

DOI: 10.20189/j.cnki.CN/61-1527/E.202504005

杀伤网背景下基于深度学习的电磁频谱感知与预测技术分析

刘丁胤, 徐东辉, 刘思佚, 康 凯
(火箭军工程大学, 西安 710025)

摘 要: 针对杀伤网背景下电磁频谱资源利用所面临的挑战, 首先, 从杀伤网概念的界定出发, 梳理分析了其发展现状及关键技术, 并归纳总结了杀伤网跨域互联、动态适应性、抗毁自愈的基本特点。其次, 从作战运用需求出发, 对支撑杀伤网的通信网络应如何动态接入频段提高可靠通信和频谱资源利用率的问题进行了分析研究。最后, 基于真实数据集, 对当前应用较为普遍的频谱感知与预测模型进行仿真对比。为解决当前基于深度学习的频谱感知和预测模型所存在的不足, 提出了基于深度可分离卷积和特征融合的频谱感知模型、基于Mamba模型的频谱预测方法、联合频谱预测驱动频谱感知3个解决方案, 以应对杀伤网作战效能有效发挥时所面临的实时高效、低计算复杂度挑战。

关键词: 杀伤网; 频谱感知; 频谱预测; 深度学习

中图分类号: TN92

文献标志码: A

开放科学标识码(OSID):

文章编号: 2097-2741(2025)04-042-09



听语音
与作者
聊科研

Analysis of the Deep Learning-Based Technologies of Electromagnetic Spectrum Sensing and Prediction in the Context of a Kill Web

LIU Dingyin, XU Donghui, LIU Siyi, KANG Kai
(Rocket Force University of Engineering, Xi'an 710025, China)

ABSTRACT: First, the current development status and key technologies were analyzed based on the definition of a kill web in response to the challenges faced by the utilization of electromagnetic spectrum resources in the context of the kill web. The basic features of cross-domain interconnection, dynamic adaptability, anti-destruction, and self-healing of the kill web were summarized. Second, based on the operational requirements, a study was conducted to investigate how the communication network supporting kill web should dynamically access frequency bands to enhance reliable communication and spectrum resource utilization. Finally, based on real datasets, simulation comparisons were performed using commonly used spectrum sensing and prediction models.

收稿日期: 2025-04-08

修回日期: 2025-04-21

录用日期: 2025-05-06

基金项目: 军事类研究生资助课题 (JYKT910342023006)

第一作者: 刘丁胤 (2001—), 男, 硕士研究生, 主要从事认知无线电、频谱感知与预测研究。E-mail: 1378314905@qq.com

引用格式: 刘丁胤, 徐东辉, 刘思佚, 等. 杀伤网背景下基于深度学习的电磁频谱感知与预测技术分析[J]. 火箭军工程大学学报, 2025, 39 (4): 42-50. LIU Dingyin, XU Donghui, LIU Siyi, et al. Analysis of the deep learning-based technologies of electromagnetic spectrum sensing and prediction in the context of a kill web [J]. Journal of Rocket Force University of Engineering, 2025, 39 (4): 42-50.

To solve the deficiencies of current deep learning-based spectrum sensing and prediction models, three solutions were proposed: a spectrum sensing model based on depthwise separable convolution and feature fusion; a spectrum prediction method based on the Mamba model; and joint spectrum prediction-driven spectrum sensing, responding to the challenges of real-time, efficiency, and low computational complexity faced by the kill web in effective combat performance.

KEYWORDS: kill web; spectrum sensing; spectrum prediction; deep learning

随着信息化与智能化的飞速发展, 全新的作战概念不断被提出。杀伤网这一作战概念为作战样式的灵活多变与作战力量的动态组合带来更多可能。杀伤网源于杀伤链, 但与杀伤链有着本质区别。无论是美军还是我军, 都在不断探索杀伤网的构建。目前, 国内相关研究主要集中于分析外军相关项目研究以探索杀伤网的概念与构建方法及杀伤网网络建模 2 个方面^[1-6], 而针对支撑杀伤网通信网络关键技术的研究则较少。杀伤网中的通信网络对于无线频谱资源高效利用具有迫切需求。因此, 本文从杀伤网的需求出发, 对可以满足杀伤网跨域互联、动态适应、抗毁自愈等特点的相关频谱感知及预测技术进行探索, 分析频谱感知与频谱预测问题的本质, 分别从分类问题和预测问题出发, 对适合两者的模型与算法进行探究, 并对当前较为先进的基于深度学习的频谱感知及预测模型进行仿真实验, 分析其优势与不足。针对杀伤网背景下电磁频谱资源利用面临的挑战提出相应的解决方案, 为构建杀伤网通信网络的关键技术提供支撑。

1 杀伤网理论基础

1.1 杀伤网概念及其特点

杀伤链概念是在 1996 年空军协会研讨会上, 由美国空军前参谋长罗纳德·福格尔曼将军首次提出, 指的是“在打击一个目标的过程中各个相互依赖的环节构成的有序链条”^[7-8]。杀伤网的概念是在“马赛克战”的背景下提出的, 其定义为: 根据不同作战需求, 依赖于人工智能、大数据等技术, 快速组织战场当中跨域的传感器、武器平台、指挥控制及通信系统等作战单元, 智能决策、动态构建最优杀伤链链路并实施打击^[1-4]。

杀伤网将战场中的传感器、武器平台以及指挥控制节点连接起来, 以跨域协同、动态适应的方式形成灵活可控的作战力量, 通常具备以下特征^[2-3]。

1) 跨域协同性: 杀伤网集成陆、海、空、天、电多维节点, 打破不同作战空间之间的壁垒, 实现情报侦察、指挥控制、通信网络等系统深度协同, 形成多维度攻击窗口。

2) 动态适应性: 杀伤网依托实时数据处理与智能算法, 支持节点动态接入与网络形态灵活重构, 实现指挥决策优化, 保障杀伤链快速闭环并释放效能。

3) 抗毁自愈性: 杀伤网采用分布式、去中心化体系架构, 避免中心节点依赖, 通过冗余设计与快速重组抵御敌方“断点破链”攻击, 提升战场生存能力。

因此, 杀伤网是一张横跨多维度、涵盖多节点并动态配置资源的“网状”结构, 相较于传统“线性”结构的杀伤链, 具备更强的适应性以及战场生存能力。

1.2 杀伤网中的通信问题分析

通信网络是杀伤网构建中极为重要的一环。美国国防高级研究计划局在通信组网相关技术领域相继展开了“对抗环境下的通信”“任务优化动态网络自适应”“弹性组网分布式马赛克通信”“天基自适应通信节点”等项目研究, 旨在建立起横跨各域的通信网络, 以实现信息实时、高效地传输。

现有研究表明, 杀伤网的作战效能与其对无线电频谱资源的管控能力密切相关。李龙跃等^[3]对美军杀伤网关键技术进行解析, 提出需要发展自适应电子战与网络战技术, 通过动态频谱管理保护己方通信安全。赵仁星等^[4]提出, 杀伤网通过认知技术实现战场电磁环境感知与杀伤链动态重构, 提升了复杂对抗条件下的决策能力。路惠明^[5]揭示了当前通信技术需突破的三大瓶颈, 即全域韧性通信架构、广域通信覆盖能力及电磁环境自适应技术。张国华等^[6]提出的“马赛克战”体系进一步强调, 需建立具备电磁态势主动感知能力的动态频谱管理系统, 通过实时探测与预测实现频谱资源智能分配。

研究表明, 频谱态势的实时感知与预测技术是支撑杀伤网动态决策的核心基础。该技术通过解构敌方电磁行为特征, 可优化频谱调度策略并实现干扰规避, 从而保障战场通信链路的可靠性与抗毁性, 最终形成电磁空间的信息对抗优势。

2 杀伤网对电磁频谱利用提出的挑战

为提升杀伤网作战效能, 提高杀伤网中电磁频谱资源利用率, 创建高效可靠的通信网络, 本文结合杀伤网特性和通信网络需求进行分析研究, 基本思路如图 1 所示。




Fig. 1 Schematics of the characteristics and challenges of the kill web

2.1 动态接入对实时性的高要求

杀伤网的动态组网特性导致节点随时加入或退出, 频谱感知需实时更新节点分布与链路状态。当某节点被摧毁时, 剩余节点需及时重新分配感知任务。感知时耗是频谱感知无法避免的问题, 感知器需要持续感知频段, 以获取频谱空洞进行通信。而在高动态、强对抗的通信网络中, 为了保证对频谱信息的及时掌握, 必须实时获取频段使用情况信息, 而持续感知频谱的方法可能会导致未能及时获取频谱使用情况, 错过接入频谱的最佳时机。

2.2 抗毁自愈对高准确性的要求

杀伤网跨域组网, 联合陆、海、空、天、电多领域进行作战, 将面临复杂的背景噪声以及不同作战域所带来的不同衰落效应, 例如陆基通信易受地形遮挡, 海基通信易受多径反射影响, 天基链路存在多普勒频移。同时, 在敌我对抗的战

场环境下, 信号信噪比通常低于 -20 dB, 导致频谱感知与预测的准确率急剧下降。准确性是保证频谱利用率最基本的要求, 复杂电磁环境带来的感知、预测失效将导致大量资源消耗, 甚至影响杀伤网决策实施。

2.3 跨域互联对低计算复杂度的要求

杀伤网通信网络的研究追求在真实环境中进行部署, 而杀伤网去中心化要求分布式部署大量的硬件设备, 面临着硬件限制与算力有限的困难。因此, 需寻求高效且低计算复杂度的算法, 以平衡算法性能和计算复杂度之间的矛盾, 在减少能耗的同时保证感知及预测的准确性, 推进算法在杀伤网应用中的实际部署。

3 仿真实验与分析

分析现有频谱感知与预测技术的不足与缺陷, 并对基于深度学习的相应模型开展仿真实验, 分析现有模型的性能瓶颈, 提出改进方向以适应杀伤网复杂电磁环境的挑战。

3.1 频谱感知相关模型仿真与分析

频谱感知是认知无线电的基础, 通过动态检测电磁环境识别频谱空穴, 辅助次用户 (secondary user, SU) 无干扰接入主用户 (primary user, PU) 频段。复杂电磁环境下, 多径效应、阴影衰落及恶意干扰等问题降低了单用户感知的可靠性。协作频谱感知 (cooperative spectrum sense, CSS) 通过多节点协同提升性能, 主要分为 2 类。一是分布式 CSS, 节点自主交互数据, 无需控制中心, 鲁棒性高。Zhang 等^[9]引入区块链技术, 通过可信历史记录筛选高信誉节点, 抵御恶意攻击, 但系统开销较大; 二是集中式 CSS, 中心节点统一处理数据, 决策精度高。Tan 等^[10]利用经典卷积神经网络 (convolutional neural network, CNN) 模型处理能量矩阵, 在低信噪比下提升感知性能, 但计算成本随节点数增加。Chauhan 等^[11]提出“预测-感知”联合方案, 结合长短期记忆 (long short-term memory, LSTM) 网络预测与自适应融合规则, 可有效减少感知能耗, 但预测误差可能影响全局决策。

随着深度学习算法的不断发展, 大量性能优秀的模型被应用于频谱感知任务中。CNN 因其优秀的特征提取能力被广泛应用于图像分类、景象匹配^[12]等领域中。Xie 等^[13]通过 2 个 CNN 分别对

当前时刻信号的协方差矩阵与历史数据所构成的协方差堆叠矩阵进行特征提取, 在低信噪比条件下实现了良好的检测性能。Xie 等^[14]设计了一种 CNN-LSTM 感知模型, 使用多个感知周期内获取到的协方差矩阵作为训练数据, 通过 CNN 提取协方差矩阵当中的能量特征, 再通过 LSTM 提取隐藏在感知周期背后的时间特征进行感知。Fang 等^[15]结合 CNN 与 Transformer 捕获时间序列依赖关系的特性, 设计 CNN-Transformer 模型, 对集中式 CSS 当中多 SU 采集的接收信号矩阵进行特征提取, 融合了各 SU 采集信号的幅度空间特征以及在持续感知过程中的时间依赖性。

频谱感知可以视为检测 PU 信号是否存在的二分类问题^[16], 当 PU 正在发送信号时, SU 接收到的信号可以表示为

$$y(n) = c(n)x(n) + \omega(n) \quad (1)$$

式中: n 为时域采样点数量; $x(n)$ 为 PU 发射信号, 含有多种调制方式; $\omega(n)$ 为高斯噪声; $c(n)$ 为信道系数代表, 如多径衰落、阴影效应等信道损伤。

频谱感知可定义为 PU 信号是否存在的假设检验问题, 表达式为

$$\begin{aligned} H_0: y(n) &= \omega(n) \\ H_1: y(n) &= c(n)x(n) + \omega(n) \end{aligned} \quad (2)$$

式中: H_0 表示 PU 信号不存在, 该频段能够被 SU 使用; H_1 表示该频段已被 PU 占用。

对于频谱感知的性能指标常使用检测概率 P_d 来评估, P_d 表示 SU 正确发现 PU 存在的准确率, P_d 值越高说明模型性能越好^[17], 其表达式为

$$P_d = \frac{T_p}{T_p + F_N} \quad (3)$$

式中: T_p 表示模型正确判断为有信号的样本数量, F_N 表示模型错误判断为无信号的样本数量。

实验基于含加性高斯白噪声、多径衰落及 BPSK、QPSK、16QAM、64QAM 4 种调制方式的合成数据集进行, 对比了上述文献所提 CNN、CNN-LSTM 及 CNN-Transformer 等模型, 并增加了 GRU、TCN、Transformer、MLP-Transformer 等具有良好分类能力的模型。各模型在不同信噪比下的准确率如图 2 所示。

由图 2 可以看出, 在信噪比大于 5 dB 时, 各模型的检测准确率都能达到 90% 以上, 但当信噪比小于 -5 dB 后, 各模型感知性能急剧下降。在信

噪比为 -20 dB 时, 各模型准确率均未达到 50%。Transformer 类模型虽在抗噪性上有所提升, 但高计算复杂度限制了其在实际通信场景下的部署。因此, 亟需开发低信噪比下能够兼顾高检测概率与低计算复杂度的新型算法。




图 2 低信噪比下不同频谱感知模型准确率

Fig. 2 Accuracy of different spectrum sensing models at low SNR

3.2 频谱预测相关模型仿真与分析

频谱预测通过历史数据分析未来频谱占用状态, 降低感知时延与能耗。传统方法如马尔可夫模型仅关注时域特征, 难以满足复杂电磁环境的长期预测需求^[18-19]。多信道多步长预测技术通过多维特征建模实现宽频带、多时隙预测。赵春雁^[20]结合序列到序列模型与注意力机制, 提升多信道预测精度, 但数据错误率对鲁棒性影响较大。Pan 等^[21]提出堆叠式自动编码器和双向长短时记忆结合的预测方法, 利用时、频、空三维特征增强室外环境预测性能, 但训练成本较高。冯李杰^[22]采用 CNN-Bi-LSTM 预测星地频谱占用, 降低了传输时延, 但未解决长期预测的稳定性问题。

为了获取更准确的预测性能, 深度学习相关模型被广泛应用于频谱预测任务当中, LSTM 由于其长序列特征提取及记忆能力^[23-24], 能够很好地适用于预测当中。Transformer 中的注意力机制能够高效提取长时间序列中的隐藏信息, 为其应用于长期频谱预测奠定基础。其变体模型如 In-former^[25]、Autoformer^[26]等, 有效降低了模型的计算复杂度。

频谱预测旨在通过历史数据预测未来频谱占用状态, 其可被描述为

$$[P_{t-l}, P_{t-l+1}, \dots, P_t] \rightarrow [P_{t+1}, P_{t+2}, \dots, P_{t+m}] \quad (4)$$

式中: P_t 表示频谱监测数据; l 为回顾窗口; m 为预测步长。

基于 Electrosense^[27] 开放 API 上获取的真实聚

合频谱测量数据进行仿真验证。该数据是西班牙马德里市中心的 2 个传感器所测得的 2021 年 6 月 1 日~2021 年 6 月 8 日期间, 时间间隔为 1 min, 频率间隔为 2 MHz 所采集的 600~800 MHz 频段上的数据。选取 ARIMA、LSTM、TCN 以及 Transformer 改进变体模型 Autoformer、Informer 在数据集上进行实验分析, 实验设置回顾窗口为 100, 预测步长为 20 至 120。用时间序列预测任务中广泛使用的平均绝对误差 MAE 和均方根误差 RMSE 作为性能指标, 以分析当前预测模型在性能上的差距, 探究下一步频谱预测算法改进方向。性能指标表达式为

$$\begin{aligned} \text{RMSE} &= \sqrt{\frac{1}{k} \sum_{i=1}^k (p_i - \hat{p}_i)^2} \\ \text{MAE} &= \frac{1}{k} \sum_{i=1}^k |p_i - \hat{p}_i| \end{aligned} \quad (5)$$

式中: k 为观测值总数; p_i 为频谱数据真实值; $\hat{p}_i$ 为预测值, 指标越小则表明预测越准确。

频谱预测模型性能对比结果如图 3 所示。可以看出, ARIMA 模型基于统计学原理进行预测, 在处理长期频谱预测问题时性能较差; TCN 模型因捕获长距离依赖关系和高效并行运算的能力适用于时间序列预测, 但在进行多步长预测时感受野受限, 无法发挥良好效果; Autoformer 模型需要大量训练数据才能获得良好性能, 预测性能随着预测步长增加而下降; Informer 模型预测性能最佳, 在进行长时间预测 (预测步长为 120) 时, 仍

能保证 MAE 低于 0.45, RMSE 低于 0.60, 相较于次之的 LSTM 模型, 其 MAE、RMSE 分别提升了 6% 和 25%。Informer 模型通过自注意力蒸馏和稀疏注意力机制, 在实现良好预测性能的同时, 能够降低计算复杂度至 $O(L \log L)$, 其中 L 为输入序列长度。现有模型在常规环境下表现良好, 但在计算复杂度上仍有不足, 因此, 需探究低计算复杂度、多步长条件下高性能的频谱预测算法。不同模型计算复杂度对比如表 1 所示。




图 3 频谱预测模型性能对比

Fig. 3 Performance comparison of different spectrum prediction models

表 1 深度学习模型计算复杂度对比

Table 1 Comparison of computational complexities of different deep learning models

模型	时间复杂度	相关因素	适用场景
CNN	$K \times K \times C \times N$	卷积核大小: K 输入通道数: C 输出通道数: N	数据量较小, 实时性要求高
LSTM	$T(D \times H + H^2)$	隐藏层大小: H 输入维度: D 时间步数: T	时间依赖性高, 时序建模
TCN	$L \times C \times N \times K$	输入序列长度: L 卷积核大小: K 输入通道数: C 输出通道数: N	数据量小, 实时性要求高
Transformer	$N^2 \times D + N \times D^2$	输入步长: N 特征维度: D	所考虑频谱范围大, 序列较短
Informer	$N \log N \times D$	输入步长: N 特征维度: D	长时间序列, 成本需控制
Autoformer	$N \log N$	输入步长: N 特征维度: D	长时间序列, 存在显著周期性、复杂趋势

由表 1 可知, 各类深度学习模型存在不同特性, 在频谱感知及预测的任务中, 需根据其计算复杂度及特性, 选择适合于当前场景的模型。其中, CNN、TCN、LSTM 等经典模型因其计算复杂度较低, 适用于对实时性要求较高的场景, 但其在处理数据量较大的感知及预测任务时, 存在性能下降等问题。Transformer 类模型具有良好的捕获全局信息的能力, 但由于其建立在注意力机制上, 导致计算复杂度较高。即使 Informer 模型与 Autoformer 模型分别通过稀疏注意力机制与分解注意力机制降低了计算复杂度, 但仍难以实现在实际场景下的部署。

4 杀伤网背景下感知和预测应对方案

针对杀伤网对频谱利用的挑战, 频谱感知与预测需优先考虑准确性要求, 来探寻性能更好的分类与预测模型; 其次, 优化模型计算效率, 降低资源消耗, 提升实际部署可行性; 最后, 压缩感知时间开销, 增强动态电磁环境下的实时响应能力。基于理论与实验分析, 进一步归纳了杀伤网背景下频谱感知与预测的研究方向, 如图 4 所示。

基于Mamba模型的频谱预测方法	联合预测驱动感知	基于深度可分离卷积的特征融合感知方法
频谱预测	频谱感知	
计算复杂度	实时性	准确率

图 4 频谱感知与预测技术研究方向

Fig. 4 Research directions of spectrum sensing and prediction technologies

4.1 特征融合与深度可分离卷积

频谱感知的本质是通过对接收信号的判断, 检测 PU 信号是否存在的二分类问题, 频谱感知便是利用了 SU 接收信号的不同特征。常用的信号特征有能量特征、功率谱特征以及循环平稳特征。

在真实通信场景下, 由于信噪比较低, 基于单一特征的频谱感知性能受限。因此, 将不同信号特征结合并利用深度学习模型强大的特征提取能力进行特征提取与融合, 成为频谱感知新的研究方向^[28]。

深度可分离卷积通过将传统卷积分解为深度卷积和逐点卷积 2 个步骤, 显著降低了模型复杂度^[29]。在移动视觉^[30]、图像分类^[31]等领域得到了广泛应用, 适用于算力受限但对计算效率具有较高要求的场景。在传统卷积中, 输入 $H \times W \times C$ 特征图经 $K \times K \times C \times N$ 的卷积核处理后输出 N 通道特征, 参数量为 $K \times K \times C \times N$ 。在深度可分离卷积过程中, 深度卷积采用 C 个 $K \times K \times 1$ 的独立卷积核, 分别处理输入的各通道, 生成 C 通道中间特征图, 参数量为 $K \times K \times C$ 。深度卷积运算过程如图 5 所示。




图 5 深度卷积运算过程

Fig. 5 Process of deep convolution calculation

在深度卷积之后, 由逐点卷积利用 $1 \times 1 \times C \times N$ 的卷积核融合通道信息, 参数量为 $C \times N$ 。逐点卷积运算过程如图 6 所示。




图 6 逐点卷积运算过程

Fig. 6 Process of pointwise convolution calculation

深度可分离卷积通过以上步骤实现高效特征提取, 并且参数量从普通卷积 $K \times K \times C \times N$ 下降为 $K \times K \times C + C \times N$ 。

根据准确性与易部署要求, 将信号的能量特征、功率谱特征及循环平稳特性等多方面特征相结合^[28]作为表征信号的融合特征。利用深度可分离卷积网络提取融合特征以更好地将信号进行分类处理, 在样本数量较小的情况下, 特征融合也可以很好地表征信号本质, 深度可分离卷积网络能够通过深度卷积提取不同维度特征, 再由逐点卷积融合所有特征, 在降低计算复杂度的同时获取较高的感知性能。

4.2 基于状态空间的 Mamba 模型

状态空间模型 (state space model, SSM) 同时具备优化性能和降低计算资源的能力^[32]。SSM 通过线性时不变系统建模序列数据, 以状态方程

和输出方程描述输入到输出的映射关系, 通过将连续输入信号 $x(t)$ 转换为输出 $y(t)$ 实现预测, 由此得到的状态空间表示状态随时间的变化关系。SSM 可由常微分方程表示为

$$\begin{aligned} h'(t) &= Ah(t) + Bx(t) \\ y(t) &= Ch(t) + Dx(t) \end{aligned} \quad (6)$$

式中: $h(t)$ 为状态表示; $x(t)$ 为信号输入; $y(t)$ 为预测输出; $h'(t) = dh(t)/dt$; A 、 B 、 C 、 D 为可学习参数, 分别控制状态演化、输入影响、状态输出和输入直接传递。为适应序列处理, SSM 需通过零阶保持技术将连续信号转换为离散形式。根据保持时间 Δ 采样得到离散化 SSM, 可表示为

$$\begin{aligned} h_k &= \bar{A}h_{k-1} + \bar{B}x_k \\ y_k &= Ch_k + Dx_k \\ \bar{A} &= \exp(\Delta A) \\ \bar{B} &= (\Delta A^{-1})(\exp(\Delta A) - I)\Delta B \end{aligned} \quad (7)$$

式中: $\bar{A}$ 、 $\bar{B}$ 分别为 A 、 B 进行零阶保持之后的离散化参数; h_k 、 y_k 、 x_k 分别为状态、输出及输入离散表示。SSM 的详细实现过程如图 7 所示。输入通过矩阵 D 直接与输出进行跳跃连接, 不包含状态过程, 因此 SSM 通常被认为是阴影部分所包含的结构。离散化后, SSM 支持并行训练并实现近线性复杂度, 但固定参数导致其无法动态适应输入特征, 限制了上下文感知能力。




图 7 状态空间模型

Fig. 7 State space model

选择性状态空间模型 Mamba 通过引入选择性状态空间机制, 针对 SSM 的不足进行优化。首先, 为每个特征维度分配独立的 SSM 进行独立处理, 实现输入信息的选择性关注与忽略; 其次, 参数化输入序列根据上下文动态调整状态方程, 提升对关键信息的捕捉能力。与 Transformer 模型的多头注意力机制相比, Mamba 模型以近线性复杂度捕获长程依赖, 降低训练与推理开销, 在处理长时间序列预测任务中具有优秀性能及低计算

复杂度^[33-35], 为多步长频谱预测提供了一种高效解决方案, 尤其适用于需快速闭环的杀伤网场景。

4.3 预测驱动感知

频谱预测技术通过历史频谱占用数据的时序特征建模, 实现对未来频谱空闲状态的预判, 从而为动态频谱感知提供先验指导。其核心在于通过预测模型降低感知盲区与能耗冗余。将频谱预测与频谱感知相结合^[36], 在未开始感知之前, 利用频谱感知的结果预测出未被 PU 占用的频段, 再通过 SU 对该频段进行针对性感知, 既避免了 SU 需要持续不断感知所带来的能耗过大问题, 也减少了 SU 无效感知所带来的感知延迟, 提高了实时性。并且可以通过预测减小因为感知错误所带来的 SU 与 PU 的通信冲突概率, 既实现了对频谱使用情况实时准确的获取, 又降低了能耗, 推进了模型在现实场景下的部署进程。

5 结论

通过对当前杀伤网作战效能发挥进行分析研究, 梳理归纳了杀伤网的基本特性, 并结合杀伤网的特性要求, 提出了在杀伤网背景下电磁频谱利用研究所面临的相应挑战。

分析指出了杀伤网背景下需要依靠多 PU、SU 协作频谱感知技术对频谱空穴进行实时感知, 以满足杀伤网当中存在多用户的要求, 还需对感知可靠性进行提升, 以对抗复杂电磁环境中存在的干扰。同时, 需要依靠多信道多步长的频谱预测技术对频谱未来状态进行掌控, 辅助频谱感知及下一步的频谱接入, 满足杀伤网在复杂电磁环境下的动态适应性要求及实时性要求。

最后从技术实现角度出发, 对当前应用普遍的频谱感知与预测算法进行仿真实验, 对比分析了当前基于深度学习的频谱感知和预测模型所存在的不足。为有效克服上述问题, 本文提出了基于深度可分离卷积和特征融合的频谱感知模型、基于 Mamba 模型的频谱预测方法与频谱预测驱动频谱感知的算法, 以应对杀伤网作战效能有效发挥时面临的实时高效、低计算复杂度挑战。

参考文献

- [1] 曹翌, 陈新中, 郭晓鸿, 等. 弹性杀伤网作战概念及装备图像[J]. 指挥信息系统与技术, 2022, 13(4): 46-51.

- CAO G, CHEN X Z, GUO X H, et al. Operational concept and equipment image of elastic kill web[J]. *Command Information System and Technology*, 2022, 13(4): 46-51.
- [2] 杨松, 王维平, 李小波, 等. 杀伤链概念发展及研究现状综述[C]//第三届体系工程学术会议论文集——复杂系统与体系工程管理. 武汉: 中科蓬勃出版社, 2021: 67-72.
- [3] 李龙跃, 贾忠慧, 皮雳, 等. 美军杀伤网的概念内涵、发展现状与趋势[J]. *航空兵器*, 2024, 31(5): 11-18.
- LI L Y, JIA Z H, PI L, et al. The concept, status and trends of the US military's kill web[J]. *Aero Weaponry*, 2024, 31(5): 11-18.
- [4] 赵仁星, 赵国林, 冯明月, 等. 美军“马赛克战”概念下杀伤网探析[J]. *航天电子对抗*, 2021, 37(5): 61-64.
- ZHAO R X, ZHAO G L, FENG M Y, et al. Analysis of kill net under the concept of mosaic warfare by the US army[J]. *Aerospace Electronic warfare*, 2021, 37(5): 61-64.
- [5] 路惠明. 软件定义杀伤网构建思考[J]. *指挥信息系统与技术*, 2024, 15(2): 63-69.
- LU H M. Thoughts on software-defined kill web construction[J]. *Command Information System and Technology*, 2024, 15(2): 63-69.
- [6] 张国华, 文军, 武明, 等. 面向马赛克战的通感算融合网络架构与模型设计[J]. *通信技术*, 2023, 56(12): 1364-1375.
- ZHANG G H, WEN J, WU M, et al. Architecture and model design of communication-sensing-computing fusion network for mosaic warfare[J]. *Communication Technology*, 2023, 56(12): 1364-1375.
- [7] CHEATER J C. Accelerating the kill chain via future unmanned aircraft[M]. Bloomington: Create Space Independent Publishing Platform, 2012: 51-57.
- [8] BENITEZ M. It's about time: the pressing need to evolve the kill chain[J]. *Air Force Magazine*, 2017, 200(5): 24-29.
- [9] 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.
- [10] TAN Y H, JING X J. Cooperative spectrum sensing based on convolutional neural networks[J]. *Applied Sciences*, 2021, 11(10): 4440.
- [11] CHAUHAN P, DEKA S K, CHATTERJEE B C, et al. Cooperative spectrum prediction-driven sensing for energy constrained cognitive radio networks[J]. *IEEE Access*, 2021, 9: 26107-26118.
- [12] 李邦杰, 武健, 张大巧, 等. 基于卷积神经网络的景象匹配区适配性筛选方法[J]. *火箭军工程大学学报*, 2024, 38(3): 45-50, 59.
- LI B J, WU J, ZHANG D Q, et al. A CNN-based scene matching adaptability screening method[J]. *Journal of Rocket Force University of Engineering*, 2024, 38(3): 45-50, 59.
- [13] XIE J D, LIU C, LIANG Y C, et al. Activity pattern aware spectrum sensing: a CNN-based deep learning approach[J]. *IEEE Communications Letters*, 2019, 23(6): 1025-1028.
- [14] XIE J D, FANG J, LIU C, et al. Deep learning-based spectrum sensing in cognitive radio: a CNN-LSTM approach[J]. *IEEE Communications Letters*, 2020, 24(10): 2196-2200.
- [15] FANG X Q, JIN M, GUO Q H, et al. CNN-transformer based cooperative spectrum sensing in cognitive radio networks[J]. *IEEE Wireless Communications Letters*, 2025, 14(5): 1576-1580.
- [16] ZHENG S L, CHEN S C, QI P H, et al. Spectrum sensing based on deep learning classification for cognitive radios[J]. *China Communications*, 2020, 17(2): 138-148.
- [17] MUZAFFAR M U, SHARQI R. A review of spectrum sensing in modern cognitive radio networks[J]. *Telecommunication System*, 2024, 85(2): 347-363.
- [18] ELTOM H, KANDEEPAN S, EVANS R J, et al. Statistical spectrum occupancy prediction for dynamic spectrum access: a classification[J]. *EURASIP Journal on Wireless Communications and Networking*, 2018, 2018(1): 29.
- [19] 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.
- [20] 赵春雁. 基于LSTM的频谱预测算法研究[D]. 哈尔滨: 哈尔滨工业大学, 2021: 49-58.
- ZHAO C Y. Research on spectrum prediction algorithm based on LSTM[D]. Harbin: Harbin Institute of Technology, 2021: 49-58.
- [21] 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.

- [22] 冯李杰. 基于深度学习的卫星频谱态势感知及利用技术研究[D]. 南京: 南京邮电大学, 2022: 35-47.
- FENG L J. Research on satellite spectrum sensing and resourceutilization based on deep learning[D]. Nanjing: Nanjing University of Posts and Telecommunications, 2022: 35-47.
- [23] YU L, CHEN J, DING G R. Spectrum prediction via long short term memory[C]//2017 3rd IEEE International Conference on Computer and Communications (ICCC). Piscataway, NJ, USA: IEEE, 2017: 643-647
- [24] YU L X, WANG Q L, GUO Y F, et al. Spectrum availability prediction in cognitive aerospace communications: a deep learning perspective[C]//2017 Cognitive Communications for Aerospace Applications Workshop (CCAA). Piscataway, NJ, USA: IEEE, 2017: 1-4.
- [25] ZHOU H Y, ZHANG S H, PENG J Q, et al. Informer: beyond efficient transformer for long sequence time-series forecasting[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2021, 35(12): 11106-11115.
- [26] WU H X, XU J H, WANG J M, et al. Autoformer: decomposition transformers with auto-correlation for long-term series forecasting[EB / OL]. (2022-06-07)[2025-03-20]. <https://arxiv.org/abs/2106.13008v5>.
- [27] RAJENDRAN S, CALVO-PALOMINO R, FUCHS M, et al. Electrosense: open and big spectrum data[J]. IEEE Communications Magazine, 2018, 56(1): 210-217.
- [28] GENG Y, HUANG J Y, YANG J X, et al. Spectrum sensing for cognitive radio based on feature extraction and deep learning[J]. Journal of Physics: Conference Series, 2022, 2261 (1): 012016.
- [29] SIFRE L, MALLAT S. Rigid-motion scattering for texture classification[EB / OL]. (2014-03-07)[2025-03-22]. <https://arxiv.org/abs/1403.1687>.
- [30] HOWARD A G, ZHU M, CHEN B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications[EB / OL]. (2017-04-17)[2025-03-22]. <https://arxiv.org/abs/1704.04861>.
- [31] CHOLLET F. Xception: deep learning with depthwise separable convolutions[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2017: 1800-1807.
- [32] SMITH J T H, WARRINGTON A, LINDERMAN S W. Simplified state space layers for sequence modeling[EB/OL]. (2023-03-03)[2025-03-22]. <https://arxiv.org/abs/2208.04933>.
- [33] WANG Z H, KONG F H, FENG S, et al. Is mamba effective for time series forecasting? [J]. Neurocomputing, 2025, 619: 129178.
- [34] GU A, DAO T. Mamba: linear-time sequence modeling with selective state spaces[EB / OL]. (2024-05-31)[2025-03-22]. <https://arxiv.org/abs/2312.00752>.
- [35] CAI X, ZHU Y, WANG X, et al. MambaTS: improved selective state space models for long-term time series forecasting[J / OL]. (2024-05-26)[2025-03-22]. <https://arxiv.org/abs/2405.16440>.
- [36] CHAUHAN P, DEKA S K, CHATTERJEE B C, et al. Cooperative spectrum prediction-driven sensing for energy constrained cognitive radio networks[J]. IEEE Access, 2021, 9: 26107-26118.

(编辑: 于福兴)