

光学感前计算技术及其卫星遥感应用综述(特邀)

李天宇¹, 王国庆^{1*}, 李维^{2**}, 陈宏伟^{3***}, 刘勋², 王志斌¹, 刘少冲¹, 蔡滢馨²¹电子科技大学计算机科学与工程学院, 四川 成都 611731;²北京空间机电研究所, 北京 100094;³清华大学电子工程系, 北京 100084

摘要 光学感前计算是一种在光电传感器前端的光学域进行信息计算处理的技术,包括编码压缩、全光智能推理等计算范式,具有传输即计算、结构即功能等显著特点,在卫星光学遥感领域有着广泛的应用前景。首先对用于感前计算的光场调制器件进行介绍,包括数字微镜器件(DMD)、液晶空间光调制器(LC-SLM)、衍射光学元件(DOE)及超表面等。然后分别梳理了感前编码压缩及全光智能推理的相关技术发展,在此基础上,着重讨论光学感前计算在卫星遥感领域的应用途径和未来发展趋势。

关键词 光学感前计算; 编码压缩; 全光智能推理; 卫星遥感

中图分类号 O439 文献标志码 A

DOI: 10.3788/LOP232509

Review of Optical Pre-Sensor Computing Technology and Its Satellite Remote Sensing Applications (Invited)

Li Tianyu¹, Wang Guoqing^{1*}, Li Wei^{2**}, Chen Hongwei^{3***}, Liu Xun², Wang Zhibin¹,
Liu Shaochong¹, Cai Yanxin²¹School of Computer Science and Engineering, University of Electronic Science and Technology of China, Chengdu 611731, Sichuan, China;²Beijing Institute of Space Mechanics and Electricity, Beijing 100094, China;³Department of Electronic Engineering, Tsinghua University, Beijing 100084, China

Abstract Optical pre-sensor computing is a technique involving information computation and processing in the optical domain at the front end of photoelectric sensors. This encompasses computation paradigms such as encoding compression and all-optical intelligent inference. It exhibits significant characteristics, such as computation during optical transmission and structure-function correlation, making it widely applicable in the field of satellite remote sensing. This paper introduces optical field modulation devices employed in pre-sensor computing, such as digital micromirror device (DMD), liquid crystal spatial light modulator (LC-SLM), diffractive optical element (DOE), and metasurface. Subsequently, we systematically review the pertinent technological advancements in pre-sensor encoding compression and all-optical intelligent inference. Finally, the application pathways and future development trends of optical pre-sensor computing in the field of satellite remote sensing are discussed.

Key words optical pre-sensor computing; encoding and compression; all-optical intelligent inference; satellite remote sensing

1 引言

卫星光学遥感图像在城市规划、农业生产、林业管理、自然灾害监测与预警等方面发挥着重要作用^[1],可以提供精准的空间信息,帮助决策者制定有效的应对

策略,提高资源利用效率并减少灾害风险。因此,近年来卫星光学遥感技术得到了极大的发展,当前光学遥感卫星能够以高分辨率和高频率持续观测地表,并产生巨大的数据量,例如,美国商用地球观测卫星 WorldView-3^[2]每天能以 30 cm 全色图像分辨率对

收稿日期: 2023-11-15; 修回日期: 2023-12-11; 录用日期: 2023-12-13; 网络首发日期: 2023-12-25

通信作者: *gqwang0420@uestc.edu.cn; **wei_li_bj@163.com; ***chenhw@tsinghua.edu.cn

680000 km 的地域进行数据采集,中国的高分二号卫星^[3]每天可产生的数据量超过 1000 GB。

然而,由于卫星存在载荷空间、数据传输带宽及能耗等多方面限制,光学相机采集的海量数据给星上数据存储、星上数据智能实时处理、星地/星间数据传输等任务带来了巨大挑战^[4]。为解决以上挑战,亟需要发展计算高效且功耗较低的星上智能计算技术。

近年来,随着光计算神经网络的提出以及光学元器件加工技术的发展,在卫星上使用光计算替代电计算成为可能。光学计算的实现方式大致可分为片上集成光学计算和自由空间衍射光学计算两大类^[5],前者将光学计算功能直接集成到芯片上^[6],而后者则利用光在自由空间中的传播特性进行信息传递和处理。

光学感前计算属于自由空间衍射光学计算,是一种在光电传感器前端利用光学元器件对光信息进行调制处理以实现计算推理的技术,由于具备瞬时处理、超低功耗等优点,该技术为星上海量数据的处理提供了一种潜在解决方案。光学感前计算包括编码压缩、全光智能推理等多种计算范式。针对大视场高分辨率卫星光学遥感图像下传难的问题,可通过光学感前计算,在光学域对图像进行编码调控实现视场压缩,然后在地基端利用高通量极速解码算法实现遥感图像的解码重建。针对光学遥感图像无法得到在轨实时处理的问题,可利用光场调控元器件模拟卷积神经网络的操作,完成全光智能计算推理^[7-8],实现轨目标识别、感兴趣区域(ROI)^[9]发现等多种时效性强的任务。

本文首先对用于感前计算的光学调制器件进行介绍,然后分别对感前编码压缩和全光智能推理的相关技术进行回顾,最后讨论了光学感前计算在卫星遥感领域的应用途径。

2 光学调制器件

光学感前计算是一种在光电传感器前端利用光学调制器件对光场信息进行调制处理的技术。光场包含振幅、相位、偏振态等多个参数,通过对这些参数进行调节可实现空间光场的调控^[10],完成感前计算的功能。目前用于感前计算的空间光场调控器件主要有空间光调制器(SLM)、衍射光学元件(DOE)以及超表面(metasurface)等。

2.1 空间光场调控器

SLM 是一种用于调控光波的器件,可在电信号的驱动控制下调节液晶分子的排列来改变光波的相位、振幅和偏振态等属性。在空间光计算中,SLM 可用于对入射光进行编码计算。常见的 SLM 包括:液晶空间光调制器(LC-SLM)、数字微镜器件(DMD)、远场光束调制器、相位空间光调制器(PSLM)等。其中可实现振幅调制的 DMD 和可实现相位调制的 LC-SLM 在光学感前计算中得到了广泛的应用。

2.1.1 数字微镜器件

DMD 是一种电子输入、光学输出的微机电系统,由多个微型反射镜面组成,每个微镜可独立寻址,有多种可编程的角度状态,通过控制微镜绕固定轴(铰)的旋转和时域响应来调整成像图像和其特性,其硬件结构如图 1 所示。DMD 的微镜阵列主要由铝制微反射镜组成,铝制微反射镜在互补金属氧化物半导体(CMOS)存储电路上制作而成^[11],是 DMD 的核心部分。第一块 DMD 由德州仪器(TI)公司于 1987 年发布,经过三十多年的发展,其各项性能均得到显著提高,市面上已经出现多种解析度规格不同的 DMD,主要有 640×480(VGA)、800×600(SVGA)、1024×768(XGA)、1280×1024(SXGA)、1920×1080(1080P)等。凭借结构简单、响应时间短、分辨率较高的特点,其广泛运用于数字光刻、投影、高动态范围成像、编码孔径成像等领域^[12]。




图 1 DMD 硬件结构

Fig. 1 Hardware structure of DMD

DMD 具有一些显著的特点:1) 高分辨率,DMD 阵列由数百万个微型镜组成,每个微反射镜单元的尺寸都会对 DMD 的分辨率产生很大影响,在 DMD 的几何尺寸固定的情况下,通过增加 DMD 微反射镜单元的数量可使 DMD 能够处理高分辨率的图像,适用于各种应用,例如高清晰度的显示需求^[13];2) DMD 响应速度快,DMD 的材质决定其可以非常快速地响应电信号,在接收到控制信号后,小质量的微镜将会快速发生偏转,而无需机械运动,每次偏转所需时间小于 $10 \mu\text{s}$ ^[14-15],因此能够实现高刷新率,且在一定程度上解决了传统机械式投影系统中可能存在的运动部件磨损和维护问题;3) DMD 具有可靠性,DMD 的微反射镜结构由铝箔等材料制成的微反射镜面、偏转铰链、寻址电极及 CMOS 存储器等部分组成,经过耐热性测试、机械冲击测试、芯片粘贴测试、振动加速测试及高温老化测试等多道工艺检测以确保其质量合格,因此 DMD 具有相对较高的可靠性和耐久性。

在 DMD 中,光路的传播过程会伴随有噪声,同时 DMD 中不同位置的铝制微反射镜的反射率也会存在一定的不一致性,以及翻转过程中可能会存在转换不

完全等问题,以上问题会对 DMD 的性能产生影响。

2.1.2 液晶空间光调制器

LC-SLM 是一种主要用于对光相位进行调制的器件^[10],也可被设计用于调制光的振幅和偏振。它是由许多独立单元(像元)组成的一维或二维阵列,这些独立单元可以单独接收光信号或电信号的控制,从而实现光调制的目的^[16]。

LC-SLM 结构包含几部分,即保护玻璃、透明电极、取向膜、液晶层、像素阵列及硅基板,如图 2 所示。




图 2 LC-SLM 结构

Fig. 2 LC-SLM structure

LC-SLM 具有高分辨率的优势,工作时调节电场,通过微小的液晶单元对光波进行调制,因此也具有较高的灵活性。但 LC-SLM 在应用过程中还存在一些不足之处:1)响应速度慢,液晶分子的转变速度相对较慢,因此响应速度可能受到限制,不适用于一些需要快速光调制的应用;2)损耗比较大,驱动和校准可能相对复杂,需要高精度的电子和光学系统;3)极化依赖性,通常对入射光的偏振状态敏感,液晶分子的排列状态通常与光的偏振状态有关,因此调制器的性能可能在不同的偏振状态下发生变化^[18]。

2.2 衍射光学元件

DOE 如图 3 所示,是一种可通过微纳刻蚀工艺制造的二维分布的衍射单元,每个衍射单元可具备特定的形状和折射率及其他属性,针对不同的波长范围设计可以实现对激光波前相位分布的精细调控^[19]。激光经过每个衍射单元后发生衍射,在一定距离处形成干




图 3 DOE 示例

Fig. 3 Example of DOE

涉,从而得到特定的光场分布。透明玻璃起保护作用,玻璃内层附有透明电极;两层取向膜之间夹着液晶层,取向膜的作用是使贴近膜表面的液晶分子趋于某一方向进行排列;下层取向膜的下面是硅基板,可独立控制的像素单元刻在硅基板上。LC-SLM 工作原理可简述为:控制液晶分子的排列,从而改变光的传播特性。其中,通过改变液晶层中的折射率,光波的相位发生变化,可达到相位调制的目的^[17];通过调节液晶层对光波的偏振状态,则可实现偏振光的调制。

涉,从而得到特定的光场分布。

DOE 的设计主要通过利用标量衍射理论进行光场仿真,基于输入面和输出面光场分布,借助智能优化算法迭代优化相息图实现。通过设计相应功能的 DOE,可实现光束整形、光束扩散、光束匀质、光束聚焦等任务,使其在波前调控技术^[20]、光学成像技术^[21]、微光机电系统^[22]等领域有重要的应用前景。

DOE 一般具有高衍射效率、独特的色散性能、更多的设计自由度、宽广的材料可选性,并具有特殊的光学性能;但同时由于光刻制造技术的局限性,在实际制造 DOE 时往往需要对 DOE 的参数进行量化操作;同时实际生产过程也会引入制造误差,这使得制备的 DOE 往往会在一定程度上偏离理想情况的 DOE,从而会降低其光场调控的准确性^[23]。

2.3 超表面

Metasurface 是一种具有特殊微结构的人造材料,可用于控制光的传播和波前调制。它由一系列微小的二维结构单元组成,这些单元的尺寸比光的波长要小得多。通过调整超表面上每个微结构单元的几何形状、尺寸和材料,能够在纳米尺度上实现对光的高度定制化控制,可以实现对光的折射、反射和透射过程的精确控制。这使得超表面可以用于实现各种光学功能,如聚焦、反射、偏振转换、透镜效应、光学吸收、色散控制等。

使用超表面进行光学计算可以减小光学元件的尺寸,同时在计算中使用更广泛的光学特性,包括偏振^[24-25]、波长^[26]和入射角^[27-28]。例如,超表面已证明具有与入射角相关的传递函数功能,可用于实现紧凑的光学微分系统^[29-32],而无须使用傅里叶 4f 系统。此外,

通过结合波长多路复用超表面和光电减法,可实现负值卷积核,从而利用非相干光实现单次微分^[33-34]。然而,微分对应于单个卷积操作,而大多数机器视觉系统需要多个独立的通道。最近有关于多通道卷积的工作,受限于传输效率和计算复杂性,只能实现步幅等于内核大小的正值内核,从而阻碍了通用数字计算的实现^[35-37]。

3 感前编码压缩

光学感前编码压缩是基于压缩感知理论,依赖光学编码单元在光电传感器前端的光学域对信息进行编码压缩的一种手段。在该框架下,信息在转换为电信号的同时就实现了压缩,经传感器得到的压缩图像可结合压缩感知理论由相应的解码算法完成信号重建^[38]。压缩感知的核心思想是:信号的采样频率可以

远低于传统 Nyquist 采样定理^[39]所规定的频率,仅须在信号中获取相对较少但具有代表性的稀疏表示,就足以进行高质量的信号重建。光学感前编码区别于传统的压缩感知(例如基于块的感知压缩^[40]),它并不需要特定的感知矩阵,此外,其压缩过程也无须涉及矩阵的乘法计算。

图 4 给出了利用光学感前编码实现压缩比为 $n:1$ 的压缩示例,由 DMD 或 DOE 等光学编码元件来实现 n 个只包含 0 和 1 的随机二进制掩码矩阵,对不同时刻 t_1, t_2, \dots, t_n 获取的光场数据进行信息编码。不同时刻的图像光场经过编码重叠到图像传感器的存储空间,传感器采集混叠图像,完成光学感前编码压缩。对于经压缩得到的混叠图像,可通过解码重建算法实现不同时刻图像的解压还原。

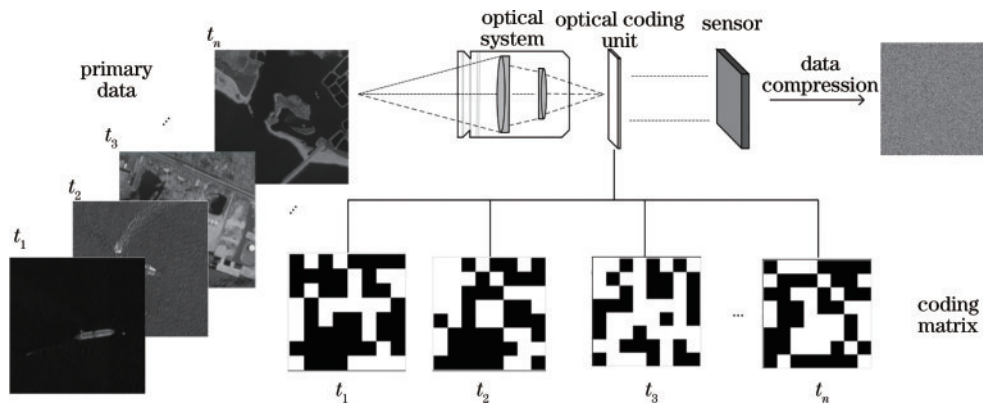


图 4 光学感前编码示例

Fig. 4 Example of optical pre-sensor encoding

3.1 感前编码压缩方法

现有研究中,感前编码压缩在卫星光学遥感领域比较少见,不过在自然图像领域,快照压缩成像(SCI)技术已经发展得相对成熟^[41]。SCI是一项融合计算机科学和计算成像的技术,其操作原理涉及在单次曝光中利用二维探测器捕获高维数据,例如视频和高光谱图像。该技术的核心理念在于通过不同的掩模对高维数据进行编码,随后将编码后的数据求和以生成一个快照测量。通过这种方法,SCI实现了对时间和空间的联合压缩感知,从而有效提升成像的效率和灵活性。

在光谱 SCI 领域, Wagadarikar 等^[42]引入了一种革新性的编码孔径快照光谱成像(CASSI)系统。该系统通过物镜收集光谱场景,并采用固定的二值编码板作为压缩感知的测量矩阵进行空间编码。编码的场景随后通过色散元件(如棱镜或光栅)得到光谱分散。这种空间-光谱编码的场景最终由 CCD 检测,在 CCD 上的一个快照包含场景的数十个光谱波段的信息。此后, Gehm 等^[43]基于此原型提出了采用双色散元件的系统(DD-CASSI),而 Wagadarikar 等^[44]进一步优化了这一设计,如图 5 所示,通过使用单色散元件简化了系统(SD-CASSI),减少了所需光学元件的数量,并在略微

降低空间分辨率的同时提高了光谱分辨率。这些技术的发展显著提升了光谱成像的效率和应用潜力,为高维光谱数据的快速、高效捕获和处理开辟了新路径。

为了解决高速相机因高昂的探测器和数据成本难以在民用领域满足需求的问题,视频压缩感知成像技术得到广泛关注。在高速相机中,探测器成本主要受高灵敏度感光芯片和高速模拟数字转换器(ADC)的制约。提高帧率会导致每一帧图像光信号强度减弱,因此需要采用高灵敏度探测器芯片,并对 ADC 的带宽提出更高要求。此外,高帧率导致数据量剧增,进而需要高速数据传输链路和大容量存储设备,从而增加了数据成本。视频压缩感知成像技术的核心思路在于优化数据采集过程,通过在采集阶段对多帧视频数据进行压缩,将其精炼到一帧图像中。这不仅显著减少了数据量,而且由于仅须采集单帧图像,因此可利用慢速 ADC 和经济实惠的感光芯片。Veeraraghavan 等^[45]通过实验证明,使用全局编码可以高时间分辨率对周期性场景进行成像,他们使用 25 frame/s 的相机捕获 2000 帧的视频信号,实现了 1.25% 的压缩比。Holloway 等^[46]通过使用子空间联合模型将该方案扩展到非周期性场景进行视频重建,实验中使用

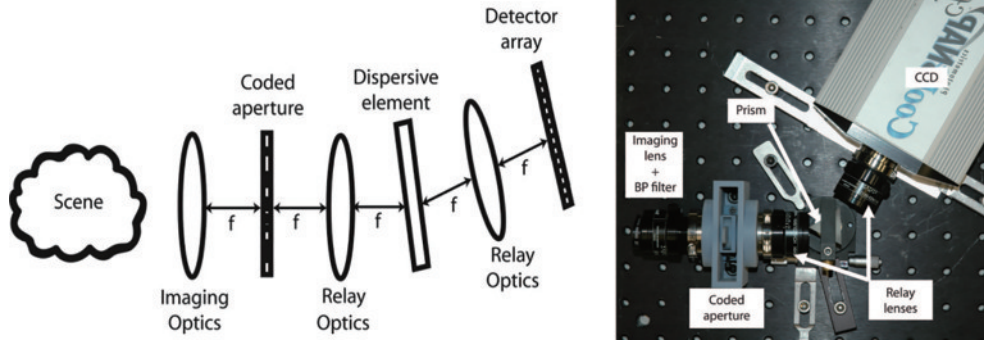


图 5 光谱 SCI 中的 CASSI 示意图^[44]
Fig. 5 Schematic of the CASSI in spectrum SCI^[44]

7 frame/s 的相机捕获 49 帧视频, 压缩比为 14%。尽管全局编码结构简单, 但这种空间不变的编码方式对复杂运动场景无法实现很好的压缩-重建效果。逐像素编码通常使用空间光调制器如 DMD 和 LC-SLM, 对不同像素点进行独立编码, Reddy 等^[47]提出可编程像素压缩相机(P2C2), 使用液晶型空间光调制器实现逐像素编码, 在实验中, 对于复杂运动模式, P2C2 原型可使用 25 frame/s 的相机捕获 200 帧的视频, 压缩比为 12.5%。Llull 等^[48]和 Koller 等^[49]提出了一种通过传感器平面中的平移掩模实现帧之间编码的方法, 避免了硬件复杂性和高功耗。

总的来说, 感前编码压缩结合了传统压缩感知技术和先进的光学编码方法, 具有如下特点: 1) 感前压缩, 在数据被完全记录和存储之前, 即在图像捕获的最前端(光学编码器件)进行压缩; 2) 数据压缩, 通过减少传感器输出的数据量, 减轻后续处理、存储和传输的负担; 3) 损失控制, 需权衡压缩比和信息损失, 联合设计解码算法与编码器件, 尽量减少对图像质量的影响; 4) 实时处理, 感前编码压缩具有较高的实时处理能力, 适应快速的数据捕获速度。

3.2 解码重建算法

感前编码压缩问题可以表示为

$$Y = \sum_{k=1}^N X_k \odot M_k, \quad (1)$$

式中: Y 是传感器测量值; X_k 代表第 k 个信号单元(可以为视频帧、图像块、光谱通道等); N 为信号单元的总数; 符号 \odot 表示 Hadamard(逐元素)乘积; M_k 代表第 k 个掩码。

该模型向量化的表示为

$$y = \Phi x, \quad (2)$$

式中: $y = \text{vec}(Y)$; $x = [x_1^T, \dots, x_N^T]^T$, $x_k = \text{vec}(X_k)$; $\Phi = [D_1, \dots, D_n]^T$, $D_k = \text{Diag}[\text{vec}(M_k)]$ 。

从编码压缩得到的测量 y 中恢复原本的信号 x 是一个“病态”问题, 现有的应用场景中多数是从视频的压缩(例如 8 帧视频压缩到 1 帧)或者光谱的压缩(例如 28 个光谱通道压缩到 1 个)恢复原信号的, 从图像的压

缩(例如压缩到原尺寸的 1/24)恢复图像的工作相对较少。尽管图像的重建任务与视频或光谱重建任务存在一定的不同, 因为图像块之间不一定像视频帧或光谱通道之间存在比较强的相关性, 但是重建的算法是可以相通的。现有主流的重建方法可以分为 4 大类^[41]: 基于正则化的迭代优化算法^[42, 50-56]、基于浅层学习的算法^[57-60]、基于深度学习的算法^[61-71]、结合深度学习与迭代优化的算法^[72-85]。其中, 得益于数据驱动的深度学习算法的发展, 基于深度学习的算法以及结合深度学习与迭代优化的算法在压缩图像重建任务上取得了突出的效果。

3.2.1 基于深度学习的重建算法

在计算成像领域, 数据驱动的深度学习算法已经成为了一种强大的工具, 推动了各种应用的发展。得益于强大的学习能力, 深度神经网络能够从大量的训练数据中学习复杂的模式和特征, 从而有效地求解病态问题。在压缩感知成像任务中, 神经网络的应用也得到了广泛的关注, 神经网络可以通过端到端的方式得到训练并用于解码压缩后的图像, 从而重建出原始图像。在深度学习算法的框架下, 问题被建模为

$$\hat{x} = f[(\Phi, y)], \quad (3)$$

式中: \hat{x} 是重建出的信号; $f(\cdot)$ 是设计过的神经网络模型。训练时, 大量带有标签的数据对 $((\Phi, y), x)$ 被用于训练网络, 测试时, 网络只需要进行一次前馈过程就能重建出原始的图像。图 6 为一个典型的基于神经网络进行编码图像重建的框架^[61], 其中测量和掩码一起作为神经网络的输入, 神经网络直接输出重建的




图 6 深度学习框架下的重建算法示意图^[61]
Fig. 6 Schematic of the reconstruction algorithm in the deep learning framework^[61]

结果。

通常来讲,用于重建信号的神经网络模型遵循编码器-解码器结构。Qiao 等^[61]通过端到端的方式训练 U-Net 对视频信号进行重建。循环神经网络被 Cheng 等^[65]用于建模连续视频帧的潜在相关性。Cheng 等^[66]还利用可逆 3D 卷积实现了高效、内存友好的高分辨率视频感知压缩(SCI)重建网络。注意力机制被证明可以有效提升重建效果^[68-71],其中 Cai 等^[70]利用面向光谱的多头注意力机制(S-MSA)计算光谱特征间的自注意力,并通过掩码注意力图(mask attention map)引导 S-MSA 生成重建信号。Cai 等^[63]还考虑了硬件适配性,基于二值化算法设计了紧凑且易于部署的解码模型。Xu 等^[64]考虑了成像系统的退化模式,并提出基于退化学习的退化感知动态傅里叶网络。Zhang 等^[62]通过在编码时结合光学感前计算,并在解码时端到端地训练点扩散函数(PSF),同时实现了重建与超分辨率任务。Li 等^[67]在解码时考虑了光学编码器件 DOE 的量化过程,端到端地训练自适应机制以调整 DOE 的高度图。




图 7 深度展开框架下的重建算法示意图^[73]

Fig. 7 Schematic of the reconstruction algorithm in the depth unfolding framework^[73]

深度展开算法大多数基于交替方向乘子法(ADMM)以及广义交替投影(GAP)算法迭代优化算法,其中 GAP 由于是计算负载相对低的算法而受到欢迎,在以 GAP 为基础的深度展开算法^[73]中,第 t 次迭代的求解过程为

$$\mathbf{x}^{(t+1)} = \mathbf{v}^{(t)} + \Phi^T (\Phi \Phi^T)^{-1} (\mathbf{y} - \Phi \mathbf{v}^{(t)}), \quad (4)$$

$$\mathbf{v}^{(t+1)} = \mathbf{D}_{t+1}(\mathbf{x}^{(t+1)}), \quad (5)$$

式中: $\mathbf{v}^{(t)}$ 是为求解 GAP 优化问题而引入的辅助变量; \mathbf{D}_t 对应为每次迭代步骤的神经网络,将 $\mathbf{x}^{(t)}$ 投影至所希望的信号空间。

由于整合了神经网络强大的学习能力,深度展开算法相对于基于正则化的迭代优化算法仅需要较少的迭代步骤,因此推理速度大幅提高。相比完全基于端到端的深度学习算法,深度展开具有一定的可解释性,并通常具有更快的收敛速度。Yang 等^[76]基于 ADMM 设计了早期的深度展开算法。Meng 等^[73]使用更低计算负载的 GAP 算法。Wu 等^[79]使用 3D 卷积作为先验。使用 Transformer 建模全局表示可以显著

相比冗长的迭代优化算法,端到端的神经网络在训练后展现了快速推理的优势。然而,完全基于深度学习的算法存在一些缺点,其中包括对大量训练数据的需求和冗长的训练时间。此外,神经网络模型在灵活性方面存在一定不足,若掩码或采样率发生变化,则需要训练新的网络^[41]。

3.2.2 结合深度学习与迭代优化的算法

在压缩感知的重建算法中,基于正则化的迭代优化算法无须依赖训练数据,但通常重建速度较慢。相比之下,端到端的深度学习算法具有快的推理速度,但需要较长时间的训练^[41]。以深度展开和 Plug-and-Play (PnP)为代表的系列算法结合了两种方法的优势,具体而言,深度展开算法将迭代优化算法的每次迭代中的特定步骤替换为一个神经网络并以端到端的方式进行训练,PnP 算法则利用预先训练的深度降噪网络作为先验,并将其整合到迭代算法中。图 7 给出了深度展开框架下的重建算法示意图^[73],其中每一个“Stage”对应于一次迭代步骤,每次迭代包括线性投影(linear projection)和卷积神经网络(CNN)两个部分。

提升重建效果^[74,83-84]。大多数重建算法是对视频或光谱信号进行重建的,Xue 等^[72]设计算法对图像信号进行重建,其提出的编码框架有应用于感前编码的可能。

深度展开算法的一个潜在问题是总阶段数^[41]。具体而言,如果总阶段数很大,以端到端方式训练网络将是具有挑战性的;另一方面,如果总阶段数很小,重建效果往往会变差。

4 全光智能推理

人工神经网络(ANN)技术已在诸多领域取得了显著成果^[86-89]。然而,目前人工神经网络的实现主要还是基于经典电子计算的方式,存在并行能力弱、运行速度慢等缺点,同时其需要较高的 GPU 或者 NPU 计算资源。基于电子计算的神经网络技术已逐渐无法跟上神经网络和人工智能的进一步发展。近年来,随着光学器件加工技术的不断成熟,基于光学方法的人工神经网络(ONN)硬件实现受到了越来越多的关注,相较于电子系统,光学系统具有更大的带宽和更快的响

应速度, 光学神经网络可以实现更大规模且并行能力更强的计算。目前的光学神经网络根据其实现方式, 可以分为基于衍射光学^[90-92]和傅里叶光学^[93]实现的空间光学计算系统以及依靠相位调制^[94-96]的片上集成光学计算系统。

4.1 空间光学计算基础

光学神经网络的基础是矩阵乘法的光学实现, 前人对此进行了大量研究并提出了不同的解决方案。Zuo 等^[90]将可编程的 SLM 按照入射光束的数量划分为几个区域, 每个区域都呈现为多个相位光栅的叠加。它根据设计好的权重 W_{ij} 将入射光束分成不同的方向, 然后利用凸透镜进行傅里叶变换, 将所有衍射光束聚焦在同一位置, 实现求和运算, 如图 8 所示。Bueno 等^[91]的实验则证明了可以通过随机衍射构建 ONN, 他们的实验利用 DOE 在不同位置的不均匀性, 使得衍射效率(即权重系数)在相应位置发生相应变化以实现矩阵乘法, 如图 9 所示。

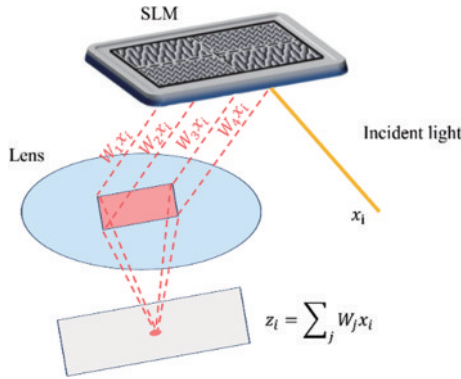


图 8 通过可编程 SLM 实现的矩阵乘法^[90]

Fig. 8 Matrix multiplication realized by programmable SLM^[90]

4.2 感前智能推理技术

为实现光学神经网络推理计算, Lin 等^[7]提出了

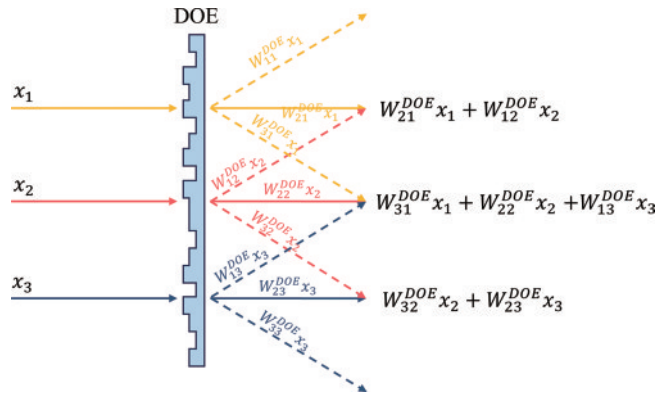


图 9 通过 DOE 实现的矩阵乘法^[91]

Fig. 9 Matrix multiplication realized by DOE^[91]

一种由多层衍射物理表面级联组成的全光学衍射深度神经网络(D²NN), 衍射表面的作用类似于神经网络中的各个层, 以光学的方式实现与神经网络相近的作用。他们通过计算机仿真的方式训练网络, 再对训练好的网络结构数据进行 3D 打印得到对应的物理实体。如图 10(a)所示, D²NN 由多个衍射层组成, 其中给定层上的每个网格都是具有不同透射系数的神经元, 每个神经元可以看作是一个次级波源, 通过衍射波与下一层的所有神经元相连, 这些神经元的透射系数在学习阶段通过深度学习得到训练; 在学习阶段之后, D²NN 的设计就固定了下来, 通过 3D 打印制造出相应的衍射层实体; 输入图像在经过多个衍射层的作用后, 利用输出层的探测器阵列测量光强度, 输出层上平面探测器的数量取决于网络所要分类的种类数量, 例如 MNIST 数据集包含 10 个分类, 则需在输出层分为 10 个探测区域, 如图 10(b)所示。D²NN 的分类依据就是找到获得最大光信号值的探测器, 那个探测器所对应的类别就是识别的结果。

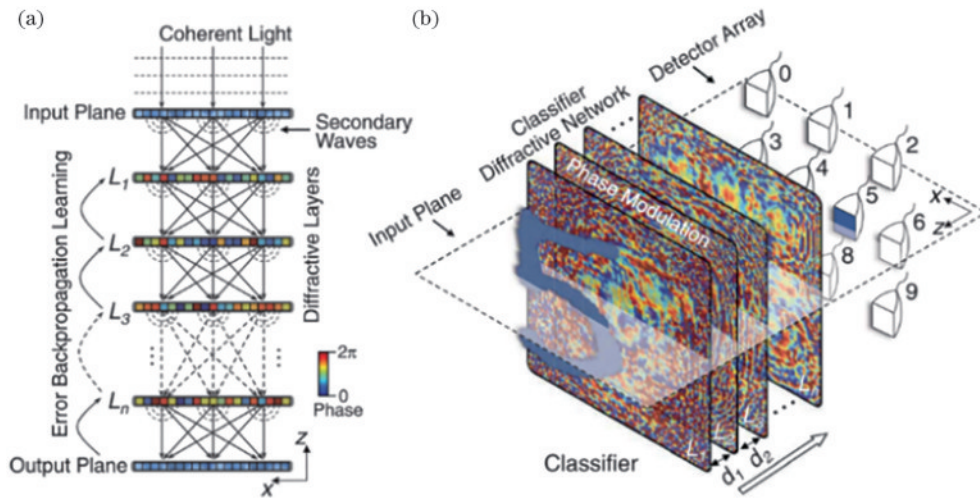


图 10 D²NN^[7]。(a)D²NN 由多个透射层组成; (b)用于手写数字识别的 D²NN 示例

Fig. 10 D²NN^[7]. (a) D²NN composed of multiple transmissive layers; (b) example of D²NN for handwritten digit recognition

在 D^2NN 的基础上, Li 等^[92] 提出了差分 D^2NN 用于解决 ONN 中光场强度没有负值的问题, 如图 11(a) 所示。其中正探测器和负探测器根据其符号分成两个联合优化的网络, 正探测器接收到的信号代表“分类概率”, 负探测器接收到的信号代表“不可能”, 来自正探测器的更强的信号意味着与该探测器对应的结果应该被认为是更可能的分类结果, 而来自负探测器的更强的信号则与之相反。图 11(b) 为差分 D^2NN 在 MNIST 数据集上进行十分分类的结果, 两张图分别为正负探测器的探测平面, 框选区域为对应分类结果的 10 个探测区域。

为解决显著目标检测的问题, Yan 等^[93] 提出了傅里叶空间 D^2NN 方法, 如图 12 所示, 傅里叶空间 D^2NN 中的光学图像处理模块在相干光下将 D^2NN 与作为非线性激活的光折变晶体(SBN:60)一起插入 4f 光学系统的傅里叶平面, 通过深度学习设计, 实现对目标场景显著目标的全光分割。

神经网络中的光学元件通常都具有制造成本

高、功能固化、一旦制造完成以后参数不可修改、无法应用在其他任务等缺点。现场可编程信息超表面的兴起^[97] 为实现可编程的衍射神经网络提供了契机。Liu 等^[98] 使用多层透射式数字可编程超表面实现了现场可编程的衍射神经网络硬件, 称之为可编程人工智能机 (PAIM), 他们使用 5 层透射式的可编程超表面阵列级联调控空间光场, 如图 13 所示, 其中每层超表面都有 8×8 个人工神经元, 每个神经元都将接收前一层中所有人工神经元辐射的波, 使得 PAIM 成为一个全连接形式的网络结构。同时 PAIM 安装了多个 FPGA 来控制每个人工神经元的增益因子, 人工神经元的增益系数可以通过有监督学习、无监督学习甚至强化学习的方式得到训练, 这使得 PAIM 成为实时可编程的智能机器。

空间光学计算系统可同时处理多个计算任务, 实现大规模的极速并行计算, 同时由于光信号具有很高的带宽, 系统可满足高带宽、低延迟的需求。然而, 为了实现复杂的全光计算推理, 空间光学计算系统在具

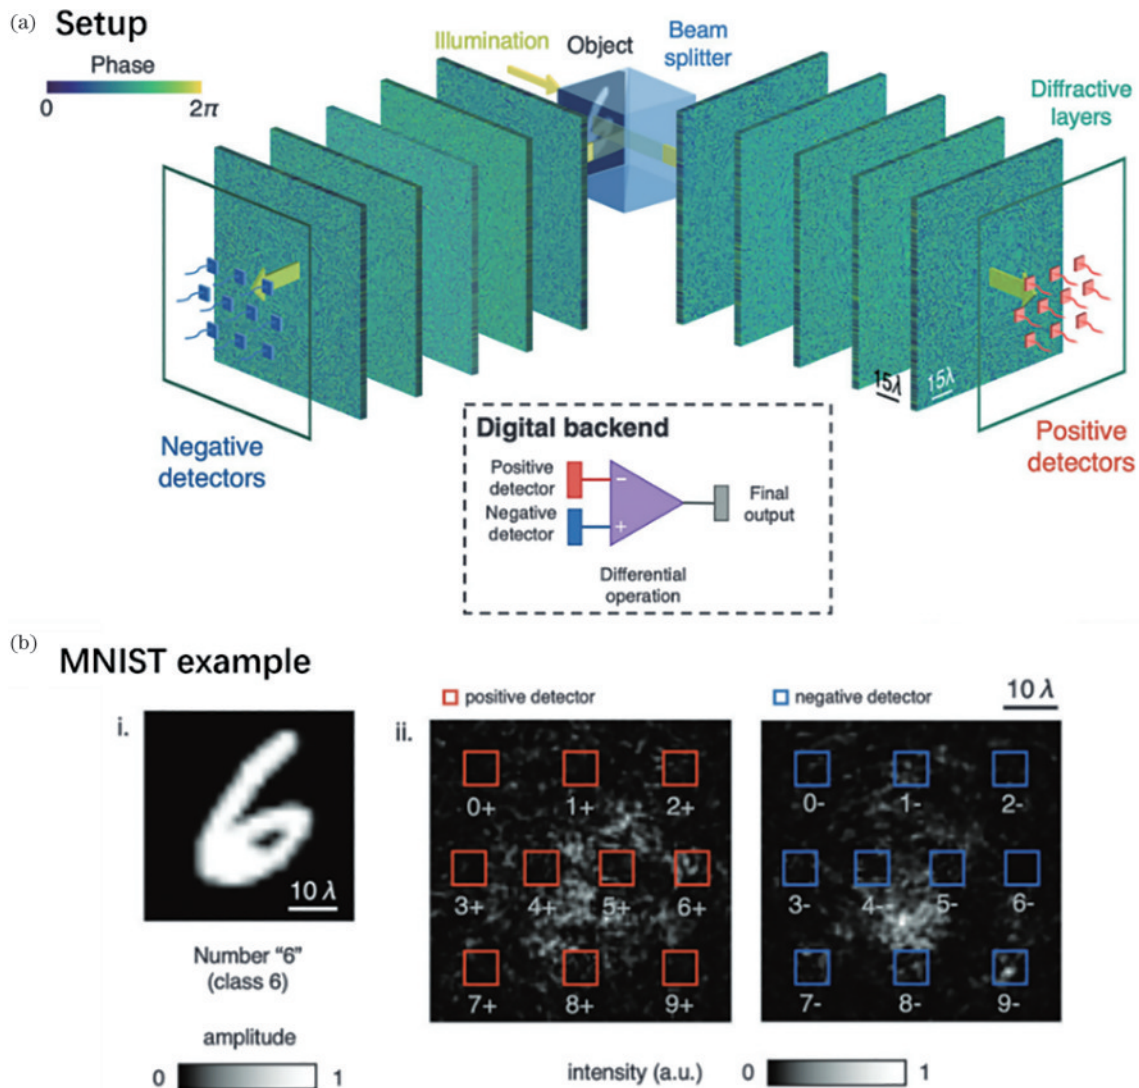


图 11 差分 D^2NN ^[92]。(a) D^2NN 的差分式设计; (b) 用于手写数字识别的差分 D^2NN 示例

Fig. 11 Differential D^2NN ^[92]. (a) Setup of the differential D^2NN design; (b) example of differential D^2NN for handwritten digit recognition

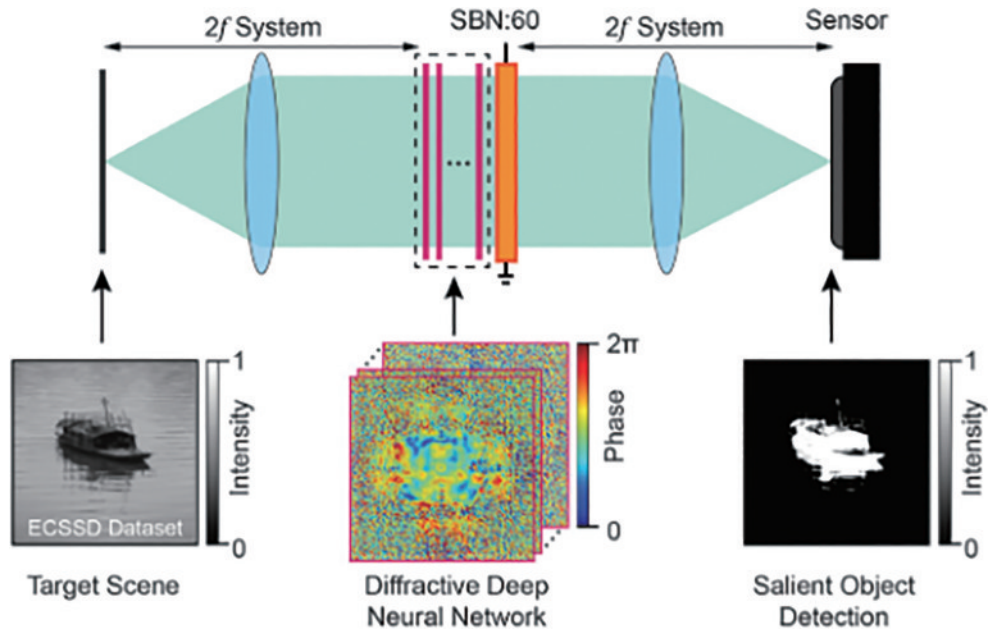


图 12 傅里叶空间 D²NN 框架^[93]

Fig. 12 Framework of Fourier-space D²NN^[93]

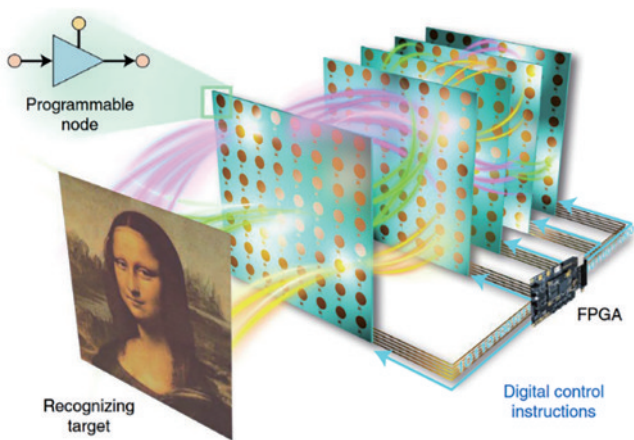


图 13 可编程人工智能机^[98]

Fig. 13 Programmable artificial intelligence machine^[98]

有以上优点的同时往往具有较大的体积和质量,且通常由多个光学元件组成,如镜子、透镜、光栅等,这些元件之间由于机械振动、温度变化等原因造成的对齐误差会导致光束偏离预期路径,进而影响计算系统的性能,因此空间光学计算系统往往需要先进行繁琐复杂的搭建与校正。此外,受限于非线性材料器件固有的特性,目前空间光学计算系统中的光学非线性过程会导致能量的大量损失,使得功耗有所增加,因此通常采用光电混合的方式实现非线性激活^[99],随着光学和材料学的进步,将会有更多的全光学线性激活方法^[100-103]得到发展。

5 卫星遥感应用

以感前编码压缩和全光智能推理为代表的光学感前计算技术在视频图像压缩、医学成像、制造业质量控

制、卫星遥感等领域都有着广泛的应用前景,本节将重点探讨其在卫星遥感领域的应用需求和应用途径。

5.1 应用需求

利用卫星光学遥感技术可以获取全球范围内的高时空分辨率的地表及空间信息,这些信息为地理、气象、农业、环境、资源、灾害等领域的研究和应用提供数据支撑,为空间态势感知、空间安全评估提供依据。因此,全球各国都在大力发展卫星光学遥感技术。随着卫星遥感技术的持续发展和图像分辨率的提升,光学遥感图像数据的像元规模正呈现出爆发性的增长,大视场高分辨率的光学遥感图像蕴含着大量的细节和信息,单张图片文件大小可能高达数千兆字节(GB)。在传统的光学遥感卫星系统中,由光学传感器捕获目标区域图像后,通过星载处理器实现对图像的数字编码压缩以及在轨分析,压缩后的图像被传输到地面进行更复杂的推理分析,其处理流程如图 14 所示,由于图像分辨率和采样频率的不断提高,目前的在轨处理系统难以满足光学图像的及时传输和实时处理需求^[104-105]。

首先,对于图像传输、存储的需求,采用数字图像压缩算法虽然可以减轻图像数据过多而导致的数据传输和星上存储压力,然而随着图像分辨率不断提升,传统的数字图像压缩算法^[106]在处理这些高分辨率图像时会面临压缩速度较慢和计算开销较大等问题,例如 JPEG 压缩算法^[107]具有 $O(N)$ 的时间复杂度。较慢的压缩速度可能导致数据无法及时得到处理和传输,从而影响实时性。而较大的计算开销意味着需要占用更多的计算资源,从而可能导致卫星上的计算处理器性能下降,甚至影响其他任务的执行。




图 14 传统光学遥感数据在轨处理流程

Fig. 14 Traditional optical remote sensing data on-orbit processing workflow

其次,对于诸如军事目标监测、深空陨石探测等敏感任务,通常需要利用深度学习模型完成对大视场高分辨率卫星遥感图像的在轨实时智能处理。然而,深度学习模型通常具有较高的时间复杂度和空间复杂度,例如表 1 中给出了当输入图像维度为 (3, 244,

244) 时典型深度学习模型^[86-87,108-109]的复杂度,因此需要被部署到具备高算力的处理器上。对于传统的电子处理器而言,意味着所需处理器的功耗较大。考虑到现阶段星上计算和能源等资源方面的限制,需要发展一种全新的光学遥感卫星计算系统。

表 1 典型深度学习模型的复杂度

Table 1 Complexity of typical deep learning models

Name	Type	Model size (#params)	Model size /MB	FLOPs /10 ⁹
AlexNet ^[86]	CNN	60, 965, 224	233	0.7
VGG-16 ^[108]	CNN	138, 357, 544	746(528)	15.5
ResNet50 ^[87]	CNN	25, 610, 269	317(98)	4.1(3.9)
ViT-S/16 ^[109]	Transformer	22, 100, 000	274(84)	4.6(4.1)

5.2 光学感前计算新体制

光学感前计算技术为卫星光学遥感数据的在轨处理提供了一种新的实现思路,其在轨处理流程如图 15 所示,光学信息在抵达传感器之前可通过感前

计算元器件完成编码或计算,在传感器上成像的同时即可得到编码压缩或计算推理结果。在此框架下,一方面可通过感前全光智能推理实现感兴趣区域(ROI)的提取,使后续轻量化神经网络仅需对 ROI

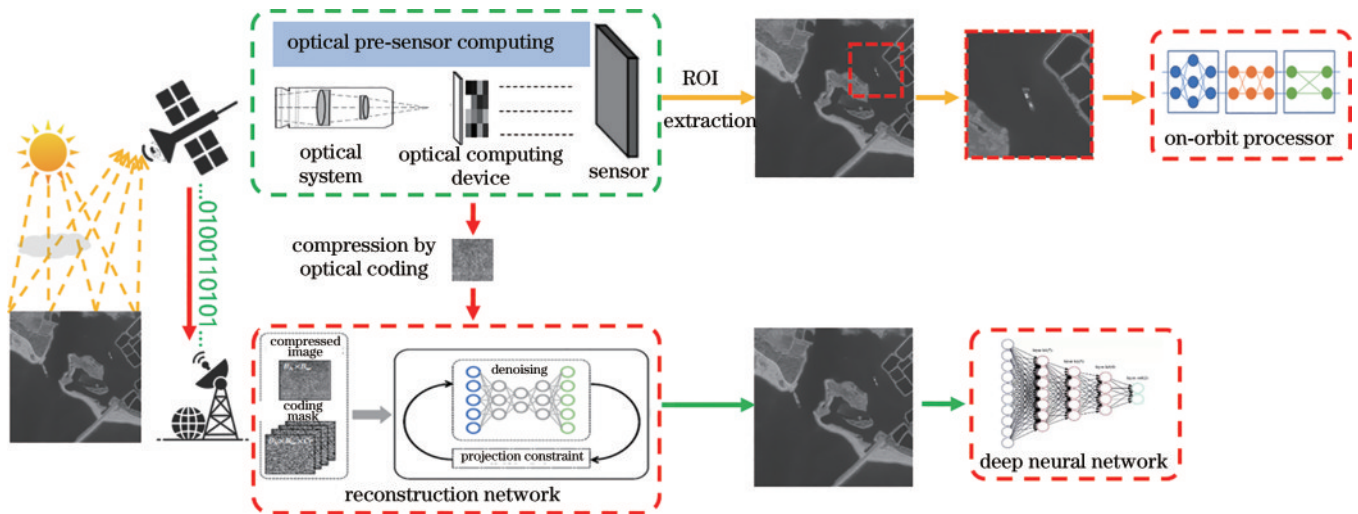


图 15 基于光学感前计算的遥感数据处理流程

Fig. 15 Optical pre-sensor computing-based optical remote sensing data processing workflow

图像进行处理,从而减小计算规模,实现对采集数据的实时在轨处理。另一方面,利用光学感前编码压缩技术,可实现高分辨率图像的极速压缩,通过在地端重构神经网络完成对采集图像的解码重构。

除了面向遥感图像信息获取和处理等方面应用外,近期 Qian 等^[110]提出了一种在探测器前端引入额外参考光路的新型光学感前测量技术,如图 16 所示。相比传统激光测距,其可以更有效地从复杂噪声环境中获取测量信号,这也是未来卫星光学感前遥感应用的发展方向之一。




图 16 基于光学感前计算的新型激光测量物理探测过程^[110]

Fig. 16 Optical pre-sensor computing-based novel laser measurement physical detection process^[110]

6 结束语

光学感前计算技术因极速计算、超低功耗等优点,为卫星光学遥感技术的发展瓶颈提供了一种全新的解决思路。综述了光学感前计算的两种计算范式,即感前编码压缩和全光智能推理,对其中的关键技术进行了回顾,并讨论了其在卫星光学遥感系统中的应用途径,包括实现大视场高分辨率图像的高通量极速编码压缩和感兴趣区域提取。

尽管光学感前计算技术具备瞬时计算、超低功耗等多项优点,但受限于光学器件的加工精度、系统固有噪声等因素,仍然有一些问题需要解决:如何消除器件安装造成的对齐误差、如何设计更加紧凑的感前计算系统、如何实现更加复杂的全光智能推理计算及如何针对特定应用场景设计感前编码对应的解码重建算法等。

随着光学元器件加工技术的提升及智能优化算法的发展,有理由相信以上问题在不远的将来会得到有效解决,具备光学感前计算能力的成像系统将成为卫星光学遥感的发展趋势。

参 考 文 献

[1] Huang Z H, Fang H, Li Q, et al. Optical remote sensing image enhancement with weak structure preservation via

spatially adaptive gamma correction[J]. *Infrared Physics & Technology*, 2018, 94: 38-47.

[2] Ye B, Tian S F, Ge J, et al. Assessment of WorldView-3 data for lithological mapping[J]. *Remote Sensing*, 2017, 9(11): 1132.

[3] 潘腾. 高分二号卫星的技术特点[J]. *中国航天*, 2015(1): 3-9.

Pan T. Technical characteristics of Gaofen-2 satellite[J]. *Aerospace China*, 2015(1): 3-9.

[4] 李维, 刘勋, 张维畅, 等. 深度学习在天基智能光学遥感中的应用[J]. *航天返回与遥感*, 2020, 41(6): 56-65.

Li W, Liu X, Zhang W C, et al. The application of deep learning in space-based intelligent optical remote sensing [J]. *Spacecraft Recovery & Remote Sensing*, 2020, 41 (6): 56-65.

[5] Shastri B J, Tait A N, de Lima T F, et al. Photonics for artificial intelligence and neuromorphic computing[J]. *Nature Photonics*, 2021, 15(2): 102-114.

[6] 符庭钊, 孙润, 黄禹尧, 等. 片上集成光学神经网络综述[J]. *中国激光*, 2024, 51(1): 0119001.

Fu T Z, Sun R, Huang Y Y, et al. Review of on-chip integrated optical neural networks[J]. *Chinese Journal of Lasers*, 2024, 51(1): 0119001.

[7] 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.

[8] 陈蓓, 张肇阳, 戴庭舸, 等. 光学神经网络及其应用[J]. *激光与光电子学进展*, 2023, 60(6): 0600001.

Chen B, Zhang Z Y, Dai T G, et al. Photonic neural networks and its applications[J]. *Laser & Optoelectronics Progress*, 2023, 60(6): 0600001.

[9] Hossain M S, Shahriar G M, Mahbulul Syeed M M, et al. Region of interest (ROI) selection using vision transformer for automatic analysis using whole slide images[J]. *Scientific Reports*, 2023, 13: 11314.

[10] 周源, 李润泽, 于湘华, 等. 基于液晶空间光调制器的光场调控技术及应用进展(特邀)[J]. *光子学报*, 2021, 50 (11): 1123001.

Zhou Y, Li R Z, Yu X H, et al. Progress in study and application of optical field modulation technology based on liquid crystal spatial light modulators (invited)[J]. *Acta Photonica Sinica*, 2021, 50(11): 1123001.

[11] Dudley D, Duncan W M, Slaughter J. Emerging digital micromirror device (DMD) applications[J]. *Proceedings of SPIE*, 2003, 4985: 14-25.

[12] 王延杰, 陈怀章, 刘艳滢, 等. 数字微镜器件在高动态辐射场景成像探测系统中的应用[J]. *光学精密工程*, 2014, 22(9): 2508-2517.

Wang Y J, Chen H Z, Liu Y Y, et al. Application of DMD to high dynamic scene image detection system[J]. *Optics and Precision Engineering*, 2014, 22(9): 2508-2517.

[13] 罗辉. 基于数字微镜器件的像素级调光技术研究[D]. 合肥: 合肥工业大学, 2020.

Luo H. Research on pixel-level dimming technology based on digital micromirror device[D]. Hefei: Hefei University of Technology, 2020.

- [14] 杨成. 基于智能算法的 DMD 光刻成像质量优化[D]. 长春: 长春理工大学, 2023.
Yang C. Optimization of DMD lithography imaging quality based on intelligent algorithm[D]. Changchun: Changchun University of Science and Technology, 2023.
- [15] 孙永强, 胡源, 王月旗, 等. 数字微镜器件在会聚成像光路中的像差分析[J]. 光学学报, 2019, 39(3): 0311001.
Sun Y Q, Hu Y, Wang Y Q, et al. Analysis on aberration of digital micromirror device in convergent imaging path[J]. Acta Optica Sinica, 2019, 39(3): 0311001.
- [16] 李育林, 傅晓理. 空间光调制器及其应用[M]. 北京: 国防工业出版社, 1996.
Li Y L, Fu X L. Spatial light modulator and its application[M]. Beijing: National Defense Industry Press, 1996.
- [17] 陈慧. 基于相位调制和深度学习的多模光纤成像方法研究[D]. 西安: 中国科学院西安光学精密机械研究所, 2022.
Chen H. Research on multimode fiber imaging based on phase modulation and deep learning[D]. Xi'an: Xi'an Institute of Optics and Precision Mechanics of CAS, 2022.
- [18] 曾臻. 基于空间光调制器的光学面形测量关键技术的研究[D]. 天津: 天津大学, 2023.
Zeng Z. Research on key technology of optical surface shape measurement based on spatial light modulator[D]. Tianjin: Tianjin University, 2023.
- [19] Poleshchuk A G. Fabrication and application of diffractive optical elements[J]. Proceedings of SPIE, 2010, 7544: 75443L.
- [20] Danziger Y, Hasman E, Friesem A A, et al. Multilevel diffractive elements for generalized wavefront shaping[J]. Optical Engineering, 1996, 35(9): 2556-2565.
- [21] Hu H Q, Zhou H, Xu Z H, et al. Practical snapshot hyperspectral imaging with DOE[J]. Optics and Lasers in Engineering, 2022, 156: 107098.
- [22] Ryf R, Stuart H R, Giles C R. MEMS tip/tilt and piston mirror arrays as diffractive optical elements[J]. Proceedings of SPIE, 2005, 5894: 58940C.
- [23] Yang L L, Cui Q F, Liu T, et al. Effects of manufacturing errors on diffraction efficiency for multilayer diffractive optical elements[J]. Applied Optics, 2011, 50(32): 6128-6133.
- [24] Kwon H, Arbabi E, Kamali S M, et al. Single-shot quantitative phase gradient microscopy using a system of multifunctional metasurfaces[J]. Nature Photonics, 2020, 14(2): 109-114.
- [25] Xiong B, Liu Y, Xu Y H, et al. Breaking the limitation of polarization multiplexing in optical metasurfaces with engineered noise[J]. Science, 2023, 379(6629): 294-299.
- [26] Khorasaninejad M, Chen W T, Devlin R, et al. Metalenses at visible wavelengths: diffraction-limited focusing and subwavelength resolution imaging[J]. Science, 2016, 352: 1190-1194.
- [27] Levanon N, Indukuri S R K C, Frydendahl C, et al. Angular transmission response of In-plane symmetry-breaking quasi-BIC all-dielectric metasurfaces[J]. ACS Photonics, 2022, 9(11): 3642-3648.
- [28] Nolen J R, Overvig A C, Cotrufo M, et al. Arbitrarily polarized and unidirectional emission from thermal metasurfaces[EB/OL]. (2023-01-28)[2023-11-12]. <https://arxiv.org/abs/2301.12301>.
- [29] Guo C, Xiao M, Minkov M, et al. Photonic crystal slab Laplace operator for image differentiation[J]. Optica, 2018, 5(3): 251-256.
- [30] Cordaro A, Kwon H, Sounas D, et al. High-index dielectric metasurfaces performing mathematical operations[J]. Nano Letters, 2019, 19(12): 8418-8423.
- [31] Zhou Y, Zheng H Y, Kravchenko I I, et al. Flat optics for image differentiation[J]. Nature Photonics, 2020, 14(5): 316-323.
- [32] Fu W W, Zhao D, Li Z Q, et al. Ultracompact meta-imagers for arbitrary all-optical convolution[J]. Light: Science & Applications, 2022, 11: 62.
- [33] Wang H W, Guo C, Zhao Z X, et al. Compact incoherent image differentiation with nanophotonic structures[J]. ACS Photonics, 2020, 7(2): 338-343.
- [34] Zhang X M, Bai B F, Sun H B, et al. Incoherent optoelectronic differentiation based on optimized multilayer films[J]. Laser & Photonics Reviews, 2022, 16(9): 2200038.
- [35] Zheng H Y, Liu Q, Zhou Y, et al. Meta-optic accelerators for object classifiers[J]. Science Advances, 2022, 8(30): eabo6410.
- [36] Bernstein L, Sludds A, Panuski C, et al. Single-shot optical neural network[J]. Science Advances, 2023, 9(25): eadg7904.
- [37] Zheng H Y, Liu Q, Kravchenko I I, et al. Intelligent multi-channel meta-imagers for accelerating machine vision[EB/OL]. (2023-06-12)[2023-11-12]. <https://arxiv.org/abs/2306.07365>.
- [38] 王霞, 马旭, 柯钧, 等. 散斑及压缩计算成像研究进展[J]. 光学学报, 2023, 43(15): 1511001.
Wang X, Ma X, Ke J, et al. Advances in speckle and compressive computational imaging[J]. Acta Optica Sinica, 2023, 43(15): 1511001.
- [39] Nyquist H. Certain topics in telegraph transmission theory[J]. Transactions of the American Institute of Electrical Engineers, 1928, 47(2): 617-644.
- [40] Gan L. Block compressed sensing of natural images[C]// 2007 15th International Conference on Digital Signal Processing, July 1-4, 2007, Cardiff, UK. New York: IEEE Press, 2007: 403-406.
- [41] Yuan X, Brady D J, Katsaggelos A K. Snapshot compressive imaging: theory, algorithms, and applications[J]. IEEE Signal Processing Magazine, 2021, 38(2): 65-88.
- [42] Wagadarikar A A, Pitsianis N P, Sun X B, et al. Spectral image estimation for coded aperture snapshot spectral imagers[J]. Proceedings of SPIE, 2008, 7076: 707602.
- [43] Gehm M E, John R, Brady D J, et al. Single-shot compressive spectral imaging with a dual-disperser

- architecture[J]. *Optics Express*, 2007, 15(21): 14013-14027.
- [44] Wagadarikar A, John R, Willett R, et al. Single disperser design for coded aperture snapshot spectral imaging[J]. *Applied Optics*, 2008, 47(10): B44-B51.
- [45] Veeraraghavan A, Reddy D, Raskar R. Coded strobing photography: compressive sensing of high speed periodic videos[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2011, 33(4): 671-686.
- [46] Holloway J, Sankaranarayanan A C, Veeraraghavan A, et al. Flutter Shutter Video Camera for compressive sensing of videos[C]//2012 IEEE International Conference on Computational Photography (ICCP), April 28-29, 2012, Seattle, WA, USA. New York: IEEE Press, 2012.
- [47] Reddy D, Veeraraghavan A, Chellappa R. P2C2: Programmable pixel compressive camera for high speed imaging[C]//2011 IEEE Conference on Computer Vision and Pattern Recognition, June 20-25, 2011, Colorado Springs, CO, USA. New York: IEEE Press, 2011: 329-336.
- [48] Llull P, Liao X J, Yuan X, et al. Coded aperture compressive temporal imaging[J]. *Optics Express*, 2013, 21(9): 10526-10545.
- [49] Koller R, Schmid L, Matsuda N, et al. High spatio-temporal resolution video with compressed sensing[J]. *Optics Express*, 2015, 23(12): 15992-16007.
- [50] Yang P H, Kong L H, Liu X Y, et al. Shearlet enhanced snapshot compressive imaging[J]. *IEEE Transactions on Image Processing*, 2020, 29: 6466-6481.
- [51] Liu Y, Yuan X, Suo J L, et al. Rank minimization for snapshot compressive imaging[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2019, 41(12): 2990-3006.
- [52] Boyd P S, Parikh N, Chu E, et al. Distributed optimization and statistical learning via the alternating direction method of multipliers[J]. *Foundations and Trends® in Machine Learning*, 2010, 3(1): 128.
- [53] Yuan X, Jiang H, Huang G, et al. SLOPE: shrinkage of local overlapping patches estimator for lensless compressive imaging[J]. *IEEE Sensors Journal*, 2016, 16(22): 8091-8102.
- [54] Metzler C A, Maleki A, Baraniuk R G. From denoising to compressed sensing[J]. *IEEE Transactions on Information Theory*, 2016, 62(9): 5117-5144.
- [55] Yuan X, Llull P, Liao X J, et al. Low-cost compressive sensing for color video and depth[C]//2014 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2014, Columbus, OH, USA. New York: IEEE Press, 2014: 3318-3325.
- [56] Yuan X. Generalized alternating projection based total variation minimization for compressive sensing[C]//2016 IEEE International Conference on Image Processing (ICIP), September 25-28, 2016, Phoenix, AZ, USA. New York: IEEE Press, 2016: 2539-2543.
- [57] Yang J B, Liao X J, Yuan X, et al. Compressive sensing by learning a Gaussian mixture model from measurements [J]. *IEEE Transactions on Image Processing*, 2015, 24(1): 106-119.
- [58] Yang J B, Yuan X, Liao X J, et al. Video compressive sensing using Gaussian mixture models[J]. *IEEE Transactions on Image Processing*, 2014, 23(11): 4863-4878.
- [59] Renna F, Wang L M, Yuan X, et al. Classification and reconstruction of high-dimensional signals from low-dimensional features in the presence of side information [J]. *IEEE Transactions on Information Theory*, 2016, 62(11): 6459-6492.
- [60] Yuan X, Tsai T H, Zhu R Y, et al. Compressive hyperspectral imaging with side information[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2015, 9(6): 964-976.
- [61] Qiao M, Meng Z Y, Ma J W, et al. Deep learning for video compressive sensing[J]. *APL Photonics*, 2020, 5(3): 030801.
- [62] Zhang B, Yuan X, Deng C, et al. End-to-end snapshot compressed super-resolution imaging with deep optics[J]. *Optica*, 2022, 9(4): 451-454.
- [63] Cai Y H, Zheng Y X, Lin J, et al. Binarized spectral compressive imaging[EB/OL]. (2023-05-17) [2023-11-12]. <https://arxiv.org/abs/2305.10299>.
- [64] Xu P, Liu L, Zheng H F, et al. Degradation-aware dynamic fourier-based network for spectral compressive imaging[J]. *IEEE Transactions on Multimedia*: 1-13 [2023-11-12]. <https://ieeexplore.ieee.org/document/10214675>.
- [65] Cheng Z H, Lu R Y, Wang Z J, et al. BIRNAT: bidirectional recurrent neural networks with adversarial training for video snapshot compressive imaging[M]//Vedaldi A, Bischof H, Brox T, et al. *Computer vision-ECCV 2020. Lecture notes in computer science*. Cham: Springer, 2020, 12369: 258-275.
- [66] Cheng Z H, Chen B, Liu G L, et al. Memory-efficient network for large-scale video compressive sensing[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 20-25, 2021, Nashville, TN, USA. New York: IEEE Press, 2021: 16241-16250.
- [67] Li L G, Wang L Z, Song W T, et al. Quantization-aware deep optics for diffractive snapshot hyperspectral imaging[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 18-24, 2022, New Orleans, LA, USA. New York: IEEE Press, 2022: 19748-19757.
- [68] Hu X W, Cai Y H, Lin J, et al. HDNet: high-resolution dual-domain learning for spectral compressive imaging [C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 18-24, 2022, New Orleans, LA, USA. New York: IEEE Press, 2022: 17521-17530.
- [69] Meng Z Y, Ma J W, Yuan X. End-to-end low cost compressive spectral imaging with spatial-spectral self-attention[M]//Vedaldi A, Bischof H, Brox T, et al. *Computer vision-ECCV 2020. Lecture notes in computer*

- science. Cham: Springer, 2020, 12368: 187-204.
- [70] Cai Y H, Lin J, Hu X W, et al. Mask-guided spectral-wise transformer for efficient hyperspectral image reconstruction[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 18-24, 2022, New Orleans, LA, USA. New York: IEEE Press, 2022: 17481-17490.
- [71] Cai Y H, Lin J, Hu X W, et al. Coarse-to-fine sparse transformer for hyperspectral image reconstruction[M]//Avidan S, Brostow G, Cissé M, et al. Computer vision-ECCV 2022. Lecture notes in computer science. Cham: Springer, 2022, 13677: 686-704.
- [72] Xue Y J, Zheng S M, Tahir W, et al. Block modulating video compression: an ultra low complexity image compression encoder for resource limited platforms[EB/OL]. (2022-05-07)[2023-11-12]. <https://arxiv.org/abs/2205.03677>.
- [73] Meng Z Y, Jalali S, Yuan X. GAP-net for snapshot compressive imaging[EB/OL]. (2020-12-13)[2032-11-12]. <https://arxiv.org/abs/2012.08364>.
- [74] Zheng S M, Yuan X. Unfolding framework with prior of convolution-transformer mixture and uncertainty estimation for video snapshot compressive imaging[EB/OL]. (2023-06-20)[2023-11-12]. <https://arxiv.org/abs/2306.11316>.
- [75] Zhao Y P, Zheng S M, Yuan X. Deep equilibrium models for video snapshot compressive imaging[EB/OL]. (2022-01-18)[2023-11-12]. <https://arxiv.org/abs/2201.06931>.
- [76] Yang Y, Sun J, Li H B, et al. Deep ADMM-Net for compressive sensing MRI[C]//Advances in Neural Information Processing Systems 29: Annual Conference on Neural Information Processing Systems 2016, December 5-10, 2016, Barcelona, Spain. Canada: NIPS, 2016: 10-18.
- [77] Ma J W, Liu X Y, Shou Z, et al. Deep tensor ADMM-net for snapshot compressive imaging[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV), October 27 - November 2, 2019, Seoul, South of Korea. New York: IEEE Press, 2020: 10222-10231.
- [78] Yuan X, Liu Y, Suo J L, et al. Plug-and-play algorithms for large-scale snapshot compressive imaging[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 1444-1454.
- [79] Wu Z, Zhang J, Mou C. Dense deep unfolding network with 3D-CNN prior for snapshot compressive imaging [C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV), October 10-17, 2021, Montreal, QC, Canada. New York: IEEE Press, 2022: 4872-4881.
- [80] Wang L Z, Sun C, Zhang M Q, et al. DNU: deep non-local unrolling for computational spectral imaging[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 1658-1668.
- [81] Wang L Z, Sun C, Fu Y, et al. Hyperspectral image reconstruction using a deep spatial-spectral prior[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE Press, 2020: 8024-8033.
- [82] Huang T, Dong W S, Yuan X, et al. Deep Gaussian scale mixture prior for spectral compressive imaging[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 20-25, 2021, Nashville, TN, USA. New York: IEEE Press, 2021: 16211-16220.
- [83] Cai Y H, Lin J, Wang H Q, et al. Degradation-aware unfolding half-shuffle transformer for spectral compressive imaging[EB/OL]. (2022-05-20)[2023-11-12]. <https://arxiv.org/abs/2205.10102>.
- [84] Wang P, Yuan X. SAUNet: spatial-attention unfolding network for image compressive sensing[C]//Proceedings of the 31st ACM International Conference on Multimedia, October 29-November 3, 2023, Ottawa ON, Canada. New York: ACM Press, 2023: 5099-5108.
- [85] Wu Z L, Yang C S, Su X F, et al. Adaptive deep PnP algorithm for video snapshot compressive imaging[J]. International Journal of Computer Vision, 2023, 131(7): 1662-1679.
- [86] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.
- [87] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [88] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[C]//Proceedings of the 31st International Conference on Neural Information Processing Systems, December 4-9, 2017, Long Beach, California, USA. New York: ACM Press, 2017: 6000-6010.
- [89] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks[J]. Communications of the ACM, 2020, 63(11): 139-144.
- [90] Zuo Y, Li B H, Zhao Y J, et al. All-optical neural network with nonlinear activation functions[J]. Optica, 2019, 6(9): 1132-1137.
- [91] 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.
- [92] Li J X, Meng D, Luo Y, et al. Class-specific differential detection in diffractive optical neural networks improves inference accuracy[J]. Advanced Photonics, 2019, 1(4): 046001.
- [93] Yan T, Wu J M, Zhou T K, et al. Fourier-space diffractive deep neural network[J]. Physical Review Letters, 2019, 123(2): 023901.
- [94] Shen Y C, Harris N C, Skirlo S, et al. Deep learning with coherent nanophotonic circuits[J]. Nature Photonics, 2017, 11(7): 441-446.
- [95] Zhu H H, Zou J, Zhang H, et al. Space-efficient optical computing with an integrated chip diffractive neural network[J]. Nature Communications, 2022, 13: 1044.

- [96] Fu T Z, Zang Y B, Huang Y Y, et al. Photonic machine learning with on-chip diffractive optics[J]. *Nature Communications*, 2023, 14: 70.
- [97] Cui T J, Qi M Q, Wan X, et al. Coding metamaterials, digital metamaterials and programmable metamaterials [J]. *Light: Science & Applications*, 2014, 3(10): e218.
- [98] Liu C, Ma Q, Luo Z J, et al. A programmable diffractive deep neural network based on a digital-coding metasurface array[J]. *Nature Electronics*, 2022, 5(2): 113-122.
- [99] Williamson I A D, Hughes T W, Minkov M, et al. Reprogrammable electro-optic nonlinear activation functions for optical neural networks[J]. *IEEE Journal of Selected Topics in Quantum Electronics*, 2020, 26(1): 7700412.
- [100] Vandoorne K, Dierckx W, Schrauwen B, et al. Toward optical signal processing using photonic reservoir computing [J]. *Optics Express*, 2008, 16(15): 11182-11192.
- [101] Vandoorne K, Dambre J, Verstraeten D, et al. Parallel reservoir computing using optical amplifiers[J]. *IEEE Transactions on Neural Networks*, 2011, 22(9): 1469-1481.
- [102] Mesaritakis C, Papataxiarhis V, Syvridis D. Micro ring resonators as building blocks for an all-optical high-speed reservoir-computing bit-pattern-recognition system[J]. *Journal of the Optical Society of America B*, 2013, 30(11): 3048-3055.
- [103] Rosenbluth D, Kravtsov K, Fok M P, et al. A high performance photonic pulse processing device[J]. *Optics Express*, 2009, 17(25): 22767-22772.
- [104] 李维, 刘勋, 张维畅, 等. 天基边缘智能光学遥感技术构想[J]. *航天返回与遥感*, 2022, 43(4): 1-11.
- Li W, Liu X, Zhang W C, et al. Space based edge intelligent remote sensing[J]. *Spacecraft Recovery & Remote Sensing*, 2022, 43(4): 1-11.
- [105] 张飞, 陈小前, 于帅, 等. 基于天基边缘计算的在轨智能技术[J]. *上海航天(中英文)*, 2021, 38(4): 19-24.
- Zhang F, Chen X Q, Yu S, et al. On-orbit artificial intelligence based on space edge computing[J]. *Aerospace Shanghai (Chinese & English)*, 2021, 38(4): 19-24.
- [106] Gunasheela K S, Prasantha H S. Satellite image compression-detailed survey of the algorithms[M]//Guru D S, Vasudev T, Chethan, et al. *Proceedings of international conference on cognition and recognition. Lecture notes in computer science*. Singapore: Springer, 2018, 14: 187-198.
- [107] Hussain A J, Al-Fayadh A, Radi N. Image compression techniques: a survey in lossless and lossy algorithms[J]. *Neurocomputing*, 2018, 300: 44-69.
- [108] Liu S Y, Deng W H. Very deep convolutional neural network based image classification using small training sample size[C]//2015 3rd IAPR Asian Conference on Pattern Recognition (ACPR), November 3-6, 2015, Kuala Lumpur, Malaysia. New York: IEEE Press, 2016: 730-734.
- [109] Dosovitskiy A, Beyer L, Kolesnikov A, et al. An image is worth 16×16 words: transformers for image recognition at scale[EB/OL]. (2020-10-22)[2023-11-12]. <https://arxiv.org/abs/2010.11929>.
- [110] Qian G W, Xu X Q, Zhu S, et al. Quantum induced coherence light detection and ranging[J]. *Physical Review Letters*, 2023, 131(3): 033603.