

# 激光与光电子学进展

## 基于相变材料的光子神经形态计算技术综述

王金融, 宋兵, 徐晖, 张亨宇, 孙振源, 李清江\*

国防科技大学电子科学学院, 湖南 长沙 410073

**摘要** 当前物联网、云计算等产生的海量非结构化数据,极大提高了对数据处理算力和能效的需求。神经形态计算借鉴生物大脑的信息处理方式,以神经元与神经突触为基本单元,从互联架构与信息处理模式等方面模拟生物神经系统,能够实现实时、超低功耗信息处理,成为大数据时代计算技术发展的前沿热点。其中,光子神经形态计算技术是在光域上进行神经形态计算数据处理的技术,既能够充分发挥光子高速传输、低功耗、高并行度的优势,又能够避免光电和电光转换带来的额外时间功耗开销,具有很大的研究和应用价值。近年来,相变材料作为一种具有高折射率对比度和非易失特性的光学材料,可在光、电、热等激励作用下进行折射率的连续调节,为非易失光子神经形态计算提供了一种可行的解决方案,成为当前的研究热点。本文首先介绍了光子神经形态计算的基本原理和实现方法,在此基础上讨论了相变材料用于光子神经形态计算的原理。其次,针对不同类型的实现途径,研究了不同相变材料的特点和选型办法,综合分析了当前应用较多的两类相变材料以及各类光突触器件和阵列集成应用。最后对基于相变材料的光子神经形态计算技术的发展进行了展望。

**关键词** 材料; 相变材料; 神经形态计算; 光神经网络

中图分类号 TN256

文献标志码 A

DOI: 10.3788/LOP222566

### An Overview of Photonic Neuromorphic Computing Techniques Based on Phase-Change Materials

Wang Jinrong, Song Bing, Xu Hui, Zhang Hengyu, Sun Zhenyuan, Li Qingjiang\*

*College of Electronic Science and Technology, National University of Defense Technology,  
Changsha 410073, Hunan, China*

**Abstract** The large amount of unstructured data generated by the Internet of Things and cloud computing has recently increased the demand for data computing power and energy efficiency. Referencing the information processing method of the biological brain with neuron and synapse as basic units, neuromorphic computing can simulate the biological nervous system from the aspects of interconnection architecture and information processing mode, and realize ultra-low power processing of real-time information, which have become the forefront of the development of computing technology in the big data era. The processing of computational data in the optical domain makes photonic neuromorphic computing research important owing to its high application potential. On the one hand, photonic neuromorphic computing can take advantage of high-speed transmission, low power consumption, and high parallelism of photons. On the other hand, it can also prevent photoelectric and electro-optic conversion, thus, reducing additional time and power consumption. In recent years, phase-change materials (PCM), as a kind of optical material with high refractive index contrast and non-volatile property, whose refractive rate can be continuously adjusted under the driving of optical, electrical, and thermal excitations, have provided a feasible solution for non-volatile photonic neuromorphic computing and have become the current research hotspot. In this paper, we first introduce the basic principle and implementation method of photonic neuromorphic computing. Subsequently, we discuss the principle of utilizing phase-change materials in photonic neuromorphic computing. According to the unique characteristics of phase-change materials selected in different implementation schemes, two kinds of phase-change materials and different applications of optical synapse devices and integrated arrays are then summarized. Finally, we prospect the development of photonic neuromorphic computing techniques based on phase-change materials.

**Key words** materials; phase-change material; neuromorphic computing; optical neural network

收稿日期: 2022-09-19; 修回日期: 2022-10-13; 录用日期: 2022-10-24; 网络首发日期: 2022-11-04

基金项目: 国家自然科学基金(62104256, 61974164, 62074166, 61804181, 62004219, 62004220)

通信作者: \*qingjiangli@nudt.edu.cn

## 1 引 言

当今社会正处于信息爆炸的时代,随着 5G、大数据、物联网、智能终端、自动驾驶等技术的高速发展,全球数据流量呈几何级态势增长,这对计算机的算力和能耗提出了更高的要求。而随着摩尔定律减缓甚至失效,人们亟待提出新的解决方案来满足大数据对算力和能耗的需求。

自人工智能概念被提出以来,由于其强大的自我学习能力和并行处理能力,被当作是解决大规模非结构化数据应用处理问题的有力工具。在此基础上,基于高性能计算的人工神经网络取得了飞速的发展,在众多领域取得了广泛的应用成果。例如,通过神经网络的训练,Google 公司的围棋人工智能 AlphaGo<sup>[1]</sup>彻

底战胜人类棋手;同时在人脸识别、自动驾驶、机器翻译等各个领域,人工智能已经实现了商业化的应用。然而,现阶段的高性能计算机仍采用冯·诺依曼架构,存储器和处理器分置导致频繁调用处理数据时消耗大量能量,且处理器高速处理数据与存储器低速读写产生矛盾,因此基于传统架构的计算系统在体积和能效方面面临严峻挑战。同时,摩尔定律发展面临物理极限的挑战,硬件特征尺寸微缩对算力的提升放缓,且密度提升导致单位面积产生的热量更多且散热困难,这些问题制约了传统计算系统的智能化处理性能的进一步提升。图 1 展示了计算芯片从中央处理器(CPU)发展到神经网络处理器(NPU)的过程中算力不断提高,但是依然无法跨越 100 TOPS/W 的瓶颈,与人脑存在着 10~100 倍的差距。

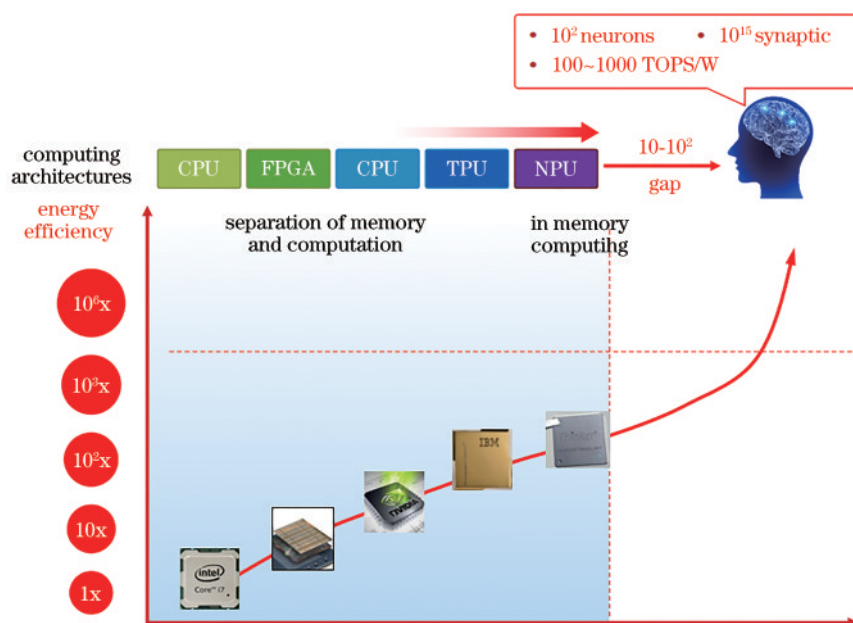


图 1 芯片算力比较图

Fig. 1 Comparison diagram of chip computing power

近年来,基于忆阻器<sup>[2-3]</sup>等新型微纳电子器件的神经形态计算技术发展迅速,其存算一体机制有望破解存算分置的难题。忆阻器的阻值状态随着历史激励能够连续调节,能够模拟生物电子突触可调特性,且能稳定保持,对于存算一体的计算架构具有天然的适应性。神经形态计算系统是借鉴生物大脑的信息处理方式,以神经元与神经突触为基本单元,从互联架构与信息处理模式等方面模拟生物神经系统,能够实时处理非结构化信息的超低功耗新型计算系统。近年来,基于忆阻器的电学神经形态计算发展迅速,在图像识别<sup>[4]</sup>、双耳定位<sup>[5]</sup>、脑电信号处理<sup>[6-7]</sup>等方面展现出了高能效的潜力。但是,现阶段忆阻器的发展面临着状态波动、器件间串扰的挑战,并且有望解决这些问题所需要的材料、工艺等方面的突破也面临着重重困难。

与电子器件相比,基于光学器件的神经形态计算

技术能够充分发挥光子独特优势,避免电子技术方面的难点问题。基于光学器件的光子神经形态计算利用光学器件对矩阵的乘加运算进行加速,符合矩阵运算的数学性质,并且运算过程中前向传播速度等于光速。受益于玻色子的本质,光子之间没有相互作用力,相互之间不会被干扰,因此光学器件能够实现超宽带宽和高并行度,并且光的传输能耗很低,具有较低的功耗。因此光子计算可以在运行速度、能耗、并行度上实现巨大飞跃。

## 2 光子神经形态计算

光子神经形态计算是指通过空间光学元件、光波导器件实现对输入光场的逐元素乘加运算,继而实现矩阵向量乘加运算,完成神经形态计算的技术。光子计算的历史从 20 世纪 60 年代发明激光器开始,2017 年

出现了集成的光神经网络用于模拟光计算,光计算开始应用于完成特定功能的光学运算,光子神经形态计算出现并进入了快速发展的时期,主要分为空间光学和集成光学两条路径。

空间光子神经形态计算,是指利用光场传播的衍射积分特性,采用透镜、相位板等光学元件配置特定的网络结构,实现输入场与光学元件的幅度和相位逐元素相乘,主要分为傅里叶光学方法和衍射光学方法。集成光子神经形态计算,是指利用调制器对导波光的调制特性,在硅基光子平台开发波导器件阵列配

置特定的网络结构,实现输入光与波导器件阵列的逐元素乘加运算,主要分为损耗调制方法和相位调制方法。

### 2.1 空间光学

#### 2.1.1 傅里叶光学神经形态计算

傅里叶光学的基本原理是通过光学  $4f$  系统对光场进行正向和逆向的傅里叶变换,在傅里叶平面上插入光学元件实现对输入光场幅度和相位逐元素乘加。傅里叶光学能够通过一次卷积操作实现非相干光图像的直接模板匹配,如图 2(a) 所示。




图 2 混合光电卷积神经网络<sup>[7]</sup>。(a) 光学  $4f$  系统的成像原理; (b) 光学卷积层设计, 包括输入图像、卷积内核堆栈和输出层  
Fig. 2 Hybrid photoelectric convolutional neural network<sup>[7]</sup>. (a) Imaging principle of optical  $4f$  system; (b) optical convolutional layer design including input image, convolutional kernel stack, and output layer

2018 年, 美国斯坦福大学提出一种混合光电卷积神经网络, 用于实现图像分类, 如图 2(b) 所示。该网络在电子计算之前整合了一层光学卷积计算, 当光通过  $4f$  系统时, 光学卷积自然发生, 大大减少了整个网络的计算量。使用 Google QuickDraw 数据集对光卷积层进行验证, 准确率为 72.2%; 采用 CIFAR-10 数据集对整个混合光电卷积神经网络 (CNN) 进行模拟验

证, 准确率达到 51% 时, 电子部分只需要 180234 个 FLOPS; 而采用纯电子神经网络的准确率达到 51.9% 时, 需要超过一百万个 FLOPS<sup>[7]</sup>。由此可见, 与电子神经网络相比, 混合光电 CNN 更高效, 需要的计算资源更少。

#### 2.1.2 衍射光学神经形态计算

衍射光学神经形态计算的基本原理是用衍射层调



控输入光场的相位和幅度,一个衍射板就是一个卷积核,因而相比傅里叶光学计算,其体积将大幅下降。

图 3 是美国加州大学洛杉矶分校提出的一种光子衍射深度学习计算系统,由多层衍射表面构成物理层,通过光学衍射连接到后续的层,实现了正向传播过程,通过协同这些衍射表面可以做到以光子形式进行神经网络的运算功能。该衍射神经网络训练学习部分在电子计算机上完成,运用 3D 打印技术把数值结果制备成 8 cm×8 cm 的衍射板,然后再搭建光学系统,在光子神经网络中进行推理和预测,结果在 10000 幅

MNIST 手写数字测试图像中,获得 91.75% 的正确率<sup>[8]</sup>。2017 年,西班牙巴利阿里大学演示了一个多达 2025 个衍射耦合光子节点的网络,形成了一个大规模的递归神经网络。该网络使用了全并行的方案,并且无源权值使能量利用率和带宽最大化,最终输出结果能够有效地收敛,并且取得了很好的效果<sup>[9]</sup>。2021 年,美国犹他大学提出一种软硬件协同设计的方法,解决了部署不同 D2NN 算法需要重构和复制物理分光系统的问题,能够在 D2NN 算法中实现多任务学习,自动识别正在实施部署的任务。结果证明,其在多功能性和

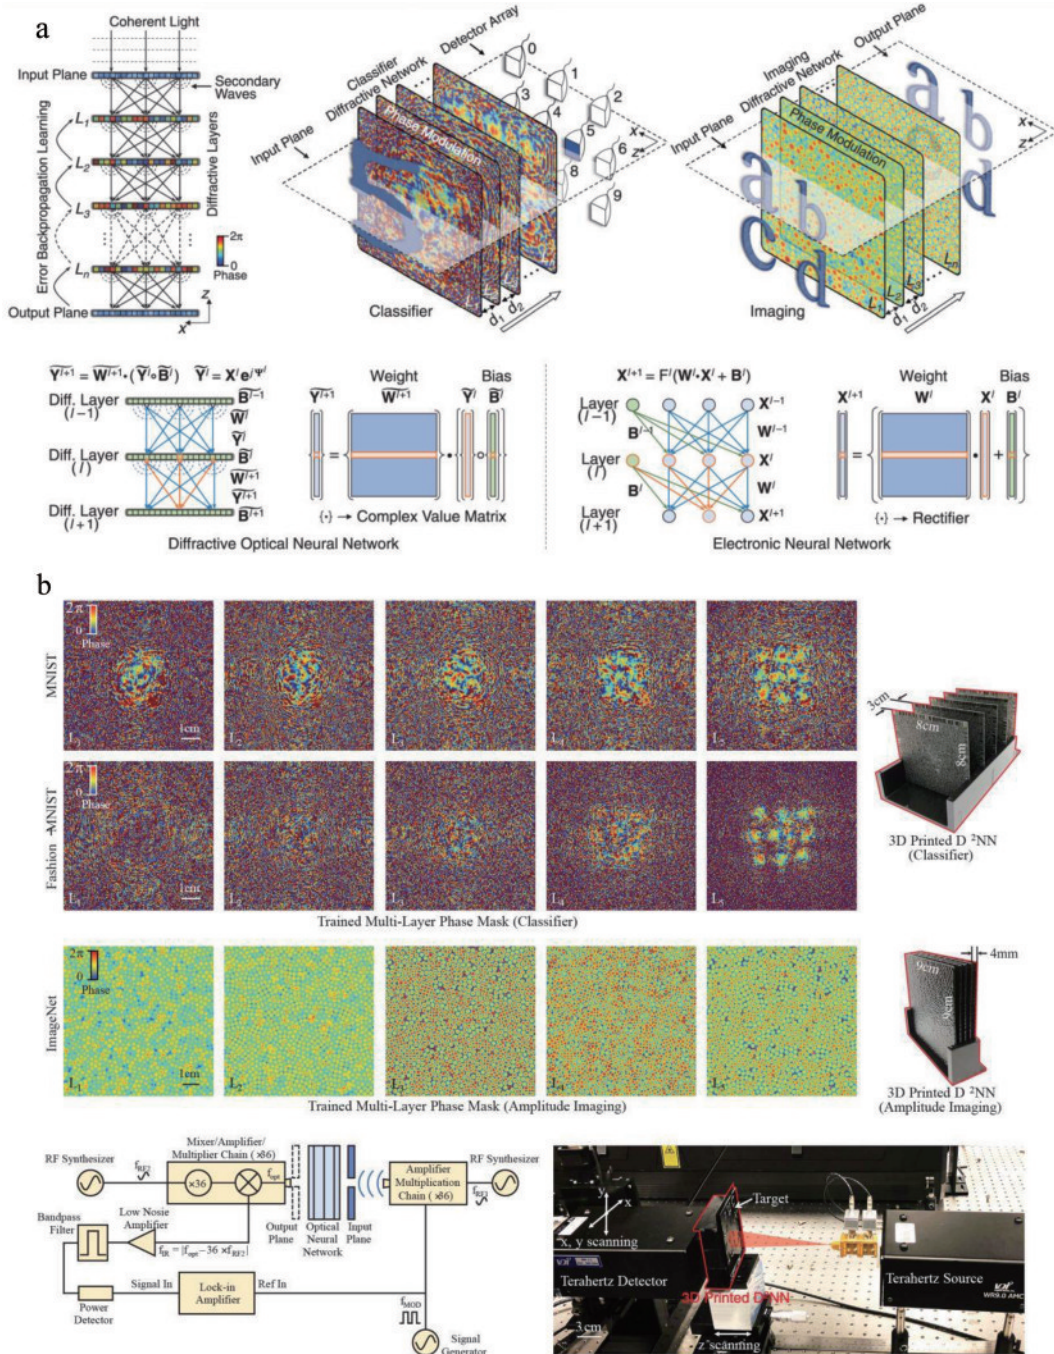


图 3 光子衍射深度学习计算系统<sup>[8]</sup>。(a) 光子衍射深度学习计算系统的基本原理;(b) 3D 打印 D2NN 网络测试  
Fig. 3 Photonic diffraction deep learning computing system<sup>[8]</sup>. (a) Basic principle of photonic diffraction deep learning computing system; (b) 3D printing D2NN network test

硬件性能方面有了显著的提升<sup>[10]</sup>。

与傅里叶光学方法相比,衍射光学方法不仅能够实现卷积神经网络,还能够实现递归神经网络、增强神经网络和储层计算等多种类型全光神经形态计算<sup>[11-21]</sup>,同时能够进行神经网络训练,因此系统功能很强大,只是空间尺寸大、可重构性差和集成性差的挑战依然严峻。

## 2.2 集成光学

### 2.2.1 损耗调制光子神经形态计算

如图 4(a)所示,损耗调制方法通常采用具有波长

选择功能的微环谐振器阵列来实现,通过每个微环谐振器上的电或热调制波导损耗对网络进行配置,输入信号使用不同波长的光表示,通过微环谐振器对波长的选择特性实现逐元素乘加计算<sup>[22-24]</sup>。

2017年,美国普林斯顿大学提出世界上首个基于损耗调制的光子神经网络,如图 4(b)所示,这里的连接是通过微环权重库和首次被用作光子神经元的电光调制器配合而成。在此基础上编程了一个 49 节点的硅光子神经网络,并且在一个实验性的差分系统仿真任务中的表现是传统方法的 1960 倍以上<sup>[25]</sup>。

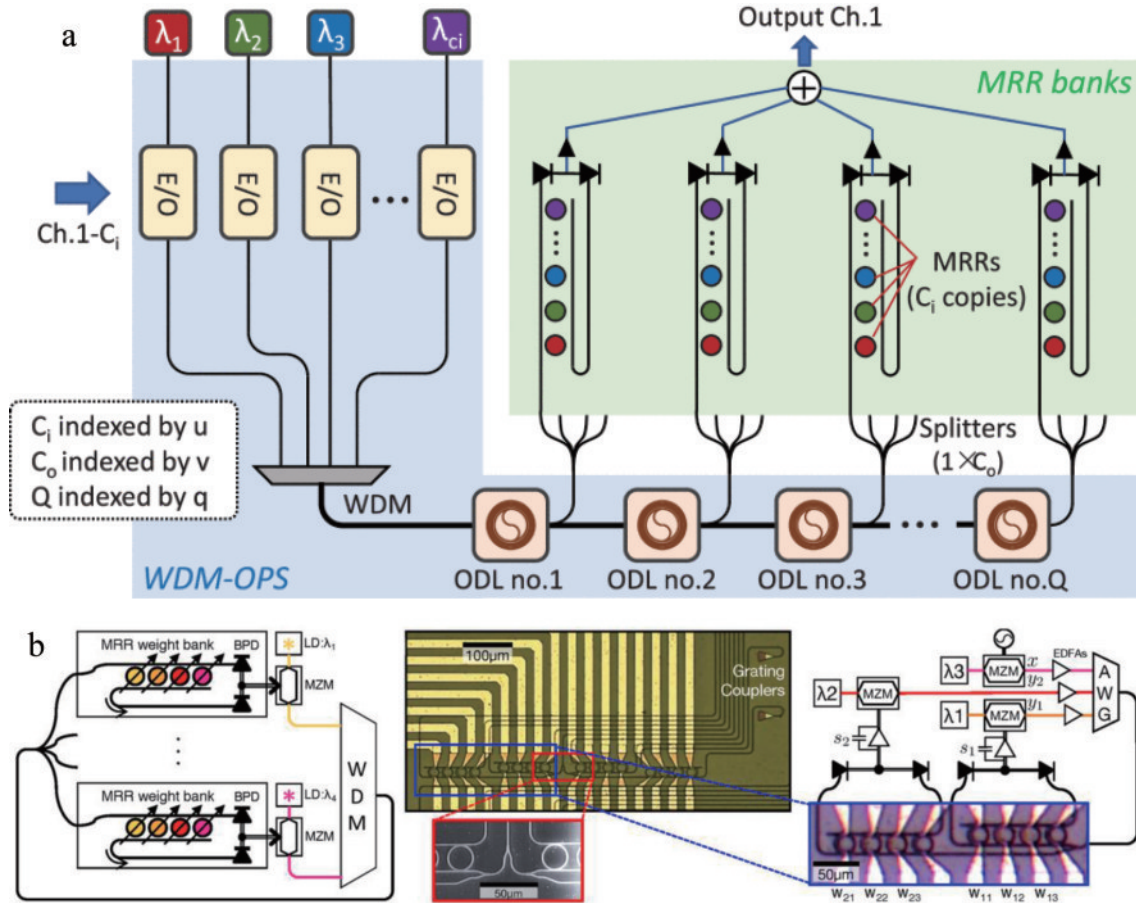


图 4 美国普林斯顿大学提出首个光子神经网络,数据输入采用基于波分复用(WDM)的光补丁方案,并采用微环组进行大规模加权与求和<sup>[22-25]</sup>

Fig. 4 Princeton University of USA proposed the first photonic neural network, using wavelength division multiplexing (WDM) based optical patch scheme to input data, and using microloop groups for large-scale weighting and summation<sup>[22-25]</sup>

损耗调制方法能够轻易实现可配置的光子神经形态计算,且输入不需要相干光,更适用于在环境照明条件下进行快速处理,但是器件本身是易失的,每次计算前网络需要重新配置,会带来额外的配置时间和功耗开销。

### 2.2.2 相位调制光子神经形态计算

相位调制方法通常采用马赫-曾德尔干涉仪(MZI)阵列实现,其基本原理是通过利用干涉仪的电或热调制相位功能对网络进行配置,利用分束器将输入相干光分配给网络的不同通路完成乘加计算,最后输出矩阵-向量的乘加结果。

2017年,美国麻省理工学院设计了一个包含 56 个 MZI 的可编程纳米光子处理器(图 5),可以零能耗地执行矩阵乘加计算,并且在元音识别中达到了 77% 的准确率<sup>[26]</sup>。2021 年底,曦智科技公司发布了第二款光子计算处理器 PACE(光子计算引擎)——单个光子芯片中集成超过 10000 个光子器件,系统时钟达到了 1 GHz,运行单一计算问题的速度可达目前高端通用处理器(GPU)的数百倍。

相位调制方法能够更容易实现并行的可配置乘加运算,且硅光 FAB 厂很容易大规模制造这类芯片,是



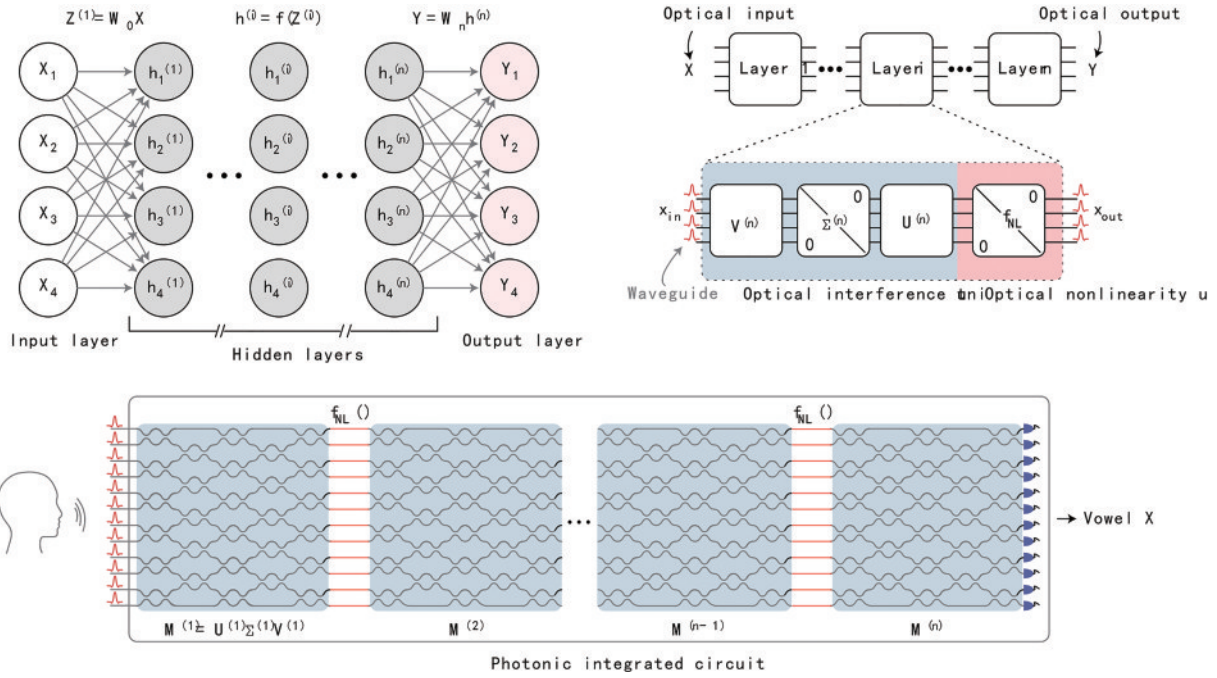


图 5 可编程纳米光子处理器<sup>[26]</sup>  
Fig. 5 Programmable nanophotonic processor<sup>[26]</sup>

一种很有潜力的光子神经形态计算芯片实现方式。目前还存在的难点问题是,这种方法计算时需要使用相干光输入,导致输入光的相位需要严格控制,且每个器件都是易失的,因而每次工作前都需要进行器件配置,因此,随着阵列规模的增加,损耗、噪声和缺陷会对结果产生明显的影响。

总的来看,空间光学的核心器件是透镜等光学元件,优点是实现简单,缺点是尺寸大且不可配置。集成光学的核心器件是微环谐振器和 MZI 等光波导器件,其解决了尺寸和可配置性的问题,但由于器件易失,网络每次工作均需要重新配置,这一部分又额外引入了能耗和不确定性。而神经形态计算中的权重调整完成后,大部分时间是不需要更改的,因而亟须发展非易失、可配置的光子神经形态计算技术。

### 3 相变光子神经形态计算

对于图像识别等简单推理应用,器件的非易失性是一种理想的性能要求。非易失光子神经形态计算采用的非易失性材料,需要满足状态多值可控、状态可长时间保持、易于光波导集成、兼容金属氧化物半导体 (CMOS) 工艺、透过带宽大、损耗低等要求。

#### 3.1 硫系化合物相变材料

硫系化合物相变材料 (PCM) 是指至少含有一种硫系元素 (S、Se、Te) 的化合物,受到外部电、光、热等激励作用时,其晶格结构能够在非晶态 (完全无序) 和晶态 (完全有序) 两个状态之间切换,表现出明显的折射率、电阻率等外部特性差异。当晶态的相变材料受到一个短而高的脉冲激励时,材料的内部结构被高能

量的脉冲打乱并且在迅速降温的过程中转化为非晶态。当非晶态的相变材料受到一个长而低的脉冲激励时,材料被融化,在缓慢降温的过程中晶格有序排列形成晶态,如图 6 所示。以  $\text{Ge}_2\text{Sb}_2\text{Te}_5$  (GST) 材料为例,当它处于非晶态时,晶格结构处于完全无序状态,光折射率、消光系数、电导率都比较低。当处于晶态时,晶格结构处于完全有序状态,光折射率、消光系数、电导率都比较高。利用这两种状态间的差异,就可以设计实现存储和计算应用。

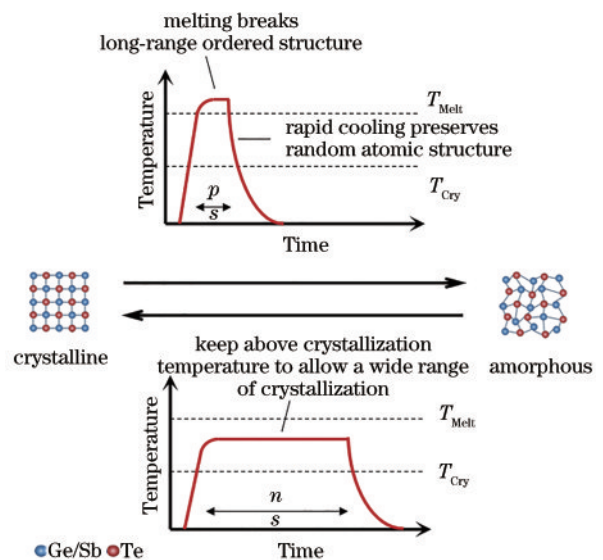


图 6 PCM 相变条件及其晶格结构  
Fig. 6 Phase transition conditions and lattice structure of PCM

硫系化合物相变材料在光学领域已经有很成熟的应用,例如光盘存储利用了相变材料状态间光学常数

的差异<sup>[27]</sup>。除了存储,硫系化合物相变材料在计算方面也有广泛的应用前景,其原理是利用相变材料光透过率/相位延迟模拟突触权值,计算光输入时经过相变材料完成乘法,波导耦合后完成加法运算,继而实现神经网络乘加运算。图 7(a)表示的是标量乘法,在输入端输入低能量的光脉冲  $b$ ,其沿波导传输并透过相变材料,与相变材料的透过率  $a$  实现乘法,在输出端测量

光强即可得到乘法结果。图 7(b)表示用于实现  $1 \times 2$  矩阵和  $2 \times 1$  矢量相乘的原理。计算时,将表示任意两个数字(例如  $P_1$  和  $P_2$ )的输入脉冲同时对同时发送到左右光栅耦合器,再透过各自的锗碲砷合金(GST)材料。输出脉冲由材料透过率加权,因此携带每个单独乘法的信息(即  $P_1 \times G_{11}$  和  $P_2 \times G_{12}$ ),从而完成乘加运算<sup>[28]</sup>。

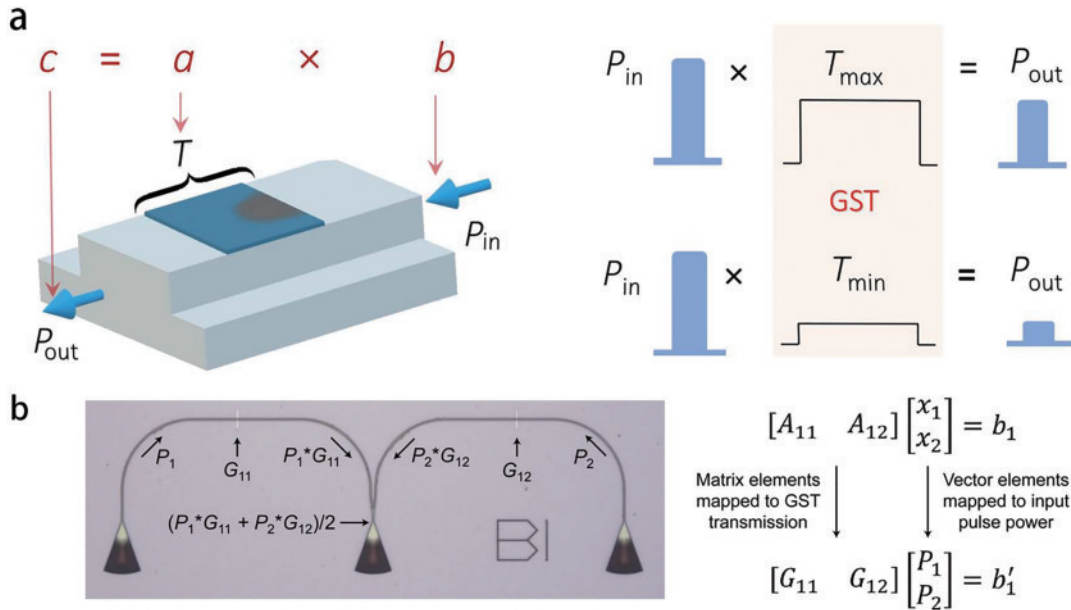


图 7 神经网络乘加运算原理<sup>[28]</sup>。(a) 标量乘法原理;(b)  $1 \times 2$  矩阵和  $2 \times 1$  矢量相乘原理

Fig. 7 Principle of multiplication and addition in neural networks<sup>[28]</sup>. (a) Principle of scalar multiplication; (b) principle of  $1 \times 2$  matrix and  $2 \times 1$  vector multiplication

### 3.2 相变光子神经形态计算原理

相变光子神经形态计算的具体实现路径有损耗调制和相位调制两种。损耗调制主要是利用相变材料的消光系数的差异,当输入光通过相变材料时,不同晶态相变材料的消光系数影响输出光的功率,达到控制状态的目的。相位调制利用相变材料的折射率差异,使用 MZI 结构对输入光的相位进行调制,即可实现输出端的光功率调节。

1) 损耗调制。基于 GST 等高消光系数对比度的材料,构建波导与相变材料的堆叠结构,通过高光强的调制光或电激励改变材料消光系数后实现对计算光强的损耗调制运算。主要调制方式包括电调、光调、光电混合调制三种方式。电调是通过电极施加电脉冲激励引发相变材料改变,因此在器件设计的时候要充分考虑到波导、电极、相变材料三者的相互影响,同时还需要考虑到电极的聚热效应,引起足够的热量促使其发生相变。光调是集成光波导与相变材料,通过耦合外部光源进行材料的状态调制,因此在器件设计的时候要充分考虑到耦合效率问题。光电混合调制是结合了两者优势的调制方式,同一个器件既能够电调制,也能够光调制,便于进行光电集成,这样可以在电和光域中

无缝工作,而不需要重复的电光转换。

2) 相位调制。基于  $Sb_2S_3$  等高折射率对比度、低损耗的材料,利用相变材料状态间的折射率差异,构建波导与相变材料的相位调制结构,如 MZI 结构,通过电/光激励改变材料折射率,实现对计算光的相位调制。在计算时实现对其中一路输入光场的相位调制,两路光相干后实现乘加运算。主要有电调、光调两种方式。其中,电调与损耗调制一样。光调目前采用的是空间光调制的方法,其采用高吸收波段的光对材料进行照射从而实现状态改变。

基于相变材料的损耗调制和相位调制两种技术路径近年来都取得了快速发展,其中损耗调制方式发展相对较快,从 2017 年到 2020 年已由单个突触器件模拟发展到了小规模阵列,具备了初步处理能力,但仍存在器件损耗和传输损耗大、芯片集成规模较小、计算能效较低等关键问题。基于相变材料的相位调制神经形态计算技术虽然刚起步,且器件尺寸较大,但容易与 MZI、微环等波导器件结合,传输损耗小,具有计算能效优势。

### 3.3 相变光子神经形态计算研究现状

#### 3.3.1 材料选型

相变材料的选择要充分考虑折射率、消光系数、

调制能耗、调制速度、保持时间等特性。相变材料的折射率和消光系数决定了调制的状态数,折射率差异大或消光系数差异大的相变材料能够为器件的调制提供更大的空间。表 1 将几种材料的具体参数进行了对比。

损耗调制型相变光子神经形态计算主要利用相变材料不同状态的消光系数差异,目前已经利用 GST 和锗硒锑碲合金(GSST)两种材料进行验证。图 8(a)、8(b)中两幅图分别展示了晶态和非晶态两种材料的消

光系数和折射率。其中,融化温度决定非晶化的能耗与速度,两种材料均为 600 °C 左右。结晶温度决定非晶态的稳定性、晶化能耗和速度,三者之间需要折中考虑,GSST 的结晶温度相对高一些。晶态与非晶态之间的差异窗口决定了可调制的状态数,GST 的消光系数差异大概为 0.9,GSST 的消光系数差异大概为 0.4,因此,GST 有望比 GSST 实现更多的状态。同时消光系数决定了系统损耗、阵列规模和计算能耗,因此消光系数不能太大。

表 1 常见相变材料参数<sup>[29-30]</sup>  
Table 1 Common phase-change material parameters<sup>[29-30]</sup>

	Ge <sub>2</sub> Sb <sub>2</sub> Te <sub>5</sub>	Ge <sub>2</sub> Sb <sub>2</sub> Se <sub>4</sub> Te <sub>1</sub>	Sb <sub>2</sub> Se <sub>3</sub>	Sb <sub>2</sub> S <sub>3</sub>
Melting temperature /°C	600	630	620	550
Crystallization temperature /°C	160	250	200	270
Amorphous refractive index	3.9@1550 nm	3.4@1550 nm	3.285@1550 nm	2.712@1550 nm
Crystalline refractive index	6.1@1550 nm	5.1@1550 nm	4.050@1550 nm	3.308@1550 nm
Amorphous extinction coefficient	0.0055@1550 nm	0.0001@1550 nm	<0.0001@1550 nm	<0.0001@1550 nm
Crystalline extinction coefficient	0.9040@1550 nm	0.4250@1550 nm	<0.0001@1550 nm	<0.0001@1550 nm

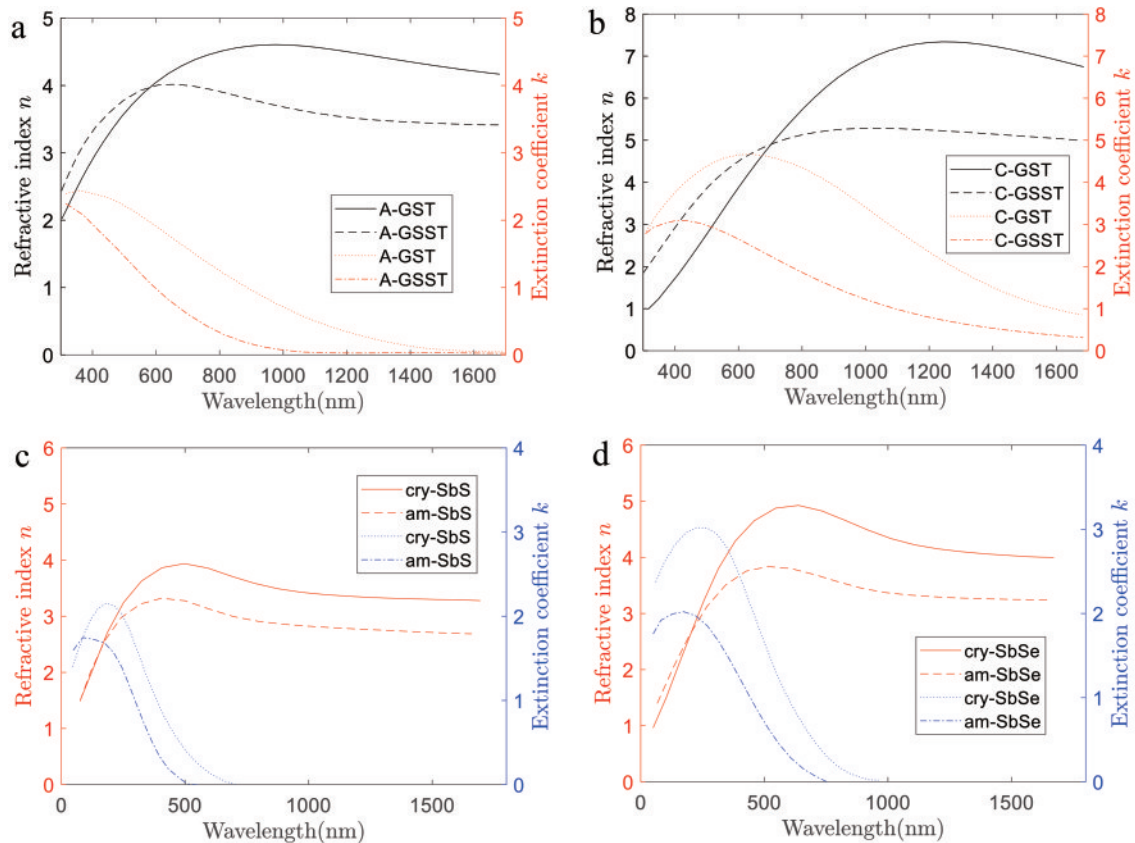


图 8 相变材料的折射率和消光系数<sup>[29-30]</sup>。(a)、(b) GST 和 GSST 在晶态和非晶态下的折射率和消光系数；(c)、(d) SbS 和 SbSe 在晶态和非晶态下的折射率和消光系数

Fig. 8 Refractive indices and extinction coefficients of phase-change materials<sup>[29-30]</sup>. (a), (b) Refractive indices and extinction coefficients of GST and GSST in crystalline and amorphous states; (c), (d) refractive indices and extinction coefficients of SbS and SbSe in crystalline and amorphous states

相位调制型相变光子神经形态计算主要利用折射率差异,目前的研究重点是 SbS 和 SbSe 两种材料,这两种材料晶态与非晶态的折射率差异达到 0.5 以上,

并且消光系数极低。相位调制材料的折射率差异决定了可调制的状态数,SbS 和 SbSe 的折射率差异分别大概为 0.6 和 0.8,并且折射率的大小决定了器件的尺



寸,两者折射率均比 SiN 高,因此器件尺寸可以相对缩小。消光系数低意味着器件的损耗低,能够实现更大规模阵列的集成。

### 3.3.2 器件设计

相变光突触器件设计主要关注波导材料、波导结构、相变材料结构等方面。其中,损耗调制注重相变材料与波导的耦合方式,提高调制光利用效率和状态精细度,进一步降低调制能耗。相位调制注重加热电极材料、相变材料与波导和加热电极间的尺寸匹配关系,电极尺寸太小不易聚热,因而调制难度增加;电极太靠近波导容易对器件造成影响等。

损耗调制的器件结构主要分为三类。第一类是微环型单元器件结构,在微环谐振器上覆盖一层相变材料,通过改变相变材料的状态来控制微环谐振器对计算光的损耗,进而达到控制输出光功率来完成计算<sup>[31-37]</sup>。2012年,英国牛津大学提出一种基于相变材料的光存储器件[图 9(a)],其具有亚纳秒的读写能力,在 SiN 环形谐振器中一段覆盖 GST 薄膜,调谐光通过控制端口耦合到微环形谐振器中对 GST 进行调制<sup>[38]</sup>。该器件消光比达到 10 dB,通过改变控制端口和微环谐

振器的耦合距离,以达到对 GST 晶化程度的控制,可实现多能级的调制。2018年,美国华盛顿大学展示了 GST 与 Si 微环的非易失光子开关[图 9(b)],其采用了空间光调制方式改变脉冲能量和脉冲数完成相变材料调制,两个状态的消光比达到 33 dB<sup>[39]</sup>。以上器件均为单输入输出的损耗调制器件。2019年,美国华盛顿大学又使用 GST 与 SiN 微环谐振器设计了 1×2 平行光子开关[图 9(c)],通过将 GST 图案化和封装成亚波长结构,该器件在直通端口和分接端口中实现了低于 1 dB 的插入损耗,并且能够可靠地进行光热和电热切换<sup>[40]</sup>。2020年,浙江大学提出了一种基于 GST 辅助微环谐振器的波长选择型的 2×2 垂直微环光子开关[图 9(d)],通过仿真证明,共振波长在 ON 和 OFF 态变化很小,适用于多通道波分复用系统<sup>[41]</sup>。该器件在实现基本的光学互联开关、开发高性能的光学开关方面取得巨大进展,同时采用的微环谐振器结构具有紧凑的尺寸,可以用于实现 WDM 系统中的光学开关。但是基于微环谐振器的光学开关通常具有非常有限的工作带宽,因此必须仔细控制谐振波长。

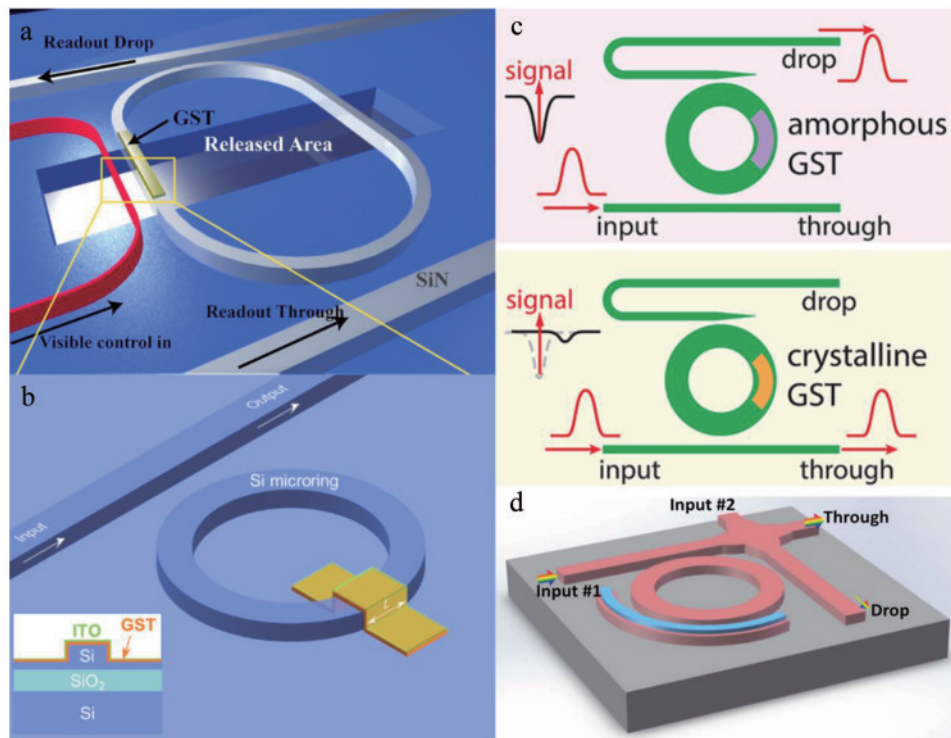


图 9 微环型单元器件结构<sup>[38-41]</sup>。(a) 控制端口将光耦合到微环谐振器上,通过光加热来影响 GST 状态;(b) 结合 GST 的硅微环集成开关;(c) 基于氧化铝封装 GST 的氮化硅开关,当 GST 为非晶态时,输入光耦合到微环中。当 GST 为晶态时,输入光与微环解耦合;(d) 基于 GST 的波长选择性光子开关

Fig. 9 Microring element device structure<sup>[38-41]</sup>. (a) Control port couples light to microring resonator and influences GST state by light heating; (b) silicon microring integrated switch with GST; (c) based on alumina encapsulated GST silicon nitride switch, when GST is amorphous, input light is coupled to microring, and when GST is crystalline, input light is decoupled from microloop; (d) wavelength selective photonic switch based on GST

损耗调制的第二类器件结构是直波导型单元器件,即在一根直波导上覆盖相变材料,其调制方式主要

是光调,可以在 Si、SiN 波导上实现<sup>[42]</sup>。2015年,印度理工学院展示了一种基于相变材料的稳健、非易失性

全光存储器[图 10(a)],通过使用光学近场效应,在单个器件中实现了 8 个级别的位存储,可以轻松地在中间状态之间切换<sup>[43]</sup>。2017 年,复旦大学通过在锥形波导上特殊设计的离散相变岛结构[图 10(b)],获得了可编程性的片上仿生光子突触,器件均匀性得到进一步优化<sup>[44]</sup>。在此基础上,阐明了一种基于神经元前后信号之间的时间延迟来调节突触权重的全光学方法,该方法可以模拟生物系统中的 STDP 规则。2019 年,美国华盛顿大学利用非对称定向耦合器实现了  $1 \times 2$  和

$2 \times 2$  的开关[图 10(c)]<sup>[45]</sup>。该器件的优势为紧凑(耦合长度为  $30 \mu\text{m}$ )、低功耗(1 dB)、宽频带(在串扰小于  $-10 \text{ dB}$  时超过  $30 \text{ nm}$ )。然而该器件是通过快速热退火(RTA)将 GST 从非晶态转换为晶态,不能反向操作 GST 的状态。2020 年,国防科技大学<sup>[46]</sup>系统地评估和比较了相变光子学在硅平台和氮化硅平台上的计算性能[10(d)],成功地演示了在硅光子波导上使用相变光学存储器的单脉冲调制,并演示了高效的编程、存储器保持和读出超过 50 个比特。实验结果表明,虽然硅

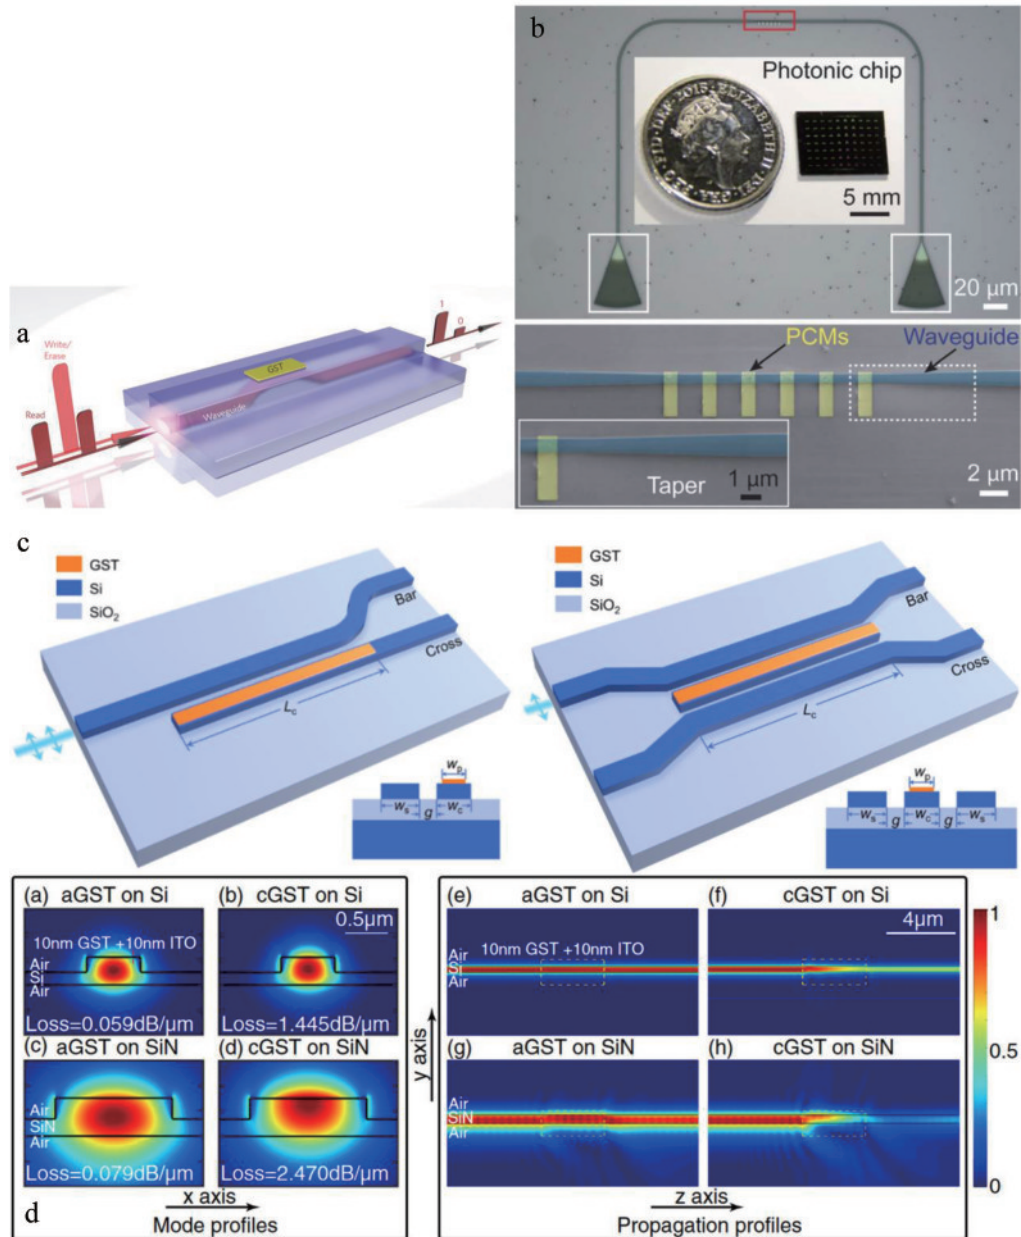


图 10 直波导型单元器件结构<sup>[43-46]</sup>。(a) 顶部 GST 的状态存储信息。内存的读取和写入可以通过光脉冲来执行。数据的读出通过 GST 的两种晶态对光的吸收差异读取光波导的传出量；(b) 片上光子突触；(c) GST 在 Si 和 SiN 上的本征模分布和传播分布；(d) 基于 GST-ON-SOI 实现的  $1 \times 2$  和  $2 \times 2$  开关

Fig. 10 Straight waveguide element device structure<sup>[43-46]</sup>. (a) State storage information of top GST. Memory reads and writes can be performed by light pulses. Readout of data reads efferent amount of optical waveguide by difference of light absorption between two crystal states of GST; (b) on-chip photon synapses; (c) eigenmode distribution and propagation distribution of GST on Si and SiN; (d)  $1 \times 2$  and  $2 \times 2$  switches based on GST-ON-SOI implementation



平台在集成潜力、调制速度和器件占用空间方面优于氮化硅,但它们需要在能效方面进行权衡。

损耗调制的第三类结构是混合型单元器件结构,器件结构中既包含波导,也包含电极,因此可以使用光调、电调两种方式。2019年,英国牛津大学结合等离子体、光子学和电子学实现了一个集成的相变存储单元,可以同时实现 GST 电子和光学性能的读出,实现相变材料存储单元的光电混合操作。两个金电极之间形成等离子体纳米阱,用 75 nm 的 GST 薄膜连接纳米间隙,使用部分蚀刻的氮化硅脊波导将光信号传输到等离子体存储单元,通过一个锥形的几何形状进行耦

合,通过发射光脉冲或电脉冲可逆地将 GST 在晶态和非晶态之间转换<sup>[47]</sup>。2019年,上海交通大学基于硅多模干涉仪(MMI)结构,实现了电脉冲对相变材料进行调制,从而实现光开关,擦除和写入可以停留在任何中间水平,并且可以重复实现<sup>[48]</sup>。2020年,美国华盛顿大学利用硅 PIN 二极管加热器,演示了一种可扩展的非易失性电可重构光子开关[图 11(b)],并获得了具有低驱动电压、接近于零的额外损耗和具有高持久性的优点<sup>[49]</sup>。混合型单元器件克服了单独使用某种热控方式带来的插入损耗大、驱动电压高以及循环次数少等缺点。

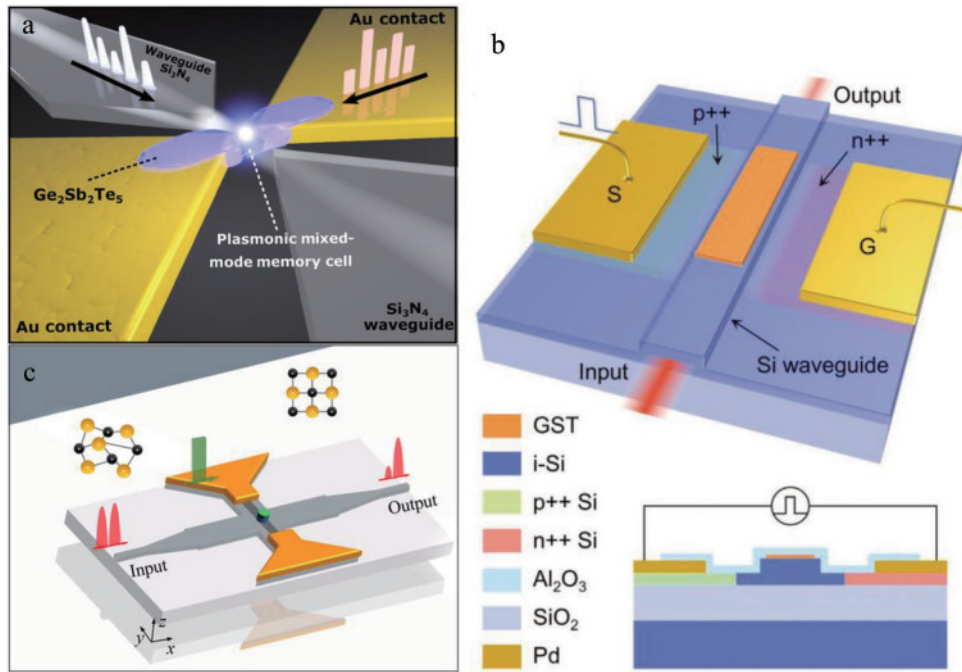


图 11 混合型单元器件结构<sup>[47-49]</sup>。(a) 入射光通过波导传递到相变材料,金触点作为电极对相变材料进行调制;(b) 基于硅 PIN 二极管加热器的非易失可重构光子开关;(c) 基于 GST 的可擦除光学记忆开关  
Fig. 11 Hybrid element device structure<sup>[47-49]</sup>. (a) Incident light is transmitted through waveguide to phase-change material, and gold contacts act as electrodes to modulate phase-change material; (b) non-volatile reconfigurable photonic switch based on silicon PIN diode heater; (c) erasable optical memory switch based on GST

相位调制主要采用的是 MZI 结构,在 MZI 的一条路径上覆盖相变材料,调制方式一般为电调。2021年,上海交通大学展示了由低损耗相变材料 SbS 和 MZI 构成的  $2 \times 2$  光开关[图 12(a)],基于两个 MMI 构成的非对称 MZI(UMZI)结构,将 SbS 沉积在 UMZI 的一条臂上,在 SbS 发生相变时实现  $\pi$  的相移。实验结果表明,器件的插入损耗(IL)低于 3 dB,在 10 nm 波长范围内,串扰(CT)低于 -10 dB<sup>[50]</sup>。同年,美国南安普敦大学利用沉积在 SOI 脊波导上的 SbSe,实现了超过  $10\pi$  的光学相位控制<sup>[51]</sup>,将一层 SbSe 贴片沉积到 MZI 的一条臂上,然后使用 638 nm 波长的激光器实现相变材料中单个像素的切换[图 12(b)]。

### 3.3.3 阵列实现与应用验证

阵列实现与应用验证主要考虑器件互联方式、损

耗控制、阵列器件调控方法等问题。其中损耗调制器件阵列已经开始从单列向交叉阵列拓展,已具备小规模处理能力,常见的阵列实现有微环互联阵列和交叉互联阵列<sup>[52-55]</sup>。相位调制器件目前仅有单元器件的原理验证,尚未实现大规模阵列尝试。

2019年,英国牛津大学提出了微环互联阵列结构,相变材料光透过率比拟突触权值,基于微环阵列实现波长选择和 WDM,计算光输入时经过相变材料完成乘法,微环复用后实现加法。基于该架构,设计制造了 4 个  $1 \times 15$  的小规模阵列,每个阵列存在 4 个输入端口,分别用于信号光输入、权值调整、读取输入和读取输出[图 13(a)]。该阵列结构网络能够区分 4 个 15 像素图像,实现了 A、B、C、D 4 个字母的分类,识别结果如图 13(b)所示。然而,在该架构的全光学实现中,所

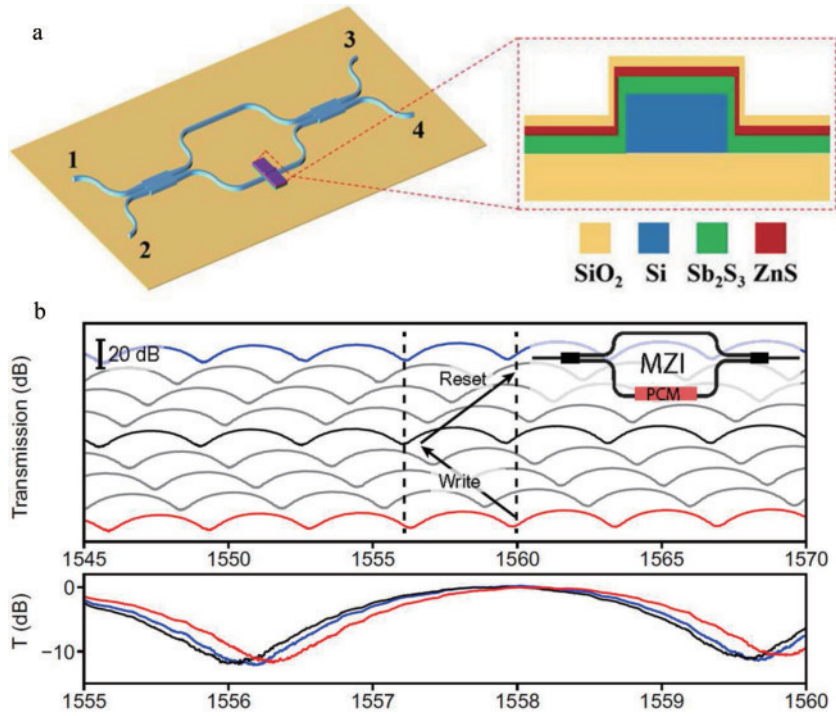


图 12 MZI 结构<sup>[50-51]</sup>。(a) Si-SbS 集成光开关原理图；(b) 激光退火过程中 MZI 相位状态变化  
Fig. 12 MZI structure<sup>[50-51]</sup>. (a) Schematic diagram of Si-SbS integrated optical switch; (b) phase state change of MZI during laser annealing

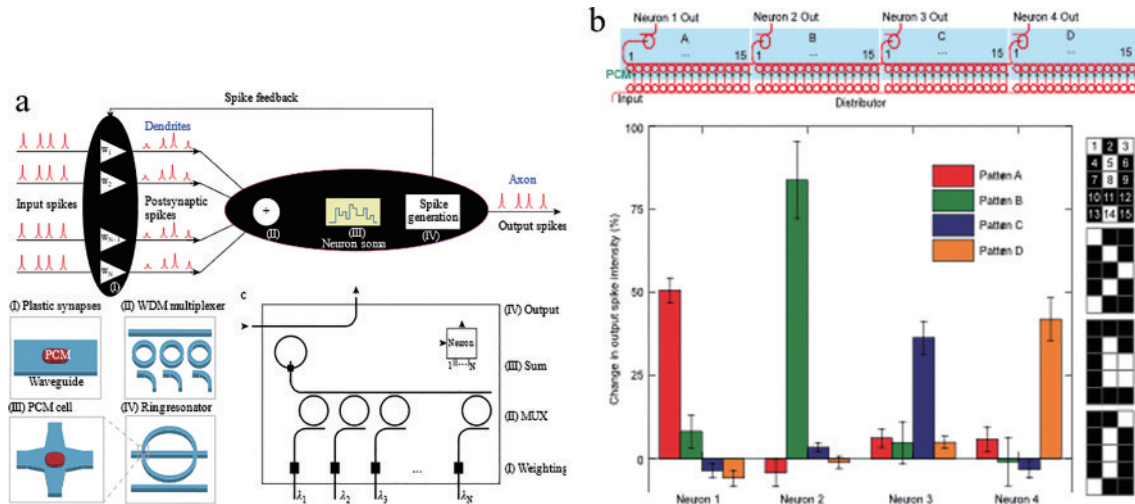


图 13 微环互联阵列,即一种具有自学能力的全光尖峰神经突触网络<sup>[56]</sup>。(a) 微环互联阵列由 4 个输入神经元和 1 个输出神经元组成；(b) 神经网络成功识别出 4 种模式

Fig. 13 Interconnected array of microloops which is an all-optical spike neural synaptic network with self-learning capabilities<sup>[56]</sup>. (a) Microloop interconnected array consists of four input neurons and one output neuron; (b) neural network successfully identifies four patterns

有神经元都需要在每次脉冲后重新结晶,因此,操作周期的数量最终会受到 PCM 单元的耐用性的限制<sup>[56]</sup>。

2021 年,英国牛津大学又提出了最新型的交叉互联阵列,还是相变材料光透过率比拟突触权值,但是基于波导交叉器件实现器件间行列互联,通过微环光频梳实现多波长并行输入,经过相变材料完成乘法,经过定向耦合器完成列上信号相加<sup>[57]</sup>。在以上架构基础上实现了 16×16 的实际交叉阵列,搭建了单层感知机网络,

阵列器件与验证系统如图 14 所示。该系统可一次同时实现 64 个乘加运算,通过实际阵列进行串行和并行的卷积运算处理,实现多类图像的边缘强化。图 14(a)展示的是对 128 pixel×128 pixel 的手写数字或汽车图像进行卷积计算,其所采用的卷积核尺寸为 3×3 的卷积核,4 个卷积核对应于 9×4 阵列,光子张量核的结构如图 14(b)所示,计算结果如图 14(c)所示,准确展示了清晰可见的边缘特征,证明了光学卷积操作的有效性。



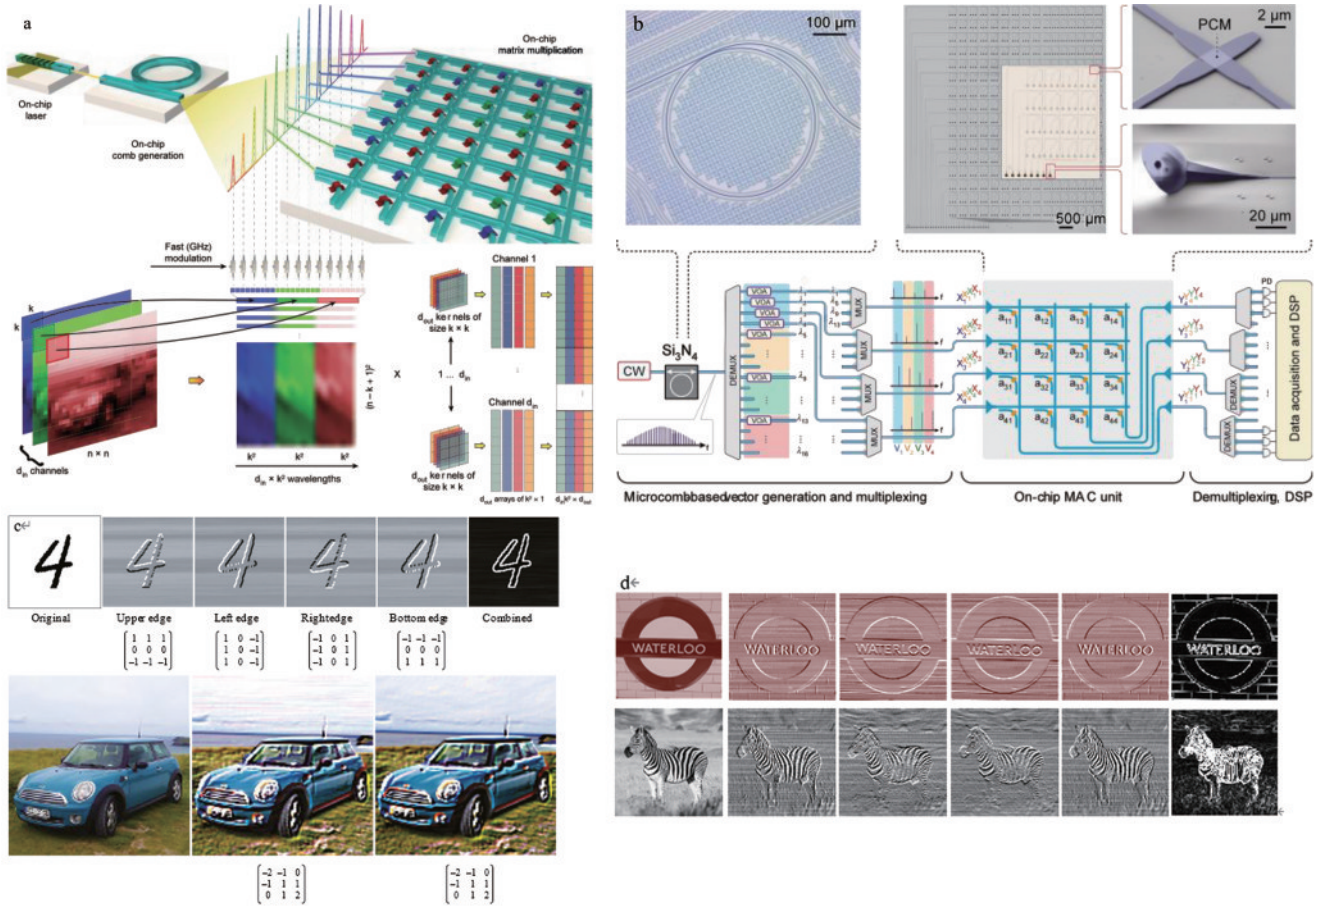


图 14 交叉互联阵列<sup>[57]</sup>。(a) 集成光子结构卷积计算阵列结构；(b) 用于卷积运算的光子张量核的结构示意图；(c) 128 pixel×128 pixel 图像的处理结果；(d) 采用并行图像处理方法的处理结果

Fig. 14 Cross interconnected array<sup>[57]</sup>. (a) Integrated photonic structure convolution computing array structure; (b) schematic diagram of structure of photon tensor kernel used for convolution operations; (c) processing results of 128 pixel×128 pixel images; (d) processing results of parallel image processing method

图 14(d)使用的是并行图像处理方法,其卷积核是  $2 \times 2$ ,因此 4 个卷积核对应于  $4 \times 4$  阵列。计算时,每个通道输入 4 路光线,每个图像卷积核同时获得新图像的 4 个像素,从而将处理时间缩短至原来的  $1/4$ ,结果再次突出了可以清楚看到的不同边缘。但是,耦合效率的限制进一步影响了阵列规模的扩大,导致阵列的计算能效优势并不能完全发挥出来。

#### 4 前景与挑战

物联网、大数据等产业智能化发展对高算力、低能耗智能计算提出迫切需求,相变光子神经形态计算是神经网络与光电子硬件的同构性创造,具有强大的技术潜力和广阔的应用前景,但是在研究过程中还存在一系列的难点和挑战。

1) 探索相变功能材料的光场作用机理与性能定向调制规律。相变材料的光场作用机理直接决定相变材料的性能,当前采用的常规相变材料转换速度慢、时间长,限制了光子相变器件运行速度的提高。因此,建立光场作用机制模型,优化设计高调制速度、高对比度、

高耐久性的新型相变材料是提高相变光子神经形态计算的重要基础。其次,开发高品质薄膜制备工艺,探索 CMOS 兼容的干法、湿法等刻蚀工艺,通过优化设计微纳结构等是实现器件材料性能提升的重要途径。

2) 高性能的相变光突触与神经元器件的设计制备。光突触器件和神经元器件性能决定光脉冲神经形态计算的速度和能耗,因此高性能光突触和神经元器件的设计、制备与调控是核心基础问题。光突触器件的折射率对比度影响器件可调控的相位状态数和权值精度,直接影响神经形态计算的计算精度,同时影响器件在计算时的输入能耗;光神经元器件的折射率对比度影响器件的消光比和触发阈值,调制速度影响计算的能耗。因此,通过材料、结构的优化设计和精确调控,实现高精度、高稳定性的光突触和神经元器件,可为相变光子神经形态计算提供关键的器件基础。

3) 大规模光突触器件阵列的片内传输损耗控制机制。光突触器件的大规模集成是应用的前提,制约集成规模的关键基础问题包括集成光路的空间尺度和传输过程的信号能量、噪声损耗等问题。理论上,突触阵

列规模越大、连接度越丰富、连接带宽越高,所对应的变换矩阵维度越大、稠密度越高、运算速度越快,所能实现的基础算力越强。但是,一方面,突触阵列所处的片上空间受限,尤其是还需要针对所有突触排布复杂的光电控制逻辑以实现变换矩阵中任意元素进行有效操控;另一方面,阵列中高速光互连所要求的信号分光、传输、复用等处理必然存在一定的物理层损伤。因此,在空间尺度、信号能量、光电抗噪、模数协同等多约束条件下,选择合适的输入输出信号表征方式,发挥时、频、空多维光互连的大带宽、低时延和低功耗特性,优化突触阵列及其控制结构,同时探索神经形态计算模型下不同稀疏度变换矩阵的等效特性,是提高光突触器件的阵列集成度并提升其利用率的有效手段。

4)高可靠性光突触网络的架构设计与调控。光脉冲神经网络处理架构包括阵列中计算输入的信号编码、神经突触的配置方式、数字架构向全光突触阵列的映射机制和网络训练方法,决定整个计算系统的处理能力。因此,需要进一步研究少态轻量化光脉冲神经网络架构,探索和优化光突触网络结构,优化光突触网络中光导入途径,提高相变材料调制光利用率,研究突触状态检测、权值校准与稳定控制方法,以提高突触阵列的可靠性。

## 参 考 文 献

- [1] Silver D, Schrittwieser J, Simonyan K, et al. Mastering the game of go without human knowledge[J]. *Nature*, 2017, 550(7676): 354-359.
- [2] Abraham I. The case for rejecting the memristor as a fundamental circuit element[J]. *Scientific Reports*, 2018, 8: 10972.
- [3] Kavehei O, Iqbal A, Kim Y S, et al. The fourth element: characteristics, modelling and electromagnetic theory of the memristor[J]. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 2010, 466(2120): 2175-2202.
- [4] Yao P, Wu H Q, Gao B, et al. Fully hardware-implemented memristor convolutional neural network[J]. *Nature*, 2020, 577(7792): 641-646.
- [5] Gao B, Zhou Y, Zhang Q T, et al. Memristor-based analogue computing for brain-inspired sound localization with *in situ* training[J]. *Nature Communications*, 2022, 13: 2026.
- [6] Liu Z W, Tang J S, Gao B, et al. Neural signal analysis with memristor arrays towards high-efficiency brain-machine interfaces[J]. *Nature Communications*, 2020, 11(1): 4234.
- [7] 彭晓钰, 杨锦清, 吴春红, 等. 基于后向传播神经网络的激光定位系统动态范围的提升[J]. *光学学报*, 2021, 41(6): 0620001.  
Peng X Y, Yang J Q, Wu C H, et al. Improvement of dynamic range of laser positioning system based on back propagation neural network[J]. *Acta Optica Sinica*, 2021, 41(6): 0620001.
- [8] Chang J L, Sitzmann V, Dun X, et al. Hybrid optical-electronic convolutional neural networks with optimized diffractive optics for image classification[J]. *Scientific Reports*, 2018, 8: 12324.
- [9] Lin X, Rivenson Y, Yardimci N T, et al. All-optical machine learning using diffractive deep neural networks [J]. *Science*, 2018, 361(6406): 1004-1008.
- [10] Bueno J, Maktoobi S, Froehly L, et al. Reinforcement learning in a large-scale photonic recurrent neural network [J]. *Optica*, 2018, 5(6): 756-760.
- [11] Li Y J, Chen R Y, Sensale-Rodriguez B, et al. Real-time multi-task diffractive deep neural networks via hardware-software co-design[J]. *Scientific Reports*, 2021, 11(1): 11013.
- [12] Lee S Y, Kim Y H, Cho S M, et al. Holographic image generation with a thin-film resonance caused by chalcogenide phase-change material[J]. *Scientific Reports*, 2017, 7: 41152.
- [13] Goi E, Chen X, Zhang Q M, et al. Nanoprinted high-neuron-density optical linear perceptrons performing near-infrared inference on a CMOS chip[J]. *Light: Science & Applications*, 2021, 10: 40.
- [14] Hejda M, Robertson J, Bueno J, et al. Neuromorphic encoding of image pixel data into rate-coded optical spike trains with a photonic VCSEL-neuron[J]. *APL Photonics*, 2021, 6(6): 060802.
- [15] Kulce O, Mengü D, Rivenson Y, et al. All-optical synthesis of an arbitrary linear transformation using diffractive surfaces[J]. *Light: Science & Applications*, 2021, 10: 196.
- [16] Fu T Z, Zang Y B, Huang H H, et al. On-chip photonic diffractive optical neural network based on a spatial domain electromagnetic propagation model[J]. *Optics Express*, 2021, 29(20): 31924-31940.
- [17] Kulce O, Mengü D, Rivenson Y, et al. All-optical information-processing capacity of diffractive surfaces[J]. *Light: Science & Applications*, 2021, 10: 25.
- [18] Zuo Y, Zhao Y J, Chen Y C, et al. Scalability of all-optical neural networks based on spatial light modulators [J]. *Physical Review Applied*, 2021, 15(5): 054034.
- [19] Zhou T K, Lin X, Wu J M, et al. Large-scale neuromorphic optoelectronic computing with a reconfigurable diffractive processing unit[J]. *Nature Photonics*, 2021, 15(5): 367-373.
- [20] Rahman M S S, Li J X, Mengü D, et al. Ensemble learning of diffractive optical networks[J]. *Light: Science & Applications*, 2021, 10(1): 14.
- [21] 翟中生, 黄缘胜, 李沁洋, 等. 基于空间光调制器的正交相位光栅衍射特性[J]. *光学学报*, 2022, 42(16): 1605002.  
Zhai Z S, Huang Y S, Li Q Y, et al. Diffraction characteristics of orthogonal phase grating based on spatial light modulator[J]. *Acta Optica Sinica*, 2022, 42(16): 1605002.
- [22] Xu S F, Wang J, Wang R, et al. High-accuracy optical convolution unit architecture for convolutional neural networks by cascaded acousto-optical modulator arrays



- [J]. *Optics Express*, 2019, 27(14): 19778-19787.
- [23] Hamerly R, Bernstein L, Sludds A, et al. Large-scale optical neural networks based on photoelectric multiplication[J]. *Physical Review X*, 2019, 9(2): 021032.
- [24] Xu S F, Wang J, Zou W W. Optical patching scheme for optical convolutional neural networks based on wavelength-division multiplexing and optical delay lines[J]. *Optics Letters*, 2020, 45(13): 3689-3692.
- [25] Tait A N, de Lima T F, Zhou E, et al. Neuromorphic photonic networks using silicon photonic weight banks[J]. *Scientific Reports*, 2017, 7: 7430.
- [26] Shen Y C, Harris N C, Skirlo S, et al. Deep learning with coherent nanophotonic circuits[J]. *Nature Photonics*, 2017, 11(7): 441-446.
- [27] Li X, Youngblood N, Rios C, et al. Fast and reliable storage using a 5 bit, nonvolatile photonic memory cell [J]. *Optica*, 2019, 6(1): 1-6.
- [28] Rios C, Youngblood N, Cheng Z G, et al. In-memory computing on a photonic platform[J]. *Science Advances*, 2019, 5(2): eaau5759.
- [29] Zhang Q H, Zhang Y F, Li J Y, et al. Broadband nonvolatile photonic switching based on optical phase change materials: beyond the classical figure-of-merit[J]. *Optics Letters*, 2017, 43(1): 94-97.
- [30] Delaney M, Zeimpekis I, Lawson D, et al. A new family of ultralow loss reversible phase-change materials for photonic integrated circuits:  $\text{Sb}_2\text{S}_3$  and  $\text{Sb}_2\text{Se}_3$ [J]. *Advanced Functional Materials*, 2020, 30(36): 2002447.
- [31] Zheng J J, Khanolkar A, Xu P P, et al. Non-volatile all-optical quasi-continuous switching in GST-on-silicon microring resonators[C]//Conference on Lasers and Electro-Optics, May 13-18, 2018, San Jose, California. Washington, D.C.: Optica Publishing Group, 2018: SF3A.6.
- [32] Zhang H Y, Zhou L J, Xu J, et al. Silicon microring resonators tuned with GST phase change material[C]//2018 Asia Communications and Photonics Conference (ACP), October 26-29, 2018, Hangzhou, China. New York: IEEE Press, 2018.
- [33] Hu H, Zhang H Y, Zhou L J, et al. Non-volatile optical memory based on a slot nanobeam resonator filled with GST material[C]//2018 Asia Communications and Photonics Conference (ACP), October 26-29, 2018, Hangzhou, China. New York: IEEE Press, 2018.
- [34] Zhao P, Guo P X, Liu Z Y, et al. Photonic digital-to-analog converter based on microring resonator and photonic-nonvolatile-memory[C]//Asia Communications and Photonics Conference 2021, October 24-27, 2021, Shanghai, China. Washington, D.C.: Optica Publishing Group, 2021: W2D.3.
- [35] Xu P P, Zheng J J, Doylend J, et al. Non-volatile integrated-silicon-photonic switches using phase-change materials[C]//2019 Asia Communications and Photonics Conference (ACP), November 2-5, 2019, Chengdu, China. New York: IEEE Press, 2019.
- [36] Rios C, Hosseini P, Wright C D, et al. On-chip photonic memory elements employing phase-change materials[J]. *Advanced Materials*, 2014, 26(9): 1372-1377.
- [37] 陈卓, 李天成, 孙德贵, 等. SOI波导反射模式的古斯-汉欣空间位移效应及其数字式热光开关[J]. *光子学报*, 2021(4): 0423001.
- Chen Z, Li T C, Sun D G, et al. Digital thermo-optic switch of SOI waveguide based on Goos-Hanchen spatial shift of reflected mode[J]. *Acta Photonica Sinica*, 2021, 50(4): 0423001.
- [38] Pernice W H P, Bhaskaran H. Photonic non-volatile memories using phase change materials[J]. *Applied Physics Letters*, 2012, 101(17): 171101.
- [39] Zheng J J, Khanolkar A, Xu P P, et al. GST-on-silicon hybrid nanophotonic integrated circuits: a non-volatile quasi-continuously reprogrammable platform[J]. *Optical Materials Express*, 2018, 8(6): 1551-1561.
- [40] Wu C M, Yu H S, Li H, et al. Low-loss integrated photonic switch using sub-wavelength patterned phase change material[J]. *ACS Photonics*, 2018, 6(1): 87-92.
- [41] Zhang C P, Zhang M, Xie Y W, et al. Wavelength-selective  $2 \times 2$  optical switch based on a  $\text{Ge}_2\text{Sb}_2\text{Te}_5$ -assisted microring[J]. *Photonics Research*, 2020, 8(7): 1171-1176.
- [42] Wu D, Yang X, Zhang H Y, et al. Resonant-enhanced optical switch based on non-volatile phase change material GST[C]//Optoelectronics and Communications Conference 2021, July 3-7, 2021, Hong Kong, China. Washington, D. C.: Optica Publishing Group, 2021: T3E.5.
- [43] Rios C, Stegmaier M, Hosseini P, et al. Integrated all-photonic non-volatile multi-level memory[J]. *Nature Photonics*, 2015, 9(11): 725-732.
- [44] Cheng Z G, Rios C, Pernice W H P, et al. On-chip photonic synapse[J]. *Science Advances*, 2017, 3(9): e1700160.
- [45] Xu P P, Zheng J J, Doylend J K, et al. Low-loss and broadband nonvolatile phase-change directional coupler switches[J]. *ACS Photonics*, 2019, 6(2): 553-557.
- [46] Li X, Youngblood N, Cheng Z G, et al. Experimental investigation of silicon and silicon nitride platforms for phase-change photonic in-memory computing[J]. *Optica*, 2020, 7(3): 218-225.
- [47] Farmakidis N, Youngblood N, Li X, et al. Plasmonic nanogap enhanced phase-change devices with dual electrical-optical functionality[J]. *Science Advances*, 2019, 5(11): eaaw2687.
- [48] Zhang H Y, Zhou L J, Lu L J, et al. Miniature multilevel optical memristive switch using phase change material[J]. *ACS Photonics*, 2019, 6(9): 2205-2212.
- [49] Zheng J J, Fang Z R, Wu C M, et al. Nonvolatile electrically reconfigurable integrated photonic switch enabled by a silicon PIN diode heater[J]. *Advanced Materials*, 2020, 32(31): 2001218.
- [50] Yang X, Nisar M S, Yuan W, et al. Phase change material enabled  $2 \times 2$  silicon nonvolatile optical switch [J]. *Optics Letters*, 2021, 46(17): 4224-4227.
- [51] Delaney M, Zeimpekis I, Du H, et al. Nonvolatile programmable silicon photonics using an ultralow-loss

- Sb<sub>2</sub>Se<sub>3</sub> phase change material[J]. *Science Advances*, 2021, 7(25): eabg3500.
- [52] Xu Z, Luo H, Zhu H, et al. Nonvolatile optically reconfigurable radiative metasurface with visible tunability for anticounterfeiting[J]. *Nano Letters*, 2021, 21(12): 5269-5276.
- [53] Tait A N, Nahmias M A, Shastri B J, et al. Broadcast and weight: an integrated network for scalable photonic spike processing[J]. *Journal of Lightwave Technology*, 2014, 32(21): 3427-3439.
- [54] Xu X Y, Tan M X, Corcoran B, et al. Photonic perceptron based on a Kerr microcomb for high-speed, scalable, optical neural networks[J]. *Laser & Photonics Reviews*, 2020, 14(10): 2000070.
- [55] Robertson J, Wade E W, Kopp Y, et al. Toward neuromorphic photonic networks of ultrafast spiking laser neurons[J]. *IEEE Journal of Selected Topics in Quantum Electronics*, 2020, 26(1): 7700715.
- [56] Feldmann J, Youngblood N, Wright C D, et al. All-optical spiking neurosynaptic networks with self-learning capabilities[J]. *Nature*, 2019, 569(7755): 208-214.
- [57] Feldmann J, Youngblood N, Karpov M, et al. Parallel convolutional processing using an integrated photonic tensor core[J]. *Nature*, 2021, 589(7840): 52-58.