

基于多尺度注意力机制 ResNet 的雷达工作模式识别

卓奕弘, 熊敬伟, 潘继飞, 郭林青

(国防科技大学电子对抗学院, 安徽合肥 230037)

摘要: 雷达工作模式识别是解释雷达行为和功能的基本任务。现有方法难以在信号灵活、环境复杂的条件下筛除脉冲序列中不同空间和不同通道中的冗余信息。本文在深度残差网络的基础上,增加了空间自注意力模块和通道自注意力模块以适应上述信号特点。模型引入自注意力机制以实现雷达序列不同空间和通道的自适应权重分配,使网络能更有效地关注更具差异性的信息,实现了极端条件下雷达工作模式的高精度识别。同经典深度学习网络 AlexNet、LeNet、VGGNet、ResNet 以及常规深度卷积网络相比,该模型在 0~50% 漏脉冲条件下,平均识别率提升了 36%,在独立测试集 40% 漏脉冲比例下模型仍然具备 90% 以上的识别率,证明了所提网络的优越性和有效性。

关键词: 多功能雷达; 模式识别; 自注意力机制; 特征提取; 深度学习

中图分类号: TN971 **文献标志码:** A **文章编号:** 1672-2337(2024)02-0170-10

引用格式: 卓奕弘, 熊敬伟, 潘继飞, 等. 基于多尺度注意力机制 ResNet 的雷达工作模式识别[J]. 雷达科学与技术, 2024, 22(2): 170-179.

ZHUO Yihong, XIONG Jingwei, PAN Jifei, et al. Radar Working Mode Recognition Based on Multi-Scale Attention Mechanism ResNet[J]. Radar Science and Technology, 2024, 22(2): 170-179.

Radar Working Mode Recognition Based on Multi-Scale Attention Mechanism ResNet

ZHUO Yihong, XIONG Jingwei, PAN Jifei, GUO Linqing

(College of Electronic Engineering, National University of Defense Technology, Hefei 230037, China)

Abstract: Mode recognition is a basic task to interpret radar behavior and function. Under the condition of flexible signal and complex environment, the existing methods are difficult to screen out the redundant information in different spaces and channels in the pulse sequence. In this paper, based on the deep residual network, a spatial self-attention module and a channel self-attention module are added to adapt to the above signal characteristics. The self-attention mechanism is introduced in the model to realize the adaptive weight allocation of different spaces and channels of radar sequence, so that the network can focus on more diverse information more efficiently. The high precision recognition of radar working mode is realized under extreme conditions. Compared with classical deep learning networks such as AlexNet, LeNet, VGGNet, ResNet and conventional deep convolutional networks, the average recognition rate of this model is improved by 36% under the condition of 0~50% leakage pulses. In the independent test set, the model still has a recognition rate of more than 90% under the 40% leakage pulse. The advantages and effectiveness of the proposed network are proved.

Key words: multifunctional radar; mode recognition; self-attention mechanism; feature extraction; deep learning

0 引言

雷达工作模式识别(Radar Mode Identification, RMI)是指从未知的接收信号中获取雷达样式及参数来分析雷达功能,识别雷达所处工作状态的过程。随着相控阵以及信号处理技术的高速发展,现代多功能雷达(Multi-Function Radar, MFR)已经具备了实时调整信号样式、灵活变换方向的能力,

能够实现有效的搜索、跟踪、制导等多元化作战任务^[1]。RMI技术在电子情报(ELINT)、认知无线电、作战决策等领域发挥着巨大的作用^[2-4]。但随着雷达工作样式更加多元,参数可变性显著增强,电磁空间越加复杂,人们无法通过以往简单的方式,例如模板匹配、统计直方图等方法有效地识别MFR的工作模式^[5]。现代复杂环境下的RMI已经成为一个重要且具有挑战性的问题。本文试图结

合雷达信号特点,利用深度学习“端到端”的优势,提出一种行之有效的解决方法。

早期的雷达信号由于电磁环境单纯,信号参数简单,工作样式单一,因此通过对 PDW 参数的简单比对即可实现工作模式的识别^[6]。即使参差、滑变等复杂调制样式出现,由于雷达行为相对固定和单一,利用模式之间的关联分析仍然可以完成雷达的分选识别^[7-13]。但随着相控阵技术的发展,雷达波形与样式灵活多变,参数的混叠也越来越严重,传统的识别方法逐渐失效,研究者开始引入特征提取能力优异的机器学习方法^[14]。

机器学习方法是在建立模型的基础上,通过学习大量数据来优化模型以实现分类识别。K-近邻、支持向量机(SVM)等传统分类器和广泛应用的深度学习网络就是其典型代表。传统分类器^[15-16]通过聚类分析对数据进行粗分类后再利用分类器进行识别,发挥了机器学习在回归问题和分类问题上的出色性能,但无法识别复杂信号样式。神经网络在雷达信号识别上应用更加广泛,文献^[17-21]分别建立了去噪自编码器(DAE)、卷积神经网络(CNN)、残差神经网络(ResNet)和循环神经网络(RNN)来识别信号,在给定条件下均取得 90% 以上的识别率,验证了深度学习方法在信号识别领域的优势,但同时也暴露出单一网络面对复杂环境的薄弱性。因此,不少学者开始对神经网络进行改进^[22-23]。

雷达信号不同于图像,受到噪声和硬件的影响,信号传输过程中会发生一定的丢失和畸变,因此信号中会混杂大量冗余且错误的信息^[24],对模式识别产生很大的负面影响。同时,雷达脉冲信号中,脉冲幅度、脉冲到达方向等信息对于雷达功能影响较小,不同模式下并不会产生明显差异,而载频、脉冲间隔、脉冲宽度等对功能的影响也不尽相同,因此对于不同通道的信息,采取不同的取舍策略极为必要。针对以上特点,本文提出了基于多尺度注意力机制的 ResNet 网络来实现工作模式识别。针对不同空间位置和通道信息权重不一致的问题,设计了空间注意力模块和通道注意力模块,以实现自适应的权值分配。在 4 种雷达工作模式数据集上的实验体现了所给网络的优越性,与

经典深度学习网络相比平均识别率提升了 36%,在独立测试集 40% 漏脉冲比例下模型仍然具备 90% 以上的识别率。

1 雷达工作模式分析

在典型对抗环境下,对抗双方以非合作方的角度采集雷达信号,经过一系列的分析处理后得到所需的情报信息,其过程一般包括信号的预处理、分选、识别等过程。而对于信号识别来说,由于不同的作战需要,一般包含雷达型号识别、个体识别以及工作模式识别,典型工作流程如图 1 所示。本文重点针对战场威胁态势评估影响较大的雷达工作模式开展研究。

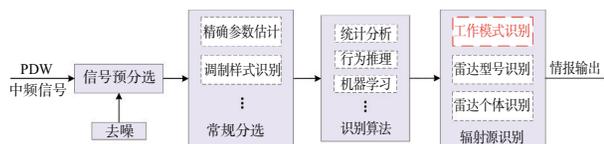


图1 典型对抗环境下信号处理流程

1.1 雷达信号基本组成

雷达工作模式因其独特的功能需求通常要求与之对应的参数范围和调制样式。完整的雷达脉冲信号流包含截获信号的脉内波形和脉间样式,这可以准确且完整地表征雷达信号。而进行逐脉冲采样的形式得到的雷达全脉冲流信息量巨大,采用传统的识别算法或是基于神经网络的算法都很难处理如此大规模的数据。考虑到本文研究对象为雷达工作模式,脉内波形对区分不同模式的影响较小,因此,我们采用了雷达全脉冲中脉冲描述字的集合来表征该部分雷达信号。信号接收机通常采集到的雷达信号数据包括采样得到的脉内波形和脉冲描述字^[25](PDW)。包含载频、脉宽、脉幅、脉冲到达时间、方位等信息,如图 2 所示。

1.2 脉冲调制样式

脉冲调制样式是雷达信息的重要组成部分,雷达波形设计时通常在载频、脉冲重复间隔和脉宽等参数上采用一定的调制以满足雷达的功能需要。典型的信号调制样式包括恒定、抖动、参差、

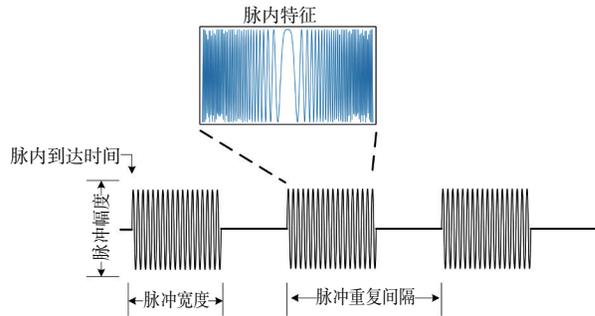
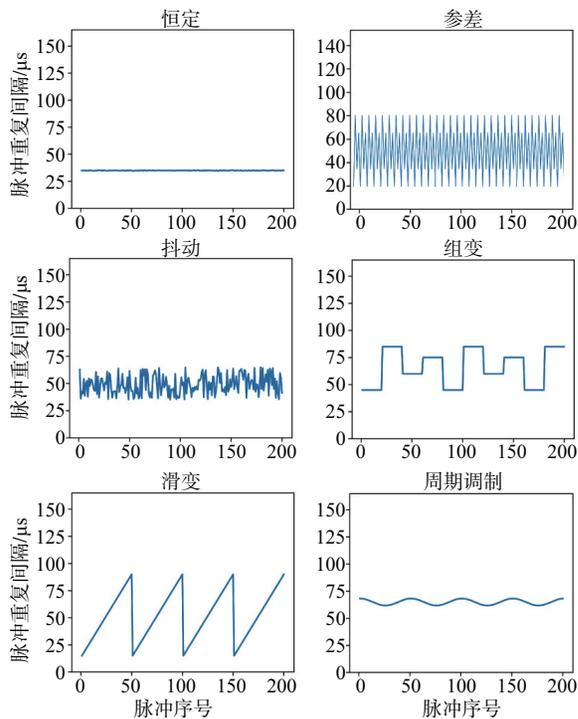


图2 雷达脉冲基本模型

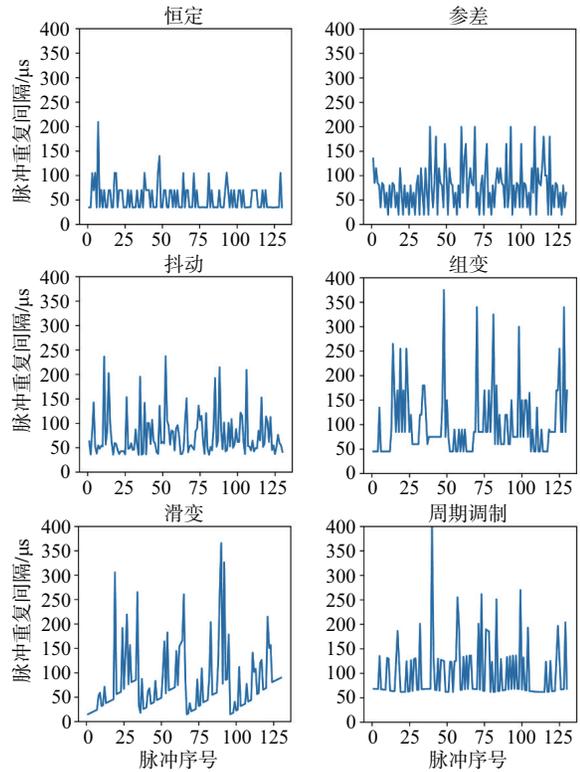
驻留转换、滑变、周期调制等,其中恒定与抖动调制的参数值随时间在一定范围内随机变化,而参差、驻留转换、滑变、周期调制等参数值以特定的形式和规律进行变化。在理想环境下,脉冲调制样式的规律清晰可见,但实际环境中,由于天线的转动以及电子干扰的影响,会产生大量的漏脉冲和杂脉冲,脉冲参数分布的规律将受到极大的干扰,以致常规方法难以识别。图3描述了理想和30%漏脉冲条件下6种脉冲调制样式的参数规律。

1.3 主要的雷达工作模式

为满足雷达的功能需求, MFR 需要从波束资源



(a) 理想环境



(b) 30%漏脉冲条件

图3 不同环境下6种典型调制样式

源调度和波形设计上优化不同模式信号参数。雷达行为可以有限地定义为4个类别:速度搜索、距离搜索、目标跟踪以及边搜索边跟踪^[26]。本文主要以机载相控阵雷达为例,从非合作信号的角度定义不同模式。

1) 速度搜索模式(VS)。VS模式是一种能提供最远探测距离的雷达工作模式,主要通过检测目标速度来发现目标。该模式以固定周期使用高重频恒定调制,能最大化雷达相参处理周期以获得探测距离的提升,且避免了多普勒模糊,此时迎头目标处于低杂波区域中,因而能避免回波模糊产生的副瓣噪声。

2) 距离搜索模式(RWS)。RWS模式是雷达最常用的搜索模式,其特点是能快速探测到多个目标,并提供目标的距离、方位、高度等信息。根据重复频率范围可以分为高重频(HPRF)和中重频(MPRF)两种波形,两种波形互相配合,提供大空域态势的迅速探测。HPRF模式下脉冲参数相对固定,主要利用3段式线性调频解距离模糊,虽然能在一定程度上解决距离模糊

和距离幻影问题,但精度较低。MPRF模式下雷达采用驻留转换或参差的方式解距离模糊,精度上有所提高,但相参处理增益减小,探测距离降低。

3) 单目标跟踪模式(STT)。STT模式是雷达精度最高、能量最为集中的工作模式,可以精确、连续地获得目标的方位、距离、速度等信息,天线波束始终跟随目标变化,成锁定状态,可以引导精确武器进行打击。由于该模式用于确定目标的跟踪,在已知的距离波门和多普勒频率范围内跟踪目标,因而不用考虑模糊问题,具备最为灵活的波形设计方式。为保证稳定跟踪和武器打击,可根据情况采取恒定、滑变、抖动、参差、周期调制等多种调制方式。

4) 搜索加跟踪模式(TAS)。TAS模式是以跟

踪为主的复合工作模式,主要用于对目标空域进行多目标跟踪的同时,保证一定的搜索功能。该模式下雷达利用波束调度的方法,保证跟踪目标的稳定照射,确保跟踪不丢失,具有较高的精度。波形设计上,搜索时与RWS模式类似,跟踪时与STT模式类似,资源划分根据目标数量及调度方法确定。

2 多尺度注意力ResNet

2.1 算法总体框架

为应对雷达脉冲中冗余信息和通道权值不一致给工作模式识别带来的挑战,本文提出了一种基于多尺度自注意力机制的深度残差神经网络,称为MSA-ResNet(Multi-Scale Attention ResNet),所提网络的总体框架如图4所示。

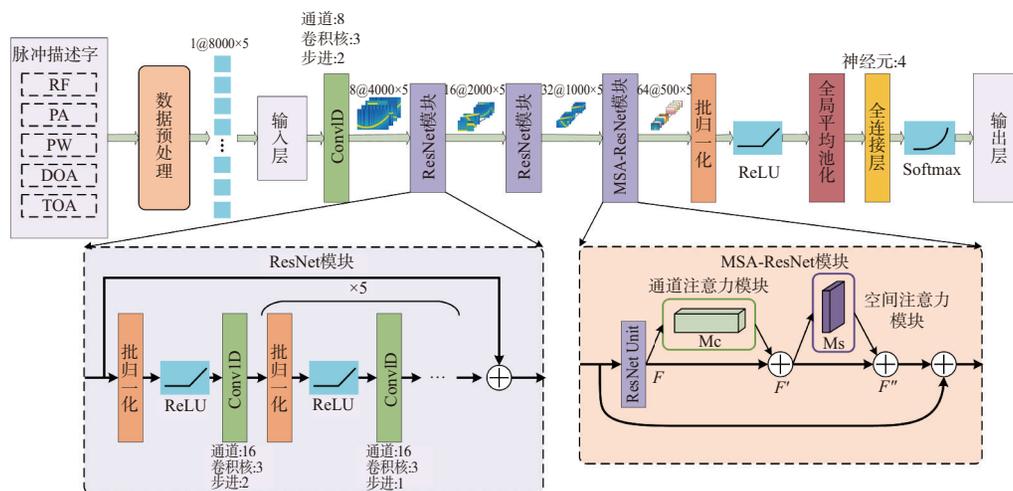


图4 多尺度注意力ResNet-18总体框架

网络主要包括3个模块:1)基础网络ResNet-18。该网络能够有效地从变化多样且高度重叠的参数信息中提取可分离的工作模式特征,实现模式识别。2)通道注意力模块CAM(Channel Attention Module)。该模块对残差模块输出信息进行进一步处理,可以自适应调整不同通道的权值,使网络关注影响力大的通道。3)空间注意力模块SAM(Spatial Attention Module)。该模块关注脉冲序列上不同区域参数的影响力大小并进行自适应的取舍,能够有效筛除无关识别的冗余信息。

2.2 深度残差网络ResNet-18

在所提模型中,我们使用深度残差网络作为

基础网络解决工作模式识别的问题。残差神经网络是兼顾学习能力和效率的神经网络,在计算机视觉和医疗图像识别领域取得了巨大的成功并推广在语义识别、信号识别等多个领域。使用ResNet用于脉冲调制规律识别而未采用RNN类的网络或Transformer等新型网络主要是基于4点考虑:1)在一维的时间序列上,信号的语义关联信息主要集中在临近的局部区域,无需全局的语义信息。因此1D的卷积运算能够最有效地提取信号的变化规律,避免资源的浪费。2)样本中脉冲数量为8 000~16 000个,模型需要具备足够的表达能力,能够提取长样本中互相重叠且缺失严重的脉冲信号规律。3)模型结构应当避免过于庞大和复

杂,需要兼顾性价比。4)既能拥有强大的表示能力,又能有效避免深层网络反向传播时产生的梯度消失和梯度爆炸问题。1D 的 ResNet 很好地满足了上述 4 个要求。

该网络的输入为打平后的 PDW 参数,即将输入样本展开为一维,共 5 个通道,每个通道 8 000 个数据点,此时样本大小为 $[1 \times 8\ 000 \times 5]$,网络通过 1 个 1D 卷积层、3 个残差模块和 1 个全连接层提取特征,3 个残差模块具有相同的架构,每个残差模块中包含 6 个卷积层以及对应的批归一化层和激活函数,模块之间添加残差连接以适应更深层次网络。卷积层的滤波器大小设置为 3×1 ,每个卷积层都搭配 1 个批归一化层和 1 个 ReLU 激活函数用于自适应的调整变化的梯度。在最后 1 个残差模块之后使用了 1 个全局平均池化来提取各通道的重要特征,使用全连接层和 Softmax 激活函数输出 $[4 \times 1]$ 的 One-hot 标签。传统的卷积神经网络通过直接连接的卷积层进行分类,很容易造成模型过拟合,而本文采用全局平均池化提取每个特征图的均值,直接输入全连接层,并采用残差结构建立模块之间快捷连接,在加深网络深度时有效避免

了过拟合问题的发生。表 1 详细介绍了所提网络每一层的输出形状和参数数量。

表 1 模型结构参数集

网络层	输出形状	参数量
输入层	8 000×1	-
Conv1D	4 000×4	16
ResNet Unit1	2 000×16	6 160
ResNet Unit2	1 000×32	24 256
ResNet Unit3	500×64	94 592
批归一化层	500×64	256
全局平均池化层	64	-
全连接层	7	455
总参数量		125 735
可训练参数量		123 935

2.3 通道自注意力模块

虽然基础网络 ResNet-18 已经具备较强的特征提取能力,但对于不同通道信息一概而论,没有取舍和侧重,因此会造成计算资源的浪费以及识别能力的下降。本文引入通道自注意力模块 CAM^[27]来自适应分配通道权值,使网络有倾向性地关注更有价值的通道。CAM 模块结构如图 5 所示。

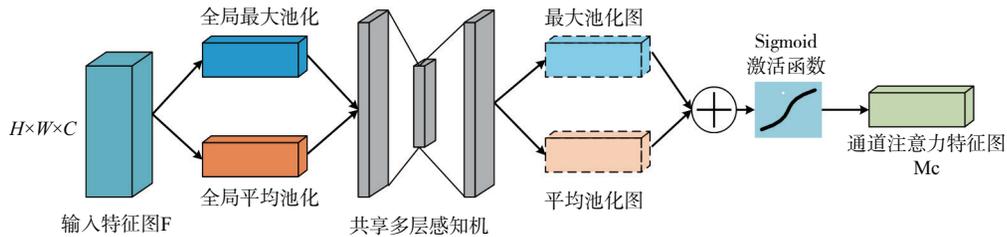


图 5 通道自注意力模块 CAM 结构图

具体分为 3 个步骤:

1) 将输入的特征图 $F (H \times W \times C)$ 并行做基于 $H \times C$ 的全局平均池化和全局最大池化,得到 2 个 $1 \times 1 \times C$ 的特征图, C 表示特征图 F 的通道数量, H 和 W 表示特征图的高和宽。

2) 将得到的特征图输入 1 个共享的双层感知机中,两层感知机中间添加 1 个 ReLU 的激活函数,第 2 层的感知机神经元个数为输出通道的个数。

3) 对多层感知机的输出特征进行基于对应点位相加的 Element-Wise 加和操作,再通过 Sigmoid 函数,生成最终的通道注意力特征图 M_c 。

整个 CAM 模块的表达式可以写为

$$M_c(F) = f(W_0 W_1 (F_{avg}^c + F_{max}^c)) \quad (1)$$

式中, $f(\cdot)$ 表示 Sigmoid 激活函数, W_0 和 W_1 表示 2 层共享感知机的权值向量, F_{avg}^c 和 F_{max}^c 分别表示基于 $H \times W$ 的全局平均池化和全局最大池化。

对上述步骤进行分析,CAM 模块是将特征图的空间维度进行压缩,得到基于通道的一维矢量后再进行操作。而压缩信息时,并行采用最大池化和平均池化的原因在于池化丢失的信息较多,采用并行连接的方式可以保留更多信息,因此 CAM 性能较单纯使用平均池化的 SENet^[28]相比有所提升。从通道注意力图的结构上来说,平均池化对特征图 F 上的每一个区域都有一定的反馈,而

最大池化在进行反向梯度传播时,对特征图响应最大的地方进行反馈。

2.4 空间自注意力模块

考虑雷达脉冲序列内漏脉冲与杂脉冲的影响,本文引入空间自注意力模块 SAM,实现不同区域的自适应权值分配,使网络重点关注更有价值的区域。SAM 模块结构如图 6 所示,主要包括 3 个部分。

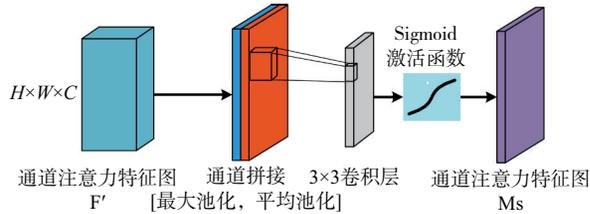


图6 空间自注意力模块SAM结构图

1) 并行采用基于通道 C 的全局平均池化和全局最大池化对输入特征图 $F(H \times W \times C)$ 进行处理,得到 2 个 $H \times W \times 1$ 的特征图。

2) 对 2 个特征图做通道拼接操作,合并成一个 $H \times W \times 2$ 的特征图。

3) 通过 3×1 的卷积操作融合平均池化和最大池化提取的信息,并使特征图重新降维至 1 维,再经过 Sigmoid 激活函数生成最终的通道注意力特征图 M_s 。

SAM 模块的表达式可以写为

$$M_s(F) = f(\text{Conv}^{3 \times 1}[F_{\text{avg}}^s; F_{\text{max}}^s]) \quad (2)$$

式中, $f(\cdot)$ 表示 Sigmoid 激活函数, $\text{Conv}^{3 \times 1}$ 表示 3×1 的 1 维卷积, F_{avg}^s 和 F_{max}^s 分别表示基于通道的全局平均池化和全局最大池化。同样地,空间注意力模块对通道信息进行压缩,保留了对特征图的空间信息的关注。

3 实验结果与分析

本节主要进行实验来测试和比较所提多尺度注意力机制 ResNet 与传统机器学习算法、经典深度神经网络 (AlexNet、LeNet、VGGNet、ResNet、常规深度卷积网络) 的性能。实验在 PyCharm 2022 上运行, CPU 为 Intel (R) Core (TM) i7-9900 k@4.20 GHz, GPU 为 NVIDIA GeForce RTX 2060。

3.1 数据集 RPDWS

由于雷达技术的保密性,目前没有可用的公共数据集,许多文献中采用的雷达数据集仅对雷达参数范围和规律进行罗列,与实际数据贴合不紧密。本文在已有文献^[26,29-31]的基础上,参考《雷达手册》《机载雷达手册》等公开资料,以雷达全脉冲信号为主体,构建了机载多功能雷达工作模式数据集 RPDWS。

RPDWS 主要对雷达工作模式进行描述,包括速度搜索、距离搜索、目标跟踪和搜索加跟踪 4 种,信号样式如表 2 所示,每个信号样本在所给范围内随机生成,而不局限于特定型号。每个工作模式样本从给定范围中随机组合产生,训练集每种模式包括 6 000 个样本,测试集每种模式 2 000 个样本。需要注意的是,测试集完全独立于训练集和验证集产生而非在同一组数据中划分,以模拟训练集与测试集之间的不匹配。

表2 RPDWS数据集

工作模式	波形	PRI/ μs	PW/ μs	占空比	调制样式
脉冲数量=16 000 RF 范围=8 500~10 000 MHz					
通用 PA=PA/PA _{max} 量测误差 $\leq 10\%$ 样本数量=6 000					
VS	高重频	3.3~10	1~3	10%~30%	恒定
RWS	高重频	3.3~10	1~3	10%~30%	恒定
	中重频	50~165	1~20	1%~25%	参差,组变
STT	高重频和中重频	3.3~125	0.1~20	0.1%~25%	恒定,参差,抖动,滑变,周期调制
TAS	高重频和中重频	3.3~165	0.1~20	0.1%~25%	搜索波形参照 RWS 跟踪波形参照 STT

3.2 基础网络 ResNet-18 的工作性能

本小节利用基础深度学习网络 ResNet-18 在数据集 RPDWS 的基础上与传统机器学习分类器 (线性核的支持向量机 Linear SVM、高斯核支持向量机 RBF SVM、决策树 Decision Tree、随机森林 Random Forest、多层感知神经网络 Neural Net、朴素贝叶斯 Naïve Bayes) 进行比较,以验证深度学习网络在识别任务上的优越性,实验结果如图 7 所示,黑色虚线为无效识别线。

从图 7 不难看出,在 0~50% 漏脉冲条件下,传统分类器的平均识别率基本在 80% 以下,且在某

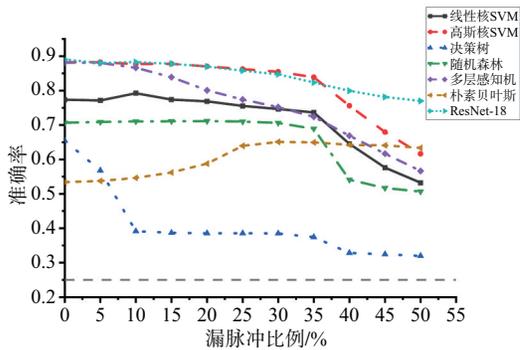


图7 基础网络 ResNet 与传统分类器性能
个临界值附近识别率会出现相对剧烈的恶化。相比而言,基础网络 ResNet-18 识别曲线相对平缓,且整体识别率优于传统分类器。

究其原因,这是因为对于雷达的不同工作模式,其工作频段和脉冲到达方位相对固定,幅度信息随机,而影响性能的关键参数,如脉冲重复间隔、脉宽等,在数据分布上又重叠交织,这对关注

数据分布的分类器来说无疑增加了识别的难度。简单结构的分类器已经无法满足雷达脉冲序列规律提取的需要。

3.3 多尺度注意力 MSA-ResNet 工作性能

本文在 PDWS 数据集下,采用 AlexNet、LeNet、VGGNet、ResNet、常规深度卷积网络等经典深度学习网络作为对比模型进行实验。

首先,我们在训练视图下对各网络模型的收敛性能进行分析。网络使用了 Adam 优化器,学习率以 40 个轮次为间隔自 10^{-2} 减少至 10^{-4} ,Batch 的大小设置为 128,网络采用 L2 正则化,正则化系数为 10^{-4} ,每次训练共 160 轮。

每种深度学习网络训练 10 次以确保实验的有效性,训练结果如图 8 所示,阴影填充部分表示 10 次训练中收敛模型结果的标准差。

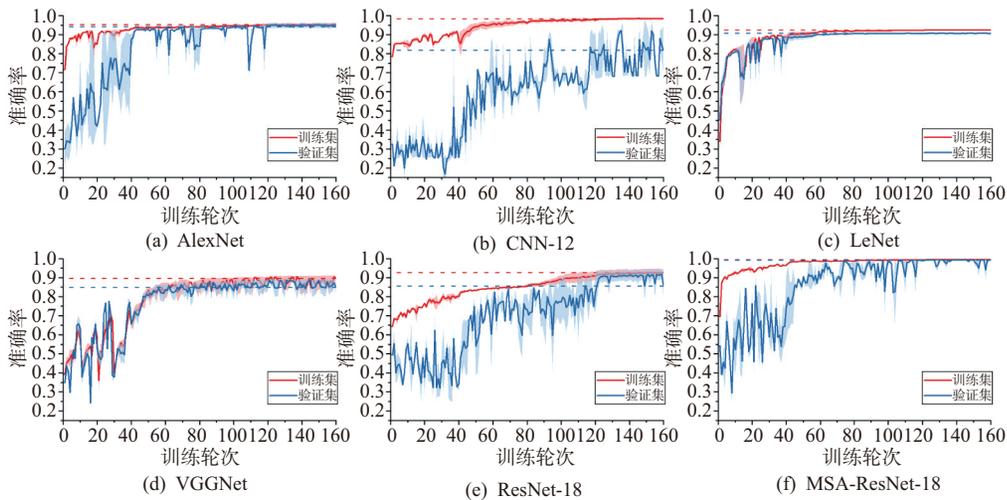


图8 MSA-ResNet-18 与经典深度学习网络训练曲线

从 6 种网络训练集和验证集的曲线对比看,常规卷积神经网络 CNN 出现相对严重的过拟合,测试集与训练集平均精度相差约 20%,VGGNet 也一定程度存在该问题,而其他 4 种网络训练集与验证集精度基本保持一致。

从训练曲线标准差来看,AlexNet 和 ResNet-18 的波动更大,这也意味着模型的稳定性不够,需要反复多次的训练才能找到最优结构。

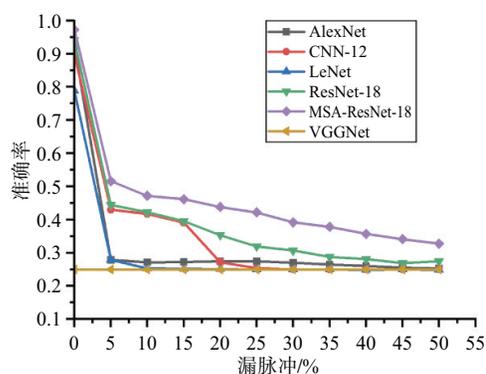
从训练阶段的识别准确率上看,如表 3 所示,6 种模型几乎都保证了 90% 以上的准确率,加入多尺度注意力机制的 ResNet-18 相比于基础网络平

均识别率提升了约 14%,达到 98.5%,且完全收敛,最佳识别率提升约 4%,识别能力在 6 种网络中最优,初步证明多尺度注意力机制在模式识别中的有效性。

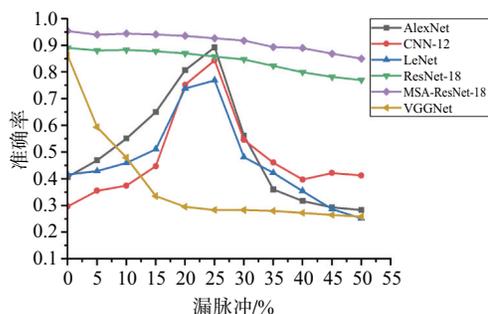
表 3 深度学习网络验证集最优识别准确率

模型	准确率
AlexNet	96.2%
CNN	94.5%
LeNet	94.3%
VGGNet	89.1%
ResNet	95.3%
MSA-ResNet	99.1%

下一步,在测试视图下对各网络的泛化能力进行分析。为了进一步验证复杂环境下网络的识别能力,我们分别选择上述6种网络的最优模型进行测试。测试集独立于训练集产生,间隔5%设置0~50%的丢失脉冲以验证模型的泛化能力。考虑到完美环境下模型无法学习到漏脉冲雷达序列的特征,我们设置2种实验环境进行对比,一种在标准数据下进行训练,另一种采用一定的数据增强措施,在脉冲序列中梯次添加10%~30%丢失脉冲,实验结果如图9所示。



(a) 在标准环境下训练



(b) 在增强数据集下训练

图9 MSA-ResNet-18与经典深度学习网络测试准确率

从2种训练环境的测试精度可以看出,在标准环境下训练时,各个模型仅在同样0%漏脉冲的环境中识别效果达到预期,在漏脉冲比例上升时,各网络识别能力急剧恶化,几乎无法完成模式识别的任务。这也说明此时模型未能学习到漏脉冲条件下的雷达序列规律。而在增强数据集下训练时,模型识别能力有了显著的提升,在一定漏脉冲条件下能保持一定的识别能力。

从图9(b)中识别曲线的变化情况来看,VGGNet识别率随漏脉冲变化迅速下降,无法适应模式识别任务。而AlexNet、CNN-12、LeNet振荡明显,

出现一个明显的峰值,3种网络模型虽然具备一定的识别能力,但是仅在漏脉冲比例为20%左右,即处于类似于训练集的环境下,才具备较高的识别率。这也意味着这3种模型未能提取漏脉冲雷达序列的深层规律,泛化能力较弱。而对比来看,本文所提MSA-ResNet-18及其基础网络ResNet-18则在整个区间内变化平缓,且在两种训练环境中识别能力均优于其他网络,这表示这两种网络学习到了雷达序列变化的深层规律,在不同环境下的泛化能力强。相较于MSA-ResNet和ResNet,同样属于深层网络的VGGNet仅达到浅层网络的识别性能,甚至还有一定程度的衰减。

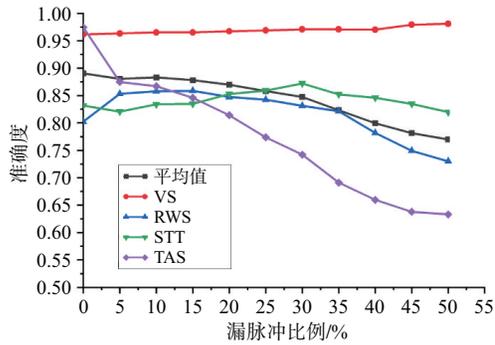
究其原因,卷积网络结构中的残差连接起到了关键的作用,它使得网络在学习的过程中更好地避免了梯度问题带来模型性能的波动,使得深层网络结构的梯度传导更加顺畅,因此更好地发挥了深层网络表达能力强的优势。而多尺度注意力机制使得MSA-ResNet相比于ResNet有了更进一步的提升。

3.4 MSA-ResNet 识别能力扩展分析

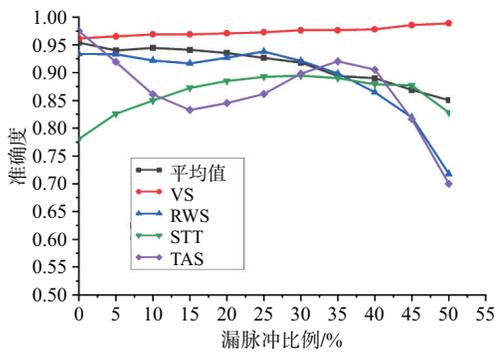
通道注意力机制和空间注意力机制通过自适应的权值分配使模型能够更有效地关注最重要的通道和区域。本节重点针对MSA-ResNet和ResNet在各个模式的识别能力进行分析。下面分别从精确度和准确率对识别能力进行分析。

精确度(Precision)是指对于被分类模型标记为某种类型的结果中,结果为真的比例,可以有效衡量信号被识别为某种工作模式时的可信度。准确率(Accuracy)是指正确分类的样本与总样本数的比例,可以从整体范围更加清晰地反应模型的识别能力。

MSA-ResNet和ResNet的识别精确度如图10所示。从两种网络的对比来看,加入多尺度注意力机制之后的ResNet整体的识别精确度有了一定的提高。而从不同工作模式的识别精确度看,VS模式的识别精确度变化不大,而其他3种相对复杂的工作模式都有了一定程度的提升,尤其是时分复合的TAS工作模式。这是因为VS模式雷达脉冲的变化规律相对简单,模型可以有效找到不同漏脉冲比例带来的规律变化,因此整体下降幅度较



(a) ResNet-18



(b) MSA-ResNet-18

图 10 工作模式的识别精确度

小。而其他 3 种工作模式都采用较为复杂的脉冲调制方法,冗余信息和环境干扰带来的变化更加难以捕捉,因此更容易产生错误识别。此时注意力机制带来的有目的性的权值分配产生了更大的效益。

MSA-ResNet 在漏脉冲分别为 10%、20%、50% 环境下识别的混淆矩阵如图 11 所示。可以看出,虽然模式识别精度随着漏脉冲增加有所下降,但并不意味着所有模式都受到影响,例如 VS 和 STT 模式几乎不受影响,而 RWS 和 TAS 模式混淆严重,性能下降明显,RWS 模式几乎无法做到有效识别。这是因为 RWS 模式下雷达工作参数以“分段式”为主,40% 以上的漏脉冲使得参数变化突破了由单一波形到复合波形的“临界值”,而 RWS 模式本身就是 TAS 时分复合模式中的一种,且其 HPRF 波形与 VS 模式参数范围重叠,一部分数据分布非常相似,所以在自身结构被破坏时,无法有效提取与 RWS 模式对应的特征,产生大量错误分类。这也说明如果对于复杂环境下的复杂调制样式,基于自注意力的网络模型性能依然是有限的,我们将在未来的研究中继续探索解决方案。

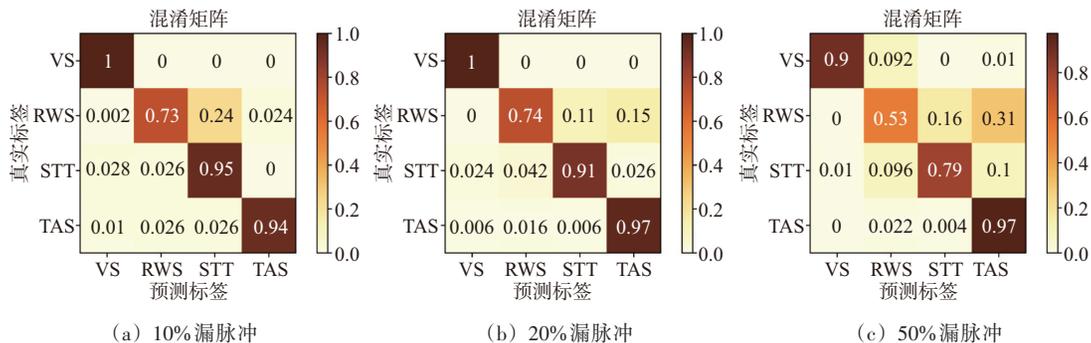


图 11 MSA-ResNet-18 不同环境下混淆矩阵

4 结束语

本文为雷达工作模式识别设计了一种基于多尺度注意力机制的深度学习网络,称为 MSA-ResNet。其优点在于利用通道注意力和空间注意力机制对残差连接的卷积神经网络进行了改进。在复杂漏脉冲环境下,使网络能更有效地关注更有价值的信息。在所给数据集实验下,所提网络的稳定性和泛化性也得到了定量验证。在 0~50% 漏脉冲条件下,平均识别率提升了 36%,在独立测

试集 40% 漏脉冲比例下模型仍然具备 90% 以上的识别率。尽管在更恶劣环境中模型对 RWS 模式的识别性能恶化,但通常情况下所提模型仍适用于识别非特定型号的雷达工作模式。未来可行的工作可以尝试无监督条件下的工作模式识别,这可能更加贴近真实条件。

参考文献:

[1] DE MARTINO A. Introduction to Modern EW Systems [M]. 2nd. Boston, MA: Artech House, 2018.

- [2] WEBER M E, CHO J Y N, THOMAS H G. Command and Control for Multifunction Phased Array Radar [J]. IEEE Trans on Geoscience and Remote Sensing, 2017, 55(10): 5899-5912.
- [3] REVILLON G, MOHAMMAD-DJAFARI A, ENDERLI C. Radar Emitters Classification and Clustering with a Scale Mixture of Normal Distributions [J]. IET Radar, Sonar & Navigation, 2019, 13(1):128-138.
- [4] ZHANG Zhongshan, LONG Keping. Self-Organization Paradigms and Optimization Approaches for Cognitive Radio Technologies: a Survey [J]. IEEE Wireless Communications, 2013, 20(2):36-42.
- [5] MARDIA H K. New Techniques for the Deinterleaving of Repetitive Sequences [J]. IEE Proceedings F-Radar and Signal Processing, 1989, 136(4):149-154.
- [6] NISHIGUCHI K, KOBAYASHI M. Improved Algorithm for Estimating Pulse Repetition Intervals [J]. IEEE Trans on Aerospace and Electronic Systems, 2000, 36(2):407-421.
- [7] ZHOU Yun, YU Xuelian, CUI Minglei, et al. Radar Target Recognition Based on Multiple Features Fusion with Dempster-Shafer Theory [C]// IEEE 2011 10th International Conference on Electronic Measurement & Instruments, Chengdu, China: IEEE, 2011:262-266.
- [8] HAN Lubing, GAO Feifei, LI Zan, et al. Low Complexity Automatic Modulation Classification Based on Order-Statistics [J]. IEEE Trans on Wireless Communications, 2017, 16(1):400-411.
- [9] LUNDEN J, KOIVUNEN V. Automatic Radar Waveform Recognition [J]. IEEE Journal of Selected Topics in Signal Processing, 2007, 1(1):124-136.
- [10] ORLIC V D, DUKIC M L. Multipath Channel Estimation Algorithm for Automatic Modulation Classification Using Sixth-Order Cumulants [J]. Electronics Letters, 2010, 46(19):1348-1349.
- [11] LIU Shaokun, YAN Xiaopeng, LI Ping, et al. Radar Emitter Recognition Based on SIFT Position and Scale Features [J]. IEEE Transactions on Circuits and Systems II: Express Briefs, 2018, 65(12):2062-2066.
- [12] ZHANG Ming, LIU Lutao, DIAO Ming. LPI Radar Waveform Recognition Based on Time-Frequency Distribution [J]. Sensors, 2016, 16(10):1682.
- [13] 马珂, 毕大平. 机载火控雷达空空工作状态识别研究 [J]. 雷达科学与技术, 2021, 19(6):697-703.
- [14] 田西兰, 李川, 王凤. 智能化军用雷达目标识别关键问题探讨 [J]. 雷达科学与技术, 2021, 19(5):534-538.
- [15] LI Dongmei, GU Lei, ZHU Lanxiang. Identification and Parameter Estimation Algorithm of Radar Signal Subtle Features [J]. Physical Communication, 2020, 42:101140.
- [16] WU Zhilu, YANG Zhutian, SUN Hongjian, et al. Hybrid Radar Emitter Recognition Based on Rough k-Means Classifier and SVM [J]. EURASIP Journal on Advances in Signal Processing, 2012(1):198.
- [17] LI Xueqiong, HUANG Zhitao, WANG Fenghua, et al. Toward Convolutional Neural Networks on Pulse Repetition Interval Modulation Recognition [J]. IEEE Communications Letters, 2018, 22(11):2286-2289.
- [18] LI Xueqiong, LIU Zhangmeng, HUANG Zhitao. Denoising of Radar Pulse Streams with Autoencoders [J]. IEEE Communications Letters, 2020, 24(4):797-801.
- [19] LIU Lutao, LI Xinyu. Radar Signal Recognition Based on Triplet Convolutional Neural Network [J]. EURASIP Journal on Advances in Signal Processing, 2021(1):1-16.
- [20] HAN J W, PARK C H. A Unified Method for Deinterleaving and PRI Modulation Recognition of Radar Pulses Based on Deep Neural Networks [J]. IEEE Access, 2021, 9:89360-89375.
- [21] LI Xueqiong, LIU Zhangmeng, HUANG Zhitao. Attention-Based Radar PRI Modulation Recognition with Recurrent Neural Networks [J]. IEEE Access, 2020, 8:57426-57436.
- [22] 乔洁, 岳晓军. 基于改进残差网络的雷达辐射源多标签识别 [J]. 现代雷达, 2022, 44(1):39-44.
- [23] 普运伟, 刘涛涛, 吴海潇. 基于卷积双向长短时记忆网络的雷达辐射源信号识别 [J]. 激光与光电子学进展, 2022, 59(22):361-368.
- [24] 陈禾, 张心怡, 李灿. 基于多尺度注意力CNN的SAR遥感目标识别 [J]. 雷达科学与技术, 2021, 19(5):517-525.
- [25] JIANG Q. Network Radar Countermeasure Systems: Integrating Radar and Radar Countermeasures [M]. Berlin, Germany: Springer, 2016.
- [26] SKOLNIK M I. Radar Handbook [M]. 3rd. New York: McGraw-Hill, 2008.