

# 基于频带相关性 Deep Learning 的 无线通信干扰智能识别



杨岚,肖海涛,张渭乐

西安交通大学 智能网络与网络安全教育部重点实验室, 陕西 西安 710072

**摘要:**近年来,随着无线通信技术在军事领域的发展及各类无线通信装备数量的增加,战场电磁环境变得越来越复杂,其要求通信系统具有更强的抗干扰能力,而智能干扰识别是抗干扰的前提。基于传统机器学习的各类干扰识别算法存在干扰前期特征提取繁杂、低干噪比(JNR)下识别正确率低的问题。本文针对上述问题,引入了并行多路多尺度卷积,通过增加网络宽度、提升网络识别速度和精度,解决前期特征提取繁杂的问题;结合频带相关性长短时记忆网络(LSTM)创新性地提出了基于LSTM的频带相关性无线通信干扰智能识别网络,该方法利用LSTM探知干扰信号频带相关性,提升低干噪比下的干扰识别正确率。通过仿真证明了多尺度并行卷积比普通卷积网络更稳定,识别速度和泛化性更佳,该网络提升了低干噪比下的识别正确率,平均识别正确率达99.86%。可见,本文所提的网络模型是解决复杂电磁环境下的智能干扰识别的一种有效可用模型。

**关键词:**复杂电磁环境认知; 干扰识别; 频带相关性; 长短时记忆网络; 并行多路多尺度卷积

中图分类号:TN975

文献标识码:A

DOI: 10.19452/j.issn1007-5453.2022.04.014

未来作战环境不同于传统作战环境,未来作战高度依赖无线通信进行信息作战<sup>[1]</sup>。电磁频谱作为战场信息的核心载体,对其进行正确的认知有着十分重大的意义,不仅可以快速获取战场信息,而且使无线通信系统更为可靠<sup>[2]</sup>。无线通信处在一个较为开放的环境,因此更容易受到各方干扰信号及噪声的影响,使信息传输准确率、通信系统安全率下降<sup>[3]</sup>。及时感知电磁环境的变化<sup>[4]</sup>,可以更好地适应战场环境,其中最重要的一步是识别干扰信号,国内外学者也对各类识别方法进行了大量探索。

传统的干扰检测方式有能量检测、匹配滤波检测、循环平稳检测等。1967年,参考文献[5]中提出的能量检测方法,在没有得到干扰信号先验信息的前提下,做出干扰存在与否的两种检验假设,接收检测统计量与门限阈值进行比较后,判断干扰存在与否,参考文献[6]对该方法进行了改进,提高了低信噪比下的识别准确率。参考文献[7]提出一种两级盲频谱检测算法,利用空域匹配滤波优势,使提出的

新算法在低信噪比和低采样率下有更高的检测正确率。为了进一步提高干扰信号检测准确率,引入基于特征提取的干扰识别算法,通过人工提取各类特征后进行干扰分类,综合分析提取信号频域、时域等多个维度的特征参数,并提出了一种基于决策树算法的干扰信号识别算法<sup>[8]</sup>,仿真结果表明其识别性能较好。参考文献[9]提取信号时频域图像的特征,输入特征到支持向量机(SVM)进行分类前降维操作。参考文献[10]研究了基于SVM和反向传播神经网络(BP神经网络)干扰信号识别模型,对比了不同训练数据数目、不同特征预处理情况下的算法识别性能。采用上述方法,信号需要先经过复杂的前期处理,网络泛化能力也不强,对于低干噪比下的干扰信号存在识别准确率不高的问题,面对复杂的电磁环境无所适从。

深度神经网络在图像和语音处理等领域有着非常突出的表现,有着极好的数据表达能力。因此,深度学习强大的特征表达能力在识别干扰信号领域有很大的潜力<sup>[11]</sup>。参考

收稿日期: 2021-11-23; 退修日期: 2022-01-18; 录用日期: 2022-02-22

基金项目: 航空科学基金(2019ZC070002)

引用格式: Yang Lan, Xiao Haitao, Zhang Weile. Intelligent jamming identification based on deep learning with frequency band correlation for wireless communication[J]. Aeronautical Science & Technology, 2022, 33(04): 108-118. 杨岚, 肖海涛, 张渭乐. 基于频带相关性 Deep Learning 的无线通信干扰智能识别[J]. 航空科学技术, 2022, 33(04): 108-118.

文献[12]设计了基于深度学习的干扰识别实数卷积网络,与基于特征提取的干扰识别算法进行对比,识别性能有了很大的提升。为了防止网络破坏信号实部与虚部相关性,复数识别网络<sup>[13]</sup>被提出,不同网络输入数据格式对识别性能产生影响且复数干扰识别网络中采用频域数据格式比起时域数据识别效果更好。上述各类干扰识别方式在高于噪比下取得了不错的识别效果,但在低噪比下的识别率普遍不高,本文就低噪比下识别率不高的问题,创新性地提出了利用长短时记忆网络(LSTM)探知干扰信号频带相关性,提升低噪比下的干扰识别正确率。

本文希望通过挖掘干扰信号频带相关性提高干扰信号的识别正确率,基于该想法构建了一个新的基于 LSTM 的多尺度并行卷积网络。首先,利用改进的并行卷积网络拓宽网络宽度、提高网络泛化性,自动提取数据特征进行干扰分类;然后,利用长短时记忆网络挖掘频带相关性提高干扰信号在低噪比下的识别正确率,最后将识别结果与普通智能干扰信号识别结果进行对比,为复杂电磁环境下的干扰识别提供一种新的思路<sup>[14-20]</sup>。

## 1 基础理论

### 1.1 卷积神经网络

普通的全连接神经网络具有梯度消失、可扩展性差等缺点,卷积神经网络大大改善了这些缺点,避免了对原始数据复杂的前期处理,真正实现了端到端的学习过程。卷积神经网络典型结构如图1所示,从图中可以看出,进入全连接层之前,数据要经过多个卷积层和池化层的处理。




图1 卷积神经网络典型结构

Fig.1 Typical structure of a convolutional neural network

以二维输入数据为例,输入经过卷积层处理后,得到如下结果

$$C_{i,j} = (I \times K)_{i,j} = \sum_m \sum_n I_{i-m,j-n} K_{m,n} \quad (1)$$

式中: $I$ 为输入数据, $K$ 为需要的二维卷积核, $C$ 为卷积层的输出。

经过卷积层对数据进行特征提取后,利用池化层减小、压缩特征图,提取有用信息,常见方法有最大值池化、均值池化等。其中, $h$ 与 $w$ 分别代表池化窗口的高和宽。

均值池化计算方式

$$y_{m,n} = \frac{1}{hw} \sum_{\substack{0 \leq i \leq h, \\ 0 \leq j \leq w}} x_{mh+i,nw+j} \quad (2)$$

最大池化计算方式

$$y_{m,n} = \max_{\substack{0 \leq i \leq h, \\ 0 \leq j \leq w}} x_{mh+i,nw+j} \quad (3)$$

卷积层是CNN的核心结构,通过对输入数据的降维处理自动提取原始数据的特征。激活层与全连接层中的激活层相同,令上一层的数据具有非线性,引入激活函数增加了神经网络模型的非线性学习。池化层又称子采样层或下采样层,目的在于降低数据规模,增强网络的泛化处理能力。此后再加入全连接层,此时数据特征已经过卷积层和池化层反复提炼,因此比直接采用原始数据所取得的效果更好。

### 1.2 长短时记忆神经网络

与其他神经网络不同,循环神经网络(Recurrent Neural Network)结构每一个神经元中都有自身的循环,除去神经元之间的连接,每个神经元与自身也有连接。这种结构使得该网络获得了“记忆”功能,可以“记住”网络之前的输入信息。

循环神经网络处理时间序列问题的效果很好,但后期容易出现梯度爆炸、梯度消失等问题。为了克服这些问题,后期引入“门”结构去掉或者增加神经元状态信息,即选择性保留重要内容,本文选用的是LSTM。

LSTM内部结构如图2所示,从左到右依次为遗忘门、输入门和输出门。上一个时间的神经元状态量与上一个时间的输出进入遗忘门,“遗忘”掉部分信息,输入门主要负责通过的信息内容。通过遗忘门剩下的信息与通过输出门新加的信息共同更新神经元状态。最后输出门的设计起到调优的作用,通过该门之后,输出变为符合模型输出的信息形式。

遗忘门有目的地筛选信息,信息通过一个sigmoid层获得表示各部分信息通过的比重的值。计算过程如式(4)所示

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (4)$$




图2 LSTM内部结构

Fig.2 Internal structure of LSTM

传入门则负责加入的信息数量。实现该功能需要两个步骤:(1)决定哪些部分需要更新;(2)具体更新内容 $k_t$ 。联合这两个步骤,对状态做一个更新。计算过程如式(5)~式(7)所示

$$i_t = \sigma[W_i \cdot (h_{t-1}, x_t) + b_i] \quad (5)$$

$$k_t = \tanh[W_c \cdot (h_{t-1}, x_t) + b_c] \quad (6)$$

$$C_t = f_i C_{t-1} + f_i k_t \quad (7)$$

最终输出值依赖于输出门的过滤操作。输出门的计算过程如式(8)、式(9)所示。

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (8)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (9)$$

## 2 基于频带相关性的LSTM无线通信干扰智能识别

### 2.1 模型架构

现有的深度学习模型并没有很好地解决低干噪比下的干扰信号识别问题。本文中提出的模型立足实现智能识别、高噪声下的高识别正确率,称为基于频带相关性的LSTM无线通信干扰智能识别。下面将介绍该模型的详细结构。

本研究构建的干扰识别模型结构图如图3所示,模型结构表见表1。输入数据为需要进行判别的频段及该频段之前的 $N$ 个频段数据,将其进行归一化操作。整个模型大体由两部分组成,即基于频带相关性LSTM的干扰预测模块和基于并行多路多尺度卷积的干扰识别模块。首先基于频带相关性LSTM的干扰预测模块将需要频段前的 $N$ 个频段数据输入LSTM网络,对下一个频段(即需要判别的频段)进行初步预测是否有干扰存在。然后再将需要判别频段的数据及初步预测结果输入两层CNN网络进行初步特征提取,通过三层并行卷积进一步提取数据深层特征提升识别率,最终通过全连接层和softmax分类器确认分类结果。

表1从上至下对应模型结构图,其中LSTM预测模块中的100/1表示其仅包含一层LSTM,隐含层节点数为100;普通卷积网络中各参数尺寸为卷积(池化)/步长,并行多路多尺度卷积各参数如图3所示,括号内数字为各卷积核厚度。

### 2.2 基于频带相关性的LSTM预测模块

#### 2.2.1 频带相关性

低干噪比下的干扰信号特征不明显,导致低干噪比下的识别正确率很低,故本文利用频带相关性,引入LSTM网




图3 本文所用模型结构

Fig.3 Model structure used in this paper

络探知干扰信号频带相关性,提升低干噪比下的干扰识别正确率。

假设第 $k$ 个频带的第 $n$ 个样本为 $r_k(n)$ ,  $n = 1, 2, \dots, N$ 。根据二元假设检验理论

$$r_k(n) = \begin{cases} w_k(n) \\ w_k(n) + J_k(n) \end{cases} \quad (10)$$

式中: $w_k(n)$ 表示为均值为零,方差为 $\sigma_w^2$ 的高斯白噪声, $J_k(n)$ 表示第 $k$ 个频带存在的干扰信号,在此假设其均值为

表1 模型结构表

Table 1 Model structure table

| 网络模块     | 操作类型            | 模型参数  |
|----------|-----------------|-------|
| LSTM预测模块 | LSTM            | 100/1 |
|          | FULL Connection | —     |
|          | softmax         | —     |
| 普通卷积网络   | Convolution     | 1*5/2 |
|          | Max Pooling     | 1*3/2 |
| 普通卷积网络   | Convolution     | 1*3/2 |
|          | Max Pooling     | 1*3/2 |
| 多尺度卷积(a) | 多尺度卷积(a)        | 图3    |
|          | Max Pooling(a)  | 1*3/2 |
| 多尺度卷积(b) | 多尺度卷积(b)        | 图3    |
|          | Max Pooling(b)  | 1*3/2 |
| 多尺度卷积(c) | 多尺度卷积(c)        | 图3    |
|          | Max Pooling(c)  | 1*3/2 |
| 分类器      | Full Connection | —     |
|          | softmax         | —     |

零, 方差为  $\sigma_k^2$ 。第  $k$  个频带上的总功率为

$$p_k = \frac{1}{N} \sum_{n=1}^N |r_k(n)|^2 \quad (11)$$

由中心极限定理得到, 当  $N$  无穷大时, 式(11)变为

$$p_k \sim \begin{cases} N(\sigma_w^2, \frac{1}{N} \sigma_w^4) \\ N(\sigma_{J_k}^2 + \sigma_w^2, \frac{1}{N} (\sigma_{J_k}^2 + \sigma_w^2)^2) \end{cases} \quad (12)$$

将  $k$  个频带功率表示成矢量形式为

$$\bar{p} = [p_1, p_2, \dots, p_k] \quad (13)$$

虽然每个频带的中心频率各不相同, 但它们占据的频率范围有一些彼此重叠的情况。以图4所示的Wi-Fi系统的频带划分图为例, 每个信道在中心频域两侧都有延展情况, 部分覆盖到了其他频带。但认知无线电划分频带时对带宽有限制要求, 划分频段的时候带宽不会过大, 所以相邻频段一般都会有相同的频谱状态。本文利用该特点提升低干扰比下的识别正确率。




图4 Wi-Fi系统的频带划分示意图

Fig.4 Schematic diagram of band division of Wi-Fi

### 2.2.2 基于频带相关性LSTM的干扰预测

了解 LSTM 基本结构之后, 本文利用其进行完整的 LSTM 预测模块搭建, 如图5所示。




图5 基于LSTM的预测模块

Fig.5 Prediction module based on LSTM

本文中提出的LSTM预测模块旨在提高低干扰比下的干扰识别正确率。LSTM作为循环神经网络(RNN)的一种变体, 是一种时间递归神经网络, 常常用来处理具有时间相关的问题。由上一节可知相邻频段之间会有相同的频谱状态, 即有一定的相关性存在, 所以本文模型引入LSTM模块, 通过探知频带相关性提升识别正确率。

由服从指数分布的参数  $\theta_1$  取整决定干扰连续频段数, 重复若干次生成所需要的数据量。将需要判断频段的前  $N$  个干扰信号频带数据输入 LSTM 网络中, 模块仅含一层 LSTM, 隐藏层节点数为 100, 后跟全连接层与 softmax 进行初次分类。

此处将交叉熵函数作为误差函数进行第一次误差矫正, 其交叉熵函数的定义为

$$\text{loss}_1 = - \sum_{n=1}^N R_n \ln O_n \quad (14)$$

式中:  $O_n$  为网络输出的第  $n$  个元素,  $R_n$  是真实矢量标签。交叉熵可以衡量同一个随机变量的两个不同概率分布的差异程度, 即真实概率分布与网络预测概率分布之间的差异, 其值越小代表模型分类效果越好。

### 2.3 基于并行多路多尺度卷积识别模块

#### 2.3.1 Inception 模块

卷积神经网络深度加深会带来参数急剧增加的问题, 从而导致过拟合问题; 网络加深也会使梯度在深处消失, 导致模型难以训练。针对这些问题, 2014年, 谷歌公司提出一种名叫“GoogLeNet”的网络结构<sup>[13]</sup>, 其模型层数为22层。该模型结构很大程度上解决了参数过多、深层梯度消失等问题。一方面在不同深度增加两个 loss 来克服梯度消失的



问题,另一方面采用Inception这种并行结构增加网络宽度。

起初,该结构内部仅对输入做了四路分支,分别采用不同大小的卷积核对数据从不同角度进行特征提取,如图6所示。最初的结构直接串联导致最终得到的数据厚度是普通卷积的4倍,故后期加入1\*1卷积对所在分支进行降维,改进后的Inception结构如图7所示。




图6 最初的Inception结构

Fig.6 Initial inception structure




图7 改进后的Inception结构

Fig.7 Inception structure

### 2.3.2 基于并行多路多尺度卷积干扰识别

了解了Inception的具体结构及其所具有的优势后,本文引入该模块并对其进行一定修改,将修改后的Inception结构作为本文提出模型的一部分,称修改后的模型为并行多尺度卷积网络。

传统的CNN卷积网络因为前后层密集连接,使得网络训练参数过多,不仅使训练难度增大,也更容易出现过拟合现象。为了防止该现象发生,本文在传统两层卷积网络之后加入并行多路多尺度卷积网络,其结构如图8所示。两层普通卷积网络的输出作为并行多路多尺度卷积网络输入,对上一层结果分为四路进行处理。内部先用1\*1卷积核对传入数据进行厚度减小处理(降维)、增加网络宽度,再利用不同大小1\*3、1\*5的卷积核对输入数据的特征信息从多个尺度进行提取,这些提取出的特征所包含的信息也往往比单一卷积层提取的特征更丰富,而后将处理得到的四路数据在通道维度上进行级联,进行最大池化得到下一层




图8 并行多路卷积结构图

Fig.8 Parallel multiplex convolution structure diagram

的输入数据。

此处将交叉熵函数作为误差函数,其交叉熵函数的定义为

$$\text{loss}_2 = -\sum_{n=1}^N R_n \ln O_n \quad (15)$$

式中: $O_n$ 为网络输出的第 $n$ 个元素, $R_n$ 是真实矢量标签。交叉熵可以衡量同一个随机变量的两个不同概率分布的差异程度,即真实概率分布与网络预测概率分布之间的差异,其值越小代表模型分类效果越好。采用Adam算法进行优化。

为了提升低干噪比下的干扰识别正确率,本文提出用LSTM预测模块先判断有无干扰,辅助并行多路多尺度卷积网络进行干扰识别。模型设有两个损失函数:(1)位于LSTM预测模块,以初步判定有无干扰;(2)位于并行多路卷积网络之后,以具体判断干扰类别。损失函数具体分布位置如图9所示。两个损失函数权重比为2:1,即

$$\text{loss} = 2\text{loss}_1 + \text{loss}_2 \quad (16)$$




图9 网络损失函数分布图

Fig.9 Network loss function distribution

## 3 仿真试验结果

### 3.1 仿真数据和环境构建

#### 3.1.1 仿真数据

试验仿真数据集由单音干扰、多音干扰、扫频干扰及部分频带干扰、噪声调频干扰5种典型的干扰类型组成。

##### (1)单音干扰

单音干扰复基带表达式

$$J(t) = A \exp [j(2\pi f_0 t + \phi)] \quad (17)$$

式中： $A$ 代表单音干扰幅度， $f_0$ 为干扰信号频率， $\phi$ 为初始相位。图 10(a)是采样周期为  $10^{-7}$ s、采样点数为 1024、频率位置随机的复基带单音干扰信号频谱图。

### (2) 多音干扰

多音干扰复基带表达式

$$J(t) = \sum_{m=1}^M A_m \exp [j(2\pi f_m t + \phi_m)] \quad (18)$$

式中： $A_m$ 为第  $m$  个单音的幅度值， $f_m$ 为第  $m$  个单音的干扰频率， $\phi_m$ 为第  $m$  个单音的初始相位。图 10(b)是采样周期为  $10^{-7}$ s、采样点数为 1024、频率位置随机的复基带多音干扰信号频谱图。

### (3) 扫频干扰

扫频干扰的复基带表达式

$$J(t) = A \exp [j(2\pi f_0 t + \pi k t^2 + \phi)] \quad (19)$$

式中： $A$ 为幅度， $f_0$ 为初始频率， $\phi$ 为初始相位。图 10(c)是采样周期为  $10^{-7}$ s、采样点数为 1024、 $k$ 为  $10^{-3} \sim 10^{-6}$ 、初始频率位置随机的复基带扫频干扰信号频谱图。

### (4) 部分频带干扰

部分频带干扰复基带表达式

$$J(t) = U_n(t) \exp [j(2\pi f_0 t + \phi)] \quad (20)$$

式中： $U_n(t)$ 是均值为零、方差为  $\sigma_n^2$  的高斯噪声， $f_0$ 为干扰的中心频率， $\phi$ 为初始相位。图 10(d)是采样周期为  $10^{-7}$ s、采样点数为 1024、频点位置随机的复基带部分频带干扰信号频谱图。

### (5) 噪声调频干扰

噪声调频干扰复基带表达式

$$J(t) = A \exp [j(2\pi f_0 t + k_{f_m} \int_0^t \xi(t') dt')] \quad (21)$$


式中： $A$ 为幅度， $f_0$ 为中心频率， $k_{f_m}$ 为调频系数， $\xi(t)$ 是均值为零，方差为  $\sigma_n^2$  的高斯噪声，具体带宽由  $k_{f_m}$  及  $\sigma_n^2$  共同决定。图 10(e)是采样周期为  $10^{-7}$ s、采样点数为 1024、调频系数  $k_{f_m}$  为 0.3~2 随机值、 $\sigma_n^2 = 2 \times 10^6$  的复基带噪声调频干扰信号频谱图。

## 3.1.2 仿真环境


仿真硬件环境为 CPU(Intel(R) Core(TM)i5-9400)，仿真软件为 MATLAB 和深度学习框架 pytorch，其中 MATLAB 用来产生仿真数据集，pytorch 用来进行网络训练和测试。仿真中，采样周期为  $10^{-7}$ s，采样点数为 1024，信道模型为加性高斯白噪声。

模型具体的网络参数见表 2，训练样本信号 JNR 为


-5dB 到 20dB，步长为 0.5dB，每种干扰在每个 JNR 下的样本数为 200；为测试网络泛化性，设测试样本信号 JNR 为




(a) 单音干扰功率谱图




(b) 多音干扰功率谱图



(c) 扫频干扰功率谱图



(d) 部分频带干扰功率谱图



(e) 噪声调频干扰功率谱图

图10 干扰信号功率谱图

Fig.10 Interference signal power spectrum

-20~30dB,步长为0.5dB,每种干扰在每个JNR下的样本数为100。频带是否存有干扰由两个服从指数分布的参数 $\theta_1$ 和参数 $\theta_2$ 取整产生,重复若干次,直到产生所需的数据量为止。网络学习率为0.001,batch\_size设置为100。

表2 模型参数表

Table 2 Model parameter table

| 网络模块     | 操作类型        | 模型参数  | 输入数据尺寸     | 输出数据尺寸   |
|----------|-------------|-------|------------|----------|
| LSTM预测模块 | LSTM        | 100/1 | N*1024     | 1*2      |
|          | FC          | —     |            |          |
|          | softmax     | —     |            |          |
| 普通卷积     | Convolution | 1*5/2 | 1*(1024+1) | 1*512*8  |
|          | Max Pooling | 1*3/2 | 1*512*8    | 1*256*8  |
| 普通卷积     | Convolution | 1*3/2 | 1*256*8    | 1*128*16 |
|          | Max Pooling | 1*3/2 | 1*128*16   | 1*64*16  |
| 多尺度卷积(a) | 多尺度卷积       | 图3    | 1*64*16    | 1*64*16  |
|          | Max Pooling | 1*3/2 | 1*64*16    | 1*32*16  |
| 多尺度卷积(b) | 多尺度卷积       | 图3    | 1*32*16    | 1*32*32  |
|          | Max Pooling | 1*3/2 | 1*32*32    | 1*16*32  |
| 多尺度卷积(c) | 多尺度卷积       | 图3    | 1*16*32    | 1*16*32  |
|          | Max Pooling | 1*3/2 | 1*16*32    | 1*8*32   |
| 分类器      | FC          | —     | 8*32       | 1*5      |
|          | softmax     | —     | 1*5        | 1*5      |


### 3.2 仿真结果分析

#### 3.2.1 两层普通卷积网络和并行多路卷积网络的仿真结果分析


首先,模型不考虑频带相关性,仅用两层卷积层和并行多路卷积网络进行干扰识别,识别结果如图11~图12所示,记两层CNN网络为普通CNN,两层CNN加上三层多尺度

并行卷积结构为图中的并行多路卷积。


由图11的识别结果可以看出,JNR为-15dB时,并行多路卷积网络开始捕捉到扫频干扰特征从而进行识别。图11(d)为两网络的识别率对比,由图可见,两网络由JNR为-15dB时开始捕捉信号特征,JNR为-5dB时已经可以达到98%以上




(a) 多音干扰识别正确率




(b) 扫频干扰识别正确率



(c) 噪声调频干扰识别正确率



(d) 模型识别正确率



(e) 损失函数变化图

图 11 普通卷积与并行多路网络识别对比图


Fig.11 Comparison between different network recognition effects

的识别正确率。两网络看似产生效果相同,但具体看图 11(e) 损失函数变化图发现,并行卷积网络在迭代次数 10 次左右时,网络模型就已经达到稳定状态。图 12 为 5 层 CNN 网络与本文所用的并行多路卷积模型的运行总时间与网络达到稳定时间的对比图。由图可见,本文提出的模型每层运行时间大约为 15.27min,而五层卷积网络每层运行时间为 19.8min,并行多路卷积网络增加了网络宽度,减少了计算量,不仅节省了运行总时间,也能使网络更快达到稳定状态。

### 3.2.2 并行多路卷积网络和本文所提网络结构结果对比

考虑具有频带相关性的数据,将加入 LSTM 结构之后的模型称本文所提模型,将该模型识别结果与并行多路卷积(未加 LSTM 网络)进行对比,仿真结果如图 13 所示。


由仿真结果图 13 可以看出,除了单音干扰在高噪声比下的识别正确率有些许波动外,扫频干扰、噪声调频干扰、部分频带干扰的识别正确率比并行多路卷积网络的识别率更稳定,保持在 99.8% 以上;低噪声比下,并行多路卷积网络在 JNR




(b) 达到稳定状态所用时间

图 12 运行时间对比图


Fig.12 Run time comparison




(a) 单音干扰识别正确率



(b) 多音干扰识别正确率




(c) 扫频干扰识别正确率




(a) 运行时间






(d) 噪声调频干扰识别正确率



(e) 部分频带干扰识别正确率



(f) 两模型识别正确率

图13 本文所提模型与并行多路卷积识别效果对比图

Fig.13 Comparison between the proposed model and parallel multi-channel convolution recognition

为-13dB左右才开始有干扰识别趋势,但本文提出模型识别率在JNR为-20dB时就达到了98%。其中,单音干扰和多音干扰识别率有不平稳的现象,单音干扰识别率有10%左右的波动情况,多音干扰波动情况在0.03%左右,噪声调频干扰、扫频干扰及部分频带干扰识别正确率均无明显波动。

对比其他的普通卷积网络,本文所提模型在低干噪比下的识别率有着非常显著的提升。低干噪比下的干扰信号特征不太明显,所以以提取特征为主的卷积网络没办法有效捕捉到各类干扰特征,导致识别率过低。本文引入LSTM预测模块后,通过探知频带相关性得到初步结论,即

干扰是否存在,将该结果作为主要参考与需要判别频带数据同时输入并行卷积网络之后,不仅提升了网络稳定性,且大大提升了在低干噪比下的识别正确率。

## 4 结束语

军事电子对抗中快速获取电磁干扰信息和稳定可靠的无线通信链路尤为重要,因此快速判断识别战场干扰具有十分重大的意义。本文提出并行多路多尺度卷积提高了网络识别的稳定性,减少了网络运行时间。并行多路多尺度卷积与LSTM相结合的网络通过学习频带相关性,大大提升了低干噪比下的干扰识别正确率。仿真试验和分析结果证明了本文所提模型的有效性和优越性。未来将在真实干扰信号场景下验证模型的有效性和识别性能,并进一步改进模型。

AST

## 参考文献

- [1] 张澎,张成,管洋洋,等.关于电磁频谱作战的思考[J].航空学报,2021,42(8):94-105.  
Zhang Peng, Zhang Cheng, Guan Yangyang, et al. Reflections on electromagnetic spectrum operations[J]. Chinese Journal of Aeronautics, 2021,42(8): 94-105. (in Chinese)
- [2] 罗富刚,李文元,唐思维.从电磁频谱战看未来军事通信的发展趋势[J].中国战略新兴产业,2017(24):50.  
Luo Fugang, Li Wenyuan, Tang Siwei. Looking at the future development trend of military communications from the perspective of electromagnetic spectrum warfare[J]. China Strategic Emerging Industry, 2017(24): 50. (in Chinese)
- [3] 逢天洋,李永贵,牛英滔,等.通信电子干扰的分类与发展[J].通信技术,2018,51(10):2271-2278.  
Mei Tianyang, Li Yonggui, Niu Yingtao, et al. Classification and development of communication electronic interference[J]. Communications Technology, 2018, 51(10): 2271-2278. (in Chinese)
- [4] 胡新宇.基于认知的战场电磁环境侦察技术[J].空天防御,2019,2(4):40-45.  
Hu Xinyu. Cognition-based battlefield electromagnetic environment reconnaissance technology[J]. Air & Space Defense, 2019,2(4): 40-45. (in Chinese)
- [5] Urkowitz H. Energy detection of unknown deterministic signals [J]. Proceedings of the IEEE, 2005, 55(4): 523-531.

- [6] 张天林. 基于信号能量的干扰检测技术研究[D]. 重庆:重庆大学,2018.
- Zhang Tianlin. Research on interference detection technology based on signal energy[D]. Chongqing: Chongqing University, 2018. (in Chinese)
- [7] 包志强,崔妍蕊,徐笑. 一种关于空间谱的两级多天线盲频谱检测[J]. 电信科学,2018,34(3):59-66.
- Bao Zhiqiang, Cui Yanrui, Xu Xiao. A two-stage multi antenna blind spectrum detection on spatial spectrum[J]. Telecommunications Science, 2018, 34(3): 59-66. (in Chinese)
- [8] 方芳,李永贵,牛英滔,等. 基于决策树算法的干扰信号识别[J]. 通信技术,2019,52(11):2617-2623.
- Fang Fang, Li Yonggui, Niu Yingtao, et al. Interference signal recognition based on decision tree algorithm[J]. Communication Technology, 2019,52(11):2617-2623. (in Chinese)
- [9] 郝万兵,马若飞,洪伟. 基于时频特征提取的雷达有源干扰识别[J]. 火控雷达技术,2017,46(4):11-15.
- Hao Wanbing, Ma Ruofei, Hong Wei. Radar active jamming identification based on time-frequency feature extraction[J]. Fire Control Radar Technology, 2017,46(4):11-15. (in Chinese)
- [10] 徐国进. 典型通信干扰信号识别技术研究[D]. 成都:电子科技大学,2018.
- Xu Guojin. Research on identification technology of typical communication interference signals[D]. Chengdu: University of Electronic Science and Technology, 2018. (in Chinese)
- [11] 刘强. 基于深度学习的雷达干扰识别技术[D]. 成都:电子科技大学,2020.
- Liu Qiang. Radar jamming identification technology based on deep learning[D]. Chengdu: University of Electronic Science and Technology, 2020. (in Chinese)
- [12] 练东海. 基于深度学习的无线通信干扰信号识别与处理[J]. 通信电源技术,2021,38(2):104-107.
- Lian Donghai. Wireless communication interference signal recognition and processing based on deep learning[J]. Telecom Power Technologies, 2021,38(2):104-107. (in Chinese)
- [13] 党泽. 基于深度学习的无线通信干扰信号识别与处理技术研究[D]. 成都:电子科技大学,2020.
- Dang Ze. Research on wireless communication interference signal recognition and processing technology based on deep learning[D]. Chengdu: University of Electronic Science and Technology, 2020. (in Chinese)
- [14] Szegedy C, Liu W, Jia Y, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015.
- [15] 陈晶晶. 认知无线电中基于次用户节点选择的频谱感知方法研究[D]. 南京:南京邮电大学,2020.
- Chen Jingjing. Research on spectrum sensing method based on secondary user node selection in cognitive radio[D]. Nanjing: Nanjing University of Posts and Telecommunications, 2020. (in Chinese)
- [16] 王方勇,杜栓平. 基于调频信号子带相关性分析的回波特征提取方法[J]. 应用声学, 2010,29(5):344-351.
- Wang Fangyong, Du Shuanping. Echo feature extraction method based on frequency modulated signal subband correlation analysis[J]. Journal of Applied Acoustics, 2010,29 (5): 344-351. (in Chinese)
- [17] 兰博. 基于谱相关的自适应能量检测[D]. 北京:北京邮电大学,2020.
- Lan Bo. Adaptive energy detection based on spectral correlation [D]. Beijing: Beijing University of Posts and Telecommunications, 2020. (in Chinese)
- [18] Bello I, Pham H, Le Q V, et al. Neural combinatorial optimization with reinforcement learning[J/OL]. [2016-11-29]. <https://doi.org/10.48550/arXiv.1611.09940>.
- [19] 吴明忠,刘永志. 人工智能技术在直升机领域的应用及发展展望[J]. 航空科学技术,2021,32(1):29-34.
- Wu Mingzhong, Liu Yongzhi. Application and development prospect of artificial intelligence technology in helicopter field [J]. Aeronautical Science & Technology, 2021,32(1): 29-34. (in Chinese)
- [20] 何晓晓,姚呈康. 人工智能等新技术在航空训练中的应用研究[J]. 航空科学技术,2020,31(10):7-11.
- He Xiaoxiao, Yao Chengkang. Application of artificial intelligence and other new technologies in aviation training [J]. Aeronautical Science & Technology, 2020,31(10): 7-11. (in Chinese)

## Intelligent Jamming Identification Based on Deep Learning with Frequency Band Correlation for Wireless Communication

Yang Lan, Xiao Haitao, Zhang Weile

*Key Laboratory of Intelligent Network and Network Security, Ministry of Education, Xi'an Jiaotong University, Xi'an 710072, China*

**Abstract:** In recent years, with the development of wireless communication technology in the military field and the increase of the number of all kinds of wireless communication equipment, the battlefield electromagnetic environment has become more and more complex, which requires the communication system with stronger anti-jamming capability. Intelligent jamming recognition is the precondition of anti-jamming. Various jamming recognition algorithms based on traditional machine learning have the problems of complex interference feature extraction and the low recognition accuracy under low jammer-to-noise ratio (JNR). Therefore, aiming at the problem of intelligent recognition of various typical interference signals, a parallel convolution module with multi-channel and multi-scale is introduced to increase network width, improve network recognition speed and accuracy, and solve the problem of complex feature extraction in the previous period. Combining the parallel convolution based CNN with the band correlation based long-term and short-term memory network (LSTM), an innovative intelligent wireless communication jamming recognition network based on deep learning with band-correlation is proposed in this paper. This method uses LSTM to detect the band correlation of interference signals and to improve the accuracy of jamming recognition at low jammer-to-noise ratio. Simulations show that our proposed network is more stable, faster and more generalized than ordinary convolution network. The band correlation based LSTM improves the recognition accuracy of our method under low jammer-to-noise ratio (with an average recognition accuracy of 99.86%). Therefore, the network model proposed in this paper is an effective and available model to solve the intelligent interference recognition in complex electromagnetic environment.

**Key Words:** cognition of complex electromagnetic environment; disturbance recognition; frequency band correlation; long and short memory network; parallel multichannel multiscale convolution

---

**Received:** 2021-11-23; **Revised:** 2022-01-08; **Accepted:** 2022-02-22


**Foundation item:** Aeronautical Science Foundation of China (2019ZC070002)



中航出版传媒有限责任公司  
CHINA AVIATION PUBLISHING & MEDIA CO., LTD.

广告

# 航空工业知识服务平台



特色检索体系

灵活多样组合

双重阅读模式

丰富内容资源

可提供定制服务

开通试用：个人申请请发送E-mail至jinningbo@aviationnow.com.cn，邮件中请注明：姓名、手机号、工作单位，我们在一个工作日内将为期七天的试用账号通过手机或邮件发送给您。

电话：010-85672623

网址：<http://knowledge.aviationnow.com.cn>

地址：北京市朝阳区京顺路5号曙光大厦C座

邮编：100028