

# 基于改进 UNet3+网络的雷达辐射源信号识别

李霜<sup>1</sup>, 董玮<sup>1</sup>, 董会旭<sup>2</sup>, 凌云飞<sup>2</sup>, 张歆东<sup>1</sup>

(1. 吉林大学电子科学与工程学院, 长春, 130012; 2. 空军航空大学航空作战勤务学院, 长春, 130022)

**摘要** 针对传统识别辐射源信号的方法需要手动提取并选取特征、在低信噪比条件下难以准确识别信号的问题, 提出了一种基于改进 UNet3+网络的辐射源信号识别方法。通过删减 UNet3+的网络层级, 保留网络特征融合能力的同时降低了网络的复杂度, 并引入注意力机制优化模型性能, 构建了一个新的网络模型。通过对8种常见的雷达信号进行仿真实验, 实验结果表明: 改进模型的识别准确率达到96.63%, 对比一些经典网络模型, 训练总用时更短, 在低信噪比条件下能更加有效识别辐射源信号, 可以适应复杂的电磁环境。

**关键词** 雷达信号; 深度学习; UNet3+; 注意力机制; 低信噪比

**DOI** 10.3969/j.issn.1009-3516.2022.02.009

**中图分类号** TN971.1 **文献标志码** A **文章编号** 1009-3516(2022)02-0055-06

## A Radar Emitter Signal Recognition Based on Improved UNet3+ Network

LI Shuang<sup>1</sup>, DONG Wei<sup>1</sup>, DONG Huixu<sup>2</sup>, LING Yunfei<sup>2</sup>, ZHANG Xindong<sup>1</sup>

(1. College of Electronic Science and Engineering, Jilin University, Changchun 130012, China; 2. School of Aviation Operations and Services, Aviation University of Air Force, Changchun 130022, China)

**Abstract** Aimed at the problems that traditional emitter signal identification methods often need to carry out artificial feature extraction and signals are difficult to be identified accurately under condition of low SNR environments, a method of emitter signal recognition based on improved UNet3+ network is proposed. By trimming the UNet3+ network hierarchy, the feature fusion ability is retained while the complexity of the network is reduced. The attention mechanism is introduced to optimize the model performance, and a new network model is constructed. The simulation results of eight common radar signals show that the recognition accuracy of the improved model reaches 96.63%. Compared with some classical network models, the total training time is shorter, and the ability to identify the radiation source signal is more effectively under condition of low SNR environments. And the proposed model can also be adapted to the complex electromagnetic environments.

**Key words** radar signal; deep learning; UNet3+; attention mechanism; low signal-to-noise ratio

辐射源信号识别是电子对抗侦察的关键部分<sup>[1-2]</sup>, 识别敌方雷达信号, 获取战场信息, 为战役指挥决策提供了关键的判断依据。早期战场电磁环境相对简单, 人工提取特征后通过与雷达数据库比对,

**收稿日期:** 2021-06-02

**作者简介:** 李霜(1994—), 男, 吉林大安人, 硕士生, 研究方向为电子侦察情报的分析与处理。E-mail: 2918706809@qq.com

**引用格式:** 李霜, 董玮, 董会旭, 等. 基于改进 UNet3+网络的雷达辐射源信号识别[J]. 空军工程大学学报(自然科学版), 2022, 23(2): 55-60. LI Shuang, DONG Wei, DONG Huixu, et al. A Radar Emitter Signal Recognition Based on Improved UNet3+ Network[J]. Journal of Air Force Engineering University (Natural Science Edition), 2022, 23(2): 55-60.

能够较为准确地识别雷达信号。文献[3]提出了一种融合先验信息的辐射源信号识别方法;文献[4]提出了基于小波网络对不同脉冲重复间隔模式的辐射源信号识别方法。这些方法在并不复杂的电磁环境下具有较好的识别能力,但是在电磁环境日益复杂的背景下,这类方法的识别速度和识别精度不能满足识别要求。如何在复杂的电磁环境<sup>[5-7]</sup>中准确地识别信号成为亟待解决的问题。

深度学习(deep learning, DL)作为机器学习中的分支,近年来广泛应用在计算机视觉<sup>[8]</sup>、智能控制<sup>[9]</sup>、自然语言处理<sup>[10-11]</sup>等领域,在辐射源信号识别中也具有优异的性能。文献[12]对雷达信号的伪WVD和CWD时频图像提取特征,并用多层感知机、径向基函数神经网络、概率神经网络3种分类器对信号进行识别,但是在低信噪比条件下,部分信号的识别精度较低;文献[13]利用 AlexNet 网络模型对信号的时频图进行分类识别,将信号转化为二维图像进行识别,提高了识别精度,但大幅度增加了计算量,耗时较长,样本量较大时并不适用。

为解决上述问题,本文引入 UNet3+<sup>[14]</sup>网络对辐射源信号进行识别。UNet3+网络能处理序列数据,相较于处理时频图像的方法,计算量较小,可以适应样本量较大的情况。UNet3+网络能自主进行信号特征提取,无需人为选择特征,相较于人工提取特征的方法,能较为全面地提取特征,适应多数类型信号的识别。该网络通过全尺度跳过连接将数据的深层特征和浅层特征进行融合<sup>[15-17]</sup>,充分提取了数据特征,进而拥有较高的识别准确率。本文在 UNet3+的基础上,将5层级的 UNet3+网络删减为3层级,保留其特征融合能力的同时降低了网络的复杂度,并引入注意力机制,优化了模型性能,在低信噪比的条件下也拥有较好的识别能力。

## 1 UNet3+网络

UNet3+网络是基于 UNet<sup>[18-20]</sup>网络设计的一种新的网络结构,UNet 的整体结构是先编码,再解码,通过多尺度的方式提取信息进行识别,但是编码器提取的特征并没有被解码器充分使用,可能会丢失部分关键信息。UNet3+网络的结构如图1所示,它是一种基于U形的体系结构,拥有5个层级,通过全尺度跳过连接的方式进行特征融合,例如节点  $X_{Dc}^2$ (第2层级的解码层),将其更浅(包括同一层级的)编码器和比其更深的解码器的数据堆叠成新的特征,解码层对接收的特征进行融合和提取,充分利用了多尺度特征。

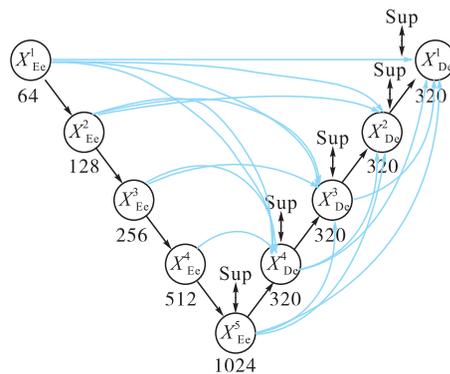


图1 UNet3+网络的结构图

## 2 注意力机制

注意力机制<sup>[21-24]</sup>是从人类视觉的注意力机制得到启发:人类在观察事物时,先全面观察,再经过大脑处理,挑选出需要重点关注的位置仔细观察,得到关键信息。

特征提取是信号识别的关键。注意力机制能筛选出重要信息,其具体表现形式为会根据信息的重要程度分配不同的概率权重,网络会更加注重权重系数较大的信息,忽略一些无需关注的信息,突出关键信息的影响,增强模型判断的准确性,提升识别速度。

注意力机制的具体实现流程如图2所示。

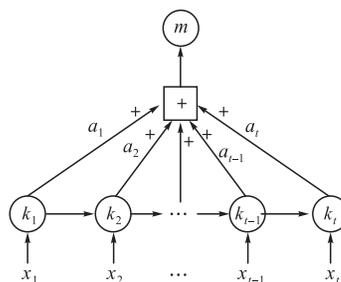


图2 注意力机制实现流程

如图2所示,  $[x_1, x_2, \dots, x_{i-1}, x_i]$ 表示输入的辐射源信号信息,计算注意力主要分为以下3步:

**步骤1** 计算权重:

$$e_i = u \tanh(\omega k_i + b) \quad (1)$$

式中: $b$ 是偏置系数; $u$ 和 $\omega$ 是权重系数。

**步骤2** 对上一步得到的权重  $e_i$  归一化,得到的  $a_i$  为注意力机制对神经网络隐藏层输出的注意力概率权重:

$$a_i = \frac{\exp(e_i)}{\sum_{j=1}^i \exp(e_j)} \quad (2)$$

**步骤3** 将注意力概率权重和辐射源信号中各元素进行加权求和得到注意力辐射源信号:

$$m_i = \sum_{t=1}^i a_t k_t \quad (3)$$



本总数为 76 800,所有样本随机打乱进行训练。信号的具体参数见表 1。计算机配置见表 2。

表 1 8 种信号的主要参数

8 种信号	信号参数	参数取值
BPSK	采样频率/kHz	7
	巴克码位数	{7,11,13}
Costas	采样频率/kHz	{15,17}
	频率/kHz	{[4 716 523],[2 638 751]}
FMCW	采样频率/kHz	7
	调制带宽/kHz	{0.25,0.35,0.5}
	调制周期/ms	{50,25,35}
多相码	采样频率/kHz	7
	码位数	{36,64}

表 2 计算机配置

计算机硬件	型号
CPU	Intel(R) i5 9400F
GPU	NVIDIA GeForce GTX 1650super

#### 4.1 实验 1

为了探究删减网络层级对网络的影响,对 5 层级的 UNet3+模型和 3 层级的 UNet3+模型做对比试验,其他参数保持不变,评价标准为测试集的准确率,训练集的训练时间。实验结果见表 3。

表 3 删减网络层级对网络的影响

神经网络	准确率/%	训练时间/s
3 层级 UNet3+	95.77	890
5 层级 UNet3+	95.34	1 412

由表 3 可知,3 层级 UNet3+的训练时间比 5 层级 UNet3+的训练时间少 522 s,准确率没有太大改变,说明删减后的 3 层级 UNet3+网络在不降低网络识别准确率的同时提升了识别速度,减低了网络模型的复杂度,提升了模型的泛化能力。

#### 4.2 实验 2

为了探究全尺度跳过连接的特征融合对网络识别能力的影响,以是否进行全尺度跳过连接的特征融合作为自变量,分别训练无特征融合的 UNet3+模型和有特征融合的 UNet3+模型做对比试验(二者都是 5 层级的网络模型),其他参数保持不变,评价标准为测试集的准确率和损失、训练集的训练时间。实验结果如表 4 所示。

表 4 特征融合对网络识别能力的影响

特征融合	准确率/%	损失	训练时间/s
有	95.77	0.129 8	890
无	93.60	0.182 6	401

由表 4 可知,进行特征融合的 UNet3+模型训练时间较长,因为特征融合后需要处理的数据变多,导致训练时间变长;在准确率、损失上效果更好,说明 UNet3+模型通过特征融合保留了更多的细节

信息,充分利用了原始数据集,可以通过更多的特征进行识别,进而提高识别能力。

#### 4.3 实验 3

为了探究引入注意力机制带来的影响,将是否引入注意力机制作为自变量进行对比试验,评价标准为测试集的准确率、训练集的训练轮数和训练时间,实验结果如表 5 所示。

表 5 注意力机制实验结果

注意力机制	准确率/%	训练轮数	时间/s
有	96.63	12	390
无	95.77	29	907

由表 5 可知,有注意力机制的 UNet3+网络训练时间更短、训练轮数更少,网络的识别能力约提高了 0.9%,可以看出注意力机制小幅度提升了识别准确率,大幅度提高了识别速度,这是因为注意力机制对需要关注的特征分配了更多的注意力资源,忽略一些无需关注的特征,进而提高网络对辐射源信号的识别能力。

为进一步探究注意力机制提升网络识别准确率和训练速度的原因,实验将注意力层的概率权重数值画出图像,实验分为以下 3 步:

**步骤 1** 随机从 P3 信号中抽取一个长度为 1024 的数据,直接输入到训练好的有注意力机制的 UNet3+模型中。

**步骤 2** 通过 get\_layer 函数获得注意力层的概率权重。因为网络模型结构的原因,获得的数据长度为 $(1 \times 1\ 536 \times 8)$ 。

**步骤 3** 将步骤 2 中获得的三维张量展平,长度为 $(1 \times 12\ 288)$ 画出图像,注意力层概率权重如图 4 所示。

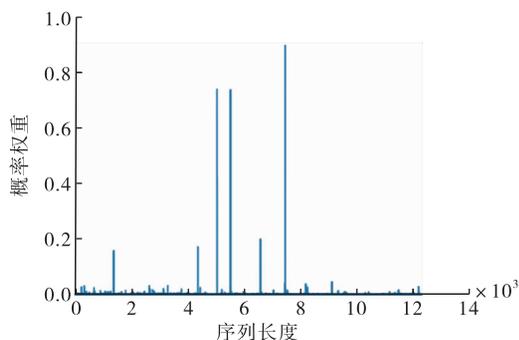


图 4 注意力层的概率权重

概率权重是由辐射源信号和辐射源信号中各元素权值的相似度计算得出的,从图 4 可以清楚地看出得到的是一组长短明显的针状图,说明有的辐射源信号元素分配了较小的概率权重,即注意力机制抑制了不重要特征,有的辐射源信号元素分配了较大的概率权重,说明注意力机制保留了关键信息,最终突出了关键信息的影响,进而提升网络的识别能力。

### 4.4 实验 4

实验 4 分为 3 个小实验进一步探究模型的识别能力。

1)小实验 1:为了探究本文模型对比常见深度学习模型的优势。用本文模型与 CLDNN<sup>[26]</sup>模型、GRU<sup>[27]</sup>模型、VGG16<sup>[28]</sup>、AlexNet<sup>[29]</sup> 4 种常用的经典网络模型以及未改进 UNet3+模型进行对比试验。在不同信噪比下的识别准确率如图 5 所示。

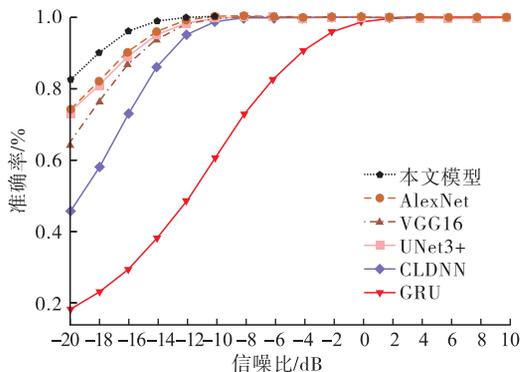


图 5 不同深度学习模型在不同信噪比下的识别准确率

从图 5 中可以看出,本文模型曲线全程在最上方,说明本文模型的识别精度最高,尤其是在信噪比最低的一 20 dB 的条件下,本文模型的准确率高于 80%,远高于大部分经典模型。

2)小实验 2:为了探究本文模型在复杂电磁环境下的识别能力,使用训练完成的模型对不同信噪比下的 8 类信号的测试集进行识别,实验结果如图 6 所示。

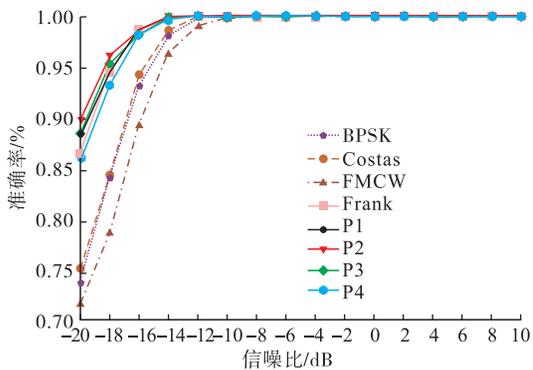


图 6 8 类信号识别准确率

由图 6 中可以看出,在噪声较严重的一 16 dB 的信噪比条件下,8 类信号的识别准确率皆能达到 90%,在噪声最严重的一 20 dB 信噪比条件下,8 类信号均有高于 70%的识别准确率,其中 FMCW 信号识别准确率最低为 72%,说明在低信噪比环境下 FMCW 信号最难识别。综上所述,本文模型是基本能够满足低信噪比条件下识别要求的。

3)小实验 3:图 7 为 8 类信号的混淆矩阵。图中深蓝色对角线为正确识别出 8 类信号的概率,对角线外的区域是错误分类识别信号的概率。由图 7

可知,8 类信号的识别准确率均能达到 94%以上,其中 Costas 与 BPSK、Costas 与 FMCW、FMCW 与 BPSK 错误率比较高,说明分类识别他们的能力较低。其他错误区域错误率全部低于 1%,说明本文网络识别能力较好,基本能够满足辐射源信号的识别要求。

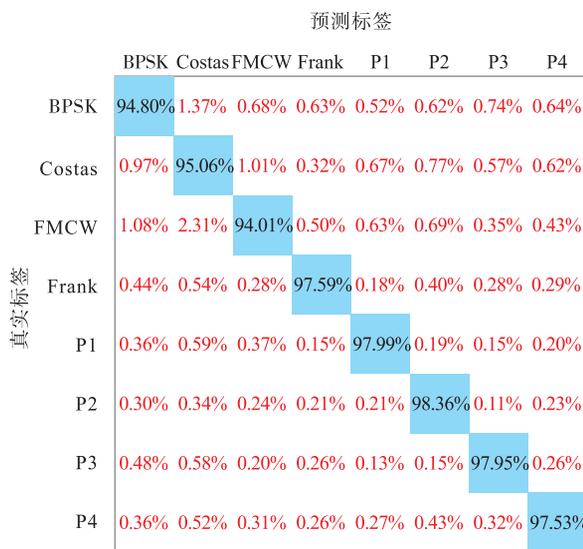


图 7 8 类信号混淆矩阵

## 5 结语

本文在 UNet3+模型的基础上进行改进,在减少网络层级的同时,保留了 UNet3+网络的特征融合能力,并引入了注意力机制,进一步优化了模型性能。实验表明,本文提出的网络能够较为准确地识别 8 种辐射源信号,尤其是在信噪比较低时,相较于经典网络模型,能够更加准确地识别信号。综上所述,本文提出的模型在低信噪比条件下能较好地识别雷达信号,更加适应战场上复杂的电磁环境。

### 参考文献

- [1] WANG S Q, BAI J, HUANG X Y, et al. Analysis of Radar Emitter Signal Sorting and Recognition Model Structure[J]. Procedia Computer Science, 2019, 154: 500-503.
- [2] 曾文龙,张萌,周江. 复杂电磁环境对电子对抗侦察的影响及时策[J]. 国防科技, 2008(4): 54-57.
- [3] 盖明久,关欣,衣晓,等. 基于条件证据理论的雷达辐射源识别方法[J]. 西安电子科技大学学报, 2006, 33(5): 833-837.
- [4] 陶荣辉,李合生,韩宇,等. 基于直方图和小波网络的雷达信号识别方法[J]. 电波科学学报, 2005, 20(6): 784-788.
- [5] FU W, HU Z, LI D. A Sorting Algorithm for Multiple Frequency-Hopping Signals in Complex Electro-

- magnetic Environments [J]. *Circuits, Systems, and Signal Processing*, 2020, 39(1): 245-267.
- [6] ZHANG C, HAN Y, ZHANG P, et al. Research on Modern Radar Emitter Modelling Technique under Complex Electromagnetic Environment[J]. *The Journal of Engineering*, 2019, 2019(20): 7134-7138
- [7] WANG Y, ZHANG S, ZHANG Y, et al. A Cooperative Spectrum Sensing Method Based on Empirical Mode Decomposition and Information Geometry in Complex Electromagnetic Environment[J]. *Complexity*, 2019(7):1-13.
- [8] BLACK K M, LAW H, ALDOUKHI A H, et al. Deep Learning Computer Vision Algorithm for Detecting Kidney Stone Composition: Towards an Automated Future[J]. *European Urology Supplements*, 2019, 18(1):853-854.
- [9] HONG W, PENG Y. Delay Control System of Intelligent Traffic Scheduling Based on Deep Learning and Fuzzy Control[J]. *Journal of Intelligent & Fuzzy Systems*, 2020,38(12): 1-11.
- [10] BUKHARI D, WANG Y T, WANG H. Multilingual Convolutional, Long Short Term Memory, Deep Neural Networks for Low Resource Speech Recognition [J]. *Procedia Computer Science*, 2017, 107: 842-847
- [11] VISHAL P, RAJESH K A. Convolutional Support Vector Machines for Speech Recognition[J]. *International Journal of Speech Technology*,2019, 22(3):601-609.
- [12] GULUM T O. Autonomous Non-linear Classification of LPI Radar Signal Modulations[J]. *Monterey California Naval Postgraduate School*, 2007, 6 ( 3 ): 337-351.
- [13] 郭立民,陈鑫,陈涛. 基于 AlexNet 模型的雷达信号调制类型识别[J]. *吉林大学学报(工学版)*, 2019, 49(3): 1000-1008.
- [14] HUANG H, LIN L, TONG R, et al. UNet 3+: A Full-Scale Connected UNet for Medical Image Segmentation [C]//2020 IEEE International Conference on Acoustics, Speech and Signal Processing. [S. l.]: IEEE,2020:1055-1059
- [15] ZHOU Y, ZHANG Y, YANG D, et al. Pipeline Signal Feature Extraction with Improved VMD and Multi-Feature Fusion[J]. *Systems Science & Control Engineering an Open Access Journal*, 2020, 8(1):318-327.
- [16] VIMINA E R, JACOB K P. Feature Fusion Method Using BoVW Framework for Enhancing Image Retrieval [J]. *IET Image Processing*,2019,13(11):1979-1985.
- [17] HOU S, SUN Q. An Orthogonal Regularized CCA Learning Algorithm for Feature Fusion[J]. *Journal of Visual Communication and Image Representation*, 2014, 25(5):785-792.
- [18] 张钢强,李俊峰. 基于改进 UNet 网络的船舶水尺读数识别方法研究 [J]. *光电子·激光*, 2020, 31(11): 1182-1196.
- [19] EMEK R A, DEMIR N. Building Detection from SAR Images Using Unet Deep Learning Method[J]. *The International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2020, 44: 215-218.
- [20] ZHANG J, MO J, XU H, et al. A Semantic Segmentation Method for Exposed Rebar on Dam Concrete Based on Unet[J]. *Journal of Physics: Conference Series*, 2020, 1651(1): 012169.
- [21] XU H F, CHAI L, LUO Z M, et al. Stock Movement Predictive Network via Incorporative Attention Mechanisms Based on Tweet and Historical Prices[J]. *Neurocomputing*, 2020, 418:326-339.
- [22] LEI Y T, DU W W, HU Q H. Face Sketch-to-Photo Transformation with Multiscale Self-Attention GAN [J]. *Neurocomputing*,2020,396:13-23.
- [23] ZUO Y, JIANG L, SUN H, et al. Short Text Classification Based on Bidirectional TCN and Attention Mechanism[J]. *Journal of Physics: Conference Series*, IOP Publishing, 2020, 1693(1): 012067.
- [24] KIM Y, CHOI A. EEG-Based Emotion Classification Using Long Short-Term Memory Network with Attention Mechanism[J]. *Sensors*, 2020, 20(23): 6727.
- [25] 石荣,吴聪. 信噪比的不同定义及对调制识别性能评估的影响[J]. *通信技术*,2019,52(7):1556-1562.
- [26] GUO J, XU N, LI L J, et al. Attention Based CLDNNs for Short-Duration Acoustic Scene Classification[C]//Interspeech 2017. 2017: 469-473.
- [27] 何春蓉,朱江. 基于注意力机制的 GRU 神经网络安全态势预测方法[J]. *系统工程与电子技术*,2021,43(1): 258-266.
- [28] QU Z, MEI J, LIU L, et al. Crack Detection of Concrete Pavement with Cross-Entropy Loss Function and Improved VGG16 Network Model[J]. *IEEE Access*, 2020, 8:54564-54573.
- [29] KRIZHEVSKY A, SUTSKEVER I, HINTON G E, et al. Image Net Classification with Deep Convolutional Networks[J]. *Communications of the ACM*,2017,60(6): 84-90.

(编辑:徐楠楠)