化繁为简：干扰分类任务的CNN模型复杂度研究

Taiwo Oyedare*、Vijay K. Shah†、Daniel J. Jakubisin*‡、Jeffrey H. Reed** 布拉德利
电气与计算机工程系，弗吉尼亚理工大学，美国布莱克斯堡
† 网络安全工程系，乔治·梅森大学，美国费尔法克斯
‡ 弗吉尼亚理工大学国家安全研究所，美国弗吉尼亚州布莱克斯堡 电子邮件：
toyedare@vt.edu、vshah22@gmu.edu、djj@vt.edu、reedjh@vt.edu

arXiv:2303.03326v1 [eess.SP] 6 Mar 2023

摘要—**随着使用无线频谱的设备数量不断增加，寻找减少干扰并优化频谱利用的方法变得至关重要。深度学习模型（如卷积神经网络）凭借直接从数据中学习的能力，已被广泛用于识别、分类或缓解干扰。然而，关于此类深度学习模型复杂度的研究仍然有限。基于深度学习的无线分类文献主要关注提高分类准确率，往往以模型复杂度为代价。对于许多无线设备而言，这可能并不实际，例如物联网设备通常计算资源十分有限，无法处理过于复杂的模型。因此，在设计用于干扰分类的深度学习模型时，考虑模型复杂度十分重要。为此，我们对基于CNN的无线分类进行了分析，探讨数据集大小、CNN模型复杂度与分类准确率之间的权衡，并考察不同分类难度层级，即干扰分类、异构发射机分类和同构发射机分类。基于三个无线数据集的研究结果表明，参数较少的简单CNN模型，其性能可以与更复杂的模型不相上下，为卷积神经网络在计算受限应用中的使用提供了重要见解。**

索引词—**干扰分类、卷积神经网络、模型复杂度。**

I. 引言

物联网（IoT）、5G设备及其他无线技术的普及，导致相互干扰的无线设备数量不断增加，无论这种干扰是有意还是无意的。对干扰进行分类对于确保良好的通信质量和遵守频谱共享政策至关重要。在无线通信领域，无线干扰指感兴趣信号受到共享同一信道的另一信号干扰，这一概念已得到广泛研究 [1]–[3]。此类干扰会显著降低信号与噪声加干扰比（SINR），并扰乱发射器与接收器之间的通信。

传统上，许多干扰分类技术依赖于基于规则的方法，但当多种共存技术同时使用时，这些方法往往效果不佳。因此，人们开始探索其他分类算法，这些算法采用特征检测或提取技术，例如循环平稳特征检测 [4], 。然而，这些技术需要领域专业知识，可能会导致解决方案复杂，而且往往难以扩展。近年来，研究人员转而采用深度学习技术，以减少对领域专业知识的需求 [3], [5], [6]。深度学习也已广泛应用于干扰抑制 [7]。

卷积神经网络（CNN）是一种无模型的深度学习方法，已被证明在图像分类和自然语言处理等多个领域行之有效。CNN已用于多种分类任务，包括协议/干扰分类 [3], [5], [6], [8]–[10], 、发射机分类 [11], 和调制分类 [12]。在无线通信应用中使用CNN或其他深度学习模型执行分类任务时，研究人员需要确保能够获取高质量的数据集和高效的模型。早期研究 [5], [6], [9] 着重于提升不同深度学习模型的分类性能，但数据集大小、所用CNN模型的复杂度与分类难度之间的关系，往往被忽视或想当然地认为已知。尽管许多研究人员会在训练过程中调整CNN的超参数，但通常并未探究滤波器尺寸、隐藏层中的节点数量等影响模型复杂度的其他因素。在物联网等资源受限应用中，过于复杂的CNN模型可能无法用于现实场景中的分类。这是因为物联网设备的处理能力和存储能力有限，可能因此面临性能、安全性、隐私和可靠性方面的挑战 [13], [14]。因此，必须了解如何依据模型复杂度、数据集大小和分类难度来选择超参数。

典型的卷积神经网络架构由一系列前馈层组成，这些层应用卷积滤波器和池化操作，随后是全连接层，将前面各层生成的二维特征图转换为用于分类的一维向量 [15]。卷积神经网络无需在使用前单独进行特征提取，但从头开始训练可能耗时且困难，因为构建和训练模型需要大量标注数据集 [16]。深度学习模型的复杂度会受到多种因素影响，例如层数、滤波器数量、滤波器大小以及隐藏层中的节点数量

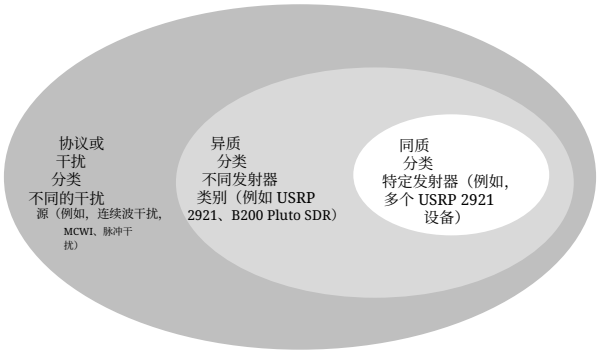


图1：干扰分类概览

。深度学习领域的研究人员通常致力于通过超参数调优和其他优化技术来提升模型性能。文献中，人们一直关注利用这些方法提高分类性能。尽管优化深度学习模型以提升性能十分重要，但无线通信文献对影响模型复杂度的因素缺乏全面分析。本文旨在通过全面且实证的方式，研究模型复杂度、数据集大小与分类难度之间的关系。据我们所知，这是最早研究这一关系的工作之一。

我们的贡献如下：

- 我们全面分析了三种不同卷积神经网络架构（简单、中等和复杂）的复杂度，并考察其与数据集大小和分类难度之间的关系。
- 我们通过实验表明，参数较少的简单 CNN模型，其性能可与更复杂的 CNN模型相媲美。这一点很重要，因为处理能力和存储能力有限的资源受限设备，可以从使用较简单的 CNN模型中受益。

II. 分类任务概述

本文中的干扰分类任务按图 1 所示的不同难度层级进行。在干扰或协议层级，卷积神经网络可用于区分不同协议或干扰源。在异构层级，卷积神经网络可用于区分不同的发射机类别。最后，在同构层级，卷积神经网络可用于区分特定发射器类别（同构类别），例如来自同一型号或制造商的发射机。最外层的分类最简单，最内层的分类最困难。

A. 发射机分类

大多数发射机都有各自独有的特征。例如，许多无线设备中的功率放大器在高功率运行时，有时会呈现非线性 [17] [18]。这些非线性可用于将发射机分为不同类别。我们简要讨论用于分类任务的发射机特征。

*1)*类别 *A (USRP 2921)*：与其他发射机类别相比，这些发射机采用了更可靠的线性功率放大器和更精细的滤波器。

2) 类别 *B (USRP B200)*：与类别 A 中的发射机相比，此类别发射机中的组件可靠性较低。其设计旨在满足低成本实验的需求。它们使用 $AD9364$ 的单条链路，这通常用于降低硬件和软件复杂度。

3) 类别 *C (Adalm Pluto SDR)*：此类别的发射机能力远不及另外两个类别。考虑到 Pluto SDR 体积小、成本低，它能够支持广泛而实用的 SDR 应用。

B. 分类层级

本节将讨论模型复杂度研究中开展的三个层级的分类实验。

1) 协议或干扰分类：协议或干扰级别的分类比本节讨论的另外两种分类更容易。这是因为，在这一层级上存在足够明显的区分特征。例如，在本文使用的射频干扰数据集中，所描述的三种干扰机之间存在显著差异。例如，将信号源与双音连续波相结合的 MCWI，其结构不同于 CI [19]。

2) 异质分类：本研究使用了上述第 II-A 节所列三类中的各一个发射器。虽然其中三个发射器中的两个（USRP 2921 和 USRP B200）由同一家公司（National Instruments）生产，但三者均属于不同型号。就难度而言，这种分类比同质分类（第 II-B3 节所述）更容易，但比第 II-B1 节所述的协议或干扰分类更困难。

3) 同质分类：在这一分类任务中，我们旨在区分 A、B 或 C 类中的发射机。这些发射机完全相同（制造商和型号相同），因此这是三个层级中最具挑战性的分类问题。这是因为分类算法必须识别具有相同架构和硬件组件的发射机之间的细微差异。所有设备发送的 OFDM 波形相同，这使分类变得更加复杂。

III. 卷积神经网络的实现细节

A. 用于模型复杂度分析的卷积神经网络参数

所采用的卷积神经网络算法是经过修改的*Tensorflow* CNN模型，用于对 MNIST 数据集中的手写数字进行分类。我们通过改变隐藏层中的节点数、滤波器数量以及训练数据集的大小，为 CNN模型设置了三个复杂度级别。这些因素都会影响模型中的参数数量。一般来说，

表 I：模型复杂度的卷积神经网络参数

参数	简单	中等	复杂
隐藏层中的节点层	0.26k	1.04k	8k
总计 数量 of 的参数整个网络	6.1k	48k	276k
滤波器尺寸（滤波器数量）	3*3（16）	3*3（32）	
批次大小	16		
层数	3		
步幅	2		
类别数	4（适用于同质设备） 3（适用于异质设备）		
学习率	0.0002		
最大池化尺寸	2 * 2		
丢弃概率	50%		
输入矩阵尺寸	38*100		
激活函数	ReLU		
优化器	使用交叉熵损失的Adam优化器		
Loss	交叉熵损失		
训练规模	16、64、256、1024、4096、8192、16384		
测试规模	2k		

CNN算法的复杂度会随着参数数量的增加而提高。随着卷积神经网络架构变得更加复杂，通常预期卷积神经网络算法的性能也会提升。然而，一个潜在的缺点是，算法可能会开始对训练数据过拟合，导致训练准确率高于测试准确率。

我们的网络包含三个卷积层、最大池化层和一个全连接层。 3×3 滤波器由卷积层应用于输入矩阵。在生成的子区域中执行卷积运算，从而在相应的输出特征图中产生一个值。为在模型中引入非线性，我们对特征图值应用尺度不变修正线性单元（ReLU）激活函数。

卷积层收集的数据通过池化层进行下采样。我们使用了 2×2 的最大池化函数。这意味着保留信号中最重要的特征，并删除其他特征 [20], , 从而有助于发射机分类。表 I 列出了三种设计中所有参数的具体信息。

表 II：用于干扰分类的卷积神经网络参数

参数	RESNet
批次大小	64
层数	18
学习率	0.0001
最大池化维度	2×2
激活函数	ReLU
训练集/测试集大小	80%/20%
丢弃概率	80%

B. 干扰分类的*CNN*架构

本节介绍用于干扰分类任务的 CNN 模型架构及训练参数。该 CNN模型是一个预训练的*ResNet18*模型，详见 [21]。其架构总结于表 II。模型由多个卷积层组成，依次为两个全连接层和一个输出层。Leaky ReLU（ Leaky ReLU(x) $= \max\{\alpha x, x\}$，其中$\alpha \in (0,1)$ 是预设参数）。所有卷积层和全连接层均采用带有$\alpha = 0.2$的激活函数。随后，对输出层应用 softmax函数。所有卷积层均进行批归一化 [22], , 但输出层和全连接层除外。此外，我们在卷积层中采用步幅 $= 2$而非 2×2池化层进行下采样。这些改动提升了性能，并降低了不同训练轮次之间结果的方差。x 归一化为 $x' = x/x_{\max}$，其中 $x_{\max}$ 是 x中允许的最大输入值。我们采用 Adam优化器，并使用 [23] 中建议的默认值。学习率为 1×10^{-4}，批次大小为 64。

IV. 实验设置

本节介绍用于研究数据集大小、模型复杂度和分类水平的数据集。值得注意的是，我们仅使用了公开可用的干扰分类数据集，而本文所述模型复杂度研究所用的数据集则由我们自己的测试平台生成。这是因为使用公开数据集存在一些限制，例如，我们无法控制用于产生干扰的发射机类型。此外，由于我们直接使用现成的数据集，因此无法更改传输所用的信道。

A. 为模型复杂度生成的数据集

用于评估模型复杂度的数据集生成过程与 [11] 中使用的过程类似。唯一的区别是，与 [11] 中的工作相比，我们增加了更多训练数据。我们将创建基带波形、通过信道传输并接收该波形的过程定义为发射机-接收机链路。需要注意的是，发射机-接收机链路的详细信息见 [11]。

1）基带波形生成：硬件设备通过 GNU Radio Companion 信号处理模块发送生成的 OFDM数据包。具体做法是从随机源生成由 0 和 1 组成的比特流。我们使用的 OFDM 波形从随机源接收 10,000 个数据比特，并使用 FFT 长度为 512 的 QPSK 调制方案将其映射到 OFDM 波形中，占用中心的 200 个子载波，循环前缀长度为 128。

2) 射频传输： 在传输过程中，GNU Radio 与发射器硬件通过 USRP硬件驱动程序（UHD）硬件支持包连接。所有 USRP 设备均通过名为 UHD 的库进行管理和通信。具体而言，使用一个 GNU Radio 模块，其输入参数包括采样率、射频带宽、缓冲区大小、中心频率、设备的物理地址以及衰减。随后，OFDM 波形被上变频至 2.45 GHz（即传输中心频率），并通过硬件的天线发射。发射器集合包括四台 USRP 2921、四台 USRP B200 以及四台 Adalm Pluto 软件定义无线电（SDR）。

表 III：比较　　各模型复杂度与设备类别的训练准确率和测试准确率　　ory

同质分类（USRP 2921）							同质分类（USRP B200）					
	简单卷积神经网络		中等卷积神经网络		复杂卷积神经网络		简单卷积神经网络		中等卷积神经网络		复杂卷积神经网络	
数据集 Size	训练 Acc	Test Acc	训练 Acc	Test Acc	训练 Acc	Test Acc	训练 Acc	Test Acc	训练 Acc	Test Acc	训练 Acc	Test Acc
16	1.00	0.407	1.00	0.406	1.00	0.408	1.00	0.502	1.00	0.492	1.00	0.544
64	0.996	0.545	1.00	0.563	1.00	0.568	0.988	0.567	1.00	0.608	1.00	0.591
256	1.00	0.660	1.00	0.688	1.00	0.694	0.996	0.623	1.00	0.658	1.00	0.652
1024	0.971	0.744	1.00	0.784	1.00	0.788	0.955	0.663	1.00	0.709	1.00	0.722
4096	0.947	0.807	0.99	0.836	1.00	0.829	0.900	0.806	0.995	0.821	1.00	0.826
8192	0.899	0.838	0.986	0.856	0.99	0.842	0.864	0.830	0.984	0.837	0.99	0.858
16384	0.88	0.860	0.975	0.862	0.99	0.876	0.856	0.843	0.971	0.860	0.97	0.870
同质分类（Adalm Pluto SDR）							异质分类					
	简单卷积神经网络		中等卷积神经网络		复杂卷积神经网络		简单卷积神经网络		中等卷积神经网络		复杂卷积神经网络	
数据集 Size	训练 Acc	Test Acc	训练 Acc	Test Acc	训练 Acc	Test Acc	训练 Acc	Test Acc	训练 Acc	Test Acc	训练 Acc	Test Acc
16	0.859	0.369	1.00	0.437	1.00	0.407	0.96	0.762	1.00	0.842	1.00	0.816
64	0.988	0.512	1.00	0.548	1.00	0.450	1.00	0.836	1.00	0.844	1.00	0.841
256	0.939	0.641	1.00	0.633	1.00	0.579	0.997	0.883	1.00	0.885	1.00	0.895
1024	0.862	0.700	0.993	0.689	1.00	0.673	0.99	0.913	1.00	0.920	1.00	0.919
4096	0.820	0.718	0.959	0.699	0.99	0.706	0.97	0.937	0.99	0.954	1.00	0.952
8192	0.775	0.736	0.901	0.738	0.96	0.718	0.98	0.955	0.986	0.958	1.00	0.968
16384	0.772	0.747	0.865	0.753	0.85	0.754	0.98	0.97	0.975	0.970	1.00	0.972

3) 射频接收：在接收端，当天线和发射器处于同一信道时，接收器即可接收信号。我们假设接收器已知发射器的中心频率和带宽，并在接收端校正频偏。发射信号的中心频率和采样率存储在 UHD USRP 信号源模块中，该模块由运行 GNU Radio Companion 的计算机使用，用于将信号下变频至基带频率。信号经过低噪声放大器后，在基带处分离为同相与正交分量。随后，信号经过低通滤波器处理，并传输至模数转换器（ADC）。ADC 处理完成后，数字采样被时钟同步并写入 FPGA。经过精确频率调谐进行数字下变频后，使用一系列滤波器对 FPGA 镜像进行抽取。借助 UHD，抽取后的原始采样通过主机接口（本例中使用千兆以太网链路）传输至主机。主机使用 GNU Radio 收集复数采样，并将 IQ 数据保存至文件，再传输至 MATLAB 进行进一步处理。

4）连续小波变换（*CWT*）信号预处理：CWT 突出了接收信号中可用于分类过程的特征。对于 CWT，使用 N 个样本为长度为 N 的信号生成一个由系数构成的 $M \times N$ 矩阵，其中 M 表示尺度数 [24]。尺度根据波长在频域和时域中的能量分布 [24] 自动确定。

使用 CWT MATLAB 函数对信号进行预处理，以增强接收信号中发射器的关键特性。信号转换后，将每个样本产生的大小为 $M \times N$ 的二维矩阵堆叠在一起，并作为三维矩阵发送至卷积神经网络分类器。本项目中，CWT 过程的输出维度为 38×100 的系数矩阵，而 CWT 的输入为 2×128。

B. 干扰分类数据集

1）射频干扰数据集：在这项工作中，我们使用公开可用的无线干扰数据集来评估我们的方法。本研究使用的 RFI 数据集由 [19] 的作者创建。他们通过在不同信噪比（SNR）下将目标信号（SOI）与三类干扰机（连续波干扰（CWI）、多连续波干扰（MCWI）和啁啾干扰（CI））相结合来创建该数据集。

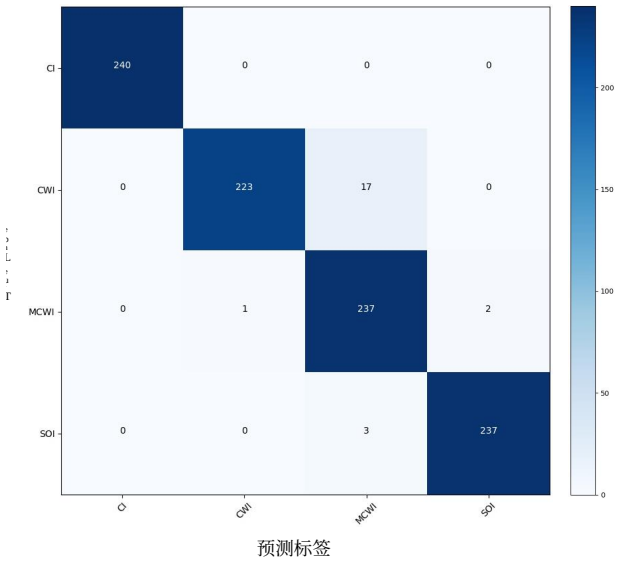
2）*CRAWDAD* 数据集：本文使用的第二个数据集取自达特茅斯大学无线数据存档社区资源（CRAWDAD）网站。该数据集由 Schmidt 等人提供 [3], , 包含不同信噪比下 IEEE 802.11b/g、IEEE 802.15.4 和蓝牙分组传输的记录，涵盖基带 [25], 以及基带中的频偏 [9]。该数据集共有 15 个不同类别，其中 10 个属于 IEEE 802.15.1 设备，3 个属于 IEEE 802.11 设备，其余 2 个属于 IEEE 802.15.4 设备。

V. 结果

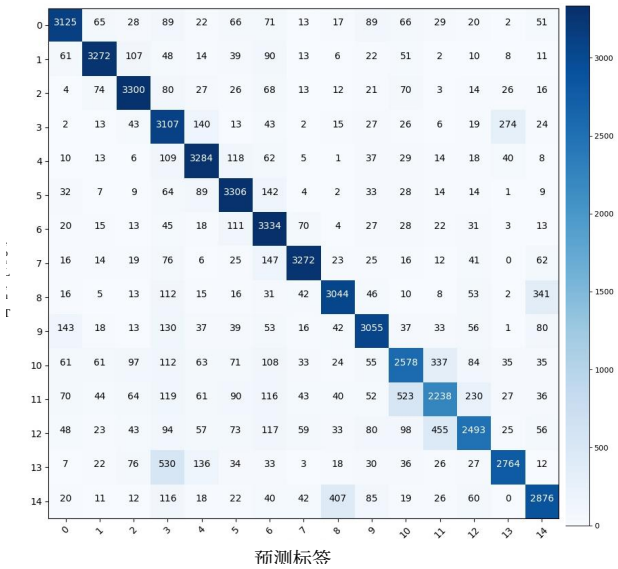
本节讨论模型复杂度和干扰分类研究的结果。模型复杂度研究十分重要，因为它们有助于理解分类性能与深度学习算法（本文使用的卷积神经网络）所采用参数数量之间的关系。需要指出的是，生成我们自己的数据集来研究模型复杂度，使我们能够改变数据生成过程中的不同条件，而这在公开可用数据集中无法实现。

A. 模型复杂度

本节考察了各种 CNN模型在不同设备类别上的表现。当测试准确率显著低于训练准确率时，说明该算法在训练集上表现良好，但在测试集上表现不佳，这表明出现了过拟合。为了使



（a）*RFI* 数据集的混淆矩阵。（分类准确率：97.8%）



（b）*CRAWDAD* 数据集的混淆矩阵（分类准确率-率：80%）

图 2：RFI 和 CRAWDAD 数据集的 CNN 分类混淆矩阵。

深度学习算法能够在新的、未见过的数据上表现良好，训练准确率和测试准确率应当相近。这表明该算法已经学会了良好的泛化。

表 III 比较了所有分类任务的训练准确率和测试准确率。在较小的数据集大小下，所有模型都倾向于出现明显的过拟合。然而，随着数据集大小增加，这些算法往往能够克服过拟合问题。对于大多数分类类别，过拟合问题都显著减少，训练准确率与测试准确率之间的差异保持在 5% 以内。当 CNN模型较为复杂、包含多个层和隐藏层中的许多节点时，通常会出现过拟合。为防止过拟合，可以使用随机失活 [26] 和提前停止 [27]等正则化技术。

图 3 表明，对于大多数发射机而言，尽管简单卷积神经网络的参数显著更少，但其性能与中等和复杂卷积神经网络相近。事实上，图 3d 显示，在数据集大小达到 100 后，对于异质发射机，简单卷积神经网络的性能与复杂卷积神经网络相当。尽管更复杂或更精密的 CNN模型可能带来一些益处，但必须在网络的泛化能力与其复杂性之间取得平衡。这些发现表明，深度学习模型既要简单又要稳健，这对于资源受限应用尤其如此。

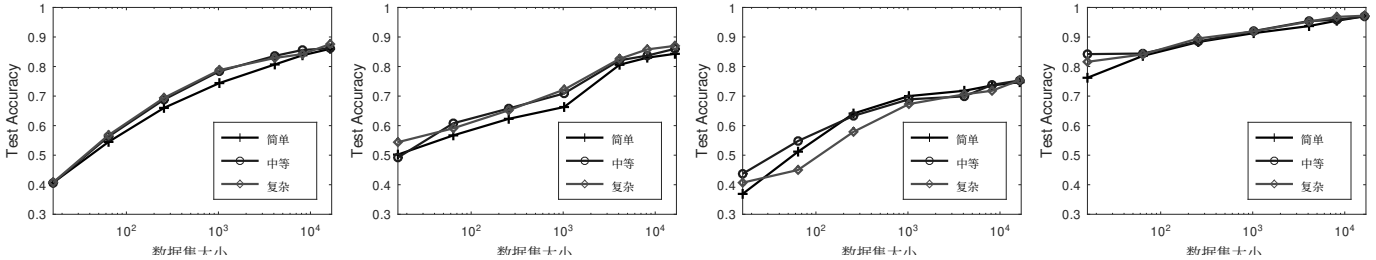
B. 干扰分类

对干扰源进行准确分类对于干扰抑制或缓解至关重要。使用预训练 ResNet18 模型，我们在 RFI 数据集上取得了 97.8% 的准确率，如表 II 所示。图 2a 显示了干扰类别的混淆矩阵，表明在这项相对简单的分类任务中，模型性能出色。对于在经过 25 个训练轮次后，CRAWDAD 数据集上的分类性能约为 80%，如图 2b 所示的混淆矩阵所示。

如第五节 A 部分所述，虽然复杂度更高的 CNN 模型往往在分类任务中表现更好，但通常也容易出现过拟合。当深度学习模型记住训练数据集时，就会发生过拟合，导致训练准确率很高，但测试或验证准确率较低。表 III 和图 3c 中 Pluto SDR 的结果均体现了这一点。这些结果进一步凸显了第五节 A 部分所讨论的模型复杂度研究结果的重要性。如前所述，复杂度较低的模型通常也能达到与复杂模型相当的表现，同时不会面临过拟合风险。因此，使用既不过于复杂也不过于简单的模型十分重要。可以从较简单的模型入手，根据需要逐步增加复杂度，并仅使用足以取得良好表现的二维卷积层和滤波器，从而确定恰当的复杂度。这有助于避免欠拟合和过拟合问题。

第六节. 结论

总之，本文全面研究了使用卷积神经网络进行干扰分类的方法。我们的结果表明，正如所使用的两个数据集所示，CNN模型能够准确地对不同干扰源进行分类。研究发现，尽管中等和复杂卷积神经网络分类器的表现略优于简单分类器，但性能差异并不显著。这一发现十分重要，因为资源受限设备可以轻松采用更简单的模型。在设计深度学习模型时，目标是创建能够应用于新数据的模型。简单模型更有可能做到这一点，



（a）USRP 2921　（b）USRP B200　(c) Pluto SDR　(d) 异质

s

Fig. 3：同质与异质发射机类别的测试准确率比较

因为它们不易出现过拟合，而过拟合是复杂模型常见的问题。不同的分类任务（例如同质分类和异质分类）可能需要不同数量的数据以及不同程度的模型复杂度。在我们的研究中，训练数据集大小和隐藏层中的节点数量对CNN模型性能的影响最大。虽然数据集大小很重要，但我们还注意到，训练数据集的质量也会显著影响CNN分类器的性能。

致谢

本研究部分由美国空军研究实验室 (AFRL) 的 FA8750-20-2-0504号资助、洛克希德·马丁公司 M16-005-RPP010号资助，以及美国国家科学基金会的 CNS-1564148号资助提供支持。

参考文献

[1] L. Qiu、Y. Zhang、F. Wang、M. K. Han 和 R. Mahajan，“无线干扰的一般模型”，载于第*13*届*ACM*移动计算与网络年度国际会议论文集，第171–182页，2007年。[2] J. Bruno，“无线网络中的干扰降低”，计算研究专题，维拉诺瓦大学计算科学系，2007年。[3] M. Schmidt、D. Block 和 U. Meier，“使用卷积神经网络识别无线干扰”，载于*2017*年*IEEE*第*15*届工业信息学国际会议（*INDIN*），第180–185页，IEEE，2017年。[4] K. Kim、I. A. Akbar、K. K. Bae、J.-S. Um、C. M. Spooner 和 J. H. Reed，“认知无线电中的信号检测与分类循环平稳方法”，载于*2007*年第二届*IEEE*动态频谱接入网络新前沿国际研讨会，第212–215页，IEEE，2007年。[5] J. Yu、M. Alhassoun 和 R. M. Buehrer，“使用深度神经网络进行干扰分类”，*arXiv*预印本 *arXiv:2002.00533*，2020年。[6] J. Kim、S. Lee、Y.-H. Kim 和 S.-C. Kim，“使用卷积神经网络对汽车雷达系统的干扰信号进行分类”，*IEEE Access*，第8卷，第176717–176727页，2020年。[7] T. Oyedare、V. K. Shah、D. J. Jakubisin 和 J. H. Reed，“使用深度学习进行干扰抑制：当前方法与尚待解决的挑战”，*IEEE Access*，2022年。[8] Y. Zhao、W.-C. Wong、H. K. Garg、T. Feng、Z. Zhang 和 L. Tang，“使用嵌套LSTM网络进行室内位置识别与干扰分类”，载于*2019*年*IEEE*全球通信大会（*GLOBECOM*），第1–6页，IEEE，2019年。[9] S. Grunau、D. Block 和 U. Meier，“使用卷积神经网络进行多标签无线干扰识别”，*arXiv*预印本 *arXiv:1804.04395*，2018年。

[10] K. Sankhe、M. Belgiovine、F. Zhou、S. Riyaz、S. Ioannidis 和 K. Chowdhury，“Oracle：通过卷积神经网络实现优化无线电分类”，载于*IEEE INFOCOM 2019*——*IEEE*计算机通信会议，第370–378页，IEEE，2019年。[11] T. Oyedare 和 J.-M. J. Park，“使用深度学习估算发射机分类所需的训练数据集大小”，载于*2019*年*IEEE*动态频谱接入网络国际研讨会（*DySPAN*），第1–10页，IEEE，2019年。[12] T. J. O’Shea、J. Corgan 和 T. C. Clancy，“卷积无线电调制识别网络”，载于神经网络工程应用国际会议，第213–226页，施普林格，2016年。[13] H. F. Atlam、R. J. Walters 和 G. B. Wills，“雾计算与物联网：综述”，大数据与认知计算，第2卷，第2期，第10页，2018年。[14] F. Pereira、R. Correia、P. Pinho、S. I. Lopes 和 N. B. Carvalho，“资源受限物联网设备面临的挑战：能源与通信是未来物联网部署的关键成功因素”，传感器，第20卷，第22期，第6420页，2020年。[15] D. Rav`ı、C. Wong、F. Deligianni、M. Berthelot、J. Andreu-Perez、B. Lo 和 G.-Z. Yang，“健康信息学中的深度学习”，*IEEE*生物医学与健康信息学杂志，第21卷，第1期，第4–21页，2016年。[16] H. Mohsen、E.-S. A. El-Dahshan、E.-S. M. El-Horbaty 和 A.-B. M. Salem，“使用深度学习神经网络对脑肿瘤进行分类”，未来计算与信息学期刊，第3卷，第1期，第68–71页，2018年。[17] F. Edalat，功率放大器非线性对系统性能指标误码率（*BER*）的影响。博士论文，麻省理工学院，2003年。[18] A. C. Polak、S. Dolatshahi 和 D. L. Goeckel，“通过发射机缺陷识别无线用户”，*IEEE*通信领域精选期刊，第29卷，第7期，第1469–1479页，2011年。[19] S. Ujan、N. Navidi 和 R. Jr Landry，“利用端到端迁移学习高效识别并表征射频干扰（RFI）”，应用科学，第10卷，第19期，第6885页，2020年。[20] W. Wang、Y. Ning、H. Rangwala 和 N. Ramakrishnan，“用于识别关键句和检测事件的多示例学习框架”，载于第*25*届*ACM*信息与知识管理国际会议论文集，第509–518页，2016年。[21] K. He、X. Zhang、S. Ren 和 J. Sun，“用于图像识别的深度残差学习”，载于*IEEE*计算机视觉与模式识别会议论文集，第770–778页，2016年。[22] S. Ioffe 和 C. Szegedy，“批归一化：通过减少内部协变量偏移加速深度网络训练”，*arXiv*预印本 *arXiv:1502.03167*，2015年。[23] D. P. Kingma 和 J. Ba，“Adam：一种随机优化方法”，*arXiv*预印本 *arXiv:1412.6980*，2014年。[24] “基于CWT的时频分析。”
h
t
t
p
s://
w
w
w.
m
a
t
hworks.co
m/help/wavelet/examples/cwt-based-time-frequency-analysis.html。[25] M. Schmidt、D. Block 和 U. Meier，“CRAWDAD 数据集 OWL/干扰（v. 2019年2月12日）。”下载自 https://crawdad.org/owl/interference/20190212，2019年2月。[26] L. Xie、J. Wang、Z. Wei、M. Wang 和 Q. Tian，“Disturblabel：在损失层对CNN进行正则化”，载于*IEEE*计算机视觉与模式识别会议论文集，第4753–4762页，2016年。[27] X. Ying，“过拟合及其解决方案概述”，载于物理学杂志：会议系列，第1168卷，第022022页，IOP出版社，2019年。