

时频空频谱态势预测：深度特征学习视角

潘光良^{1,2}, 张颖³, 赵海涛¹, 吴启晖⁴

(1. 南京邮电大学物联网学院, 江苏 南京 210003; 2. 电子科技大学长三角研究院(湖州), 浙江 湖州 313000;
3. 南京邮电大学通信与信息工程学院, 江苏 南京 210003; 4. 南京航空航天大学电子信息工程学院, 江苏 南京 211106)

摘要: 频谱态势预测为频谱感知、决策与共享提供先验信息, 可有效缓解频谱资源紧缺问题。首先, 突破传统线性模型建模局限, 综述了深度特征学习在时频、时空和跨域频谱预测中的研究现状。然后, 以时/频/空自注意力特征学习为核心, 构建深度频谱态势预测学习三维分类框架, 并给出了关于深度时频频谱预测学习、深度时空频谱预测学习和深度跨域频谱预测学习实现的关键技术路线, 进一步在真实世界频谱数据上对关键技术的有效性进行实验分析。实验结果表明, 所提方法 1 和 2 较现有主流基线平均预测性能提升 10% (即所有评估指标平均值的最低值) 以上。

关键词: 低空智能网; 频谱态势预测; 深度特征学习; 图自注意力; Mamba; 扩散网络

中图分类号: TN92

文献标志码: A

doi: 10.11959/j.issn.1000-436x.TXXB250612

Temporal-frequency-spatial spectrum situation prediction: from the perspective of deep feature learning

Pan Guangliang^{1,2}, Zhang Ying³, Zhao Haitao¹, Wu Qihui⁴

1. School of Internet of Things, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

2. Yangtze Delta Region Institute (Huzhou), University of Electronic Science and Technology of China, Huzhou 313000, China

3. School of Communications and Information Engineering, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

4. College of Electronic and Information Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 211106, China

Abstract: Spectrum situation prediction provides prior information for spectrum sensing, decision-making, and sharing, thereby effectively alleviating spectrum resource scarcity. Firstly, the limitations of traditional linear modeling approaches were overcome, and the current research progress of deep feature learning in time-frequency, spatiotemporal, and cross-domain spectrum prediction was reviewed. Subsequently, with time, frequency, and spatial-domain self-attention feature learning as the core, a three-dimensional classification framework was established for deep spectrum situation prediction. It further presented the key technical implementation routes for deep time-frequency spectrum prediction, deep spatiotemporal spectrum prediction, and deep cross-domain spectrum prediction. Further experimental analysis was conducted on real-world spectrum data to validate the effectiveness of the key technologies. The experimental results demonstrate that the proposed methods 1 and 2 achieve an average prediction performance improvement of over 10% compared to existing mainstream baselines (i.e., the minimum value among the averages of all evaluation metrics).

Key words: low-altitude intelligent network, spectrum situation prediction, deep feature learning, graph self-attention, Mamba, diffusion network

收稿日期: 2025-12-27; 修回日期: 2026-03-18

通信作者: 潘光良, glpan@njupt.edu.cn

基金项目: 国家自然科学基金资助项目(No.62501300);江苏省高等学校基础科学(自然科学)研究基金资助项目(No.25KJB510023);绿色通信浙江省工程研究中心开放研究课题基金资助项目

Foundation Items: The National Natural Science Foundation of China (No.62501300), The Basic Science Research Higher Education Institutions in Jiangsu Province (Natural Science) (No.25KJB510023), The Open Research Project Fund of Zhejiang Provincial Engineering Research Center for Green Communications

0 引言

随着6G、低空智能网 (low-altitude intelligent network, LAIN)、物联网 (Internet of things, IoT) 等技术的快速革新, 全球对无线频谱资源的需求急剧增加, 导致有限的频谱资源日益紧张^[1-3]。传统的频谱资源分配主要采用静态分配或许可式分配, 即每个频段固定分配给特定用户群体 (如TV、军事通信等)。然而, 多项研究表明大量许可频段在时间和空间上并未被充分利用, 仍存在大量空闲的频谱资源^[4]。为缓解此问题, 认知无线电 (cognitive radio, CR) 技术应运而生。在不干扰主用户 (primary user, PU) 的前提下, 该技术通过动态感知频谱状态并合理分配次级用户 (secondary user, SU) 接入空闲频段, 从而实现频谱资源的高效利用。进一步, 对于一个认知无线网络 (cognitive radio network, CRN), 其包含频谱感知、频谱决策、频谱共享和频谱移动等功能^[5-6], 这些功能相互配合可以维护网络频谱使用秩序, 更高效地管控频谱资源^[7]。

频谱态势预测作为服务CRN电磁频谱智能管控的一项关键技术, 能够通过捕捉历史频谱测量 (如图1所示, 其呈现了马德里和鲁汶两个城市2012年10月6日实地测量的时频频谱演变情况)

的潜在规律, 推理未来频谱态势变化情况 (如空闲/忙碌、占用度、信号功率水平等参数)^[8-10]。这些参数为CRN中自适应频谱感知^[11-12]、积极的频谱迁移^[13-14]、准确的频谱决策^[15]和高效的频谱共享^[16-17]提供重要先验信息和性能增益, 从而提高网络的频谱利用率, 降低拥塞和干扰问题。准确的频谱态势预测不仅能够减少自适应频谱感知的时延和能耗, 还能帮助SU提前获知PU的活动信息并快速迁移, 从而提高动态频谱接入 (dynamic spectrum access, DSA) 的实时性与准确性, 优化频谱资源的动态分配与管理^[18-19]。

要想实现高效、准确的频谱态势预测具有极高挑战性。首先, 受频谱使用者信号特性、传播环境及电磁干扰等外部因素影响, 频谱数据呈现高度非线性, 传统线性模型, 如自回归模型 (autoregressive model, AR) 和隐马尔可夫模型 (hidden Markov model, HMM) 难以精准捕捉其使用模式特征^[20-21]。其次, 频谱数据存在时域、频域和空间域多个维度的相互依赖性, 并在某些时间段和频段存在稀疏性和频谱使用不均衡性, 给规律学习和模型建模带来困难。最后, 受硬件部署、隐私保护等因素影响, 对数据资源极端受限的目标域 (如频段、区域) 频谱态势预测充满挑战性。

深度学习 (deep learning, DL) 克服了传统线

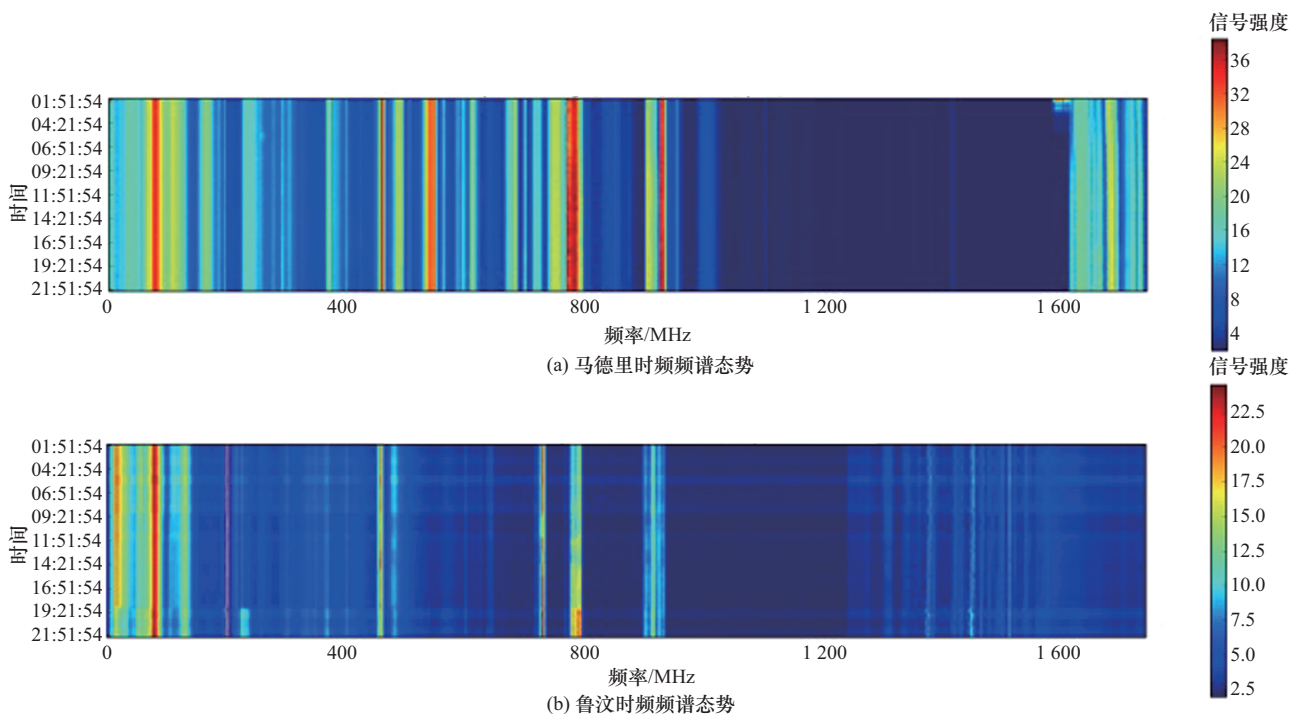


图1 真实测量的马德里和鲁汶时频频谱态势

性模型瓶颈, 凭借其在自动提取非线性特征、多维度数据处理和跨域自适应深度特征迁移方面的优势, 为解决频谱态势预测中非线性特征提取、时频空依赖性学习以及跨域知识迁移提供新的解决方案^[22]。然而, 现有研究仍存在模型复杂度高、长期预测精度差以及跨域迁移能力弱等问题。

基于上述背景与 3 类关键挑战, 本文主要贡献包括: 构建时频、时空与跨域的时频空频谱态势预测三维分类体系; 提出以自注意力为核心的深度频谱态势预测学习框架, 突破传统线性模型的预测局限性; 给出图自注意力、图扩散网络和多源域知识迁移在时频、时空与跨域频谱预测中的关键技术实现方案; 在一个真实世界的频谱数据集上验证了关键技术的有效性。

1 国内外研究现状

DL 源于 Pitts 和 McCulloch 在 20 世纪 40 年代提出的“神经元模型”雏形, Geoffrey Hinton 在 2006 年提出深度置信网络 (deep belief network, DBN) 后进入快速发展期, 直到今天火热的大语言模型 (large language model, LLM)^[23]。DL 通常为多层神经网络的组合, 设 \mathbf{x} 为输入向量, \mathbf{y} 为模型输出, 对于具有 L 层的神经网络, 第 l 层的计算可表示为

$$\mathbf{h}^{(l)} = f(\mathbf{W}^{(l)}\mathbf{h}^{(l-1)} + \mathbf{b}^{(l)}), l = 1, 2, \dots, L \quad (1)$$

其中, $\mathbf{h}^{(0)} = \mathbf{x}$ 为输入向量, $\mathbf{h}^{(l)}$ 为第 l 层的输出, $\mathbf{W}^{(l)}$ 和 $\mathbf{b}^{(l)}$ 分别为第 l 层的权重与偏置, $f(\cdot)$ 为激活函数 (如 ReLU、Tanh), 模型输出为 $\mathbf{h}^{(L)} = \mathbf{y}$ 。近年来, 基于 DL 的频谱态势预测方法在电磁频谱认知学习领域受到国内外学者广泛关注。下面分别从时频、时空与跨域频谱预测 3 个方面介绍应用 DL 的研究现状。

1.1 时频频谱预测

时频频谱预测主要着眼于捕捉频谱数据的时间依赖性与频段间的相关性, 常用模型包括循环神经网络 (recurrent neural network, RNN)、卷积神经网络 (convolutional neural network, CNN) 及其结合体。在应用 RNN 中, 文献[24]采用长短时记忆 (long short-term memory, LSTM) 网络构建预测模型, 以学习频谱序列潜在的时间依赖性。文献[25]在真实采集的 Wi-Fi 数据上采用 LSTM 网络处理 ISM 频段的突发性变化。文献[26]利用 2D-LSTM 探索频谱的时频双维度频谱模式规律以提高频谱占用

预测精度。文献[27]提出了一种双向 LSTM 融合注意力的多频段频谱预测方法。文献[28]进一步以双向 LSTM 网络为学习核心, 设计增强生成对抗网络 (generative adversarial network, GAN) 实现轻量级多频段频谱预测。此外, 针对 LSTM 的收敛问题, 文献[29]提出了 Kandeepan-Niranjana 型网络初始化方法以加速训练并提升预测效果。在应用 CNN 中, 文献[30]利用时间卷积网络 (temporal convolutional network, TCN) 构建编-解码结构来预测大规模无线电频谱使用情况, 以提高当前的频谱分配效率。为实现面向高频通信的时频频谱预测, 文献[31]采用多尺度残差卷积模块学习不同尺度的时频相关性并聚合其学习特征。文献[32]提出了一种联合 CNN 和门控记忆单元 (gated recurrent unit, GRU) 名为双重卷积门控循环单元 (dual convolution gated recurrent unit, DCG) 的学习系统, 实现不需要先验信息的多频段频谱预测。文献[33]将多频段数据构造为图结构, 结合图卷积网络 (graph convolutional network, GCN) 与 GRU 进行时频特征提取, 以实现高精度时频频谱预测。文献[34]则通过图对比学习与高斯混合模型进行多尺度特征融合实现频谱预测。

尽管上述方法在短期预测与局部频谱使用模式学习上取得了成效, 但仍存在诸多局限。例如, LSTM 网络隐藏单元规模增长导致计算与存储开销显著, 特定的门结构在时间依赖性学习上难以突破长期预测累积误差问题。CNN 擅长处理局部特征但弱于捕捉长距离全局依赖关系, 且其平移不变性在处理不同频率成分位置时可能丢失关键信息。因此, 如何设计低复杂度深度网络精准捕捉频谱序列的长距离关系、全局时频依赖性充满挑战。

1.2 时空频谱预测

时空频谱预测更侧重于捕捉频谱数据的时空相关性, 通常采用融合网络来捕捉这种时空相关性。例如, 文献[35]提出的卷积 LSTM (convolutional LSTM, ConvLSTM) 用于长期频谱预测以辅助频谱用户实现准确的 DSA。文献[36]根据时间亲近性、日周期性及周周期性采用 3 个 ConvLSTM 改进型模块分别学习这些特征信息并聚合其输出以增强预测精度。文献[37]结合 CNN 与卷积残差网络 (residual network, ResNet) 短期预测大规模区域频谱态势, 以缓解 CNN 逐层特征传递中

的梯度消失问题。文献[38]则将 Transformer 与 CNN 相结合用于实现长期时频空频谱预测,通过整合卷积、自注意力和前馈网络捕捉局部特征,兼顾全局关系。

实现高精度时空频谱预测不仅依赖先进的深度预测模型,还需要高质量的训练数据。针对稀疏部署的频谱传感器(spectrum sensor, SS)带来的数据缺失问题,现有研究常采用空间插值方法进行频谱地图重构。文献[35-36,38]基于逆距离空间插值填补缺失数据,文献[37]则采用邻近插值以重构大规模区域的频谱矩阵,但这些方法在复杂遮挡或严重阴影效应下重构精度受限。为此,文献[39]将无线电地图区域分解并用自编码器建模以缓解泛化难题。文献[40]结合非参数插值与多线性秩块性张量分解提出了一种受不确定性约束的求解器。文献[41]将最大似然估计引入块张量分解与深度生成模型,构建了一种适用于多类无线电地图的量化频谱重构框架,提升对阴影效应的鲁棒性。

由此可见,目前时空频谱预测研究多通过堆叠或组合现有网络以提升模型性能,但此类做法往往会导致模型的网络复杂度激增与训练成本上升,难以兼顾局部与全局特征的有效建模和模型结构的低复杂度设计。此外,借鉴文献[39-41]的设计思路,开发复杂度和精度均衡的频谱地图重构方法同样重要。

1.3 跨域频谱预测

跨域频谱预测旨在将源域(如频段或空间域)中学到的相关性知识迁移到目标域。对于跨频段预测,文献[42]提出了基于GAN与迁移学习(transfer learning, TL)的数据增强框架,通过相似性度量选取与目标频段相近的源数据对GAN进行预训练,通过扩充目标频段的训练数据来提高迁移性能。在此基础上,文献[43]采用SDC-GAN模型,主要聚焦于选取并扩充与目标带差异最小的源样本以提高迁移效率。文献[44]则结合注意力机制与LSTM设计融合网络,并提出共享模式学习器与自适应权重损失的TL方法以解决数据极端缺失问题。文献[45]分析评估不同频段之间的差异,利用非目标带数据构建元学习(meta learning, ML)数据集,再通过ML找到模型参数的最优分布,并训练模型将其迁移到目标带实现预测。

对于跨域频谱预测,目前相关研究工作较少,

现有研究多来自其他领域(如跨时空交通流量预测)。例如,文献[46]提出的时空自适应网络将数据丰富城市的时空知识迁移到数据稀缺城市,采用空间对抗自适应模块捕捉源城市与目标城市空间域的不变相关性。文献[47]利用域对抗图神经网络(graph neural network, GNN)缓解城市间分布差异,并通过全局时空注意力来提取可迁移知识。文献[48]提出了一种物理引导的多源域GAN,将多个交通区域可转移网络流量模式迁移到目标区域以提高预测精度。

总体来看,跨域频谱预测的主流研究策略是通过增强目标域数据量或迁移相关域知识来提升性能,但现有跨频段方法多依赖于利用已有网络来设计相对简单的迁移策略,可能会带来负面知识。跨空域频谱预测研究尚处于起步阶段,仅能借鉴其他领域的方法,且现有工作聚焦于单一域到单目标域的知识迁移,忽视了多源域知识迁移的研究。因此,如何设计解决跨域频谱预测的高性能源域不变相关性迁移网络以及高效多域自适应知识迁移方法仍是亟待突破的难题。

2 深度频谱态势预测学习框架

为了解决以上在时频频谱预测、时空频谱预测和跨域频谱预测中的关键挑战,本文以自注意力学习、张量分解和TL等为理论基础,构建深度频谱态势预测学习框架来解决这些挑战,具体结构和内在关联如图2所示。该框架从多维频谱特征学习难度逐级提升与应用场景复杂度递进两个维度,对3个子框架进行理论阐述:时频频谱预测主要针对频谱数据在时间与频率维度上的耦合关系建模,是整个框架的基础层;在时频建模基础上,时空频谱预测进一步引入空间维度,将频谱预测问题拓展为三维张量建模问题;跨域频谱预测在前两个子框架完成域内特征学习基础上,进一步解决目标域训练数据不足问题。下面将具体介绍每一种频谱态势预测学习子框架。

时频频谱态势预测的核心机理在于挖掘频谱数据在时间和频率维度上的相关性。在未来的6G无线网络中,大量无线设备频繁接入频谱导致某些频段出现拥塞和干扰,而某些频段又过于空闲。如果SU可以在不干扰PU的前提下动态识别并接入空闲频段,不仅可以提高频谱利用率,还可以

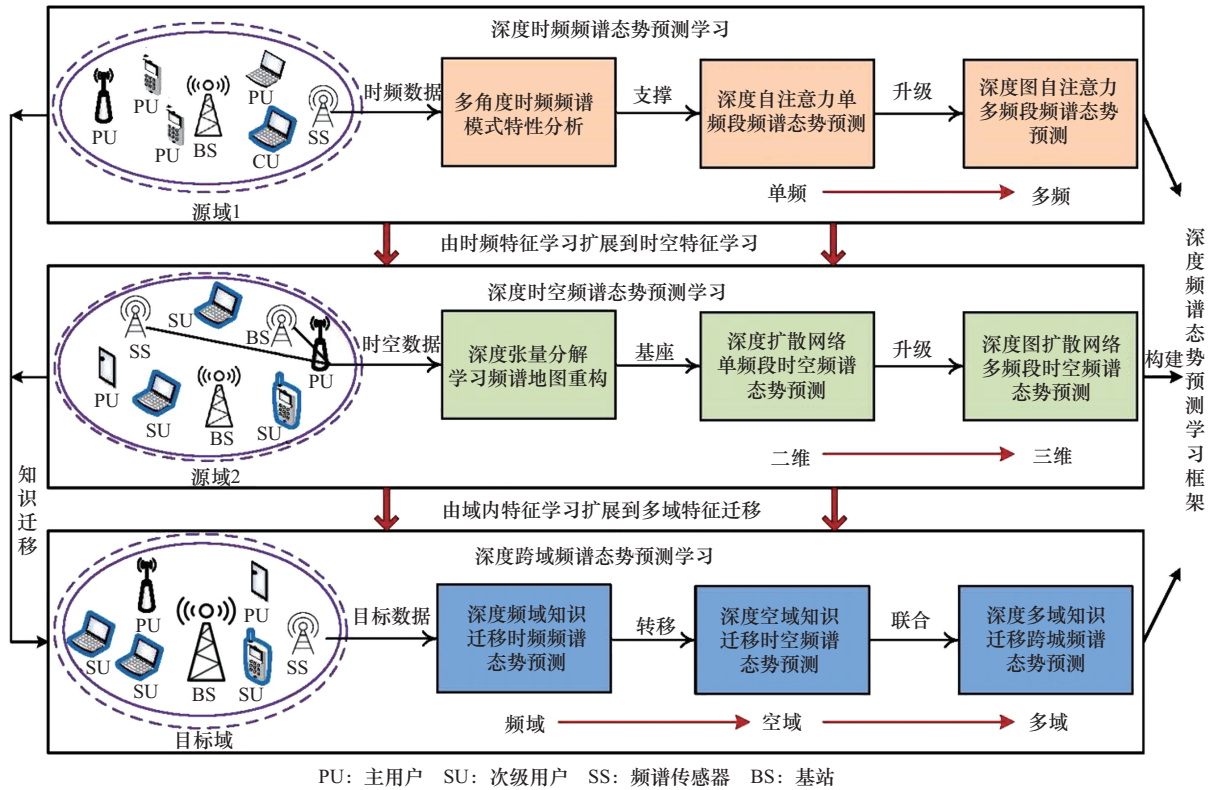


图2 深度频谱态势预测学习框架

减少干扰。实现这一目标的关键在于SU能够提前感知未来频段的占用状态，通过时频频谱预测发现空闲频段并优化接入策略。为此，本文设计了深度时频频谱态势预测学习框架。首先，频谱使用模式在不同时间段和频段表现出动态差异，通过多角度对频谱数据的时频模式特性进行分析，确认其存在潜在相关性，保证时频频谱态势预测的“可预测性”。在保证“可预测性”的基础上，该框架利用自注意力长距离的上下文学习能力和不同位置的动态权重分配能力学习长期的频谱使用模式变化规律，并能够关注到重要变化的趋势信息，实现准确的单频段频谱态势预测，帮助SU根据自身需求选择快速接入还是长期接入使用的频段。当所用频段极度拥挤时，为了能够更高效、更充分地利用频谱资源，设计深度图自注意力多频段频谱态势预测框架。该框架将多频段频谱数据构造为图结构，然后利用自注意力机制动态学习频谱数据的长期时频依赖性。在此过程中，该框架对邻居节点自适应加权聚合，根据语义相关性自主选择有用的邻居信息。通过预测未来多个频段的频谱态势，可以为SU提供更多的选择，还可帮助频谱管理者合理地分配频谱资源。

时空频谱态势预测在时频维度的基础上扩展到时频空域，不同于时频域，空间域的引入导致频谱使用模式具有复杂的时频空依赖性，如城市与郊区、不同功能区之间的频谱使用模式存在显著差异。准确的时空频谱态势预测可以为频谱管理者提供整个空间域的全方位频谱使用模式情况，进而帮助其进行更合理的频谱资源共享和动态分配。为此，本文设计了深度时空频谱态势预测学习框架。首先，受限于硬件部署和测量成本，频谱传感器无法遍布整个空间域，用于时空频谱态势预测的历史频谱测量是稀疏缺失的，同时横跨时频空3个维度。该框架利用张量分解建模时频空频谱数据，并结合DL网络重构时空频谱地图。一方面，张量分解可降低频谱数据维度，提高模型的可解释性；另一方面，DL网络可通过发挥其非线性处理优势来优化分解的模块数据。基于重构的时空频谱态势数据，针对单频段时空频谱态势预测，该框架利用扩散网络得天独厚的优势，通过逐步还原未来状态的潜在分布，可以更好地刻画频谱使用模式的时间演化与空间扩散的耦合规律^[49]。进一步，深度扩散频谱预测网络不直接回归未来值，而是生成未来分布。所学习的重构数据毕竟是非真实值，存在噪声与异常，而该框架在

训练过程中主动加入噪声,具有天然的去噪和去异常能力。再进一步,该框架借助前面用到的多频段图结构设计思想,将图引入多频段时频空频谱态势预测中。同样将多个频段的时空频谱图构造为图结构,然后利用深度扩散网络学习时频空频谱图相关性。

前两个子框架中解决域内频谱态势预测问题,在某些极端条件下(如引言中所提到的硬件部署受限),导致目标预测域可利用的频谱数据较少,而相关域恰有丰富可利用的频谱数据。为此,本文设计了深度跨域频谱态势预测学习框架。首先,不同频段间虽然相互关联,但其相关程度存在显著差异。深度频域知识迁移可以准确划分不同频段对目标频段的可迁移性,将源频段的不变时频相关性知识最大化迁移到目标频段,有利于提升目标域时频频谱态势预测准确率。进一步,在时空频谱态势预测中,不同空间域间虽然相互关联,但其相关程度不同。空间域的差异性不同于频域的差异性,其空间环境受多方面因素影响,是动态多变和极其复杂的,且相关程度远低于频段间的相关性。深度空域知识迁移可以准确划分不同空间域对目标域的可迁移性,可以将源空间域的不变时空相关性知识最大化迁移到目标空间域。前面两种方法是将单域相关知识进行迁移,知识的单一性注定了其性能的一般性。在更复杂的场景下,目标域的相关知识可能不只来自相关程度最高的源域。深度多域知识迁移在最小化负面知识的前提下,尽可能利用多个域的相关知识来提高目标域性能。由于多个域的相关特征具有差异性,通过特征对齐和领域自适应来聚合多域特征,提高迁移效率。

3 深度频谱态势预测学习关键技术实现

本节围绕第2节提出的深度时频频谱态势预测学习、深度时空频谱态势预测学习与深度跨域频谱态势预测学习子框架,给出对应的关键技术实现路线,为深度频谱态势预测学习框架提供技术指导。

3.1 图自注意力建模时频频谱态势预测

针对多频段频谱数据中存在的长期时频依赖关系难以有效建模的问题,本节构建频段关联图结构并融合 Transformer 与 Mamba 网络,实现对频谱序列全局依赖关系的高效建模,在提升频谱预测精度

的同时降低长序列建模复杂度。如图2中的源域1所示,在一个兴趣区域内,存在一个由若干PU和SU组成的CRN。在该网络中,任意给定的一个频谱传感器被用于测量 F 个频段上的信号功率,并将接收信号强度(received signal strength, RSS)实时上传至数据存储中心(data storage center, DSC)。该频谱传感器的频谱测量可表示为矩阵 $\mathbf{X}_{1:T; 1:F} \in \mathbb{R}^{T \times F}$,其中 T 表示频谱测量的时隙范围, F 表示频谱测量的频段范围。那么,基于历史的时频测量数据 $\mathbf{X}_{1:T; 1:F}$,时频频谱态势预测问题可表示为:

$$\hat{\mathbf{X}}_{T+1:T+M; 1:F} = \arg \max_{\mathbf{X}_{1:T; 1:F}} p(\mathbf{X}_{T+1:T+M; 1:F} | \mathbf{X}_{1:T; 1:F}) \quad (2)$$

其中, $\hat{\mathbf{X}}_{T+1:T+M; 1:F} \in \mathbb{R}^{M \times F}$ 和 $\mathbf{X}_{T+1:T+M; 1:F} \in \mathbb{R}^{M \times F}$ 分别为 F 个频段未来 $T+1$ 到 $T+M$ 时隙的预测值和真实值。当 $F=1$ 时为单频段预测,主要捕捉时间相关性,数据维度较低;当 $F>1$ 时则为多频段预测,主要捕捉时频相关性,数据维度较高。由于短期与长期预测在不同场景有不同的理解,本文假设 $M < T$ 表示短期预测, $M \geq T$ 表示长期预测。

在图自注意力建模之前,该子框架首先多角度分析频谱数据的时频模式特性,验证其“可预测性”并设计针对性深度预测网络。具体通过皮尔逊相关系数、可视化分析等方法,识别频谱数据的时频相关性,观察其趋势、季节性和周期性^[8]。进一步,还可以利用自相关函数和偏自相关函数分析滞后关系,识别频谱数据的周期性特征和长期依赖性。在此基础上,深度时频频谱态势预测学习框架设计了一种多模式自注意力机制的单频段频谱预测技术,具体结构如图3所示,其中左侧的STL分解频谱测量序列为不同时间尺度的频谱变化特征,后将3类分量分别输入自注意力模块以增强模型对不同模式频谱行为建模能力;右侧的多头注意力通过多组注意力头并行学习不同子空间特征,从而捕捉多尺度时频依赖关系。该技术先采用局部回归季节趋势分解(seasonal-trend decomposition using LOESS, STL)把频谱测量 $\mathbf{X}_{1:T; f}$ 分解为趋势 $\mathbf{T}_{1:T; f}$ 、季节性 $\mathbf{S}_{1:T; f}$ 和残差 $\mathbf{R}_{1:T; f}$ 三部分(其中 f 为任意某一频段),再将上述分量特征信息输入对应的自注意力模块进行特征学习。

以趋势部分为例,首先对 $\mathbf{T}_{1:T; f}$ 进行嵌入编码为查询 \mathbf{Q} (维度定义为 d_q)、键 \mathbf{K} ($d_k, d_k = d_q$)和

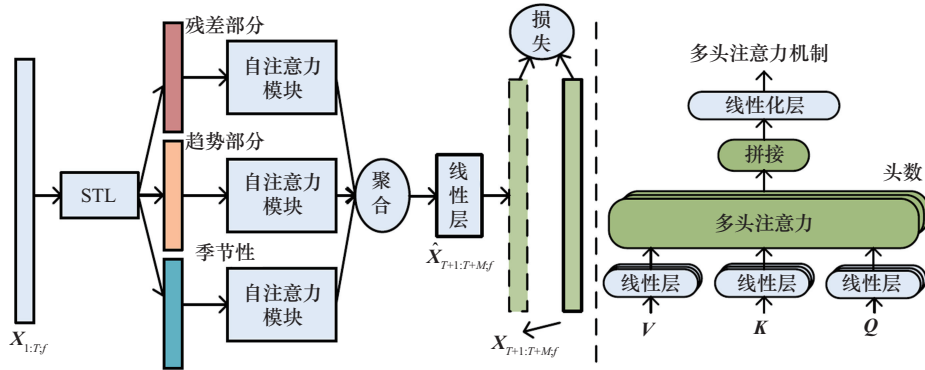


图3 多模式自注意力机制的单频段频谱预测技术

值 $V(d_v)$ ，那么单头注意力可表示为：

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{d_k}\right)\mathbf{V} \quad (3)$$

其中， $\text{Softmax}(\cdot)$ 为归一化的 Softmax 函数。进一步，多头注意力 (o 头) 表示为：

$$\text{MHead}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \mathbf{W}_{\text{out}} \text{Concat}(\text{head}_1, \dots, \text{head}_o) \quad (4)$$

其中， $\text{head}_i = \text{Attention}(\mathbf{Q}_i \mathbf{W}_i^Q, \mathbf{K}_i \mathbf{W}_i^K, \mathbf{V}_i \mathbf{W}_i^V)$ ， $i \in \{1, \dots, o\}$ ， $\mathbf{W}_{\text{out}} \in \mathbb{R}^{o d_v \times d_{\text{model}}}$ 为最后线性层的输出投影 (d_{model} 为模块的输入维度)， $\mathbf{W}_i^Q \in \mathbb{R}^{d_{\text{model}} \times d_k}$ 、 $\mathbf{W}_i^K \in \mathbb{R}^{d_{\text{model}} \times d_k}$ 和 $\mathbf{W}_i^V \in \mathbb{R}^{d_{\text{model}} \times d_v}$ 为经过线性权重矩阵，即模型的优化参数。经过3个模块的输出特征以拼接的方式进行聚合，最后通过一个线性层输出未来频谱态势。所设计模型在预测之前需要进行训练，训练目标则为最小化预测值与真实值之间的均方误差 (mean square error, MSE)。

$$L_{\text{MSE}} = \|\hat{\mathbf{X}}_{T+1:T+M;f} - \mathbf{X}_{T+1:T+M;f}\|_2^2 \quad (5)$$

与单频段预测相比，多频段预测需要处理更高维度的数据及复杂的时频相关性。为此，该框架设

计了一种融合图 Transformer 与 Mamba 网络的多频段频谱态势预测技术，具体结构如图4所示。

将多频段频谱数据构造为图结构，定义每个频段为图节点，频段间的相关性为图的边。重构的频谱数据是无向图结构数据，常用邻接矩阵表示。任意两个节点间的相关性用皮尔逊相关系数 ρ 表示^[50]。

$$\rho = \frac{\sum_{i=1}^T (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^T (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^T (y_i - \bar{y})^2}} \quad (6)$$

其中， x_i 和 y_i 分别为两个不同频段的第 i 个时隙测量值， \bar{x} 和 \bar{y} 分别为过去 T 个时间段的平均值，相关系数范围为 $[-1, 1]$ ，表示相关强度。

进一步，引入小波变换提取多尺度特征 (具体参考文献^[51])，并采用希尔伯特-黄变换 (Hilbert-Huang transform, HHT) 进行去噪 (具体参考文献^[52])，以捕捉局部与全局模式，并将这三部分输入图 Transformer 和 Mamba 网络^[53]。为了在图结构上实现注意力计算，通常采用邻域约束的注意力机制，即每个节点仅与其邻居计算注意力权重，而非全局计算。

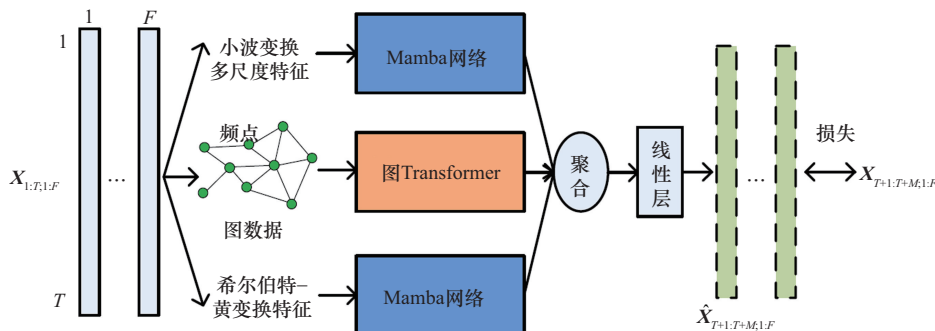


图4 基于图 Transformer 和 Mamba 网络的多频段频谱态势预测技术

$$\alpha_{ij} = \frac{\exp\left(\text{leakyReLU}\left(\mathbf{a}^T\left[\mathbf{W}_h\mathbf{h}_i\|\mathbf{W}_h\mathbf{h}_j\right]\right)\right)}{\sum_{k \in \mathcal{N}(i)} \exp\left(\text{leakyReLU}\left(\mathbf{a}^T\left[\mathbf{W}_h\mathbf{h}_i\|\mathbf{W}_h\mathbf{h}_k\right]\right)\right)} \quad (7)$$

其中, \mathbf{h}_i 和 \mathbf{h}_j 分别为图中节点 i 和节点 j 的特征向量, \mathbf{W}_h 为特征变换的权重矩阵, $\mathcal{N}(i)$ 为节点 i 的邻居集合, $\|$ 为向量拼接操作, α_{ij} 为注意力系数, 表示节点 i 关注邻居节点 j 的程度。由于频谱图数据的节点是无序的, 需采用特殊的编码方式, 如基于拉普拉斯特征向量的位置 \mathbf{P}_i 编码为:

$$\mathbf{P}_i = \mathbf{U}\mathbf{A}^{-\frac{1}{2}}\mathbf{U}^T\mathbf{e}_i \quad (8)$$

其中, \mathbf{U} 为拉普拉斯矩阵的特征向量, \mathbf{A} 为特征值矩阵。

引入 Mamba 网络, 利用连续时间状态空间模型 (state space model, SSM) 建模频谱序列, 并通过结构化状态空间序列 (structured state space sequence, S4) 机制优化计算效率, 它通过对状态空间矩阵 \mathbf{A} 的结构进行参数化, 将传统 SSM 转化为一种高效、线性的序列处理机制, 具体参考文献[53]。最后, 将学习到的特征拼接聚合后输入线性层投影得到未来频谱态势。

3.2 图扩散网络建模时空频谱态势预测

针对时空频谱数据存在空间采样稀疏以及频谱演化过程具有随机扩散特性的建模难题, 本节提出了融合图扩散网络与生成对抗重构模型的时空频谱态势预测技术, 有效刻画频谱演化的时空耦合动态过程, 提高预测鲁棒性与泛化能力。与时频频谱态势预测场景类似, 如图2中的源域2所示, 考虑一个由若干 PU 与 SU 组成的 CRN。在 CRN 中, 不是考虑任意给定的一个传感器, 而是考虑通过 Q 个稀疏分布的传感器来测量该兴趣区域 F 个频段上的信号功率。这些频谱测量可用一个三维张量 $\mathbf{X}_{\text{sparse}} \in \mathbb{R}^{N \times N \times F}$ 表示, 其中 $N \times N$ 为整个区域的长宽尺寸。由于实际的部署环境受地理障碍物和硬件成本影响, 无法实现在每个地理位置的全覆盖。因此, 采集数据的缺失与时空频谱态势预测需要大量数据学习形成矛盾, 故采用 Transformer 构建 GAN 重构频谱地图。

该子框架将重构模型命名为 TransGAN, 其包括生成器 (G) 与判别器 (D)。生成器将稀疏分布的频谱测量 $\mathbf{X}_{\text{sparse}}$ 线性投影为补丁 Token: $\mathbf{X}_0 =$

$\text{Linear}\left(\mathbf{X}_{\text{sparse}}\right)$ 。这些 Token 经过 L 层 Transformer 块 (采用图3中的多头注意力机制) 的特征提取后进入一个多层感知机 (multi-layer perceptron, MLP), 得到最终重构频谱地图补丁 $\mathbf{X}_L = \text{Transformer}\left(\mathbf{X}_{L-1}\right)$ 。最后, 通过补丁重组得到频谱地图 $\mathbf{I} = \text{Patch}_{\text{Reconstruction}}\left(\mathbf{X}_L\right)$ 。判别器则将重构频谱地图和真实频谱地图划分为补丁 Token: $\mathbf{X}'_0 = \text{PatchEmbedding}\left(\mathbf{I}\right)$, 再经级联 Transformer 提取全局特征 $\mathbf{X}'_L = \text{Transformer}\left(\mathbf{X}'_{L-1}\right)$ 。最后, 基于这些特征采用全连接 MLP, 即 $\text{MLP}_{\text{Head}(\cdot)}$ 进行二分类输出一个真假的概率 $[0,1]$ 。

$$\hat{y} = \text{MLP}_{\text{Head}\left(\mathbf{X}'_L\right)} \quad (9)$$

TransGAN 的训练优化目标为让生成器生成的频谱地图尽可能真, 让判别器尽可能准确地判断频谱地图真伪, 可认为是一个零和博弈过程, 其具体可表示为:

$$\min_G \max_D (D, G) = \mathbb{E}_{x \sim p_{\text{data}}} [\ln D(x)] + \mathbb{E}_{z \sim p_z} [\ln(1 - D(G(z)))] \quad (10)$$

其中, x 和 z 分别为真实频谱样本和符合高斯分布的噪声向量。

经过以上过程可得到重构频谱地图 $\mathbf{X} \in \mathbb{R}^{N \times N \times F}$ 。给定 T_{st} 个时隙的 F_{st} 个频段历史时空频谱测量为 $\mathbf{X}_{1:T_{st}; 1:F_{st}}^{\text{map}}$, 时空频谱态势预测问题可表示为:

$$\hat{\mathbf{X}}_{T_{st}+1:T_{st}+M_{st}; 1:F_{st}}^{\text{map}} = \arg \max_{\mathbf{X}_{1:T_{st}+1:T_{st}+M_{st}; 1:F_{st}}^{\text{map}}} p\left(\mathbf{X}_{T_{st}+1:T_{st}+M_{st}; 1:F_{st}}^{\text{map}}, \mathbf{X}_{1:T_{st}; 1:F_{st}}^{\text{map}}\right) \quad (11)$$

其中, $\hat{\mathbf{X}}_{T_{st}+1:T_{st}+M_{st}; 1:F_{st}}^{\text{map}}$ 和 $\mathbf{X}_{1:T_{st}; 1:F_{st}}^{\text{map}}$ 分别表示 F_{st} 个频段未来 $T_{st} + 1$ 到 $T_{st} + M_{st}$ 时隙的预测频谱地图和实际频谱地图。当 $F_{st} = 1$ 时, 为单频段预测; 当 $F_{st} > 1$ 时, 为多频段预测。

对于单频段时空频谱态势预测, 该子框架设计了一种基于扩散网络的单频段时空频谱态势预测技术, 其具体实现流程如图5所示。

首先, 采用传统 CNN 提取整个空间域的空间相关性。

$$\mathbf{H}^{(l+1)} = \sigma\left(\mathbf{W}^{(l)} * \mathbf{H}^{(l)} + \mathbf{b}^{(l)}\right) \quad (12)$$

其中, $*$ 为二维卷积操作, $\mathbf{H}^{(l)}$ 为第 l 层的特征图。然后, 采用 Transformer 捕捉长期的时间相关性,




图5 基于扩散网络的单频段时空频谱态势预测技术

同时引入马尔可夫过程，逐步向频谱数据中添加噪声实现向前扩散。

$$q(\mathbf{X}_t|\mathbf{X}_{t-1}) = \mathcal{N}(\mathbf{X}_t; \sqrt{1 - \beta_t} \mathbf{X}_{t-1}, \beta_t I) \quad (13)$$

其中， \mathbf{X}_t 为某一时刻 t 的频谱地图数据， β_t 为噪声调节参数，经过 T_d 轮迭代后， \mathbf{X}_T 近似服从标准正态分布 $\mathcal{N}(0, I)$ 。向后扩散通过CNN和Transformer构造的时空预测模型 f_θ 逐步去噪。

$$p_\theta(\mathbf{X}_{t-1}|\mathbf{X}_t) = \mathcal{N}(\mathbf{X}_{t-1}; \mu_\theta(\mathbf{X}_t, t), \sigma_\theta^2 I) \quad (14)$$

其中， $\mu_\theta(\mathbf{X}_t, t)$ 为时空预测模型的均值， σ_θ 为可学习的噪声参数，并通过最大化似然函数引入变分推断证据下界来优化 f_θ 使它逐步去噪，预测未来的时空频谱态势。模型训练的损失函数为MSE外加KL (Kullback-Leibler)散度来约束扩散模型的分布。

$$\min_{\theta} \|\hat{\mathbf{X}}_{T_{st}+1:T_{st}+M_{st};f}^{\text{map}} - \mathbf{X}_{T_{st}+1:T_{st}+M_{st};f}^{\text{map}}\|_2^2 + \lambda D_{\text{KL}}(q(\mathbf{X}_t|\mathbf{X}_{t-1}) \| p_\theta(\mathbf{X}_{t-1}|\mathbf{X}_t)) \quad (15)$$

对于多频段时空频谱态势预测，频率维度的增加导致处理数据难度显著提升，普通模型难以兼顾复杂度与预测精度。为此，该子框架将普通的CNN替换为GCN，定义不同位置和频段为节点，采用3.1节中的皮尔逊相关系数作为图结构的边，级联GCN捕捉空间相关性特征可表示为：

$$\mathbf{H}^{(l+1)} = \sigma \left(\tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \mathbf{D}^{-\frac{1}{2}} \mathbf{H}^{(l)} \mathbf{W}^{(l)} \right) \quad (16)$$

其中， $\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}$ 为邻接矩阵， $\tilde{\mathbf{D}}$ 为度矩阵， $\mathbf{W}^{(l)}$ 为学习参数， σ 为激活函数。此外，该子框架可利用知识蒸馏 (knowledge distillation, KD) 技术降低由多频段频谱数据处理带来的模型复杂度^[54-55]。通过KL散度最小化学生模型 (实际用来预测) 和教师模型 (多频段时空频谱态势预测模型) 的预测分布误差。教师模型不仅提供最终频谱预测态势，还提供中间频谱特征，让参数更少的学生模型学习更好的时空表示。

$$\mathcal{L}_{\text{feature}} = \frac{1}{L} \sum_{l=1}^L \|\mathbf{F}_T^{(l)} - \mathbf{F}_S^{(l)}\| \quad (17)$$

其中， $\mathbf{F}_T^{(l)}$ 和 $\mathbf{F}_S^{(l)}$ 分别为教师和学生模型在第 l 层的特征图。

3.3 多源域知识迁移学习建模跨域频谱态势预测

针对目标频段或目标区域频谱数据匮乏以及不同频谱域之间分布差异显著导致模型泛化能力不足的问题，本节提出了基于多源域知识迁移学习的跨域频谱态势预测技术，实现跨频段与跨空间域知识共享，提升低样本场景下预测性能。深度跨频段时频频谱预测学习和深度跨空域时空频谱预测学习分别利用相关频段和源区域 (如图2中的源域1和源域2) 的相关性知识来提升目标域的预测精度，且目标域通常数据量较少。进一步，多源域辅助目标域预测则相对灵活，允许多个相关频段或多个源区域的相关性知识协同辅助目标域预测。

在跨频段时频频谱预测中，定义源频段特征数据为 $\mathbf{X}_S \in \mathbb{R}^{m \times d_s}$ ，对应的未来频谱态势为 \mathbf{Y}_S ，目标频段特征数据为 $\mathbf{X}_T \in \mathbb{R}^{n \times d_t}$ ，对应的未来频谱态势为 \mathbf{Y}_T 其中， m 和 d_s 分别为源频段的数据量和频段数， n 和 d_t 分别为目标频段的数据量和频段数，且 $m \gg n$ 。预测目标是构建一个预测模型 $f(\cdot)$ 来最小化目标频段的预测误差。

$$\min_f \mathbb{E}_{(\mathbf{X}_T, \mathbf{Y}_T) \sim P_T} [\mathcal{L}(\mathbf{Y}_T, f(\mathbf{X}_T))] \quad (18)$$

其中， $\mathcal{L}(\cdot, \cdot)$ 为损失函数MSE。为缩小源域与目标域的数据分布差异，该子框架设计了一个多模态融合学习跨频段频谱态势预测技术，具体结构如图6所示，其中，A部分为多模态特征编码，通过Transformer编码器提取时序依赖特征，通过图编码器提取频谱拓扑结构相关性特征；B部分为跨域特征融合与对齐，通过特征拼接及分布匹配实现源域与目标域特征对齐；C部分为利用融合特征输入预测器，生成目标频段未来频谱态势结果。具体流程为源频段和目标频段数据由原始数据和构造图数据构成，再将其分别输入自注意力Transformer架构的系列编码器和图编码器 (如图6中A部分) 中。经两个编码器提取时间依赖性和空间依赖性特

征后, 将两组特征进行对齐拼接 (如图 6 中 B 部分)。拼接后的特征被输入由 Transformer 构成的预测器 (如图 6 中 C 部分) 中。

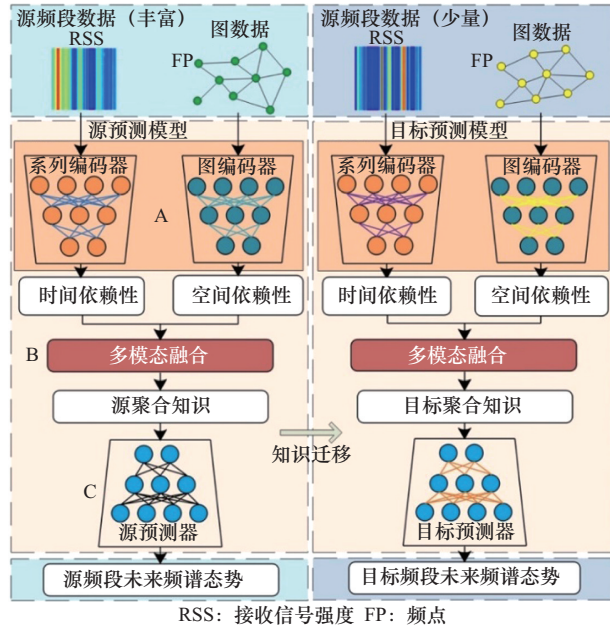


图 6 多模态融合学习跨频段频谱态势预测技术

通过此预测模型的特征变换映射 $\Phi(\cdot)$, 可以缩短源频段和目标频段在特征空间中的距离。

$$\mathbf{Z}_S = \Phi(\mathbf{X}_S), \mathbf{Z}_T = \Phi(\mathbf{X}_T) \quad (19)$$

其中, \mathbf{Z}_S 和 \mathbf{Z}_T 分别为源频段和目标频段的特征嵌入。为减少跨频段分布差异, 该技术首先使用最大均值差异 (maximum mean discrepancy, MMD) 作为域对齐损失:

$$\mathcal{L}_{\text{MMD}} = \|\mathbb{E}[\mathbf{Z}_S] - \mathbb{E}[\mathbf{Z}_T]\| \quad (20)$$

或采用生成对抗训练, 根据式(10)可得到:

$$\min_G \max_D \mathbb{E}_{X_S \sim P_S} [\ln D(G(X_S))] + \mathbb{E}_{X_T \sim P_T} [\ln(1 - D(G(X_T)))] \quad (21)$$

其中, $G(\cdot)$ 为特征提取网络, $D(\cdot)$ 为域判别器。然后, 在共享特征空间中, 该技术用源频段的预测模型进行预训练, 并在目标频段进行微调特征增强学习。

$$\min_f \mathbb{E}_{(X_T, Y_T)} [\mathcal{L}(Y_T, f_T(\Phi(X_T))) + \lambda \mathcal{L}_{\text{MMD}}] \quad (22)$$

其中, λ 控制 MMD 损失对优化目标的贡献。

在跨空域时空频谱预测中, 该子框架同样借鉴 3.2 节设计思路, 引入 KD 机制, 定义源域的强监督

模型作为教师网络指导目标频段的学生网络学习, 从而减少目标域的标注需求。优化目标为:

$$\mathcal{L}_{\text{KD}} = \alpha \mathcal{L}_{\text{CE}}(Y_S, f_S(\mathbf{X}_S)) + (1 - \alpha) \mathcal{L}_{\text{KL}}(f_S(\mathbf{X}_T), f_T(\mathbf{X}_T)) \quad (23)$$

其中, \mathcal{L}_{CE} 为交叉熵损失 (用于监督训练源域), \mathcal{L}_{KL} 为 KL 散度, 用于让目标域模型模仿源域模型的输出分布, α 为权重参数。该方法能够在目标域标注数据极端缺少的情况下辅助目标域的时空频谱态势预测, 同时能避免额外的生成对抗训练。

对于多源域辅助目标域频谱态势预测, 该子框架引入 ML 来优化知识迁移性能, 以提升模型的快速适应能力, 使它在目标域的少量数据上快速优化, 其优化框架可表示为

$$\theta^* = \theta - \beta \nabla_{\theta} \sum_{T_i} \mathcal{L}_{T_i}(f_{\theta - \rho \nabla_{\theta} \mathcal{L}_{T_i}}) \quad (24)$$

其中, T_i 为不同的相关域任务, θ 为模型初始参数, ρ, ε 为学习率^[56]。ML 包括内循环和外循环, 内循环针对单个源域任务进行快速参数更新, 以学习域特定特征; 外循环则综合多个源域任务更新全局模型参数, 以学习跨域共享特征。通过多源域知识迁移可进一步提升目标域预测精度。

3.4 关键参数设置与敏感性分析

本节选取多头注意力头数、噪声调节参数 β_i 和 MMD 损失权重 λ 作为关键参数设置和敏感度分析, 其他参数也按照相同方式选取。

(1) 多头注意力头数 o 。根据文献[57]并结合频谱数据维度特点, 将 o 的搜索范围设定为 [2, 4, 8, 16]。采用网格搜索方法, 在第 4 节所用数据集上对不同头数进行对比实验, 综合预测精度与计算复杂度选取最优值 $o=8$ 。当头数过小时, 模型难以捕捉复杂多频段相关性; 当头数过大时, 容易产生过拟合并增加计算开销。

(2) 式(13)中的噪声调节参数 β_i 。本文采用线性噪声调度策略, 将 β_i 设置在 $[10^{-4}, 0.02]$ 。按照文献[58]设计原则, 结合频谱数据噪声强度与空间传播特性进行调整。若 β_i 取值过小, 模型去噪能力下降; 若取值过大, 则会破坏频谱空间结构信息。

(3) 式(22)中的 MMD 损失权重 λ 。根据文献[59]将 λ 设置在 $[0.01, 1]$ 内进行搜索。采用分层网格搜索策略, 在保证目标域预测误差最小的同时控制源域迁移强度。当 λ 过小时, 跨域特征对齐作用减弱; 当 λ 过大时, 可能导致模型过度依赖源域特征。

4 仿真实验分析

4.1 性能对比


本节选取第3节中两个关键技术作为经典案例进行仿真实验分析，它们分别为基于图 Transformer 和 Mamba 网络的多频段频谱态势预测技术（算法1）和基于扩散网络的单频段时空频谱预测技术（算法2）。验证算法1和算法2的所有实验是在一台 AMD Ryzen 9 9950X 16-Core Processor (4.30 GHz) CPU, NVIDIA GeForce RTX 5090 D v2 24GB GPU, 64 GB RAM 的 PC 上实现的。基于 CUDA12.8 和 PyTorch 2.8.0 框架，使用 Python 编程语言。具体实验设置如下。

(1) 算法1实验。本文用一个来自西班牙马德里市区传感器 (ID: test_yago) 测量的真实世界频谱数据集 (参考文献[8]开放 API 地址) 来验证算法1的先进性，其频率范围为 600~640 MHz，采样间隔为 2 MHz，数据采集时间为 2021 年 6 月 1 日至 6 月 8 日，采样时间间隔为 4 min，样本总数为 10 080，训练集、测试集和验证集的划分比例为 4:1:1。算法1中的图 Transformer 网络层数为 2，映射维度为 128，头数为 8，下降率为 0.1。Mamba 网络的状态空间维度为 32，局部卷积核尺寸为 3，通道扩展倍数为 2，网络深度为 2。模型训练参数：学习率为 0.01，批处理尺寸为 4，训练轮数为 20，提前停止的耐心值为 6，采用 Adam 优化器。对比基线采用传统的 HMM^[60] 和主流的深度学习 LSTM+注意力 (LSTM-Atten)^[27] 和 Transformer^[57]。


由图7可知，在输入 96 步预测 48 步下，算法1 (MamGTrans) 的平均绝对误差 (mean absolute error, MAE) 和 MSE 全部低于基线算法。例如，算法1的 MSE 分别比 HMM、LSTM-Atten 和 Transformer 下降了 79.96%、43.95% 和 13.45%。这些结果说明算法1中的多种特征分解提取机制和图注意力 Mamba 网络的时频相关性特征捕捉能力强于 LSTM 网络的记忆单元和 Transformer 的单纯自注意力。

(2) 算法2实验。与算法1相同，本文同样采用来自西班牙马德里市区的传感器 (ID 包括 test_yago_3、test_yago、rack_3 和 rack_2，采用常用的邻近空间插值填充为 64×64 的频谱地图) 测量的真实世界频谱数据集，采样频率为 610 MHz，采样时间为 2021 年 6 月 1 日至 6 月 3 日，采样时间间隔为 1 min，样本总数为 4 800，训练集、测试集和验证集的划分比例

为 4:1:1。算法2的训练学习率为 0.001，训练轮数为 20，批处理尺寸为 4，同样采用 Adam 优化器。扩散网络采用线性噪声调度策略，起始噪声强度为 0.000 1，终止噪声强度为 0.02，扩散步数为 1 000 (即 T_d)，条件输入形式为 $(B, f, T, 64, 64)$ ，预测目标采用点预测形式。对比基线采用目前主流的深度学习网络 ConvLSTM^[35]、NN-ResNet^[37] 和 PredRNN^[61]。



(a) MAE对比结果



(b) MSE对比结果

图7 在输入 96 步预测 48 步下算法1与基线算法的预测误差对比

由图8可知，在输入 10 帧预测 10 帧下，算法2 (DiffTrans) 的平均 MSE 低于所有基线算法，同时峰值信噪比 (peak signal-to-noise ratio, PSNR) 高于所有基线算法。例如，算法2的 PSNR 分别比 ConvLSTM、NN-ResNet 和 PredRNN 高 16.47%、

7.11%和5.27%。这些结果说明算法2得益于扩散网络能够利用多阶扩散过程实现长距离时空依赖建模。由卷积和门控结构组成的基线局限于规则网格结构和局部感受野,无法刻画非欧氏空间关系。





图8 在输入10帧预测10帧下算法2与基线算法的MSE和PSNR对比

表1给出了算法1和算法2与基线算法的复杂度对比结果。由表1可知,在时频频谱态势预测中,算法1的计算复杂度高于传统线性HMM,低于主流的Transformer,从图7中可以看到算法1取得了最优的预测性能。此外,算法1及其基线算法推理时间都在秒级以内,而HMM却需要消耗更多的时间。这说明算法1实现了计算复杂度和预测性能的折中。从时空频谱态势预测中可以看出,算法2相比于其基线算法取得了最低的参数量,而推理时间都在秒级,性能相当。

表1 所提算法与基线算法的复杂度对比结果

算法	参数量/MB	推理时间/ms
HMM	忽略不计	1 639
LSTM-Atten	0.32	36
Transformer	1.40	238
MamGTrans (算法1)	0.45	100
ConvLSTM	9.06	38
NN-ResNet	13.99	29
PredRNN	6.05	27
DiffTrans (算法2)	2.5	25

4.2 消融实验

本节进行消融实验分析以验证图3和算法1中各模块设计的有效性。首先选择600 MHz频点数据,其他关于数据集的设置与算法1相同,注意力头数为4。图3模块设计的消融实验结果如图9所示。

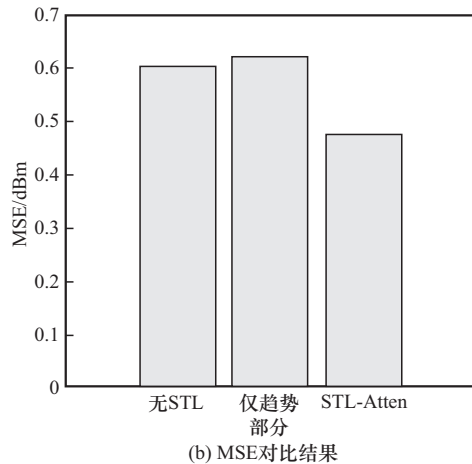
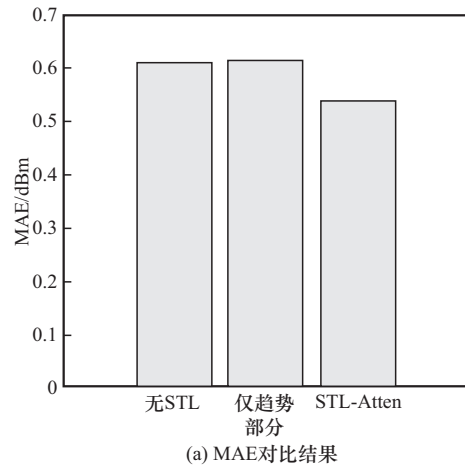


图9 在输入96步预测96步下STL-Atten(即STL+多头注意力)的消融实验对比

由图 9 可知, STL-Atten 的所有预测误差全部低于无 STL 和仅趋势部分的情况。例如, STL-Atten 的 MSE 分别比无 STL 和仅趋势部分预测模型下降了 21.18% 和 23.57%。这些结果可以说明 STL-Atten 中的 STL 机制可增强多头自注意力的学习能力, 仅趋势分解特征无法带来额外的增益。

为了说明算法 1 每个模块的独立贡献, 设计 3 组对照组: 仅 GNN、GNN+小波变换分支和 GNN+HHT。关于数据集的实验设置与算法 1 相同。算法 1 的消融实验结果如图 10 所示。





图 10 在输入 96 步预测 48 步下算法 1 的消融实验对比

由图 10 可知, 以 MAE 为例, 相比于仅 GNN, 增加小波变换分支网络后, 其 MAE 降低了 8.37%, 这说明小波变换分支网络可有效抑制频谱数据中的异常噪声, Mamba 网络保持了学习能力并降低了

模型参数量 (如表 1 所示)。以 MSE 为例, 相比于仅 GNN, 增加 HHT 分支网络后, 其 MSE 降低了 11.82%, 这说明 HHT 分支网络提取频谱数据的隐藏时频特征可有效提高模型预测性能, 沿用小波变换分支网络中用到的 Mamba 网络同样发挥作用。MamGTrans 在这些模块的共同作用下取得了最小的 MAE 和 MSE。值得注意的是, 小波变换分支网络对模型的贡献高于 HHT 分支网络。

5 结束语

本文从深度特征学习视角讨论时-频-空频谱态势预测问题。首先, 本文首次将现有频谱态势预测研究总结为时频、时空以及跨域频谱态势预测, 并综述了深度特征学习在这 3 个方向上的研究现状, 总结出 3 个迫切待解决的关键挑战。然后, 以自注意力学习机制为核心, 本文提出深度频谱态势预测学习框架为解决这 3 个关键挑战提供理论指导, 具体为深度时频频谱态势预测学习、深度时空频谱态势预测学习和深度跨域频谱态势预测学习 3 个子框架。在此框架基础上, 本文结合 KD、TL 以及 ML 等理论工具给出了 3 个子框架的关键技术路线实现思路, 并在一个真实世界数据集上验证了相关技术的有效性, 后续关于深度跨域频谱态势预测的关键技术将通过真实数据集验证分析。这些技术可具体应用在无人机 DSA、车联网资源调度等场景, 提升无线频谱资源利用率。在时频和时空预测模型中仍需降低模型计算复杂度、超大规模频谱数据下实时性有待提升, 未来计划通过模型轻量化、联邦学习来解决。

参考文献:

[1] 刘光毅, 张慧敏, 佟舟, 等. 6G 移动信息网络架构: 从通信到一切皆服务的变迁[J]. 中国科学: 信息科学, 2024, 54(5): 1236-1266.
Liu G Y, Zhang H M, Tong Z, et al. 6G mobile information network architecture: migrate from communication to XaaS[J]. Scientia Sinica (Informationis), 2024, 54(5): 1236-1266.

[2] 董超, 崔灿, 贾子晔, 等. 面向低空智能网的多维信息统一表征技术综述[J]. 电子与信息学报, 2025, 47(5): 1215-1229.
Dong C, Cui C, Jia Z Y, et al. Survey of unified representation technology of multi-dimensional information for low altitude intelligent network[J]. Journal of Electronics & Information Technology, 2025, 47(5): 1215-1229.

[3] 金立民, 王海超, 谷江春, 等. 低空具身智能频谱管控技术研究[J]. 数据采集与处理, 2025, 40(1): 45-55.
Jin L M, Wang H C, Gu J C, et al. Research on low-altitude embodied artificial intelligence-enabled spectrum management and control technology[J]. Journal of Data Acquisition and Processing, 2025, 40(1):

- 45-55.
- [4] 沈锋, 丁国如, 李婕, 等. 电磁频谱多维态势压缩测绘技术研究进展[J]. 通信学报, 2023, 44(11): 25-42.
- Shen F, Ding G R, Li J, et al. Research progress on electromagnetic spectrum multidimensional situation compressed mapping technology[J]. Journal on Communications, 2023, 44(11): 25-42.
- [5] Li J J, Yang L, Wu Q Q, et al. Active RIS-aided NOMA-enabled space-air-ground integrated networks with cognitive radio[J]. IEEE Journal on Selected Areas in Communications, 2025, 43(1): 314-333.
- [6] Zhang D N, Lu Y Y, Ding W R, et al. Knowledge embedding networks based on deep learning for automatic modulation classification in cognitive radio[J]. IEEE Transactions on Communications, 2024, 72(12): 7814-7825.
- [7] Jiang T, Jin M, Guo Q H, et al. Graph learning-based cooperative spectrum sensing with corrupted RSSs in spectrum-heterogeneous cognitive radio networks[J]. IEEE Transactions on Wireless Communications, 2024, 23(10): 15447-15461.
- [8] Pan G L, Wu Q H, Ding G R, et al. Deep stacked autoencoder-based long-term spectrum prediction using real-world data[J]. IEEE Transactions on Cognitive Communications and Networking, 2023, 9(3): 534-548.
- [9] Wang L, Hu J, Zhang C D, et al. Deep learning models for spectrum prediction: a review[J]. IEEE Sensors Journal, 2024, 24(18): 28553-28575.
- [10] Rajendran S, Calvo-Palomino R, Fuchs M, et al. Electrosense: open and big spectrum data[J]. IEEE Communications Magazine, 2018, 56(1): 210-217.
- [11] Zhang Q Y, Zeng W H, Qin Z J, et al. TaP2-CSS: a trustworthy and privacy-preserving cooperative spectrum sensing solution based on blockchain[J]. IEEE Internet of Things Journal, 2024, 11(8): 14634-14646.
- [12] Janu D, Kumar S, Singh K. A graph convolution network based adaptive cooperative spectrum sensing in cognitive radio network[J]. IEEE Transactions on Vehicular Technology, 2023, 72(2): 2269-2279.
- [13] Du Y H, Qiao X Q, Zhang Y, et al. Interference-aware spectrum resource management in dynamic environment: strategic learning with higher-order statistic optimization[J]. IEEE Transactions on Cognitive Communications and Networking, 2022, 8(3): 1512-1528.
- [14] Hu J Q, Moorthy S K, Harindranath A, et al. A mobility-resilient spectrum sharing framework for operating wireless UAVs in the 6 GHz band[J]. IEEE/ACM Transactions on Networking, 2023, 31(6): 3128-3142.
- [15] Zhu R B, Li M Y, Liu H, et al. Federated deep reinforcement learning-based spectrum access algorithm with warranty contract in intelligent transportation systems[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(1): 1178-1190.
- [16] Safavinejad R, Chang H H, Liu L J. Deep reinforcement learning for dynamic spectrum access: convergence analysis and system design[J]. IEEE Transactions on Wireless Communications, 2024, 23(12): 18888-18902.
- [17] Girmay M, Maglogiannis V, Naudts D, et al. Enabling uncoordinated dynamic spectrum sharing between LTE and NR networks[J]. IEEE Transactions on Wireless Communications, 2024, 23(6): 5953-5968.
- [18] Xiao Y, Shi S H, Lou W J, et al. BD-SAS: enabling dynamic spectrum sharing in low-trust environment[J]. IEEE Transactions on Cognitive Communications and Networking, 2023, 9(4): 842-856.
- [19] Cao X L, Yang B, Wang K N, et al. AI-empowered multiple access for 6G: a survey of spectrum sensing, protocol designs, and optimizations[J]. Proceedings of the IEEE, 2024, 112(9): 1264-1302.
- [20] Pan G L, Wu Q H, Zhou B, et al. Spectrum prediction with deep 3D pyramid vision transformer learning[J]. IEEE Transactions on Wireless Communications, 2025, 24(1): 509-525.
- [21] Ding G R, Jiao Y T, Wang J L, et al. Spectrum inference in cognitive radio networks: algorithms and applications[J]. IEEE Communications Surveys & Tutorials, 2018, 20(1): 150-182.
- [22] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. Nature, 2015, 521(7553): 436-444.
- [23] Hinton G E, Osindero S, Teh Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554.
- [24] Yu L, Chen J, Ding G R. Spectrum prediction via long short term memory[C]//Proceedings of the 2017 3rd IEEE International Conference on Computer and Communications (ICCC). Piscataway: IEEE Press, 2017: 643-647.
- [25] Wang X Y, Peng T, Zuo P L, et al. Spectrum prediction method for ISM bands based on LSTM[C]//Proceedings of the 2020 5th International Conference on Computer and Communication Systems (ICCCS). Piscataway: IEEE Press, 2020: 580-584.
- [26] Aygül M A, Nazzal M, Ekti A R, et al. Spectrum occupancy prediction exploiting time and frequency correlations through 2D-LSTM[C]//Proceedings of the 2020 IEEE 91st Vehicular Technology Conference (VTC2020-Spring). Piscataway: IEEE Press, 2020: 1-5.
- [27] Ben C, Peng Y, Wang Y, et al. Enhanced multi-band spectrum prediction using singular spectrum analysis and attention-based BiLSTM[J]. IEEE Transactions on Cognitive Communications and Networking, 2025, 11(1): 118-126.
- [28] Ji N C, Liu T C, Zhang Y B, et al. Generative augmented cascade broad learning for lightweight multi-band spectrum prediction[J]. IEEE Transactions on Cognitive Communications and Networking, 2026, 12: 382-394.
- [29] Radhakrishnan N, Kandeepan S. An improved initialization method for fast learning in long short-term memory-based Markovian spectrum prediction[J]. IEEE Transactions on Cognitive Communications and Networking, 2021, 7(3): 729-738.
- [30] Ghasemi A, Parekh J. DeepAir: predicting radio spectrum usage at scale with deep temporal convolutional networks[C]//Proceedings of the 2021 IEEE International Conference on Communications Workshops (ICC Workshops). Piscataway: IEEE Press, 2021: 1-7.
- [31] Yu L, Chen J, Zhang Y M, et al. Deep spectrum prediction in high frequency communication based on temporal-spectral residual network[J]. China Communications, 2018, 15(9): 25-34.
- [32] Yu L X, Guo Y F, Wang Q L, et al. Spectrum availability prediction for cognitive radio communications: a DCG approach[J]. IEEE Transactions on Cognitive Communications and Networking, 2020, 6(2): 476-485.
- [33] Zhang X L, Guo L T, Ben C, et al. A-GCRNN: attention graph convolution recurrent neural network for multi-band spectrum prediction[J]. IEEE Transactions on Vehicular Technology, 2024, 73(2): 2978-2982.
- [34] Li S, Sun Y X, Han Y, et al. CL-MFGCN: graph structure contrastive learning and multiscale feature fusion graph convolutional network for spectrum prediction[J]. IEEE Internet of Things Journal, 2025, 12(4): 3600-3612.
- [35] Shawel B S, Woldegebreal D H, Pollin S. Convolutional LSTM-based long-term spectrum prediction for dynamic spectrum access[C]//Proceedings of the 2019 27th European Signal Processing Conference (EUSIPCO). Piscataway: IEEE Press, 2019: 1-5.
- [36] Li X, Liu Z C, Chen G J, et al. Deep learning for spectrum prediction from spatial-temporal-spectral data[J]. IEEE Communications Letters, 2021, 25(4): 1216-1220.

- [37] Ren X Y, Mosavat-Jahromi H, Cai L, et al. Spatio-temporal spectrum load prediction using convolutional neural network and ResNet[J]. IEEE Transactions on Cognitive Communications and Networking, 2022, 8(2): 502-513.
- [38] Xu H K, Li J, Wu Q H, et al. Dconv-former: efficient transformer for spatial-temporal-spectral spectrum prediction[J]. IEEE Wireless Communications Letters, 2025, 14(8): 2272-2276.
- [39] Shrestha S, Fu X, Hong M Y. Deep spectrum cartography: completing radio map tensors using learned neural models[J]. IEEE Transactions on Signal Processing, 2022, 70: 1170-1184.
- [40] Chen X N, Wang J, Zhang G Y, et al. Tensor-based parametric spectrum cartography from irregular off-grid samplings[J]. IEEE Signal Processing Letters, 2023, 30: 513-517.
- [41] Timilsina S, Shrestha S, Fu X. Quantized radio map estimation using tensor and deep generative models[J]. IEEE Transactions on Signal Processing, 2024, 72: 173-189.
- [42] Lin F D, Chen J, Ding G R, et al. Spectrum prediction based on GAN and deep transfer learning: a cross-band data augmentation framework[J]. China Communications, 2021, 18(1): 18-32.
- [43] Peng C, Zhu R G, Zhang M B, et al. Cross-band spectrum prediction algorithm based on data conversion using generative adversarial networks[J]. China Communications, 2023, 20(10): 136-152.
- [44] Li K H, Li C, Chen J M, et al. Boost spectrum prediction with temporal-frequency fusion network via transfer learning[J]. IEEE Transactions on Mobile Computing, 2023, 22(6): 3209-3223.
- [45] Peng C, Zhang M B, Hu W L, et al. Cross-band spectrum prediction algorithm based on transfer learning and meta learning[C]//Proceedings of the 2021 7th International Conference on Computer and Communications (ICCC). Piscataway: IEEE Press, 2021: 2303-2307.
- [46] Fang Z Q, Wu D E, Pan L, et al. When transfer learning meets cross-city urban flow prediction: spatio-temporal adaptation matters[C]//Proceedings of the Thirty-First International Joint Conference on Artificial Intelligence. Piscataway: IEEE Press, 2022: 2030-2036.
- [47] Ouyang X C, Yang Y, Zhang Y L, et al. Domain adversarial graph neural network with cross-city graph structure learning for traffic prediction[J]. Knowledge-Based Systems, 2023, 278: 110885.
- [48] Li J Y, Liao C L, Hu S, et al. Physics-guided multi-source transfer learning for network-scale traffic flow prediction[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(11): 17533-17546.
- [49] Du H Y, Zhang R C, Liu Y Q, et al. Enhancing deep reinforcement learning: a tutorial on generative diffusion models in network optimization[J]. IEEE Communications Surveys & Tutorials, 2024, 26(4): 2611-2646.
- [50] Li X, Wang X, Song T C, et al. Robust online prediction of spectrum map with incomplete and corrupted observations[J]. IEEE Transactions on Mobile Computing, 2022, 21(12): 4583-4594.
- [51] Shi J, Chen G, Zhao Y N, et al. Synchrosqueezed fractional wavelet transform: a new high-resolution time-frequency representation[J]. IEEE Transactions on Signal Processing, 2023, 71: 264-278.
- [52] Azizi R, Seker S. Microgrid fault detection and classification based on the boosting ensemble method with the Hilbert-Huang transform[J]. IEEE Transactions on Power Delivery, 2022, 37(3): 2289-2300.
- [53] Liu X, Zhang C X, Huang F X, et al. Vision mamba: a comprehensive survey and taxonomy[J]. IEEE Transactions on Neural Networks and Learning Systems, 2026, 37(2): 505-525.
- [54] Tang J L, Chen S, Niu G, et al. Distribution shift matters for knowledge distillation with webly collected images[C]//Proceedings of the 2023 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway: IEEE Press, 2023: 17424-17434.
- [55] Cao P, Wang W, Liu Y L, et al. A lightweight consensus protocol for distributed collision-free spectrum allocation[J]. IEEE Wireless Communications Letters, 2026, 15: 1553-1557.
- [56] Vettoruzzo A, Bouguelia M R, Vanschoren J, et al. Advances and challenges in meta-learning: a technical review[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, 46(7): 4763-4779.
- [57] Pan G L, Li J, Li M L. Multi-channel multi-step spectrum prediction using transformer and stacked Bi-LSTM[J]. China Communications, 2025, 22(5): 1-13.
- [58] Ho J, Jain A N, Abbeel P. Denoising diffusion probabilistic models[J]. Advances in Neural Information Processing Systems, 2020, 33: 6840-6851.
- [59] Long M S, Cao Y, Wang J M, et al. Learning transferable features with deep adaptation networks[C]//International Conference on Machine Learning. New York: PMLR, 2015: 97-105.
- [60] Luo S, Zhou T, Xiao Y, et al. Predicting spectrum status duration using non-linear Homotopy estimation based HMM for UAV communications[J]. Signal Processing, 2023, 212: 109131.
- [61] Pan G L, Yau D K Y, Zhou B, et al. Deep learning for spectrum prediction in cognitive radio networks: state-of-the-art, new opportunities, and challenges[J]. IEEE Network, 2026, 40(1): 192-200.

[作者简介]



潘光良 (1994-), 男, 博士, 南京邮电大学讲师, 主要研究方向为电磁频谱认知学习与智能管控、低空车联网。



张颖 (2001-), 女, 南京邮电大学硕士生, 主要研究方向为车联网、联邦学习。



赵海涛 (1983-), 男, 南京邮电大学教授, 主要研究方向为物联网、车联网、低空车联网。



吴启晖 (1970-), 男, 南京航空航天大学教授, 主要研究方向为电磁频谱认知学习与智能管控、低空车联网、认知信息论、机器学习、空天地一体化网络。