

基于动态图神经网络与对比学习的 单通道同频盲信号分离方法

罗 鸣¹, 赖金山¹, 孙鹏钊¹, 张 昆², 张凤荔¹, 王瑞锦^{1*}

(1. 电子科技大学, 四川成都 610054; 2. 成都蓉蓉联创科技有限公司, 四川成都 610041)

摘 要: 在复杂电磁环境下, 目标信号与干扰信号在时域、频域高度重叠, 单通道接收条件下的同频盲信号分离面临较大挑战。现有基于卷积的分离方法在复杂非平稳干扰条件下, 主要存在非局部相关性建模不足、目标信号与干扰信号隐空间解耦能力有限、对未知干扰模式泛化性较弱等问题。本文提出基于动态图神经网络与对比学习的单通道同频盲信号分离方法(Dynamic Graph and Contrastive Learning network, DGCL)。首先, 将复基带混合序列映射为I/Q双通道表示, 并依托动态图神经网络实现多尺度图时序特征的有效提取, 通过多尺度分段、动态构图与图消息传递的协同作用, 增强对复杂非平稳干扰的表征能力; 其次, 设计目标信号匹配驱动的对比学习自编码器, 在结构匹配重构的基础上引入对比约束, 提升目标信号与干扰信号在隐空间中的可分性; 此外, 在训练时设计隐空间流形混合增强策略, 通过扩展深层特征分布, 提升模型对未知干扰模式的鲁棒性。在单载波、多载波及多类干扰条件下的实验表明, DGCL在误码率与均方误差两项指标上均表现出显著优势。相较于常规基准模型WaveNet框架, DGCL的MSE(Mean Square Error)降低了6.7 dB, BER(Bit Error Rate)下降了 1.72×10^{-2} , 这些结果验证了本文方法的有效性。

关键词: 单通道盲信号分离; 同频干扰; 图神经网络; 对比学习; 流形混合

基金项目: 国家自然科学基金(No.62271128); 四川省重大科技专项(No.2025ZDZX0093); 四川省科技计划项目(No.2025ZHRG0006); 成都市重点研发支持计划项目(No.2025-YF08-00128-GX, No.2025-YF12-00029-RC)

中图分类号: TP18 **文献标识码:** A **文章编号:** 0372-2112(2026)06-2493-16

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.12263/DZXB.20260400

Single-Channel Co-Frequency Blind Signal Separation Based on Dynamic Graph Neural Networks and Contrastive Learning

LUO Ming¹, LAI Jinshan¹, SUN Pengzhao¹, ZHANG Kun², ZHANG Fengli¹, WANG Ruijin^{1*}

(1. University of Electronic Science and Technology of China, Chengdu, Sichuan 610054, China;

2. Chengdu Jingrong Lianchuang Technology Co., Ltd., Chengdu, Sichuan 610041, China)

Abstract: In complex electromagnetic environments, target signals and interference signals heavily overlap in both time and frequency domains, posing significant challenges for co-frequency blind signal separation under single-channel reception conditions. Under complex non-stationary interference conditions, existing convolution-based separation methods primarily suffer from insufficient non-local correlation modeling, limited decoupling capability between target and interference signals in the latent space, and weak generalization to unknown interference patterns. To address these issues, this paper proposes a single-channel co-frequency blind signal separation method based on dynamic graph neural networks and contrastive learning (DGCL). First, the complex baseband mixture sequence is mapped into an in-phase/quadrature (I/Q) dual-channel representation, and dynamic graph neural networks are utilized to effectively extract multi-scale graph temporal features. Through the synergistic effects of multi-scale segmentation, dynamic graph construction, and graph message passing, the representation capability for complex non-stationary interference is enhanced. Second, a contrastive learning autoencoder driven by target signal matching is designed. By introducing contrastive constraints on top of structural matching reconstruction, the separability of the target signal and the interference signal in the latent space is improved. Furthermore, a latent space manifold mixup enhancement strategy is designed during training. By expanding the deep feature distribution, the model's robustness against unknown interference patterns is elevated. Experiments conducted under single-carrier, multi-carrier, and multi-class interference conditions indicate that DGCL demonstrates significant advantages in both bit error rate and mean square error metrics. Compared with the conventional WaveNet baseline, DGCL reduces MSE (Mean Square Error) by 6.7 dB and decreases BER (Bit Error Rate) by 1.72×10^{-2} . These results verify the effectiveness of the pro-

posed method.

Keywords: single-channel blind signal separation; co-frequency interference; graph neural network; contrastive learning; manifold mixup

Foundation Item(s): National Natural Science Foundation of China (No.62271128); Major Scientific and Technological Project of Sichuan Province (No. 2025ZDZX0093); Science and Technology Project of Sichuan Province (No.2025ZHRG0006); Key Research and Development Support Project of Chengdu (No.2025-YF08-00128-GX, No.2025-YF12-00029-RC)

0 引言

随着无线通信、物联网、雷达感知网络以及动态频谱共享技术的快速发展,现代无线电频谱资源日益紧张。在 5G-Advanced 及未来 6G 网络中,海量无线设备的接入与频谱复用使得复杂电磁环境下的同频干扰 (Co-Frequency Interference, CFI) 问题,逐渐成为限制无线通信链路可靠性与智能接收机性能的关键障碍。当目标信号 (Signal Of Interest, SOI) 与敌意干扰、非合作通信信号或工业电磁噪声等未知干扰信号在时域、频域发生高度重叠,且接收端受限于设备体积、功耗或硬件成本而缺乏空间分集增益时,传统的空间滤波与多天线干扰抑制技术往往难以适用。在此背景下,如何在仅已知目标信号调制先验,而对干扰模式及信道状态完全未知的半盲单通道接收条件下准确恢复目标信号,进而保障后续的数字解调与纠错译码性能,已成为射频信号处理与射频机器学习领域的重要研究问题^[1]。

与理想加性高斯白噪声 (Additive White Gaussian Noise, AWGN) 信道下的经典信号接收场景不同,复杂电磁环境中的同频干扰通常表现出非高斯、非平稳、突发性强以及统计特性未知等特点。目标信号与干扰信号在单通道接收机前端存在深度的非线性耦合。对于缺乏空间维度自由度的单天线接收机而言,传统模型驱动的信号处理方法存在明显的理论局限。匹配滤波、线性最小均方误差 (Linear Minimum Mean Square Error, LMMSE) 估计以及基于高阶累积量的独立成分分析 (Independent Component Analysis, ICA) 与非负矩阵分解 (Nonnegative Matrix Factorization, NMF) 等盲源分离 (Blind Source Separation, BSS) 算法,通常依赖于高斯噪声假设、信号线性可分条件或多通道观测下的统计独立性假设^[2]。研究表明,在单通道强同频干扰场景下,因目标与干扰信号特征流形高度重叠,传统盲分离算法在求解严重欠定的混合矩阵时,呈现严重的秩亏状态^[3]。这不仅难以实现有效的信号解耦,还容易引发相位畸变与误差传播,导致分离性能急剧下降,甚至掩盖真实信号的物理特征^[4]。从逆问题的数学角度来看,复杂电磁环境下的单通道同频盲信号分离是一个兼具高度欠定性、非线性与强耦

合特征的非凸优化问题。

近年来,随着深度学习技术在射频领域的深入应用,数据驱动方法为同频干扰抑制提供了新的解决方法^[5]。以 U-Net、WaveNet 及其变体为代表的深度神经网络在单通道分离任务中,表现出优于传统基线算法的性能潜力^[1]。此类数据驱动方法通过在大规模混合信号样本上的端到端优化,能够隐式提取目标信号与干扰信号的高维统计结构特征,在一定程度上降低了对精确先验知识和复杂解析物理模型的依赖^[6]。

然而,当前基于深度卷积的学习型盲信号分离方法仍存在不少理论与技术的局限^[7-8]。其一,复杂非平稳干扰的非局部相关性建模能力不足。目前主流卷积主干网络主要通过堆叠卷积核来扩展局部,这种静态时序拓扑虽能捕捉一定程度的中短距离时序依赖,却无法高效显式地刻画那些相距较远但统计模式相似的干扰片段间的非局部关联。尤其针对突发位置不定、持续周期跨度大的非平稳结构化通信干扰,基于固定图谱的局部卷积操作缺乏对全局拓扑关系的自适应捕捉能力,特征表征的上限因此受到制约。其二,隐空间中目标与干扰特征的判别性解耦能力有限。现有面向目标信号 (SOI) 匹配的自编码器方法,虽能借助调制先验提升波形重构质量,但这类网络大多受限于均方误差 (Mean Square Error, MSE) 等基于时域的全局重构损失,难以在特征层面精准划定目标与干扰的边界,导致二者特征在隐空间中仍存在一定程度的混叠。其三,对未知动态干扰模式的泛化性与鲁棒性有待提升。真实复杂电磁环境中的干扰模式极具多样性,相关跨领域研究也表明,一旦学习系统的特征表征层受到错误表示或污染信息的干扰,整体判别性能会出现明显下滑。而传统射频数据增强策略多局限于输入波形层面的简单处理,对特征分布的拓展能力有限,难以支撑模型应对全新的未知干扰模式。由于复基带射频信号承载着敏感的幅度、相位和高阶调制星座图结构信息,直接在底层物理波形上扰动极易破坏信号的局部相位连续性与物理生成机制的一致性,导致增强样本偏离真实的电磁信道物理规律,进而限制了模型对未见干扰分布特征的泛化能力^[9-10]。

针对上述问题,本文面向复杂电磁环境下的单通

道同频盲信号分离任务,提出了基于动态图神经网络与对比学习的单通道同频盲信号分离方法(Dynamic Graph and Contrastive Learning network, DGCL)。贡献如下:

(1)提出基于动态图神经网络的多尺度图时序特征提取方法,不同于传统 WaveNet 及其改进方法依赖固定时序拓扑,其将单通道混合复基带序列表示为多尺度图结构,通过动态邻接关系建模远距离相关片段间的非局部依赖,克服了时间序列线性处理的局限性,提升了对非平稳、突发性同频干扰的表征能力。

(2)提出目标信号匹配驱动的对图学习自编码器,在调制匹配重构的基础上引入对比约束,以纯净目标信号、分离结果和真实干扰分别构造锚点、正样本和负样本,显式拉近目标特征并排斥干扰特征,增强隐空间中的目标与干扰可分性。

(3)提出了训练期隐空间流形混合增强策略。相较于传统输入层加噪或翻转增强,本文在深层特征空间中构造连续过渡样本,以符合高层语义分布的方式扩展训练样本覆盖范围,在不增加测试复杂度的前提下提升了模型的泛化能力与鲁棒性。

基于公开数据集在单载波 QPSK (Quadrature Phase Shift Keying)与多载波 OFDM-QPSK (Orthogonal Frequency Division Multiplexing - Quadrature Phase Shift Keying)两类目标信号、四类典型干扰及多组信干噪比条件下开展实验。结果表明, DGCL 在误码率 (Bit Error Rate, BER) 与 MSE 两项指标上均表现出稳定优势。消融实验进一步验证了动态图神经网络特征提取、对比学习自编码器和流形混合增强的有效性。

1 相关工作

1.1 射频信号分离

射频信号分离旨在从混合观测中恢复目标信号成分,在复杂噪声、干扰与不完全先验条件下,提高目标波形的重构保真度及后续通信链路的解调可靠性。基于匹配滤波和 LMMSE 估计的方法在多天系统和高斯信道模型下表现优异。然而,此类经典方法的应用存在局限性,通常要求空间自由度大于信号源数量的多通道阵列,或严重依赖信号间严格的统计独立性与线性混叠假设。在单通道且目标与干扰在时频域高度重叠的复杂环境下,系统矩阵会呈现严重的病态甚至秩亏^[5]。这种维度降级导致传统盲信号分离方法的解空间存在难以消除的排列模糊与幅度模糊,难以实现物理层波形的高保真恢复。

近年来,数据驱动方法为解决上述问题提供了新途径。各类深度神经网络通过端到端学习,在极低信号与干扰加噪声比 (Signal to Interference plus Noise

Ratio, SINR) 条件下相比传统 LMMSE 方法取得了显著的性能提升。以 WaveNet 为代表的生成式时域卷积网络成为该领域的重要基准。Tian 等人^[11]在 WaveNet 基础上引入可学习的空洞率 (learnable dilation) 并配合定制化数据增强,提升了模型对多尺度时间信号的适配能力; Henneke^[12]结合解调先验信息,在主干后端嵌入与目标信号调制结构匹配驱动的自编码器,使网络在降噪的同时契合物理波形的符号结构,有效降低了分离后的 MSE。此外,为克服卷积网络局部感受野的局限性, Damara 等人^[13]探讨了集成自注意力机制的 Transformer U-Net 架构; Yapar 等人^[14]与 Naseri 等人^[15]分别基于深度音乐源提取器 (Deep Extractor for Music Sources, DEMUCS) 和多尺度 U-Net 实现了时频混合域的高效特征提取。

综上所述,尽管射频信号分离技术发展迅速,但在面对高度非平稳的通信干扰时,传统的线性时间机制仍难以高效表征长程序列中的自我相似性特征。相较于上述基于传统卷积或注意力机制的方法,本文方法突破了固定时序感受野的限制,利用动态图机制自适应挖掘长程干扰的拓扑相似性,在复杂非平稳干扰下具备更强的特征捕捉能力。

1.2 图神经网络

图神经网络^[16] (Graph Neural Network, GNN) 的核心思想在于将数据集或样本内部的局部单元抽象为节点,通过边权重刻画节点间的相关性,进而在图拓扑上利用消息传递完成高维特征的聚合与关系推理。相较于依赖欧几里得空间规则网格的卷积神经网络 (Convolutional Neural Network, CNN), GNN 在处理非欧氏几何结构数据以及捕获长距离、非连续依赖关系方面具有显著优势^[17]。

在无线通信与射频领域, GNN 已表现出良好的特征表征与系统建模能力。Shen 等人^[18]证实 GNN 能够建立空间离散实体间的特征关联,从而缓解了大规模无线资源管理中的扩展性瓶颈; Lee 等人^[19]从理论层面论证了图神经网络在处理无线通信节点非规则拓扑关系时的鲁棒性与去中心化优势。同时,在处理包含复杂空间-光谱特征的高光谱图像分类任务中, GNN 也验证了其挖掘高维数据内在拓扑结构的有效性^[10]。类似地,针对符号社交网络中对抗攻击的研究进一步揭示了图传播机制的抗噪潜力^[20]。

将 GNN 的拓扑建模思想引入单通道复基带序列信号处理,具有重要的研究价值。射频环境中的干扰信号在时间轴上往往表现出随机的间断性与突发性,但其在局部波形片段上具有明显的同构性。解决传统的膨胀卷积通常按照固定步长提取特征问题。而本文提出的 DGCL 是基于动态图神经网络的时序特

征提取方法,在单个复基带样本内部构建动态图,把不同时刻的局部波形片段作为节点进行消息传递^[6],并依据深层特征空间的余弦相似度实时构建动态邻接矩阵,使网络能够自适应地将时间上跨度较大但统计特征相似的干扰片段在拓扑空间中直接连接。同时,借鉴稀疏图结构可降低连接开销的思想^[21],DGCL对动态图邻接关系进行稀疏化约束,仅保留关键关联边,以兼顾特征传播效率与结构表达能力。这种样本内动态图建模方式更贴合同频干扰突发、间断和远距离自相似的时序特征,不仅有助于滤除高斯底噪,还能增强对复杂非平稳干扰拓扑结构的联合表达能力,为后续的隐空间解耦提供高可靠的特征基础。

1.3 对比学习

通过拉近相似样本、推远不相似样本来塑造表示空间几何结构,其目标在于使模型学到更具判别性与可迁移性的隐空间表示。在时序与无线信号任务中,传统的去噪自编码器通常利用MSE^[14]等距离度量函数,约束网络输出以逼近纯净信号。然而,Guo等人^[5]指出,在处理复数域射频信号分离时,由于相位旋转与包络畸变的非线性叠加,低信噪比下单凭时域重构损失易导致模型陷入模式崩塌,即解码器输出平均化的模糊波形,难以在隐空间内划定明确的目标与干扰边界。

对比学习为解决隐空间解耦不彻底的问题提供了新的方法。Huang等人^[22]分析了多模态与单模态对比学习的理论边界,证明了在单模态高维噪声信号中,局部拓扑块的对比学习能够有效收敛出稳健的决策超平面;Yue等人^[23]提出的TS2Vec将多尺度时序语义建模与对比损失相结合,验证了层次化正负样本关系可增强时间序列表征;此外,面向自动调制识别的对比学习方法表明,在低信噪比与域偏移条件下,对比学习有助于提升无线信号特征的鲁棒性^[24]。总之,对比学习能显式塑造类内聚合、类间分离的表示结构,但正负样本构造与任务语义的对齐通常需结合具体问题展开设计。

对于单通道同频盲信号分离,仅采用MSE重构损失,网络往往只能保证输出波形在数值上接近目标,难以在隐空间中形成目标聚合、干扰远离的分布结构。受此启发,本文设计的目标信号匹配驱动的对比如学习自编码器不同于常规的时域全局对比,本文将对比约束嵌入目标调制匹配的自编码器瓶颈层,不仅保证了波形重构的保真度,更在隐空间严格划定了目标与干扰的分布边界,解决了传统MSE损失下特征混叠的难题。

1.4 混合式数据增强与插值正则化

深度神经网络在拟合有限规模的训练分布时表

现出较强的能力,但在面对真实开放电磁环境中未知的突发干扰时,往往面临泛化能力不足的问题。数据增强与插值正则化是提升深度模型泛化能力与鲁棒性的重要手段。例如,Zhang等人^[25]提出的Mixup方法通过对输入样本及其标签进行凸组合,促使模型在样本之间学习更平滑的映射关系;Verma等人^[26]提出的Manifold Mixup,将插值操作从输入层推广至隐空间表示层,使网络能够学习更紧凑且具备泛化性的特征结构。在此基础上,Hendrycks等人^[27]提出的AugMix利用多种增强路径组合来提升模型的鲁棒性与不确定性校准能力。整体而言,该方向已从简单的输入扰动,发展为涵盖输入空间、隐空间及一致性约束的系统化正则化方案。

对于复基带射频信号,输入层增强并非最优选择。在射频通信领域,输入信号的同相与正交分量蕴含着严格的相位轨迹与多载波正交性^[28]。若在原始输入波形上直接应用时域裁剪、加噪或线性叠加,极易破坏波形的物理连贯性与信道衰落的自然包络,进而产生大量违背电磁物理规律的失效样本^[6]。相比之下,在网络深层特征流形中进行插值,更接近高层语义分布,能够在较少破坏物理结构的前提下扩展表示边界^[8]。此类方法的优势在于有助于提升模型应对未知分布时的鲁棒性,其局限性则在于最终效果一定程度上依赖于特征空间本身是否已具备良好的可分性。

针对盲信号分离任务,若模型仅在固定的干扰组合上进行训练,极易对已知样本分布产生过拟合。将插值引入深层特征空间,能够利用构造的连续过渡样本约束网络学习更为平滑地分离映射^[29]。因此,与输入层Mixup或AugMix等增强方式相比,本文的DGCL方法在不增加推理阶段额外计算开销的前提下,把插值位置放在动态图特征提取后的深层流形空间,避免直接扰动I/Q波形的相位连续性和OFDM子载波正交结构,在满足复基带射频信号分离中的物理一致性约束条件下提升了模型对未知干扰模式的适应能力与整体鲁棒性。

2 本文方法

2.1 单通道混合信号数学建模

有别于理想高斯信道假设,本研究将接收信号建模为离散时间复基带形式。设有限观测窗口内的采样序列为 $y[n]$,其可表示为目标信号、同频干扰及加性噪声经多径信道后的线性叠加:

$$y[n] = (h_s * s)[n] + (h_i * i)[n] + w[n] \quad (1)$$

其中: $s[n]$ 为发送端的纯净目标数字调制波形,接收端已知其生成机制; $i[n]$ 为处于同频段的未知或异步

干扰信号,通常为结构化通信信号或无明显统计规律的宽带电磁干扰; $h_s[n]$ 和 $h_i[n]$ 分别表示目标信号与干扰信号所经历的独立多径衰落信道冲激响应(Channel Impulse Response, CIR),接收端未知这两个信道冲激响应时变特性; $w[n] \sim \text{CN}(0, \sigma_w^2)$ 表示方差为 σ_w^2 的复圆对称高斯白噪声;*代表离散时间线性卷积算子。

在盲信号分离设定下,接收端已知目标信号的部分先验统计信息,包括调制类型、符号速率及脉冲成形滤波器的滚降系数,而干扰信号的生成机制、高阶累积量特征及信道状态信息完全未知。该设定克服了传统盲源分离方法对空间分集或统计独立性的依赖,通过引入先验知识将欠定问题转化为半盲问题。需要说明的是,“盲”并非指对目标信号完全无先验的全盲源分离,而是指在单通道推理阶段不依赖干扰

信号的调制体制、生成模型、信道状态或类别先验,模型仅利用目标信号的有限调制结构先验,从混合观测中恢复 SOI。因此,本文方法适用于目标信号体制已知、干扰模式未知且两者同频混叠的半盲分离场景,不讨论目标调制参数完全未知或多个未知源同时全盲分离的情况。

因此,本文旨在解决单通道、无空间分集增益且信号高度混叠条件下的分离问题。构建并训练由权重参数 θ 表征的非线性映射算子,使重构信号在特征空间与物理波形层面均逼近理想目标信号 s ,如图1所示。模型的优化目标在最小化时域 MSE 的基础上,致力于为下游数字解调与纠错解码任务提供高保真且相位准确的信号输入,进而有效降低系统的误码率与误符号率。




图1 单通道混合信号分离

Figure 1 Single-channel mixed signal separation

2.2 网络整体架构与输入数据结构

在完成单通道混合信号分离任务数学建模后,针对复杂电磁环境下单通道同频干扰呈现出的非高斯、非平稳、多时间尺度耦合等特征,本文提出了一种面向该环境的单通道盲信号分离网络 DGCL。该网络结合图神经网络特征提取、目标信号匹配重构与对比学习约束,实现目标信号与干扰信号的有效分离。整体架构由输入映射层、基于动态图神经网络的多尺度图时序特征提取模块、用于目标信号匹配驱动的对比学习自编码器,以及训练期流形混合增强分支四个部分组成,如图2所示。多尺度动态与对比学习的盲信号分离网络以定长复基带混合序列为输入,在仅利用目标信号已知调制先验且不依赖干扰生成模型的条件,直接学习从混合观测到纯净 SOI 的非线性映射:

$$\mathbf{Y} = [\text{Re}(\mathbf{y}), \text{Im}(\mathbf{y})] \in \mathbb{R}^{2 \times 40960} \quad (2)$$

其中, $\text{Re}(\cdot)$ 和 $\text{Im}(\cdot)$ 分别表示取复基带混合序列实部和虚部的运算。由于常规深度卷积网络难以直接在复数域上进行原生运算,而输入样本为固定长度的复基带序列,因此这里首先将输入混合信号 $\mathbf{y}$ 映射为双通道实值张量。其中,第一个通道表示同相分量 $\mathbf{I} = \text{Re}(\mathbf{y})$,第二个通道表示正交分量 $\mathbf{Q} = \text{Im}(\mathbf{y})$ 。该处理方式能

够在不显著增加计算复杂度的前提下,保留复基带波形的幅度与相位信息。

随后,该张量 $\mathbf{Y}$ 被输入特征提取模块。该模块通过多尺度编码、动态图构建、图消息传递及多尺度聚合,从混合 I/Q 序列中提取兼具局部调制细节与长距离依赖的深层特征表示 $\mathbf{F}$ 。与传统固定空洞卷积主干不同,基于动态图神经网络的架构突破了线性时间轴上的局部卷积传播限制,利用样本自适应图结构,显式建模相距较远但统计特征相似的干扰片段之间的关联,从而提升多尺度动态图与对比学习的盲信号分离网络在复杂非平稳干扰条件下的特征表达能力。

深层特征进而被输入自编码器模块。该模块由调制匹配编码器、调制匹配解码器、共享编码器、投影头及对比约束组件构成。其主路径将深层混合特征压缩为低维潜表示,并重构出纯净目标信号估计值 $\hat{s}$ 。同时,利用已知的目标信号 s ,通过残差关系计算真实干扰信号 b 。在训练阶段,真实纯净 SOI、估计 SOI 与真实干扰分别经由共享编码器和投影头映射至统一隐空间,以构造锚点样本、正样本和负样本。通过对比损失约束,缩小 SOI 特征间的距离并扩大与干扰特征的差异,从而实现判别性特征解耦。

为进一步提升多尺度动态图与对比学习的盲信号分离网络对未知复杂干扰的泛化能力,本文在训练




图2 基于动态图神经网络与对比学习的盲信号分离网络

Figure 2 Blind signal separation network based on dynamic graph neural networks and contrastive learning

阶段引入流形混合增强分支。具体而言,在多尺度动态图与对比学习的盲信号分离网络输出的深层特征空间中,从同一批次内随机选取两个样本的特征表示进行凸组合,同时对对应的监督目标进行一致性插值,以构造连续过渡的隐空间增强样本。该分支仅在训练阶段启用,旨在约束多尺度动态图与对比学习的盲信号分离网络学习更平滑、鲁棒的分离映射;推理阶段仅保留主路径,不引入额外计算开销。

综上所述,本文构建了特征提取—隐空间解耦与重构—训练期泛化增强的统一框架。前端模块负责从复杂混合信号中提取判别性深层特征,中间模块在隐空间中实现 SOI 与干扰的分离。

训练期增强分支则进一步提升模型对未见干扰模式的鲁棒性与泛化能力,最终实现复杂电磁环境下的单通道盲信号分离。

2.3 基于动态图神经网络的多尺度图时序特征提取

传统 WaveNet 及其改进结构主要依赖一维卷积与固定空洞率堆叠来扩大感受野,虽然能在一定程度上建模长程依赖,但实际上仍局限于在单一线性时间轴上进行局部卷积传播。当输入信号中存在突发性强、持续时间不一且分布位置不固定的同频干扰时,仅通过固定卷积核和静态空洞率扩展感受野,通常难以显式捕获相距较远但统计特征相似的干扰片段间的非局部关联。针对上述问题,本文将原有动态空洞卷积主干替换为基于动态图神经网络的多尺度图时序特征提取模块,通过多尺度编码、动态图构建、图消息传递及多尺度特征聚合,从混合 I/Q 序列中提取

具备更高判别度的深层特征 F , 如图 3 所示。

输入混合基带信号表示为 $Y \in \mathbb{R}^{2 \times N}$, 为避免直接对点级采样构图带来的高计算复杂度与噪声边传播问题,本文提出的 DGCL 方法首先将长序列划分为若干局部时间片段,并以此作为图节点。考虑到射频信号同时存在局部调制细节与长程干扰结构,这里采用多尺度划分策略,在不同尺度下分别构造节点序列,以兼顾短时局部纹理与长时上下文关系。本文提出的 DGCL 共选取四个尺度 ($L_1=80, L_2=128, L_3=160, L_4=256$), 同时为便于后续还原至原始时间长度,采用不重叠划分方式,即取某个尺度下的片段长度为 L_m , 步长等长记为 S_m , 从而得到该尺度下的 M_m 个局部片段。

四个尺度的选取同时考虑了数据集物理层结构、采样长度整除性与计算开销。80 点与 OFDM-QPSK 的单符号块长度一致; 128 点对应单载波 QPSK 中 8 个符号的根升余弦脉冲成形跨度; 160 和 256 点是前两个尺度的两倍, 引入这两个较大尺度的目的是在符号周期的基础上, 跨越多个物理符号去捕捉相距较远的同频干扰片段间的非局部依赖关系, 从而为动态构图提供更宏观的上下文视野。上述尺度均能整除 40960 点输入长度, 可在不引入补零误差的情况下兼顾短时调制细节和长时突发干扰结构。

$$\mathbf{P}_i^{(m)} \in \mathbb{R}^{2 \times L_m}, i=1, 2, \dots, M_m \quad (3)$$

其中, $\mathbf{P}_i^{(m)}$ 表示第 m 个尺度下划分得到的第 i 个局部 I/Q 双通道信号片段, $\mathbf{P}_i^{(m)} \in \mathbb{R}^{2 \times L_m}$ 第一行和第二行分别表示同相分量和正交分量。

在每个尺度下,对各局部片段 $\mathbf{P}_i^{(m)}$ 使用共享的一维卷积编码器 $\phi_m(\cdot)$ 提取局部节点特征,在局部时域内保留 1/Q 波形的相位变化、包络起伏和瞬时调制结构,再将编码后的特征作为图节点表示,供后续图结构学习使用。由此,第 m 个尺度下的节点特征矩阵可表示为 $\mathbf{X}^{(m)}$ 。

$$\mathbf{x}_i^{(m)} = \phi_m(\mathbf{P}_i) \in \mathbb{R}^d, \quad d=128 \quad (4)$$

$$\mathbf{X}^{(m)} = [\mathbf{x}_1^{(m)}, \mathbf{x}_2^{(m)}, \dots, \mathbf{x}_{M_m}^{(m)}]^\top \in \mathbb{R}^{M_m \times d} \quad (5)$$

获取节点特征后,进一步构造动态相关图。与静态图不同,本文的 DGCL 方法不预先固定邻接关系,而是根据当前样本的节点特征自适应生成邻接矩阵。具体而言,对于第 m 个尺度下的任意两个节点 (i, j) ,定义其边权为 $a_{ij}^{(m)}$ 。首先由式(6)计算 $e_{ij}^{(m)}$,即第 m 个尺度下节点 i 与节点 j 之间的相关性得分。




图3 特征提取结构

Figure 3 Feature extraction architecture

为控制计算复杂度并抑制冗余传播,对每个节点仅保留 top- k 个最强邻接边。考虑到不同尺度下节点数量差异较大,此处不设定固定整数,而是采用与节点数相关的自适应保留策略即式(7)。最后对稀疏邻接矩阵执行归一化处理得到第 m 个尺度下的邻接矩阵 $\mathbf{A}^{(m)} \in \mathbb{R}^{M_m \times M_m}$ 。

$$e_{ij}^{(m)} = \frac{(\mathbf{W}_q \mathbf{x}_i^{(m)})^\top (\mathbf{W}_k \mathbf{x}_j^{(m)})}{\sqrt{d}} \quad (6)$$

$$k_m = \min(16, \max(8, \lfloor 0.05 M_m \rfloor)) \quad (7)$$

$$a_{ij}^{(m)} = \frac{\exp(e_{ij}^{(m)}) \cdot 1(j \in \mathcal{N}_k(i))}{\sum_{u \in \mathcal{N}_k(i)} \exp(e_{iu}^{(m)})} \quad (8)$$

其中: k_m 表示第 m 个尺度下每个节点保留的最强邻接边数量, M_m 表示该尺度下的节点总数; $a_{ij}^{(m)}$ 为节点 i 向节点 j 传递信息时的归一化边权重; $\mathbf{W}_q$ 和 $\mathbf{W}_k$ 为可学习的查询和键特征投影矩阵,用于将节点特征映射到相关性计算空间,此后所有的 $\mathbf{W}$ 均为可学习的参数矩阵; $\mathcal{N}_k(i)$ 为对节点 i 保留的 k 个最强邻居所组成的节点集合; $e_{ij}^{(m)}$ 表示第 m 个尺度下节点 i 与邻居节点 u 之间的相关性得分。

动态图构建完成后,采用图消息传递提取跨节点的非局部关联特征。取初始节点特征矩阵为 $\mathbf{H}^{(0,m)} = \mathbf{X}^{(m)}$,第 l 层图输入特征为 $\mathbf{H}^{(l-1,m)}$,对 l 第层图执行邻

居聚合得到 $\mathbf{U}^{(l,m)}$ 。为增强对干扰噪声的抑制能力,在图消息传递后进一步引入门控机制与残差连接,得到最终的特征更新 $\mathbf{H}^{(l,m)}$ 。此门控机制主要用于抑制由动态图传播引入的无关邻居信息,使多尺度动态图与对比学习的盲信号分离网络着重保留与目标信号结构相关的有效表示。

$$\mathbf{U}^{(l,m)} = \mathbf{A}^{(m)} \mathbf{H}^{(l-1,m)} \mathbf{W}_g^{(l)} \quad (9)$$

$$\mathbf{G}^{(l,m)} = \text{Sigmoid}(\mathbf{H}^{(l-1,m)} \mathbf{W}_z + \mathbf{b}_z) \quad (10)$$

$$\mathbf{H}^{(l,m)} = \mathbf{G}^{(l,m)} \odot \text{GELU}(\mathbf{U}^{(l,m)}) + \mathbf{H}^{(l-1,m)} \quad (11)$$

其中: $\mathbf{W}_g^{(l)}$ 为第 l 层图消息传递的可学习特征变换矩阵; $\mathbf{G}^{(l,m)}$ 为第 m 个尺度、第 l 层的门控系数矩阵,元素取值在 0~1 之间; $\mathbf{W}_z$ 为门控单元的可学习权重矩阵; $\mathbf{b}_z$ 为门控单元的偏置向量。

由于仅依靠图传播不足以充分建模节点内部及跨尺度的结构特征,本文在图消息传递后增加了多尺度时序聚合。对于第 m 个尺度下的图输出特征 $\mathbf{H}^{(l,m)}$,通过两层一维卷积 $\psi^{(m)}(\cdot)$ 进一步建模节点序列间的顺序关系,得到尺度级表示。随后,对所有尺度的特征进行拼接与融合,生成多尺度动态图与对比学习的盲信号分离网络的最终输出特征 $\mathbf{F}$:

$$\mathbf{Z}^{(m)} = \psi^{(m)}(\mathbf{H}^{(l,m)}) \quad (12)$$

$$\mathbf{F} = \text{Conv}_{1 \times 1}(\text{ReLU}(\text{Concat}(\mathbf{Z}^{(1)}, \mathbf{Z}^{(2)}, \dots, \mathbf{Z}^{(M_s)}))) \quad (13)$$

其中, $\mathbf{Z}^{(m)}$ 为第 m 个尺度经过时序聚合后得到的尺度

级特征表示, M_s 表示采用的尺度数, F 为送入后续自编码器的深层融合特征。相比原有基于空洞卷积的特征提取方式, 该模块具有三方面优势。一是能够显式建模时间跨度较大但统计结构相似的干扰片段关联; 二是动态图结构随输入样本自适应更新, 能更好地应对复杂电磁环境中非平稳、突发性干扰的变化; 三是多尺度建模策略兼顾了短时调制细节与长时上下文信息, 从而为后续自编码器提供了更具判别性的高层特征表示。

2.4 目标信号匹配驱动的对比学习自编码器

尽管上一步特征提取模块能够提高前端分离特征的可分性, 但仅依靠时域回归损失难以保证多尺度

动态图与对比学习的盲信号分离网络在隐空间中实现目标信号与干扰的有效表征与区分。传统自编码器主要通过重构损失最小化估计信号与纯净 SOI 的差异, 缺乏对干扰特征的显式排斥约束, 导致在低信噪比条件下易出现特征混叠。针对上述问题, 本文采用基于目标信号匹配驱动的对比学习自编码器, 该模块由调制匹配编码器、调制匹配解码器、训练期共享编码器、两层投影头与对比约束层组成, 如图 4 所示。其中, 主重构路径实现从主干特征到目标信号估计值的映射; 训练阶段的对比分支则在表征空间内约束估计 SOI 特征、趋近纯净 SOI 特征并远离干扰特征, 以此提升隐空间中目标与干扰的可分性。




图4 目标信号匹配驱动的对比学习自编码器

Figure 4 Contrastive learning autoencoder driven by target signal matching

输入为多尺度动态图与对比学习的盲信号分离网络输出的深层融合特征, 经调制匹配编码器 $E_m(\cdot)$ 输出其末端的瓶颈潜表示 z 。该低维语义表示用于压缩混合特征中的冗余干扰成分, 并尽可能保留与目标信号调制结构相关的关键语义。随后, 调制匹配解码器 $D_m(\cdot)$ 根据该潜表示恢复目标信号估计值 $\hat{s}$, 如式 (14) 所示。针对不同类型的 SOI, 采用相应的调制匹配头进行处理。

$$\hat{s} = D_m(z) = D_m(E_m(F)) \quad (14)$$

对于单载波 QPSK 信号, 目标信号匹配驱动的对比学习自编码器采用 4 层步长为 2 的一维卷积进行逐级压缩, 最终将张量映射为长度为 5120 的潜表示 $z_q \in \mathbb{R}^{5120}$ 。该结构与 QPSK 每符号 2 比特、总符号数以及序列长度之间的对应关系保持一致。对应的解

码器首先通过卷积将潜向量重新映射为符号级表示, 随后利用核长为 129、步长为 16 的转置卷积恢复脉冲成形后的波形, 最终经卷积操作输出双通道 I/Q 波形 $\hat{s}_q$ 。

对于 OFDM-QPSK 信号, 其基本结构为每 80 个采样点对应一个 OFDM 符号块, 其中包含 56 个承载 QPSK 符号的有效子载波。因此, 目标信号匹配驱动的对比学习自编码器首层采用卷积核大小和步长一致为 80 的卷积操作, 将时域波形分块映射至频域相关表示。首先, 执行一维卷积进行压缩, 其中 112 个通道对应 56 个有效子载波的实部与虚部; 随后通过卷积完成通道重组, 并映射为潜表示 $z_o \in \mathbb{R}^{57344}$, 该过程与 OFDM 有效载波上 QPSK 复符号的组织方式严格对齐。对应的解码器首先将潜向量恢复为载波级符

号表示,再通过符号到波形的映射层将每组 56 个有效子载波符号重建为 I/Q 采样点,并经维度重塑得到最终输出 $\hat{s}_o$ 。此映射链条与 OFDM 的物理生成机制一致,相比直接的端到端波形回归,更有利于多尺度动态图与对比学习的盲信号分离网络学习稳定的多载波结构。

目标信号匹配驱动的对比学习自编码器的关键不仅在于匹配调制结构,更在于显式解耦 SOI 与干扰。为此, DGCL 引入一个共享编码器 $E_c(\cdot)$, 并增加一个两层投影头 $g(\cdot)$, 将不同来源的特征映射至统一的对比空间。针对单一训练样本, 定义锚点特征为 $q_a = g(E_c(s))$, 即纯净 SOI 编码后的特征; 正样本特征 $q_p = g(E_c(\hat{s}))$, 即多尺度动态图与对比学习的盲信号分离网络分离结果编码后的特征; 负样本特征 $q_n = g(E_c(b))$, 即对应真实干扰的编码结果。据此, 对比损失定义为

$$\mathcal{L}_{\text{con}} = -\log \frac{\exp(\text{sim}(q_a, q_p)/\tau)}{\exp(\text{sim}(q_a, q_p)/\tau) + \exp(\text{sim}(q_a, q_n)/\tau)} \quad (15)$$

该损失在几何空间中施加聚合 SOI 特征与排斥干扰特征的双重约束, 引导目标信号匹配驱动的对比学习自编码超越单一的波形轮廓拟合, 进而提取更利于后续解调的纯净目标。同时在重构层面, 采用时域 MSE 约束波形恢复精度 $\mathcal{L}_{\text{rec}}$; 在符号层面, 利用已知比特标签构建比特级监督 $\mathcal{L}_{\text{bit}}$, 即解码器隐层预测比特后验 $\hat{m}$ 与真实比特序列 m 的误差计算。基于 $\mathcal{L}_{\text{rec}}$

和 $\mathcal{L}_{\text{bit}}$ 维度, 最终定义联合损失函数 $\mathcal{L}_{\text{join}}$, 计算如下:

$$\mathcal{L}_{\text{rec}} = \frac{1}{N} \|\hat{s} - s\|_2^2 \quad (16)$$

$$\mathcal{L}_{\text{bit}} = \text{BCE}(\hat{m}, m) \quad (17)$$

$$\mathcal{L}_{\text{join}} = \lambda_1 \mathcal{L}_{\text{rec}} + \lambda_2 \mathcal{L}_{\text{bit}} + \lambda_3 \mathcal{L}_{\text{con}} \quad (18)$$

其中: λ_1 为波形重构损失权重, λ_2 为比特级特征损失权重, λ_3 为对比特征损失权重; N 为单个目标信号序列包含的离散时间采样点数, 即参与重构损失计算的复采样点数量。

综上所述, 本文的 DGCL 方法将已知调制结构先验引入瓶颈层, 从而降低重构难度, 在隐空间中显式分离目标特征与干扰特征, 最终实现多维度的联合损失不断优化。

2.5 隐空间流形混合增强策略

仅依赖有限干扰样本训练的射频分离模型, 易对固定干扰模式产生过拟合现象。真实复杂电磁环境中的干扰在带宽、占空比、突发性与相位扰动等方面更为复杂, 如果仅在输入波形层面进行简单加噪或线性叠加, 不仅会破坏复基带信号原有的相位连续性, 也难以在深层语义空间中有效扩展模型的判别边界, 对未见干扰模式的泛化能力与鲁棒性表现极差。

针对上述问题, 本文提出的 DGCL 方法中, 在深层特征空间部分引入流形混合增强策略, 如图 5 所示。在多尺度动态图与对比学习的盲信号分离网络的输出特征 F 处, 从同批次中随机选取两个样本特征 (F_i, S_i) 与 (F_j, S_j) , 来构造流形混合特征 $\tilde{F}$ 与软标签 $\tilde{s}$, 如式 (19)~式 (20) 所示。




图5 流形混合增强策略

Figure 5 Manifold mixup enhancement strategy

$$\tilde{F} = \lambda F_i + (1 - \lambda) F_j \quad (19)$$

$$\tilde{s} = \lambda S_i + (1 - \lambda) S_j \quad (20)$$

其中, λ 为采样混合系数, 随后将插值特征 $\tilde{F}$ 输入后

续目标信号匹配驱动的对比学习自编码器得到混合样本预测 $\hat{s}$, 从而构建正则项:

$$\mathcal{L}_{\text{mix}} = \frac{1}{N} \|\hat{s} - \tilde{s}\|_2^2 \quad (21)$$

所提方法未在输入波形域进行硬混合,而是选择在高维流形空间进行特征级插值。深层特征已有效编码特定波类的调制结构与干扰统计特性,在此空间进行凸组合既能形成平滑的决策边界,又避免了直接破坏原始波形的局部相位轨迹。即:在不同干扰强度与模式之间人为构建连续的过渡样本,促使多尺度动态图与对比学习的盲信号分离网络拟合更平滑的映射函数。因此,多尺度动态图与对比学习的盲信号分离网络的总训练目标定义为 $\mathcal{L}_{\text{total}}$:

$$\mathcal{L}_{\text{total}} = \mathcal{L}_{\text{join}} + \lambda_4 \mathcal{L}_{\text{mix}} \quad (22)$$

其中, λ_4 为混合损失项的权重系数。在推理阶段将关闭流形混合增强策略,多尺度动态图与对比学习的盲信号分离网络仅保留正常的前向传播路径。此设计的核心在于通过隐空间插值提升模型对未知干扰模式的泛化能力,而非单纯强化波形重构性能。

2.6 算法步骤

基于上述多尺度动态图时序特征提取、目标信号匹配驱动的对比学习自编码器、隐空间流形混合增强机制,模型训练的具体步骤如算法 1 所示。

3 实验结果与分析

3.1 实验设置

本研究采用 ICASSP24 公开数据集^[1]。该数据集包含由软件无线电生成的纯净目标信号,以及通过真实无线环境捕获或信道模拟器生成的干扰信号。目标信号涵盖单载波和多载波两种典型通信体制,旨在验证分离多尺度动态图与对比学习的盲信号分离网络对不同基带物理结构的自适应重构能力。包含单载波 QPSK 与多载波 OFDM-QPSK 两类主流数字调制信号作为目标信号;同时有四种代表性的干扰信号,包含 CommSignal2、CommSignal3、CommSignal5G1 结构化通信干扰,以及 EMISignal1 非结构化电磁干扰,以模拟复杂电磁环境中的干扰特性。为构造同频干扰场景,对部分干扰信号进行频谱对齐处理,使其与目标信号频谱重叠。此外,干扰信号功率支持动态调整,便于评估模型在不同信干噪比条件下的分离性能。数据集的核心配置参数如表 1 所示。

为评估信号分离性能,本文选取 MSE 与 BER 作为核心评价指标。

模型训练基于 PyTorch 框架实现。在算法 1 所述的训练流程中,网络设定的批次大小为 64,最大训练轮数为 100 轮。优化器采用 AdamW,初始学习率设定为 1×10^{-3} ,并配合余弦退火学习率衰减策略。对于多损失函数联合优化, $\lambda_1 = 1$, $\lambda_2 = 0.5$, $\lambda_3 = 0.1$ 。流形混合增强在训练期的分支权重设定为 $\lambda_4 = 0.2$ 。温度系数 τ 与形态参数 α 根据 4.4 节的消融寻优结果,分别固定为 0.1 与 0.5。

算法 1 DGCL 模型训练

输入:混合复基带信号集 $\mathcal{Y}$ 、纯净目标信号集 $\mathcal{S}$ 、已知比特标签序列

$\mathcal{M}$ 、训练批次大小 N_b 、最大训练轮数 E_{max} 、温度系数 τ 、Beta 分

布形态参数 α 、多尺度划分参数 $\{L_m\}$ 、损失函数权重 $\lambda_1, \lambda_2, \lambda_3, \lambda_4$

输出:训练完成的分离网络模型参数 θ

1. 初始化网络模型参数 θ
2. FOR epoch=1 TO E_{max} DO
3. FOR each mini-batch IN dataloader DO
4. 获取当前批次的混合信号 $\mathbf{y} \in \mathbb{R}^{N_b \times 2 \times N}$, 以及对应的纯净信号 $\mathbf{s}$ 和真实干扰信号 $\mathbf{b} = \mathbf{y} - \mathbf{s}$
5. 针对不同尺度 s , 将信号划分为多个局部片段 $\mathbf{p}_l^{(m)}$, 并编码提取初始节点特征 $\mathbf{X}^{(m)}$
6. 计算特征余弦相似度, 构建稀疏且归一化的动态图邻接矩阵 $\mathbf{A}^{(m)}$
7. 执行图消息传递、门控过滤与残差连接, 获取节点更新特征 $\mathbf{H}^{(l, m)}$
8. 将各尺度特征进行拼接融合, 得到深层主干融合特征 $\mathbf{F}$
9. 将特征 $\mathbf{F}$ 输入调制匹配自编码器, 经编码器与解码器重构出目标信号估计值 $\hat{\mathbf{s}}$
10. 将 $\mathbf{s}, \hat{\mathbf{s}}, \mathbf{b}$ 分别输入共享编码器与投影头, 构建锚点特征 $\mathbf{q}_a$ 、正样本特征 $\mathbf{q}_p$ 和负样本特征 $\mathbf{q}_n$
11. 计算波形重构损失 $\mathcal{L}_{\text{rec}}$ 、比特损失 $\mathcal{L}_{\text{bit}}$ 以及对比特征损失 $\mathcal{L}_{\text{con}}$
12. IF 处于训练阶段 THEN
13. 随机抽取批次内两组样本特征 $\mathbf{F}_i, \mathbf{F}_j$ 及对应真实标签 $\mathbf{s}_i, \mathbf{s}_j$
14. 生成满足 $\text{Beta}(\alpha, \alpha)$ 分布的随机变量 λ
15. 执行流形插值构造特征 $\tilde{\mathbf{F}}$ 与软标签 $\tilde{\mathbf{s}}$
16. 将 $\tilde{\mathbf{F}}$ 送入自编码器得到混合估计值 $\hat{\tilde{\mathbf{s}}}$, 并计算 Mixup 增强样本损失 $\mathcal{L}_{\text{mix}}$
17. END IF
18. 根据式(22)计算联合总优化损失
19. 使用反向传播算法计算梯度, 并更新多尺度动态图与对比学习的盲信号分离网络参数 θ
20. END FOR
21. END FOR

3.2 实验对比

为验证 DGCL 的有效性, 本文选取 WaveNet^[1]、KU-TII^[11]、LHen^[12] 和 OneInAMillion^[13] 四种具有代表性的深度学习模型作为对比方法。WaveNet 是该任务中最具代表性的时域卷积基线模型, 能够通过堆叠空洞卷积扩大时域感受野, 是后续多种改进模型的重要基础。KU-TII 在 WaveNet 框架上引入可学习空洞率, 并结合更有针对性的数据增强策略, 是目前相关任务中表现最优的方法之一。LHen 在基础分离网络之后进一步引入与目标信号匹配的自编码器结构, 重点提升波形重构质量。OneInAMillion 则在编码-解码结构中融合全局注意力机制, 增强模型对长程依赖和全局上下文信息的建模能力。上述基线模型分别代表了固定卷积建模、可学习感受野调节、匹配式重构约束以及卷积-注意力联合建模等不同技术路线。通过与这些模型进行对比, 可以较为全面地考察

表 1 数据集配置与信号参数表

Table 1 Dataset configuration and signal parameters

参数项	取值/描述	说明
SOI调制类型	单载波 QPSK、多载波 OFDM-QPSK	覆盖单/多载波主流通信场景
QPSK 配置	过采样因子 $F=16$ 滚降系数为 0.5 首符号偏移 $\tau_0=8$	用于生成单载波 QPSK 目标信号
OFDM-QPSK 配置	$K=64, K=56$ 个有效子载波 8 个空载波 $T_{cp}=16$, 单符号块 80 个采样点 子载波间隔 $\Delta f=78.125$ kHz 有效占用带宽约为 4.375 MHz	每个有效子载波承载 QPSK 符号, 空子载波承载零符号
干扰类型 (记录带宽)	EMISignal1 (25 MHz) CommSignal2 (25 MHz) CommSignal3 (25 MHz) CommSignal5G1 (61.44 MHz)	包含非结构化 EMI 与结构化通信干扰, 覆盖不同复杂度干扰场景
信干噪比(SINR)	-30~0 dB	覆盖极端干扰与干扰能量相当
单帧信号 长度	$N=40\ 960$ 个复数采样点	对应观测窗口约 8.192 ms
频谱对齐 处理	对部分未居中的干扰信号进行额外频移, 使其频谱能量对齐至基带附近	用于构造目标信号与干扰信号在时域和频域均重叠的同频干扰场景

DGCL 在复杂干扰场景下的分离性能与泛化能力。

从表 2 可以看出, 在单载波 QPSK 场景下, 本文提出的 DGCL 方法有效平衡了这些维度特征, 表现出稳定优势, 在全部 7 个 SINR 点上均取得了最优。尤其在强干扰区间, 性能提升更为显著, 在 -30 dB 条件下将 BER 降低至 1.58×10^{-1} , MSE 改善至 -59.6 dB, 超越了表现强劲的低 SINR 基线 OneInAMillion。这表明单纯依赖全局注意力或匹配重构机制不足以应对复杂的同频干扰。相反, 图结构建模与目标引导约束的协同整合使多尺度动态图与对比学习的盲信号分离网络能够更好地辨别局部结构与非局部干扰模式, 从而保持目标信号的完整性并提升比特级恢复精度。综上, 单纯依赖可学习空洞率、匹配重构或注意力建模仍不足以充分解决复杂同频干扰条件下的盲分离问题, 而图结构建模、目标引导约束与增强策略的协同更有助于提升整体盲信号分离性能。

从表 3 可以看出, 由于子载波耦合、频域结构破坏和符号间干扰的共同影响, 多载波 OFDM-QPSK 场景带来了更大的挑战。尽管存在这些困难, DGCL 依然在全部 7 个 SINR 点上同时取得了最优的 BER 和 MSE, 保持了领先地位。在 -15~0 dB 的中高 SINR 区间内, 性能优势变得尤为突出。例如, 在 0 dB 时, 实现了 1.28×10^{-2} 的 BER, 大幅超越了最接近的基线模型。这种一致的卓越表现证实了 DGCL 并未对特定

调制体制产生过拟合, 相反, 其具备强大的泛化能力, 能够在复杂未知干扰下有效地保持多载波信号的频域结构一致性和符号对齐。

为进一步分析模型在不同干扰类型下的适应能力, 本文对四类干扰在全 SINR 范围内的平均性能进行统计, 结果如表 4 所示。可以看出, 本文提出的 DGCL 方法, 在 QPSK 和 OFDM 两种目标信号条件下, 均在全部干扰场景中取得了最优或并列最优的综合表现, 说明 DGCL 对不同统计结构干扰具有较好的普适性。其中, CommSignal3 作为最具挑战性的干扰模式, 其与目标信号存在严重的时频混叠。即使在这种情况下, 本文提出的 DGCL 依然在 QPSK 和 OFDM 场景下分别取得了 2.06×10^{-1} 和 2.84×10^{-1} 的最低 BER。此外, 在 QPSK 的高度结构化的 CommSignal5G1 干扰场景中, 本文提出的 DGCL 方法将 BER 显著降低至 2.91×10^{-3} , 超越了最优基线 OneInAMillion, 实现了更高的波形恢复保真度。综合指标表明, 多尺度动态图神经网络特征提取模块能够较好地捕捉不同干扰片段之间的非局部相关性, 而目标信号匹配约束与对比学习机制则有助于增强目标成分在隐空间中的聚合, 抑制干扰特征残留。

3.3 消融实验

为量化验证动态图神经网络的多尺度图时序特征提取模块、目标信号匹配驱动的对比较学习自编码器

表 2 单载波 QPSK 信号不同 SINR 下四类干扰分离性能均值表

Table 2 Mean separation performance of four types of interference for QPSK under different SINR

指标	模型	−30 dB	−25 dB	−20 dB	−15 dB	−10 dB	−5 dB	0 dB
BER	WaveNet	2.21×10^{-1}	1.40×10^{-1}	9.50×10^{-2}	6.11×10^{-2}	3.03×10^{-2}	8.35×10^{-3}	8.74×10^{-4}
	KU-TII	2.23×10^{-1}	1.41×10^{-1}	8.82×10^{-2}	5.60×10^{-2}	2.91×10^{-2}	8.00×10^{-3}	7.35×10^{-4}
	LHen	2.36×10^{-1}	1.48×10^{-1}	9.44×10^{-2}	5.76×10^{-2}	2.81×10^{-2}	8.00×10^{-3}	7.85×10^{-4}
	OneInAMillion	1.71×10^{-1}	1.31×10^{-1}	8.83×10^{-2}	5.86×10^{-2}	3.12×10^{-2}	1.10×10^{-2}	1.17×10^{-3}
	DGCL	1.58×10^{-1}	1.18×10^{-1}	7.36×10^{-2}	4.38×10^{-2}	2.05×10^{-2}	4.92×10^{-3}	2.68×10^{-4}
MSE/ dB	WaveNet	-3.31×10^{-1}	-6.34×10	-1.24×10^2	-2.28×10^2	-3.07×10^2	-3.69×10^2	-4.02×10^2
	KU-TII	-2.55×10	-5.97×10	-1.19×10^2	-2.11×10^2	-3.07×10^2	-4.00×10^2	-4.31×10^2
	LHen	-2.76×10	-5.99×10	-1.22×10^2	-2.31×10^2	-3.49×10^2	-4.41×10^2	-5.03×10^2
	OneInAMillion	-5.20×10	-8.12×10	-1.54×10^2	-2.68×10^2	-3.19×10^2	-3.85×10^2	-4.21×10^2
	DGCL	-5.96×10	-9.47×10	-1.68×10^2	-2.89×10^2	-3.68×10^2	-4.53×10^2	-5.21×10^2

表 3 多载波 OFDM-QPSK 信号不同 SINR 下四类干扰分离性能均值表

Table 3 Mean separation performance of four types of interference for OFDM-QPSK under different SINR

指标	模型	−30 dB	−25 dB	−20 dB	−15 dB	−10 dB	−5 dB	0 dB
BER	WaveNet	3.32×10^{-1}	2.72×10^{-1}	1.91×10^{-1}	1.24×10^{-1}	7.10×10^{-2}	4.20×10^{-2}	1.98×10^{-2}
	KU-TII	3.38×10^{-1}	2.67×10^{-1}	1.86×10^{-1}	1.29×10^{-1}	7.28×10^{-2}	4.01×10^{-2}	2.37×10^{-2}
	LHen	3.44×10^{-1}	2.68×10^{-1}	1.94×10^{-1}	1.18×10^{-1}	7.32×10^{-2}	3.97×10^{-2}	1.81×10^{-2}
	OneInAMillion	2.95×10^{-1}	2.60×10^{-1}	1.94×10^{-1}	1.14×10^{-1}	7.62×10^{-2}	4.84×10^{-2}	2.47×10^{-2}
	DGCL	2.81×10^{-1}	2.45×10^{-1}	1.76×10^{-1}	1.03×10^{-1}	6.12×10^{-2}	3.21×10^{-2}	1.28×10^{-2}
MSE/dB	WaveNet	-1.67×10^0	-2.72×10^0	-4.74×10^0	-7.42×10^0	-1.04×10	-1.41×10	-1.67×10
	KU-TII	-1.74×10^0	-2.82×10^0	-4.93×10^0	-7.64×10^0	-1.05×10	-1.40×10	-1.66×10
	LHen	-1.73×10^0	-2.89×10^0	-5.20×10^0	-8.79×10^0	-1.30×10	-1.98×10	-2.45×10
	OneInAMillion	-2.17×10^0	-2.70×10^0	-4.61×10^0	-7.15×10^0	-9.84×10^0	-1.32×10	-1.60×10
	DGCL	-2.28×10^0	-3.34×10^0	-5.82×10^0	-9.66×10^0	-1.42×10	-2.12×10	-2.63×10

表 4 单多载波四类干扰下全 SINR 分离性能均值表

Table 4 Mean separation performance over full SINR range for four interference types of QPSK/OFDM-QPSK

指标	模型	QPSK				OFDM			
		EMI	C2	C3	C5G	EMI	C2	C3	C5G
BER	WaveNet	1.22×10^{-2}	5.68×10^{-2}	2.25×10^{-1}	2.40×10^{-2}	6.25×10^{-2}	1.58×10^{-1}	3.11×10^{-1}	6.89×10^{-2}
	KU-TII	1.21×10^{-2}	5.82×10^{-2}	2.21×10^{-1}	2.09×10^{-2}	6.55×10^{-2}	1.55×10^{-1}	3.13×10^{-1}	6.99×10^{-2}
	LHen	1.30×10^{-2}	6.51×10^{-2}	2.18×10^{-1}	3.09×10^{-2}	6.49×10^{-2}	1.64×10^{-1}	3.06×10^{-1}	6.81×10^{-2}
	OneInAMillion	1.41×10^{-2}	4.45×10^{-2}	2.18×10^{-1}	4.38×10^{-3}	5.65×10^{-2}	1.66×10^{-1}	2.95×10^{-1}	6.12×10^{-2}
	DGCL	1.08×10^{-2}	3.96×10^{-2}	2.06×10^{-1}	2.91×10^{-3}	5.18×10^{-2}	1.43×10^{-1}	2.84×10^{-1}	4.97×10^{-2}
MSE/ dB	WaveNet	-2.84×10	-2.38×10	-5.17×10^0	-2.99×10	-1.30×10	-6.68×10^0	-2.49×10^0	-1.08×10
	KU-TII	-2.64×10	-2.83×10	-5.48×10^0	-2.86×10	-1.34×10	-6.88×10^0	-2.16×10^0	-1.09×10
	LHen	-2.92×10	-2.90×10	-5.47×10^0	-3.54×10	-1.59×10	-1.28×10	-2.60×10^0	-1.21×10
	OneInAMillion	-2.87×10	-2.44×10	-5.47×10^0	-3.75×10	-1.33×10	-6.22×10^0	-2.15×10^0	-1.02×10
	DGCL	-3.08×10	-3.05×10	-6.21×10^0	-4.02×10	-1.67×10	-1.39×10	-3.08×10^0	-1.46×10

以及隐空间流形混合增强三个模块对整体分离性能的独立贡献与协同机制,本节以单载波 QPSK 信号受 CommSignal2 同频干扰的复杂时频混叠场景为例,开展消融实验。实验以基础 WaveNet 框架作为基线模型(Config1),其配置为因果空洞卷积主干与 MSE 重构损失。通过逐级引入所提模块构造了 5 组递进式验证多尺度动态图与对比学习的盲信号分离网络。

为确保对比的公平性与架构的完整性,移除某一模块时,均采用等效的传统射频处理模块进行替换,具体实验配置与性能表现如表 5 所示。

由表 5 可见,与基线 Config1 相比,仅引入动态图神经网络特征提取模块的 Config2 能有效增强模型对复杂非平稳干扰的非局部相关性建模能力,使多尺度动态图与对比学习的盲信号分离网络从混合信号中

表 5 消融实验结果

Table 5 Ablation experiment results

实验配置编号	特征提取模块	自编码器	流形混合增强	MSE/dB	BER/ $\times 10^{-2}$
Config1(基线)	×	×	×	-2.38×10	5.68
Config2	√	×	×	-2.66×10	5.12
Config3	×	√	×	-2.81×10	4.87
Config4	√	√	×	-2.98×10	4.05
Config5(Full)	√	√	√	-3.05×10	3.96

提取更具判别性的时序结构特征。而仅引入对比学习自编码器的 Config3 较传统重构造式编码结构能更有效区分目标与干扰成分,提升分离精度。对比 Config2 与 Config3 可见,两类模块均有贡献,且对比约束自编码器在当前场景下的单模块增益略高于动态图神经网络特征提取模块。

同时引入动态图神经网络特征提取模块与对比学习自编码器后,Config4 性能进一步改善,表明两类模块具有较强的互补性。前者侧重于从混叠信号中提取动态时序特征,后者利用隐空间结构约束和目标匹配机制对深层特征进一步解耦,二者构成高质量特征提取与判别性特征分离的处理链路,综合性能优于

单模块配置。

在此基础上引入隐空间流形混合增强后,完整模型(Config5)的提升幅度虽小,但进一步改善了模型的泛化能力。其通过在隐空间构造连续过渡的增强样本,扩展了训练特征的分布范围,使模型学习到更平滑的分离映射,能在复杂干扰条件下具备更好的鲁棒性。

3.4 超参数分析

为确定模型核心超参数的最优取值,分析其对模型性能的影响规律,本实验在单载波 QPSK 与 CommSignal2 干扰场景下,基于完整模型,分别对对比学习温度系数 τ 和流形混合 Beta 分布参数 α 两个关键超参数开展单变量分析。

在目标信号匹配驱动的对比学习自编码器中,温度系数 τ 是余弦相似度的归一化调节因子,主要用于控制隐空间样本特征的相似度分布平滑程度。较小的 τ 会放大样本间的差异,使模型更加关注困难负样本,从而增强目标信号与干扰信号的判别能力,但取值过小会导致梯度波动增大,影响训练稳定性;较大的 τ 会使相似度分布过于平滑,削弱对比损失的判别性约束,导致目标与干扰特征在隐空间中的分离度下降。不同温度系数下的实验结果如表 6 所示。

表 6 不同概率平滑温度系数 τ 调节下的全局模型性能演变表现Table 6 Global model performance evolution with different τ

温度平滑系数 τ	0.05	0.1	0.5	1	2
MSE/dB	-2.97×10	-3.05×10	-3.02×10	-2.94×10	-2.88×10
BER	4.18×10^{-2}	3.96×10^{-2}	4.01×10^{-2}	4.21×10^{-2}	4.43×10^{-2}

由表 6 可知,随着 τ 的增大,模型性能整体呈先升后降的趋势。当 $\tau=0.1$ 时,模型性能达到最优。相较于 τ 更小时的结果,其结果进一步改善,表明适中的温度系数能在特征判别性与训练稳定性之间取得较好平衡。当 τ 增大至 0.5、1 和 2 时,模型性能逐步下降,其中 $\tau=2$ 时退化最为明显,表明温度系数过大会压缩隐空间中目标与干扰特征的距离,减弱对比约束的特征分离能力,进而影响信号分离效果。

表 7 不同 Beta 混合分布形态参数 α 干预下的模型鲁棒性能演变Table 7 Model robustness evolution with different α

形态参数 α	0.1	0.5	1	2	关闭 Mixup
MSE/dB	-3.00×10	-3.05×10	-3.03×10	-2.96×10	-2.98×10
BER	4.03×10^{-2}	3.96×10^{-2}	3.99×10^{-2}	4.15×10^{-2}	4.05×10^{-2}

由表 7 可知,与关闭 Mixup 对照组相比,引入流形混合增强的配置均在不同程度上提升了模型性能,说明该模块能有效扩展训练样本分布,增强模型对复杂干扰场景的适应能力。其中,当 $\alpha=0.5$ 时模型取得最优结果;当 α 较低时,插值样本过于接近原始样本,增

在隐空间流形混合增强模块中,混合系数 λ 由 Beta(α, α) 分布采样得到,参数 α 主要控制插值样本的分布特征。当 $\alpha < 1$ 时, λ 倾向于取 0 或 1 附近的值,插值样本接近原始样本,保留了原始信号的特征分布;当 $\alpha > 1$ 时, λ 倾向于取 0.5 附近的值,插值样本集中在两个原始样本的中间混合区域;当 $\alpha=1$ 时, λ 服从均匀分布,插值样本均匀覆盖全区间。本实验设置 α 取值为 {0.1, 0.5, 1, 2}, 并增设关闭 Mixup 的对照组,实验结果如表 7 所示。

强样本多样性不足,性能提升有限;当 $\alpha=1$ 时,性能仍保持较优水平;当 $\alpha=2$ 时,插值样本过度集中于中间混合区域,易破坏原始信号结构,导致 MSE 与 BER 出现明显退化。结果表明,只有适中的插值强度才能保留原始样本的判别边界,生成具有过渡特性的增强

样本,使模型学到更稳健的特征表示。

4 结论

本文提出了一种基于动态图神经网络与对比学习的单通道同频盲信号分离网络 DGCL。针对复杂非平稳干扰下存在的非局部相关性建模不足、目标与干扰隐空间特征耦合以及对未知干扰泛化性弱等问题,该网络从图拓扑建模与特征空间解耦视角出发,设计了创新性解决方案。通过将混合复基带序列映射为多尺度图结构,突破了传统卷积处理的局限,提出了动态图神经网络的多尺度图时序特征提取、目标信号匹配驱动的对比如学习自编码器与隐空间流形混合三项核心机制。特征提取模块通过自适应构图与图消息传递,捕获了时间跨度较大但统计相似的干扰片段间的非局部关联,增强了特征表征能力;目标信号匹配驱动的对比如学习自编码器在重构目标信号的同时,通过构建正负样本并在隐空间施加对比约束,有效划定了目标与干扰的特征边界;流形混合增强策略则通过在深层特征中构造连续过渡样本,扩展了特征分布,显著提升了模型对未知干扰模式的泛化性与鲁棒性。实验结果表明,本文提出的 DGCL 方法,在单载波、多载波及多类典型干扰数据集上均取得了显著的性能提升。相较于现有基线网络, DGCL 在误码率和均方误差两项核心指标上均表现出稳定优势,验证了该方法的有效性与普适性。尽管如此,面对更加极端和开放的真实电磁环境,如何有效实现多目标的有效分离,并提升模型在异构设备、动态网络及复杂干扰条件下的鲁棒性与适应能力^[30],仍然是需要深入研究的重要方向。

参考文献

- [1] Lancho A, Weiss A, Lee G C F, et al. RF challenge: The data-driven radio frequency signal separation challenge[J]. IEEE Open Journal of the Communications Society, 2025, 6: 4083-4100.
- [2] Hyvärinen A, Oja E. Independent component analysis: Algorithms and applications[J]. Neural Networks, 2000, 13(4/5): 411-430.
- [3] Hwang W L, Ho J. Null space component analysis of one-shot single-channel source separation problem[J]. IEEE Transactions on Signal Processing, 2021, 69: 2233-2251.
- [4] Wang Taihui, Yang Feiran, Yang Jun. Convolutional transfer function-based multichannel nonnegative matrix factorization for overdetermined blind source separation[J]. IEEE/ACM Transactions on Audio, Speech, and Language Processing, 2022, 30: 802-815.
- [5] Guo Pengcheng, Yu Miao, Shen Lei, et al. Single-channel blind source separation in wireless communications: A complex-domain deep learning approach[J]. IEEE Wireless Communications Letters, 2024, 13(6): 1645-1649.
- [6] Su Jie, Jiang Yuting, Ye Yuheng, et al. Patch matter: Dual modality patch contrastive for non-stationary radio signals[J]. IEEE Transactions on Mobile Computing, 2026, 25(4): 5936-5951.
- [7] 王瑞锦, 王金波, 张凤荔, 等. 联邦原型学习的特征图中毒攻击和双重防御机制[J]. 软件学报, 2025, 36(3): 1355-1374.
Wang Ruijin, Wang Jinbo, Zhang Fengli, et al. Feature map poisoning attack and dual defense mechanism for federated prototype learning[J]. Journal of Software, 2025, 36(3): 1355-1374. (in Chinese)
- [8] Liu Chao, Fu Xue, Wang Yu, et al. Overcoming data limitations: A few-shot specific emitter identification method using self-supervised learning and adversarial augmentation[J]. IEEE Transactions on Information Forensics and Security, 2024, 19: 500-513.
- [9] Yang Jian, Zhu Shaoxian, Wen Zhongyi, et al. Cross-receiver radio frequency fingerprint identification: A source-free adaptation approach[J]. Sensors, 2025, 25(14): 4451.
- [10] 万升, 杨健, 宫辰. 基于图神经网络的高光谱图像分类研究进展[J]. 电子学报, 2023, 51(6): 1687-1709.
Wan Sheng, Yang Jian, Gong Chen. Advances of hyperspectral image classification based on graph neural networks[J]. Acta Electronica Sinica, 2023, 51(6): 1687-1709. (in Chinese)
- [11] Tian Yu, Alhammadi A, Quran A, et al. A novel approach to wavenet architecture for RF signal separation with learnable dilation and data augmentation[C]//2024 IEEE International Conference on Acoustics, Speech, and Signal Processing Workshops. Piscataway: IEEE, 2024: 79-80.
- [12] Henneke L. Improving data-driven RF signal separation with SOI-matched autoencoders[C]//2024 IEEE International Conference on Acoustics, Speech, and Signal Processing Workshops. Piscataway: IEEE, 2024: 45-46.

- [13] Damara F, Utkovski Z, Stanczak S. Signal separation in radio spectrum using self-attention mechanism[C]//2024 IEEE International Conference on Acoustics, Speech, and Signal Processing Workshops. Piscataway: IEEE, 2024: 99-100.
- [14] Yapar Ç, Jaensch F, Hauff J C, et al. Demucs for data-driven RF signal denoising[C]//2024 IEEE International Conference on Acoustics, Speech, and Signal Processing Workshops. Piscataway: IEEE, 2024: 95-96.
- [15] Naseri M, Fontaine J, Moerman I, et al. A U-Net architecture for time-frequency interference signal separation of RF waveforms[C]//2024 IEEE International Conference on Acoustics, Speech, and Signal Processing Workshops. Piscataway: IEEE, 2024: 91-92.
- [16] Zhang Bingxu, Fan Changjun, Liu Shixuan, et al. The expressive power of graph neural networks: A survey[J]. IEEE Transactions on Knowledge and Data Engineering, 2025, 37(3): 1455-1474.
- [17] Jin Ming, Koh H Y, Wen Qingsong, et al. A survey on graph neural networks for time series: Forecasting, classification, imputation, and anomaly detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, 46(12): 10466-10485.
- [18] Shen Yifei, Shi Yuanming, Zhang Jun, et al. Graph neural networks for scalable radio resource management: Architecture design and theoretical analysis[J]. IEEE Journal on Selected Areas in Communications, 2021, 39(1): 101-115.
- [19] Lee M, Yu Guanding, Dai Huaiyu. Decentralized inference with graph neural networks in wireless communication systems[J]. IEEE Transactions on Mobile Computing, 2023, 22(5): 2582-2598.
- [20] Yin Xiaoyan, Lin Wanyu, Sun Kexin, et al. A²S²-GNN: Rigging GNN-based social status by adversarial attacks in signed social networks[J]. IEEE Transactions on Information Forensics and Security, 2023, 18: 206-220.
- [21] Wang Ruijin, Wang Jinbo, Li Xiong, et al. CESA: Communication efficient secure aggregation scheme via sparse graph in federated learning[J]. Journal of Network and Computer Applications, 2024, 231: 103997.
- [22] Huang Wei, Han Andi, Chen Yongqiang, et al. On the comparison between multi-modal and single-modal contrastive learning[C]//Advances in Neural Information Processing Systems 37. Neural Information Processing Systems Foundation, Inc. (NeurIPS), 2024: 81549-81605.
- [23] Yue Zhihan, Wang Yujing, Duan Juanyong, et al. TS2Vec: Towards universal representation of time series[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2022, 36(8): 8980-8987.
- [24] Du Mingyang, Pan Jifei, Bi Daping. A contrastive learner for automatic modulation classification[J]. IEEE Transactions on Wireless Communications, 2025, 24(4): 3575-3589.
- [25] Zhang Hongyi, Cissé M, Dauphin Y N, et al. Mixup: Beyond empirical risk minimization[C]//Proceedings of the 6th International Conference on Learning Representations. OpenReview.net, 2018: 2866-2878.
- [26] Verma V, Lamb A, Beckham C, et al. Manifold mixup: Better representations by interpolating hidden states[C/OL]//Proceedings of the 36th International Conference on Machine Learning. 2019: 6438-6447. <https://dblp.uni-trier.de/db/conf/icml/icml2019.html#conf/icml/VermaLBNMLB19>.
- [27] Hendrycks D, Mu N, Cubuk E D, et al. AugMix: A simple data processing method to improve robustness and uncertainty[C]//Proceedings of the 8th International Conference on Learning Representations. ICLR, 2020: 1108-1122.
- [28] Mu Shiyuan, Chen Shuai, Zu Yong, et al. Contrastive learning with feature-level augmentation for wireless signal representation[J]. Electronics, 2025, 14(13): 2728.
- [29] He Jialong, Xie Yuelei, Liu Xiangguo. Channel-robust specific emitter identification based on domain-adversarial training of neural networks and multi-feature fusion[J]. IEEE Access, 2025, 13: 153093-153104.
- [30] 王瑞锦, 赖金山, 王金波. 边缘计算下的联邦学习: 安全与隐私挑战[J]. 计算, 2026, 53(4): 24-31.
- Wang Ruijin, Lai Jinshan, Wang Jinbo. Federated learning in edge computing: Security and privacy challenges[J]. Computing Magazine of the CCF, 2026, 53(4): 24-31. (in Chinese)

作者简介



罗 鸣 男,2003年3月出生于河南省南阳市。现为电子科技大学信息与软件工程学院硕士研究生。主要研究方向为图神经网络、智能计算、知识图谱。

E-mail: 202522090401@std.uestc.edu.cn



赖金山 男,1998年10月出生于四川省资阳市。现为电子科技大学信息与软件工程学院博士研究生。主要研究方向为联邦学习与聚合安全、智能计算、网络与信息安全、区块链。

E-mail: 202311090910@std.uestc.edu.cn



孙鹏钊 男,1999年3月出生于河南省平顶山市。现为电子科技大学信息与软件工程学院博士研究生。主要研究方向为图神经网络、推荐系统。

E-mail: spz@std.uestc.edu.cn



张 昆 男,1982年1月出生于四川省成都市。高级工程师。主要研究方向为国产化基础软硬件。

E-mail: zhangkun@cdjrlc.com



张凤荔 女,1963年出生于河南省南阳市。现为电子科技大学教授。主要研究方向为智能计算、联邦学习、网络与信息安全。

E-mail: fzhang@uestc.edu.cn



王瑞锦 男,1980年出生于甘肃省天水市。现为电子科技大学教授。主要研究方向为联邦学习与聚合安全、智能计算、区块链、知识图谱、信息安全。

E-mail: ruijinwang@uestc.edu.cn