

自校准首脉冲时间编码神经元模型

冯忍, 陈云华, 熊志民, 陈平华

引用本文

冯忍, 陈云华, 熊志民, 陈平华. [自校准首脉冲时间编码神经元模型](#)[J]. 计算机科学, 2024, 51(3): 244-250.

FENG Ren, CHEN Yunhua, XIONG Zhimin, CHEN Pinghua. [Self-calibrating First Spike Temporal Encoding Neuron Model](#) [J]. Computer Science, 2024, 51(3): 244-250.

相似文献推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[类脑计算脉冲神经网络模型及其学习算法研究进展](#)

Spiking Neural Network Model for Brain-like Computing and Progress of Its Learning Algorithm
计算机科学, 2023, 50(1): 229-242. <https://doi.org/10.11896/jsjx.220100058>

[一种基于脉冲神经网络的星体表面岩石检测算法](#)

Onboard Rock Detection Algorithm Based on Spiking Neural Network
计算机科学, 2023, 50(1): 98-104. <https://doi.org/10.11896/jsjx.211100149>

[具有生物真实性的强抗噪性神经元激活函数](#)

Bio-inspired Activation Function with Strong Anti-noise Ability
计算机科学, 2019, 46(7): 206-210. <https://doi.org/10.11896/j.issn.1002-137X.2019.07.031>

[一种混合云环境下基于Merkle哈希树的数据安全去重方案](#)

Secure Data Deduplication Scheme Based on Merkle Hash Tree in HybridCloud Storage Environments
计算机科学, 2018, 45(11): 187-192. <https://doi.org/10.11896/j.issn.1002-137X.2018.11.029>

[基于面部视觉特征的精神疲劳可拓辨识模型](#)

Mental Fatigue Recognition Extension Model Based on Facial Visual Cues
计算机科学, 2013, 40(2): 284-288.

自校准首脉冲时间编码神经元模型

冯 忍 陈云华 熊志民 陈平华

广东工业大学计算机学院 广州 510006

(2359091834@qq.com)

摘要 由于脉冲神经元具有复杂的时空动力过程且脉冲信息不可导,脉冲神经网络(SNN)的训练一直是一个难题。基于人工神经网络(ANN)转SNN间接训练深度SNN的方法,避免了直接训练深度SNN的难题,但该方法所获得的SNN的性能在很大程度上会受到脉冲信息编码机制的影响。在众多编码机制中,首脉冲时间编码(TTFS)具有良好的生物学基础和更高的能效,但现有TTFS编码采用单脉冲形式,信息表征能力较弱,编码所需时间窗较大。为此,在TTFS的单脉冲编码基础上,增加一个校准脉冲,形成一种自校准首脉冲时间(SC-TTFS)编码机制,并构建相应的SC-TTFS神经元模型。在SC-TTFS中,首脉冲为必定发放的脉冲,而校准脉冲根据首脉冲发放后剩余的膜电位来确定是否发放,用于对编码脉冲所引起的转换量化误差和截断误差进行补偿,同时缩小编码所需的时间窗。通过对多种编码对应的转换误差进行对比分析,以及在多种网络结构上进行ANN-SNN转换实验,验证了所提方法的优越性。采用CIFAR10和CIFAR100数据集,基于VGG和ResNet两种网络结构进行了实验验证。结果表明,所提方法在两类网络结构和两种数据集上均实现了精度无损的ANN-SNN转换,且相较于最先进的同类方法,所提方法所构建的SNN具有最短的网络推理延迟。另外,在VGG结构上,所提方法相比TTFS编码能源效率提升了约80%。

关键词: 脉冲神经网络;脉冲编码机制;ANN-SNN转化

中图分类号 TP183

Self-calibrating First Spike Temporal Encoding Neuron Model

FENG Ren, CHEN Yunhua, XIONG Zhimin and CHEN Pinghua

School of Computer Science, Guangdong University of Technology, Guangzhou 510006, China

Abstract Because of the complex spatio-temporal dynamic process of spike neurons and the non-differentiable spike information, the training of spike neural network(SNN) has always been very difficult. The ANN-to-SNN method for indirect training of deep SNN avoids the difficulties of direct training of deep SNN. However, the performance of the SNN obtained in this approach is greatly affected by the spike information encoding mechanism. Among many coding mechanisms, TTFS has a good biological basis and is energy efficient, but existing TTFS codes use a single-spike formalism, which has weak information representation capability and large time windows for encoding. Therefore, based on the single spike coding of TTFS, a calibration spike is added to form a self-calibrating first spike time to first spike coding mechanism, and the corresponding SC-TTFS neuron model is constructed. In SC-TTFS, the first spike is the spike that must be emitted, while the calibration spike determines whether it is emitted according to the residual membrane potential after the first spike is emitted, which is used to compensate the quantification error and truncation error caused by the coding spike and to reduce the time window required for coding. The advantages of this approach are verified by comparing and analyzing the corresponding conversion errors of various codes and ANN-SNN conversion experiments on various network architectures. On CIFAR10 and CIFAR100 datasets, the proposed algorithm is verified by experiments based on VGG and ResNet network structures, and it achieves ANN-SNN transformation with non-destructive accuracy on both network structures and two data sets. Compared to state-of-the-art similar methods, the SNN constructed by the proposed method has the smallest network inference latency. In addition, on the VGG structure, the proposed method improves the energy efficiency by about 80% compared with TTFS coding.

Keywords Spiking neural network, Spike encoding mechanism, ANN-SNN conversion

到稿日期:2022-12-01 返修日期:2023-04-05

基金项目:广东省自然科学基金(2021A1515012233)

This work was supported by the Natural Science Foundation of Guangdong Province, China(2021A1515012233).

通信作者:陈云华(yhchen@gdut.edu.cn)

1 引言

作为第三代人工神经网络,脉冲神经网络(Spiking Neural Network, SNN)借鉴了生物神经系统的信息处理机制,兼具生物合理性和计算高效性,为类脑计算的发展提供了必要的模型和算法^[1]。与 ANN(Analog Neural Network)相比, SNN 的异步脉冲传输机制使其适合部署在具有神经形态计算芯片的硬件设备上,且具有低功耗、低延迟和计算潜能强大等优势。由于脉冲神经元具有复杂的时空动力过程且脉冲信息不可导, SNN 的训练一直是一个难题。

有研究者通过对脉冲发放过程进行近似,基于近似梯度对 SNN 进行监督式训练^[2-5]或者基于 STDP 规则^[6-7]进行无监督式训练。但这两类方法训练得到的 SNN 的精度仍然较低,且很难实现深层次的 SNN。2015 年, Cao 等^[8]提出基于 ANN 转 SNN 间接训练 SNN 的方法,获得了具有较高分类精度的深度 SNN。该方法的基本思路是先通过监督学习训练 ANN,然后将训练好的权重等参数迁移到与 ANN 具有相同结构的 SNN 上。基于 ANN 转 SNN 间接训练 SNN 的方法,避免了直接训练深度 SNN 所面临的难题,但由于 SNN 与 ANN 的信息处理与传递机制存在巨大差异,转化得到的 SNN 有较大的精度损失。为此,研究者对 ANN-SNN 转换误差进行了大量研究^[9-12],结果表明,要实现精度无损的转换, SNN 神经元的解码值应高度接近于 ANN 神经元的激活值。而脉冲序列的解码值取决于其所采用的脉冲信息编码机制。因此,基于 ANN 转 SNN 间接训练 SNN 的方法的性能在很大程度上会受到脉冲信息编码机制的影响。

目前,在 ANN-SNN 转换的研究工作中主要存在两类脉冲信息编码机制:速率编码^[8-12]和时间编码。速率编码通过统计 SNN 推理时间窗口内神经元发放的脉冲数量来解码脉冲序列的信息。速率编码虽然简单且鲁棒性强,但却忽视了脉冲序列中所包含的时间信息,且会产生大量脉冲,导致 SNN 的网络推理延迟和功耗过高。时间编码可分为相位编码^[13-15]、突发编码^[16-17]和首脉冲时间编码(Time to First Spike, TTFS)^[18-21]等几大类。其中, TTFS 编码具有良好的生物学基础和最高的能效,其源于人类视觉神经对刺激信号快速反应。有研究表明^[22-23],神经元在接收到刺激后产生的第一个脉冲的时间包含了刺激的大部分信息。TTFS 编码是一种将神经元膜电位转变为脉冲发放时间的编码机制,神经元产生脉冲的时刻与膜电位值的大小成比例。

近年来,出现了不少基于 TTFS 编码的 ANN-SNN 转化研究。2018 年, Rueckauer 等^[18]基于 SNN 首脉冲发放时间与 ANN 模拟激活值的反比关系,首次在 SNN 中实现 TTFS 编码,但其方法并不适用于深度神经网络模型。2019 年, Zhang 等^[20]根据 LIF 神经元模型的特性提出了基于 TTFS 的反向编码,并设计了 Ticking 神经元来辅助实现。反向编码使得深度 SNN 应用 TTFS 也能取得较高的网络精度,但由于使用了 Ticking 神经元, SNN 需要执行大量额外的加法运算。2020 年, Park 等^[21]针对反向编码计算量较大的缺陷,提出了 T2FSNN 模型。T2FSNN 采用一个指数衰减的函数作为神经元的阈值核函数,将膜电位编码成脉冲时间,极大地

降低了编码所需的脉冲数及系统实现的额外运算,但仍需要较大的编码时间窗口才能实现无损转换。上述方法中的 TTFS 编码,均采用单脉冲编码,由于单脉冲的信息表征能力较弱,为了实现精度无损的转换,往往需要设置较长的编码时间窗口。例如 Park 等提出的 T2FSNN 模型,需要将 SNN 神经元的编码时间窗口设置为 32 个时间步(甚至更长)才能实现精度接近无损的转换,最终导致网络的精度和延迟性能均不理想。

相比 T2FSNN 的单脉冲形式, Stöckl 等^[24]提出的 FS 神经元模型采用多脉冲来拟合 ANN 的激活值,其所用的编码时间窗口更小。受到该项研究的启发,本文在 TTFS 单个编码脉冲的基础上增加校准脉冲,以提升 TTFS 编码的性能。根据 Davidson 等^[25]对 ANN 与 SNN 在数字硬件上实现的性能的对比结果可知, SNN 神经元并不宜发放超过两个脉冲,否则将丧失其固有的低功耗和低延迟的性能优势。为此,本文在 TTFS 的首脉冲编码基础上,增加一个校准脉冲,形成了一种自校准首脉冲时间(Self-calibrating Time to First Spike, SC-TTFS)编码机制,并构建了相应的 SC-TTFS 神经元模型。首脉冲和校准脉冲都遵循信息强度越大、脉冲发放的时刻点越早这一原则。在 SC-TTFS 中,首脉冲为必定发放的脉冲,而校准脉冲根据首脉冲发放后剩余的膜电位确定是否发放,因此, SC-TTFS 神经元在时间窗内最多发放两个脉冲。在国内外文献中,尚未见到有与本文提出的 SC-TTFS 编码方案相同或者类似的方案。与国内外最新的成果相比,本文提出的 SC-TTFS 不仅能够实现较高精度下的无损转换,还能够大幅度降低网络延迟和功耗。

2 基于 TTFS 编码的 ANN-SNN 转化

2.1 TTFS 编码机制

SNN 由脉冲神经元组成,神经元之间通过突触连接,神经元在接收到突触前神经元的输入脉冲信号后,将其累积到自身膜电位上,一旦累积的膜电位超过神经元的发放阈值时,便向突触后神经元发放脉冲。如图 1(a)所示,基于 TTFS 编码的 SNN 神经元只发放一个脉冲,之后神经元将被抑制产生更多脉冲,且神经元的膜电位越大,其脉冲发放的时间越早。突触后神经元在接收到突触前神经元发放的脉冲后,根据其发放的精确时间对脉冲进行解码,并累积到自身膜电位上,其过程可以通过如下公式表示^[21]:

$$v_j^l(t) = v_j^l(t-1) + s_j^l(t) \quad (1)$$

$$s_j^l(t) = \sum_{i=1}^{M^{l-1}} W_{ij}^l z_i^{l-1}(t) \quad (2)$$

$$z_i^{l-1}(t) = \varphi^{l-1}(t) \delta_i^{l-1}(t) \quad (3)$$

$$\delta_i^{l-1}(t) = \begin{cases} 1, & \text{if } v_i^{l-1}(t) \geq \theta^{l-1} \\ 0, & \text{else} \end{cases} \quad (4)$$

其中, $v_j^l(t)$ 表示网络第 l 层神经元 j 在 t 时刻的累积膜电位, $s_j^l(t)$ 表示神经元 j 在 t 时刻接收到的脉冲解码输入, M^{l-1} 表示网络第 $l-1$ 层的神经元个数, W_{ij}^l 表示网络第 l 层与第 $l-1$ 层的连接权重, $z_i^{l-1}(t)$ 表示 SNN 第 $l-1$ 层神经元 i 的输出脉冲解码值, $\varphi^{l-1}(t)$ 表示脉冲时间的解码函数, $\delta_i^{l-1}(t)$ 表示脉冲序列, θ^{l-1} 表示网络第 $l-1$ 层神经元的发放阈值。

2.2 ANN-SNN 转化

TTFS 编码机制下, ANN-SNN 转化的基本原理是使得 $v_i^l = a_i^l$ (a_i^l 表示 ANN 第 l 层神经元 i 的激活值), 即 SNN 的累积膜电位(解码值)等于 ANN 的激活值。然而 SNN 的脉冲响应函数与 ANN 的激活函数存在差异, 因此不可避免地会产生转化损失。在转化工作中, ANN 常用 ReLU 激活函数^[8]。

$$a_j^{l+1} = \max(0, \sum_i^M W_{ij}^{l+1} a_i^l) \quad (5)$$

这里假设不使用偏置项, a_j^{l+1} 表示 ANN 第 $l+1$ 层神经元 j 的输入值。根据 TTFS 编码原理, SNN 的脉冲响应函数可用如下公式表示:

$$V_j^{l+1} = \sum_{i=1}^M W_{ij}^{l+1} e^t(t) \delta_i^l(t) \quad (6)$$

$$t = \text{clip}(\lceil \phi(v_i^l) \rceil, 0, T) \quad (7)$$

其中, V_j^{l+1} 表示 SNN 第 $l+1$ 层神经元 j 的膜电位(类比 ANN 的输入值); $\phi: v \rightarrow t$ 表示 TTFS 编码机制的膜电位到脉冲时刻的单调衰减映射函数; T 表示编码时间窗口; clip 函数设置上边界 T 和下边界 0 ; $\lceil x \rceil$ 为 ceil 函数, 即返回大于或等于 x 的最小整数。该脉冲响应函数如图 1(b)(实线)所示, 可以看到其与 ANN 的 ReLU 激活函数(虚线)存在较大差异。

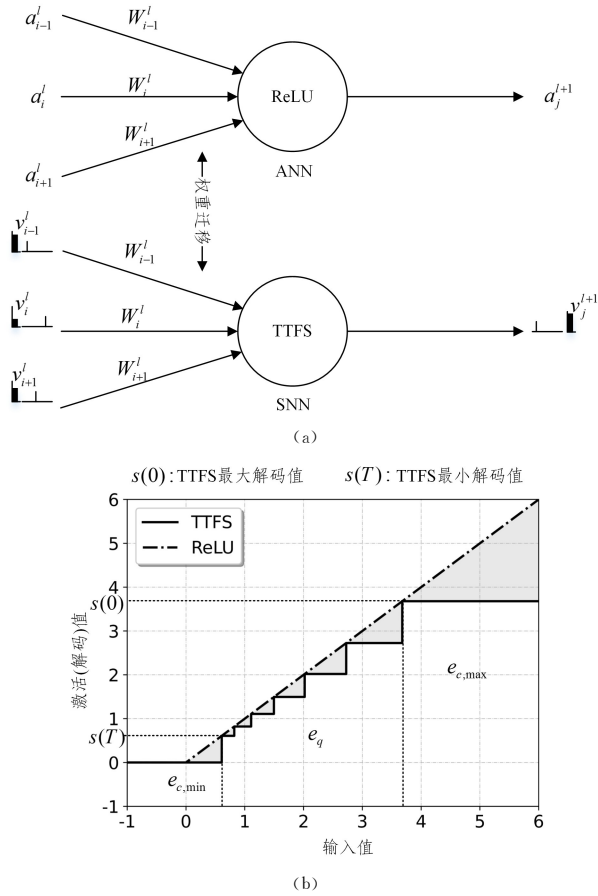


图 1 TTFS 编码机制及 ANN-SNN 转化误差

Fig. 1 TTFS coding mechanism and conversion error of ANN-SNN

根据 ANN-SNN 转化的基本原理, 优化转化的目标为:

$$\min(\text{clipceil}(v, T) - \text{ReLU}(a)) \quad (8)$$

为了优化此目标, TTFS 编码只能增大时间窗口 T , 导致 SNN 的推理延迟较大。可见, TTFS 的单脉冲编码有其固有

的缺陷。从式(8)可以看出, 降低转换误差的关键在于减少 SNN 编码中的 clip 和 ceil 函数所导致的截断和量化误差。受到 Stöckl 等^[24]提出的多脉冲相位编码的启发, 同时结合 Davidson 等^[25]关于 SNN 神经元最佳发放脉冲数的研究结果, 本文在 TTFS 的首脉冲编码基础上, 增加了一个校准脉冲, 形成了一种自校准首脉冲时间(SC-TTFS)编码机制。在 SC-TTFS 中, 神经元最多发放两个脉冲, 其中, 首脉冲为必定发放的脉冲, 而校准脉冲根据首脉冲发放后剩余的膜电位确定是否发放, 用于对编码脉冲所引起的转换量化误差和截断误差进行补偿, 从而缩小编码所需的时间窗。

3 SC-TTFS 编码机制及神经元模型

如图 2(a)所示, 与 TTFS 编码在时间窗口 T 内仅产生单个脉冲不同, SC-TTFS 在时间窗口 T 内最多可产生两个脉冲。同时, 在 SC-TTFS 编码机制中, 神经元传递信息的过程被分为两个阶段: 编码阶段和解码阶段。如图 2(b)所示, 神经元在编码阶段产生脉冲, 在解码阶段接收上一层神经元发放的脉冲, 在执行网络推理时, 此过程将以流水线的方式进行。为了在特定时刻产生相应的脉冲, SC-TTFS 神经元设置有两个阈值: 编码阈值与校准阈值。下面详细介绍 SC-TTFS 编码机制及神经元模型。

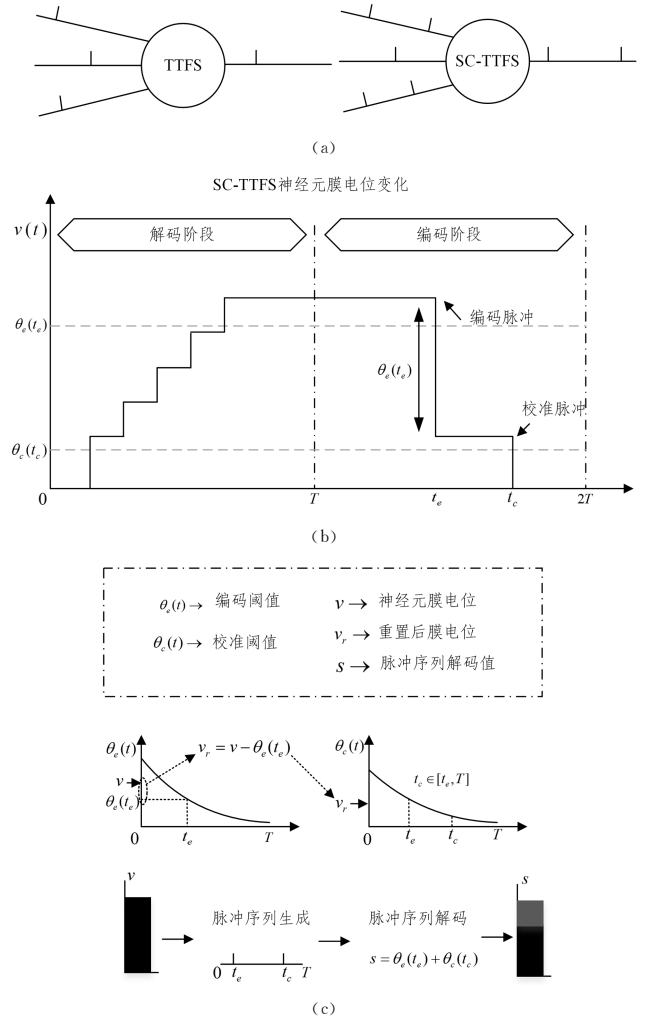


图 2 SC-TTFS 编码机制及神经元模型

Fig. 2 SC-TTFS coding mechanism and neuron model

3.1 编码阈值与校准阈值

SC-TTFS 神经元中有两个阈值——编码阈值与校准阈值,如图 2(b)所示。在编码阶段,神经元优先根据编码阈值判定是否发放编码脉冲:

$$t_j^{l,e} = \arg \min_t \min(v_j^l(t) \geq \theta_c^l(t)), t \geq 0 \quad (9)$$

其中, $t_j^{l,e}$ 表示 SNN 第 l 层神经元 j 的编码脉冲发放时间点,为了方便表示,本文都以脉冲的发放时间点表示神经元发放的脉冲; $v_j^l(t)$ 表示神经元 j 在 t 时刻的膜电位; $\theta_c^l(t)$ 表示 SNN 第 l 层神经元的编码阈值。为了提高 SNN 网络的稀疏性,若在编码窗口结束后,膜电位仍低于阈值,则神经元不发放脉冲,其脉冲时间视为无穷大,即:

$$t_j^{l,e} = \infty, \text{ if } v_j^l(T) < \theta_c^l(T) \quad (10)$$

其中, T 表示编码阶段的编码时间窗口长度。如果神经元在编码阈值下发放了脉冲,则将其膜电位按以下方式进行重置:

$$v_{j,r}^l(t) = v_j^l(t) - \theta_c^l(t_j^{l,e}) \quad (11)$$

重置后的神经元膜电位 $v_{j,r}^l(t)$ 将在校准阈值下判定是否发放校准脉冲:

$$t_j^{l,c} = \arg \min_t \min(v_{j,r}^l(t) \geq \theta_c^l(t)), t \geq t_j^{l,e} \quad (12)$$

其中, $t_j^{l,c}$ 表示校准脉冲的发放时间点, $\theta_c^l(t)$ 表示校准阈值。由于校准脉冲是在编码脉冲之后发放,故 $t_j^{l,c} \geq t_j^{l,e}$, 同样地,

$$t_j^{l,c} = \infty, \text{ if } v_{j,r}^l(T) < \theta_c^l(T) \quad (13)$$

SC-TTFS 神经元在发放校准脉冲后,膜电位将被重置为 0 以抑制发放更多脉冲。在 SC-TTFS 神经元中,编码阈值与校准阈值均由指数衰减的函数来表示。

$$\theta_c^l(t) = \alpha^l e^{(-k^l t + \beta^l)}, \theta_c^l(t) = \alpha^l e^{(-k^l t + \beta^l)} \quad (14)$$

其中, α, β, k 均为可训练的超参数。使用衰减的函数来表示神经元阈值是为了实现神经元膜电位越大就越早发放脉冲,且使用函数可以减少训练相关参数时的硬件内存和时长消耗。

3.2 SC-TTFS 神经元

SC-TTFS 神经元的膜电位变化如图 2(b)所示。在编码阶段,当神经元膜电位超过对应阈值时便发放一个脉冲,其脉冲的发放时间可通过以下公式求得:

$$t = \lceil \max(0, (-\ln(v/\alpha + \tau) + \beta)/k) \rceil \quad (15)$$

其中, τ 为 \ln 函数的稳定系数。神经元脉冲发放的时间点为编码时间窗口 $[0, T]$ 内的整数。在解码阶段, SC-TTFS 神经元根据相应的阈值函数对上一层神经元发放的脉冲进行解码,并累积到膜电位上。

$$v_j^l(t) = v_j^l(t-1) + \sum_i^{M^{l-1}} W_{ij}^l \theta_c^{l-1}(t) \epsilon(t - t_i^{l-1,e}) + \sum_i^{M^{l-1}} W_{ij}^l \theta_c^{l-1}(t) \epsilon(t - t_i^{l-1,c}) \quad (16)$$

$$\epsilon(t) = \begin{cases} 1, & \text{if } t=0 \\ 0, & \text{else} \end{cases} \quad (17)$$

3.3 SC-TTFS 与 TTFS 对比分析

相比 TTFS 编码, SC-TTFS 增加了校准脉冲,这将导致 SNN 执行网络推理时增加最多一倍的发放脉冲数量。由于编码时间窗口有限, SC-TTFS 可用查找表替代编码和解码阈值函数以避免乘法计算,故校准脉冲只会使硬件系统增加成本较低的操作。下面分别对使用 TTFS 和 SC-TTFS 编码机制的 ANN-SNN 转化误差进行比较分析。假设两者使用

相同的映射函数将神经元膜电位转化为脉冲,并使用相同的脉冲解码函数,如图 1(b)所示,基于 TTFS 编码的 ANN-SNN 转化的截断误差与量化误差可以通过以下公式表示:

$$e_a^l = \sum_{i=1}^{M^l} |a_i^l - s_i^l(f)| \leq \sum_{j=1}^{L^l} |a_j^l - s_j^l(T)| + \sum_{k=1}^{M^l - (U^l + L^l)} |s_k^l(f - 1) - s_k^l(f)| + \sum_{i=1}^{U^l} |a_i^l - s_i^l(0)| \quad (18)$$

$$= e_{c,\min}^l + e_q^l + e_{c,\max}^l$$

其中, M^l 表示网络第 l 层神经元的数量, a_i^l 表示 ANN 第 l 层神经元 i 的激活值, f 表示脉冲的发放时间, U^l 为 ANN 网络层中激活值大于 SNN 输出脉冲解码最大值的神经元数量, L^l 为 ANN 网络层中激活值小于 SNN 输出脉冲解码最小值的神经元数量, $s_i^l(0)$ 和 $s_i^l(T)$ 分别表示 SNN 脉冲解码最大值和最小值。 L^l 与 U^l 分别形成了 SNN 与 ANN 的截断误差 $e_{c,\min}^l$ 和 $e_{c,\max}^l$, e_q^l 为量化误差。基于 SC-TTFS 神经元的 SNN 与 ANN 第 l 层输出值之间的误差 e_e^l 为:

$$e_e^l = \sum_{i=1}^{M^l} |a_i^l - (s_i^{l,e}(f_e) + s_i^{l,c}(f_c))| \leq \sum_{j=1}^{L^l} |a_j^l - s_j^{l,e}(T)| + \sum_{i=1}^{U^l} |a_i^l - s_i^{l,e}(0) - s_i^{l,c}(0)| + \sum_{k=1}^{M^l - (U^l + L^l)} |s_k^{l,e}(f_e - 1) - s_k^{l,e}(f_e) - s_k^{l,c}(f_c)| \leq e_{c,\min}^l + e_{c,\max}^l + e_q^l \quad (19)$$

其中, $s_i^{l,e}$ 和 $s_i^{l,c}$ 分别表示 SNN 第 l 层神经元 i 编码脉冲和校准脉冲的解码值, f_e 和 f_c 分别表示神经元发放阈值脉冲和校准脉冲的精确时间。根据式(18)与式(19)可知,与使用单脉冲的 TTFS 编码相比,在增加了校准脉冲后, SNN 与 ANN 输出值之间的量化误差与截断误差均有所减小,且根据 SC-TTFS 编码机制,神经元所能产生的脉冲序列数为:

$$N(T) = \sum_{i=1}^T (i+1)$$

即神经元的解码值数从 T 扩展到了 $N(T)$, 这可以大幅降低编码的时间窗 T , 减小 SNN 的推理延迟。虽然发放更多的脉冲可以进一步减小转化误差,但 Davidson 等^[25]对 ANN 与 SNN 在数字硬件上的性能对比研究结果表明, SNN 的神经元并不宜发放超过两个脉冲,因此,本文将 SC-TTFS 编码设计为最多发放一个编码脉冲和一个校准脉冲。

3.4 SC-TTFS 神经元及 BN 层超参数调优

关于 SC-TTFS 神经元的超参数设置,可以根据 ANN 的输出激活值进行调整,使 SNN 的输出脉冲序列在解码后与 ANN 的激活值接近。然而 SC-TTFS 神经元的编码时间窗口有限, SNN 与 ANN 之间必然存在近似误差,且在深度神经网络结构中,网络层间的近似误差会逐层累积^[7],最终导致网络精度下降。为了解决这个问题,本文提出对 SC-TTFS 神经元及 BN 层超参数进行调优,方法如下:

1) 将 ANN 中的模拟神经元替换为 SC-TTFS 神经元,构成预转化 SNN;

2) 基于梯度下降法训练预转化 SNN 中神经元以及 BN (Batch-Normalization, BN) 层的超参数;

3) 预转化 SNN 训练完成后,将网络中 BN 层的参数整合到前层中构成最终的 SNN。

其中,基于梯度下降法训练预转化 SNN 时,其损失函数 L_{CE} 为预转化 SNN 输出层与训练集标签的交叉熵,即:

$$L_{CE} = -\sum_i y_i \log_2(v_i) \quad (20)$$

其中, y 为训练集的 one-hot 标签, v 为预转化 SNN 输出层的累积膜电位。由于使用了函数来代替阈值, 因此可以很容易地求得反向传播过程中 SC-TTFS 神经元超参数的梯度信息。

$$\frac{\partial L_{CE}}{\partial \alpha_c} = \frac{\partial L_{CE}}{\partial v^{j+1}} \frac{\partial v^{j+1}}{\partial \alpha_c} = W^l (e^{-k_c^l t^{l,c} + \beta_c^l}) \quad (21)$$

$$\frac{\partial L_{CE}}{\partial k_c^l} = \frac{\partial L_{CE}}{\partial v^{j+1}} \frac{\partial v^{j+1}}{\partial k_c^l} = -W^l t^{l,c} \theta_c^l (t^{l,c}) \quad (22)$$

$$\frac{\partial L_{CE}}{\partial \beta_c^l} = \frac{\partial L_{CE}}{\partial v^{j+1}} \frac{\partial v^{j+1}}{\partial \beta_c^l} = W^l \theta_c^l (t^{l,c}) \quad (23)$$

其中, 校准阈值函数的超参数 α_c, β_c, k_c 的梯度与以上公式类似。在 ANN 中, BN 层的作用在于减少 ANN 的内部协变量偏移, 从而加快网络的训练过程。由于其无法被转化成 SNN 模式, 因此在预转化 SNN 训练完成后, 需要将 BN 层的参数整合到前层中。

$$W \leftarrow W \frac{\gamma}{\sigma}, b \leftarrow \beta + (b - \mu) \frac{\gamma}{\sigma} \quad (24)$$

其中, W 和 b 为前层的权重和偏置参数, $\gamma, \sigma, \beta, \mu$ 均为 BN 层的参数, 且 γ 和 β 为需要训练的超参数。

4 实验结果

4.1 数据集及相关实验设置

为了更好地与其他相关研究工作进行比较, 本文训练 VGG16^[26] 和 ResNet20^[27] 作为基准 ANN 模型, 再将其转化为 SNN, 并在 CIFAR10 和 CIFAR100 数据集^[28] 上验证本文提出的方法。其中, CIFAR10 数据集包含 60 000 张 RGB 彩色图像, 每张图像的尺寸为 32×32 , 图像的标签分为 10 个类别, 其中 50 000 张作为训练集图像, 10 000 张作为测试集图像。CIFAR-100 数据集与 CIFAR10 数据集类似, 其图像标签分为 100 个类别, 每个类别各有 500 张训练图像和 100 张测试图像。在具体实验中, 本文对两类数据集进行了归一化处理。

在将 ANN 转化成 SNN 之后, 本文基于 ANN 在两个数据集上各网络层的输出数据分布对 SC-TTFS 神经元的超参数进行了初始化设置, 此初始化操作是为了加快网络的收敛速度, 减少训练时长。在本实验中, SC-TTFS 神经元在两个数据集上的相关系数初始化如表 1 所列。在对 SNN 进行训练时, 本文使用 Adam 优化器调整学习率, 由于初始化 SC-TTFS 神经元的参数后, SNN 各网络层输出数据分布已与 ANN 接近, 过大的学习率会导致网络的收敛过程出现较大波动, 因此本文将初始学习率设置为 1×10^{-5} , 并在代码运行过程中采用余弦退火学习率衰减策略, epoch 设置为 100, batch_size 为 128。本文的实验基于 Pytorch 深度学习框架实现, 硬件平台为: Inter(R) Core(TM) i9-9900k, GeForce RTX 2080Ti, 10 GB 内存。

表 1 神经元在不同数据集上的参数初始化

Table 1 Parameter initialization of neurons on different datasets

超参数	CIFAR10		CIFAR100	
	编码阈值	校准阈值	编码阈值	校准阈值
α	2.0	1.0	4.5	2.0
β	-1.0	0.8	-1.0	-0.5
k	0.8	1.0	0.9	1.0

4.2 与其他编码机制的对比

本文通过与已有的采用不同编码机制的研究工作在 SNN 分类精度、推理延迟、脉冲数等方面进行对比来评估所提方法, 结果如表 2 和表 3 所列。表 2 和表 3 中的研究工作都是基于 ANN-SNN 转化构建 SNN, 且网络结构分别为 VGG16 和 ResNet20, 基于本文方法所转化的 VGG16 结构的 SNN 在 CIFAR10 数据集和 CIFA-R100 数据集上的分类精度分别为 95.80% 和 77.75%, 转化 ResNet20 结构的 SNN 在两类数据集上的精度分别为 96.62% 和 78.75%, 均达到了无损转化, 且均优于其他研究工作。本文转换所得到的 SNN 分类精度均高于源 ANN, 原因是 SC-TTFS 神经元的阈值机制使其可以过滤掉一些不能触发脉冲或偏离的极大输入, 而这些输入可能是一些噪声信号, 这使得转换后的 SNN 具有更好的抗噪声性能, 从而获得更高的精度。表 2 和表 3 中的脉冲数表示在数据集中完成一个图像的分类任务时 SNN 平均所需发放的脉冲个数, 脉冲数越大表示 SNN 在推理时网络所执行的操作越多。如表 2 和表 3 所列, 本文方法的 SNN 在脉冲数和推理延迟性能方面均优于其他大部分研究工作, 虽然相比具有最少脉冲数的基于 TTFS 编码机制的研究工作, 基于本文方法所构建的 SNN 脉冲数在 CIFAR10 和 CIFAR100 数据集上要多约 1.5 倍, 但在推理延迟性能上分别提高了约 84% 和 81%。

表 2 CIFAR10 上不同编码机制 ANN-SNN 转化方法对比

Table 2 Comparison of ANN-SNN conversion methods with different encoding mechanisms on CIFAR10

网络模型	编码机制	分类精度/%		转化损失	推理延迟	脉冲数
		ANN	SNN			
VGG16	Rate(2017) ^[9]	91.41	91.06	0.35	1500	9.300×10^6
VGG16	Phase(2018) ^[13]	91.41	91.21	0.20	1500	35.200×10^6
VGG16	Burst(2019) ^[16]	91.41	91.41	0.00	1125	6.920×10^6
VGG16	Rate(2020) ^[10]	93.63	93.39	0.24	512	2.612×10^6
VGG16	TTFS(2020) ^[21]	—	91.43	—	680	0.069×10^6
VGG16	Rate(2021) ^[12]	95.74	95.65	0.09	500	5.500×10^6
VGG16	SC-TTFS	95.74	95.80	-0.06	108	0.175×10^6
ResNet20	Phase(2018) ^[13]	91.40	91.40	0.00	502	—
ResNet20	Rate(2019) ^[29]	89.10	87.46	1.64	大于 512	—
ResNet20	Rate(2019) ^[30]	93.15	92.94	0.21	大于 512	—
ResNet20	Rate(2021) ^[12]	95.46	85.42	0.04	128	—
ResNet20	Phase(2021) ^[14]	95.02	95.16	-0.14	206	—
ResNet20	Phase(2021) ^[24]	91.58	91.45	0.13	200	0.261×10^6
ResNet20	SC-TTFS	96.54	96.62	-0.08	100	0.440×10^6

表 3 CIFAR100 上不同编码机制 ANN-SNN 转化方法对比

Table 3 Comparison of ANN-SNN conversion methods with different encoding mechanisms on CIFAR100

网络模型	编码机制	分类精度/%		转化损失	推理延迟	脉冲数
		ANN	SNN			
VGG16	Phase(2018) ^[13]	68.77	68.37	0.40	3000	86.504×10^6
VGG16	Burst(2019) ^[16]	68.77	68.69	0.08	3000	24.238×10^6
VGG16	Rate(2020) ^[10]	71.22	69.40	1.82	512	2.048×10^6
VGG16	TTFS(2020) ^[21]	—	68.79	—	680	0.084×10^6
VGG16	Rate(2021) ^[12]	77.74	77.72	0.02	1200	13.300×10^6
VGG16	SC-TTFS	77.74	77.75	-0.01	126	0.210×10^6
ResNet20	Rate(2019) ^[29]	69.72	64.09	5.63	512	—
ResNet20	Rate(2020) ^[10]	68.72	67.82	0.90	512	—
ResNet20	Phase(2020) ^[19]	68.72	68.18	0.54	512	—
ResNet20	Rate(2021) ^[12]	77.16	77.63	-0.47	256	—
ResNet20	Phase(2021) ^[12]	77.97	78.12	-0.15	265	—
ResNet20	SC-TTFS	78.68	78.75	-0.07	100	0.498

4.3 神经形态硬件上能耗估计对比

为了更好地比较各方法 SNN 的综合性能,本文对各方法的 SNN 在两个神经形态架构 TrueNorth^[31] 和 SpiNNaker^[32] 上的能源效率进行了估计。TrueNorth 和 SpiNNaker 是基于人脑神经形态混合信号的由大量神经元和可编程神经突触组成的两种计算机芯片。在 TrueNorth 和 SpiNNaker 上,能量的消耗包括计算与路由操作和静态能量消耗,分别对应 SNN 的脉冲数和推理延迟,本文根据文献[33]中对 TrueNorth 和 SpiNNaker 上能量消耗的占比估计计算各方法的 SNN 能耗估计,即:

$$E = N \times E_i + L \times E_l \quad (25)$$

其中, E 表示 SNN 的能耗估计, N 表示 SNN 的脉冲数, L 表示 SNN 的推理延迟。在 TrueNorth 和 SpiNNaker 中, (E_i, E_l) 分别为 $(0.4, 0.6)$ 和 $(0.64, 0.36)$,且本文对 SNN 的能耗估计结果进行了归一化处理。如图 3 和图 4 所示,相比其他研究工作,本文方法的 SNN 能量消耗最低,其中相比具有最少脉冲数的基于 TTFS 编码机制的方法,SNN 的能源效率提升了约 80%。综合以上实验结果,基于本文方法所构建的 SNN 在分类精度、推理延迟和能源效率性能指标上均超越了目前大部分同类研究工作,从而证明了本文方法的优势。




图 3 CIFAR10 上不同编码机制的 SNN 能耗估计对比

Fig. 3 Comparison of SNN energy consumption estimates for different coding mechanisms on CIFAR10




图 4 CIFAR100 上不同编码机制的 SNN 能耗估计对比

Fig. 4 Comparison of SNN energy consumption estimates for different coding mechanisms on CIFAR100

结束语 TTFS 被证明是 ANN-SNN 转化中具有更高能源效应的编码方法。然而现有的 TTFS 编码采用的单脉冲形式,其信息表征能力较弱。为了缩小单脉冲所产生的转化量化误差,需要设置较大的编码时间窗口,导致 SNN 存在较大的推理延迟。针对这个问题,本文分析了基于单脉冲 TTFS 编码的 ANN-SNN 转化近似误差,提出了带有校准脉冲的 SC-TTFS 编码机制和相应的神经元模型。与 TTFS 只发放

一个脉冲不同,SC-TTFS 在时间窗口 T 内最多可发放两个脉冲,即编码脉冲和校准脉冲。其中,校准脉冲用来对编码脉冲下的 ANN-SNN 转化量化误差进行补偿,同时扩展编码窗口 T 的脉冲解码值范围,从而在降低转化量化误差的同时,缩小转化的截断误差。此外,本文针对 SNN 解码值与 ANN 激活值间的误差,对 SC-TTFS 阈值函数及 BN 层的超参数进行了微调学习。本文基于深度神经网络架构 VGG16 和 ResNet20 构建了使用 SC-TTFS 神经元的深度 SNN,在大型数据集 CIFAR10 和 CIFAR100 上的实验结果表明,相比其他编码机制的研究工作,本文方法的 SNN 具有最高的分类精度,且 VGG16 结构的 SNN 相比具有最少脉冲数的基于单脉冲 TTFS 编码的研究工作,在推理延迟和能源效率性能上均提升了约 80%。未来将进一步优化 SC-TTFS 神经元的阈值函数以减少 SNN 执行网络推理时发放的脉冲数量。

参考文献

- [1] ZHANG T L, XU B. Research Status and Prospect of Pulse Neural Network [J]. Journal of Computer Science, 2021, 44(9): 1767-1785.
- [2] BOHTE S M, KOK J N, LA POUTRÉ J A. Spikeprop: back-propagation for networks of spiking neurons [C] // ESANN. Bruges, 2000: 419-424.
- [3] NEFTCI E O, MOSTAFA H, ZENKE F. Surrogate Gradient Learning in Spiking Neural Networks: Bringing the Power of Gradient-based optimization to spiking neural networks [J]. IEEE Signal Processing Magazine, 2019, 36(6): 51-63.
- [4] LEE J H, DELBRUCK T, PFEIFFER M. Training deep spiking neural networks using backpropagation [J]. Frontiers in Neuroscience, 2016, 10: 508.
- [5] MIRSADEGHI M, SHALCHIAN M, KHERADPISHEH S R, et al. Spike time displacement based error backpropagation in convolutional spiking neural networks [J]. arXiv: 2108. 13621, 2021.
- [6] TAVANA EI A, MAIDA A S. Multi-layer unsupervised learning in a spiking convolutional neural network [C] // 2017 International Joint Conference on Neural Networks (IJCNN). IEEE, 2017: 2023-2030.
- [7] TAVANA EI A, MAIDA A. BP-STDP: Approximating back-propagation using spike timing dependent plasticity [J]. Neurocomputing, 2019, 330: 39-47.
- [8] 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.
- [9] RUECKAUER B, LUNGU I A, HU Y, et al. Conversion of continuous-valued deep networks to efficient event-driven networks for image classification [J]. Frontiers in Neuroscience, 2017, 11: 682.
- [10] HAN B, SRINIVASAN G, ROY K. Rmp-snn: Residual membrane potential neuron for enabling deeper high-accuracy and low-latency spiking neural network [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 13558-13567.
- [11] MUELLER E, HANSJAKOB J, AUGÉ D, et al. Minimizing Inference Time: Optimization Methods for Converted Deep Spiking

- Neural Networks[C]//2021 International Joint Conference on Neural Networks(IJCNN). IEEE,2021.
- [12] LI Y, DENG S, DONG X, et al. A free lunch from ANN: Towards efficient, accurate spiking neural networks calibration [C]//International Conference on Machine Learning. PMLR, 2021:6316-6325.
- [13] KIM J, KIM H, HUH S, et al. Deep neural networks with weighted spikes[J]. *Neurocomputing*, 2018, 311:373-386.
- [14] LI Y, ZENG Y, ZHAO D. Bsn: Towards faster and better conversion of artificial neural networks to spiking neural networks with bistable neurons[J]. arXiv:2105.12917, 2021.
- [15] RUECKAUER B, LIU S C. Temporal pattern coding in deep spiking neural networks[C]//2021 International Joint Conference on Neural Networks(IJCNN). IEEE, 2021.
- [16] PARK S, KIM S, CHO H, et al. Fast and efficient information transmission with burst spikes in deep spiking neural networks [C]//2019 56th ACM/IEEE Design Automation Conference (DAC). IEEE, 2019.
- [17] GUO W, FOU DA M E, ELTAWIL A M, et al. Neural coding in spiking neural networks: A comparative study for robust neuro-morphic systems [J]. *Frontiers in Neuroscience*, 2021, 15: 638474.
- [18] RUECKAUER B, LIU S C. Conversion of analog to spiking neural networks using sparse temporal coding[C]//2018 IEEE International Symposium on Circuits and Systems(ISCAS). IEEE, 2018.
- [19] HAN B, ROY K. Deep spiking neural network: Energy efficiency through time based coding [C]//European Conference on Computer Vision. Cham: Springer, 2020:388-404.
- [20] ZHANG L, ZHOU S, ZHI T, et al. Tdsnn: From deep neural networks to deep spike neural networks with temporal-coding [C]//Proceedings of the AAAI Conference on Artificial Intelligence. 2019:1319-1326.
- [21] PARK S, KIM S, NA B, et al. T2FSNN: Deep spiking neural networks with time-to-first-spike coding[C]//2020 57th ACM/IEEE Design Automation Conference(DAC). IEEE, 2020.
- [22] TOVEE M J, ROLLS E T. Information encoding in short firing rate epochs by single neurons in the primate temporal visual cortex[J]. *Visual cognition*, 1995, 2(1):35-58.
- [23] KUMAR S, KAPOSVARI P, VOGELS R. Encoding of predictable and unpredictable stimuli by inferior temporal cortical neurons[J]. *Journal of Cognitive Neuroscience*, 2017, 29(8):1445-1454.
- [24] STÖCKL C, MAASS W. Optimized spiking neurons can classify images with high accuracy through temporal coding with two spikes[J]. *Nature Machine Intelligence*, 2021, 3(3):230-238.
- [25] DAVIDSON S, FURBER S B. Comparison of artificial and spiking neural networks on digital hardware[J]. *Frontiers in Neuroscience*, 2021, 15:651141.
- [26] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. arXiv:1409.1556, 2014.
- [27] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016:770-778.
- [28] KRIZHEVSKY A, HINTON G. Learning multiple layers of features from tiny images[J/OL]. <https://citeseerx.ist.psu.edu/viewdoc/download;jsessionid=0D60E5DD558A91470E0EA1725FF36E0A?doi=10.1.1.222.9220&rep=rep1&type=pdf>.
- [29] SENGUPTA A, YE Y, WANG R, et al. Going deeper in spiking neural networks: VGG and residual architectures[J]. *Frontiers in Neuroscience*, 2019, 13:95.
- [30] RATHI N, ROY K. DIET-SNN: A low-latency spiking neural network with direct input encoding and leakage and threshold optimization[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 34(6):3174-3182.
- [31] MEROLLA P A, ARTHUR J V, ALVAREZ-ICAZA R, et al. A million spiking-neuron integrated circuit with a scalable communication network and interface[J]. *Science*, 2014, 345(6197):668-673.
- [32] FURBER S B, GALLUPPI F, TEMPLE S, et al. The spinnaker project[J]. *Proceedings of the IEEE*, 2014, 102(5):652-665.
- [33] MORADI S, MANOHAR R. The impact of on-chip communication on memory technologies for neuromorphic systems[J]. *Journal of Physics D: Applied Physics*, 2018, 52(1):014003.



FENG Ren, born in 1995, postgraduate. His main research interests include neuromorphic computing, computer vision and machine learning.



CHEN Yunhua, born in 1984, Ph.D, professor, postgraduate supervisor, is a member of CCF(No. 30983M). Her main research interests include neuromorphic computing, computer vision and machine learning.

(责任编辑:何杨)