FSUNet：基于结构化状态建模的雷达脉冲流分选方法

周叶剑[①③] 冯继元[①③] 魏少鹏[*②] 魏 嵩[②]
[①](浙江工业大学信息工程学院 杭州 310000)
[②](中国石油大学(华东)海洋与空间信息学院 青岛 266000)
[③](全省复杂系统智能感知与控制重点实验室 杭州 310000)

摘要：雷达辐射源信号分选旨在从交叠的脉冲流中分离出各辐射源对应的脉冲序列，是雷达信号侦察处理的关键环节，其结果将直接影响后续体制识别、行为分析与威胁评估等任务的准确性。现有方法通常以脉冲描述字作为主要特征，并通过不同辐射源脉冲在参数空间中的差异实现归属判别。然而，在复杂电磁环境下，脉冲描述字的估计可靠性极易受噪声、测量误差和波形混叠等因素影响，导致不同辐射源脉冲的特征区分度下降，从而制约了分选性能的进一步提升。针对上述问题，该文提出一种基于结构化状态建模的端到端脉冲流分选网络FSUNet。该网络直接以观测窗口内的脉冲流作为输入，在统一框架下联合建模脉内局部形态特征与脉间时序依赖关系，实现从原始信号到分选结果的端到端映射。具体而言，FSUNet首先利用多尺度自适应偏移机制提取脉冲边界与局部瞬态特征；随后通过结构化状态空间模块对跨脉冲的上下文依赖进行递推建模，以增强长程时序表征能力和分选结果的一致性；最后结合跳跃连接与注意力融合机制，自适应整合局部细节与全局状态信息。实验结果表明，在多种分选场景下，FSUNet能够在保持计算效率的同时取得较高的分选精度和鲁棒性。

关键词：雷达辐射源分选；脉冲序列建模；状态空间建模；可变卷积；深度学习

中图分类号：TN957.51 **文献标识码**：A **文章编号**：2095-283X(2026)x-0001-15

DOI: 10.12000/JR26044 **CSTR**: 32380.14.JR26044

引用格式：周叶剑, 冯继元, 魏少鹏, 等. FSUNet：基于结构化状态建模的雷达脉冲流分选方法[J]. 雷达学报(中英文), 待出版. doi: 10.12000/JR26044.

Reference format: ZHOU Yejian, FENG Jiyuan, WEI Shaopeng, *et al.* FSUNet: A radar pulse stream sorting method based on structured state modeling[J]. *Journal of Radars*, in press. doi: 10.12000/JR26044.

FSUNet: A Radar Pulse Stream Sorting Method Based on Structured State Modeling

ZHOU Yejian[①③] FENG Jiyuan[①③] WEI Shaopeng[*②] WEI Song[②]
[①](*College of Information Engineering*, *Zhejiang University of Technology*, *Hangzhou* 310000, *China*)
[②](*College of Ocean and Spatial Information*, *China University of Petroleum* (*East China*), *Qingdao* 266000, *China*)
[③](*Zhejiang Key Laboratory of Intelligent Perception and Control for Complex Systems*, *Hangzhou* 310000, *China*)

收稿日期：2026-02-12；改回日期：2026-07-18；网络出版：2026-07-31
*通信作者： 魏少鹏 spwei@upc.edu.cn *Corresponding Author: WEI Shaopeng, spwei@upc.edu.cn
基金项目：国家自然科学基金(62471438, 62301612)，山东省青年科技人才托举工程(SDAST2025 QTA099)，山东省自然科学基金(ZR2024MF096, ZR2023QF004)，中央高校基本科研基金(26CX07006A)
Foundation Items: The National Natural Science Foundation of China (62471438, 62301612), Young Talent of Liftingengineering for Science and Technology in Shandong (SDAST2025 QTA099), The Natural Science Foundation of Shandong Province (ZR2024MF096, ZR2023QF004), The Fundamental Research Funds for the Central Universities (26CX07006A)
责任主编：陈展野 Corresponding Editor: CHEN Zhanye

©The Author(s) 2026. This is an open access article under the CC-BY 4.0 License
(https://creativecommons.org/licenses/by/4.0/)

Abstract: Radar emitter signal deinterleaving separates pulse sequences from individual emitters within overlapping pulse streams. This is a critical step in radar signal intelligence processing, as its performance directly affects the accuracy of subsequent tasks such as waveform recognition, behavior analysis, and threat assessment. Current methods typically use pulse description words as the primary features, assigning pulse attribution based on parameter differences among emitters. However, in complex electromagnetic environments, the reliability of pulse description word estimation is highly susceptible to noise, measurement errors, and waveform overlap. These issues reduce the feature separability of pulses from different emitters, thereby limiting further improvements in deinterleaving performance. To address these challenges, this study proposes FSUNet, an end-to-end pulse stream deinterleaving network based on structured state modeling. FSUNet directly accepts the pulse stream within an observation window as input and jointly models intrapulse local morphological features and interpulse temporal dependencies within a unified framework. This enables an end-to-end mapping from raw signals to deinterleaving results. Specifically, FSUNet first utilizes a multiscale adaptive offset mechanism to extract pulse boundaries and local transient features. It then introduces a structured state space module to recursively model cross-pulse contextual dependencies, enhancing long-range temporal representation and improving the consistency of deinterleaving results. Finally, skip connections are combined with an attention-based fusion mechanism to adaptively integrate local details with global state information. Experimental results show that FSUNet achieves high deinterleaving accuracy and robustness across various scenarios while maintaining computational efficiency.

Key words: Radar emitter signal sorting; Pulse sequence modeling; Structured state modeling; Deformable convolution; Deep learning

1 引言

雷达辐射源信号分选，又称雷达辐射源信号去交错，是指从交织脉冲流中恢复各辐射源对应脉冲序列的过程[1]。作为电子支援及相关系统中的关键环节，其分选结果将直接影响后续体制识别、行为分析和态势评估等任务的准确性。然而，在实际侦察场景中，多部辐射源往往并行工作，使截获的脉冲流呈现高密度交织特征；同时，噪声干扰、参数扰动、脉冲缺失以及有源干扰导致的波形结构畸变，会进一步引入观测误差，模糊不同辐射源脉冲间的特征差异，从而增加脉冲边界提取、序列重构与辐射源分选的难度[2]。

传统雷达脉冲分选方法通常采用由粗到精的级联处理思路，即先依据脉冲参数差异对截获脉冲进行初步划分，再利用时序规律完成精细分选[3]。在这一框架下，预分选阶段主要利用脉冲描述字(Pulse Descriptor Word, PDW)中的属性参数构建特征空间，以降低后续主分选的搜索空间和计算复杂度。通常情况下，PDW包含到达方向(Direction of Arrival, DOA)、载频(Radio Frequency, RF)、脉宽(Pulse Width, PW)、脉冲幅度(Pulse Amplitude, PA)以及到达时间(Time of Arrival, TOA)等参数。其中，DOA, RF, PW和PA等属性参数通常用于反映不同辐射源在空间指向、频率配置和脉冲形态等方面的差异，TOA则主要为后续时序分析提供时间基准。基于上述参数，K-means[4]、DBSCAN[5]、模糊C均值(Fuzzy C-Means, FCM)[6]和密度峰值聚类[7]等聚类方法常被用于实现脉冲粗分组。在预分选获得粗分组结果后，主分选阶段进一步利用TOA序列中蕴含的脉冲到达规律，对同一辐射源脉冲进行关联判定与序列重构。具体而言，该阶段通常通过分析相邻或多阶脉冲到达时间差，估计脉冲重复间隔(Pulse Repetition Interval, PRI)及其变化特征，并结合关联匹配[8]、累积差值直方图(Cumulative Difference histogram, CDIF)[9]、顺序差值直方图(Sequential Difference histogram, SDIF)[10]以及PRI变换[11]等方法，对预分选结果进行细化和校正，从而恢复各辐射源对应的脉冲序列。然而，上述级联方法依赖可靠的PDW参数估计和稳定的PRI时序规律。在复杂电磁环境下，噪声、混叠和波形畸变会削弱参数估计可靠性，PRI 捷变、抖动和参差等复杂模式则会破坏时序稳定性。二者共同导致预分选偏差和序列重构困难，并在级联结构中经误差传递进一步放大，最终引发误分、漏分或错误合并，限制传统方法的鲁棒性。

随着深度学习在特征表示学习和序列建模中的发展，相关方法逐渐被引入雷达脉冲分选任务，以提升复杂观测条件下的特征建模能力和分选鲁棒性。现有深度学习方法大多延续了传统框架对PDW的依赖，并在此基础上从参数表征增强和结构化任务建模两个方向展开探索。在参数表征增强方面，这类方法围绕PDW参数序列开展特征学

习，通过样本关系建模、多参数关联增强或时空依赖建模等手段，提升参数表征的判别能力。例如，Li等人[12]利用图卷积网络与半监督学习建模PDW样本间的结构关系，Lang等人[13]采用残差图卷积网络增强参数关联特征提取能力，Zhou等人[14]基于Transformer的多重自注意力机制刻画PDW参数序列中的关联关系，Chen等人[15]则引入多视角注意力超图神经网络以建模样本间高阶关联结构。在结构化任务建模方面，相关研究进一步将脉冲分选转化为序列标注、语义分割或图结构推断问题，通过学习式模型恢复脉冲的归属关系。例如，Wang等人[16]将雷达信号去交错建模为语义分割式序列标注问题，Liu等人[17]面向多功能雷达脉冲组结构构建层次化深度网络，Nuhoglu等人[18]将脉冲流转换为二维图像表示并利用图像分割网络实现去交错，Guo等人[19]则基于复杂网络表示与拉普拉斯图聚类开展分选建模。总体来看，虽然深度学习方法通过增强特征表达和时序建模能力，在一定程度上改善了复杂条件下的脉冲分选性能。但是，现有方法大多仍以PDW参数序列为主要建模对象，对原始采样波形中蕴含的脉冲边界、瞬态结构、局部调制形态等细粒度信息利用不足。同时，雷达脉冲流并非孤立的脉冲集合，其形成过程不仅与单脉冲参数相似性和局部时序关系有关，还受到辐射源工作状态、波形调度策略及其动态演化过程的共同影响[20]。因此，脉冲分选不应仅被视为基于静态参数特征的脉冲匹配问题，可进一步建模为受潜在状态演化约束的多源序列分离问题。

从任务形式上看，雷达脉冲分选可理解为在多源混合观测条件下，对不同信号成分进行区分并判定其辐射源归属的过程。这一任务与盲源分离(Blind Source Separation, BSS)在问题目标上具有一定相似性。然而，以独立成分分析[21]和非负矩阵分解[22]为代表的传统BSS方法，通常依赖于固定的混合模型和特定的统计假设，而这些假设在高密度交织、脉冲重叠且统计特性时变的雷达脉冲流场景下难以成立。近年来，随着深度学习在语音分离和时序建模领域的快速发展，端到端分离框架为复杂混合信号处理提供了新的技术路径。例如，Luo等人[23,24]分别利用时域卷积网络和双路径循环神经网络进行局部与全局建模，Hao等人[25]引入时频联合特征以增强分离判别能力，Zhou等人[26]设计了基于注意力机制的U型网络，通过特征提取与重建实现脉冲分选，Shin等人[27]则提出非对称编解码结构，通过分离与重构联合建模提升混合信号恢复能力。上述工作为端到端信号分离提供了有益借鉴，但其建模假设和网络归纳偏置主要源于连续语音或通用时序信号分离任务，侧重于波形级局部模式提取和常规时序依赖建模。与之不同，雷达脉冲流由稀疏、离散的瞬态脉冲事件组成，其时序结构呈现出局部突发性、非均匀分布性和跨脉冲关联性，并随辐射源调度状态的改变而动态演化。这一本质差异使得现有端到端分离框架难以直接适配脉冲流的独特结构特性。因此，有必要构建更符合脉冲流结构特性的端到端建模框架，以实现状态演化约束下的跨脉冲动态关联建模。

针对上述问题，本文提出一种端到端脉冲流分选网络FSUNet。不同于依赖PDW参数构建特征空间的分选方法，FSUNet直接以原始采样脉冲流作为输入，通过结构化状态建模刻画脉冲流中的状态演化规律与跨脉冲依赖关系。具体而言，网络首先采用多尺度自适应偏移机制提取脉冲边界、局部瞬态及关键形态特征，以增强对复杂观测条件下局部结构变化的感知能力；随后引入结构化状态空间模块，通过连续隐状态递推聚合跨脉冲上下文信息，从而建模长程时序依赖并增强序列一致性；最后结合跳跃连接与注意力融合机制，自适应整合局部细节特征与全局状态表征，提升复杂电磁环境下脉冲分选的稳定性与鲁棒性。本文的主要贡献如下：

(1) 提出一种基于结构化状态建模的端到端雷达辐射源脉冲流分选网络FSUNet，实现从原始采样脉冲流到分选结果的直接映射，并在统一框架下协同建模脉内局部形态、脉间时序依赖与辐射源归属关系。

(2) 构建面向脉冲流时序组织特性的结构化状态空间模块，通过连续隐状态递推传递跨脉冲上下文信息，增强网络对长程依赖关系和序列一致性的建模能力。

(3) 设计多尺度自适应偏移特征提取策略，通过动态调整局部采样位置增强对脉冲边界、调制突变和瞬态结构区域的感知能力，提升复杂观测条件下的局部形态表征效果。

2　脉冲流信号建模与状态演化分析

2.1　脉冲流的观测模型与分选问题表述

在雷达侦察接收过程中，多个辐射源的脉冲信号常在同一观测窗口内交织到达，形成混合脉冲流。该观测信号可视为若干单源脉冲序列的叠加，每一单源序列则由具有特定波形参数与发射时序的单脉冲构成。作为上述序列的基本组成单元，单个雷达脉冲的带通信号通常由幅度包络、载频项和脉内相位调制共同决定，其复解析形式可写为

$$s(t)=a(t)\exp(\mathrm{j}(2\pi f_{\mathrm{c}}t+\phi(t))) \tag{1}$$

其中，$a(t)$表示脉冲幅度包络，f_{c}表示载频，$\phi(t)$表示脉内瞬时相位。引入参考频率f_0对式(1)进行下变频，可得到复基带表示$s_{\mathrm{b}}(t)$：

$$s_{\mathrm{b}}(t)=s(t)\exp(-\mathrm{j}2\pi f_0 t) \tag{2}$$

下变频后，载频信息以相对参考频率f_0的频偏形式保留，幅度包络、脉宽以及脉内调制等结构信息仍包含在基带波形$s_{\mathrm{b}}(t)$中。为统一描述，记复基带单脉冲波形为$g(t;\theta)$，其中θ表示脉宽、频偏、脉内调制及其他波形参数。而在观测窗口内，同一辐射源通常会按照一定的发射时序连续产生多个脉冲。

每个脉冲可看作由单脉冲波形$g(t;\theta)$经过时间平移、幅度缩放和参数配置得到。设第i个辐射源共产生K_i个脉冲，则复基带脉冲序列可表示为

$$\tilde{S}_i(t)=\sum_{k=1}^{K_i}A_{i,k}\,g\left(t-\mathrm{TOA}_{i,k};\,\theta_{i,k}\right) \tag{3}$$

其中，$A_{i,k}$为幅度系数，$\mathrm{TOA}_{i,k}$为到达时刻，$\theta_{i,k}$为第k个脉冲的波形参数。对于同一辐射源，相邻脉冲之间的脉冲重复间隔定义为

$$\mathrm{PRI}_{i,k}=\mathrm{TOA}_{i,k+1}-\mathrm{TOA}_{i,k} \tag{4}$$

上述定义表明，单源脉冲流同时受单脉冲波形结构与跨脉冲时序关系的约束。进一步地，当多部辐射源在同一观测窗口内同时工作时，接收端观测信号可近似表示为多个单源脉冲序列的叠加：

$$\tilde{X}(t)=\sum_{i=1}^{M}\tilde{S}_i(t)+n(t) \tag{5}$$

其中，M为辐射源数量，$n(t)$为加性噪声。因此，脉冲分选的核心在于从混合观测信号$\tilde{X}(t)$中区分并恢复各辐射源对应的脉冲序列。

传统分选方法通常先对$\tilde{X}(t)$进行脉冲检测与参数测量，然后基于PDW序列完成聚类或关联判决。该流程具有较强的可解释性，但其性能高度依赖前端检测和测参精度。在非理想情况下，PDW估计误差会削弱参数空间中的类间可分性；同时，有限的PDW参数难以完整表征脉冲边界、脉内细节以及跨脉冲上下文关系。为减少对显式测参结果的依赖，本文直接对观测窗口内下变频后的脉冲流进行建模。设观测窗口长度为T_{obs}，采样率为f_{s}，则离散采样点数为$T=T_{\mathrm{obs}}f_{\mathrm{s}}$。对观测信号进行采样和预处理后，得到网络实输入序列：

$$\boldsymbol{x}=[x[1]\;x[2]\cdots x[T]]^{\mathrm{T}}\in\mathbb{R}^{T} \tag{6}$$

其中，$x[t]$为第t个采样点的观测幅度。相比低维PDW表示，原始采样序列保留了脉冲边界、局部瞬态变化和脉内结构信息，也为建模跨脉冲时序依赖提供了更完整的观测基础。为了更好地建模时序信息，本文以各辐射源在时间轴上的脉冲分布作为预测目标。设单个观测窗口内最多包含M个辐射源，对应的多通道二值掩码定义为

$$\boldsymbol{Y}=[\boldsymbol{y}_1\,\boldsymbol{y}_2\cdots\boldsymbol{y}_M]^{\mathrm{T}}\in\{0,1\}^{M\times T} \tag{7}$$

其中，$\boldsymbol{y}_m\in 0,1^{\mathrm{T}}$ 表示第m个辐射源在时间轴上的二值脉冲分布，m=1, 2,⋯,M。在此基础上，设参数为θ的端到端分选模型为$\mathcal{F}_\theta$，其输入输出映射关系表示为

$$\hat{\boldsymbol{Y}}=\mathcal{F}_\theta(\boldsymbol{x}) \tag{8}$$

其中，$\hat{\boldsymbol{Y}}\in[0,1]^{M\times T}$表示模型预测的多通道脉冲分布概率矩阵。随后，根据最优通道匹配结果对标签通道进行重新排列，以消除通道排列不确定性对分选结果的影响。因此，雷达脉冲分选可转化为原始观测波形上的结构化序列建模与多通道时序预测问题。

2.2 脉冲流的状态演化特性分析

雷达辐射源的脉冲发射过程受任务阶段、工作模式和调度策略共同约束，其PRI, PW, RF及脉内调制等参数会随时间协同演化[28]。稳定工作时，同源脉冲的参数和时序具有较强一致性，模式切换则常引发多个参数的协同调整。因此，观测脉冲流本质上是由潜在辐射源状态驱动的动态序列，而非孤立脉冲的随机组合，如图1所示。

为刻画这种状态驱动的脉冲生成过程，本文首先借鉴结构化信号处理思想[29]，并采用有限状态机(Finite State Machine, FSM)[30]对离散工作状态及其转移关系进行形式化描述。FSM可定义为

$$\mathcal{M}=(Q,\Sigma,\delta,q_0) \tag{9}$$

其中，Q为状态集合，Σ为输入集合，$q_0\in Q$为初始状态，$\delta\colon Q\times\Sigma\to Q$为状态转移函数。给定时刻$t$的输入$x_t\in\Sigma$，状态递推过程可表示为

$$q_t=\delta(q_{t-1},x_t) \tag{10}$$

在雷达脉冲流建模中，q_t可对应辐射源的工作模式、调度阶段或波形配置状态，而输入x_t则表示当前观测到的脉冲特征或局部观测信息。由此可见，同源脉冲之间的关联不仅体现在单个脉冲的局部波形结构中，还体现在跨脉冲的状态连续性与调度规律中。而从层次化角度看，短时间范围内的脉冲局部结构主要反映当前状态的外在表现，例如脉

宽、载频、PRI及调制形式等参数组合。可将这类显式局部模式表示为

$$O = \{o_1, o_2, \cdots, o_K\} \tag{11}$$

其中，o_K表示第K类典型局部观测模式，k=1, 2,⋯, K，K为典型局部观测模式的类别数。进一步地，较长时间尺度上的脉冲组织还受到任务阶段、波形调度和模式切换等宏观因素影响，这类因素难以由单个脉冲或短窗口局部特征直接确定，可抽象为隐状态集合：

$$\mathcal{H} = \{\mathrm{Mode}_1, \mathrm{Mode}_2, \cdots, \mathrm{Mode}_{N_{\mathrm{mode}}}\} \tag{12}$$

其中，Mode_m表示由任务阶段、脉冲调度策略和波形参数配置共同表征的第m类潜在工作状态，$m = 1, 2, \cdots, N_{\mathrm{mode}}$为潜在工作状态类别数。

显式观测模式描述局部可观测结构，隐状态则刻画跨脉冲的长程演化关系，二者共同构成由局部观测到全局状态的分析视角。然而，FSM更适合描述边界清晰的离散状态切换。在真实接收条件下，噪声干扰、脉冲重叠、参数抖动以及模式渐变等因素会使不同状态的观测分布出现连续过渡或局部重叠[31]，从而削弱固定离散状态划分的适用性。因此，本文采用连续隐状态来刻画脉冲流的演化过程[32]。该状态随输入观测自适应更新，在递推中融合当前局部特征与历史上下文，从而保持跨脉冲时序依赖。

2.3 基于连续隐状态的结构化建模框架

基于上述状态演化分析，本文构建“观测表征—状态递推—归属预测”的建模框架。其核心思想是：首先利用编码器从原始采样脉冲流中提取局部观测特征；随后通过状态空间模型递推聚合跨脉冲上下文，形成连续全局状态表征；最后由解码器恢复时间分辨率，并输出各辐射源对应的多通道脉冲响应。整体框架如图2所示。

根据式(6)，观测窗口内的实值采样序列记为$\boldsymbol{x} \in \mathbb{R}^T$，其中，$T$为采样点数，$x[t]$为第$t$个采样时刻的观测幅度。前端编码器对$\boldsymbol{x}$进行局部特征提取和时间维压缩，得到特征序列：

$$\boldsymbol{F} = \mathrm{Enc}(\boldsymbol{x}) = [\boldsymbol{f}_1\, \boldsymbol{f}_2 \cdots \boldsymbol{f}_{T'}] \in \mathbb{R}^{d \times T'} \tag{13}$$

其中，$\boldsymbol{f}_t \in \mathbb{R}^d$为压缩后第$t$个时间位置的局部观测特征，$d$为特征维度，$T'$为压缩后的序列长度。该过程在降低序列冗余的同时，保留了脉冲边界、局部形态和瞬态变化等判别信息。

在编码特征基础上，本文引入结构化状态空间模型(State-Space Model, SSM)作为连续隐状态递推算子[33]。令$\boldsymbol{h}_t \in \mathbb{R}^n$表示第$t$个时间位置对应的连续隐状态，则离散时间下的状态更新和输出映射可写为

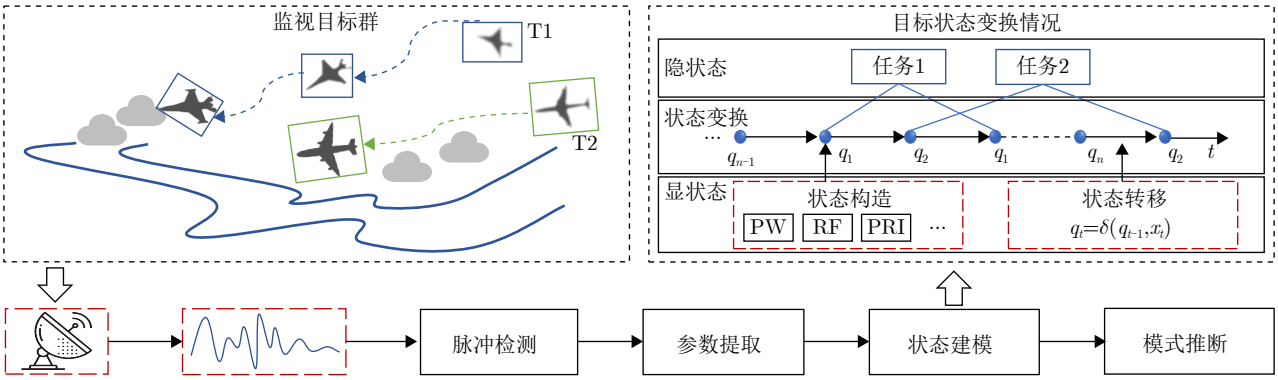

图 1 雷达脉冲观测与状态变化过程

Fig. 1 Radar pulse observation and state variation process

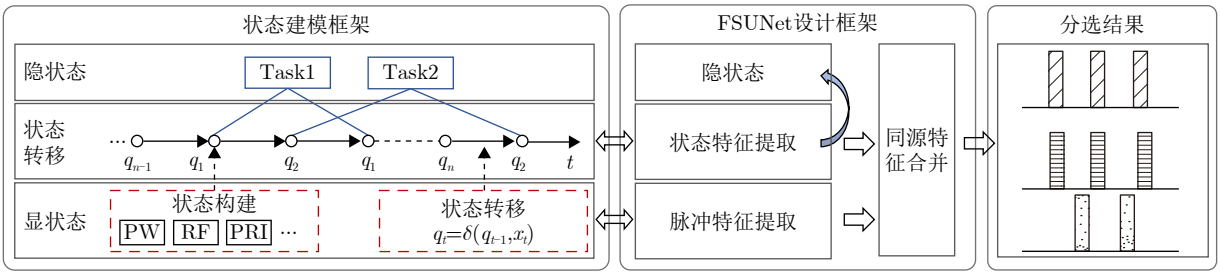

图 2 FSUNet建模框架

Fig. 2 Structured state modeling framework of FSUNet

$$\boldsymbol{h}_t = \bar{\boldsymbol{A}}\boldsymbol{h}_{t-1} + \bar{\boldsymbol{B}}\boldsymbol{f}_t \tag{14}$$

$$\boldsymbol{z}_t = \boldsymbol{C}_{\mathrm{s}}\boldsymbol{h}_t + \boldsymbol{D}\boldsymbol{f}_t \tag{15}$$

其中，$\boldsymbol{z}_t$为状态输出表征，$\bar{\boldsymbol{A}}$控制历史状态的传递，$\bar{\boldsymbol{B}}$控制当前观测特征对隐状态的注入，$\boldsymbol{C}_{\mathrm{s}}$和$\boldsymbol{D}$则分别用于将隐状态和局部特征映射到输出表征空间。将式(13)递推展开，可得

$$\boldsymbol{h}_t = \bar{\boldsymbol{A}}^t\boldsymbol{h}_0 + \sum_{\tau=1}^{t}\bar{\boldsymbol{A}}^{t-\tau}\bar{\boldsymbol{B}}\boldsymbol{f}_\tau \tag{16}$$

由式(15)可知，当前隐状态$\boldsymbol{h}_t$不仅包含当前观测特征，还累积了历史观测在状态空间中的影响。因此，$\boldsymbol{h}_t$可视为对历史脉冲信息及其时序依赖关系的递归压缩表示，有助于增强跨脉冲上下文建模能力。整个状态输出序列为

$$\boldsymbol{Z} = [\boldsymbol{z}_1\,\boldsymbol{z}_2\cdots\boldsymbol{z}_{T'}] \tag{17}$$

解码器再进一步将$\boldsymbol{Z}$映射回原始时间分辨率，并生成多通道脉冲响应：

$$\hat{\boldsymbol{Y}} = \sigma(\mathrm{Dec}(\boldsymbol{Z})) \tag{18}$$

其中，$\sigma(\cdot)$为 Sigmoid 激活函数，$\hat{\boldsymbol{Y}} \in [0,1]^{M\times T}$为预测的多通道脉冲响应概率矩阵，第$m$个通道表示对应辐射源在各采样时刻的脉冲存在概率。

因此，该框架将原始观测表征、连续状态递推与多通道响应预测统一于同一分析流程。其中，连续隐状态的引入，使局部观测特征能够沿递推过程与历史上下文深度结合，进而在表征层面同时刻画脉冲的局部形态与跨脉冲时序依赖。

3 FSUNet神经网络

在多源交织脉冲流中，脉冲分选既依赖脉冲边界、瞬态变化和脉内形态等局部结构特征，也受到PRI调度、参数捷变和体制切换等跨脉冲时序关系的约束。因此，分选模型需要同时具备局部结构感知与长程依赖建模能力。基于此，本文构建端到端脉冲流分选网络FSUNet，其整体结构如图3所示。网络以原始采样脉冲流为输入，采用编、解码器结构预测时间轴上的多通道脉冲归属概率。编码器提取局部波形特征，并通过结构化状态空间模块聚合跨脉冲上下文；解码器结合跳跃连接与注意力融合机制整合浅层细节和深层状态表征，逐级恢复时间分辨率并输出分选结果。

3.1 局部特征提取模块

雷达脉冲流具有明显的时域非平稳性，脉冲边界、调制突变和瞬态幅相变化等局部区域包含重要判别信息，而传统一维卷积采样位置固定，难以适应边界偏移和局部结构变化，容易导致特征响应错位和边界定位偏差。针对这一问题，本文设计了一种多尺度自适应偏移的局部特征提取模块，结构如图4所示。该模块首先通过多尺度卷积分支提取不同感受野下的局部模式，再结合池化与降采样构建偏移量预测分支，为可变形卷积生成上下文感知的采样偏移，从而使特征采样位置更好地对齐脉冲边界、调制突变和局部瞬态区域。

设输入的一维特征为$\boldsymbol{X} \in \mathbb{R}^{C\times T_{\mathrm{in}}}$，其中$C$为通

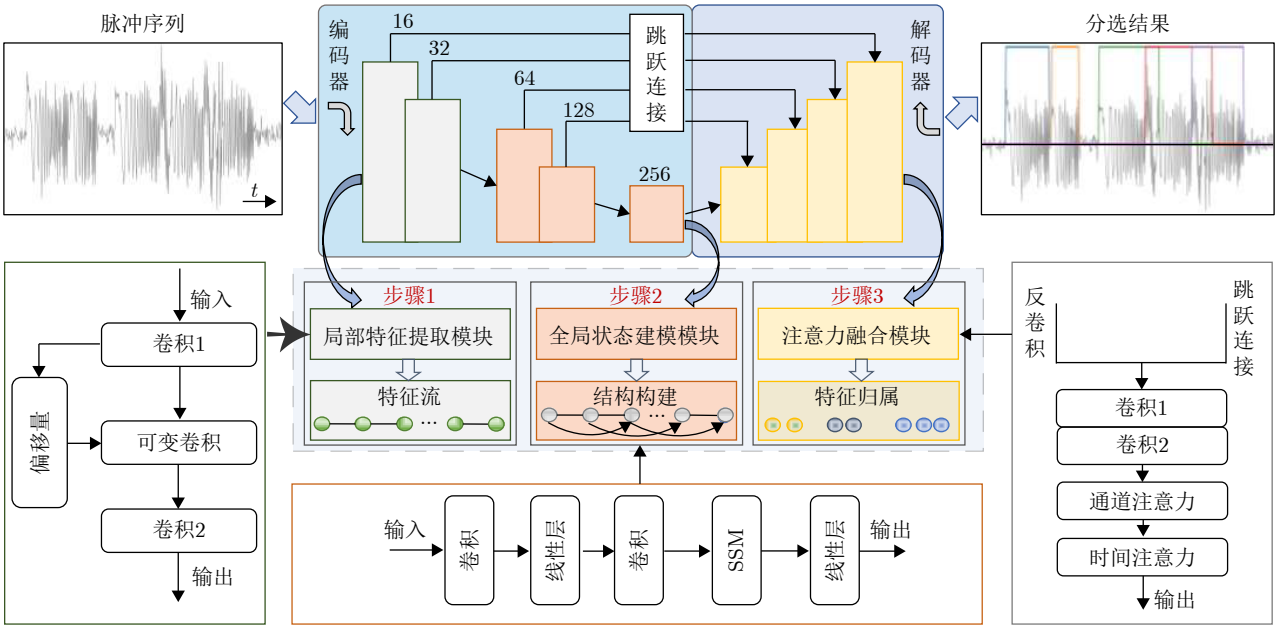

图 3 FSUNet网络结构

Fig. 3 Architecture of FSUNet

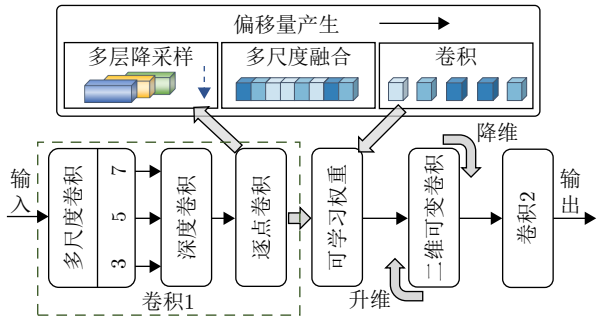

图 4 局部特征提取模块

Fig. 4 Local feature extraction module

道数，T_{in}为输入特征的时间长度。采用S个不同卷积核尺度的分支并行建模，以捕获多时间尺度局部结构：

$$\boldsymbol{F}_i = \text{Conv}_{k_i}(\boldsymbol{X}), i = 1, 2, \cdots, S \tag{19}$$

其中，k_i表示第i个分支的卷积核大小。通过合理填充，各分支输出在时间维度上保持一致。随后，将不同尺度的局部特征在通道维度进行拼接，得到多尺度融合特征：

$$\boldsymbol{F}_{\text{merge}} = \text{Concat}(\boldsymbol{F}_1, \boldsymbol{F}_2, \cdots, \boldsymbol{F}_S) \tag{20}$$

为提升偏移预测的上下文感知能力，在$\boldsymbol{F}_{\text{merge}}$上构建多尺度聚合分支。首先通过不同尺度平均池化提取多范围上下文：

$$\boldsymbol{P}_j = \text{AvgPool}_{s_j}(\boldsymbol{F}_{\text{merge}}), j = 1, 2, \cdots, L \tag{21}$$

其中，L为池化分支数，s_j表示第j个池化分支的池化核大小。随后，对各池化分支进行倍率为r_j的时域降采样，以进一步扩大偏移预测分支的有效感受野：

$$\bar{\boldsymbol{P}}_j = \text{DownSample}_{r_j}(\boldsymbol{P}_j) \tag{22}$$

由于不同分支经池化和降采样后的时间长度可能不同，采用插值统一到长度T'_{off}：

$$\tilde{\boldsymbol{P}}_j = \text{Resize}(\bar{\boldsymbol{P}}_j, T'_{\text{off}}) \tag{23}$$

其中，$\boldsymbol{P}_j$，$\bar{\boldsymbol{P}}_j$和$\tilde{\boldsymbol{P}}_j$分别表示第j个分支在池化、降采样和长度对齐后的特征表示。T'_{off}表示偏移量预测分支对齐后的时间长度。进一步地，将各尺度上下文特征进行拼接，得到偏移感知特征

$$\boldsymbol{F}_{\text{off}} = \text{Concat}(\tilde{\boldsymbol{P}}_1, \tilde{\boldsymbol{P}}_2, \cdots, \tilde{\boldsymbol{P}}_L) \tag{24}$$

最后，通过1×1卷积将偏移感知特征映射为采样偏移量张量：

$$\Delta\boldsymbol{P} = \text{Conv}_{1\times1}(\boldsymbol{F}_{\text{off}}) \tag{25}$$

其中，$\Delta\boldsymbol{P} \in \mathbb{R}^{K \times T'_{\text{off}}}$，$K = |\mathcal{R}|$表示卷积核采样点数。

与传统卷积在固定位置进行采样不同，可变形卷积在每个规则采样点上引入由网络预测得到的偏移量，使卷积核能够根据输入特征的局部结构动态调整采样位置。对于输出位置t_0，一维可变形卷积可表示为

$$y(t_0) = \sum_{n \in \mathcal{R}} w(n)\xi(t_0 + n + \Delta_n(t_0)) \tag{26}$$

其中，$w(n)$表示第n个采样点对应的卷积权重，$\Delta_n(t_0)$表示在输出位置t_0处第n个采样点的预测偏移量，$\xi(\cdot)$表示可变形卷积中的局部输入特征。由于偏移后的采样位置通常为非整数位置，因此采用线性插值计算对应特征值：

$$\xi(t) = \sum_{q \in \mathcal{N}(t)} G(q, t)\xi(q) \tag{27}$$

其中，$\mathcal{N}(t)$表示位置t相邻的两个整数采样点集合，$G(q, t) = \max(0, 1 - |q - t|)$表示一维线性插值权重。

通过该设计，偏移量预测分支可在多尺度上下文引导下感知局部结构变化，并驱动采样点向边界、调制突变和瞬态区域偏移。相比固定采样卷积，该模块有助于缓解采样错位、减少特征扩散，并提升非平稳局部结构的判别表征能力。

3.2 全局状态建模模块

局部特征能够描述脉冲边界和瞬态结构，但受感受范围限制，难以刻画跨脉冲同源关联。在非理想的条件下，仅依赖局部响应容易导致片段断裂和归属混淆。为增强分选结果的时序连续性和全局一致性，本文在编码器深层引入结构化状态空间模块，通过连续隐状态递推聚合跨脉冲上下文信息，形成面向长序列脉冲流的全局状态表征，其结构如图5所示。

设输入特征序列为$\{\boldsymbol{x}_t\}_{t=1}^{T'}$，其中$\boldsymbol{x}_t \in \mathbb{R}^d$。模块通过隐状态递推建模跨时间步依赖。记隐状态维度为d_{state}，第t步隐状态为$\boldsymbol{h}_t \in \mathbb{R}^{d_{\text{state}}}$，初始状态为$\boldsymbol{h}_0 = 0$。

首先，对每个时间步的输入进行线性投影，并划分为门控、状态转移和时间尺度3个分支：

$$(\boldsymbol{g}_t, \boldsymbol{u}_t, \boldsymbol{d}_t) = \boldsymbol{W}_{\text{proj}}\boldsymbol{x}_t + \boldsymbol{b}_{\text{proj}} \tag{28}$$

其中，$\boldsymbol{g}_t$为门控分支，用于调制输出；$\boldsymbol{u}_t$为状态转移分支，用于生成输入驱动、状态更新和状态读出项；$\boldsymbol{d}_t$为时间尺度分支，用于生成离散步长。

在此基础上，对状态转移分支$\boldsymbol{u}_{1:T'}$在序列维上施加一维卷积，并引入SiLU非线性激活，以增强相邻时间步之间的信息交互和局部时序混合能力：

$$\begin{aligned}\tilde{\boldsymbol{u}}_t =& \text{SiLU}(\text{ConvOneD}(\boldsymbol{u}_{1:T'})_t),\\ &\tilde{\boldsymbol{u}}_t \in \mathbb{R}^{3d_{\text{state}}}\end{aligned} \tag{29}$$

然后将卷积混合后的$\tilde{\boldsymbol{u}}_t$再划分为3个等维分

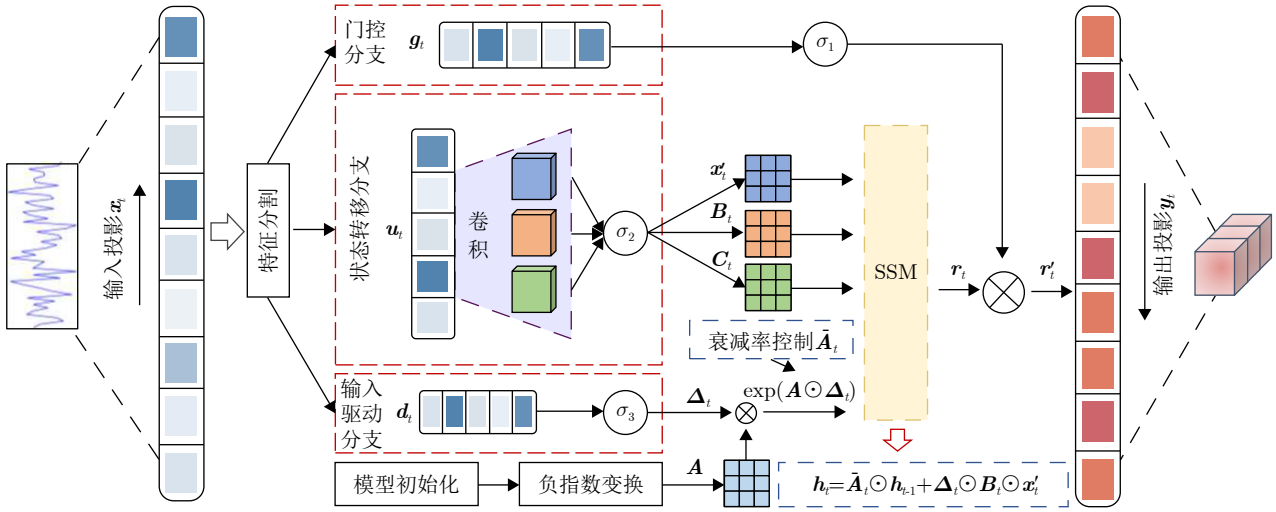

图 5 全局状态建模模块

Fig. 5 Global state modeling module

量，分别用于输入写入、状态更新调制和状态读出调制：

$$(\boldsymbol{x}'_t, \boldsymbol{B}_t, \boldsymbol{C}_t) = \mathrm{Split}(\tilde{\boldsymbol{u}}_t; [d_{\mathrm{state}}\ d_{\mathrm{state}}\ d_{\mathrm{state}}]) \tag{30}$$

其中，$\boldsymbol{x}'_t, \boldsymbol{B}_t, \boldsymbol{C}_t \in \mathbb{R}^{d_{\mathrm{state}}}$。$\boldsymbol{x}'_t$ 表示当前时刻写入状态空间的输入驱动项，$\boldsymbol{B}_t$用于调制当前输入对隐状态的写入强度，$\boldsymbol{C}_t$用于调制隐状态到输出表征的读出过程。

同时，也对时间尺度分支$\boldsymbol{d}_t$施加Softplus激活，以获得正值离散步长：

$$\boldsymbol{\Delta}_t = \mathrm{Softplus}(\boldsymbol{d}_t + \boldsymbol{b}_\Delta), \boldsymbol{\Delta}_t \in \mathbb{R}^{d_{\mathrm{state}}} \tag{31}$$

为保证递推稳定性，采用负指数形式参数化连续系统衰减率，并结合离散步长得到状态转移因子：

$$\boldsymbol{A} = -\exp(\boldsymbol{A}_{\log}), \bar{\boldsymbol{A}}_t = \exp(\boldsymbol{\Delta}_t \odot \boldsymbol{A}) \tag{32}$$

其中，$\boldsymbol{A}_{\log} \in \mathbb{R}^{d_{\mathrm{state}}}$是对数域中的可学习参数，$\odot$表示逐元素乘法。由于$\boldsymbol{A}$被约束为负值，$\bar{\boldsymbol{A}}_t$表现为稳定的衰减因子，用于控制历史隐状态在当前时间步的保留程度。

基于上述状态转移因子、输入驱动项及写入调制项，隐状态递推过程可表示为

$$\boldsymbol{h}_t = \bar{\boldsymbol{A}}_t \odot \boldsymbol{h}_{t-1} + \boldsymbol{\Delta}_t \odot (\boldsymbol{B}_t \odot \boldsymbol{x}'_t) \tag{33}$$

其中，第1项表示历史状态的保留与衰减，第2项表示当前输入在$\boldsymbol{B}_t$调制下写入隐状态。该递推过程使模型能够传递并更新状态信息，刻画长程依赖和状态演化。

在获得当前隐状态$\boldsymbol{h}_t$后，模块进一步通过状态读出项和输入直连项共同生成读出表征：

$$\boldsymbol{r}_t = \boldsymbol{C}_t \odot \boldsymbol{h}_t + \boldsymbol{D} \odot \boldsymbol{x}'_t \tag{34}$$

其中，$\boldsymbol{D} \in \mathbb{R}^{d_{\mathrm{state}}}$为可学习参数。第1项表示从隐状态中读出的全局上下文信息，第2项表示输入驱动项的直连补偿，用于保留当前时间步的局部观测特征。

状态更新与读出完成后，门控分支$\boldsymbol{g}_t$进一步作用于读出表征，对状态空间模块生成的全局状态信息进行选择性调制：

$$\boldsymbol{r}'_t = \mathrm{RMSNorm}(\boldsymbol{r}_t \odot \mathrm{SiLU}(\boldsymbol{g}_t)), \boldsymbol{y}_t = \boldsymbol{W}_{\mathrm{out}} \boldsymbol{r}'_t \tag{35}$$

其中，$\boldsymbol{W}_{\mathrm{out}}$为输出线性映射矩阵，$\boldsymbol{y}_t$为全局状态建模模块在第$t$个时间步的输出特征。

经上述处理，隐状态作为跨时间步信息载体，持续融合历史上下文与当前观测，从而强化脉冲间同源关联及长程时序依赖的建模，为后续解码与归属判决提供更为稳定的全局特征支撑。

3.3 注意力融合模块

在局部特征提取和全局状态建模后，不同层级特征在语义抽象程度和时间分辨率上仍存在差异。浅层特征偏向边界与细节，深层特征偏向上下文与全局一致性。若直接拼接，冗余通道和背景响应会影响解码效果。因此，本文引入通道与时序联合注意力，对融合特征进行重标定，突出判别相关的响应并抑制干扰。

设第l个解码阶段的特征为$\boldsymbol{F}_l^{\mathrm{d}} \in \mathbb{R}^{C_{\mathrm{d}} \times T_l}$，对应编码器的跳跃连接特征为$\boldsymbol{F}_l^{\mathrm{e}} \in \mathbb{R}^{C_{\mathrm{e}} \times T_l}$，其中$C_{\mathrm{d}}$和$C_{\mathrm{e}}$分别表示两类特征的通道数，$T_l$表示该尺度下的时间长度。首先，在通道维度上对二者进行拼接，并采用核长为1的一维卷积完成跨层信息融合与通道压缩。设融合后的输出通道数为C，则有

$$\boldsymbol{F}_l = \mathrm{Conv}_1\left(\mathrm{Concat}(\boldsymbol{F}_l^{\mathrm{d}}, \boldsymbol{F}_l^{\mathrm{e}})\right) \tag{36}$$

其中，$\boldsymbol{F}_l \in \mathbb{R}^{C\times T_l}$为融合特征，然后再通过通道注意力建模不同语义通道的重要性。沿时间维执行全局平均池化(Global Average Pooling, GAP)和全局最大池化(Global Max Pooling, GMP)，得到互补的通道统计：

$$\boldsymbol{u}_{\rm avg} = {\rm GAP_t}(\boldsymbol{F}_l), \boldsymbol{u}_{\rm max} = {\rm GMP_t}(\boldsymbol{F}_l) \tag{37}$$

其中，$\boldsymbol{u}_{\rm avg}, \boldsymbol{u}_{\rm max} \in \mathbb{R}^C$。平均池化能够反映通道响应的整体分布特征，最大池化则有助于保留显著响应信息。随后，再将两类通道描述子分别输入共享参数的两层多层感知机(Multi-Layer Perceptron, MLP)，并对输出结果进行融合，生成通道注意力权重：

$$\boldsymbol{m}_{\rm c} = {\rm Sigmoid}({\rm MLP}(\boldsymbol{u}_{\rm avg}) + {\rm MLP}(\boldsymbol{u}_{\rm max})) \tag{38}$$

其中，$\boldsymbol{m}_{\rm c} \in \mathbb{R}^C$表示通道权重。通过按维度广播的逐元素乘法对融合特征进行通道重标定，可得到

$$\boldsymbol{F}_l^{\rm c} = \boldsymbol{m}_{\rm c} \odot \boldsymbol{F}_l, \boldsymbol{F}_l^{\rm c} \in \mathbb{R}^{C\times T_l} \tag{39}$$

通道注意力能够增强与脉冲归属判别相关的语义响应，并抑制冗余或噪声通道对后续解码过程的干扰。

在通道重标定后，引入时序注意力刻画不同时间位置的重要性。沿通道维对$\boldsymbol{F}_l^{\rm c}$分别进行平均汇聚和最大汇聚，得到

$$\boldsymbol{v}_{\rm avg} = {\rm Mean_c}(\boldsymbol{F}_l^{\rm c}), \boldsymbol{v}_{\rm max} = {\rm Max_c}(\boldsymbol{F}_l^{\rm c}) \tag{40}$$

其中，$\boldsymbol{v}_{\rm avg}, \boldsymbol{v}_{\rm max} \in \mathbb{R}^{T_l}$。平均汇聚用于描述各时间位置的整体响应水平，最大汇聚则用于捕获局部显著时间响应。随后，将二者沿通道维进行拼接，并通过核长为k的一维卷积生成时序注意力权重：

$$\boldsymbol{m}_{\rm t} = {\rm Sigmoid}({\rm Conv}_k({\rm Concat}(\boldsymbol{v}_{\rm avg}, \boldsymbol{v}_{\rm max}))) \tag{41}$$

其中，$\boldsymbol{m}_{\rm t} \in \mathbb{R}^{T_l}$，${\rm Conv}_k(\cdot)$表示核长为$k$的一维卷积，并通过适当填充保持输出时间长度为$T_l$。最终，将时序注意力权重作用于通道重标定后的特征，得到模块输出：

$$\boldsymbol{F}_l^{\rm out} = \boldsymbol{m}_{\rm t} \odot \boldsymbol{F}_l^{\rm c}, \boldsymbol{F}_l^{\rm out} \in \mathbb{R}^{C\times T_l} \tag{42}$$

通过联合通道与时序注意力，网络可对跨层特征实施自适应重标定，突出归属相关通道与关键时间区域。该机制使网络在解码阶段有效融合浅层细节与深层全局状态，从而提升特征重构质量及归属判决的稳定性。

4　实验结果与分析

4.1　实验设置

4.1.1　实验参数与场景设置

为评估FSUNet在不同电磁环境下的脉冲分选性能，本文参考典型雷达体制参数与PRI调度规律[13,34]，构建多源交织脉冲流仿真数据集。每个观测窗口长度为$T_{\rm obs}$，窗口内随机生成M个辐射源，并分别配置不同的信噪比、脉宽、幅度、PRI调度方式以及脉内调制等参数，具体设置见表1。训练所需的监督标签由真实脉冲的起止位置和辐射源编号生成，并与输入采样时间轴严格对齐，从而支持模型联合学习脉冲定位与辐射源归属判定。

为全面评估模型在不同条件下的分选性能，本文构建5类典型实验场景，覆盖基础交织、脉宽变化、脉内调制变化、相位编码变化与PRI调度变化。其中，基础多源交织场景使用带有随机抖动PRI的LFM脉冲，用于模拟常规交织条件；脉宽变化场景通过引入PW捷变，检验模型对脉冲宽度和边界差异的适应能力；脉内调制变化场景将波形扩展为LFM, CW和NLFM，分析不同脉内结构带来的影响；相位编码变化场景引入Barker, Frank和P4等编码形式，考察相位结构变化时的判别能力；PRI

表 1　仿真数据集参数设置

Tab. 1　Parameter settings for simulated dataset generation

场景设置	参数名称	参数设置
全场景基础参数	带宽B	3 MHz
	观测窗口$T_{\rm obs}$	3 ms
	信噪比SNR	U(0,10) dB
	脉冲宽度$T_{\rm p}$	U(60,150) μs
	采样率$f_{\rm s}$	6 MHz
	辐射源数目M	[2,5]
	幅度缩放A_m	U(0.2,1.0)
	基准PRIT_0	U(400,1000) μs
	PW捷变区间1	U(60,100) μs
	PW捷变区间2	U(100,150) μs
PRI调度类型	固定PRI	$T_{{\rm PRI},n} = T_0$
	随机抖动PRI	$T_{{\rm PRI},n} = T_0(1+\epsilon_n)$
	滑变PRI	$T_{{\rm PRI},n} = T_0 + (n \bmod L_c)\Delta T$
	参差PRI	$T_{{\rm PRI},n} = T_0(1+\alpha_{n \bmod L_s})$
	正弦调制PRI	$T_{{\rm PRI},n} = T_0\left[1+\beta\sin\left(\frac{2\pi {\rm TOA}_n}{L_m}\right)\right]$
PRI调制参数	随机抖动ϵ_n	$\epsilon_n \sim {\rm U}(-\rho,\rho)$
	抖动幅度ρ	U(0.05,0.25)
	滑变周期L_c	$\{5,6,\cdots,15\}$
	滑变步进$\Delta T/T_0$	U(0.02,0.08)
	参差周期L_s	$\{2,3,4\}$
	参差偏移系数α	U(0.10,0.40)
	正弦调制周期T_m	U(5,25)
	正弦调制幅度β	U(0.10,0.40)
脉内调制	脉内调制	LFM, CW, NLFM
	相位编码	Barker, Frank, P4

调度变化场景则在LFM波形基础上加入固定、随机抖动、参差、滑变及正弦调制等多种PRI模式，用以验证模型对复杂脉间时序依赖的建模能力。上述设置从脉冲边界、脉内结构与脉间时序3个层面互补展开，为FSUNet分选性能评估提供了支撑。

4.1.2 数据预处理与损失函数

在数据生成过程中，本文引入幅度缩放系数A_m以模拟不同辐射源的接收功率差异。为抑制该操作及多源叠加引起的样本间尺度波动，同时保留窗口内相对幅度关系，对每个输入样本执行全局最大幅度归一化：

$$\tilde{\boldsymbol{x}} = \frac{\boldsymbol{x}}{\max(|\boldsymbol{x}|) + \epsilon} \tag{43}$$

其中，$\boldsymbol{x}$表示原始输入序列，$\max(|\boldsymbol{x}|)$表示该序列的全局最大幅度，ϵ为防止分母为零而引入的极小正数。该归一化操作能够在保留脉冲相对幅度关系和局部形态特征的同时，降低不同样本之间幅值尺度差异对网络优化过程的影响。

训练过程中，本文对多通道预测响应与真实分选标签进行监督约束。为同时刻画逐点预测精度和整体形态一致性，损失函数由均方误差项和余弦相似度项共同构成。设模型输出为$\hat{\boldsymbol{Y}}$，真实标签为$\boldsymbol{Y}$，则均方误差定义为

$$\mathcal{L}_{\mathrm{mse}} = \frac{1}{N}\|\hat{\boldsymbol{Y}} - \boldsymbol{Y}\|_{\mathrm{F}}^2 \tag{44}$$

其中，$N = M \times T$表示单个样本中参与损失计算的标签元素总数。为进一步约束预测结果与真实标签在整体形态上的一致性，引入余弦相似度损失：

$$\mathcal{L}_{\cos} = 1 - \frac{\mathrm{vec}\left(\hat{\boldsymbol{Y}}\right)^{\mathrm{T}} \mathrm{vec}\left(\boldsymbol{Y}\right)}{\left\|\mathrm{vec}\left(\hat{\boldsymbol{Y}}\right)\right\|_2 \|\mathrm{vec}\left(\boldsymbol{Y}\right)\|_2 + \epsilon_{\mathrm{s}}} \tag{45}$$

其中，$\mathrm{vec}(\cdot)$表示向量化操作，ϵ_{s}为防止分母为零的极小常数。最终训练损失定义为

$$\mathcal{L} = \alpha\mathcal{L}_{\mathrm{mse}} + (1-\alpha)\mathcal{L}_{\cos} \tag{46}$$

其中，$\alpha \in (0,1)$为平衡幅值误差约束和形态一致性约束的权重参数。训练初始阶段设置$\alpha = 0.5$，使两项损失具有相同权重；随后将其对应的未约束参数经Sigmoid函数映射至0至1区间，并与网络参数共同优化，自适应调整两类约束在训练过程中的相对贡献。

4.1.3 训练配置

为避免数据泄露，训练集、验证集和测试集独立生成，三者之间不共享原始样本或切片。训练集、验证集和测试集均遵循相同的参数分布，样本规模分别为4000, 1000和1000组。整个实验基于PyTorch 2.7.0实现，运行环境为Windows 11。硬件平台包括NVIDIA L40 GPU, Intel Core i9-10900K CPU和96 GB内存。训练阶段采用AdamW优化器，初始学习率设置为1×10^{-3}，权重衰减为1×10^{-4}，批大小为32，最大训练轮数为100。训练过程中根据验证集保存最优模型，并在测试集上报告最终结果。

4.2 评判准则

为全面评估模型在雷达脉冲分选任务中的性能，本文从检测正确性和时域匹配精度两个方面构建评价指标体系。其中，检测正确性用于衡量模型是否能够准确识别脉冲并判定其辐射源归属，时域匹配精度则用于评估预测结果与真实脉冲在时间轴上的重合程度和形态一致性。

在检测性能方面，本文采用精确率(Precision, Pre)、召回率(Recall, Rec)和F1分数(F1-score)进行评价。Pre表示预测为脉冲的样本中与真实目标正确匹配的比例，主要反映模型的误检情况；Rec表示真实脉冲中被模型正确检出并完成归属判定的比例，主要反映模型的漏检情况；F1-score为Pre和Rec的调和平均值，用于综合衡量误检与漏检共同作用下的整体检测性能。

在时域匹配性能方面，本文采用交并比(Intersection over Union, IoU)和相似度(Similarity, Sim)进行评价。IoU用于度量预测脉冲与真实脉冲在时间轴上的重叠程度，能够反映模型对脉冲边界位置和持续时间的估计精度；Sim则在预测掩码阈值二值化后，通过余弦相似度衡量预测掩码与真实掩码之间的一致性，用于表征模型对脉冲时域占用形态的匹配能力。

4.3 分选结果

4.3.1 不同场景下的分选结果分析

表2给出了$M = 5$, SNR=0 dB条件下FSUNet在不同场景中的性能表现。除基础分选任务外，本文还额外设置了脉冲堆叠区域检测和脉冲边缘检测两类辅助任务，以评估模型对重叠片段和边界结构的表征能力。结果表明，FSUNet在各场景下均保持了较稳定的性能，验证了其在低信噪比和高密度交织条件下有效提取脉冲局部结构特征、并结合跨脉冲上下文信息实现可靠归属判决的能力。

由图6可见，在脉冲间隔较大、结构相对稀疏的非重叠区域，模型输出的掩码边界清晰，预测的脉冲起止位置与真实标注基本一致，表明FSUNet能够准确刻画脉冲的局部时域结构，并有效抑制噪声扰动。在多脉冲密集交织的重叠区域，局部遮蔽

表 2　不同任务场景下的模型性能

Tab. 2　Model performance under different task scenarios

任务场景	实验设置	IoU	Sim	Pre	Rec	F1
脉冲分选	脉冲分选	0.845	0.920	0.902	0.931	0.916
	堆叠检测	0.949	0.974	0.974	0.967	0.971
	边缘检测	0.827	0.904	0.912	0.905	0.908
脉内结构变化	脉宽变化	0.861	0.926	0.916	0.933	0.925
	混合调制	0.803	0.893	0.896	0.886	0.891
	混合相位	0.831	0.910	0.898	0.918	0.908
脉间时序变化	PRI变化	0.800	0.892	0.906	0.873	0.889

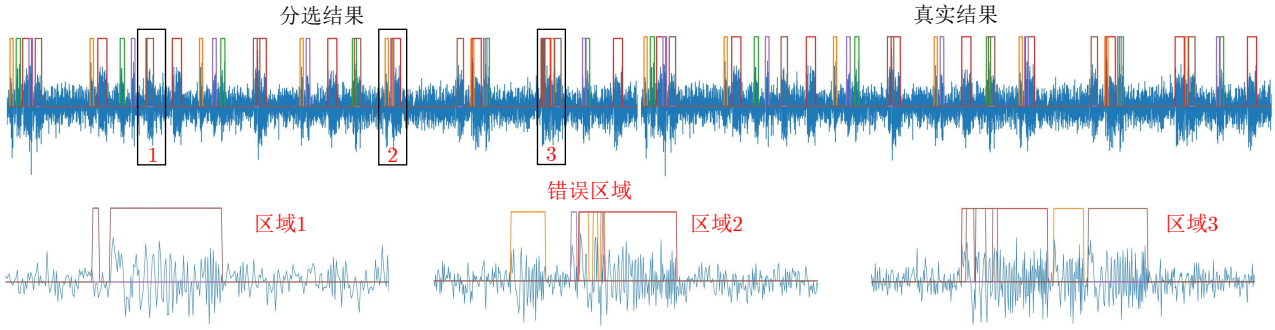

图 6 脉冲分选结果

Fig. 6 Radar pulse sorting results

和特征混叠会削弱部分时间位置的响应强度，导致低置信度区域在阈值化过程中被抑制，从而产生轻微断裂或局部不连续现象。尽管如此，模型整体仍能保持合理的分离趋势和稳定的同源归属结果，验证了其在高耦合观测条件下良好的分离判别能力。堆叠检测与脉冲边缘检测结果表明，FSUNet在整体归属判决之外，还可对重叠区域和关键边界位置形成较可靠响应。这说明模型具备多源脉冲堆叠区域的感知能力，以及对脉冲边界结构的刻画能力。

在脉内结构变化场景中，脉宽变化改变脉冲持续范围，混合调制与混合相位编码则引入更多样的局部波形与相位结构，削弱了局部形态特征的一致性，对模型细粒度表征与泛化提出更高要求。实验表明，FSUNet在该类场景下仍保持较好分选性能，能够从脉冲边界、局部结构及跨脉冲上下文中提取稳健判别信息。在脉间时序变化场景中，PRI由随机抖动扩展为固定、参差、滑变或正弦调制等形式后，同源脉冲到达间隔呈现离散切换、连续漂移或周期性变化等非平稳特征，加大了同源关联建模难度。实验表明，PRI变化虽使性能有所下降，但FSUNet仍可借助序列级上下文实现可靠归属判定，维持较稳定整体结果。

综合来看，局部结构、脉内形态及跨脉冲时序关系的变化对分选任务提出了多层次挑战，而FSUNet在各类场景下仍保持较优且稳定的分选性能，说明其局部结构表征与全局时序建模具有有效互补性，增强了复杂电磁环境下的分选鲁棒性。

4.3.2　不同信噪比下的结果分析

为评估模型在不同噪声强度下的分选稳定性，本文在无噪声多源混合脉冲流的基础上叠加加性高斯白噪声，并通过调节噪声功率控制观测信噪比。在固定辐射源数量为$M=5$的条件下，进一步考察模型在SNR由10 dB降低至0 dB时的性能变化，结果如表3所示。随着SNR从10 dB降低至0 dB，各项指标虽整体呈下降趋势，但变化幅度相对有限。即使在0 dB强噪声条件下，模型仍取得了较好的性能表现，表明FSUNet具有较好的抗噪声干扰能力。可以看出，模型在复杂交织、脉冲重叠以及低信噪比条件下均能保持较稳定的分选性能。

表 3　不同SNR下的模型性能指标

Tab. 3　Performance metrics under different SNR levels

SNR (dB)	IoU	Sim	Pre	Rec	F1
10	0.893	0.946	0.931	0.956	0.943
8	0.887	0.942	0.923	0.958	0.940
6	0.883	0.940	0.926	0.950	0.938
4	0.888	0.943	0.928	0.954	0.941
2	0.854	0.922	0.912	0.931	0.921
0	0.845	0.920	0.902	0.931	0.916

上述结果说明，FSUNet对脉冲局部形态特征与跨脉冲时序依赖的联合建模，能够在观测质量下降时为局部判别提供上下文约束，从而减弱噪声扰动对脉冲边界定位和辐射源归属判定的影响。

4.4 对比实验

为验证FSUNet的有效性，本文选取涵盖卷积、循环和注意力机制的代表性深度学习模型作为基线，包括循环神经网络Dual-Path RNN[24]，时频处理网络X-TF-GridNet[25]，注意力建模网络CAU-Net[26]和SepReformer[27]，以及卷积及其变体网络U-Net[35], U^2-Net[36], DCN[37]和VoxResNet[38]。为保证对比的公平性，所有基线模型均在仿真数据集上重新训练与测试，并在输入形式、训练策略和主要超参数设置上尽可能保持一致。本文从模型规模、计算复杂度和分选性能3个方面进行综合比较，分别报告参数量、计算量(GFLOPs)以及 IoU, Sim, Pre, Rec等评价指标，以分析不同模型在分选精度与计算开销之间的权衡关系。

表4给出了0 dB条件下的对比结果。可以看出，FSUNet在分选精度和计算效率之间取得了较好的平衡。与U-Net, U^2-Net, VoxResNet等纯卷积模型相比，FSUNet不仅能够提取局部波形结构，还通过状态空间递推机制显式建模跨脉冲上下文关系，因此在同源脉冲连续性保持和复杂交织场景下的归属判定方面表现更稳定。与SepReformer等基于注意力的全局建模方法相比，FSUNet在保持较高分选性能的同时具有更低的参数量和计算复杂度，说明结构化状态建模能够在长程依赖表达和计算效率之间取得更优折中。

同时，本文引入基于PDW参数的传统聚类方法作为对照。鉴于聚类输出为无语义簇编号，与监督模型的类别评价口径不同，采用聚类任务常用的purity指标进行评估。具体而言，选取PW, TOA, PRI和RF构成特征向量，经标准化后分别采用K-means[4], DBSCAN[5]和FCM[6]进行聚类，purity分别为0.856, 0.863和0.854。可见，在测参稳定、特征空间可分性较好时，传统聚类仍具一定分选能力；但其性能高度依赖PDW估计精度，在测参误差增大、参数漂移或类间分布接近时，结果易波动。FSUNet则直接从原始采样波形学习判别表征，并结合跨脉冲时序建模强化同源一致性约束，更有利于在动态调度及非理想观测条件下保持稳定分选性能。

为进一步评估实际运行代价，本文在NVIDIA L40 44 GB GPU上采用半精度浮点进行推理测试。当Batch Size为1时，FSUNet的平均推理时延为16.81 ms；当Batch Size为8时，总推理耗时为17.09 ms，吞吐率达到468.0 样本/s。该结果表明，FSUNet具有较好的批量并行处理能力，能够满足一定规模的离线或准实时处理需求。不过，面向单窗口低时延部署时，模型仍需在轻量化结构设计和推理加速方面进一步优化。

综上，FSUNet通过局部波形表征、跨脉冲状态建模和多层级特征融合的协同设计，在复杂交织和非理想观测条件下表现出较高的分选精度与鲁棒性。深度学习基线和传统聚类方法的对比结果进一步说明，FSUNet在端到端分选性能以及精度开销综合权衡方面具有较明显优势。

4.5 消融实验

为验证FSUNet各组成模块的有效性，本文按表5开展消融实验。结果表明，各模块在脉冲分选与边缘检测任务中作用各异且相互补充，完整模型在各项指标上均表现最优，说明性能提升源于局部特征提取、跨脉冲时序建模与多层级特征融合的协同，而非单一结构贡献。

具体而言，全局状态建模模块对维持跨脉冲时

表 4 不同模型性能对比

Tab. 4 Performance comparison of different models

模型	参数量(M)	GFLOPs	IoU	Sim	Pre	Rec	F1
FSUNet	1.54	1.14	0.845	0.920	0.902	0.931	0.916
Dual-Path RNN[24]	1.38	3.48	0.733	0.850	0.831	0.861	0.846
X-TF-GridNet[25]	3.36	1.60	0.707	0.831	0.799	0.859	0.828
CAU-Net[26]	2.76	2.76	0.650	0.792	0.774	0.804	0.788
SepReformer[27]	4.56	16.14	0.840	0.918	0.894	0.925	0.909
U-Net[35]	0.27	2.76	0.477	0.642	0.647	0.633	0.640
U^2-Net[36]	14.72	9.22	0.601	0.759	0.735	0.778	0.756
DCN[37]	0.71	4.86	0.512	0.687	0.676	0.689	0.683
VoxResNet[38]	0.22	0.58	0.637	0.784	0.753	0.805	0.778

表 5　消融实验结果

Tab. 5　Results of ablation experiments

任务	实验设置	IoU	Sim	Pre	Rec	F1
脉冲分选	FSUNet	0.845	0.920	0.902	0.931	0.916
	删除可变形卷积模块	0.781	0.880	0.847	0.909	0.877
	删除多尺度偏移量预测	0.810	0.897	0.873	0.917	0.895
	删除全局状态建模模块	0.604	0.756	0.743	0.763	0.753
	用Transformer代替全局建模	0.780	0.881	0.864	0.889	0.877
	删除注意力融合模块	0.640	0.786	0.707	0.871	0.780
边缘检测	FSUNet	0.827	0.904	0.912	0.905	0.908
	删除可变形卷积模块	0.757	0.851	0.852	0.835	0.843
	删除全局状态建模模块	0.817	0.897	0.898	0.881	0.889

序一致性具有关键作用。删除该模块后，模型在脉冲归属判定上的性能明显下降，表明稳定分选需要依赖长序列范围内的上下文约束。采用Transformer替代状态空间模块后，虽然模型仍能捕获部分脉冲间关系，但整体分选效果和计算效率均不及原方案，说明结构化状态建模在长程依赖表达和复杂度控制之间具有更好的综合权衡。而局部结构建模的增益则主要来自可变形卷积和多尺度偏移预测。删除相关组件后，模型在脉冲边界定位和细节刻画方面均出现退化，说明自适应采样和特征对齐有助于聚焦边界、突变和局部瞬态区域。该现象在边缘检测任务中更加明显，表明关键边界的精确刻画高度依赖局部几何自适应能力。

4.6　实验总结

综合上述实验结果可以看出，FSUNet在基础分选、堆叠检测、边缘定位、脉内结构变化以及非平稳PRI调度等场景下均表现出较好的稳定性。模型能够在脉冲重叠、局部波形变化和脉间时序规律变化等复杂条件下，有效完成脉冲边界定位与辐射源归属判定。消融实验进一步表明，FSUNet的性能提升并非依赖单一模块，而是来源于多尺度局部结构解析、跨脉冲状态建模和多层级特征融合之间的协同作用。从工程实现角度来看，FSUNet在保持较高分选精度的同时，其参数量、计算量和推理时延均处于可接受范围，具备一定的批量处理能力和实际部署潜力。然而，对于单窗口低时延或资源受限平台下的实时应用，模型仍需在轻量化结构设计、推理加速和在线自适应等方面进一步优化。

5　结语

针对复杂电磁环境下多源交织雷达脉冲分选问题，本文提出了一种基于结构化状态建模的端到端分选网络FSUNet。该网络直接以原始采样脉冲流为输入，通过多尺度自适应局部特征提取增强对脉冲边界、瞬态结构和局部形态变化的感知能力，并利用状态空间递推机制建模跨脉冲上下文关系，以刻画同源脉冲的时序连续性和状态演化规律。并在此基础上，FSUNet结合跳跃连接与注意力融合机制，自适应整合局部细节特征和全局状态表征，从而提升复杂交织条件下的脉冲定位与辐射源归属判定能力。实验结果表明，FSUNet在多种复杂场景下具有较好的分选精度和鲁棒性，并在计算效率可控的前提下优于对比方法。消融实验验证了局部特征提取、全局状态建模和注意力融合等核心模块的有效性。后续工作将围绕时频联合表征、多模态协同建模和小样本自适应学习展开，以进一步提升模型在未知辐射源和复杂干扰条件下的泛化能力。

利益冲突 所有作者均声明不存在利益冲突

Conflict of Interests The authors declare that there is no conflict of interests

参 考 文 献

[1] 隋金坪, 刘振, 刘丽, 等. 雷达辐射源信号分选研究进展[J]. 雷达学报, 2022, 11(3): 418–433. doi: 10.12000/JR21147.
SUI Jinping, LIU Zhen, LIU Li, *et al.* Progress in radar emitter signal deinterleaving[J]. *Journal of Radars*, 2022, 11(3): 418–433. doi: 10.12000/JR21147.

[2] WEI Shaopeng, HAN Haoyu, WEI Song, *et al.* ISRJ suppression using joint morphological component analysis and signal reconstruction based on jamming parameters estimation[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2026, 62: 3773–3797. doi: 10.1109/TAES.2025.3648973.

[3] CHENG Wenhai, ZHANG Qunying, DONG Jiaming, *et al.* An enhanced algorithm for deinterleaving mixed radar signals[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2021, 57(6): 3927–3940. doi: 10.1109/TAES.2021.

3087832.

[4] LLOYD S. Least squares quantization in PCM[J]. *IEEE Transactions on Information Theory*, 1982, 28(2): 129–137. doi: 10.1109/TIT.1982.1056489.

[5] ESTER M, KRIEGEL H P, SANDER J, *et al.* A density-based algorithm for discovering clusters in large spatial databases with noise[C]. Second International Conference on Knowledge Discovery and Data Mining, Portland, USA, 1996: 226–231.

[6] BEZDEK J C. Pattern Recognition with Fuzzy Objective Function Algorithms[M]. New York, USA: Springer, 1981: 1–272. doi: 10.1007/978-1-4757-0450-1.

[7] RODRIGUEZ A and LAIO A. Clustering by fast search and find of density peaks[J]. *Science*, 2014, 344(6191): 1492–1496. doi: 10.1126/science.1242072.

[8] WILKINSON D R and WATSON A W. Use of metric techniques in ESM data processing[J]. *IEE Proceedings F* (*Communications, Radar and Signal Processing*), 1985, 132(4): 229–232. doi: 10.1049/ip-f-1.1985.0055.

[9] MARDIA H K. New techniques for the deinterleaving of repetitive sequences[J]. *IEE Proceedings F* (*Radar and Signal Processing*), 1989, 136(4): 149–154. doi: 10.1049/ip-f-2.1989.0025.

[10] MILOJEVIĆ D J and POPOVIĆ B M. Improved algorithm for the deinterleaving of radar pulses[J]. *IEE Proceedings F* (*Radar and Signal Processing*), 1992, 139(1): 98–104. doi: 10.1049/ip-f-2.1992.0012.

[11] NELSON D. Special purpose correlation functions for improved signal detection and parameter estimation[C]. 1993 IEEE International Conference on Acoustics, Speech, and Signal Processing, Minneapolis, USA, 1993: 73–76. doi: 10.1109/ICASSP.1993.319597.

[12] LI Ziying, FU Xiongjun, DONG Jian, *et al.* Radar signal sorting via graph convolutional network and semi-supervised learning[J]. *IEEE Signal Processing Letters*, 2025, 32: 421–425. doi: 10.1109/LSP.2024.3519884.

[13] LANG Ping, FU Xiongjun, DONG Jian, *et al.* A novel radar signals sorting method via residual graph convolutional network[J]. *IEEE Signal Processing Letters*, 2023, 30: 753–757. doi: 10.1109/LSP.2023.3287404.

[14] ZHOU Zixiang, FU Xiongjun, DONG Jian, *et al.* Radar signal sorting with multiple self-attention coupling mechanism based Transformer network[J]. *IEEE Signal Processing Letters*, 2024, 31: 1765–1769. doi: 10.1109/LSP.2024.3421948.

[15] CHEN Hongzhuo, QI Liangang, GUO Qiang, *et al.* A multi-view attention hypergraph neural network for radar emitter signal sorting[J]. *IEEE Signal Processing Letters*, 2025, 32: 3754–3758. doi: 10.1109/LSP.2025.3602393.

[16] WANG Chao, SUN Liting, LIU Zhangmeng, *et al.* A radar signal deinterleaving method based on semantic segmentation with neural network[J]. *IEEE Transactions on Signal Processing*, 2022, 70: 5806–5821. doi: 10.1109/TSP.2022.3229630.

[17] LIU Zhangmeng. Pulse deinterleaving for multifunction radars with hierarchical deep neural networks[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2021, 57(6): 3585–3599. doi: 10.1109/TAES.2021.3079571.

[18] NUHOGLU M A, ALP Y K, ULUSOY M E C, *et al.* Image segmentation for radar signal deinterleaving using deep learning[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2023, 59(1): 541–554. doi: 10.1109/TAES.2022.3188225.

[19] GUO Qiang, HUANG Shuai, QI Liangang, *et al.* A radar signal deinterleaving method based on complex network and Laplacian graph clustering[J]. *IEEE Signal Processing Letters*, 2024, 31: 2580–2584. doi: 10.1109/LSP.2024.3461656.

[20] HE Chao, ZHANG Lei, WEI Song, *et al.* Multifunction radar working mode recognition with unsupervised hierarchical modeling and functional semantics embedding based LSTM[J]. *IEEE Sensors Journal*, 2024, 24(14): 22698–22710. doi: 10.1109/JSEN.2024.3406680.

[21] HYVÄRINEN A and OJA E. Independent component analysis: Algorithms and applications[J]. *Neural Networks*, 2000, 13(4/5): 411–430. doi: 10.1016/S0893-6080(00)00026-5.

[22] LEE D D and SEUNG H S. Learning the parts of objects by non-negative matrix factorization[J]. *Nature*, 1999, 401(6755): 788–791. doi: 10.1038/44565.

[23] LUO Yi and MESGARANI N. TasNet: Time-domain audio separation network for real-time, single-channel speech separation[C]. 2018 IEEE International Conference on Acoustics, Speech and Signal Processing, Calgary, Canada, 2018: 696–700. doi: 10.1109/ICASSP.2018.8462116.

[24] LUO Yi, CHEN Zhuo, and YOSHIOKA T. Dual-path RNN: Efficient long sequence modeling for time-domain single-channel speech separation[C]. 2020 IEEE International Conference on Acoustics, Speech and Signal Processing, Barcelona, Spain, 2020: 46–50. doi: 10.1109/ICASSP40776.2020.9054266.

[25] HAO Fengyuan, LI Xiaodong, and ZHENG Chengshi. X-TF-GridNet: A time-frequency domain target speaker extraction network with adaptive speaker embedding fusion[J]. *Information Fusion*, 2024, 112: 102550. doi: 10.1016/j.inffus.2024.102550.

[26] ZHOU Yejian, ZHENG Ye, WEI Shaopeng, *et al.* CAU-Net: A convolutional attention U-network for radar signal deinterleaving[J]. *IEEE Communications Letters*, 2024, 28(7): 1569–1573. doi: 10.1109/LCOMM.2024.3404957.

[27] SHIN U H, LEE S, KIM T, *et al.* Separate and reconstruct:

Asymmetric encoder-decoder for speech separation[C]. 38th International Conference on Neural Information Processing Systems, Vancouver, Canada, 2024: 1655. doi: 10.52202/079017-1655.

[28] LUO Zhenghao, YUAN Shuo, SHANG Wenxiu, *et al*. Automatic reconstruction of radar pulse repetition pattern based on model learning[J]. *Digital Signal Processing*, 2024, 152: 104596. doi: 10.1016/j.dsp.2024.104596.

[29] 李廉林, 周小阳, 崔铁军. 结构化信号处理理论和方法的研究进展[J]. 雷达学报, 2015, 4(5): 491–502. doi: 10.12000/JR15111.
LI Lianlin, ZHOU Xiaoyang, and CUI Tiejun. Perspectives on theories and methods of structural signal processing[J]. *Journal of Radars*, 2015, 4(5): 491–502. doi: 10.12000/JR15111.

[30] BRAND D and ZAFIROPULO P. On communicating finite-state machines[J]. *Journal of the ACM* (*JACM*), 1983, 30(2): 323–342. doi: 10.1145/322374.322380.

[31] 王俊, 郑彤, 雷鹏, 等. 深度学习在雷达中的研究综述[J]. 雷达学报, 2018, 7(4): 395–411. doi: 10.12000/JR18040.
WANG Jun, ZHENG Tong, LEI Peng, *et al*. Study on deep learning in radar[J]. *Journal of Radars*, 2018, 7(4): 395–411. doi: 10.12000/JR18040.

[32] KALMAN R E. Mathematical description of linear dynamical systems[J]. *Journal of the Society for Industrial and Applied Mathematics Series A Control*, 1963, 1(2): 152–192. doi: 10.1137/0301010.

[33] DAO T and GU A. Transformers are SSMs: Generalized models and efficient algorithms through structured state space duality[C]. 41st International Conference on Machine Learning, Vienna, Austria, 2024: 10041–10071.

[34] CHI Kun, SHEN Jihong, LI Yan, *et al*. Multi-function radar signal sorting based on complex network[J]. *IEEE Signal Processing Letters*, 2021, 28: 91–95. doi: 10.1109/LSP.2020.3044259.

[35] RONNEBERGER O, FISCHER P, and BROX T. U-Net: Convolutional networks for biomedical image segmentation[C]. 18th International Conference on Medical Image Computing and Computer-Assisted Intervention, Munich, Germany, 2015: 234–241. doi: 10.1007/978-3-319-24574-4_28.

[36] QIN Xuebin, ZHANG Zichen, HUANG Chenyang, *et al*. U^2-Net: Going deeper with nested U-structure for salient object detection[J]. *Pattern Recognition*, 2020, 106: 107404. doi: 10.1016/j.patcog.2020.107404.

[37] DAI Jifeng, QI Haozhi, XIONG Yuwen, *et al*. Deformable convolutional networks[C]. 2017 IEEE International Conference on Computer Vision, Venice, Italy, 2017: 764–773. doi: 10.1109/ICCV.2017.89.

[38] CHEN Hao, DOU Qi, YU Lequan, *et al*. VoxResNet: Deep voxelwise residual networks for brain segmentation from 3D MR images[J]. *NeuroImage*, 2018, 170: 446–455. doi: 10.1016/j.neuroimage.2017.04.041.

作 者 简 介

周叶剑，副教授，主要研究方向为空间态势感知、雷达成像智能解译。

冯继元，硕士生，主要研究方向为雷达信号参数估计、深度学习。

魏少鹏，副教授，主要研究方向为雷达探测与成像、雷达干扰对抗。

魏　嵩，讲师，主要研究方向为雷达信号检测、雷达干扰对抗。

(责任编辑：于青)