

基于集成注意力的 Bi-LSTM 雷达信号分选方法*

张宇翔^{1,2}, 张群英^{1†}, 侯进硕^{1,2}, 吴映莹^{1,2}, 刘小军¹, 方广有¹

(1 中国科学院空天信息创新研究院电磁辐射与探测技术重点实验室, 北京 100190;

2 中国科学院大学电子电气与通信工程学院, 北京 100049)

(2025 年 3 月 4 日收稿; 2025 年 4 月 16 日收修改稿)

Zhang Y X, Zhang Q Y, Hou J S, et al. Radar signal sorting using integrated attention-based Bi-LSTM[J]. Journal of University of Chinese Academy of Sciences, 2026, 43(5): 633-640. DOI: 10. 7523/j. ucas. 2025. 023.

摘要 雷达辐射源信号分选是现代战争中雷达电子侦察的关键环节。然而,随着电磁环境日益复杂,侦察接收机截获的信号往往存在大量脉冲缺失、虚假脉冲和脉冲抖动。复杂电磁环境具有信号长程相关、数据分布多样性、不同时间步信息互补等特点,而现有基于双向长短期记忆网络(Bi-LSTM)的雷达信号分选方法性能不足,主要是因为其全局依赖建模能力不足、存在梯度消失与过拟合风险以及特征交互受限。针对此,提出一种集成注意力的 Bi-LSTM 方法,通过集成多头自注意力机制、层归一化和残差连接等技术,分别解决上述问题。主要改进工作包括:1)数据预处理:将原始到达时间数据转换为到达时间差数据,以提升输入数据的鲁棒性与精度;2)特征提取与融合:采用 Bi-LSTM 层提取正向与反向时序信息,并引入多头自注意力机制进行深层次特征融合,兼顾长程依赖的捕捉与局部细节的提取;3)优化训练稳定性:利用残差连接与随机失活正则化,保证梯度传递的畅通性。实验结果表明该方法相较于 Bi-LSTM 方法准确率有明显提升,结构上的改进有效增强了模型对脉冲缺失、虚假脉冲和脉冲抖动的鲁棒性。

关键词 雷达信号分选;双向长短期记忆网络;多头自注意力;信号干扰;脉冲缺失;虚假脉冲;脉冲抖动

中图分类号: TN957.5 文献标志码: A DOI: 10. 7523/j. ucas. 2025. 023

Radar signal sorting using integrated attention-based Bi-LSTM

ZHANG Yuxiang^{1,2}, ZHANG Qunying¹, HOU Jinshuo^{1,2}, WU Yingying^{1,2},
LIU Xiaojun¹, FANG Guangyou¹

(1 Key Laboratory of Electromagnetic Radiation and Detection Technology, Aerospace Information Research Institute,
Chinese Academy of Sciences, Beijing 100190, China;

2 School of Electronic, Electrical and Communication Engineering, University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract Radar signal sorting is a key aspect of radar electronic reconnaissance in modern warfare. However, as the electromagnetic environment becomes increasingly complex, the signals intercepted by reconnaissance receivers often suffer from a large number of missing pulses, spurious

* 国家重点研发计划(2023YFC3011503)资助

† 通信作者, E-mail: qyzhang@mail. ie. ac. cn

pulses, and pulse timing jitter. The complex electromagnetic environment is characterized by long-range signal correlations, diverse data distributions, and complementary information across different time steps. Existing bidirectional long short-term memory (Bi-LSTM)-based radar signal sorting methods perform inadequately, primarily due to their insufficient ability to model global dependencies, risks of gradient vanishing and overfitting, and limited feature interaction. This paper proposes an integrated attention Bi-LSTM method that addresses these issues through the incorporation of multi-head self-attention mechanisms, layer normalization, and residual connections. The main improvements include: 1) Data preprocessing: Converting the original time of arrival data into time difference of arrival data to enhance the robustness and accuracy of the input data. 2) Feature extraction and fusion: Utilizing Bi-LSTM layers to extract both forward and backward temporal information, while introducing a multi-head self-attention mechanism for deep feature fusion, balancing the capture of long-range dependencies and local detail extraction. 3) Optimizing training stability: Employing residual connections and dropout regularization to ensure smooth gradient propagation. Experimental results indicate that this method achieves significantly improved accuracy compared to traditional Bi-LSTM approaches, and the structural improvements effectively enhance the model's robustness against pulses loss, spurious pulse, and pulse jitter.

Keywords radar signal sorting; bidirectional long short-term memory (Bi-LSTM); multi-head self-attention; signal interference; pulse loss; spurious pulse; pulse jitter

在现代雷达电子侦察、电子对抗以及相关领域中,雷达信号的提取与辨识一直是至关重要的课题^[1]。雷达脉冲分选,即从混杂的脉冲序列中提取出各个雷达辐射源的有效信号,是支撑后续目标检测、跟踪与决策的基础步骤^[2]。近年来,由于各种通信辐射源及干扰的广泛存在,再加上低截获概率技术的发展,截获的雷达信号往往呈现出脉冲抖动、脉冲缺失率大、虚假脉冲众多等特点^[3-4],这使得传统基于模型的信号处理方法面临越来越严峻的挑战^[5-6]。

传统的雷达信号处理方法,如基于傅里叶变换、时频分析的算法,在一定程度上能实现信号分选^[7],但当面对复杂背景和高度非线性信号时,常常暴露出识别率低、稳定性差以及实时性不足等问题^[8]。因此,利用深度学习方法对雷达信号进行高效特征提取与分类,已成为近年来研究的热点^[9-10]。深度神经网络在图像、语音及自然语言处理等领域展现了优异的性能,并逐步向雷达信号处理等传统领域渗透^[11-12],为处理时序信号提供了新的思路和方法。

目前,基于循环神经网络(recurrent neural network, RNN)及其变体的方法在雷达信号分选上取得了不错的效果^[13-14]。Liu 和 Philip^[15]提出一种基于 RNN 的方法,解决了脉冲流的分类、去噪和解交错问题。该方法采用门控循环单元处理脉冲流的时间序列特征,并通过学习脉冲流的长

期模式实现去噪和解交错。然而,RNN 在处理长序列时容易遭遇梯度消失问题。

Guo 等^[16]提出一种基于轨迹特征和长短期记忆网络(long short-term memory, LSTM)的雷达信号分选方法。该方法利用脉冲幅度的变化规律提取轨迹特征,并通过 LSTM 模型进行脉冲序列的预测和分选。LSTM 能够有效捕捉脉冲序列中的时间依赖关系,但单向 LSTM 模型在处理复杂脉冲序列时可能无法充分利用序列的双向信息。

为解决这一问题,Zhu 等^[17]提出一种基于神经机器翻译网络的方法,采用双向长短期记忆网络(bidirectional long short-term memory, Bi-LSTM)捕捉混合雷达脉冲序列中非相邻脉冲的时间依赖关系。Bi-LSTM 能够同时捕捉序列的正向和反向信息,显著增强了局部特征的提取能力,有效地解决了来自多个雷达源的脉冲序列的分离问题,即使存在测量噪声和丢失脉冲的条件下也能表现出色。

尽管 Bi-LSTM 能够同时捕捉正向与反向时序信息,并在局部特征提取方面具有优势^[18],但仍存在以下局限:

1) 全局依赖建模能力不足: Bi-LSTM 主要依赖局部时序信息,难以充分捕捉长距离依赖关系,导致对复杂信号模式的识别能力受限^[19];

2) 梯度消失与过拟合风险: 在长序列建模过程中,梯度衰减可能导致局部特征传递不充分,而

Bi-LSTM模型参数较多,易增加过拟合风险;

3)特征交互受限:传统结构较难实现全局各位置之间的特征交互,限制了模型对复杂信号的适应能力。

针对这些问题,近年来研究者引入注意力机制、层归一化、残差连接等技术,以提升全局信息捕捉能力和训练稳定性。其中,多头自注意力机制能够并行关注不同子空间中的特征信息,显著增强远程依赖建模能力;层归一化可有效缓解内部协变量偏移问题,加速收敛;残差连接则在保留原始信息的同时,缓解梯度消失问题,提升模型稳定性。

在此基础上,本文提出一种集成注意力的双向长短期记忆网络方法(integrated attention Bi-LSTM, IA-Bi-LSTM),在传统Bi-LSTM的基础上,进行以下关键改进:

1)全局特征强化:引入多头自注意力机制,增强远程依赖关系的建模能力,提高复杂信号模式的识别精度;

2)训练稳定性优化:利用层归一化减少内部协变量偏移,加速收敛,提升模型在复杂环境下的泛化能力;

3)梯度流动与抗噪增强:结合残差连接技术,优化信息传递路径,缓解梯度消失问题,并增强模型对噪声的鲁棒性。

仿真实验结果表明,IA-Bi-LSTM在雷达信号处理任务中有效提升了全局信息捕捉能力,同时保持较高的稳定性和抗干扰能力,进一步提高了信号分选的准确度。

1 IA-Bi-LSTM结构和算法介绍

1.1 IA-Bi-LSTM整体框架

IA-Bi-LSTM的整体框架如图1所示,主要由

数据预处理模块、Bi-LSTM结构、层归一化结构、多头自注意力机制、残差连接与随机失活(dropout)结构构成。

网络的输入数据是交错的到达时间(time of arrival, TOA)雷达脉冲数据。首先经数据预处理模块转为到达时间差(difference of TOA, DTOA)数据,再通过Bi-LSTM提取时序特征,并结合多头自注意力机制和其他辅助模块对特征进行深度融合,最终通过全连接层映射到目标输出空间。

1.2 数据预处理模块

本文设计并实现了一个高效的数据预处理模块,旨在解决网络结构中数据输入阶段的格式与质量问题。原始数据以TOA形式获取,直接反映了数据采集过程中的时延信息。然而,直接使用TOA数据会受到噪声、干扰等因素的影响,不利于反映数据特征。为此将TOA数据转换为DTOA数据,以在一定程度上消除系统中的固定偏差和环境噪声,提高数据用于网络结构处理时的鲁棒性和精度。

该数据预处理模块完成了以下几项任务:

1)数据校正与归一化

在数据预处理初期,通过对TOA数据进行校正,剔除偏差数据。同时,对校正后的数据采用归一化处理,保证数据在相同维度下的对比性,为后续的特征提取提供稳定的输入基础。

2)TOA到DTOA数据转换

在传统的主分选任务中,只依赖TOA数据作为参数,并不能揭示各序列间的内在联系。同时,由于TOA序列是一个不断递增的序列,随着脉冲数量的增加,后续脉冲的数据值会显著大于前面的数据。这种数值上的巨大差异使得如果直接将原始TOA序列作为输入,神经网络将难以捕捉到




图1 IA-Bi-LSTM整体框架

Fig. 1 Overall framework of IA-Bi-LSTM

时序特征,导致训练过程变得相当困难。鉴于此,为适应神经网络对数值特性的要求,将 TOA 数据转换为 DTOA 数据,并在 DTOA 序列的起始位置补充 1 个 0,以保证序列长度的一致性。

3) 数据重构与格式转换

转换完成后,模块将 DTOA 数据整理为适合后续深度学习网络输入的张量结构,封装在 Dataset 类的结构中。这一过程使得数据具有高度的并行计算能力,为后续大规模网络训练提供了有力支撑。

1.3 Bi-LSTM 层结构

Bi-LSTM 层利用正向和反向 2 个 LSTM 子网络,可同时捕捉时序信号的信息。通过这种结构,网络不仅能够学习到前向依赖关系,还能获得反向的时序依赖,提高了网络在处理长序列时的能力^[20]。

单个 LSTM 网络按时间步处理输入,以正向时间步递增为例,其每个时间步的计算公式如下

1) 输入门

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i), \quad (1)$$

其中: x_t 为当前时间步的输入向量, h_{t-1} 为上一时间步的隐状态向量, W_i 和 U_i 为对应输入门的输入权重矩阵和先前隐状态的权重矩阵, b_i 为输入门的偏置。 σ 是 Sigmoid 激活函数, $\sigma(z) = \frac{1}{1 + e^{-z}}$,用来将计算结果映射到(0,1)区间,从而控制当前输入对记忆状态的影响。

2) 遗忘门

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f), \quad (2)$$

与输入门类似, W_f 、 U_f 及 b_f 分别为遗忘门的输入权重、先前隐状态权重与偏置。遗忘门控制在更新记忆状态时,应遗忘多少先前的记忆。

3) 候选记忆状态

$$\tilde{c}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c), \quad (3)$$

其中: W_c 、 U_c 及 b_c 为候选记忆状态对应的权重矩阵和偏置; $\tanh$ 是双曲正切激活函数, $\tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$,将数据映射到(-1,1)区间。

此步骤用于生成经过非线性变换后的候选记忆状态,为后续构建新的记忆状态提供备选信息。

4) 记忆状态更新

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t, \quad (4)$$

其中: c_{t-1} 为上一时间步的记忆状态; $\odot$ 是元素级乘法,也称 Hadamard 乘积,对于 2 个向量表示对应元素逐个相乘,即 $(a \odot b)_j = a_j \times b_j$ 。

式(4)融合了遗忘门和输入门的调控,使得部分前一时刻的记忆保留,同时加入当前候选记忆状态以更新记忆。

5) 输出门及隐状态

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o), \quad (5)$$

$$\vec{h}_t = o_t \odot \tanh(c_t), \quad (6)$$

其中: W_o 、 U_o 及 b_o 为输出门对应的权重矩阵和偏置。 $\vec{h}_t$ 为正向 LSTM 单元的隐状态输出。本步骤首先通过 Sigmoid 函数确定输出门的激活程度,再将激活值与记忆状态(经过非线性 tanh 处理)的每个元素逐一相乘,输出最终的隐状态。

6) 在经过正向和反向两部分计算后,将每个时间步的隐状态进行融合拼接

$$h_t = [\vec{h}_t; \overleftarrow{h}_t], \quad (7)$$

其中: $\overleftarrow{h}_t$ 为反向 LSTM 单元在该时间步的隐状态输出; $[\ ;]$ 表示拼接操作,将正向和反向隐状态在特征维度上合并,生成包含前后序列信息的综合隐状态。这样生成的 h_t 同时包含了前后序列信息,为后续处理提供更为丰富的序列特征表达。

1.4 层归一化与多头注意力机制

在现代深度学习模型中,多头注意力机制是一种关键技术,尤其在基于 Transformer 的模型架构中得到了广泛应用^[21]。

多头注意力机制通过将输入表示分别映射到多个子空间内,并在每个子空间中独立计算注意力得分,从而实现对输入序列中不同语义成分的并行捕捉。具体而言,设输入表示为 X ,首先经过 3 个不同的线性变换,得出查询矩阵 Q 、键矩阵 K 及值矩阵 V 。在此基础上,模型将 Q 、 K 和 V 拆分成 h 个子空间,分别用以计算各自的注意力表示

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V, \quad (8)$$

其中 d_k 为每个子空间中键向量的维度。多个注意力头独立进行上述计算后,将得到的输出向量进行拼接,并通过一个线性变换映射回原始的表示空间。这样的设计使得模型能够从多个角度理解输入的上下文信息,既捕捉了局部细节,也兼顾

了全局关联性。

在本网络结构中,首先采用层归一化技术对LSTM的输出进行处理。层归一化是对每个样本内部的特征维度进行归一化,它能够有效缓解梯度消失或梯度爆炸问题,保证各层输出在数值上的稳定性,从而加速模型训练与收敛。将原始LSTM输出归一化,使其在后续模块中具有更为规范和稳定的分布。

接下来,模型引入多头自注意力机制。多头自注意力通过对归一化后的LSTM输出同时构造矩阵 Q 、 K 和 V ,实现对输入序列各位置间相关性的建模。这样既能捕捉长程依赖,从不同的子空间分别挖掘特征信息,还能做到信息融合,形成对序列更全面的表征,为后续任务提供更丰富的上下序列信息。

最终,多头注意力机制输出的张量形状依旧保持,确保特征表示的维度与Bi-LSTM输出结构的一致性。为模型提供了更高层次的特征表示,有助于提升模型在复杂序列任务中的表现。

1.5 残差连接与Dropout层

在深度学习模型中,残差连接是一种有效的结构设计,旨在缓解深层网络中的梯度消失问题。通过引入跨层连接,残差连接允许梯度直接从后面的层流向前面的层,促进了信息的传递。具体而言,对于给定的输入 x ,残差连接的输出可以表示为

$$y = F(x) + x, \quad (9)$$

其中 $F(x)$ 被跨层的网络输出。

Dropout是一种正则化技术,通过随机丢弃一定比例的神经元,防止模型对训练数据的过拟合。丢弃方式是在训练过程中以概率 p 将某些神经元的输出置为零,从而促使模型学习更为鲁棒的特征表示。

为提升模型在复杂任务中的训练稳定性和泛化性能,本文将经过注意力机制提取到的特征与Bi-LSTM提取的特征残差连接并引入Dropout层,既利用残差连接所带来的梯度流动优势和多尺度特征融合,又借助Dropout的正则化效果。这种特征增强方法在多种任务中均表现出显著的效果,能够更好地捕捉数据中的隐含结构信息。

1.6 算法流程

算法流程图如图2所示。首先,将雷达信号数据按照批次输入网络。接着,利用Bi-LSTM层




图2 算法整体流程图

Fig. 2 Overall process of the proposed algorithm

对输入序列进行正向与反向处理,从而有效捕捉到上下文信息,并生成尺寸为隐藏层大小2倍的特征向量。为进一步稳定数据分布并提升训练效率,随后采用层归一化对Bi-LSTM输出进行处理。

在提取局部时序特征的基础上,为获得全局依赖关系,引入多头自注意力机制。此模块类似于对时序特征的“全局滤波”,能够显著增强对长距离依赖信息的捕捉能力。随后,将自注意力模块的输出同经过层归一化后的原始Bi-LSTM特征进行融合,采用残差连接保证梯度能够直接传递,同时利用Dropout技术对融合结果进行正则化,以有效防止模型过拟合现象。

最后,经过融合及正则化处理后的特征向量将通过全连接层映射到输出空间,通过激活函数softmax生成最终的预测结果。整个流程的设计在融合局部和全局信息的同时,通过层归一化、残差连接和Dropout等方法提高了网络的稳定性和泛化性能。

2 仿真实验分析

主要进行了4种干扰条件下的仿真实验,分别是:只存在脉冲缺失;只存在虚假脉冲;只存在脉冲抖动;既存在脉冲缺失又存在虚假脉冲。脉

冲缺失的比例为 0 ~ 50%, 虚假脉冲的比例为 0 ~ 50%。其中虚假脉冲是序列时间范围内随机生成的脉冲。

2.1 数据集和实验参数

数据集分为 2 部雷达分选和 3 部雷达分选。2 部雷达的数据集由 1 个固定重频和 1 个滑变重频组成, 具体重频参数设置如表 1 所示。3 部雷达的数据集由 2 个固定重频和 1 个滑变重频组成, 具体重频参数设置如表 2 所示。

每个数据集都仿真了 10 000 条交错 TOA 序列, 每条 TOA 序列长度为 1 000, 其中 80% 用作训练集, 20% 用作测试集。

实验使用 Pytorch 框架, 在 Nvidia GeForce RTX 4080 设备上实验。模型损失函数选择 CrossEntropyLoss, 优化器选择 Adam, 数据批次大小选择 64, 随机失活权重为 0.1, 学习率为 5×10^{-5} , 训练轮数选择为 400, 直至收敛。

在网络参数的设置上, 输入特征数为 1, 隐藏层节点数为 200, 隐藏层数为 2, 注意力头数选择 8, 分类标签数根据需要进行选择 3 或 4。

2.2 仿真结果

为评估 IA-Bi-LSTM 模型在雷达分选上的效果, 在相同的实验条件下与 LSTM 网络和 Bi-LSTM 网络进行对比。重点比较在不同的脉冲缺失率、虚假脉冲比例和脉冲抖动比例下的分选准确率。

首先对 2 部雷达进行分选。

当虚假脉冲和脉冲抖动比例为 0 时, 3 种网络的准确率随脉冲缺失率的变化情况如图 3 所示。当脉冲缺失率较低时, 3 种方法的准确率都较高; 当脉冲缺失率逐渐升高时, LSTM 和 Bi-LSTM 下降明显; 而 IA-Bi-LSTM 在 30% 的缺失率情况下依然

保持着高准确率。在缺失率 40% 以上时, IA-Bi-LSTM 的准确率要比另外 2 个模型高出至少 15 个百分点。

当脉冲抖动率和缺失率为 0 时, 3 种网络的准确率随虚假脉冲比例的变化情况如图 4 所示。当虚假脉冲比例开始升高, LSTM 的准确率就有明显下降; 而虚假脉冲比例到 10% 以上时, Bi-LSTM 准确率下降趋势加快; IA-Bi-LSTM 直到虚假脉冲比例达到 40% 都保持着高准确率, 并且领先 15 个百分点; 直到虚假脉冲比例达到 50% 时, IA-Bi-LSTM 的准确率仍有 78%。

脉冲缺失率和虚假脉冲比例同时升高情况下, 3 种网络的对比情况如图 5 所示。在极限数据条件下, 3 种网络的准确率都有下滑, 但在 30% 脉冲缺失率和 30% 的虚假脉冲比例下, IA-Bi-LSTM 的准确率高出 11 个百分点。40% 缺失率和 40% 虚假比例的情况下, IA-Bi-LSTM 的准确率比 Bi-LSTM 高 5 个百分点。




图3 脉冲缺失率变化性能对比

Fig. 3 Pulse missing rate variation performance comparison




图4 虚假脉冲比例变化性能对比

Fig. 4 Spurious pulse ratio variation performance comparison

表 1 2 部雷达重频参数设置

Table 1 Two-radar PRF parameter configuration		
重频模式	重频值/Hz	起始时间/ μ s
固定重频	1~1 000	1~100 000
滑变重频	$(30 \sim 80)n + 1 \sim 300$	1~100 000

表 2 3 部雷达重频参数设置

Table 2 Three-radar PRF parameter configuration		
重频模式	重频值/Hz	起始时间/ μ s
固定重频 1	200~800	1~100 000
固定重频 2	600~1 500	200 000~300 000
滑变重频	$(30 \sim 80)n + 1 \sim 300$	150 000~200 000




图5 脉冲缺失率与虚假脉冲比例变化性能对比

Fig. 5 Pulse missing rate and spurious pulse ratio variation performance comparison

当环境中的噪声偏大,信号的真实特性可能被噪声淹没,导致 TOA 数据的散点分布更为分散,用不同比例的脉冲抖动仿真环境噪声场景。不同比例的脉冲抖动下,3种网络的对比情况如图6所示。可以看出3种网络在脉冲抖动比例升高的同时,性能都有所下降,但 IA-Bi-LSTM 的效果仍为最好。

3部雷达在不同脉冲缺失率和虚假脉冲比例下各网络的分选准确率如表3所示。从表3可以看出,IA-Bi-LSTM 的表现优于 LSTM 和 Bi-LSTM,尤其是在无缺失、无干扰以及单一严重场景(仅




图6 脉冲抖动比例变化性能对比

Fig. 6 Pulse jitter ratio variation performance comparison

有缺失或仅有虚假脉冲)的条件下,显示出更明显的优势;在严重干扰缺失条件下,准确率也比 Bi-LSTM 高出2个百分点。

综合网络在2部雷达数据集和3部雷达数据集上的分选效果,可以看出:1)在理想和较优条件下,IA-Bi-LSTM 利用双向信息融合、多头自注意力、层归一化和残差连接等改进技术,可显著提高提取准确率。2)即便在高干扰、高缺失、高脉冲抖动情况下,尽管所有模型的性能均有所下降,但 IA-Bi-LSTM 依旧能够保持较高的准确率,表明结构上的改进有效增强了模型对缺失、虚假脉冲和脉冲抖动的鲁棒性。

表3 不同脉冲缺失率和虚假脉冲比例下各网络的分选准确率				
Table 3 Sorting accuracy of various networks under different pulse missing rates and spurious pulse ratios				
网络模型	分选准确率			
	缺失率0 虚假比例0	缺失率0 虚假比例30%	缺失率30% 虚假比例0	缺失率30% 虚假比例30%
LSTM	89.96	78.13	73.82	65.93
Bi-LSTM	92.19	89.10	76.13	72.74
IA-Bi-LSTM	98.78	92.42	85.22	74.84

3 结论

本文针对脉冲缺失率高、虚假脉冲比例大、脉冲抖动比例大等复杂电磁环境下,雷达信号分选困难的问题,提出一种基于集成注意力的 Bi-LSTM 的雷达信号分选方法。

通过双向 LSTM 捕获正向与反向时序信息,并利用多头自注意力机制实现全局依赖关系的捕捉,充分提取雷达脉冲序列中的详细变化及长期模式。通过多头注意力机制,从多个角度理解输入的上下时序信息,既捕捉了局部细节,也兼顾了全局关联性。通过层归一化、残差连接与 Dropout

正则化方法,有效缓解深层网络训练过程中的梯度消失和过拟合问题,保证了模型在高虚假脉冲率、高缺失率、高脉冲抖动率情况下依然具备较高的分选准确率。

仿真实验结果验证了所提出的 IA-Bi-LSTM 模型在不同干扰、缺失、抖动条件下均取得了优于传统 LSTM 与 Bi-LSTM 方法的性能表现。在2部雷达及3部雷达数据集的测试中,无论是单一干扰环境,还是极端复合条件下,新方法均显示出明显的鲁棒性与高准确率,其在脉冲缺失率、虚假脉冲比例、脉冲抖动率较严重的场景中均优势明显。

本研究从网络架构、数据预处理到特征融合

等方面对传统 Bi-LSTM 模型进行针对性优化,有效提升了雷达信号分选的性能。未来工作可进一步探讨更深层次的特征交互机制以及自适应处理策略,在更多复杂场景下验证模型的泛化能力,同时结合实际系统需求,实现在线实时雷达信号处理,为电子侦察和对抗提供更强有力的技术支持。

参考文献

- [1] 李明松. 基于机器学习的雷达信号脉间参数分选研究[D]. 哈尔滨: 哈尔滨工程大学, 2021. DOI: 10.27060/d.cnki.ghbcu.2021.000277.
- [2] 陈涛, 刘福悦, 李金鑫, 等. 基于深度分割的端到端雷达信号分选[J]. 系统工程与电子技术, 2023, 45(5): 1351-1358. DOI: 10.12305/j.issn.1001-506X.2023.05.11.
- [3] 王怡明. 基于无监督聚类的雷达信号分选算法研究与系统设计[D]. 合肥: 安徽大学, 2023. DOI: 10.26917/d.cnki.ganhu.2023.001042.
- [4] Li X Q, Liu Z M, Huang Z T. Attention-based radar PRI modulation recognition with recurrent neural networks[J]. IEEE Access, 2020, 8: 57426-57436. DOI: 10.1109/ACCESS.2020.2982654.
- [5] 王俊岭, 黄琰璟. 基于序列关联的参差信号分选算法[J]. 电子与信息学报, 2021, 43(4): 1145-1153. DOI: 10.11999/JEIT191030.
- [6] 刘严, 郭福成. 基于滑动时间窗的雷达脉冲列分选方法[J]. 电子与信息学报, 2022, 44(11): 3900-3909. DOI: 10.11999/JEIT210982.
- [7] 普运伟, 陈新杰, 余永鹏, 等. 基于模糊函数多维结构度量特征的雷达辐射源信号流在线分选[J]. 仪器仪表学报, 2023, 44(8): 277-288. DOI: 10.19650/j.cnki.cjsi.J2311559.
- [8] 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.
- [9] Chi K, Shen J H, Li Y, et al. Multi-function radar signal sorting based on complex network[J]. IEEE Signal Processing Letters, 2020, 28: 91-95. DOI: 10.1109/LSP.2020.3044259.
- [10] Wang C, Wang Y, Li X Q, et al. A deinterleaving method for mechanical-scanning radar signals based on deep learning[C]//2022 7th International Conference on Intelligent Computing and Signal Processing (ICSP). April 15-17, 2022, Xi'an, China. IEEE, 2022: 138-143. DOI: 10.1109/ICSP54964.2022.9778808.
- [11] 何利健, 张锐, 林晓冬. 基于DWT和双通道LSTM的卫星电池阵电流预测方法[J]. 中国科学院大学学报, 2023, 40(3): 415-421. DOI: 10.7523/j.issn.2021.0028.
- [12] 王艺璇, 张怀, 石耀霖, 等. 基于LSTM神经网络的南加州中期地震预测[J]. 中国科学院大学学报, 2025, 42(2): 199-208. DOI: 10.7523/j.ucas.2023.068.
- [13] 李洁, 林永峰. 基于多时间尺度RNN的时序数据预测[J]. 计算机应用与软件, 2018, 35(7): 33-37, 62. DOI: 10.3969/j.issn.1000-386x.2018.07.006.
- [14] 姜在阳, 孙思月, 李华旺, 等. 一种基于JANET模型的雷达信号分选方法[J]. 中国科学院大学学报, 2021, 38(6): 825-831. DOI: 10.7523/j.issn.2095-6134.2021.06.013.
- [15] Liu Z M, Yu P S. Classification, denoising, and deinterleaving of pulse streams with recurrent neural networks[J]. IEEE Transactions on Aerospace and Electronic Systems, 2019, 55(4): 1624-1639. DOI: 10.1109/TAES.2018.2874139.
- [16] Guo Q, Teng L, Qi L G, et al. A novel radar signals sorting method-based trajectory features[J]. IEEE Access, 2019, 7: 171235-171245. DOI: 10.1109/ACCESS.2019.2955819.
- [17] Zhu M T, Wang S F, Li Y J. Model-based representation and deinterleaving of mixed radar pulse sequences with neural machine translation network[J]. IEEE Transactions on Aerospace and Electronic Systems, 2022, 58(3): 1733-1752. DOI: 10.1109/TAES.2021.3122411.
- [18] 王易丽. 基于机器学习的雷达信号分选算法研究[D]. 成都: 电子科技大学, 2023. DOI: 10.27005/d.cnki.gdzku.2023.005056.
- [19] Beck M, Pöppel K, Spanring M, et al. Xlstm: extended long short-term memory[EB/OL]. arXiv 2024:2405.04517. (2024-12-06) [2025-04-08]. <https://arxiv.org/abs/2405.04517v2>.
- [20] 廉文超, 宋小全, 郝朝阳, 等. 双向长短期记忆网络在激光雷达风廓线预测的应用[J]. 光学学报, 2024, 44(24): 58-67. DOI: 10.3788/AOS240891.
- [21] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[EB/OL]. arXiv 2023: 1706.03762. (2023-08-02) [2025-04-08]. <https://arxiv.org/abs/1706.03762v7>.