



基于注意力的联想忆阻脉冲神经网络及其无监督图像分类应用

邓泽坤¹, 王春华^{1*}, 蔺海荣², 邓全利¹, Yichuang SUN³

1. 湖南大学信息科学与工程学院, 长沙 410082, 中国

2. 中南大学电子信息学院, 长沙 410083, 中国

3. School of Engineering and Computer Science, University of Hertfordshire, Hatfield AL10 9AB, UK

* 通信作者. E-mail: wch1227164@hnu.edu.cn

收稿日期: 2023-12-15; 修回日期: 2024-03-22; 接受日期: 2024-07-30; 网络出版日期: 2024-11-08

国家自然科学基金 (批准号: 62271197, 62201204)、广东省基础与应用基础研究基金 (批准号: 2024A1515011910) 和中国博士后科学基金 (批准号: 2022M71104) 资助项目

摘要 无监督学习不需要对训练数据进行人工标注, 在硬件系统的图像分类应用中具有重要价值. 现有忆阻脉冲神经网络 (memristive spiking neural network, MSNN) 的无监督学习主要集中于前后神经元之间的突触调节过程, 这导致学习仅限于局部神经活动而忽略了神经反应之间的内部联系. 联想记忆是大脑实现记忆的重要方式, 其通过无监督方式将不同刺激关联起来以建立互联的网络记忆. 同时, 人类视觉系统利用注意机制从海量信息中选择重要信息, 以有效减少输入神经元的数量和神经网络的规模. 本文提出了一种基于注意力的联想忆阻脉冲神经网络 (attention-based associative memristive spiking neural network, AAMSNN) 的全电路设计, 并将其应用于无监督图像分类应用. 其中, 注意力编码模块和注意力选择模块启发于人脑的注意力机制, 用于搜索并选择重要特征信息, 减少 AAMSNN 的输入神经元数量. 联想忆阻脉冲神经网络由巴甫洛夫联想忆阻交叉阵列构成, 通过调节联想记忆权重实现无监督图像分类. 与其他 MSNN 相比, AAMSNN 具有更小的 MSNN 规模和更少的忆阻器数量, 并实现了更优的无监督图像分类准确率.

关键词 忆阻脉冲神经网络, 注意力, 联想记忆, 无监督学习, 图像分类

1 引言

脉冲神经网络 (spiking neural network, SNN) 以生物启发的脉冲发放现象来近似生物神经网络的信号处理模式, 使用脉冲信号来传递信息, 具有低能耗和高计算效率的优势, 被广泛研究应用于图像识别、视觉传感和类脑计算等相关场景中^[1]. 由软件程序实现的 SNN 通常运行在冯·诺伊曼 (von

引用格式: 邓泽坤, 王春华, 蔺海荣, 等. 基于注意力的联想忆阻脉冲神经网络及其无监督图像分类应用. 中国科学: 信息科学, 2024, 54: 2554–2571, doi: 10.1360/SSI-2023-0393

Deng Z K, Wang C H, Lin H R, et al. An attention-based associative memristive spiking neural network and its application in unsupervised image classification (in Chinese). Sci Sin Inform, 2024, 54: 2554–2571, doi: 10.1360/SSI-2023-0393

Neumann) 体系结构的传统计算系统上^[2]. 由于在冯·诺伊曼体系结构中存储单元和计算单元是物理分离的, 需要进行频繁的数据传输, 而存储单元和计算单元之间存在显著的性能差距, 因此导致了高延迟和高能耗问题. 与软件实现相比, SNN 的硬件实现具有更快的处理速度和更低的功耗. 然而, 大多数 SNN 的硬件实现是由缺乏非易失特性的 CMOS 器件设计的, 这导致电路设计非常复杂. 近年来, 许多具备非易失特性的存储器件被提出^[3], 其中忆阻器的类生物突触动态特性为 SNN 的电路设计提供了有效的解决方案. 忆阻器被定义为第 4 种基本电路元件^[4], 用于表示电荷量与磁通量之间的关系. 2008 年, 惠普实验室首次研发了一种具有非易失性存储功能的纳米双端忆阻器器件^[5]. 此后, 越来越多的忆阻器模型和忆阻器器件被应用于构建忆阻计算电路^[6~10]、神经元电路^[11~13] 和神经网络电路^[14~17].

SNN 的无监督学习是一种生物启发式的学习方式, 最近许多忆阻脉冲神经网络 (memristive spiking neural network, MSNN) 被提出用于无监督学习, 这为实现类脑硬件平台奠定了基础. 2020 年, Zhao 等^[18] 通过在脉冲时间依赖可塑性 (spiking timing dependent plasticity, STDP) 学习规则中添加侧抑制和稳态机制, 提高了 MSNN 的可扩展性和学习效率. 2021 年, Adnan 等^[19] 提出了一种带有双忆阻突触的 MSNN, 并通过 STDP 学习规则和稳态机制实现了无监督学习. 2022 年, Ku 等^[20] 设计了一种具有赢者通吃 (winner-take-all, WTA) 模块的两层全连接 MSNN, 并提出了一种硬件友好的突触适应机制来实现 STDP 学习规则. 2023 年, Wang 等^[21] 设计了一种具有 STDP 学习规则的 MSNN, 用于无监督数字识别应用. 之后, Florini 等^[22] 设计了一种基于 STDP 和 Bienenstock-Cooper-Munro (BCM) 学习规则的 MSNN, 实现了无监督学习. 然而, 这些 MSNN 主要关注前后神经元之间的 STDP 或 BCM 突触学习过程, 而忽略了 MSNN 中神经反应之间的内部联系. 由于 STDP 或 BCM 学习规则仅考虑局部神经活动, 这使得 MSNN 的学习性能受到了限制. 此外, 现有 MSNN 通常需要与输入图像像素总数相同的输入神经元, 这导致 MSNN 需要较大规模的神经网络来处理数据. 人类视觉系统依赖视网膜中约 1 亿个杆状细胞和锥状细胞来创建约 1 亿像素的分辨率, 但只有大约 150 万个神经节细胞将视觉信息从视网膜传输到大脑. 为了有效减少输入神经节细胞的数量和神经网络的规模, 人类视觉系统利用注意机制从海量信息中选择并优先处理重要信息^[23,24]. 最近, 一些工作提出了基于忆阻器的多头注意 Transformer 网络电路^[25,26], 但这些电路遵循监督学习方法. 与监督学习相比, 无监督学习不需要对训练数据进行人工标注, 减少了对标签和监督信号的依赖, 降低了人工干预的成本.

联想记忆是大脑通过联想刺激实现记忆的重要方式. 巴甫洛夫 (Pavlov) 条件反射是一种典型的联想记忆, 其通过将条件刺激与非条件刺激关联起来以建立相互联系的网络记忆. 巴甫洛夫条件反射实验表明, 如果条件刺激与非条件刺激同时反复出现, 则两者的神经反应联系不断加强. 相反, 如果条件刺激与非条件刺激没有同时发生, 则两者的神经反应联系就会减弱. 近年来, 巴甫洛夫联想记忆的忆阻电路方案被相关领域的学者广泛研究^[27,28], 通过设计忆阻电路复现了巴甫洛夫条件反射实验. 然而, 将巴甫洛夫联想记忆原理应用于无监督学习的 MSNN 仍有待进一步探讨. 本文的主要贡献如下:

- (1) 将注意力机制与巴甫洛夫联想记忆相结合, 提出了一种基于注意力的联想忆阻脉冲神经网络 (attention-based associative memristive spiking neural network, AAMSNN) 的全电路设计.
- (2) 基于注意力机制设计了注意力编码电路和注意力选择电路, 用于从注意力信号中搜索和选择相关特征信息, 减少了 AAMSNN 的输入神经元数量. 同时, 基于巴甫洛夫联想记忆原理, 设计了一种联想忆阻脉冲神经网络调节不同刺激之间的神经反应联系, 实现了无监督图像分类.
- (3) 相比于其他用于无监督图像分类的 MSNN, 所设计的 AAMSNN 以更小的 MSNN 规模和更少的忆阻器数量实现了优于其他 MSNN 的分类准确率.




图 1 (网络版彩图) 基于注意力的联想忆阻脉冲神经网络框图

Figure 1 (Color online) Framework of the AAMSNN

2 电路设计与分析

2.1 电路框图与结构

AAMSNN 的框图如图 1 所示, 其中包含 4 个模块: 特征提取模块、注意力编码模块、注意力选择模块和联想忆阻脉冲神经网络模块, 联想忆阻脉冲神经网络模块由 L 个大小为 $k \times k$ 的巴甫洛夫联想忆阻交叉阵列构成. 在框图中, 大小为 $N \times N$ 的图像通过大小为 $H \times H$ 的第 1 个卷积核提取 Z 个特征像素, 对 Z 个特征像素进行注意力编码生成注意力信号 S_{A1} . 将注意力信号 S_{A1} 传输到 n 个注意力通道用于注意力选择并受控输出 n 个脉冲信号, 将 n 个脉冲信号分成 L 组分别传输到 L 个巴甫洛夫联想忆阻交叉阵列的 k 列横杆中. 同时, 将图像顺时针旋转 90° , 通过大小为 $H \times H$ 的第 2 卷积核提取 Z 个特征像素, 对 Z 个特征像素进行注意力编码得到注意力信号 S_{A2} . 注意力信号 S_{A2} 被传输到 n 个注意力通道用于注意力选择并受控输出 n 个脉冲信号. 将 n 个脉冲信号分成 L 组分别传输到 L 个巴甫洛夫联想忆阻交叉阵列的 k 行横杆中. 最后, 每个巴甫洛夫联想忆阻交叉阵列对输入的 $2k$ 个脉冲信号进行无监督学习.

AAMSNN 的电路结构如图 2 所示, 图像数据经过特征提取、注意力编码和注意力选择后被稀疏编码为脉冲信号, 脉冲信号传输到联想忆阻脉冲神经网络中进行无监督学习. 其中, CMOS 逻辑门的正电源为 5 V, 负电源接地, 导通电压为 2.5 V.

近年来, 许多电压控制型忆阻模型已被提出用于电路仿真, 如 TiO_2 忆阻模型^[29]和 VTEAM 模型^[30]. 但是 TiO_2 忆阻模型缺乏阈值电压; 而对 VTEAM 模型施加脉冲电压时, 其忆阻状态变化量为常量而难以真实描述忆阻变化特性. 本文采用一种压控阈值忆阻器模型^[31]用于 PSPICE 仿真, 这种忆阻器模型是基于 $\text{Ag}/\text{AgInSbTe}/\text{Ta}$ (AIST) 忆阻器的实验数据设计的. 与其他忆阻模型相比, AIST 忆阻器模型在施加脉冲信号时能够实现忆阻值稳定调节. AIST 忆阻器模型的数学表达式如下:

$$M(t) = R_{\text{ON}} \frac{w(t)}{D} + R_{\text{OFF}} \left(1 - \frac{w(t)}{D} \right), \quad (1)$$

$$\frac{dw(t)}{dt} = \begin{cases} \mu_v \frac{R_{\text{ON}}}{D} \frac{i_{\text{off}}}{i(t) - i_0} F(w(t)), & v(t) > V_{T+} > 0, \\ 0, & V_{T+} \geq v(t) \geq V_{T-}, \\ \mu_v \frac{R_{\text{ON}}}{D} \frac{i(t)}{i_{\text{on}}} F(w(t)), & 0 > V_{T-} > v(t), \end{cases} \quad (2)$$

$$F(w(t)) = 1 - \left(\frac{2w(t)}{D} - 1 \right)^{2p}, \quad (3)$$

其中, $M(t)$ 为忆阻值, R_{ON} 为低阻态, R_{OFF} 为高阻态, $w(t)$ 为掺杂区宽度, μ_v 为平均离子迁移率, D 为忆阻薄膜总厚度, i_{off} , i_{on} 和 i_0 为常量, V_{T+} 和 V_{T-} 分别为正阈值电压和负阈值电压, $F(w(t))$ 为窗




图 2 (网络版彩图) 基于注意力的联想忆阻脉冲神经网络电路结构

Figure 2 (Color online) Circuit schematic of the AAMSN. (a) Feature extraction module; (b) attention encoding module; (c) attention selection module, which contains two main components: attention matching circuit (AMC) and control circuit (CC); (d) associative memristive spiking neural network module consisting of L Pavlovian associative memristor cross arrays

表 1 忆阻器 PSPICE 仿真参数

Table 1 PSPICE simulation parameters of memristors

	μ_V ($m^2 \cdot s^{-1} \cdot \Omega^{-1}$)	D (nm)	R_{ON} (k Ω)	R_{OFF} (k Ω)	V_{T+} (V)	V_{T-} (V)	i_{off} (A)	i_{on} (A)	i_0 (A)	p
Value	$7.6e-8$	10	1	10	0.1	-0.1	$1.5e-9$	1	$1e-7$	10

函数. 忆阻器的 PSPICE 仿真参数如表 1 所示. 忆阻值和施加电压之间的关系如图 3 所示, 当忆阻器两端的电压未超过阈值时, 忆阻值保持不变. 当忆阻器两端的电压超过正阈值时, 忆阻值先迅速减小, 然后缓慢减小. 当忆阻器两端的电压超过负阈值时, 忆阻值先迅速增大, 然后缓慢增大.

2.2 特征提取模块

图 2(a) 所示特征提取模块共包含两个特征提取电路, 分别用于从原始输入图像和旋转 90° 的图像中提取特征像素. 每个特征提取电路有 m 个输入和一个输出, 其中 $m = H^2$. $v_{1,1}(t), v_{1,2}(t), \dots, v_{1,m}(t)$ 是原始图像的像素转换信号, $v_{2,1}(t), v_{2,2}(t), \dots, v_{2,m}(t)$ 是旋转 90° 图像的像素转换信号. 像素转换信号 $v_{q,i}(t)$ 的电压幅值 $V_{q,i}$ 由图像灰度值 $p_{q,i}$ 转换得到, 可以计算为

$$V_{q,i} = \lambda p_{q,i}, \quad (4)$$

其中 $q = 1, 2, i = 1, 2, \dots, m$. λ 是转换系数, $p_{q,i} \in [0, 255]$.

根据基尔霍夫 (Kirchhoff) 电流定律, $v_{Aq}(t)$ 可以计算为

$$v_{Aq}(t) = - \sum_{i=1}^m \frac{R_{Aq}}{R_{q,i}} v_{q,i}(t). \quad (5)$$




图 3 (网络版彩图) 忆阻器在不同电压下的 PSpice 仿真结果

Figure 3 (Color online) SPICE simulation of memristance adjustment under different applied voltages

卷积结果 $v_{Fq}(t)$ 可以计算为

$$v_{Fq}(t) = - \left(\sum_{i=1}^m \frac{R_{Fq}}{M_{cq,i}} v_{q,i}(t) + \frac{R_{Fq}}{R_{Bq}} v_{Aq}(t) \right) = - \sum_{i=1}^m R_{Fq} \left(\frac{1}{M_{cq,i}} - \frac{R_{Aq}}{R_{q,i} R_{Bq}} \right) v_{q,i}(t) = - \sum_{i=1}^m W_{q,i} v_{q,i}(t), \quad (6)$$

其中, $M_{cq,i}$ 是第 q 个特征提取电路中第 i 个忆阻器的忆阻值. $W_{q,i}$ 是第 q 个卷积核的第 i 个权重. 设置 $R_{Aq} = R_{Bq}$, 则 $W_{q,i} = R_{Fq} \left(\frac{1}{M_{cq,i}} - \frac{1}{R_{q,i}} \right)$.

通过输入高于忆阻器阈值的电压来调整忆阻值, 从而将卷积核的权重写入忆阻器阵列^[32]. 然后, 将 m 个像素转换信号 (低于忆阻器阈值电压) 输入到忆阻器阵列进行特征提取. 大小为 $N \times N$ 的图像由大小为 $H \times H$ 的卷积核卷积计算 Z 次以获得 Z 个特征像素. 卷积步幅设置为 1, 因此 $Z = (N - H + 1)^2$. 设每次卷积的时间设为 T_c , 因此每张图像的总卷积时间为 ZT_c .

2.3 注意力编码模块

神经科学研究表明, 神经节细胞通过增加或减少动作电位的频率来传播信息^[33]. 因此, 我们使用不同频率的正弦振荡信号来编码注意力信号. 在图 2(b) 所示的注意力编码模块中, 两个注意力编码电路利用控制信号 $v_a(t)$ 和 $v_b(t)$ 分别将正弦振荡信号 $S(t)$ 编码为注意力信号 $S_{A1}(t)$ 和 $S_{A2}(t)$. 信号 $S(t)$ 是频率递增的正弦振荡信号, $S(t)$ 中每个频率的振荡周期与卷积时间 T_c 相同. $S(t)$ 的频率 f_l 可以表示为

$$f_l = f_A + lF, \quad (7)$$

其中 $l = 1, 2, \dots, Z$, f_A 是基本频率, F 是频率增益. 因此 $S(t)$ 是一个多频率振荡信号, 总时间长度为 ZT_c , 这与每个图像的总卷积时间一致. 在仿真中, $S(t)$ 由特定的正弦信号源生成. 注意力编码电路中的电阻都设置为 10 kΩ. TG_{A1} 和 TG_{A2} 为传输门 (transmission gate, TG), 其电路结构如图 2 右下角所示. 当 C 端口输入电压为 5 V 时, TG 导通; 当 C 端口输入电压小于等于 0 V 时, TG 截止. $v_{a1}(t)$ 和 $v_{b1}(t)$ 分别是 $v_{F1}(t)$ 和 $v_{F2}(t)$ 的反相信号. 如图 4(a) 所示, 当 $0 \sim 0.1$ ms 时, $v_{a1}(t) < 0$ V, 因此编码控制信号 $v_a(t) = -5$ V, TG_{A1} 截止, $S_{A1}(t) = 0$ V. 当 $0.1 \sim 0.2$ ms 时, $v_{a1}(t) \geq 0$ V, 因此 $v_a(t) = 5$ V, TG_{A1} 导通, 此时 $S(t)$ 的振荡频率被编码为 $S_{A1}(t)$ 的频率特征. 同理, 如果 $v_{b1}(t) \geq 0$ V, 则编码控制




图 4 (网络版彩图) (a) 注意力编码的电路仿真结果; (b) 注意力匹配电路 $\text{AMC}_{1,1}$ 的注意力匹配过程示例, 其中 $S_{A1}(t)$ 的频率为 100 kHz, $s_1(t)$ 的频率分别为 70, 90, 100, 110 和 130 kHz

Figure 4 (Color online) (a) Circuit simulation of attention encoding; (b) examples of the attention matching results for the attention matching circuit $\text{AMC}_{1,1}$, where the frequency of $S_{A1}(t)$ is 100 kHz, and the frequencies of $s_1(t)$ are 70, 90, 100, 110, and 130 kHz, respectively

信号 $v_b(t) = 5 \text{ V}$, TGA_2 导通, $S(t)$ 的振荡频率被编码为 $S_{A2}(t)$ 的频率特征.

2.4 注意力选择模块

注意力机制的选择性对于生物大脑中信息的有效处理至关重要. 注意力机制对重要信息进行搜索和选择, 并在选择重要信息的同时忽略不相关的信息, 从而更有效地将学习资源分配给重要信息, 提高计算效率^[34]. 图 2(c) 所示的注意力选择模块用于从注意力信号 $S_{A1}(t)$ 和 $S_{A2}(t)$ 中搜索和选择与匹配信号频率相关的频率特征. 注意力信号 $S_{A1}(t)$ 和 $S_{A2}(t)$ 分别输入到相应的 n 个注意力通道中, 每个注意力通道包含一个注意力匹配电路 (AMC) 和一个控制电路 (CC). AMC 由乘法器、积分运算放大电路和反相运算放大电路组成. 在图 2 所示的 $\text{AMC}_{1,1}$ 中, 乘法器的两个输入端口分别接收注意力信号 $S_{A1}(t)$ 和匹配信号 $s_1(t)$. $\text{AMC}_{1,1}$ 的输出电压 $x_{1,1}(t)$ 由 $v_{c1,1}(t)$ 反相放大. 信号 $v_{c1,1}(t)$ 和 $x_{1,1}(t)$ 可以表示为

$$v_{c1,1}(t) = -\frac{1}{R_{c1}C} \int s_1(t)S_{A1}(t)dt, \quad (8)$$

$$x_{1,1}(t) = -\frac{R_{c4}}{R_{c3}}v_{c1,1}(t). \quad (9)$$

在相同初始相位的条件下, 当注意力信号与匹配信号具有相同频率时, 输出信号 $x_{1,1}(t)$ 的电压值最大, 并且 $x_{1,1}(t)$ 的电压值随注意力信号与匹配信号频率差的增加而减小. 为了确保注意力信号和匹配信号在每次注意力选择期间具有相同的初始相位, 每个振荡周期内振荡信号的初始相位都设置为 0. 图 4(b) 所示为注意力匹配过程的示例, 其中电路参数设置为 $R_{c1} = 50 \text{ k}\Omega$, $R_{c2} = 10 \text{ k}\Omega$, $R_{c3} = 10 \text{ k}\Omega$, $R_{c4} = 60 \text{ k}\Omega$, $C = 10 \text{ nF}$ 且 $T_c = 0.1 \text{ ms}$. 匹配信号幅值设置为 5 V. 注意力匹配结果显示, 当 $S_{A1}(t)$ 和 $s_1(t)$ 具有相同的频率 (100 kHz) 时, 输出电压值最高 (1.907 V). 同时, $S_{A1}(t)$ 和 $s_1(t)$ 的频率值之间的差值越大, 输出最高电压值越小, 如 $f_{SA1} = 100 \text{ kHz}$, $f_{s1} = 90 \text{ kHz}$ 时, 输出最高电压值为 0.433 V, 而 $f_{SA1} = 100 \text{ kHz}$, $f_{s1} = 70 \text{ kHz}$ 时, 输出最高电压值为 0.182 V. 因此, $\text{AMC}_{1,1}$ 可以从注意力信号 $S_{A1}(t)$ 中搜索并选择与匹配信号 $s_1(t)$ 相关的频率特征, $S_{A1}(t)$ 中的频率越接近匹配信号的频率, $x_{1,1}(t)$ 的电压值就越大.

人类视觉系统的注意力机制倾向于在更大的范围内搜索信息, 并将注意力集中在与目标相关的信息上^[35]. 基于注意力选择原理, 将匹配信号的频率间隔设置为 sF , 以便在更大的范围内搜索和匹配注意力信号的相关频率特征. 匹配信号 $s_j(t)$ 的频率 f_{mj} 设置为

$$f_{mj} = f_A + jsF, \quad (10)$$

其中 s 是频率间隔系数, $j = 1, 2, \dots, n$. 此外, 注意力通道的数量 n 可以计算为 $n = \frac{Z}{s}$.

在 $CC_{1,1}$ 电路中, 信号 $x_{1,1}(t)$ 输入到运放比较电路中, 与阈值电压 v_{th} 进行比较, 并输出比较结果 $X_{1,1}(t)$. 当 $x_{1,1}(t) \geq v_{th}$ 时, $X_{1,1}(t) = 5 \text{ V}$; 当 $x_{1,1}(t) < v_{th}$ 时, $X_{1,1}(t) = 0 \text{ V}$. 在仿真中, 阈值电压 v_{th} 设置为 2.5 V , 因此 AMC 的输出电压超过 2.5 V 时会激活相应的 CC. 在图 5(a) 所示的 $CC_{1,1}$ 电路仿真中, $x_{1,1}(t)$ 由 $S_{A1}(t)$ 和 $s_1(t)$ 匹配生成, 其中 $f_{SA1} = 100 \text{ kHz}$, f_{s1} 从 75 kHz 到 125 kHz 递增, 频率间隔设置为 1 kHz , 每个频率的振荡周期为 0.1 ms . 当 $x_{1,1}(t) \geq 2.5 \text{ V}$ 时, $X_{1,1}(t) = 5 \text{ V}$. 若 $X_{1,1}(t) = 5 \text{ V}$, 则 $x_{a1,1}(t) = 5 \text{ V}$ 且 $x_{b1,1}(t) = 0 \text{ V}$. 信号 $x_{a1,1}(t)$ 和 $x_{b1,1}(t)$ 的电压状态一直持续到复位信号 $r(t) \geq 2.5 \text{ V}$. 复位信号 $r(t)$ 是一个脉冲信号, 其脉冲在完成每个图像的学习之后立即产生. 当 $r(t) \geq 2.5 \text{ V}$ 时, $x_{b1,1}(t) = 5 \text{ V}$ 且 $x_{a1,1}(t) = 0 \text{ V}$. 信号 $c(t)$ 是用于控制 $Y_{1,1}(t)$ 输出的脉冲信号, 其脉冲产生于注意力信号完成注意力选择后的学习周期内. 如果 $c(t) = 5 \text{ V}$ 且 $x_{a1,1} = 5 \text{ V}$, 则 NMOS $N_{a1,1}$ 导通且 $Y_{1,1}(t) = V_E$. 如果 $c(t) = 5 \text{ V}$ 且 $x_{b1,1} = 5 \text{ V}$, 则 NMOS $N_{b1,1}$ 导通且 $Y_{1,1}(t) = 0 \text{ V}$. 当 $c(t) = 0 \text{ V}$ 时, $Y_{1,1}(t)$ 的电压接近 0 V . 在仿真中, $c(t)$ 和 $r(t)$ 的脉冲宽度设置为 1 ms , $c(t)$ 和 $r(t)$ 的脉冲幅度设置为 5 V .

本文提出的注意力选择方法从注意力信息中搜索和选择相关的频率特征, 减少了神经网络输入信号的数量, 从而减少了 AAMSN 的输入神经元数量. 同时, 在注意力选择过程中考虑了频率特征之间的相关性, 极大地保证了重要信息被选择且无关信息被忽略, 从而在减少输入信号数量的同时保证了无监督学习的准确性.

2.5 联想忆阻脉冲神经网络模块

在巴甫洛夫条件反射实验中, 食物 (非条件刺激) 可以引起唾液分泌 (非条件反射), 是一种固定的神经反应. 条件刺激是与食物相关联并可以引起唾液分泌 (条件反射) 的其他刺激, 当食物与某一条件刺激同时出现时, 两者的神经反应联系 (联想记忆) 增强; 如果食物与该条件刺激没有同时出现, 则两者的神经反应联系减弱. 根据巴甫洛夫条件反射实验中的联想记忆原理, 设计了一种巴甫洛夫联想忆阻交叉阵列, 如图 2(d) 所示. 联想忆阻脉冲神经网络模块由 L 个巴甫洛夫联想忆阻交叉阵列构成, 每个巴甫洛夫联想忆阻交叉阵列包含一个大小为 $k \times k$ 的忆阻交叉阵列和 k 个输出电路. 注意力选择电路的 n 个输出脉冲信号被分为 L 组并分别输入到 L 个巴甫洛夫联想忆阻交叉阵列中. 每组信号包含 k 个信号且 $L = \frac{n}{k}$. 在图 2 所示的巴甫洛夫联想忆阻交叉阵列 1 中, 脉冲信号 $Y_{1,1}(t), Y_{1,2}(t), \dots, Y_{1,k}(t)$ 输入到忆阻交叉阵列的共 k 列横杆, 同时脉冲信号 $Y_{2,1}(t), Y_{2,2}(t), \dots, Y_{2,k}(t)$ 输入到忆阻交叉阵列的共 k 行横杆. 输入到列横杆和行横杆的共 $2k$ 个脉冲信号视为 $2k$ 个不同的条件刺激. 两个条件刺激分别输入到一个忆阻交叉单元中, 每个忆阻交叉单元包含两个忆阻器. 每列忆阻交叉单元中两个忆阻器之间的端口都连接到一个输出电路, 在学习期间该端口输入非条件刺激信号, 在测试期间该端口输出忆阻交叉单元中两个条件刺激与非条件刺激的联想记忆结果. 忆阻器的电导值代表条件刺激与非条件刺激的联想记忆权重, 如忆阻器 $M_{a1,k}$ 的电导值代表联想记忆权重 $w_{a1,k}$, 即 $w_{a1,k} = \frac{1}{M_{a1,k}}$.

以第 k 列横杆的忆阻交叉单元为例, 在学习期间, 若 $c(t) = 5 \text{ V}$ 且 $v_T(t) = -5 \text{ V}$, 则 TG_{Bk} 导通, PMOS P_{Bk} 导通, NMOS N_{Tk} 截止, 忆阻交叉单元中两个忆阻器之间的端口输入非条件刺激信




图 5 (网络版彩图) (a) 控制电路 $CC_{1,1}$ 的仿真结果; (b) 联想记忆权重的 4 种调节情况

Figure 5 (Color online) (a) Circuit simulation of the control circuit $CC_{1,1}$; (b) four cases of associative weight adjustment

号 $v_{Bk}(t) = V_B$. 当条件刺激信号 $Y_{2,1}(t)$ 出现脉冲时, 即 $Y_{2,1}(t) = V_E$, 则忆阻器 $M_{a1,k}$ 两端的电压 $v_{a1,k}(t) = V_E - V_B$; 若 $Y_{2,1}(t)$ 无脉冲出现, 即 $Y_{2,1}(t) = 0$ V, 则 $v_{a1,k}(t) = -V_B$. 此时联想记忆权重随 $v_{a1,k}(t)$ 的变化而进行调节, 即条件刺激与非条件刺激的神经反应联系出现增强或减弱. 若 $c(t) = 0$ V 且 $v_T(t) = -5$ V, 则 TG_{Bk} 截止, $v_{Bk}(t) = 0$ V, 即端口未输入非条件刺激信号, 同时 $c(t) = 0$ V 时由 CC 产生的刺激信号中无脉冲生成, 此时忆阻器 $M_{a1,k}$ 两端的电压 $v_{a1,k}(t) = 0$ V, 因此忆阻值保持不变.

图 5(b) 所示为一个忆阻交叉单元中两个忆阻器在学习期间联想记忆权重的 4 种调节情况, 其中 $w_{a1,k}$ 为条件刺激 $Y_{2,1}(t)$ 与非条件刺激的联想记忆权重, $w_{b1,k}$ 为条件刺激 $Y_{1,k}(t)$ 与非条件刺激的联想记忆权重. 在仿真中, $V_B = 0.15$ V. Case (1): 当两个条件刺激 $Y_{2,1}(t)$ 和 $Y_{1,k}(t)$ 的脉冲同时出现时, 即 $Y_{2,1}(t) = V_E$ 且 $Y_{1,k}(t) = V_E$, 此时 $v_{a1,k}(t) > V_{T+}$ 且 $v_{b1,k}(t) > V_{T+}$, 权重 $w_{a1,k}$ 和 $w_{b1,k}$ 都增加, 因此两个条件刺激与非条件刺激的神经反应联系都增强. Case (2): 如果只有条件刺激 $Y_{2,1}(t)$ 的脉冲出现, 即 $Y_{2,1}(t) = V_E$ 且 $Y_{1,k}(t) = 0$ V, 此时 $v_{a1,k}(t) > V_{T+}$ 且 $v_{b1,k}(t) < V_{T-}$, 权重 $w_{a1,k}$ 增加且 $w_{b1,k}$ 减小, 因此 $Y_{2,1}(t)$ 与非条件刺激的神经反应联系增强而 $Y_{1,k}(t)$ 与非条件刺激的神经反应联系减弱. Case (3): 如果只有条件刺激 $Y_{1,k}(t)$ 的脉冲出现, 即 $Y_{2,1}(t) = 0$ V 且 $Y_{1,k}(t) = V_E$, 此时 $v_{a1,k}(t) < V_{T-}$ 且 $v_{b1,k}(t) > V_{T+}$, 权重 $w_{a1,k}$ 减小且 $w_{b1,k}$ 增加, 因此 $Y_{1,k}(t)$ 与非条件刺激的神经反应联系增强而 $Y_{2,1}(t)$ 与非条件刺激的神经反应联系减弱. Case (4): 若两个条件刺激 $Y_{2,1}(t)$ 和 $Y_{1,k}(t)$ 的脉冲都没有出现, 即 $Y_{2,1}(t) = 0$ V 且 $Y_{1,k}(t) = 0$ V, 此时 $v_{a1,k}(t) < V_{T-}$ 且 $v_{b1,k}(t) < V_{T-}$, 权重 $w_{a1,k}$ 和 $w_{b1,k}$ 都减小, 因此两个条件刺激与非条件刺激的神经反应联系都减弱.

在测试期间, V_E 电压降至 50 mV, $c(t) = 0$ V 且 $v_T(t) = 5$ V, 因此 PMOS P_{Bk} 截止, NMOS N_{Tk} 导通. 忆阻交叉单元的联想记忆结果为 $Y_{2,1}(t)w_{a1,k} + Y_{1,k}(t)w_{b1,k}$. 测试期间联想记忆结果分为如下 4 种情况: (1) 当 $Y_{2,1}(t)$ 和 $Y_{1,k}(t)$ 的脉冲同时输入时, $Y_{2,1}(t) = V_E$ 且 $Y_{1,k}(t) = V_E$, 联想记忆结果为 $V_E(w_{a1,k} + w_{b1,k})$. (2) 当只有 $Y_{2,1}(t)$ 的脉冲输入时, $Y_{2,1}(t) = V_E$ 且 $Y_{1,k}(t) = 0$ V, 联想记忆结果为 $V_E w_{a1,k}$. (3) 当只有 $Y_{1,k}(t)$ 的脉冲输入时, $Y_{2,1}(t) = 0$ V 且 $Y_{1,k}(t) = V_E$, 联想记忆结果为 $V_E w_{b1,k}$. (4) 当 $Y_{2,1}(t)$ 和 $Y_{1,k}(t)$ 都无脉冲输入时, $Y_{2,1}(t) = 0$ V 且 $Y_{1,k}(t) = 0$ V, 联想记忆结果为 0. 因此, 在

学习阶段一个忆阻交叉单元中反复同时出现的两个条件刺激脉冲会使两个联想记忆权重不断增大, 在测试阶段该忆阻交叉单元中同时出现两个条件刺激脉冲时会输出大于其他情况的联想记忆结果. 第 k 列横杆中输入的条件刺激 $Y_{1,k}(t)$ 分别在 k 个忆阻交叉单元中与条件刺激 $Y_{2,1}(t), Y_{2,2}(t), \dots, Y_{2,k}(t)$ 构成 k 个不同的联想记忆结果, 第 k 列横杆输出电路的输出信号为 k 个忆阻交叉单元的总联想记忆结果, 输出信号 $v_{sk}(t)$ 计算为

$$v_{sk}(t) = \frac{R_{d1}R_{d3}}{R_{d2}} \sum_{z=1}^k \left(Y_{2,z}(t)w_{az,k} + Y_{1,k}(t)w_{bz,k} \right). \quad (11)$$

测试输出信号 $v_{ok}(t)$ 计算为

$$v_{ok}(t) = \begin{cases} 5 \text{ V}, & \text{if } v_{sk}(t) \geq V_{th}, \\ 0 \text{ V}, & \text{if } v_{sk}(t) < V_{th}, \end{cases} \quad (12)$$

其中 V_{th} 是输出阈值电压. 在仿真中, $V_{th} = 1 \text{ V}$, $R_{d1} = 10 \text{ k}\Omega$, $R_{d2} = 15 \text{ k}\Omega$, $R_{d3} = 10 \text{ k}\Omega$.

本文将一个巴甫洛夫联想忆阻交叉阵列中的所有输出信号 $v_{o1}(t), v_{o2}(t), \dots, v_{ok}(t)$ 转换为具有 k 个位点的二进制序列. 例如, $v_{ok}(t) = 5 \text{ V}$ 时, 则序列的第 k 个位点幅值等于 1. 否则, 第 k 个位点幅值等于 0. 由于 AAMSN 中具有 L 个巴甫洛夫联想忆阻交叉阵列, 因此每个图像在测试期间可以产生 L 个序列 $(O_1, O_2, \dots, O_L)$. 然后, 将 L 个序列组合成具有 n 个点的总输出序列 $OS = [O_1, O_2, \dots, O_L]$, 并且序列 OS 表示图像的测试结果.

近年来, 学者们提出了一些用于 MSNN 的无监督图像分类测试方法. 第 1 种测试方法是在测试阶段将带标签数据输入神经网络并计算所有输出神经元的脉冲数, 脉冲计数最高的输出神经元被标记为与输入类别相同的获胜神经元^[22]. 第 2 种测试方法是在测试前使用带标签数据来标记输出神经元, 生成最大脉冲数的输出神经元被视为与输入类别相关联^[19]. 第 3 种测试方法是在测试之前将输出神经元的最大电压与带标签的输入类别相关联^[18]. 本文将少量带标签图像作为验证图像输入到完成学习后的 AAMSN 中进行验证, 验证阶段和测试阶段不进行任何学习操作. 对同一类别中所有验证图像的输出序列的同一位点进行计数, 计数结果转换为每个类别的类验证序列 DS 的位点统计值. 然后通过计算类验证序列与测试序列之间的相关性来进行分类. 类验证序列的数量与图像类别的数量相同.

余弦相似度是通过计算两个向量之间的角余弦值来测量的^[36]. 本文采用余弦相似度 C_s 来定量测量测试序列 OS 与类验证序列 DS 之间的相关性. 余弦相似度 C_s 计算为

$$C_s = \frac{\mathbf{OS} \cdot \mathbf{DS}}{\|\mathbf{OS}\| \|\mathbf{DS}\|}, \quad (13)$$

其中 $\mathbf{OS}$ 和 $\mathbf{DS}$ 是序列 OS 和 DS 的向量. $\mathbf{OS} \cdot \mathbf{DS}$ 表示序列 OS 和 DS 的向量内积. $\|\mathbf{OS}\|$ 和 $\|\mathbf{DS}\|$ 分别是 $\mathbf{OS}$ 和 $\mathbf{DS}$ 的欧几里得范数 (Euclidean norm). 当 $C_s = 0$ 时, OS 和 DS 不相关; 当 $C_s = 1$ 时, OS 和 DS 完全相关. 因此, 余弦相似度 C_s 可以用作分类的依据.

为了计算余弦相似度, 本文设计了一个余弦相似度计算电路, 如图 6 所示. 在余弦相似度计算电路中, 测试序列 OS 中各个位点值被转换成电压信号 $v_{os1}(t), v_{os2}(t), \dots, v_{osn}(t)$, 类验证序列 DS 中各个位点值被转换成电压信号 $v_{ds1}(t), v_{ds2}(t), \dots, v_{dsn}(t)$. 测试序列 OS 的电压信号输入图 6(a) 用于计算 $\|\mathbf{OS}\|$, 并输出得到 $v_{os}(t)$. 类验证序列 DS 的电压信号输入到图 6(b) 中用于计算 $\|\mathbf{DS}\|$, 并输出得到 $v_{ds}(t)$. 图 6(c) 用于计算点积 $\mathbf{OS} \cdot \mathbf{DS}$, 并输出得到 $v_{dp}(t)$. 余弦相似度输出电路如图 6(d) 所示, 其




图 6 (网络版彩图) 余弦相似度计算电路

Figure 6 (Color online) Cosine similarity calculation circuit. (a) Calculation circuit for $\|\mathbf{OS}\|$; (b) calculation circuit for $\|\mathbf{DS}\|$; (c) calculation circuit for the dot product $\mathbf{OS} \cdot \mathbf{DS}$; (d) cosine similarity output circuit

将点积结果 $v_{dp}(t)$ 除以 $v_{os}(t)$ 与 $v_{ds}(t)$ 的乘积, 得到余弦相似度结果 $C_s(t)$. 序列 OS 与 DS 的电压转换因子设置为 0.01, 转换时间设置为 1 ms, 余弦相似度计算电路的所有电阻设置为 10 k Ω . 余弦相似度计算电路中余弦相似度结果 $C_s(t)$ 的电压幅值计算为

$$C_s = -\frac{v_{dp}}{v_{os}v_{ds}} = -\frac{-\sum_{j=1}^n (v_{osj}v_{dsj})}{(-\sqrt{V_{os}})(-\sqrt{V_{ds}})} = \frac{\sum_{j=1}^n (v_{osj}v_{dsj})}{\sqrt{\sum_{j=1}^n (v_{osj}^2)}\sqrt{\sum_{j=1}^n (v_{dsj}^2)}}. \quad (14)$$

图 7 所示为余弦相似度计算电路的仿真示例. 图 7(a) 所示为一个 DS 序列的电压信号, 图 7(b) 和 (c) 分别为两个不同 OS 序列 OS₁ 和 OS₂ 的电压信号. 图 7(d) 为 DS 与 OS₁ 在余弦相似度计算电路中的计算结果, 其中 $v_{ds} = 0.145$ V, $v_{os} = 0.289$ V, $v_{dp} = -0.042$ V, 余弦相似度 $C_s = 0.999$ V. 图 7(e) 为 DS 与 OS₂ 在余弦相似度计算电路中的计算结果, 其中 $v_{ds} = 0.145$ V, $v_{os} = 0.276$ V, $v_{dp} = -0.024$ V, 余弦相似度 $C_s = 0.605$ V. 由计算结果可知, OS₁ 序列与 DS 序列更相关.

3 无监督图像分类应用

在无监督图像分类实验中, 将 MNIST 数据集^[37] 的手写数字图像和 EMNIST 数据集^[38] 的手写大写字母图像作为分类基准, 图像的大小设置为 28×28 .

实验 1: 选取 MNIST 数据集中 50000 张图像作为无标签训练图像. 选取 MNIST 数据集的 10 个类别中每个类别各 100 张有标签图像作为验证图像, 用于生成类验证序列. 选取 MNIST 测试集中 5000 张无标签图像作为测试图像.

实验 2: 选取 EMNIST 数据集中 100000 张图像作为无标签训练图像. 选取 EMNIST 数据集的 26 个类别中每个类别各 100 张有标签图像作为验证图像, 用于生成类验证序列. 选取 EMNIST 测试集中 5000 张无标签图像作为测试图像.

实验过程可以描述为以下 5 个步骤:

- (1) 将所有训练图像输入 AAMSNN 进行无监督训练, 且设置 $v_T(t) = -5$ V.
- (2) 完成所有训练图像的无监督训练后, 将 V_E 电压降至 50 mV 且 $v_T(t) = 5$ V.




图 7 (网络版彩图) 余弦相似度计算电路的仿真结果

Figure 7 (Color online) Simulation results of cosine similarity calculation circuit. (a) Voltage signal of sequence DS; (b) voltage signal of sequence OS₁; (c) voltage signal of sequence OS₂; (d) cosine similarity calculation results of DS and OS₁; (e) cosine similarity calculation results of DS and OS₂




Figure 8 (Color online) (a) Simulation result of feature extraction for a image example of digit 8; (b) attention encoding result in a local time from 34.2 to 36.0 ms

- (3) 将每个类别的验证图像输入到训练好的 AAMSNN 以生成类验证序列.
- (4) 将测试图像输入到训练好的 AAMSNN 中, 每个测试图像输出一个测试序列.
- (5) 计算测试序列与所有类验证序列之间的余弦相似度. 将余弦相似度最大的测试序列与类验证序列归为同一类别.

3.1 实验仿真与分析

在实验仿真中, 使用拉普拉斯高斯 (Laplacian of Gaussian, LoG) 卷积核提取图像特征, 其中 $H = 5$, $m = 25$, $Z = 576$ 且 $T_c = 0.1$ ms. 图 8(a) 是对一个手写数字 8 图像进行特征提取的仿真结果, 仿真总时间为 $ZT_c = 57.6$ ms. 当 $v_{a1}(t)$ 的幅值超过 0 V 时, $v_a(t)$ 在相应的时间上产生幅值为 5 V 的脉冲. $S(t)$ 的振荡频率在 $v_a(t) = 5$ V 时被编码为注意力信号 $S_{A1}(t)$ 的频率特征, 如图 8(b) 所示. 由于全局时间的高频正弦振荡信号难以详细显示, 图 8(b) 展示的是 $S_{A1}(t)$ 的局部时间信号. 在仿真中, $f_A = 100$ kHz, $F = 500$ Hz.

图 9(a) 和 (b) 所示为注意力信号 $S_{A1}(t)$ 在 $AMC_{1,58}$ 和 $AMC_{1,59}$ 中的注意力匹配结果. 在仿真中, $s = 6$, $n = 96$. 在图 9(a) 中, 由于注意力信号 $S_{A1}(t)$ 中具有与 $s_{58}(t)$ 相同频率的频率特征, 因此




图 9 (网络版彩图) (a) $AMC_{1,58}$ 和 (b) $AMC_{1,59}$ 的注意力信号匹配结果; 控制电路 (c) $CC_{1,58}$ 和 (d) $CC_{1,59}$ 的仿真结果

Figure 9 (Color online) Attention matching results of (a) $AMC_{1,58}$ and (b) $AMC_{1,59}$; simulation results of (c) $CC_{1,58}$ and (d) $CC_{1,59}$





图 10 (网络版彩图) 数字类别的类验证序列. 横坐标表示同类别下类验证序列中位点的统计值, 纵坐标表示类验证序列的位点

Figure 10 (Color online) Class validation sequence of each digit class. The abscissa represents the cumulative values of the points in class validation sequence under the same digit class, and the ordinate represents the points of class validation sequence

$x_{1,58}(t)$ 在 34.8 ms 左右达到最大幅值并超过 2.5 V. 在图 9(b) 中, $x_{1,59}(t)$ 的最大幅值在 35.4 ms 左右超过 2.5 V. 然而, 从图 8(b) 可以观察到, 注意力信号 $S_{A1}(t)$ 只在 35.2~35.4 ms 之间有振荡信号, 在 35.4~36.0 ms 之间没有振荡信号, 即 $S_{A1}(t)$ 中没有与 $s_{59}(t)$ 相同频率的频率特征. 这些结果表明, 即使注意力信号中没有与匹配频率相同的频率, 注意力选择电路也会在更大的注意力信号范围内搜索与匹配频率相关的频率, 从而选择到相关的频率特征信息.

控制电路的仿真结果如图 9(c) 和 (d) 所示. 在前 57.6 ms 内, $c(t) = 0$ V. 在 57.6~58.6 ms 期间, $c(t) = 5$ V. 在仿真中, $V_E = 0.3$ V. 在图 9(c) 中, 由于在 34.8 ms 时 $x_{1,58}(t) > 2.5$ V, 因此从 34.8 ms 开始, $x_{a1,58}(t) = 5$ V 且 $x_{b1,58}(t) = 0$ V. 当 $c(t) = 5$ V 且 $x_{a1,58}(t) = 5$ V 时, NMOS $N_{a1,58}$ 被控制导通, $Y_{1,58}(t) = V_E$. 因此, 如果 AMC 的输出电压超过 2.5 V, 意味着注意力选择电路选择到了注意力信号中的相关频率特征, 并且相应 CC 的输出电压为 V_E . 同理, 图 9(d) 中由于在 35.4 ms 时 $x_{1,59}(t) > 2.5$ V, 因此在 57.6~58.6 ms 期间 $Y_{1,59}(t) = V_E$. 而如果 AMC 的输出电压未超过 2.5 V, 则 CC 的输出电压为 0 V, 表示注意力信号中不存在与匹配频率相同或相关的频率特征.

图 11 (网络版彩图) 不同 s 和 k 参数值下的分类准确率**Figure 11** (Color online) Classification accuracy under different parameter values of s and k . (a) MNIST dataset; (b) EMNIST dataset

在无监督学习中, 忆阻器的初始忆阻值随机设置. 在对 50000 张无标签手写数字图像进行无监督训练后, 将 10 个数字类别各 100 张带标签手写数字图像输入到训练好的 AAMSNN 中, 生成 10 个类别的类验证序列, 如图 10 所示. 然后, 将测试图像输入到训练好的 AAMSNN 中, 输出测试序列. 最后, 在余弦相似度计算电路中计算测试序列与类验证序列之间的余弦相似度.

3.2 分类结果

通过在不同频率间隔 s 和不同 $k \times k$ 大小的巴甫洛夫联想忆阻交叉阵列下进行仿真实验, MNIST 数据集和 EMNIST 数据集的分类准确率如图 11(a) 和 (b) 所示. 实验结果表明, 当 $s = 3$ 和 $k = 8$ 时, MNIST 数据集的分类准确率为 93.2%, EMNIST 数据集的分类准确率为 76.8%, 两者均为最高分类准确率. 由于具有 26 个类别的 EMNIST 数据集的无监督图像分类比具有 10 个类别的 MNIST 数据集更具挑战性, 因此 EMNIST 数据集的分类准确率低于 MNIST 数据集. 当 $k = 4$ 时, 分类准确率相对较低, 这是因为巴甫洛夫联想忆阻交叉阵列 (4×4) 中的忆阻器数量太少, 无法建立更多输入信号之间的神经反应联系. 当 $k = 16$ 时, 分类准确率也相对较低, 因为巴甫洛夫联想忆阻交叉阵列 (16×16) 中的忆阻器数量太多, 导致神经反应联系受到了更多的干扰. 当 $s = 6$ ($n = 96$) 时, 分类准确率相对于 $s = 3$ ($n = 192$) 和 $s = 4$ ($n = 144$) 最低, 即频率间隔过大将导致分类准确率降低. 因此在实际应用中, 频率间隔和巴甫洛夫联想忆阻交叉阵列大小是获得更好分类结果的关键考虑因素.

4 性能分析

4.1 相关工作的比较

本工作与其他用于无监督图像分类的 MSNN 的比较结果如表 2 所示. 首先, 本文所提出的 AAMSNN 利用注意力机制来选择重要信息并忽略无关信息, 减少了 AAMSNN 的输入神经元数量, 所需输入神经元数量约为其他工作的 48.9%. 其次, 其他工作主要关注 STDP 或 BCM 学习规则, 这导致学习仅限于局部神经元活动, 而没有考虑 MSNN 中不同刺激相关联形成的神经反应联系. 相比之下, AAMSNN 应用巴甫洛夫联想记忆原理来调节神经网络中的神经反应联系, 以更小的 MSNN 规模实现了对图像的无监督分类, 且 AAMSNN 的忆阻器数量比文献 [18~21] 中的忆阻器数量小两个数量级, 只需文献 [22] 约 39.8% 的忆阻器数量. 在 MNIST 数据集的无监督分类中, AAMSNN 取得了比其他工作更高的分类准确率. 比较结果表明, 所提出的 AAMSNN 以更小的 MSNN 规模和更少的忆阻器数量

表 2 与其他用于无监督图像分类的 MSNN 的比较

Table 2 Comparison with other MSNNs for unsupervised image classification

Work	Biological mechanism	Learning rule	Number of input neurons	MSNN scale	Number of memristors	MNIST (%)
[18]	Lateral inhibition and homeostatic	STDP	784	784×400	3.136×10^5	91.7
[19]	Homeostatic	STDP	784	784×1000	1.568×10^6	90.1
[20]	WTA	STDP	784	784×256	4.014×10^5	92.7
[21]	—	STDP	784	$28 \times 28 \times 324$	2.540×10^5	90.2
[22]	—	STDP and BCM	784	784×10	7.840×10^3	91.4
This work	Attention	Pavlovian associative memory	384	$8 \times 8 \times 24$	3.122×10^3	93.2

表 3 AAMSNN 的功耗与面积开销

Table 3 Power consumption and area overhead of AAMSNN

Circuit	Power (mW)	Area (μm^2)
Feature extraction module	0.88	1.95×10^3
Attention encoding module	0.51	4.76×10^3
One AMC	0.07	3.09×10^3
One CC	0.02	19.80
One Pavlovian associative memristor cross array	1.52	1.79×10^4
Cosine similarity calculation circuit	1.92	1.02×10^5
Total circuit	74.37	1.73×10^6

实现了优于其他 MSNN 的分类准确率.

4.2 电路功耗和面积开销分析

AAMSNN 的功耗主要包括运算放大器、CMOS 逻辑门、乘法器、电阻、忆阻器、NMOS 和 PMOS. 电路功耗通过 PSPICE 仿真报告得到, 如表 3 所示, 其中 $s = 6$, $n = 96$, $k = 8$, $L = 12$. 此外, AIST 忆阻器的尺寸为 $100 \text{ nm} \times 25 \text{ nm} \times 100 \text{ nm}$ [39]. NMOS 和 PMOS 的面积约为 $0.9 \mu\text{m}^2$. 使用 $25 \Omega/\text{sq}$ 的方块电阻可以计算出 $1 \text{ k}\Omega$ 电阻的面积为 $(1 \text{ k}\Omega \div 25 \Omega) \times 0.6 \mu\text{m} \times 0.6 \mu\text{m} = 14.4 \mu\text{m}^2$. 运算放大器的面积约为 $600 \mu\text{m}^2$. “与”逻辑门的面积约为 $5.4 \mu\text{m}^2$, “或非”逻辑门的面积约为 $3.6 \mu\text{m}^2$, “非”逻辑门的面积约为 $1.8 \mu\text{m}^2$. 乘法器的面积约为 $25.2 \mu\text{m}^2$. 根据上述分析, AAMSNN 的面积开销计算结果如表 3 所示.

4.3 鲁棒性分析

为了分析 AAMSNN 的鲁棒性, 我们对具有不同椒盐噪声强度的图像进行了 30 次测试并得到不同椒盐噪声强度下的平均准确率. 椒盐噪声会随机将图像的一些像素值改变为 0 或 255, 椒盐噪声的强度用 sp 表示. 强度越大, 噪声像素越多. 在仿真中, 使用 MNIST 数据集和 EMNIST 数据集作为分类基准, 图像大小为 28×28 , $s = 3$, $k = 8$. 不同椒盐噪声强度下的平均准确率如表 4 所示. 注意力可以搜索和选择重要信息, 能够有效地滤除噪声和不相关信息, 使 AAMSNN 对噪声具有更强的鲁棒性. 因此当椒盐噪声强度为 0.05 时, AAMSNN 能够保持良好的分类准确率. 随着椒盐噪声强度的增大, 被

表 4 不同强度椒盐噪声下的平均准确率

Table 4 Average accuracy under different intensities of salt-pepper noise

Intensity of salt-pepper noise	MNIST (%)	EMNIST (%)
sp = 0.05	81.3	62.6
sp = 0.10	63.7	45.8
sp = 0.15	48.5	34.3
sp = 0.20	33.2	20.1




图 12 (网络版彩图) 忆阻交叉阵列的非理想性对分类准确率的影响

Figure 12 (Color online) Influence of non-ideality in memristor cross arrays on classification accuracy

改变为噪声像素的重要像素增多, 影响了注意力对重要像素的选择, 导致分类准确率显著减小.

4.4 非理想性分析

理想情况下, 忆阻器可以存储连续的模拟值, 但在实际中, 由于参数漂移和器件老化等非理想问题, 忆阻器表现出离散的存储行为^[40]. 由于忆阻交叉阵列中的非理想性会影响无监督学习的分类准确性, 因此应予以考虑. 利用蒙特卡罗 (Monte Carlo) 分析法将忆阻器件中的非理想性建模为忆阻值的高斯变化^[41], 其中变化量设置为 σ/μ (%). 不同 σ/μ 下的分类准确率结果如图 12 所示. 在仿真中, 使用 MNIST 数据集和 EMNIST 数据集作为分类基准, 图像大小为 28×28 , $s = 3$, $k = 8$. 蒙特卡罗仿真的仿真次数为 100 次, 分类准确率结果为平均准确率. 仿真结果表明, 随着 σ/μ 的增加, 分类准确率下降, 表明忆阻器的非理想性越显著, 分类性能越差. 先前的研究表明, 忆阻交叉阵列中的非理想性效应随着忆阻交叉阵列中有效电阻的增加而减小^[41]. 通过增加忆阻交叉阵列中低电导值的比例, 可以减小非理想性的影响. 此外, 可以使用非线性感知训练 (NEAT) 方法^[40] 来减轻忆阻交叉阵列中的非理想性.

5 总结

本文提出了一种基于注意力的联想忆阻脉冲神经网络 (AAMSNN) 的全电路设计, 并将其应用于无监督图像分类. 受人脑注意力机制的启发, 设计了注意力编码电路和注意力选择电路用于搜索和选

择信号中的相关特征信息,减少了 AAMSNN 的输入神经元数量. 基于巴甫洛夫联想记忆原理,设计了一种由巴甫洛夫联想记忆交叉阵列构成的联想记忆脉冲神经网络,用于调节不同刺激之间的神经反应联系,实现了无监督图像分类. 相比于其他用于无监督图像分类的 MSNN,所提出的 AAMSNN 以更小的 MSNN 规模和更少的忆阻器数量实现了更高的分类准确率. 因此,本文工作可以为构建小规模无监督学习硬件系统提供研究基础,可以应用于仿生视觉和类脑计算等领域,减小硬件规模和数据标记成本. 未来,我们将进一步优化神经网络结构,并实现更优的无监督分类性能.

参考文献

- 1 Niu L Y, Wei Y, Liu W B, et al. Research progress of spiking neural network in image classification: a review. *Appl Intell*, 2023, 53: 19466–19490
- 2 Sateesan A, Sinha S, Smitha K G, et al. A survey of algorithmic and hardware optimization techniques for vision convolutional neural networks on FPGAs. *Neural Process Lett*, 2021, 53: 2331–2377
- 3 Cheng C D, Tiw P J, Cai Y M, et al. In-memory computing with emerging nonvolatile memory devices. *Sci China Inf Sci*, 2021, 64: 221402
- 4 Chua L. Memristor-the missing circuit element. *IEEE Trans Circ Theor*, 1971, 18: 507–519
- 5 Strukov D B, Snider G S, Stewart D R, et al. The missing memristor found. *Nature*, 2008, 453: 80–83
- 6 Deng Q L, Wang C H, Sun J R, et al. Nonvolatile CMOS memristor, reconfigurable array, and its application in power load forecasting. *IEEE Trans Ind Inform*, 2024, 20: 6130–6141
- 7 Luo L, Dong Z K, Hu X F, et al. Reconfigurable logic circuit design for stateful Boolean logic computing. *Sci China Inf Sci*, 2021, 64: 189401
- 8 Xu C, Wang C H, Sun J R. A memristor-based RBM circuit implementation and application in license plate image processing. *Sci Sin Inform*, 2023, 53: 164–177 [徐聪, 王春华, 孙晶茹. 基于忆阻器的 RBM 及其在车牌图像处理中的应用. *中国科学: 信息科学*, 2023, 53: 164–177]
- 9 Wang G Y, Shen S H, Liu G Z, et al. Design of memristor based multiplier circuits. *J Electron Inform Technol*, 2020, 42: 827–834 [王光义, 沈书航, 刘公致, 等. 基于忆阻器的乘法器电路设计. *电子与信息学报*, 2020, 42: 827–834]
- 10 Xiao P D, Hong Q H, Du S H, et al. Design and application of a programmable matrix determinant-solving circuit based on memristors. *Sci Sin Inform*, 2023, 53: 1008–1025 [肖平旦, 洪庆辉, 杜四春, 等. 基于忆阻器的可编程矩阵行列式求解电路设计及应用. *中国科学: 信息科学*, 2023, 53: 1008–1025]
- 11 Li K X, Bao H, Li H Z, et al. Memristive Rulkov neuron model with magnetic induction effects. *IEEE Trans Ind Inf*, 2022, 18: 1726–1736
- 12 Wang C H, Luo D W, Deng Q L, et al. Dynamics analysis and FPGA implementation of discrete memristive cellular neural network with heterogeneous activation functions. *Chaos Soliton Fract*, 2024, 187: 115471
- 13 Yang H, Duan S K, Dong Z K, et al. A memristor-CMOS-based general-logic circuit and its applications. *Sci Sin Inform*, 2020, 50: 289–302 [杨辉, 段书凯, 董哲康, 等. 基于忆阻器 – CMOS 的通用逻辑电路及其应用. *中国科学: 信息科学*, 2020, 50: 289–302]
- 14 Wang C H, Liang J H, Deng Q L. Dynamics of heterogeneous Hopfield neural network with adaptive activation function based on memristor. *Neural Netw*, 2024, 178: 106408
- 15 Deng Z K, Wang C H, Lin H R, et al. A memristive spiking neural network circuit with selective supervised attention algorithm. *IEEE Trans Comput-Aided Des Integr Circ Syst*, 2023, 42: 2604–2617
- 16 Hu X F, Shi W Q, Zhou Y, et al. Quantized and adaptive memristor based CNN (QA-mCNN) for image processing. *Sci China Inf Sci*, 2022, 65: 119104
- 17 Kong X X, Yu F, Yao W, et al. Memristor-induced hyperchaos, multiscroll and extreme multistability in fractional-order HNN: image encryption and FPGA implementation. *Neural Netw*, 2024, 171: 85–103
- 18 Zhao Z Y, Qu L H, Wang L, et al. A memristor-based spiking neural network with high scalability and learning efficiency. *IEEE Trans Circ Syst II*, 2020, 67: 931–935
- 19 Adnan M M, Sayyaparaju S, Brown S D, et al. Design of a robust memristive spiking neuromorphic system with unsupervised learning in hardware. *J Emerg Technol Comput Syst*, 2021, 17: 1–26

- 20 Ku B W, Schuman C D, Adnan M M, et al. Unsupervised digit recognition using cosine similarity in a neuromemristive competitive learning system. *J Emerg Technol Comput Syst*, 2022, 18: 1–20
- 21 Wang Y, Yan Y, Liu Y, et al. Unsupervised learning of digit recognition through spike-timing-dependent plasticity based on memristors. In: *Proceedings of the 4th International Conference on Artificial Intelligence and Education (ICAIE)*, Guilin, 2023. 221–226
- 22 Florini D, Gandolfi D, Mapelli J, et al. A hybrid CMOS-memristor spiking neural network supporting multiple learning rules. *IEEE Trans Neural Netw Learn Syst*, 2024, 35: 5117–5129
- 23 Arizpe J M, Noles D L, Tsao J W, et al. Eye movement dynamics differ between encoding and recognition of faces. *Vision*, 2019, 3: 9
- 24 Fries P, Womelsdorf T, Oostenveld R, et al. The effects of visual stimulation and selective visual attention on rhythmic neuronal synchronization in macaque area V₄. *J Neurosci*, 2008, 28: 4823–4835
- 25 Yang C, Wang X P, Zeng Z G. Full-circuit implementation of transformer network based on memristor. *IEEE Trans Circ Syst I*, 2022, 69: 1395–1407
- 26 Xiao H, Zhou Y, Gao T T, et al. Memristor-based light-weight transformer circuit implementation for speech recognizing. *IEEE J Emerg Sel Top Circ Syst*, 2023, 13: 344–356
- 27 Liao M L, Wang C H, Sun Y C, et al. Memristor-based affective associative memory neural network circuit with emotional gradual processes. *Neural Comput Applic*, 2022, 34: 13667–13682
- 28 Sun J W, Han G Y, Zeng Z G, et al. Memristor-based neural network circuit of full-function pavlov associative memory with time delay and variable learning rate. *IEEE Trans Cybern*, 2020, 50: 2935–2945
- 29 Biolek D, Biolková V, Biolek Z. SPICE model of memristor with nonlinear dopant drift. *Radioengineering*, 2009, 18: 210–214
- 30 Kvatinisky S, Ramadan M, Friedman E G, et al. VTEAM: a general model for voltage-controlled memristors. *IEEE Trans Circ Syst II*, 2015, 62: 786–790
- 31 Zhang Y, Wang X P, Li Y, et al. Memristive model for synaptic circuits. *IEEE Trans Circ Syst II*, 2017, 64: 767–771
- 32 Truong S N, Min K S. New memristor-based crossbar array architecture with 50-% area reduction and 48-% power saving for matrix-vector multiplication of analog neuromorphic computing. *JSTS-J Semiconductor Tech Sci*, 2014, 14: 356–363
- 33 Zhao M, Chalmers L, Cao L, et al. Electrical signaling in control of ocular cell behaviors. *Prog Retinal Eye Res*, 2012, 31: 65–88
- 34 Moore T, Zirnsak M. Neural mechanisms of selective visual attention. *Annu Rev Psychol*, 2017, 68: 47–72
- 35 Liang L, Fratzl A, Goldey G, et al. A fine-scale functional logic to convergence from retina to thalamus. *Cell*, 2018, 173: 1343–1355
- 36 Zhou H J, Yang L, Bao H, et al. Memristive cosine-similarity-based few-shot learning with lifelong memory adaptation. *Adv Intell Syst*, 2023, 5: 1–9
- 37 Deng L. The MNIST database of handwritten digit images for machine learning research [best of the web]. *IEEE Signal Process Mag*, 2012, 29: 141–142
- 38 Cohen G, Afshar S, Tapson J, et al. EMNIST: extending MNIST to handwritten letters. In: *Proceedings of the International Joint Conference on Neural Networks (IJCNN)*, 2017. 2921–2926
- 39 Zhang Y T, Zeng Z G. A multi-functional memristive pavlov associative memory circuit based on neural mechanisms. *IEEE Trans Biomed Circ Syst*, 2021, 15: 978–993
- 40 Bhattacharjee A, Panda P. SwitchX: $G_{\min}$ - $G_{\max}$ switching for energy-efficient and robust implementation of binarized neural networks on ReRAM xbars. *ACM Trans Des Autom Electron Syst*, 2023, 28: 1–21
- 41 Bhattacharjee A, Bhatnagar L, Kim Y, et al. NEAT: nonlinearity aware training for accurate, energy-efficient, and robust implementation of neural networks on 1T-1R crossbars. *IEEE Trans Comput-Aided Des Integr Circ Syst*, 2022, 41: 2625–2637

An attention-based associative memristive spiking neural network and its application in unsupervised image classification

Zekun DENG¹, Chunhua WANG^{1*}, Hairong LIN², Quanli DENG¹ & Yichuang SUN³

1. *College of Computer Science and Electronic Engineering, Hunan University, Changsha 410082, China;*

2. *School of Electronic Information, Central South University, Changsha 410083, China;*

3. *School of Engineering and Computer Science, University of Hertfordshire, Hatfield AL10 9AB, UK*

* Corresponding author. E-mail: wch1227164@hnu.edu.cn

Abstract Unsupervised learning does not require manual annotation of training data, showing significant value in image classification applications of hardware systems. Unsupervised learning in the existing memristive spiking neural networks (MSNNs) mainly focuses on the synaptic adjustment process between anteroposterior neurons, limiting learning to local neural activity and neglecting internal connections between neural responses. Associative memory is a crucial way for the brain to achieve memory, which associates different stimuli through unsupervised learning to establish interconnected network memories. Meanwhile, the human visual system utilizes attention mechanisms to select important information from massive data, effectively reducing the number of input neurons and the scale of neural networks. This paper proposes a fully circuit-designed attention-based associative memristive spiking neural network (AAMSNN) and applies it to unsupervised image classification. Inspired by the attention mechanism, attention encoding circuits and attention selection circuits are designed to search for and select important information, reducing the number of input neurons of AAMSNN. The associative memristive spiking neural network module consists of Pavlovian associative memristive cross arrays, and achieves unsupervised image classification by adjusting the associative memory weight. The AAMSNN has smaller MSNN size and fewer memristors than other MSNNs, and achieves superior unsupervised image classification accuracy.

Keywords memristive spiking neural network, attention, associative memory, unsupervised learning, image classification