

引用格式:张乃煜,张雅彬,查浩然. 基于深度复数脉冲神经网络的特定辐射源识别[J]. 信息对抗技术, 2025, 4(1):52-60. [ZHANG Naiyu, ZHANG Yabin, ZHA Haoran. Specific emitter identification based on deep spiking complex neural network[J]. Information Countermeasure Technology, 2025, 4(1):52-60. (in Chinese)]

基于深度复数脉冲神经网络的特定辐射源识别

张乃煜,张雅彬,查浩然*

(哈尔滨工程大学信息与通信工程学院,黑龙江哈尔滨 150001)

摘要 特定辐射源识别在民用频谱管理中起着重要作用。传统的深度神经网络方法在辐射源识别方面面临诸多挑战,包括训练时间长、能耗高以及计算稀疏性低。针对这些问题,设计了一种基于深度复数脉冲神经网络模型,该模型集成了脉冲神经层,并利用复数数据的固有特性增强信号表达能力,显著优化了计算效率并降低了硬件资源需求。测试结果表明,该模型的识别准确率达到96%,单条数据的平均推理时间为0.19 ms,在模型参数规模、推理速度和推理数据能量消耗上均优于传统神经网络模型。

关键词 特定辐射源识别;脉冲神经网络;复数神经网络;Wi-Fi信号

中图分类号 TN 911.2 **文章编号** 2097-163X(2025)01-0052-09

文献标志码 A **DOI** 10.12399/j.issn.2097-163x.2025.01.004

Specific emitter identification based on deep spiking complex neural network

ZHANG Naiyu, ZHANG Yabin, ZHA Haoran*

(College of Information and Communication Engineering, Harbin Engineering University, Harbin 150001, China)

Abstract Specific emitter identification (SEI) plays a crucial role in civilian spectrum management. Traditional deep neural network methods face many challenges in emitter identification, including extended training duration, high energy consumption, and low computational sparsity. To address these issues, a deep spiking complex neural network (S-CNet) model was designed, which integrates pulse neural layers and utilizes the intrinsic properties of complex data to enhance signal representation capabilities, significantly optimizing computational efficiency and reducing hardware resource requirements. The test results have shown that the recognition accuracy of this model reaches 96%, the average inference time for a single piece of data is 0.19 ms, and it is superior to the traditional neural network models in terms of model parameter scale, inference speed, and inference data energy consumption.

Keywords SEI; spiking neural network; complex neural network; Wi-Fi signals

0 引言

特定辐射源识别,通常被称为辐射源“指纹识别”,是一种通过从捕获的电磁信号中提取独特特征,并利用先验知识准确定位发射源来识别特定辐射源的技术。这种识别技术的关键在于射频指纹,射频指纹是由于硬件制造过程中不可避免的差异而产生的独特标识,这些标识具有不可避免且难以复制的特性^[1]。射频指纹技术可以追溯到 TOONSTRA 等^[2]在 1995 年引入的瞬态信号特征提取,当时的研究主要集中在基于瞬态特征^[3]的个体识别领域。信道噪声和设备硬件的可变性等因素对从开/关瞬态中提取可辨别特征的能力产生了极大的挑战。基于稳态特征的识别^[4]方法需要专家知识进行人工特征提取,涉及领域变换的技术,如 HALL 等^[5]通过信号的小波域特征实现了特定辐射源识别;SUSKI 等^[6]使用包络特征完成了个体识别;瞬时相位分析同样也被 HALL 等^[7]用来进行个体识别,并显示出良好的性能。

随着物联网技术的快速发展,传统的识别方法已经难以满足日益增长的设备多样性和数量,以及对广泛数据处理和实时性能的需求^[8]。研究人员转向利用人工智能技术,特别是深度学习方法^[9]。卷积神经网络(convolutional neural network, CNN)^[10]、生成对抗网络(generative adversarial network, GAN)^[11]和循环神经网络(recurrent neural network, RNN)^[12]等模型,在射频指纹提取和特定辐射源识别方面已取得显著成果。然而,深度神经网络在功耗效率、安全性、可解释性和在线学习能力等方面仍面临挑战。为了在一些能量资源、算力资源受限的条件下部署网络,研究人员对网络进行轻量化却无法表现出良好的识别效果,这限制了人工神经网络的更广泛应用。大脑作为自然界最复杂的智能实体,仍然是人工智能研究的关键参考对象。近年来,随着神经科学和人工智能的相互促进,类脑计算领域得到了快速发展。类脑计算研究的核心是脉冲神经网络(spiking neural network, SNN),其拥有最类似大脑的运行机制,被认为是下一代神经网络模型。SNN 利用具有记忆功能的神经元模型,如霍奇金-赫胥黎模型^[13]和 LIF

(leaky integrate-and-fire)模型^[14]等在提取时空特征方面表现出色,功耗更低,且非常适合并行计算应用。SNN 已成功应用于视觉处理、系统控制和医疗诊断等领域。

为了解决传统深度神经网络在辐射源识别中所面临的推理时间长、功耗高和计算稀疏性低的问题,本文提出了一种结合复数神经网络(complex neural network)和脉冲神经网络优势的新型深度复数脉冲神经网络(spiking complex neural network, S-CNet)模型。该模型通过引入二进制脉冲神经层,显著减少了硬件部署的计算和存储需求。使用实采 Wi-Fi 信号数据集进行的实验验证表明,该模型在识别准确率、推理时间和功耗方面优于传统的轻量级网络模型。

1 网络模型

1.1 LIF 模型

由于在精确量化各种神经元参数方面十分困难,传统模型常常无法充分表征生物神经元的精细行为。因此,研究人员将视角转向动态系统,构建了简化但又具有生物基础的神经模型。其中,LIF 模型是一个显著的例子,它具有 3 个主要特征:“leaky”表示在低于阈值输入存在时,膜电位将会由于跨膜持续的离子交换逐渐返回到静息状态;“integrate”表示在轴突末端累积输入信号的效应;“fire”表示当膜电位超过阈值时发生脉冲,此时神经元处于激活状态。激活后,神经元进入超极化阶段,随后进入不应期,在此期间对其他输入刺激保持不响应状态,从而保持其静息电位。通过线性微分方程描述为:

$$\tau_m \frac{dV(t)}{dt} = V_{\text{rest}} - V(t) + R_m I(t) \quad (1)$$

式中, τ_m 为膜时间常数, V_{rest} 为静息膜电位, $V(t)$ 为 t 时刻的膜电位, R_m 为膜电阻, $I(t)$ 为输入电流。

受到刺激后,神经元将经历一种类似于电容电阻电路的充电和放电过程,导致突触处的膜电位持续累积。当达到特定阈值时,LIF 神经元产生一个尖峰,这个尖峰产生过程如图 1 所示,由以下点火函数方程描述:

$$y^{(n+1)} = \begin{cases} 1, & \text{if } x_{\text{pre}}^{(n+1)} > U_{\text{th}} \\ 0, & \text{else} \end{cases} \quad (2)$$

式中, $y^{(n+1)}$ 为 LIF 神经元的脉冲输出, $x_{\text{pre}}^{(n+1)}$ 为突触处的膜电位, U_{th} 为膜电位阈值电压。

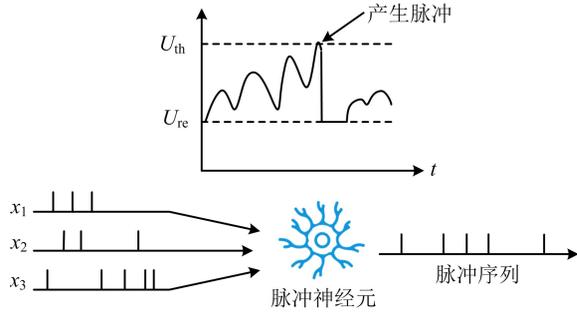


图1 LIF模型

Fig.1 LIF model

1.2 复数神经网络

虽然 CNN 在许多领域的深度特征学习能力得到了广泛认可,但在复数数据集上的表现受到实值表示和操作的固有限制。从信号处理的角度来看,复数数据包含更多信息,与实数数据相比具有更优的表达能力。这种优势使得复数神经网络在信号处理中的应用越来越广泛,输入数据在复数域内能自然地解释^[15]。

本文采用的深度复数网络通过计算电磁目标的复值向量(表示为 $\mathbf{h} = \mathbf{a} + j\mathbf{b}$)与深度复数网络模块的权重矩阵(表示为 $\mathbf{W} = \mathbf{X} + j\mathbf{Y}$)的内积来提取电磁目标的特征。

$$\mathbf{W} \cdot \mathbf{h} = (\mathbf{X} \cdot \mathbf{a} - \mathbf{Y} \cdot \mathbf{b}) + j(\mathbf{Y} \cdot \mathbf{a} + \mathbf{X} \cdot \mathbf{b}) \quad (3)$$

式中, \mathbf{X} 和 \mathbf{Y} 为实矩阵, \mathbf{a} 和 \mathbf{b} 为实向量。

批归一化处理可以用于优化模型以及提升神经网络的训练速度。它的标准公式一般只适用于实数值,因此,本文采用了可以适用于

复数值的批归一化标准公式。

设输入的数据为 x ,那么这一步骤可以采用数据 $(x - E[x])$ 乘以协方差矩阵 \mathbf{V} 的平方根的倒数来计算:

$$\tilde{x} = (\mathbf{V})^{-\frac{1}{2}} (x - E[x]) \quad (4)$$

式中,数据 $(x - E[x])$ 以 0 为中心,协方差矩阵 \mathbf{V} 为 2×2 维,具体为:

$$\begin{aligned} \mathbf{V} &= \begin{bmatrix} V_{RR} & V_{RI} \\ V_{IR} & V_{II} \end{bmatrix} \\ &= \begin{pmatrix} \text{Cov}(R\{\mathbf{x}\}, R\{\mathbf{x}\}) & \text{Cov}(R\{\mathbf{x}\}, I\{\mathbf{x}\}) \\ \text{Cov}(I\{\mathbf{x}\}, R\{\mathbf{x}\}) & \text{Cov}(I\{\mathbf{x}\}, I\{\mathbf{x}\}) \end{pmatrix} \end{aligned} \quad (5)$$

式中, $R\{\cdot\}$ 表示提取批数据的实部, $I\{\cdot\}$ 表示提取批数据的虚部。

γ 所需要的方差通过所需的主分量进行缩放输入信号来计算,缩放参数矩阵 γ 具体为:

$$\gamma = \begin{bmatrix} \gamma_{RR} & \gamma_{RI} \\ \gamma_{RI} & \gamma_{II} \end{bmatrix} \quad (6)$$

因为归一化输入的实部和虚部的方差为 1,将 γ_{RR} 和 γ_{II} 的初始值都设置为 $1/\sqrt{2}$,这样可以保证归一化值的方差模数为 1,并且设置 γ_{RI} 、 $R\{\beta\}$ 和 $I\{\beta\}$ 初始化为 0,复数值的批归一化表示为:

$$B_{BN}(\tilde{x}) = \gamma \tilde{x} + \beta \quad (7)$$

2 系统设计

本文所描述的模型总体框架如图 2 所示。

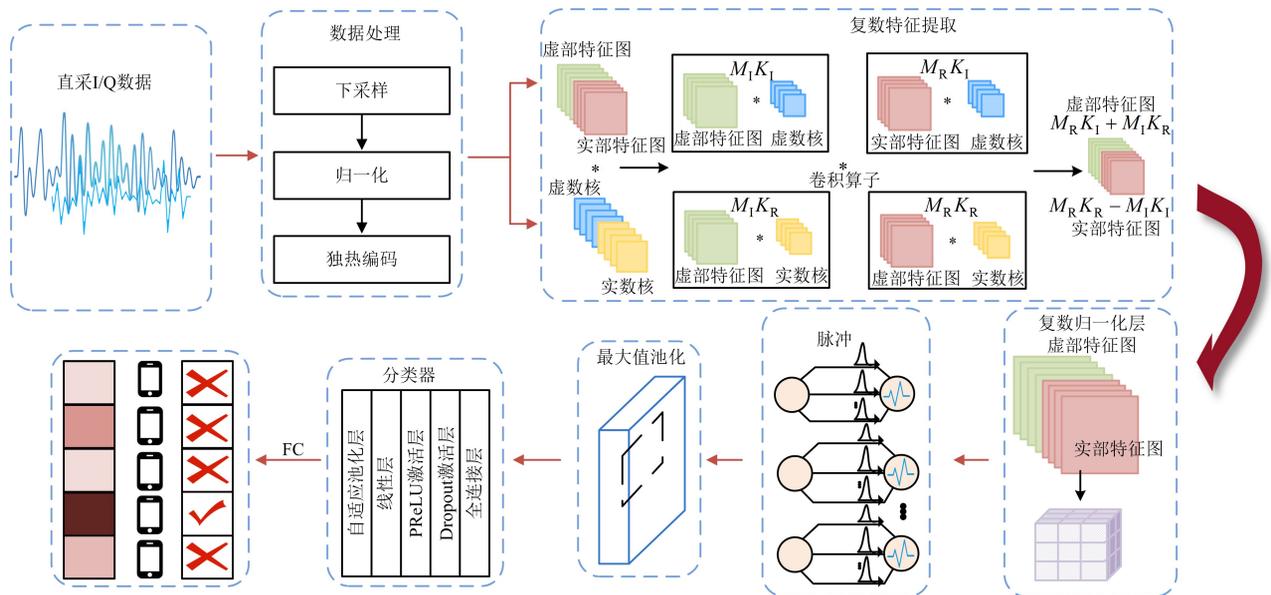


图2 模型总体框图

Fig.2 The overall schematic diagram of the model

2.1 脉冲复数神经网络

SNN 神经元的复杂动态行为和时间敏感性对训练算法开发产生了巨大挑战,目前这一领域的研究仍处于初级阶段^[16]。但利用成熟的人工神经网络(artificial neural network, ANN)训练算法,将 ANN 转换为 SNN 的策略正在兴起。这一转换过程主要是采用已验证的 ANN 技术来训练深度神经网络,随后通过频率编码的方式,将基于 ReLU 的激活输出转换为 SNN 中的 I&F 神经元尖峰率,从而简化 ANN 到 SNN 的过渡,绕过直接训练 SNN 的难题^[17]。

在此理论基础上,本文介绍了一种新颖的网络结构 S-CNet,这是一种基于复数神经网络原理构建的脉冲神经网络。S-CNet 网络独特地融合了脉冲驱动的复数神经块,提出了一种创新的处理复数信号序列方法。

S-CNet 网络架构集成了复数脉冲神经块和特定的分类器。首先,通过下采样、归一化和独热编码处理 I/Q 信号序列;其次,将数据输入到复数卷积层中进行特征提取,此层将同时处理信号的实部和虚部,特征提取完成后,数据的实部和虚部分别进行复数批归一化,这一步骤旨在提升网络学习效率并防止梯度消失或爆炸;然后,特征图进入由 LIF 神经元构建的脉冲神经层,转换为稀疏脉冲序列,实现高效的信号表达;接着,数据将通过网络最大池化层,以达到进一步降低网络复杂性并加速计算的目的;最后,一个由自适应池化层、线性层、PReLU 激活层、Dropout 层和全连接层组成的分类器负责对提取的高维度特征进行识别分类。全连接层利用信号分量和权重的交叉乘积,并将结果映射到相应的标签上。整个网络识别过程概述在算法 1 中。

算法 1 S-CNet 模型

输入:训练集 Train,训练批次大小 M ,训练迭代次数,学习率,测试集 Test

1. 数据下采样,数据归一化;
2. 随机抽取训练集 Train 中的样本;
3. 将大小为 M 的训练批次输入网络进行训练;
4. for layer=1, ..., L do
5. for $m=1, \dots, M$ do
6. 根据式(3),得到数据特征;
7. 特征进行归一化;
8. 根据式(2),得到稀疏脉冲序列;

9. 最大池化;
10. end for
11. end for
12. 数据分类器;
13. 输出类别标签;
14. 通过交叉熵损失函数计算损失值;
15. 反向传播,使用 SGD 优化算法更新网络参数;
16. 重复 3~16,判断是否达到设置的训练迭代次数;
17. 得到 S-CNet 模型参数;
18. 输入测试集 Test 测试;
19. 输出:识别准确率,混淆矩阵。

2.2 模型正则化

虽然 LIF 模型可以为输入信号的时域特征建模并输出稀疏的脉冲序列,但其最致命的问题在于点火函数的输出是离散且不可微分的^[18]。点火函数可以视为符号函数的一个变种,其导数在几乎所有地方都是 0,这使得基于梯度的优化变得不可能^[19]。在脉冲神经网络中,计算损失相对于权重参数的梯度可以使用链式法则计算:

$$\frac{\partial L}{\partial \mathbf{W}} = \sum_{n=1}^T \left(\frac{\partial L}{\partial y^{(n)}} \frac{\partial y^{(n)}}{\partial x_{\text{pre}}^{(n)}} \frac{\partial x_{\text{pre}}^{(n)}}{\partial \mathbf{c}^{(n)}} \frac{\partial \mathbf{c}^{(n)}}{\partial \mathbf{W}} \right) \quad (8)$$

式中, L 为损失函数, \mathbf{W} 为权重矩阵, $\mathbf{c}^{(n)}$ 为链式求导法则的过渡参数, $y^{(n)}$ 为脉冲神经层的输出, $x_{\text{pre}}^{(n)}$ 为脉冲神经层的输入, $\frac{\partial y^{(n)}}{\partial x_{\text{pre}}^{(n)}}$ 为点火函数的梯度。

除了 $\frac{\partial y^{(n)}}{\partial x_{\text{pre}}^{(n)}}$ 项导致 0 梯度外,其他部分可以使用梯度进行优化。为了解决这个问题,将使用替代梯度函数来规避 0 梯度问题。本文将采用三角形梯度,其公式为:

$$\frac{\partial y^{(n)}}{\partial x_{\text{pre}}^{(n)}} = \max\left(0, 1 - \left| \frac{y_{\text{pre}}^{(n)}}{U_{\text{th}}} - 1 \right| \right) \quad (9)$$

采用三角形梯度后,脉冲神经网络可以继续使用随机梯度下降法来优化权重。

3 实验测试与分析

3.1 数据与实验设置

本文将利用真实世界采集的 Wi-Fi 信号来验证所提出方法的可行性,Wi-Fi 信号的数据采集工作主要在微波暗室环境中开展,重点聚焦于视距无线传输信道(line of sight, LOS)。采集设备涵盖了 FSQ、FSW26 和 FSV13 频谱分析仪。Wi-Fi 辐射源包括 298 台在 2.4 GHz 频段工作的发射机以及 100 台在 5 GHz 频段工作的发射机,

这些辐射源的信号类型均为 Wi-Fi 信号。在信道 1 和 6 上,分别以 40 MHz 和 80 MHz 的采样率对信号进行采集。从数据集中选取 5 台发射机信号进行实验,发射机编号分别为 0、1、2、3、4,每台发射机信号在相同的信噪比条件下,包含 400 个样本,共计 2 000 个样本。

本文在基于 PyTorch 构建的框架上验证 S-CNet 模型,实验在 NVIDIA RTX 3090 GPU 上运行。实验主要参数设置见表 1 所列。

表 1 主要参数设置

Tab. 1 Main parameter settings

超参数	参数选择
训练轮数	100
Batch size	64
优化器	SGD
触发阈值	0.5
衰减因子	0.75
梯度代替函数	三角形梯度

3.2 不同模型对 Wi-Fi 数据识别结果对比分析

为了评估所提方法在 5 类 Wi-Fi 信号上的识别性能,本文选择了 ComplexNet、ResNet、ShuffleNet 和 MobileNet 作为比较模型。本文以混淆矩阵的形式呈现 S-CNet 对 5 类 Wi-Fi 信号的识别结果,如图 3 所示。从图中可以看出,模型在识别类别 1 和类别 3 上表现非常好。除了类别 0 和类别 4 之间存在一定程度的混淆外,模型在其他类别上的表现相对稳定,没有出现大范围的误分类。5 个网络的识别比较结果如图 4 所示,模型对 100 条数据进行识别所用推理时间与能量消耗对比如图 5 所示。

仅从识别准确率的角度考虑,本文提出的网络模型在 20 dB 的信噪比环境下对 Wi-Fi 信号的识别率均为 90% 以上,表现出优异的识别效果。此外,所提出的网络识别性能优于 ShuffleNet 和 MobileNet 2 种主流轻量级网络模型。这主要得益于复数神经网络中的复数卷积层可以提取不同时刻下 I/Q 不同通道采样点关联特征,而实数神经网络不具备此功能,使得实数神经网络的特征提取能力相较于复数神经网络有所下降。同时,通过脉冲神经元输出生成的稀疏输入特征,增强了模型的生物学合理性和计算效率。虽然 ComplexNet 的识别准确率与所提出的方法相

近,但其参数数量远远多于所提方法,且其推理速度最慢。同时,ShuffleNet 和 MobileNet 2 个主流轻量级网络的参数数量也比所提方法多。虽然它们的推理速度比 ComplexNet 和 ResNet 快,但仍稍慢于所提方法。因此,所提方法更适合于资源有限和处理器性能较低的实时处理平台。

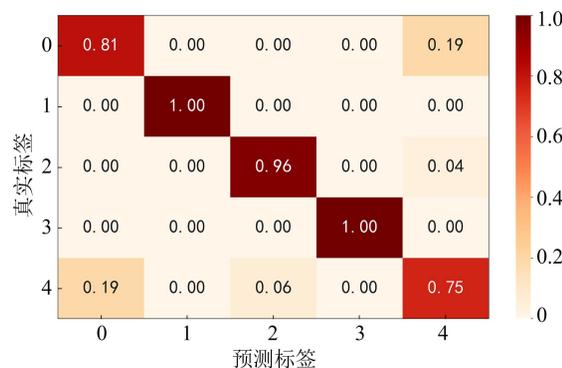


图 3 S-CNet 识别结果图

Fig. 3 Recognition results of the S-CNet

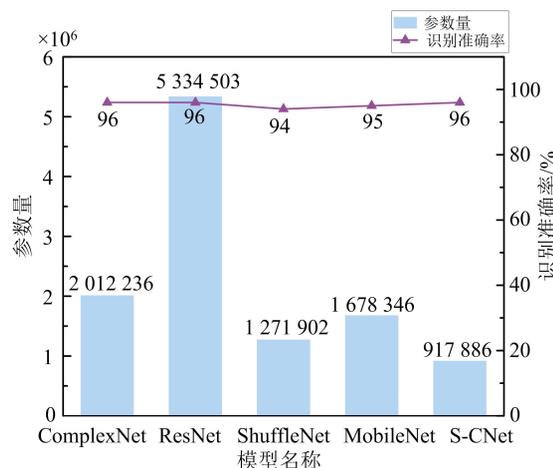


图 4 不同模型参数量与识别率对比图

Fig. 4 Comparison of parameters and recognition rates for different models

接下来,分析不同模型在推理数据过程中的能量消耗。一般的神经网络部署在硬件设备上时,处理的数据通常为浮点型,卷积运算主要通过高功耗的乘积累加运算完成,而本文所提网络处理的数据为二进制稀疏序列,仅包含数值 0 和 1,因此高功耗的乘累加运算就可以通过低功耗的累加计算完成。假设在 45 nm 的硬件上,每进行一次乘积累加运算需消耗 4.6 pJ 的能量,而一次累加运算仅需消耗 0.9 pJ^[20]。本实验计算不同模型对 1 条数据的推理能量消耗,实验结果如图 5 所示。实验结果表明,在 20 dB 的信噪比下,

虽然不同网络模型的识别准确率相差不大,但本文所提方法推理 1 条数据消耗的能量只有 0.11 mJ,约为复数网络能量消耗的 1/21,显著低于轻量化网络 ShuffleNet 和 MobileNet 的能量消耗。这一实验结果表明,本文所提方法能大幅降低神经网络在硬件设备上的能量消耗。

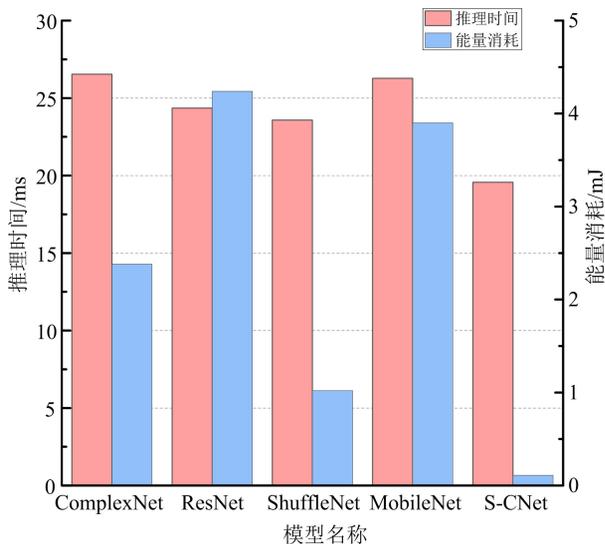


图 5 不同模型推理时间与能量消耗对比图

Fig. 5 Comparison of inference time and energy consumption for different models

3.3 模型鲁棒性分析

3.3.1 基于 Wi-Fi 信号数据的鲁棒性测试

鲁棒性是衡量深度学习模型的一项重要评价指标,主要用于检验模型在面对输入数据的微小变动时,是否能保持判断的准确性,从而反映模型在一定变化条件下的表现稳定性。鲁棒性的强弱直接影响深度学习模型的泛化能力。

为了验证所提方法的鲁棒性,本文首先使用从真实世界采集的多种信号数据集进行测试。加性高斯白噪声下的信号识别是多年来研究的经典问题,本研究测试了模型在不同信噪比条件下的性能,所用的数据为 Wi-Fi 数据,结果如图 6 所示。S-CNet 模型在高信噪比下展现出优异的性能,随着信噪比的提高,模型的识别准确率会逐渐趋于稳定,特别是信噪比在 20 dB 时,达到了 96% 的识别准确率。当信噪比大于 0 dB 时,模型能够达到良好的识别效果,即使在信噪比降至 -4 dB 时,模型仍能达到 72% 的识别准确率。而 ShuffleNet 和 MobileNet 2 个主流轻量级网络在高信噪比时识别效果良好,识别准确率与本文所

提方法相近。但是当信噪比下降时,ShuffleNet 和 MobileNet 识别准确率快速下降,对噪声敏感,模型鲁棒性差。与结构复杂的 ComplexNet 与 ResNet 相比,所提方法在信噪比大于 0 dB 时的识别准确率都约为 90%,在低信噪比时的识别准确率相近。尽管网络结构相对简单,但是 S-CNet 通过利用复数数据的强大表征能力,显著提升了信号的识别精度,表现出良好的鲁棒性。

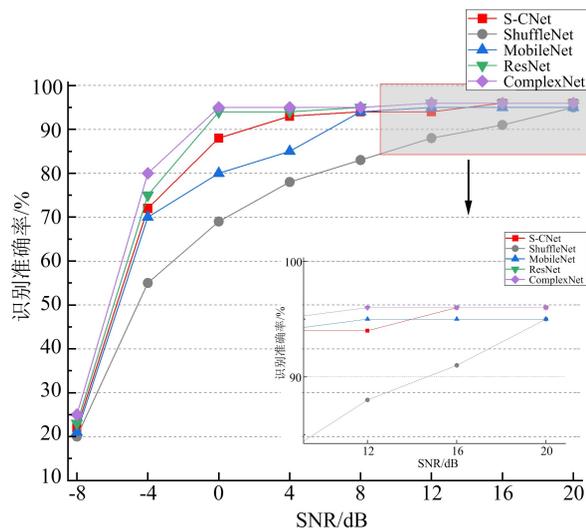


图 6 不同信噪比下识别结果图

Fig. 6 Recognition results under different signal-to-noise ratios

同时,在前面实验的基础上,我们将实验所选用的发射机数量由 5 台依次增加到 10 台。实验结果如图 7 所示,表明随着类别数量的增加,模型的识别准确率会下降。

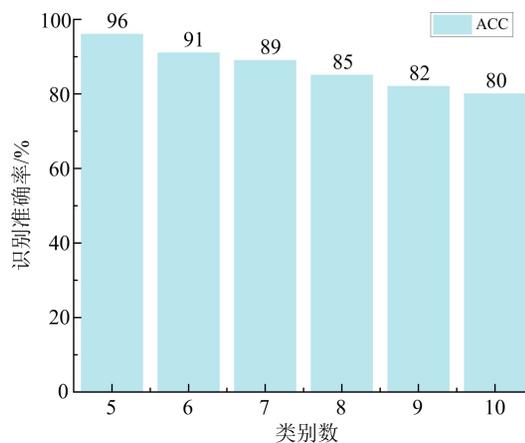


图 7 不同类别下识别结果图

Fig. 7 Recognition results under different categories

对于具有 10 个类别的 Wi-Fi 信号识别,识别准确率仅为 80%。这是因为当类别数量增加时,模型需要区分更多的类别,这对模型的容量和复

杂性提出了更高的要求。如果模型的容量不足,它将无法很好地区分所有类别,从而导致识别准确率下降。

3.3.2 多信号数据集的综合鲁棒性分析

本文使用了不同的信号数据集来验证所提方法的鲁棒性。所使用的数据集包括 ADS-B (automatic dependent surveillance-broadcast) 信号数据集、Wi-Fi 信号数据集和射频信号 (radio frequency fingerprint, RFF) 数据集。实验中使用的数据集由 20 dB 下 5 个辐射源类别的实采信号组成。作为空中监视领域的关键技术之一,ADS-B 信号是飞机通过固定数据链路向外部源传输重要的信息,如高度、速度、纬度和经度。接收这些数据的其他飞机可以定位目标进行信息交换,从而实现空域监视。RFF 信号是依据 5G NR 协议生成的物理上行链路共享信道信号和上行信道探测参考信号。实验结果如图 8 所示。结果显示,所提方法在 3 个数据集上都取得了良好的结果,在辐射源个体识别方面表现出良好的鲁棒性。

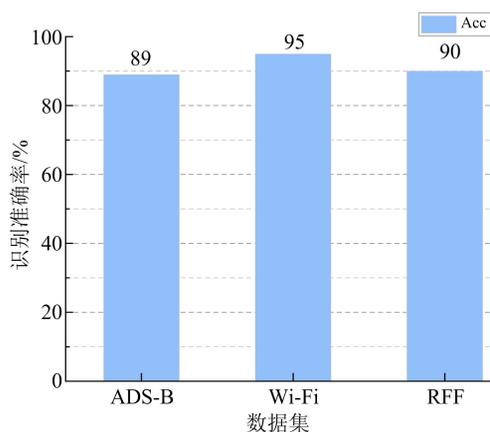


图 8 不同数据集下识别结果图

Fig. 8 Recognition results under different datasets

为了进一步验证方案的鲁棒性,本文构建了一个与 S-CNet 具有相同卷积层数的基于脉冲神经网络的卷积神经网络 (SCNN)。为了与一种基于轻量网络模型的特定辐射源识别方法进行比较,我们选择使用交替剪枝的 CNN (CNN-Alternate Pruning)^[21] 与所提方法进行对比,实验结果如图 9 所示。实验结果表明,虽然 S-CNet 与 SCNN 在高信噪比下识别效果相近,识别准确率均为 90% 以上,但是随着信噪比的下降,S-CNet 的识别准确率比较稳定,变化幅度小,而 SCNN 的识别性能受到噪声影响较大,在 2 dB 时只有

86% 的识别准确率。这是因为复数能够同时表示振幅和相位信息,这对于处理特定辐射源信号数据非常重要,而传统的 CNN 通常只处理实数,将会丢失相位信息,从而影响识别效果。同时,S-CNet 可以利用复数的相位和振幅特性来区分不同的信号特征。这种内在的鲁棒性使得其在噪声环境下的性能优于卷积神经网络。相比于 CNN-Alternate Pruning,无论是识别准确率,还是在噪声干扰下模型的稳定性,都与 S-CNet 存在一定的差距。这是因为 S-CNet 采用的脉冲神经层通过时间编码传递信息,此种方式可以更有效地利用时间动态信息,同时由于脉冲神经元基于事件的响应特性,对于噪声和扰动具有更高的鲁棒性,这使得它们在处理不完美数据时比卷积神经网络更加有效。

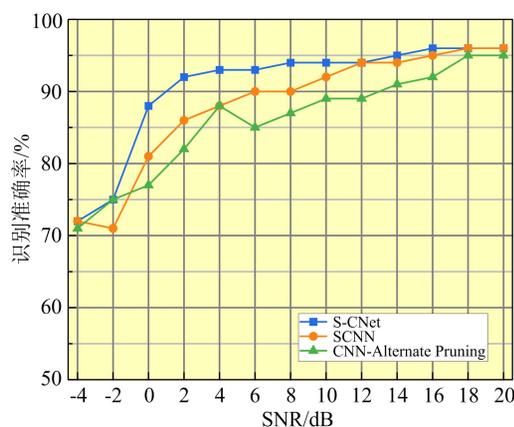


图 9 不同方法不同信噪比下识别结果图

Fig. 9 Recognition results under different methods and signal-to-noise ratios

3.4 参数消融实验

由于本文提出的网络采用了 LIF 模型构建脉冲神经元层,本文对 LIF 模型中的 2 个关键参数——触发阈值和衰减因子进行了详细的消融研究。具体而言,触发阈值的调整范围为 0.25~1,以 0.25 为步长进行变化;衰减因子则在 0~1 之间,同样以 0.25 为步长。实验结果见表 2 所列。可以发现,触发阈值和衰减因子对最终的识别性能均有显著影响。特别地,当触发阈值设置为 0.5 时,模型展现出最优的识别性能。这是因为 0.5 位于参数范围的中点,能够平衡激活函数的敏感性,使得 LIF 模型的点火函数不会产生显著的偏差。此外,研究发现衰减因子对识别率的影响甚至超过了触发阈值。换句话说,衰减因子

的取值将在很大程度上决定 S-CNet 网络的识别性能。这是因为衰减因子主要决定了神经元电位随时间的衰减速率,从而直接影响神经元对输入信号的时间积累能力。较大的衰减因子会导致电位快速下降,使得神经元无法积累足够的电位达到触发值,导致对快速输入信号的响应不足。相反,较小的衰减因子使得膜电位在较长时间内保持较高水平,从而更容易触发点火,这将导致神经元积累过多的输入信号,造成频繁触发。然而,这也会使神经元对噪声或无关信号过于敏感,引发频繁的误触发,这不仅增加了计算负担,而且导致网络无法有效聚焦于关键特征,影响整体的识别准确率。

表 2 消融实验结果

Tab. 2 Results of ablation experiment

参数	参数取值	识别准确率/%
触发阈值	0.25	92
	0.50	96
	0.75	94
	1	93
衰减因子	0	88
	0.25	91
	0.50	94
	0.75	96
	1	92

4 结束语

针对传统深度学习模型在电磁信号识别中需要大量浮点运算、对计算资源和存储空间的硬件要求较高以及模型推理时间较长的问题,本文提出了基于脉冲神经网络的 S-CNet 模型。该模型充分提取不同时刻下 I/Q 不同通道采样点关联特征,具有更强的表达能力。此外,得益于脉冲神经层的二进制传输机制,S-CNet 模型可以仅使用加法器和比较器实现,大幅降低了硬件实现所需的计算成本和存储资源需求。实验结果显示,在实际 Wi-Fi 数据集上,虽然所提出的模型在识别准确率方面略低于深度神经网络,但其识别准确率和推理速度均优于传统的轻量级网络。未来的工作可以探索更复杂的神经元模型,同时引入迁移学习和高级特征提取技术,进一步优化

基于脉冲神经网络的辐射源识别方案,以提升识别准确率。

参 考 文 献

- [1] LIN Y, TU Y, DOU Z, et al. Contour stella image and deep learning for signal recognition in the physical layer[J]. IEEE Transactions on Cognitive Communications and Networking, 2021, 7(1): 34-46.
- [2] TOONSTRA J, KINSNER W. Transient analysis and genetic algorithms for classification[C]//Proceedings of IEEE Conference on Communications, Power, and Computing. [S. l.]:IEEE,1995: 432-437.
- [3] GUO S Z, AKHTAR S, MELLA A. A method for radar model identification using time-domain transient signals [J]. IEEE Transactions on Aerospace and Electronic Systems, 2021, 57(5): 3132-3149.
- [4] XIE N, LI Z Y, TAN H J. A survey of physical-layer authentication in wireless communications[J]. IEEE Communications Surveys & Tutorials, 2020, 23(1): 282-310.
- [5] HALL J, BARBEAU M, KRANAKIS E. Radio frequency fingerprinting for intrusion detection in wireless networks[J]. IEEE Transactions on Dependable and Secure Computing, 2005, 12: 1-35.
- [6] SUSKI II W C, TEMPLE M A, MENDENHALL M J, et al. Using spectral fingerprints to improve wireless network security[C]//Proceedings of 2008 IEEE Global Telecommunications Conference. [S. l.]:IEEE, 2008:1-5.
- [7] HALL J, BARBEAU M, KRANAKIS E. Enhancing intrusion detection in wireless networks using radio frequency fingerprinting[C]//Proceedings of the International Conference on Communications and Internet Information Technology. [S. l. ;s. n.],2004: 201-206.
- [8] 张振, 李一兵, 查浩然. 基于深度学习的大规模电磁信号识别[J]. 太赫兹科学与电子信息学报, 2022, 20(1): 29-33.
ZHANG Zhen, LI Yibing, ZHA Haoran. Large-scale electromagnetic signal recognition based on deep learning[J]. Journal of Terahertz Science and Electronic Information Technology, 2022, 20(1): 29-33. (in Chinese)
- [9] ZHA H R, WANG H H, FENG Z M, et al. LT-SEI: long-tailed specific emitter identification based on decoupled representation learning in low-resource scenarios[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(1): 929-943.
- [10] 张思成, 林云, 涂涯, 等. 基于轻量级深度神经网络的电磁信号调制识别技术[J]. 通信学报, 2020, 41(11):

- 12-21.
- ZHANG Sicheng, LIN Yun, TU Ya, et al. Electro-magnetic signal modulation recognition technology based on lightweight deep neural network[J]. Journal on Communications, 2020,41(11):12-21. (in Chinese)
- [11] TU Y, LIN Y, WANG J, et al. Semi-supervised learning with generative adversarial networks on digital signal modulation classification[J]. Computers, Materials & Continua, 2018,55(2):243-254.
- [12] TU Y, LIN Y, ZHA H R, et al. Large-scale real-world radio signal recognition with deep learning[J]. Chinese Journal of Aeronautics, 2022, 35(9): 35-48.
- [13] SU C, LI J P, ZHANG Y Q. Research on image recognition algorithm based on spiking neural networks[C]//Proceedings of the 20th International Computer Conference on Wavelet Active Media Technology and Information Processing. [S. l.]: IEEE, 2023: 1-7.
- [14] AAMIR S A, STRADMAN Y, MÜLLER P, et al. An accelerated LIF neuronal network array for a large-scale mixed-signal neuromorphic architecture [J]. IEEE Transactions on Circuits and Systems I: Regular Papers, 2018, 65(12): 4299-4312.
- [15] TU Y, LIN Y, HOU C B, et al. Complex-valued networks for automatic modulation classification[J]. IEEE Transactions on Vehicular Technology, 2020, 69(9): 10085-10089.
- [16] TAVANA EI A, GHODRATI M, KHERADPISHEH S R, et al. Deep learning in spiking neural networks [J]. Neural Networks, 2019, 111: 47-63.
- [17] XU Q, LI Y X, SHEN J R, et al. Constructing deep spiking neural networks from artificial neural networks with knowledge distillation[C]//Proceedings of IEEE/CVF Conference on Computer Vision and Pattern Recognition. [S. l.]:IEEE,2023: 7886-7895.
- [18] GUO Y F, ZHANG Y H, CHEN Y P, et al. Membrane potential batch normalization for spiking neural networks[C]//Proceedings of 2023 IEEE/CVF International Conference on Computer Vision. [S. l.]: IEEE,2023:19420-19430.
- [19] LV L Z H, FANG W, YUAN L, et al. Optimal ANN-SNN conversion with group neurons[C]// Proceedings of 2024 IEEE International Conference on Acoustics, Speech and Signal Processing. [S. l.]:IEEE, 2024: 6475-6479.
- [20] PANDA P, AKETI S A, ROY K. Toward scalable, efficient, and accurate deep spiking neural networks with backward residual connections, stochastic softmax, and hybridization[J]. Frontiers in Neuroscience, 2020, 14: 653.
- [21] HE Y, XIAO L G. Structured pruning for deep convolutional neural networks; a survey[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, 46(5): 2900-2919.

作者简介

张乃煜

男,1999年生,硕士研究生,研究方向为信号处理、深度学习
E-mail:naiyuzhang2024@163.com



张雅彬

女,1978年生,博士,副教授,研究方向为光纤通信技术、光学工程、光纤传感技术
E-mail:zhangyabin@hrbeu.edu.cn



查浩然

男,1996年生,博士研究生,研究方向为深度学习、信号分析识别、软件无线电技术
E-mail:zhahaoran@hrbeu.edu.cn



责任编辑 殷文卓