

doi: 10.7690/bgzdh.2022.07.003

# 基于转换脉冲神经网络的雷达辐射源识别方法

李伟<sup>1</sup>, 朱卫纲<sup>2</sup>, 朱霸坤<sup>1</sup>, 杨莹<sup>1</sup>

(1. 航天工程大学研究生院, 北京 101416; 2. 航天工程大学电子与光学工程系, 北京 101416)

**摘要:** 为提高雷达辐射源识别智能水平, 提出一种新的基于转换脉冲神经网络进行雷达辐射源调制模式识别的方法。将仿真产生的雷达信号转换为2维时频图, 将传统的卷积神经网络(convolutional neural networks, CNN)转化为脉冲神经网络(spiking neuron network, SNN), 使用SNN进行雷达辐射源识别。仿真实验结果表明: 该方法具有优良的检测精度, 当信噪比高于-9 dB时, 识别概率可达96%以上。

**关键词:** 脉冲神经网络; 雷达辐射源识别; 卷积神经网络; 时频转换**中图分类号:** TJ06   **文献标志码:** A

## Radar Emitter Recognition Method Based on Converted Spiking Neural Network

Li Wei<sup>1</sup>, Zhu Weigang<sup>2</sup>, Zhu Bakun<sup>1</sup>, Yang Ying<sup>1</sup>

(1. Graduate School, Space Engineering University, Beijing 101416, China;

2. Department of Electronic and Optical Engineering, Space Engineering University, Beijing 101416, China)

**Abstract:** In order to improve the intelligence level of radar emitter recognition, a new method of radar emitter modulation pattern recognition based on converted spiking neural network is proposed. The simulated radar signal is transformed into a 2D time-frequency map, and the traditional CNN (convolutional neural networks) is transformed into a SNN (spiking neuron network), which is used for radar emitter recognition. The simulation results show that the proposed method has excellent detection accuracy, and the recognition probability can reach more than 96% when the SNR is higher than -9 dB.

**Keywords:** spiking neural network; radar emitter identification; convolutional neural networks; time-frequency conversion

## 0 引言

雷达辐射源识别是情报侦察、获取敌情的重要手段。准确的雷达辐射源识别是掌握战争主动权的关键<sup>[1]</sup>。传统雷达辐射源识别主要通过人工方式提取脉冲描述字参数构成特征的向量进行识别, 如模板匹配法<sup>[2]</sup>、专家系统<sup>[3]</sup>等。随着雷达自适应技术和频率捷变能力的提高, 现代雷达信号特征日益复杂, 传统的雷达辐射源识别技术已经不能适应现代雷达辐射源识别领域。

近年来, 深度学习因其自适应的特征提取能力以及良好的泛化能力, 越来越多的目光投向基于人工神经网络的雷达辐射源识别领域<sup>[4]</sup>。其中卷积神经网络(CNN)凭借强大的图像特征提取能力及其改进模型的方法, 取得了优良的雷达辐射源识别效果<sup>[5-7]</sup>。相对于全连接网络, CNN使用权值共享和池化的方法, 极大降低了网络参数和运算量。脉冲神经网络(SNN)被誉为第3代人工神经网络<sup>[8]</sup>, 具有与大脑神经元相同的工作方式。由于SNN独特的工作原理, 使得SNN相对于传统人工神经网络, 完

成相同任务时功耗仅为前者的数百分之一<sup>[9]</sup>。笔者提出一种基于CNN转换SNN的雷达辐射源识别方法。首先通过时频变换将分选后的雷达信号转换为时频2维图像, 并进行灰度化处理, 其次使用时频图训练卷积脉冲神经网络模型参数, 然后通过阈值和权重调整将CNN转换为由IF(integrate-and-fire)神经元模型构成的SNN<sup>[10]</sup>, 最终使用SNN完成雷达辐射源的识别。

## 1 卷积神经网络

基于CNN转换SNN的雷达辐射源识别流程如图1所示。

卷积神经网络是一种特殊的人工神经网络(artificial neural network, ANN), 在图像识别与分类方面表现优异。CNN主要由卷积层、池化层和全连接层组成。卷积层的主要作用是提取雷达时频图像的特征, 但从卷积层中提取的特征维度太高, 容易出现过拟合现象。池化层的主要作用是降维, 通过平均池化或者最大池化对卷积层所提取的特征进

收稿日期: 2022-03-30; 修回日期: 2022-04-28

作者简介: 李伟(1994—), 男, 河南人, 硕士, 从事雷达信号处理、认知电子战研究。E-mail: 729684332@qq.com。

行降维处理。卷积神经网络的最后几层一般是全连接层，用于对特征进行分类识别。

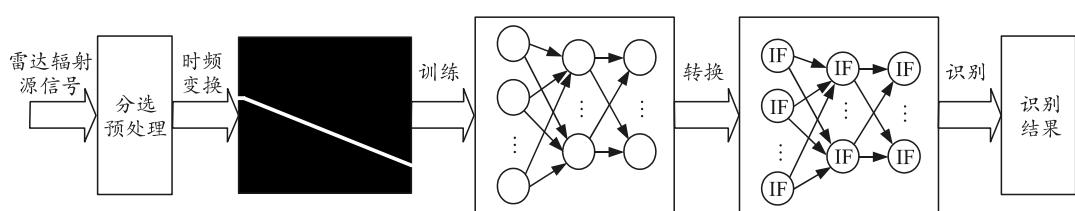


图 1 基于 CNN 转换 SNN 的雷达辐射源识别流程

与其他人工神经网络一样，卷积神经网络采用的神经元也是如图 2 所示的模型。其中： $x_i$  为输入； $y_i$  为输出； $w$  为权重；均为模拟值。

笔者采用的待转换卷积神经网络结构如图 3 所示，其中： $C$  为卷积层； $S$  为池化层； $F$  为全连接层，

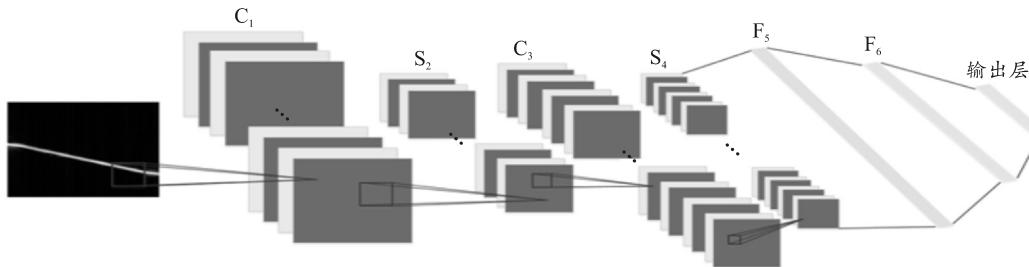


图 3 待转换卷积神经网络结构

## 2 脉冲神经网络

真实大脑神经元是通过脉冲来传递和处理信息，传统人工神经元模型是从真实大脑神经元中高度抽象出来的一种极为简化的模型。从大脑神经元细胞工作原理角度来看，传统人工神经元模型输入和输出的模拟值对应的是神经元的脉冲发放频率，忽略了脉冲发放时刻这一重要信息。如图 4 所示，对于观察窗口为 10 ms 的传统人工神经元来说，图 4(a)和图 4(b)都是 10 ms 内发放了 3 次脉冲，代表的信息是完全相同的，即对应频率数值均为 300 Hz。现有的神经科学表明，脉冲发放的精确时间点也携带着重要信息，相同的脉冲发放频率传递的信息可能完全不同<sup>[11]</sup>。

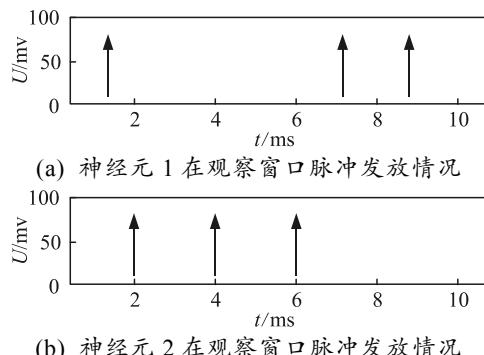


图 4 2 个神经元在 10 ms 观察窗口内的脉冲发放情况

最后连接到输出层。

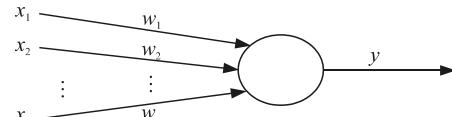


图 2 传统人工神经网络神经元模型

近年来，更具有生物可解释性的 SNN 以其丰富的信息编码方式、事件驱动和低功耗的优势引起了研究人员的关注。

### 2.1 神经元模型

脉冲神经元模型是构成 SNN 的基本单元。为了描述脉冲神经元的状态和脉冲发放情况，神经生理学家建立了许多动力学模型。其中常用的神经元模型有 IF(integrate-and-fire) 模型，LIF(leaky integrate-and-fire) 模型，H-H(Hodgkin-Huxley) 模型和 Izhikevich 模型。因 IF 和 LIF 模型具有生物可解释性的同时，运算量相对较小，被广泛用于组成脉冲神经网络。笔者使用 IF 模型组成 SNN。当膜电压  $V$  小于阈值电压  $V_{\text{thr}}$  时，IF 模型如下式所示：

$$V_j(t) = V_j(t-1) + \sum_i S_i(t) w_{ij} \quad (1)$$

其中： $i$  为突触前神经元序号； $j$  为突触后神经元序号； $t$  为时刻； $V$  为神经元膜电压； $S$  为突触前神经元； $w$  为神经元连接突触的权重。当膜电压  $V \geq V_{\text{thr}}$  时，神经元膜电压重置为静息电压  $V_{\text{rest}}$  并发放脉冲。

### 2.2 基于 ANN 转换 SNN

直接训练 SNN 将会面临脉冲不可微分的困难。在神经态硬件如 TrueNorth<sup>[12]</sup>、Tianjic<sup>[13]</sup> 等得到一

定发展后,为了能够迅速地将 ANN 网络上的最新进展成果应用到 SNN 上,发挥 SNN 低能耗、事件驱动的优势,转换方式成为了一种训练 SNN 的替代做法。转换 SNN 具备在大规模数据集和网络上实现的能力,并且性能与 ANN 保持最小的差距。

但 ANN 训练过程中,参数值有负数,而在 SNN 中,难以使用脉冲来表示负数。为解决这一问题,ANN 中采用修正线性单元(rectified linear units,ReLU)作为激活函数。ReLU 激活函数的表达式为:

$$f(x) = \max(0, x). \quad (2)$$

其中:  $x$  为输入;  $f(x)$  为输出。

相同输入  $x$  的情况下,IF 神经元和 ReLU 函数的输出情况如图 5 所示。从图 5 中可以看出,IF 神经元脉冲发放率和 ReLU 函数十分相似。注意:当输入  $x > 1$  时,IF 神经元脉冲发放率是不可能大于 1 的,此时会出现过激活现象,可以使用后续的模型归一化步骤进行调整。ANN 转换 SNN 的理论基础就是在使用 ReLU 激活函数的 ANN 网络中,SNN 可以使用 IF 神经元的平均脉冲发放率来近似<sup>[14]</sup>。

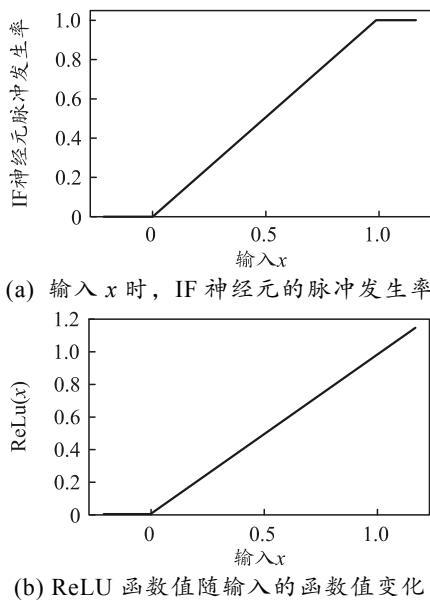


图 5 IF 神经元脉冲发生率和 ReLU 激活函数对比

由于 ANN 网络中,CNN 结合时频分析进行雷达辐射源识别可以得到良好的识别效果,笔者采用 CNN 转换 SNN 的方式来进行雷达辐射源的识别。为了能将 CNN 成功转换为 SNN,需对 CNN 网络进行一定的限制和更改。具体就是调整 CNN 网络中的偏置项,使用平均池化来代替最大池化,改变批归一化操作方法等。

如果把训练完成的 CNN 权值直接迁移到 SNN,网络将无法正常工作。主要原因在于 SNN 中的神经

元容易出现过激活和欠激活现象<sup>[15]</sup>。当阈值电压  $V_{\text{thr}}$  相对于输入非常大时,膜电压  $V$  需要很长的时间才能到达  $V_{\text{thr}}$ ,因而导致了极低的脉冲发放频率,此时神经元被称为欠激活,导致深层的网络脉冲消失。反之,如果  $V_{\text{thr}}$  相对于输入非常小时,那么膜电压  $V$  将会总是超过  $V_{\text{thr}}$ ,输入值的变化信息在后续的网络中无法体现,此时神经元被称为过激活。为防止欠激活和过激活的情况出现,权重和阈值电压都需要进行调整,模型归一化是最常用的手段。当 CNN 训练完成后,记录  $l$  层前向计算中所有节点的 ReLU 激活值,将  $l$  层中最大的激活值  $\lambda^l$  作为缩放系数,使用  $\lambda^l$  来调整权重  $W^l$  和偏置项  $b^l$ 。具体算法为:

$$W^l \leftarrow W^l * \lambda^{l-1} / \lambda^l; \quad (3)$$

$$b^l \leftarrow b^l * \lambda^{l-1} / \lambda^l. \quad (4)$$

为防止离群点的影响,提高转换后网络鲁棒性,笔者采用 99.9% 分位的激活值来代替最大激活值<sup>[16]</sup>。批归一化是在 CNN 训练中常用的一种训练技巧,可以加快模型的收敛速度;但是在 SNN 中,批归一化是难以实现的。笔者使用参数吸收的方式来进行 CNN 到 SNN 的转换。SNN 模型中的权重  $W'$  和偏置  $b'$  可以表示为:

$$W' = (\gamma / \sigma)W; \quad (5)$$

$$b' = \gamma / \sigma(b - \mu) + \beta. \quad (6)$$

其中:  $\mu$  为输入  $x_i$  的均值;  $\sigma$  为输入  $x_i$  的方差;  $\gamma, \beta$  分别为在 CNN 训练过程中学习到的尺度因子和平移因子<sup>[17]</sup>。经过模型归一化和参数吸收,CNN 可以顺利转化为 SNN。

### 2.3 参数设置

待转换的 CNN 模型包含 2 个 2 维卷积层,2 个池化层,2 个全连接层,如图 3 所示。所有的 2 维卷积层具有相同的配置,步长为 1,维度为 32,卷积核大小为  $3 \times 3$ ,采用 ReLU 激活函数和平均池化。转换后的 SNN 与 CNN 具有相同的网络结构,IF 神经元模型的阈值电压  $V_{\text{thr}}=1$ ,复位电压  $V_{\text{rest}}=0$ ,模拟步长为 100。

### 2.4 训练流程

1) 产生信号。使用 Matlab 产生 6 种典型雷达辐射源信号。

2) 时频转换。将 6 种 1 维雷达辐射源信号转换为 2 维时频图,为方便后续处理,2 维时频图均使用灰度图像。

- 3) 构建数据集。将时频图按类别以 0.6:0.2:0.2 分为训练集、验证集和测试集。
- 4) 训练 CNN。损失函数使用交叉熵损失函数, 优化器采用 Adam, 学习率设置为  $10^{-3}$ , 训练轮数为 10 轮, batch\_size 为 64, 对模型进行训练。
- 5) 转换为 SNN。将 CNN 进行模型归一化和参数吸收, 转化为 SNN。
- 6) 使用 SNN 进行辐射源识别。

### 3 仿真实验

笔者采用 Matlab 仿真 5 种典型的雷达辐射源信号来验证本模型的有效性, 包括频移键控(frequency shift keying, FSK)、二进制相移键控(binary phase shift keying, BPSK)、连续波雷达(continuous wave, CW)、线性调频(linear frequency modulation, LFM)、非线性调频(nonlinear frequency modulation, NLFM)。上述信号采用全频段信噪比, 加入随机高斯白噪声, 全频段带宽取 50 MHz, 采样频率取 100 MHz。其中, FSK 上下频分别为 20 和 30 MHz; BPSK 载频 25 MHz, 带宽 5 MHz; CW 载频为 30 MHz; LFM 中心频率为 30 MHz, 调频宽度为 17 MHz; NLFM 中心频率为 25 MHz, 调频宽度为 10 MHz。5 种信号的信噪比范围为  $-15 \sim 0$  dB, 间隔 1 dB。每种信号在每个信噪比条件下生成 2 000 个样本, 样本共计 32 000 个。本实验硬件环境为 CPU:Intel i7-7700K@4.20GHz, GPU:TITAN X。软件环境为 python3.7, pytorch1.7, 并用 CUDA10.1 进行运算加速。SNN 模型下 5 种信号在不同信噪比下识别概率如图 6 所示。从图中可以看出当信噪比大于  $-9$  dB 时, 识别率可以达到 96% 以上。

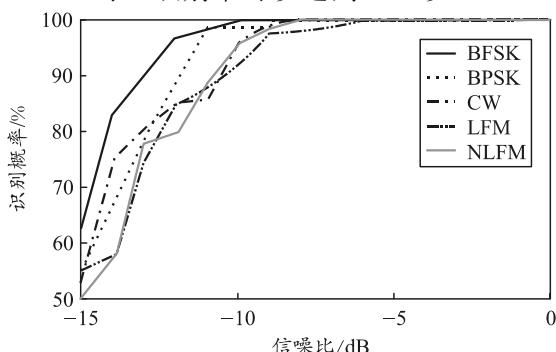


图 6 不同信噪比下 5 种雷达信号识别概率

### 4 结束语

笔者提出一种基于 CNN 转换 SNN 的雷达辐射源识别方法, 并通过仿真 5 种典型雷达辐射源信号进行验证。实验结果表明, SNN 可以对雷达辐射源

进行识别, 并取得良好效果。相对于传统 CNN, SNN 作为一种新型的网络结构, 具备更接近真实神经元的工作方式, 拥有广阔的发展前景。目前, 基于 GPU 仿真的脉冲神经网络暂时无法体现出快速运算和低功耗的特点, 如何在神经态计算芯片(如 TureNorth 或 Tianjic 等)上部署脉冲神经网络是下一步的重点研究方向。

### 参考文献:

- [1] 李宝鹏, 李淑华, 夏栋. 基于 IF 特性的雷达辐射信号脉内调制特性识别[J]. 兵工自动化, 2020, 39(8): 49–53.
- [2] TANG J, QING L I. Fast Template Matching Algorithm[J]. Journal of Computer Applications, 2010, 30(6): 1558–1559.
- [3] 李东海. 基于专家系统的雷达识别方法[J]. 舰船电子对抗, 2014, 37(5): 10–13.
- [4] 王龙. 人工神经网络在雷达目标识别中的应用[D]. 太原: 中北大学, 2015.
- [5] 孔明鑫. 基于深度卷积神经网络的雷达辐射源识别算法研究[D]. 杭州: 杭州电子科技大学, 2020.
- [6] 黄智, 王俊杰, 石国良. 基于时频分析和 CNN 的雷达辐射源识别算法[J]. 舰船电子工程, 2020, 40(1): 24–28.
- [7] 吴琼. 基于改进 CNN 的雷达辐射源识别算法研究[D]. 西安: 西安电子科技大学, 2019.
- [8] AT A, AB B, YL C, et al. A review of learning in biologically plausible spiking neural networks[J]. Neural Networks, 2020, 122: 253–272.
- [9] KIM S, PARK S, NA B, et al. Spiking-YOLO: Spiking Neural Network for Energy-Efficient Object Detection[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 11270–11277.
- [10] ABBOTT L F. Lapicque's introduction of the integrate-and-fire model neuron (1907)[J]. Brain Research Bulletin, 1999, 50(5–6): 303–304.
- [11] ROY K, JAISWAL A, PANDA P. Towards spike-based machine intelligence with neuromorphic computing[J]. Nature, 2019, 575: 607–617.
- [12] AKOPYAN F, SAWADA J, CASSIDY A, et al. Truenorth: Design and tool flow of a 65 mw 1 million neuron programmable neurosynaptic chip[J]. IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems, 2015, 34(10): 1537–1557.
- [13] DENG L, WANG G, LI G, et al. Tianjic: A unified and scalable chip bridging spike-based and continuous neural computation[J]. IEEE Journal of Solid-State Circuits, 2020.
- [14] CAO Y, CHEN Y, KHOSLA D. Spiking deep convolutional neural networks for energy-efficient object recognition[J]. International Journal of Computer Vision, 2015, 113(1): 54–66.

(下转第 20 页)