

# 基于类脑脉冲神经网络的遥感图像检测算法

段德鑫<sup>1</sup>, 路遥<sup>2</sup>, 黄立威<sup>2</sup>, 刘佩林<sup>1</sup>, 文飞<sup>1</sup>

1. 上海交通大学 电子信息与电气工程学院, 上海 200240;

2. 北京市遥感信息研究所, 北京 100192

**摘要:** 与第二代人工神经网络 (ANN) 相比, 第三代类脑脉冲神经网络 (SNN) 由于其高效、高仿生、可解释等特点, 在遥感影像智能处理的高能效、高精度、高可解译方面具有较大的潜在优势。针对现有脉冲神经网络算法延时较大的问题, 本文提出一种基于类脑脉冲神经网络的遥感图像检测算法。该算法首先搭建了一个带有动态裁剪阈值激活函数的目标检测神经网络作为源网络进行预训练, 随后借助训练过程中得到的裁剪阈值, 通过激活神经元与脉冲神经元的映射关系将源网络转换为类脑脉冲神经网络, 在继承源网络较高精度的同时还具备了低延迟、高仿生的特点。在 SSDD (SAR-Ship-Detection-Datasets) 和 RSOD 两个公开遥感数据集上的实验结果表明, 该方法能够以极低的损失将源网络转换至类脑脉冲神经网络, 并能在低时间步下对遥感目标实现较高的检测识别精度。同时该方法能够在继承 ANN 网络易于训练的特性与精度优势的同时, 充分展现 SNN 的高稀疏度的带来的巨大能效优势。

**关键词:** SAR, 遥感图像, 光学遥感, 目标检测, 深度学习, 脉冲神经网络

**中图分类号:** TP701/P2

**引用格式:** 段德鑫, 路遥, 黄立威, 刘佩林, 文飞. 2024. 基于类脑脉冲神经网络的遥感图像检测算法. 遥感学报, 28(7): 1713-1721  
Duan D X, Lu Y, Huang L W, Liu P L and Wen F. 2024. Remote sensing image detection method based on brain-inspired spiking neural networks. National Remote Sensing Bulletin, 28(7): 1713-1721 [DOI: 10.11834/jrs.20243269]

## 1 引言

遥感图像的目标检测作为遥感影像解译的重要环节, 在国防领域和国民经济领域有着广泛的应用。在水陆运输管控 (El Shair, 2003)、智能交通调度规划 (Chen 等, 2021)、国土资源调查 (李德仁 等, 2021) 和战场态势侦察感知等多种重要应用场景中, 准确检测出遥感图像中的水面船舶与地面车辆建筑等目标是一项重要的应用任务。而遥感图像的特点, 如图像场景复杂、地物类型多、目标偏小且密集、目标尺度不一等, 导致遥感图像目标检测极具挑战性。以合成孔径雷达 SAR (Synthetic Aperture Radar) 为例, 其提供的全天候、全天时的高分辨率图像由于成像机理和光学图像差别极大, 辨别图像场景干扰与遮挡复杂多变, 难以判读 (张云鹏 等, 2019)。因此准确地对遥感影像进行目标检测一直是遥感研究的重

点之一。

传统遥感图像目标检测算法可分为基于模板匹配的算法和基于传统机器学习的算法。基于模板匹配的算法主要包括模板生成和相似性度量两个步骤。该类算法简单易行, 但鲁棒性差, 无法适应目标的多变性 (An 等, 2010)。随着人工智能的快速发展, 以卷积神经网络为代表的深度学习方法也在遥感目标识别检测解译方面发挥了日渐重要的作用。基于深度卷积神经网络的目标检测网络在遥感图像检测上取得了长足的进步 (Zhu 等, 2021; 柳思聪 等, 2023)。使用深度卷积神经网络的目标检测算法分为两阶段算法与一阶段算法两大类。其中两阶段检测方法以 R-CNN (Girshick, 2015) 为代表, 两阶段方法将模型分为分类器训练与边界框回归两个阶段 (沙苗苗 等, 2022)。但是在此类方法中, 每个候选区域都需要分别进行特征提取, 候选区域的生成与特征提取割裂开来,

收稿日期: 2023-07-11; 预印本: 2024-02-23

基金项目: 科技创新 2030-脑科学与类脑研究重大项目 (编号: 2022ZD0208701); 卫星信息智能处理与应用技术重点实验室基金

第一作者简介: 段德鑫, 研究方向为人工智能、神经形态计算。E-mail: jumywizard@sjtu.edu.cn

通信作者简介: 文飞, 研究方向为类脑计算、机器学习、信号/图像处理。E-mail: wenfei@sjtu.edu.cn

导致检测效率较低 (Zhang 等, 2019; 沙苗苗 等, 2022)。一阶段方法以 YOLO (Redmon 等, 2016) 系列算法为代表。首先, 其将一系列具有不同尺度和纵横比的锚点引入到网络中, 并且这些锚点在每个空间位置上都是预先定义好的; 然后, 通过交并比分数区分和训练正负样本。由于一阶段方法同时完成分类和定位任务, 因此效率相比两阶段方法得到了提高, 也成为了当前主流的目标识别方法 (Pham 等, 2020; Gao 等, 2021; 许泽宇 等, 2022)。近年来随着 transformer 架构的发展, 也出现了例如 DETR (Carion 等, 2020) 等部分使用 transformer 的目标检测新框架。DETR 将目标检测任务转化为一个序列到序列的问题。它将输入图像划分为一系列位置编码的特征向量, 然后将这些特征向量作为序列输入 Transformer 模型用于处理图像特征并生成目标的位置和类别。相比其他目标检测框架, DETR 不需要预定义的锚框或候选框, 并能通过自注意力机制捕捉目标间的全局关系。但此类基于 Transformer 的方法需要大量的计算资源进行自注意力机制与多头注意力机制的运算, 限制了此类框架在资源受限环境中的应用。

虽然以卷积神经网络为代表的第二代人工神经网络在某种程度上受到了生物神经网络的启发, 但其与生物大脑神经元在动力学过程上有着本质的不同。大脑对信息的高效处理依赖于神经元在时域上动作电位的变化与放电, 这与主流的卷积神经网络中的激活神经元工作方式截然不同, 因此需要在神经元动力学过程模拟层面采用更加仿生的模型。脉冲神经网络 SNN (Spiking Neural Networks) 作为新一代神经网络, 在生物学原理上高度近似大脑神经元 (Ghosh-Dastidar 和 Adeli, 2009)。相较于第二代人工神经网络的神经元使用实数值激活来传递信息, 脉冲神经网络通过采用脉冲序列来表示信息, 在空间域和时间域两个维度上传递信息, 以模拟人类大脑中的信息编码和处理过程。在脉冲事件稀疏性的驱动下, SNN 具有计算高效性和生物可解释性的特点 (Tavanaei 等, 2019), 并具有更高的计算效率和更快的推理速度。

目前, 基于 SNN 的算法主要可分为 3 类: (1) 基于脉冲时间依赖可塑性 (STDP) 的无监督学习方法。它根据突触前后神经元之间的放电延迟来修

改连接突触的权重 (Kheradpisheh 等, 2018)。然而, 由于 STDP 仅利用局部突触可塑性进行调整, 无法实现突触个体与整个神经系统目标的协调, 因此难以应用于大规模深度网络。(2) 直接监督学习。近年来 SNN 在利用反向传播提高网络性能方面取得了显著进展。该方法在正向传播过程中使用 Heaviside 阶跃函数生成脉冲信号, 在反向传播过程中使用替代梯度的近似不可微函数。最近的研究表明, SNN 能够有效利用通用深度学习框架通过时间反向传播进行学习 (Che 等, 2022)。然而, 由于脉冲神经网络通过多个时间步对输入信息进行编码, 并且由于存在膜电位衰减等时域上的动力学过程, 这种方法需要将脉冲神经网络在全部时间步上展开以进行梯度的反向传播, 这导致内存和时间开销非常大, 从而令直接训练 SNN 变得十分困难。(3) 基于源神经网络转换的间接有监督学习。它的步骤是首先以特定结构训练一个卷积神经网络模型, 然后利用脉冲神经元和激活函数之间的关系将学习到的权重迁移到具有相同结构的脉冲神经网络中。这种方法能够充分利用卷积神经网络模型成熟的拓扑结构与精度优势, 并发挥类脑脉冲神经网络的高能效、低延迟和高生物可解释性的优势。随着 SNN 的能效与仿生性优势凸显, SNN 也被应用于遥感图像分类等任务中 (Niu 等, 2023), 但在目标识别等更为复杂的任务中仍然面临训练困难等问题。

综上所述, 本文首次提出了一种基于转换算法的类脑脉冲神经网络用于对遥感图像进行目标检测。首先构建了一个带有动态裁剪阈值的单阶段目标检测神经网络作为源网络进行预训练, 得到了一个具有较高精度的源目标检测网络; 随后借助训练过程中得到的裁剪阈值确定激活值范围, 通过激活神经元与脉冲神经元的映射关系将源网络转换为类脑的脉冲神经网络。最后, 将转换后的类脑脉冲神经网络在 SSDD (SAR-Ship-Detection-Datasets) 和 RSOD 两个公开遥感数据集上进行测试。

## 2 方法

本文提出的类脑脉冲神经网络的遥感图像检测算法流程图如图 1 所示。算法主要分为 3 个部分: 源网络的构建、源网络预训练与类脑脉冲神

神经网络转换。首先，根据类脑脉冲神经网络转换原理的特点搭建了一个目标识别神经网络作为源

网络，随后将源网络进行预训练，最后根据训练参数将源网络转换为类脑脉冲神经网络。

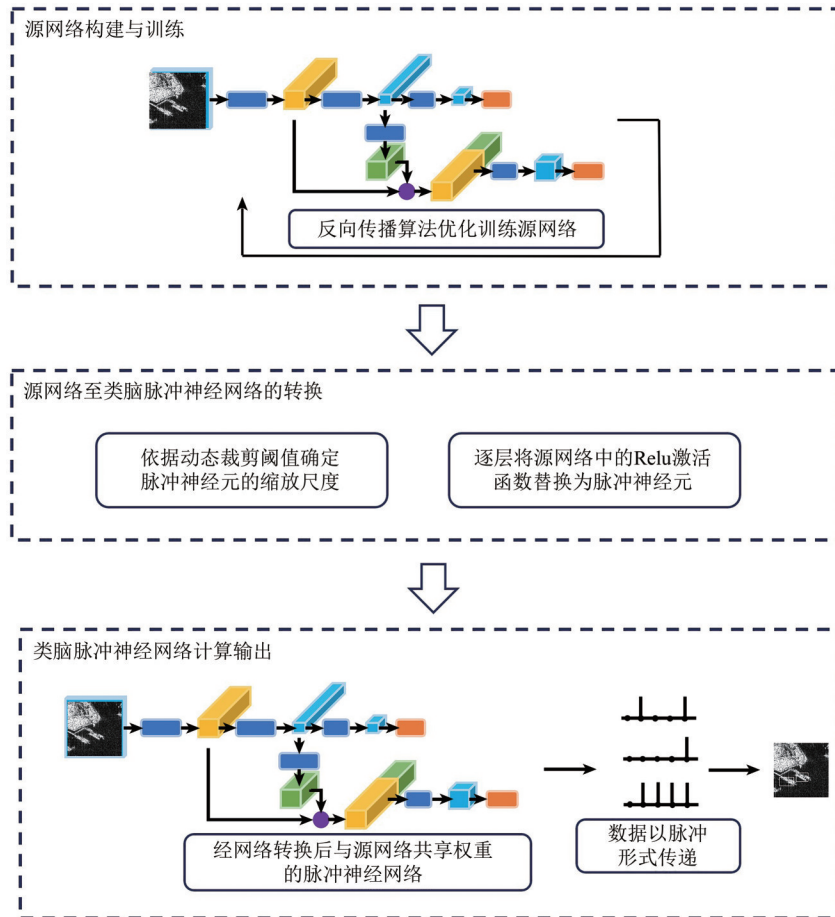


图1 算法流程图

Fig. 1 Algorithm flow chart

### 2.1 脉冲神经元模型

作为SNN的基本计算单位，IF神经元模型是目前SNN中最常见的脉冲神经元之一。IF神经元的动力学过程可以描述为充电、放电和重置3个阶段。设 $t$ 时刻下神经元的膜电位为 $V(t)$ ，神经元接受的电压输入为 $X(t)$ ， $(t - 1)$ 时刻时神经元的膜电位为 $V(t - 1)$ ，充电阶段指脉冲神经元的膜电位 $V(t)$ 接收来自突触前神经元加权输入的膜电压的过程，IF神经元的充电方程为

$$\frac{dV(t)}{dt} = V(t) + X(t) \quad (1)$$

由于脉冲神经元都是有记忆的，因此 $V(t)$ 不仅取决于当前时刻的输入 $X(t)$ ，还取决于上一个时刻末的膜电位 $V(t - 1)$ 。若使用离散的差分方程来近似连续的微分方程，则IF神经元的充电方程为

$$V(t) - V(t - 1) = X(t) \quad (2)$$

脉冲神经元的信息传递依靠脉冲进行，当神经元的膜电位 $V(t)$ 超过阈值电压 $V_{\text{threshold}}$ 时，神经元会释放出一个脉冲。这个过程也即脉冲神经元的放电，放电方程可以描述为

$$S(t) = \Theta(V(t) - V_{\text{threshold}}) \quad (3)$$

式中， $\Theta(x)$ 为判断是否放电的阶跃函数：

$$\Theta(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (4)$$

最后，因为释放脉冲会消耗神经元之前积累的电荷，因此膜电位会有一个瞬间的降低，即脉冲神经元膜电位的重置。在SNN中，膜电位的重置方式有两种：硬重置和软重置。硬重置指神经元在释放脉冲后，膜电位会被重置为固定的重置电压；而软重置指神经元在释放脉冲后会减去阈值电压。由于硬重置在放电时忽略了超过阈值电

压的电位而直接将膜电位重置为固定的阈值电压。在多次神经元的充电—放电—重置循环下，逐渐累积的被忽略电位有可能导致神经元脉冲发放率

低于预期，从而降低脉冲神经元的表征能力。为了更好地表征信息，本文选择软重置。硬重置与软重置的区别如图2所示。

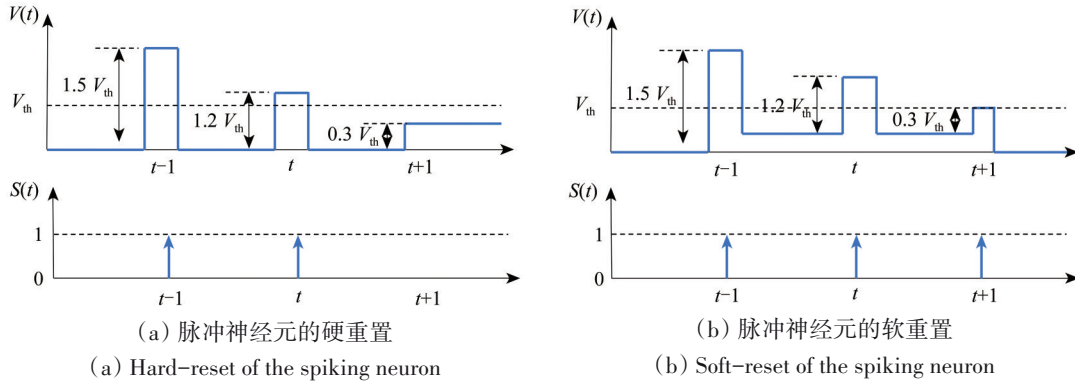


图2 在脉冲神经元的两种重置方式下,膜电位变化与神经元放电的示意图

Fig. 2 Diagram of membrane potential change and neuron firing under two reset modes of pulsed neurons

根据上述定义便得到了一个IF脉冲神经元完整的动力学过程。为了避免混淆，使用 $H(t)$ 来表示IF神经元在充电后，释放脉冲前的膜电位；使用 $V(t)$ 来表示神经元释放脉冲后的膜电位。至此，可以使用充电、放电和重置3个离散方程来描述IF脉冲神经元：

$$H(t) = V(t - 1) + X(t) \quad (5)$$

$$S(t) = \Theta(H(t) - V_{th}) \quad (6)$$

$$V(t) = H(t) - V_{th} \cdot S(t) \quad (7)$$

### 2.2 脉冲神经网络转换

根据脉冲神经元的动力学过程分析可以发现，在SNN中信息通过二值化的脉冲进行传递，因此在SNN网络中只会传递非负的脉冲激活值，在固定时间长度内单个脉冲神经元会产生特定的脉冲发放率。而对IF脉冲神经元的脉冲发放率进行分析则可以发现，当阈值电压一定时，IF神经元的脉冲发放率会随着输入的增大而线性增加，这与卷积神经网络中的Relu激活函数十分相似（图3）。




图3 卷积神经网络中的ReLU神经元与脉冲神经网络中的IF脉冲神经元的输出对应关系  
(设脉冲神经元中的阈值电压 $V_{th} = 1$ )

Fig. 3 The output correspondence between ReLU neurons in artificial neural network and IF neurons in spiking neural network  
(The threshold voltage  $V_{th}$  of the spiking neuron is set to 1)

以一个卷积神经网络为例，若某一层由卷积层和 ReLu 激活函数构成，卷积层的权重和偏置为  $\mathbf{W}_{l-1}^{\text{ANN}}$  和  $\mathbf{b}_{l-1}^{\text{ANN}}$ ，则上一层激活后的输入  $\mathbf{a}_{l-1}$  经过卷积层与 ReLu 激活层后的激活值  $\mathbf{a}_l$  可以表示为

$$\mathbf{a}_l = \max(\mathbf{W}_{l-1}^{\text{ANN}}\mathbf{a}_{l-1} + \mathbf{b}_{l-1}^{\text{ANN}}, 0) \quad (8)$$

通过统计数据集中所有激活值从而确定此层的最大激活值为  $a_{\max}^l$ ，则可以获得归一化至 0—1 范围内的归一化激活值  $\hat{\mathbf{a}}_l$ ：

$$\hat{\mathbf{a}}_l = \frac{\mathbf{a}_l}{a_{\max}^l} = \text{clip}\left(\frac{\mathbf{W}_{l-1}^{\text{ANN}}\mathbf{a}_{l-1}}{a_{\max}^l} + \frac{\mathbf{b}_{l-1}^{\text{ANN}}}{a_{\max}^l}, 0, 1\right) \quad (9)$$

而在与之对应的类脑脉冲神经网络中，脉冲神经元在  $T$  时间步后的累计膜电位  $\mathbf{v}_l(T)$  可以表示为所有时刻下，前一层脉冲神经元释放的脉冲  $s_{l-1}(t)$  经过加权后的膜电压减去释放脉冲带来的电压降：

$$\mathbf{v}_l(T) = \mathbf{W}_{l-1}^{\text{SNN}} \sum_t s_{l-1}(t) + \sum_t \mathbf{b}_{l-1}^{\text{SNN}} - v_{\text{th},l} \sum_t s_l(t) \quad (10)$$

式中， $v_{\text{th},l}$  表示  $l$  层脉冲神经元的阈值电压将上式表示为脉冲发放率的形式为

$$\mathbf{r}_l(T) = \frac{\sum_t s_l(t)}{T} = \frac{\mathbf{W}_{l-1}^{\text{SNN}} \sum_t s_{l-1}(t) + \sum_t \mathbf{b}_{l-1}^{\text{SNN}}}{T \cdot v_{\text{th},l}} - \frac{\mathbf{v}_l(T)}{T \cdot v_{\text{th},l}} \quad (11)$$

由式 (11) 可以注意到， $\mathbf{v}_l(T)$  始终不会超过  $v_{\text{th},l}$ ，当时间步  $T$  较长时式 (11) 的最后一项可以忽略。至此结合式 (8) 和式 (11) 可以得到卷积神经网络 ReLu 激活与 IF 脉冲神经元的激活映射关系。对于一个经过预训练的卷积神经网络，通过确定经过 ReLU 层的激活最大值，即可将卷积神经网络卷积层的权重迁移至脉冲神经网络中，从而将其 ReLu 激活函数转换为 IF 脉冲神经元。

但是通过对式 (11) 分析可以发现，脉冲神经网络的转换依赖于逐层确定 ReLu 激活函数的输出最大值，但是数据分布中若存在离群的极大值，则会需要为了表征这部分离群值而大大降低时间步的量化精度，从而影响转换性能。因此本文提出了一种基于动态裁剪阈值的激活函数层用来动态压缩激活值，带有动态裁剪阈值的激活函数可以表示如下：

$$\hat{\mathbf{a}} = \begin{cases} 0 & x \leq 0 \\ x & 0 < x < \sigma \\ \sigma & x \geq \sigma \end{cases} \quad (12)$$

式中， $\sigma$  为可训练的参数。在网络构建时，将所有

ReLU 激活函数替换为带有动态裁剪阈值的激活函数，随后在训练中将  $\sigma$  的优化器施加一个正则系数  $\gamma$  使得  $\sigma$  在训练过程中不断降低，从而间接压缩了每一层的激活值范围。

### 2.3 待转换网络构建

在本文工作中，使用了一个基于 YOLOv3 (Redmon 和 Farhadi, 2018) 架构的单阶段方法的目标识别神经网络作为待转换的源神经网络，网络包含的输出两个尺度的输出头。脉冲神经网络的网络结构如图 4 所示。由于 SNN 中的信息采取二值化脉冲串的方式进行传递，因此在池化操作中，池化核在每个时间步时都仅由 0 或 1 构成，这种特性使得 SNN 无法直接按照 ANN 中最大池化的计算方式进行操作 (Rueckauer 等, 2017)，因此在源网络中采用平均池化替代最大池化操作。考虑到转置卷积可以通过学习可训练的卷积核权重来执行上采样操作。因此在对特征图合并时使用转置卷积代替上采样操作，从而使低尺度的特征图合并至更大尺度特征图时能够表征更多信息。最后将网络所有激活层替换为带有动态裁剪阈值的激活函数。

## 3 实验结果与分析

### 3.1 数据集与实验环境

为了评估本文提出方法的性能，选择了 SSDD (SAR-Ship-Detection-Datasets) 和 RSOD 两个公开的遥感数据集进行了实验。两个数据集分别由数据图像和经过人工注释的标注框构成，分别包含船只与飞机目标。数据集的详细信息见表 1 与图 5。

实验在运行 Windows11 的 PC 上进行，CPU 为 AMD(R) Ryzen7 5800x，显卡为 Nvidia GeForce GTX 4090，本文所述方法使用 Pytorch1.13 深度学习框架搭建。在预训练源卷积神经网络时，使用 Adam 优化器进行训练，学习率为 0.01，动态裁剪激活层的正则系数  $\gamma$  为 0.2，预训练轮数为 400。

### 3.2 评价指标

目标检测性能使用平均精度 AP (Average Precision) 进行度量，AP 是用精度  $P$  为纵轴和召回率  $R$  为横轴的离散点绘制出的曲线下方的面积，即平均精度，AP 可以综合地衡量模型的找全能力与找准能力，精度  $P$  和召回率  $R$  的计算方式为

$$\begin{cases} P = \frac{TP}{(TP + FP)} \\ R = \frac{TP}{(TP + FN)} \end{cases} \quad (13)$$

式中, TP代表检测结果为正样本且真实值为正样本的预测框数量, FP代表检测结果为正样本但真实值为负样本的预测框数量, FN代表检测结果为负样本但真实值为正样本的预测框数量。

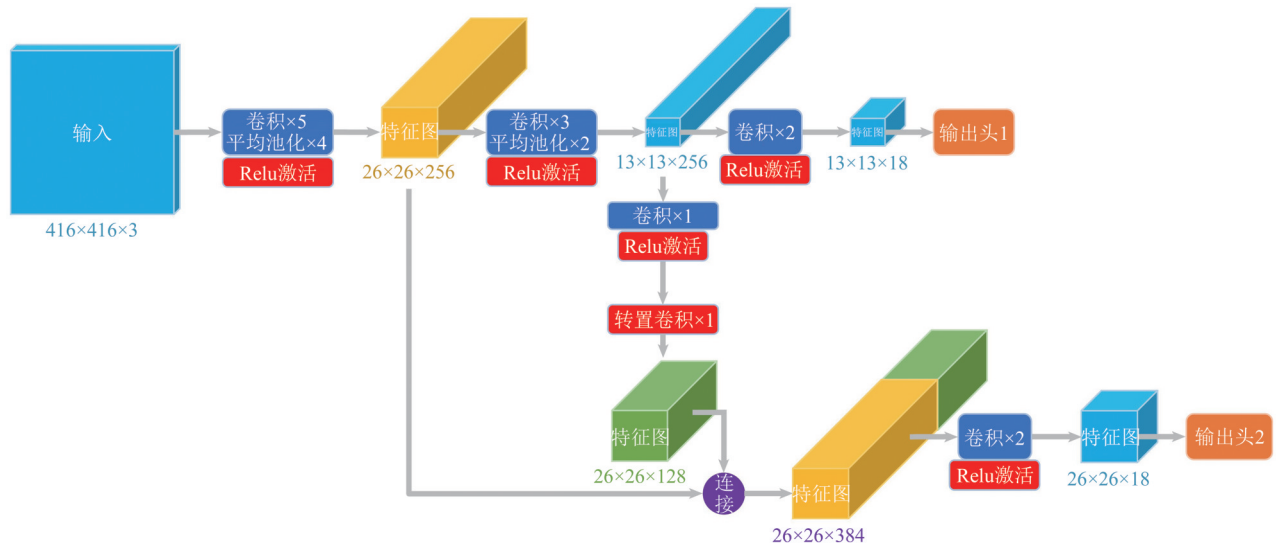


图4 源目标识别神经网络结构

Fig. 4 Architecture of source detection neural network

表1 数据集详细信息

Table 1 Datasets details

参量	数据集	
	SSD	RSOD
数据类型	SAR	光学遥感
来源	GF-3, Sentinel-1	Google earth
分辨率/m	3/5/8/10	0.3—3
图数量	39729	6112
图像尺寸	256x256	1044x915
检测目标	水面船舶	飞机



(a) SSD数据集中船舶目标  
(a) The illustration of ship targets in the SSD dataset



(b) RSOD数据集中飞机目标  
(b) The illustration of aircraft targets in the RSOD dataset

图5 两种数据集中的目标类别

Fig. 5 Diagrams of target categories in two datasets

### 3.3 实验结果

源网络训练完成后在测试数据集上进行测试,

在SSDD数据集上,源网络能够达到89.9%的平均精度,而在RSOD数据集上则能够达到90.21%,从而验证了待转换的卷积神经网络在遥感数据集上目标识别效果的有效性。随后将网络按照提出的方法转换为类脑脉冲神经网络,再将转换后的网络在两个数据集的测试集上使用不同的时间步长进行测试。在测试时,对比了本文提出的采用动态阈值转换的方法与使用固定阈值进行转换的方法。结果表明在时间步足够大时( $T > 224$ )时,无论是否使用动态裁剪阈值,转换后的类脑脉冲神经网络都能达到接近源网络的性能。但是在时间步较低时,如图6和图7所示,采用动态裁剪阈值的转换算法能更快地达到更高的平均精度,从而验证了压缩激活值能够在低时间步时提供更多的信息表征能力。不同时间步下网络检测示意图如图8所示。

为了进一步研究SNN在能量效率上的优势,本文从两种不同角度对SNN在能效上与源深度卷积神经网络进行能效对比测试。分别是SNN与源深度卷积神经网络在输入图像上的能耗以及SNN与源深度卷积神经网络在各自不同的计算平台上的能量消耗。




图6 转换后的类脑脉冲神经网络在RSOD数据集的检测性能

Fig. 6 Detection performance of transformed brain-inspired spiking network in RSOD dataset




图7 转换后的类脑脉冲神经网络在SSDD数据集的检测性能

Fig. 7 Detection performance of transformed brain-inspired spiking network in SSDD dataset




图8 不同时间步下转换的类脑脉冲神经网络检测效果

Fig. 8 Detection result of converted brain-inspired spiking neural networks in different time-steps

在深度卷积神经网络中，大部分的能耗过程发生在卷积层中。其中，卷积核与特征图的卷积运算涉及大量的乘累加MAC (Multiply-Accumulate) 操作中。而在SNN中，由于脉冲神经元的放电是二值化操作，网络能够仅在接收到脉冲放电时才会加至膜电位。因其仅在网络内部执行稀疏的累加AC (Accumulate) 运算，也因此带来了能效上的巨大潜力。根据 (Horowitz, 2014) 对运算操作的分析，在32位浮点乘累加操作中，乘运算消耗3.7 pJ，加运算占0.9 pJ，单次乘累加操作消耗为4.6 pJ。而在32位整数乘累加操作中，乘运算消耗3.1 pJ，加运算0.1 pJ。在此基础上，分别将源深度卷积神经网络与脉冲神经网络的浮点运算次数FLOPs (Floating-Point operations) 与MAC或AC运算次数相乘，计算出深度卷积神经网络与脉冲神经网络的计算复杂度与能量消耗对比，如表2所示。可以看出，转换后的脉冲神经网络在精度接近源网络的同时，计算复杂度降低了近两个数量级的计算量，而在能耗上则降低了近200倍的能量

消耗，在继承了ANN网络易于训练的特性与精度优势的同时，充分展现了其高稀疏度带来的巨大能效优势。

表2 转换后的类脑脉冲神经网络与源网络在单次推理时的能效对比

Table 2 Comparison of energy efficiency between converted brain-like pulse neural network and source network in single inference

网络类型	时间步长 T	平均精度/%	计算复杂度 (FLOPs)	能量消耗/J
源深度卷积神经网络 (YoloV3)	—	90.21	2.44E+10	0.05
转换后的脉冲神经网络	256	89.2	3.1639904E+8	0.00028

## 4 结论

为了解决主流深度学习模型在遥感图像检测中能效低和生物可解释性差的问题，本研究首次提出了一种基于类脑脉冲神经网络的遥感图像检

测算法。该算法的第一步是构建一个带有动态裁剪阈值的目标检测神经网络作为源网络进行预训练。然后利用训练过程中获得的裁剪阈值,通过映射源网络中的激活神经元和脉冲神经元的关系,将源网络转换为类脑脉冲神经网络。这种转换使得新的网络既能够保持源网络的高精度,又具备低延迟和高仿生性的特点。实验结果表明,在SSDD (SAR-Ship-Detection-Datasets) 和RSOD两个公开的遥感数据集上,该方法能够以极低的损失将源网络转换为类脑脉冲神经网络,并在较少的时间步下实现高精度的遥感目标检测和识别。通过将所提方法与标准类脑脉冲神经网络转换算法进行对比,验证了所提出方法在低时间步下的性能优势。若能够将所提出算法与当前快速发展的神经形态硬件相结合,则能够最大程度上发挥类脑脉冲神经网络稀疏性与二值放电的仿生性带来的能效优势,这也是未来的发展方向。

## 参考文献 (References)

- An R, Gong P, Wang H L, Feng X Z, Xiao P F, Chen Q, Zhang Q, Chen C Y and Yan P. 2010. A modified PSO algorithm for remote sensing image template matching. *Photogrammetric Engineering and Remote Sensing*, 76(4): 379-389 [DOI: 10.14358/PERS.76.4.379]
- Carion N, Massa F, Synnaeve G, Usunier N, Kirillov A and Zagoruyko S. 2020. End-to-end object detection with transformers//16th European Conference on Computer Vision. Glasgow: Springer: 213-229 [DOI: 10.1007/978-3-030-58452-8\_13]
- Che K W, Leng L, Zhang K X, Zhang J G, Meng M Q H, Cheng J, Guo Q H and Liao J X. 2022. Differentiable hierarchical and surrogate gradient search for spiking neural networks//Proceedings of the 36th International Conference on Neural Information Processing Systems. New Orleans: Curran Associates Inc.: 24975-24990
- Chen Y L, Qin R J, Zhang G X and Albanwan H. 2021. Spatial temporal analysis of traffic patterns during the COVID-19 epidemic by vehicle detection using planet remote-sensing satellite images. *Remote Sensing*, 13(2): 208 [DOI: 10.3390/rs13020208]
- El Shair I M. 2003. GIS and remote sensing in urban transportation planning: a case study of Birkenhead, Auckland//6th Annual International Conference. 28-31
- Gao J F, Chen Y, Wei Y M and Li J N. 2021. Detection of specific building in remote sensing images using a novel YOLO-S-CIOU model. Case: gas station identification. *Sensors*, 21(4): 1375 [DOI: 10.3390/s21041375]
- Ghosh-Dastidar S and Adeli H. 2009. Spiking neural networks. *International Journal of Neural Systems*, 19(4): 295-308 [DOI: 10.1142/S0129065709002002]
- Girshick R. 2015. Fast R-CNN//2015 IEEE International Conference on Computer Vision. Santiago: IEEE: 1440-1448 [DOI: 10.1109/ICCV.2015.169]
- Horowitz M. 2014. 1.1 computing's energy problem (and what we can do about it)//2014 IEEE International Solid-State Circuits Conference Digest of Technical Papers (ISSCC). San Francisco: IEEE: 10-14 [DOI: 10.1109/ISSCC.2014.6757323]
- Kheradpisheh S R, Ganjtabesh M, Thorpe S J and Masquelier T. 2018. STDP-based spiking deep convolutional neural networks for object recognition. *Neural Networks*, 99: 56-67 [DOI: 10.1016/j.neunet.2017.12.005]
- Li D R, Ding L and Shao Z F. 2021. Application-oriented real-time remote sensing service technology. *National Remote Sensing Bulletin*, 25(1): 15-24 (李德仁, 丁霖, 邵振峰. 2021. 面向实时应用的遥感服务技术. *遥感学报*, 25(1): 15-24) [DOI: 10.11834/jrs.20210260]
- Liu S C, Du K C, Zheng Y J, Chen J, Du P J and Tong X H. 2023. Remote sensing change detection technology in the era of artificial intelligence: inheritance, development and challenges. *National Remote Sensing Bulletin*, 27(9): 1975-1987 (柳思聪, 都科丞, 郑永杰, 陈晋, 杜培军, 童小华. 2023. 人工智能时代的遥感变化检测技术: 继承、发展与挑战. *遥感学报*, 27(9): 1975-1987) [DOI: 10.11834/jrs.20222199]
- Niu L Y, Wei Y and Liu Y. 2023. Event-driven spiking neural network based on membrane potential modulation for remote sensing image classification. *Engineering Applications of Artificial Intelligence*, 123: 106322 [DOI: 10.1016/j.engappai.2023.106322]
- Pham M T, Courtrai L, Friguet C, Lefèvre S and Baussard A. 2020. YOLO-Fine: one-stage detector of small objects under various backgrounds in remote sensing images. *Remote Sensing*, 12(15): 2501 [DOI: 10.3390/rs12152501]
- Redmon J, Divvala S, Girshick R and Farhadi A. 2016. You only look once: unified, real-time object detection//2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE: 779-788 [DOI: 10.1109/CVPR.2016.91]
- Redmon J and Farhadi A. 2018. Yolov3: an incremental improvement. arXiv preprint arXiv:1804.02767
- Rueckauer B, Lungu I A, Hu Y H, Pfeiffer M and Liu S C. 2017. Conversion of continuous-valued deep networks to efficient event-driven networks for image classification. *Frontiers in Neuroscience*, 11: 682 [DOI: 10.3389/fnins.2017.00682]
- Sha M M, Li Y and Li A. 2022. Multiscale aircraft detection in optical remote sensing imagery based on advanced Faster R-CNN. *National Remote Sensing Bulletin*, 26(8): 1624-1635 (沙苗苗, 李宇, 李安. 2022. 改进 Faster R-CNN 的遥感图像多尺度飞机目标检测. *遥感学报*, 26(8): 1624-1635) [DOI: 10.11834/jrs.20219365]
- Tavanaei A, Ghodrati M, Kheradpisheh S R, Masquelier T and Maida A. 2019. Deep learning in spiking neural networks. *Neural Networks*, 111: 47-63 [DOI: 10.1016/j.neunet.2018.12.002]
- Xu Z Y, Shen Z F, Li Y, Li J L, Wang H Y, Li S, Jiao S H and Li L L. 2022. Detection of water conservancy facilities in large-format image combining E-YOLO algorithm and NDWI constraint. *National Remote Sensing Bulletin*, 26(10): 2083-2093 (许泽宇, 沈占锋, 李杨, 李均力, 王浩宇, 李硕, 焦淑慧, 李苓苓. 2022. 结合



- E-YOLO 和水体指数约束的大面幅影像水利设施检测. 遥感学报, 26(10): 2083-2093 [DOI: 10.11834/jrs.20200124]
- Zhang S M, Wu R Z, Xu K Y, Wang J M and Sun W W. 2019. R-CNN-based ship detection from high resolution remote sensing imagery. *Remote Sensing*, 11(6): 631 [DOI: 10.3390/rs11060631]
- Zhang Y P, Bi D P, Zhou Y, Zhang B and Fang M X. 2019. Effect of cosinusoidal phase-modulated scatter-wave jamming to the jamming suppression of SAR dual-channel cancellation. *Journal of Remote Sensing (in Chinese)*, 23(1): 99-107 (张云鹏, 毕大平, 周阳, 张博, 房明星. 2019. 余弦调制散射波干扰对 SAR 双通道对消干扰抑制的影响. 遥感学报, 23(1): 99-107) [DOI: 10.11834/jrs.20197114]
- Zhu X X, Montazeri S, Ali M, Hua Y S, Wang Y Y, Mou L C, Shi Y L, Xu F and Bamler R. 2021. Deep learning meets SAR: concepts, models, pitfalls, and perspectives. *IEEE Geoscience and Remote Sensing Magazine*, 9(4): 143-172 [DOI: 10.1109/MGRS.2020.3046356]

## Remote sensing image detection method based on brain-inspired spiking neural networks

DUAN Dexin<sup>1</sup>, LU Yao<sup>2</sup>, HUANG Liwei<sup>2</sup>, LIU Peilin<sup>1</sup>, WEN Fei<sup>1</sup>

1. School of Electronic Information and Electrical Engineering, Shanghai Jiao Tong University, Shanghai 200240, China;

2. Beijing Institute of Remote Sensing Information, Beijing 100192, China

**Abstract:** In the intelligent processing of remote sensing images, third-generation brain-inspired Spiking Neural Network (SNN) surpasses its predecessor, the second-generation artificial neural network, showing remarkable advantages in terms of high energy efficiency, high precision, and high interpretability. These advantages stem from the SNN's characteristic features, including high energy efficiency, elevated sparsity, and remarkable bio-plausibility. The integration of these features in the SNN presents an enthralling solution to challenges faced in remote sensing image processing and holds immense potential for advancing this field further.

The proposed algorithm introduces a novel approach and initially establishes a target-detection neural network, which serves as the source artificial neural network for pretraining. This source network utilizes a dynamic clipping threshold activation function to optimize its performance. Subsequently, the algorithm transforms the source network into a brain-inspired SNN by leveraging the mapping relationship between activated neurons and spiking neurons. This conversion process effectively incorporates the clipping thresholds obtained during training. By seamlessly transitioning the source network into an SNN, the algorithm ensures the preservation and enhancement of key characteristics essential for remote sensing image processing.

The efficacy of the proposed method was evaluated through extensive experiments performed on two widely recognized open remote sensing datasets: SAR-Ship-Detection-Datasets (SSDD) and RSOD. Experimental results highlighted the exceptional capabilities of the proposed method in transforming the source network into a brain-inspired spiking neural network, demonstrating negligible loss in performance. Furthermore, the transformed SNN exhibited remarkable accuracy in detecting and recognizing remote sensing targets within significantly reduced time steps. The performance achieved by the transformed SNN was comparable to that of the source artificial neural network while tremendously reducing power consumption by over two orders of magnitudes. This outcome highlights the immense potential of the proposed method in revolutionizing the field of remote sensing image processing by delivering high precision and interpretability which considerably reducing energy consumption.

The integration of the third-generation brain-inspired SNN into remote sensing image processing holds tremendous potential primarily due to its high precision and low energy consumption. The proposed algorithm highlights the distinctive attributes of the SNN, such as its low delay, high bionics, and ability to inherit high precision observed in a source network. These characteristics are promising indicators of SNN's capability to considerably enhance the intelligent processing of remote sensing images. By leveraging the SNN's high precision and bio-plausible principles, the proposed algorithm lays a robust foundation for future advancements in the field of remote sensing. The SNN's inclusion in the image processing pipeline causes a paradigm shift, challenging traditional assumptions and unlocking new possibilities. The SNN is highly accurate in identifying and classifying targets with remarkable precision during remote sensing target detection. In conclusion, the proposed algorithm exhibits low delay and high bionics while demonstrating the high precision of a source network, demonstrating its potential to considerably improve the intelligent processing of remote sensing images and offering high accuracy, precision, interpretability; low energy consumption; and high bio-plausibility.

**Key words:** SAR, remote sensing image, optical remote sensing, target detection, deep learning, spiking neural networks

**Supported by** Science and Technology Innovation 2030-Major Project (Brain Science and Brain-Like Intelligence Technology) (No. 2022ZD0208701); Foundation of Key Laboratory of Satellite Information Intelligent Processing and Application Research