

中国激光

光蓄水池神经网络研究进展

杨凌雁, 张林*

天津大学精密仪器与光电子工程学院, 天津 300072

摘要 相较于电神经网络, 光神经网络有着速度快、功耗低等优点, 逐渐引起了人们的研究兴趣。光蓄水池神经网络是光循环神经网络的一种, 适用于处理时序数据, 对网络的训练过程比较简单。介绍了蓄水池神经网络的架构、特点以及实现蓄水池需要满足的条件。从具体硬件入手, 以串行结构和并行结构两种构建方式进行分类, 介绍了光蓄水池神经网络的研究进展。最后分析了当前光蓄水池神经网络存在的问题以及解决方案, 并对其未来发展进行了展望。

关键词 光计算; 蓄水池计算; 神经网络; 光波导; 谐振腔

中图分类号 O436 文献标志码 A

doi: 10.3788/CJL202148.1906001

1 引言

人工神经网络是一种模仿人脑工作方式, 依靠各层神经元之间的连接进行信息处理的系统。神经网络能够对大量数据进行分析, 并且在输入信息不完整或部分信息不正确的情况下, 也能完成所要求的任务。近年来, 神经网络被广泛应用于语音识别、图像处理、自动驾驶等热门领域, 有着广阔的应用前景。

目前, 神经网络的实现载体以集成电路芯片为主, 然而, 电神经网络在发展的过程中表现出一些局限性^[1-3]。1) 为了提高分析和处理的能力, 人工神经网络向着增大规模、增加复杂性的方向发展, 同时所需处理的数据量也急剧增加, 这对芯片的性能提出了更高的要求, 传统的电学芯片无法满足需要。虽然出现了一些新型结构, 如图形处理单元(GPU)、现场可编程逻辑门阵列(FPGA)以及专用集成电路(ASIC)等, 但是其计算能力的提升仍然需要依靠微电子集成度的提高。随着摩尔定律的逐渐失效, 芯片的最大规模集成变得困难, 并且由 7 nm 延伸到 5 nm 和 3 nm 技术节点所带来的性能提升幅度是有限的, 这些阻碍了电神经网络处理能力的进一步提升。2) 集成电路芯片大多采用冯·诺依曼结构, 数据储存区域与计算区域分离。在计算过程中, 数据需要在储存区域和计算区域之间移动, 形成

大量潮汐载荷, 不仅影响处理速度, 还会增加额外能耗。虽然已有基于忆阻器在电学领域突破冯·诺依曼结构的方案, 但是目前忆阻器有着器件性能不稳定、相关集成工艺不成熟等问题, 利用忆阻器实现大规模神经网络仍然存在挑战。3) 电路中的串扰、噪声和发热会影响神经网络性能, 阻碍进一步的集成和规模扩展, 同时导致较大的功耗。

在这种情况下, 以光作为信息载体的光神经网络逐渐引起了人们的兴趣。20世纪八九十年代, 利用光学或光电混合方式实现神经网络中的神经元互连、矩阵乘法、训练算法、联想记忆等得到广泛研究。然而, 当时人们对人工神经网络的优越性认识不足, 且电学芯片的瓶颈尚未凸显, 当时的光神经网络又存在器件体积较大、难以扩展、非线性实现困难等问题, 因此研究逐渐停滞^[3]。近年来, 随着集成光子学的迅速发展, 微纳光子器件能够实现片上大规模集成和量产, 复杂光路的构建成为可能。同时, 电学芯片难以满足当前神经网络的算力要求, 在光学领域构建神经网络的优点逐渐显现。这些使得光神经网络再次走入人们的视线。

与电神经网络相比, 光神经网络具有以下优势^[2-5]。1) 计算速度快。在光神经网络中, 光通过在特殊设计的片上结构中传输实现所需功能, 其传播速度接近真空中的光速, 传输完成即结束计算, 因

收稿日期: 2021-07-21; 修回日期: 2021-08-16; 录用日期: 2021-09-02

通信作者: *lin_zhang@tju.edu.cn

此在运算速率上占有优势。2) 并行性高。光神经网络可以通过波分复用、偏振复用、模式复用等多种方式, 获得很高的并行计算能力。3) 功耗低。光神经网络中的相当一部分功能可通过无源器件实现, 训练完成后就不再需要为其额外提供能量, 且使用光波作为载体也不易出现电神经网络中的发热问题, 所以网络消耗功率相对较少。4) 存算一体的可能性。光神经网络的设计可突破冯·诺依曼架构, 不需要在分隔开的储存区域和计算区域之间移动数据, 能够进一步提升处理效率、降低功耗。电神经网络对存算一体的探索也处于起步阶段, 因此利用光学实现存算一体有着相当大的竞争力。5) 抗电磁干扰能力强。光芯片往往具有很高的折射率对比度, 载波频率高达百 THz 的光场不易受到外部环境电磁干扰。

2 蓄水池神经网络简介

目前提出的光神经网络典型模型可以分为前馈神经网络、循环神经网络、脉冲神经网络三种^[1]。在

前馈神经网络中, 信息从输入层到输出层单向传递。光学领域研究较多的前馈神经网络是多层感知器和卷积神经网络, 多层感知器中每个神经元都与相邻层的神经元一一完全连接, 而卷积神经网络中为不完全连接。循环神经网络内部除了从前到后的单向前馈连接外, 还存在每层内部神经元之间的互连, 或从后到前的反馈连接。脉冲神经网络又被称为第三代人工神经网络, 其内部神经元的工作方式更加接近生物学模型, 当输入达到阈值时, 神经元才被激活, 输出一个脉冲信号。

与前馈神经网络相比, 循环神经网络因为内部反馈回路的存在, 具有记忆和联想的能力, 可用于时序信息处理。蓄水池神经网络是循环神经网络的一种, 它由回声状态网络 (Echo State Networks, ESNs)^[6] 和液体状态机 (Liquid State Machines, LSMs)^[7] 发展而来。2007 年, Verstraeten 等^[8] 证明这两种网络有着相同的性质, 并将其统一称为蓄水池 (reservoir)。蓄水池神经网络的内部结构如图 1 所示。

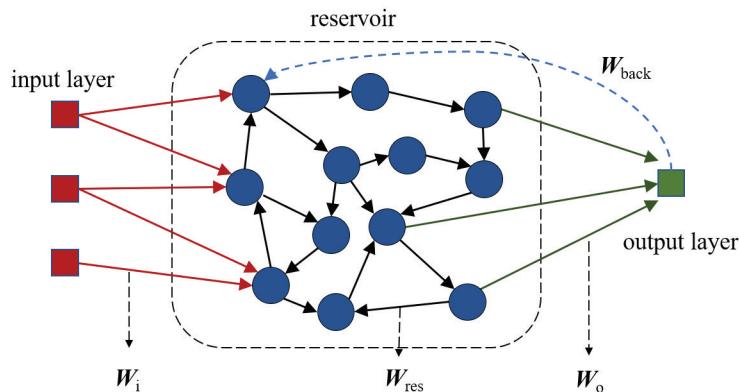


图 1 蓄水池神经网络示意图

Fig. 1 Schematic of general reservoir neural network

蓄水池神经网络由三层神经元构成, 分别为输入层、中间层和输出层, 中间层也被称为蓄水池^[9]。蓄水池层是整个神经网络中最复杂也是最重要的部分, 其内部神经元的互连有着“稀疏、随机且固定”的特点^[5]: 稀疏是指蓄水池层内的一个神经元不需要与其他神经元一一完全连接; 随机是指不需要特意为蓄水池内部神经元设计互连架构, 实际上, 蓄水池内部的连接状态可以是未知的; 固定是指在蓄水池训练过程中, 不需要改变其内部神经元的互连权值。蓄水池的这些特点充分模拟了人类大脑中生物神经元的互连方式和动态特性^[7]。因为其内部连接的稀疏和随机性, 蓄水池神经网络可以在多种物理硬件上制作, 已经有在电学^[10]、光学、自旋电子^[11]、机

械^[12]等领域实现蓄水池的方案。

蓄水池神经网络工作时, 待处理信号经输入权重矩阵 \mathbf{W}_i 加权后进入蓄水池, 蓄水池层内部神经元之间的互连权值矩阵为 \mathbf{W}_{res} , 输出层选取蓄水池层的部分神经元, 以输出权重矩阵 \mathbf{W}_o 对它们的状态进行加权求和, 得到结果。蓄水池内部神经元状态的更新过程以及蓄水池输出的求取可表示为

$$\mathbf{x}(t + \Delta t) = f_{\text{NL},1} [\mathbf{W}_i \mathbf{u}(t + \Delta t) + \mathbf{W}_{\text{res}} \mathbf{x}(t) + \mathbf{W}_{\text{back}} \mathbf{y}(t)], \quad (1)$$

$$\mathbf{y}(t + \Delta t) = \mathbf{W}_o f_{\text{NL},2} [\mathbf{x}(t + \Delta t)], \quad (2)$$

式中: \mathbf{x} 为节点状态; \mathbf{u} 为蓄水池输入; \mathbf{y} 为水池输出; \mathbf{W}_{back} 为从输出到输入的反馈权重矩阵, 该反馈在蓄水池神经网络中不是必须的; f_{NL} 为非线性函

数,非线性可以由蓄水池层内部的神经元提供(f_{NL1}),也可以由输出层提供(f_{NL2})。

在训练蓄水池神经网络的过程中,只需要调整输出矩阵 \mathbf{W}_o ,输入矩阵 \mathbf{W}_i 和内部互连权值矩阵 \mathbf{W}_{res} 可以保持固定不变。传统的循环神经网络训练依靠基于时间的反向传播(BPTT)算法,过程复杂,可能会遇到梯度消失或梯度爆炸等问题^[13]。与之相比,蓄水池神经网络只需要对输出矩阵进行线性回归训练,利用最小二乘^[14]、岭回归^[15]等算法,就可实现相应功能,具有简单快速的优点^[16]。

为了能够快速、准确地处理信息,实现神经网络的功能,蓄水池需要满足以下条件^[17]。

1) 高维空间与非线性:蓄水池需要将输入信号非线性地映射到高维空间,使原本不可分的数据变得线性可分。

2) 衰落记忆:蓄水池某一时刻的输出不仅与当前的输入有关,还受到过去一段时间内输入信号的影响,这种影响随时间逐渐减弱。

3) 近似性和分离性:蓄水池应该对相似的信号有近似的响应,而对于不同的输入信号,输出信号要有较大的差异。

为了满足上述条件,在没有外界输入的情况下,蓄水池需要运行在稳态边缘;被外部信号激发时,蓄

水池内要能够表现出复杂的动态^[18]。

3 光蓄水池神经网络的具体实现

光蓄水池神经网络有两种不同的构建方案,称为并行结构和串行结构^[1]。并行结构中的每个神经元节点都用一个光电子器件搭建,节点以一定拓扑结构互连实现神经网络。串行结构依靠单个非线性光电子节点和一条时延反馈回路实现蓄水池。下面详细介绍这两种系统架构的研究现状。

3.1 并行结构

并行结构通过内部大量光电子节点的互连实现蓄水池神经网络,其结构如图 1 所示。

最早的并行结构光蓄水池模型是比利时根特大学的 Vandoorne 等^[19]在 2008 年提出的,该模型以半导体光放大器(SOA)作为神经网络的节点。SOA 具有丰富的内部动态,且其增益容易饱和的特点可以为神经网络提供非线性。SOA 的能量传递曲线与双曲正切函数上半部分相似,如图 2 所示,而双曲正切函数是基于软件的传统蓄水池常用的非线性节点。对由 5×5 个 SOA 节点构成的蓄水池进行仿真,执行模式识别任务,成功区分了以 0.5 GHz 频率输入的三角波和方波,误码率最低可达 2.5%,性能略优于当时基于软件的蓄水池。

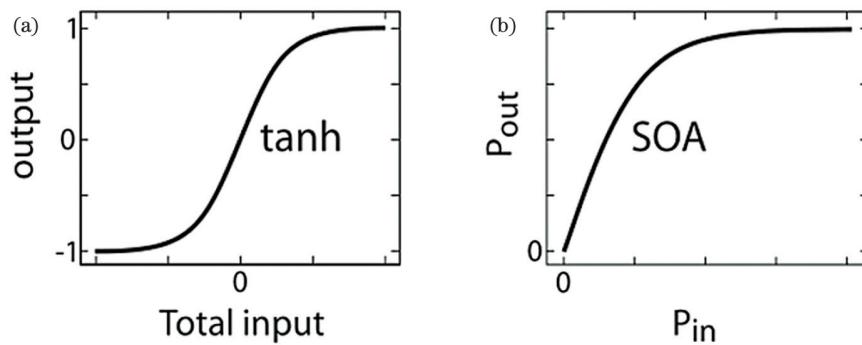


图 2 非线性函数曲线^[19]。(a)双曲正切函数;(b) SOA 稳态能量传递函数

Fig. 2 Curves of nonlinear functions^[19]. (a) Tanh function; (b) steady state power transfer function of SOA

在芯片上构建光蓄水池时,因为是在二维空间排布器件,需要避免波导交叉,同时又要保证光在蓄水池内充分流动。2011 年,Vandoorne 等^[20]提出了一种被称为旋涡拓扑(Swirl Topology)结构的节点互连方案。该方案的具体实现如图 3 所示,阵列中的每一个节点都与其相邻的节点双向互连,信息流动方向绕网络中心旋转(图 3 中显示了顺时针流动的情形)。对以该方式连接的拥有 9×9 个节点的 SOAs 网络进行仿真,完成了孤立语音数字识别任务,准确率略优于当时基于软件的蓄水池。

虽然使用 SOA 作为节点,可得到比基于软件的蓄水池更好的性能,但由于需要为 SOA 提供电压,神经网络功耗相对较高,难以发挥光神经网络的固有优势,同时 SOA 的制作也比较复杂^[21]。为了克服这些缺点,人们提出了构建无源光蓄水池的方案。2013 年,希腊雅典大学的 Mesaritakis 等^[22]使用微环谐振腔构建光蓄水池。该蓄水池中的每个节点都是一个 add/drop 微环,蓄水池部分是完全无源的,系统中的非线性来自微环内部的双光子吸收和克尔效应。节点之间连接成带反馈的瀑布拓扑

(waterfall topology)结构,如图 4 所示,首先从第一个节点向后连接成前馈网络,然后随机选取部分节点,在阵列外侧引出反馈波导。仿真证明,利用有 5×5 个微环节点的蓄水池对三位数字信号进行分

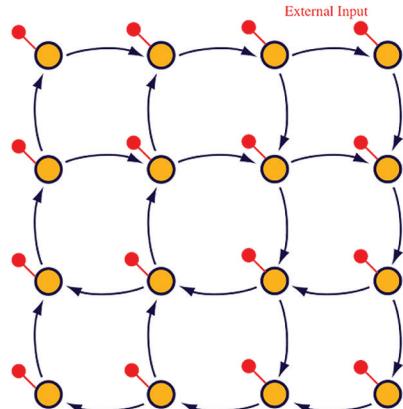


图 3 旋涡拓扑结构^[20]

Fig. 3 Swirl topology^[20]

2014 年,Vandoorne 等^[21]利用无源线性波导网路构建了并行结构光蓄水池。该蓄水池仅由片上低损耗波导、光分束器和光合束器构成,结构如图 5 所示。系统中的非线性由用于读取节点状态的光电探测器的平方非线性引入。实际制作出的蓄水池共有 4×4 个节点,总面积为 16 mm^2 。该蓄水池可以实

类,错误率可低至 0.1%;对八位数字信号进行分类,错误率为 0.5%。该蓄水池在注入光信号功率为 10 mW 的情况下就可以运行,并且不需要额外的能量驱动。

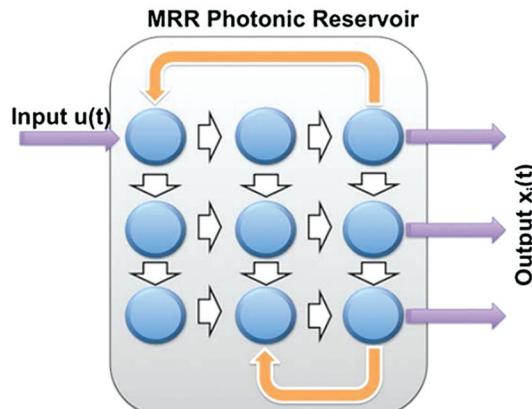


图 4 带反馈的瀑布拓扑结构^[22]

Fig. 4 Waterfall topology with feedback loop^[22]

现布尔异或运算,错误率低至 0.01%,还可以完成不超过五位的分组头识别任务。该蓄水池处理数据的速率为 12.5 Gbit/s,这是由节点间的螺旋形波导可提供的时延决定的,如果去除时延波导,处理速度可以达到几百 Gbit/s。

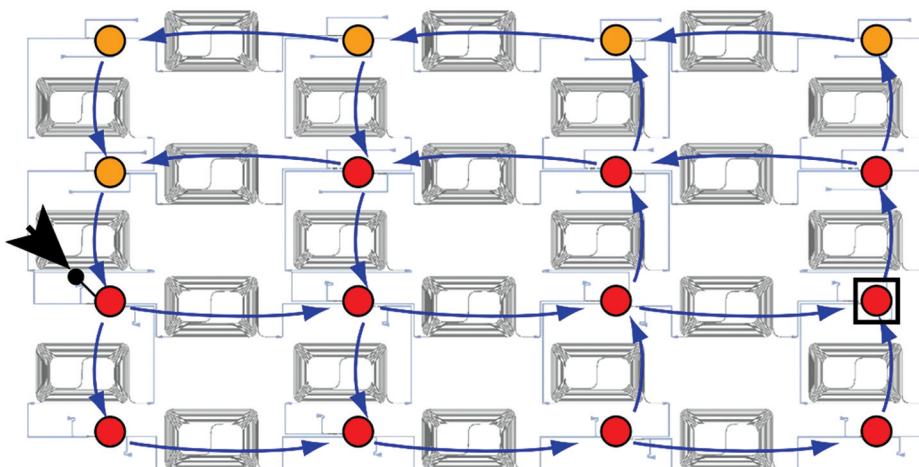


图 5 16 节点无源光蓄水池^[21]

Fig. 5 16-node passive photonic reservoir^[21]

除了采用片上光学器件阵列实现并行结构光蓄水池外,还有一些特殊的构建方案。2018 年,比利时根特大学的 Laporte 等^[23]提出了一种利用单个光子晶体腔实现蓄水池的方案。如图 6 所示,光子晶体腔为四分之一体育场形状,腔面积为 $1800 \mu\text{m}^2$,蓄水池总面积小于 0.01 mm^2 。蓄水池工作时信号从一个缺陷处输入,在腔内发生复杂的作用;在其余六个缺陷处用光电探测器读出光强,根

据输出权重矩阵加权求和得到结果。仿真可知,该结构能够完成布尔异或和分组头识别任务。光子晶体腔的高 Q 值低损耗可以提升蓄水池性能、降低功耗,且面积小,利于集成和规模扩展。

除了集成光学外,还有利用空间光构建并行结构光蓄水池的方案。2015 年, Brunner 等^[24]发现,借助衍射光学元件(DOE)可以实现二维半导体激光器阵列中不同激光器之间的耦合。2018 年,该团队在此

基础上构建了蓄水池^[25-26],结构如图 7 所示,空间光调制器(SLM)将待处理信号调制到激光器发出的光上,SLM 的每个像素都是一个节点。被 SLM 某一像素调制的光经过衍射光学元件(DOE)后,会传播到其他像素所在的位置,相当于实现了节点之间的连接,

衍射后的光由显微物镜(MO)成像到相机上,再根据相机的探测值控制 SLM,实现反馈。输出层权值由数字微镜阵列(DMD)进行设置,通过强化学习训练,在读出节点数为 900 的情况下,蓄水池可实现对 Mackey-Glass 混沌序列的预测,归一化均方根误差低至 0.042。

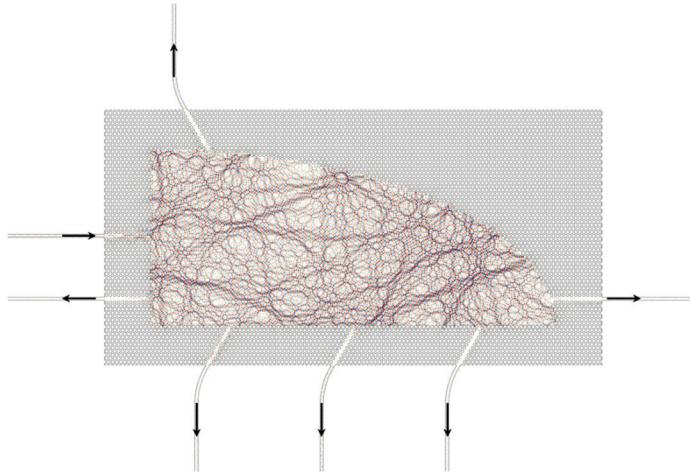


图 6 基于单个光子晶体腔的蓄水池^[23]

Fig. 6 Reservoir based on single photonic crystal cavity^[23]

2020 年,法国索邦大学的 Dong 等^[27-28]利用光在介质中的散射构建并行结构光蓄水池,如图 8 所示,SLM 调制输入光,物镜 O1 将携带信号的光投射在散射介质(SM)上,通过复杂的散射过程实现蓄水池中神经元的互连,干涉形成的散斑图通过物镜 O2 成像在相机上,选取相机上部分像素点读取探测值,进行加权求

和得到输出结果。同时,相机的探测值又和输入信号一起控制 SLM,实现反馈。DMD 也可用于输入信号的调制,虽然只能将信号二值化,但可达到比应用 SLM 的蓄水池更高的信息处理速度。同年,Paudel 等^[29]利用多模光纤代替散射介质产生散斑图,实现了基于空间光的蓄水池,散斑图由光纤中不同模式的干涉形成。

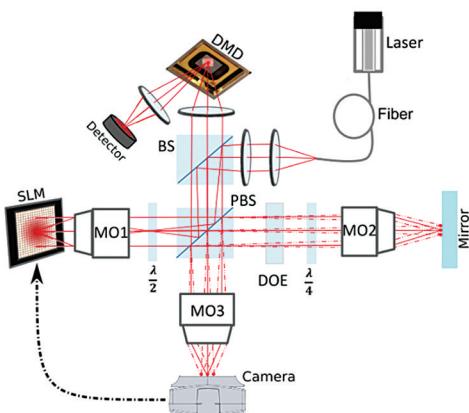


图 7 空间光衍射蓄水池^[26]

Fig. 7 Diffractively coupled spatial-light reservoir^[26]

利用空间光学更容易实现大规模高并行性的光蓄水池,然而这类蓄水池容易受到外部环境(比如气流、温度波动或振动等)的干扰,导致性能受到影响。Paudel 等^[29]也通过理论分析证明了用片上多模波导的模场干涉实现蓄水池的可行性,这种方案有利于提高集成度,减少外界干扰。

并行结构光蓄水池架构的性能总结如表 1 所

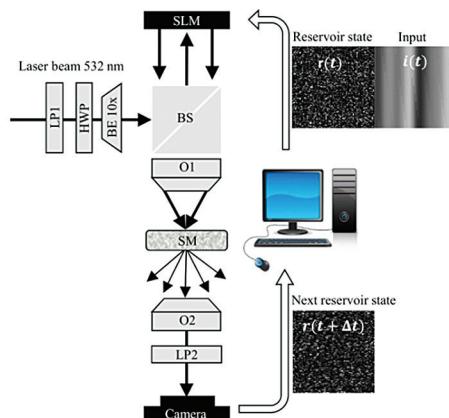


图 8 空间光散射蓄水池^[28]

Fig. 8 Spatial-light reservoir based on scattering^[28]

示,其中蓄水池规模为节点数。目前国内还没有比较系统的并行结构研究。

在研究初期,并行结构光蓄水池的规模有限,所讨论的应用复杂性相对较低,更多集中在原理性验证,近几年的最新工作逐渐转向更为实用的应用场景,但所获得的性能相比电计算仍显不足。

表1 并行结构光蓄水池的性能比较

Table 1 Performance comparison among parallel optical reservoirs

Institute	Publication time	Implementation	Node type	Nonlinearity mechanism	Optical delay	Reservoir size	Benchmark testing	Input signal power	Simulation/experiment
Ghent University [19]	2008	All-optical	SOAs	SOA gain saturation	Delay between nodes is 6.25 ps	25	Signal classification of triangular wave and rectangular wave, error rate (ER) is 2.5%	5 mW	Simulation
Ghent University [20]	2011	All-optical	SOAs	SOA gain saturation	Delay between nodes is 6.25 ps	81	Speech recognition, ER is 4.5%	-	Simulation
University of Athens [22]	2013	All-optical	InGaAsP/InP MRRs	Nonlinearity in MRRs	Delay between nodes is 50 fs to 4.5 ps	25	Digital word classification, ER is 0.1% for 3 bit signal, ER is 0.5% for 8 bit signal	10 mW	Simulation
Ghent University [21,30]	2014	All-optical	Waveguides	Nonlinear photonic conversion in detectors	Delay between nodes is 280 ps	16	Boolean XOR task, bit error rate (BER) is 0.01%; 5-bit header recognition	15 mW	Experiment
Ghent University [31]	2014	All-optical	Nanophotonic crystal cavities	-	-	200	Nonlinear channel equalization in single-wavelength metro and high-speed short-reach links, BER is <0.2%	15 mW	Simulation
Ghent University [23]	2018	All-optical	Single photonic crystal cavity	Nonlinear photonic conversion in detectors	Q-factor of photonic crystal cavity is 16400	6	Signal generation task, normalized root-mean-square error (NRMSE) is 0.03	-	Simulation
Sorbonne Université Paris Saclay & Université de Lorraine [32]	2018	All-optical	Silicon MRRs	Nonlinearity in MRRs	-	16	Boolean XOR task, BER is <0.1%; Boolean tasks, BER is <0.1%; 6-bit header recognition, BER is <0.1%	1 mW	Simulation
University Bourgogne Franche-Comté [25]	2018	Optoelectronic	Pixels of SLM, interconnected by diffraction	Filtering by polarizing beam splitter	-	300 (output layer)	Mackey-Glass chaotic time serie prediction, NRMSE is 0.042	-	Experiment
Sorbonne University [27]	2020	Optoelectronic	Pixels of SLM, interconnected by scattering	Nonlinear photonic conversion in detectors	-	4096	MG chaotic time serie prediction	-	Experiment
The Aerospace Corporation [29]	2020	Optoelectronic	Pixels of SLM, interconnected by mode interference	Nonlinear photonic conversion in detectors	-	200 (output layer)	Speaker identification, accuracy is 98.1%	-	Simulation
University of Athens [33]	2021	All-optical	MRRs	Nonlinear conversion of phase modulated inputs to amplitude modulated outputs in MRRs	Delay between nodes is 3 ps to 8 ps	30	Dispersion compensation of PAM-4 signal, BER is <0.1%	-	Experiment

3.2 串行结构

并行结构需要大量光电子器件作为节点,对制造提出了较高的要求。2011 年,西班牙巴利阿里群岛大学的 Appeltant 等^[34]提出了一种依靠单个光电子器件和一条具有时延反馈功能的回路实现光电混合蓄水池的方案,称为串行结构。相对于并行结构,串行结构只需要单个非线性元件,制造简单,容易实现。当前的光蓄水池神经网络研究也以串行结构为主。然而,串行结构光蓄水池本质上是对单个元件进行时分复用,得到多个“虚拟节点”执行运算,处理速度和并行性相对较差^[34]。

串行结构蓄水池^[9]如图 9 所示,它对信号的处理过程如下。首先,使用输入矩阵 W_i 对待处理时序信号中的每一位进行掩模(masking)处理,增加输入信号的复杂度,使蓄水池内部激发出更丰富的动态。掩模处理后的信号输入到非线性节点中,在元件内部激发出响应。响应进入时延线,经过时间 τ 后反回馈回非线性光学元件(NL),形成闭合环路。使用单个探测器以一定时间间隔读取时延线中的信

号,称读取出的数据为虚拟节点(virtual nodes)的状态。

设 τ' 为输入层的掩模周期以及每位信号的保持时间,蓄水池中虚拟节点的个数为 N ,虚拟节点之间的时间间隔为 θ ,有 $\tau' = N \cdot \theta$ 。依据 τ 与 τ' 是否相等,可以分为两种输入方案^[35]。若蓄水池中存在时间常数,则采用 $\tau = \tau'$,称为对称方案。蓄水池的时间常数要大于虚拟节点之间的时间间隔 θ ,保证相邻的虚拟节点相互耦合。若蓄水池中不存在时间常数,非线性响应是即时的,采用 $\tau \neq \tau'$,称为不对称方案。在不对称方案中,取 $\tau = (N+k) \cdot \theta$, k 为小于 N 的正整数。这种方案会使第 i 个虚拟节点和第 $i+k$ 个虚拟节点耦合。不对称方案在有时间常数的蓄水池内也可实现,能够使蓄水池内部动态更加丰富。

在输出层对虚拟节点的状态逐个进行读取,并储存到计算机中,先利用一部分数据进行离线训练,通过简单的线性回归得到最佳的输出权重矩阵 W_o ,再利用输出权重矩阵对虚拟节点状态进行加权求和,执行任务。

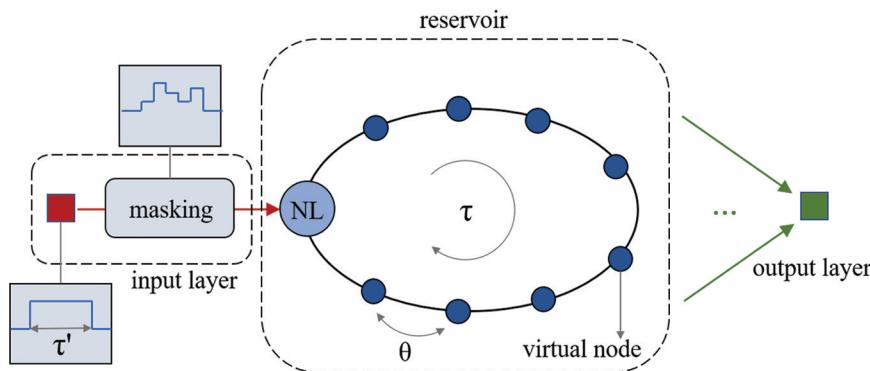


图 9 串行结构蓄水池神经网络示意图^[9]

Fig. 9 Schematic of general delay-based reservoir neural network^[9]

2012 年,比利时法语布鲁塞尔自由大学的 Paquot 等^[14]和法国弗朗什-孔泰大学的 Larger 等^[18]先后提出了光电混合的串行蓄水池实现方案。Paquot 等^[14]的蓄水池结构如图 10 所示,它以单个马赫-曾德尔调制器(MZM)作为非线性节点,待处理信号由计算机控制,从任意波形发生器(AWG)输入,通过 MZM 调制到激光器输出的连续光上,光电二极管读取时延线内的状态,输出到计算机中;同时信号也在时延线末端进入电学回路,与 AWG 的输入相加,共同控制 MZM,形成反馈;回路中的光衰减器用于调节反馈增益,使蓄水池工作在理想状态。

2012 年,Duport 等^[36]用 SOA 替代 MZM 作为节点,实现了内部无需电学回路的全光串行蓄水池,其结构如图 11 所示。系统中的非线性来自 SOA 饱

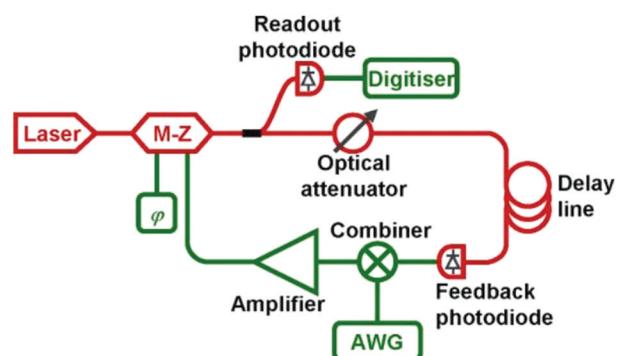


图 10 光电混合串行结构蓄水池^[14]

Fig. 10 Optoelectronic hybrid delay-based reservoir^[14] 和增益,利用该系统进行信道均衡,在信噪比为 12 dB~16 dB 的情况下,全光蓄水池性能接近光电蓄水池;信噪比较大时,性能会稍有下降。该蓄水池

也可执行孤立语音数字识别任务,但错误率为 3%,

高于光电混合蓄水池(0.4%)。

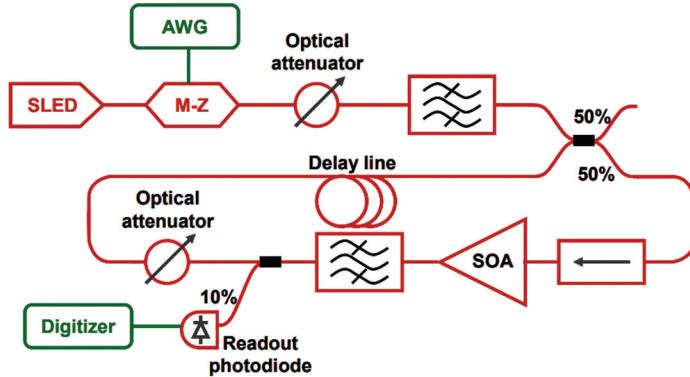


图 11 全光串行蓄水池^[36]

Fig. 11 Delay-based all-optical reservoir^[36]

在后来的研究中,半导体激光器因为在外界光信号或反馈注入的情况下能够激发出非线性,有高带宽、低功耗等优点,并且是现代光纤通信的成熟组件,所以在串行结构光蓄水池中作为非线性节点被大量使用^[37]。2016 年,日本埼玉大学的 Nakayama 等^[38]通过仿真探究了非线性节点为半导体激光器的全光串行结构蓄水池的性能,其系统简图如图 12 所示。驱动激光器(drive laser)发出的光经过调制后输入到作为非线性节点的响应激光器(response laser)中,反射镜使响应激光器发射的光重新回到其激光腔中,实现反馈。使用该蓄水池执行 Santa Fe 混沌时间序列预测,归一化均方误差(normalized

mean squared error, NMSE)低至 0.008。该研究在输入层使用了模拟信号混沌掩模,取代以前采用的数字二值掩模,发现混沌掩模可以提高蓄水池的性能。2018 年,法国洛林大学的 Vatin 等^[39]以垂直腔表面发射激光器(VCSEL)作为非线性节点,实现了串行结构光蓄水池,与传统的边发射激光器相比,VCSEL 有着高速调制能力,可以实现更快的计算^[40]。该团队利用 VCSEL 中的偏振动力学,在反馈回路中将光的偏振方向旋转 90°,再次注入激光腔,两种偏振模式耦合激发的丰富动态可以提高系统的计算能力。仿真证明,使用该蓄水池进行信道均衡实验,误码率要比单偏振模式的系统低一个数量级。

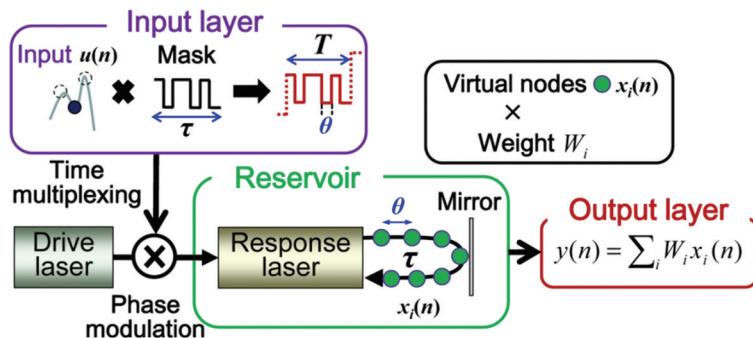


图 12 以半导体激光器为节点的串行光蓄水池^[38]

Fig. 12 Delay-based photonic reservoir with semiconductor laser as node^[38]

在国内,串行结构光蓄水池也引起了相关的研究兴趣。早在 2007 年,大连理工大学就开始了对蓄水池的相关研究^[41]。2017 年,Qin 等^[42]利用 MZM 构建串行结构光蓄水池,完成了光通信中的分组头识别任务,证明了光蓄水池在新发展起来的高带宽、低功耗光分组交换(OPS)网络中的应用潜力。2019 年,西南大学的 Hou 等^[43]在一条回路中放置两个相互延迟耦合的半导体激光器,证明可通过这种方式提高以激光器为节点的串行结构光蓄水池的性

能。2020 年,西安电子科技大学的 Guo 等^[44]利用半导体纳米激光器实现了串行结构光蓄水池,半导体纳米激光器有助于蓄水池的片上集成。2021 年,该团队又研究了具有两路相位共轭反馈的串行结构光蓄水池,使用相位共轭镜将激光器发射的光反馈回激光腔中,反射光相对于发射光的相移为零,可以获得良好的降噪效果^[45]。

串行架构光蓄水池的性能总结如表 2 所示,其中蓄水池规模为虚拟节点数。

表2 串行结构光蓄水池的性能比较
Table 2 Performance comparison among delay-based optical reservoirs

Institute	Publication time	Implementation	Node type	Nonlinearity mechanism	Optical delay	Reservoir size	Benchmark testing	Input signal power	Simulation/experiment
Université Bourgogne Franche-Comté ^[18]	2012	Optoelectronic	MZM	Electro-optic nonlinearity of MZM	Delay time of feedback loop is 20.9 μ s	400	Spoken digit recognition, ER is < 0.5%;	-	Experiment
Université Libre de Bruxelles ^[14]	2012	Optoelectronic	MZM	Electro-optic nonlinearity of MZM	Delay time is 8.5 μ s	50	Nonlinear channel equalization; signal classification of square wave and sine wave, NMSE is 0.0015	-	Simulation
Université Libre de Bruxelles ^[36]	2012	All-optical	SOA	SOA gain saturation	Delay time is 7.9 μ s	200	Speech recognition, ER is 0.4%	-	Experiment
Campus Universitat de les Illes Balears ^[37]	2013	All-optical	Semiconductor laser	Nonlinearity of laser with optical injection and feedback	Delay time is 77.6 ns	388	Spoken digit recognition, ER is 0.014%; speaker identification, ER is 0.88%;	<15 μ W	Experiment
Université Libre de Bruxelles ^[46]	2014	All-optical	Semiconductor saturable absorber mirror	Saturable absorption of semiconductor	Delay time is 8.0073 μ s	50	Nonlinear channel equalization, signal prediction	-	Experiment
Université Libre de Bruxelles ^[47]	2015	All-optical	Passive fiber cavity	Nonlinear photoelectric conversion in detector	Delay time is 1.13 μ s	200	Speech recognition, ER is 2.6%	-	Experiment
University of Saitama ^[38]	2016	All-optical	Semiconductor laser	Nonlinearity of laser with optical injection and feedback	Delay time is 40.1 ns	400	Santa Fe chaotic time serie prediction, NMSE is 0.008	-	Simulation

续表2

Institute	Publication time	Implementation	Node type	Nonlinearity mechanism	Optical delay	Reservoir size	Benchmark testing	Input signal power	Simulation/experiment
Dalian University of Technology [42]	2017	Optoelectronic	MZM	Electro-optic nonlinearity of MZM	Delay time is 9.7 ns	400	6-bit header recognition, the lowest ER is 1.25%	7 dBm, input voltage amplitude is < 2 V	
Université Paris Saclay & Université de Lorraine [39]	2018	All-optical	VCSEL	Nonlinearity of laser with optical injection and feedback; polarization mode coupling	Delay time is 0.64 ns	32	Nonlinear channel equalization, BER is 0.001 %	0.08 mW	Simulation
Southwest University [43]	2018	All-optical	Two mutually delay coupled semiconductor lasers	Nonlinearity of laser with optical injection and feedback	Delay time is 2 ns	400	Santa Fe chaotic time series prediction, NMSE is 10^{-3}	0.7 mW	
Xidian University [44]	2019	All-optical	Semiconductor nanolaser	Nonlinearity of laser with optical feedback	Delay time is 0.1 ns	200	Santa Fe chaotic time series prediction, NMSE is 5×10^{-5} ; signal classification of sine wave, and square wave, NMSE is 5×10^{-4}	-	Simulation
Université Libre de Bruxelles [48]	2019	All-optical	Single quantum cascade laser	Nonlinearity of laser with optical feedback	Delay time is 4 ns	100	Santa Fe chaotic time series prediction, the lowest NMSE is 0.036	-	Simulation
						200	Santa Fe chaotic time series prediction, NMSE is 0.006; nonlinear channel equalization, ER is 0.1 %	-	Simulation

相比于并行结构光蓄水池的构建方法,串行结构光蓄水池增加了激光器作为非线性节点的方案,激光器反馈和注入能够带来更显著的非线性效果。但因为激光器的大规模集成还比较困难,工作稳定性有待进一步提高,所以系统内的节点数(非虚拟节点数)可能会受到限制,同时激光器对宽带信号的响应也有待深入研究。

4 光蓄水池神经网络的发展方向

在谈及光计算和光神经网络的发展方向之前,值得人们注意的是,光计算概念的提出已经超过了半个世纪,包括光学傅里叶变换、光积分/微分运算、光逻辑运算和光矩阵运算等,但几乎没有光计算的技术和产品真正得以实际应用,这说明了电计算的强大生命力。尽管时至今日,微电子芯片技术中摩尔定律逐渐失效和光子芯片阵列规模不断扩大的趋势有目共睹,但仍然不可忽视的是电计算的体系架构也在不断创新,基于电子芯片的神经网络发展迅猛,算力也不断提升。因此,光计算的发展需要着眼于电计算所不擅长的方面和电计算难以持续突破的领域,才有机会获得持久的发展空间。

从长期和战略性发展的层面来讲,光神经网络的发展可以瞄准以下几个重要方面。1) 增大阵列规模。如果光计算解决的是电计算轻易即可解决的问题,电计算则极有可能在尺寸、能耗和成本方面占据优势,因此光计算的阵列规模必须足够大,或者说有发展潜力的光计算技术必须具有良好的规模可扩展性,低损耗/低功耗的光节点将成为核心。2) 提高计算精度。面向实际应用的计算技术往往需要足够的计算精度和准确性,而作为模拟计算类型之一的光计算的精度问题尚未引起研究者的足够关注。3) 力求全光操作。前述计算精度的提高往往要求阵列规模的扩大,这导致光器件的热光调谐难以避免。同时,非线性激活也可能基于光电转换、载流子和相变材料等,由于数模/模数转换或者材料特性,这些技术往往将光计算整体的带宽限制在电计算的水平,无法真正发挥光计算的独特优势,因此尽可能地在光域实现连贯的几种操作(避免频繁的光电/电光转换)是未来值得重视的发展需求。

下面针对上述目标,我们具体总结了一些代表性工作。

4.1 降低功耗

为了能够进一步扩展光蓄水池神经网络的规模,应采取措施降低光经过内部各元件后的损耗,使

其能在蓄水池内留存更久,传播到更远的位置。2018年,根特大学的 Katumba 等^[49]提出了一种绝热多模Y型波导结构,用来替代以往并行结构光蓄水池神经网络中的分束器和合束器,该结构可以实现较低的损耗。

该团队还发现,对于并行结构,信号从多个节点注入光蓄水池时,能够获得比单个节点注入更好的性能和功率利用率^[50]。在文献[21]的基础上进行研究,图13为蓄水池误码率与功率和有信号注入的节点数之间的关系。可以看出,有信号注入的节点数越多,蓄水池在相同的总输入功率下表现越好,误码率越低。这是因为多节点注入使信号在蓄水池中保持的时间更长,内部动态丰富度增加。

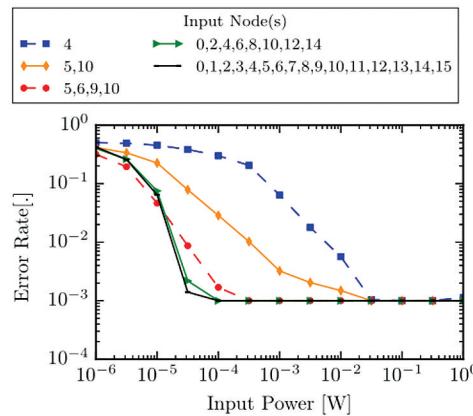


图13 在信号输入节点数不同的情况下,误码率与总输入功率的关系^[50]

Fig. 13 Error rate versus total input power for different injection scenarios^[50]

目前的并行结构光蓄水池多是基于旋涡拓扑或带反馈的瀑布拓扑构建的,其内部使用 2×1 耦合器,它的非对称性会导致无法避免的损耗。2019年,根特大学的 Sackesyn 等^[51]提出了一种新的拓扑结构,称为四端口架构,其示意图如图14所示。该架构利用 2×2 设备来合光和分光,避免了 2×1

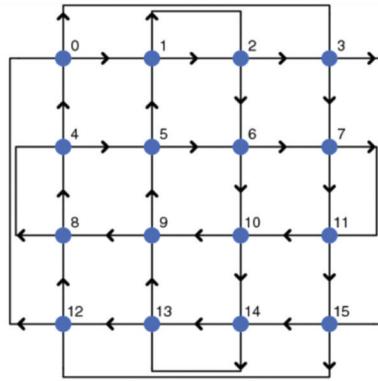


图14 四端口架构^[51]

Fig. 14 Four-port architecture^[51]

设备中的非对称性。仿真证明该结构具有更高的能量利用率。

4.2 提升速度

与并行结构相比,串行结构只需要使用单个光学元件,蓄水池内的众多神经元由虚拟节点实现,因此对制造工艺要求较低。然而,串行结构本质上是对单个元件的时分复用,难以达到并行结构的计算速度。为了改善这一问题,研究者已经提出了多种衍生方案。

2015 年,比利时荷语布鲁塞尔自由大学的 Nguimdo 等^[52]利用半导体环形激光器(SRL)作为串行结构光蓄水池的非线性节点。该结构利用了环形激光器中顺时针(CW)和逆时针(CCW)传播的两

个模式,具体构建如图 15 所示,信号经 MZM 调制到 SRL 发出的载波上,分别以 CW 和 CCW 模式进入环形激光器,使用同一条时延线进行反馈。利用 CW 和 CCW 两个模式,该蓄水池可同时处理两个任务。使用该结构进行 Santa Fe 混沌时间序列预测,CW 和 CCW 模式的 NMSE 分别达到 0.031 和 0.040;进行无线通信中的非线性信道均衡,误码率分别为 0.14% 和 0.15%。相同地,Guo 等^[53]在 2019 年使用 VCSEL 作为非线性节点,实现了串行结构光蓄水池,并且通过偏振复用,在一个蓄水池内同时处理了两路不同的信息。虽然偏振复用的蓄水池的信息处理性能较未复用的蓄水池略有下降,但在提升处理速度和减少功耗方面具有一定潜力。

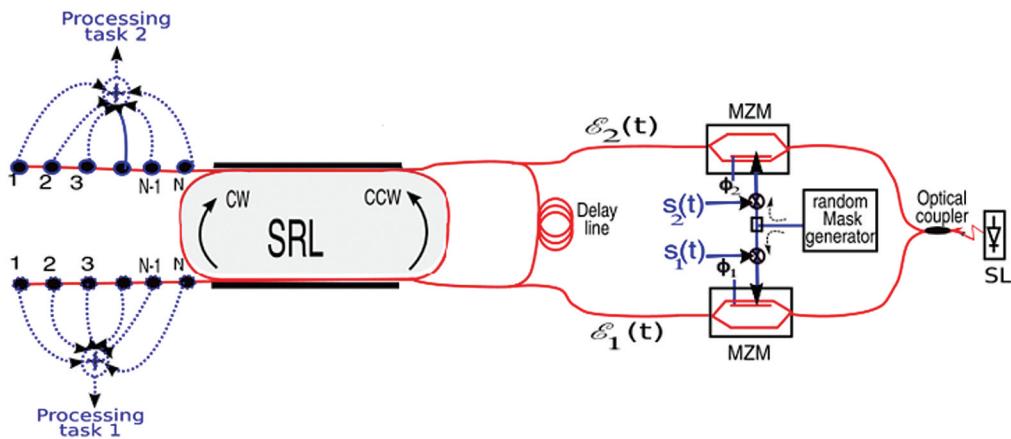


图 15 基于半导体环形激光器的串行结构光蓄水池^[52]

Fig. 15 Delay-based photonic reservoir based on SRL^[52]

2021 年,Yue 等^[54]提出了将相同的信号注入两个串行结构光蓄水池的方案,其结构如图 16 所示。非线性节点为半导体激光器(SL),时延反馈回路中的 OC 为光循环器,VA 为可变衰减器,FC 为光学耦合器。信号在电域进行掩模处理后,直接用于控制半导体的泵浦电流。取两个蓄水池中虚拟节点的状态共

同参与输出层权重矩阵训练。当两个半导体激光器参数完全相同时,蓄水池性能没有大大提高;调节两个激光器参数,使其适当失配,可以在不降低性能的情况下将处理速度提升近一倍。Sugano 等^[55]指出,利用多个串行结构光蓄水池并联同时计算的方案,其性能优于从一个激光器中引出多条时延回路的方案。

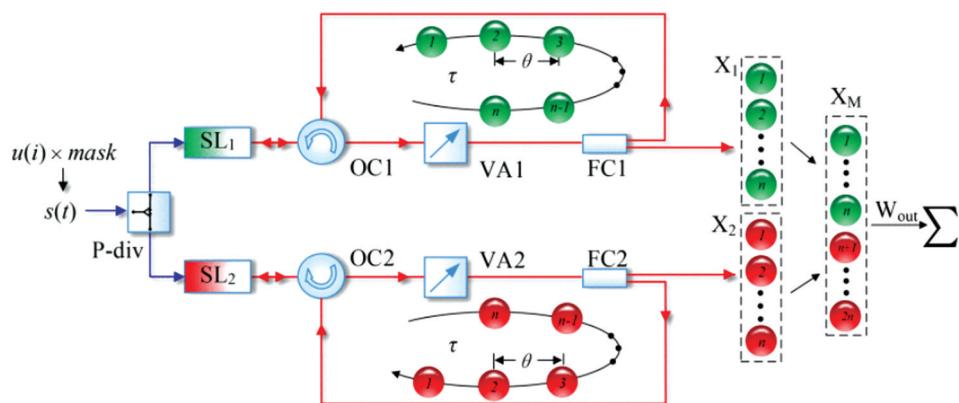


图 16 双蓄水池结构^[54]

Fig. 16 Double-reservoir structure^[54]

通过复用技术提高串行结构处理速度的光蓄水池神经网络模型的性能总结如表 3 所示, 主要工作仍是处在模型仿真阶段。非线性机制是以激光器中光反馈和注入带来的非线性效应为主, 后续基于芯片集成的无源光谐振腔阵列可能成为未来的发展方向。

4.3 全光输入输出

目前提出的光蓄水池神经网络结构大多只有蓄水池层是全光学实现的, 输入层和输出层仍然需要电学辅助^[56], 比如输入信号的调制大部分是在电学领域实现的; 输出权重矩阵的训练也大多是依靠光电探测器读取节点状态, 将读出结果储存到计算机中, 进行离线训练。在输入层和输出层进行的光电-光(O-E-O)转换, 使光神经网络难以发挥高速、高带宽等固有优势。大规模光电探测器阵列的集成困难在一定程度上也限制了蓄水池规模的扩展。

德国基尔大学的 Li 等^[57]于 2020 年提出了一

种在光学领域实现输入加权的方案, 其系统结构如图 17 所示。一个光开关(MOD)从信号传输中的每个符号中截取出持续时间为 $\Delta\tau$ 的部分, $\Delta\tau$ 等于虚拟节点之间的时间间隔 θ 。截取出的信号随后进入光学掩模模块(Masking), 输入时延线。每条时延线能够提供的光学延迟以 $\Delta\tau$ 为公差依次增加, 并且利用可变光衰减器调节光强实现加权, 达到与电学掩模相同的效果。

2021 年, 日本 Nakajima 等^[56]也提出了将信号输入具有不同时延的多条光路中以实现掩模的方案。与前述方案不同的是, 掩模权重是利用马赫-曾德尔干涉仪(Mach-Zehnder interferometer, MZI)阵列实现的, 可通过阵列中的移相器和衰减器进行调节^[58]。该光蓄水池能够对单个波长执行每秒 21.12×10^{12} 次的乘数累加运算(MAC), 通过波分复用, 可能实现千兆级别的超级运算。

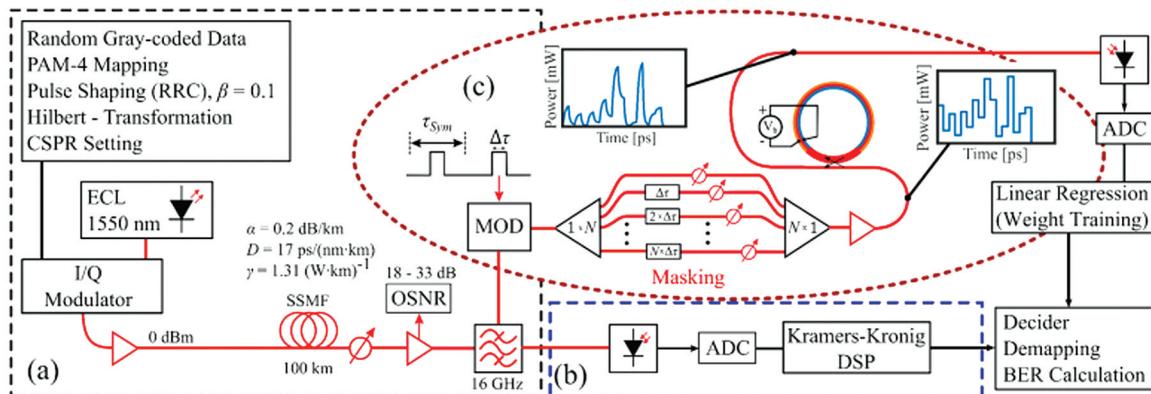


图 17 具有纯光学输入的串行光蓄水池信道均衡系统^[57]

Fig. 17 Delay-based photonic reservoir with optical input layer used for channel equalization^[57]

2018 年, 根特大学的 Freiberger 等^[59]提出在纯光学领域实现输出层加权求和, 仅使用单个光电探测器读取最终结果, 其示意图如图 18 所示。蓄水池节点的输出经过光学调制元件(OM)加权, 再经过

求和结构后, 由单个光电探测器读出。针对 OM 的权重设置问题, 该团队提出了一种“预训练-再训练”方案, 即先使用计算机执行训练过程, 确定每个 OM 应有的权值; 在片上结构制成之后, 再对 OM 进行微调, 得到最佳的结果。

2019 年, IBM 苏黎世研究中心的 Stark 等^[60]在硅基波导内埋置铁电钛酸钡(barium titanate, BTO)薄膜, 对其施加电压脉冲, 改变材料的普克尔斯系数, 最终使波导的有效折射率发生变化。使用这种方法控制施加电流的时间, 可以在全光学领域实现 10 位分辨率的非易失权重。虽然实现的权重分辨率低于软件可以达到的水平, 并且该结构中的权值会随时间缓慢漂移, 材料缺陷和噪声等也会影响其精度, 导致其进行三位分组头识别时错误率达到 $21\% \pm 6\%$, 难以处理实际任务, 但通过漂移补偿等方式, 这些缺陷的影响可能会减少。

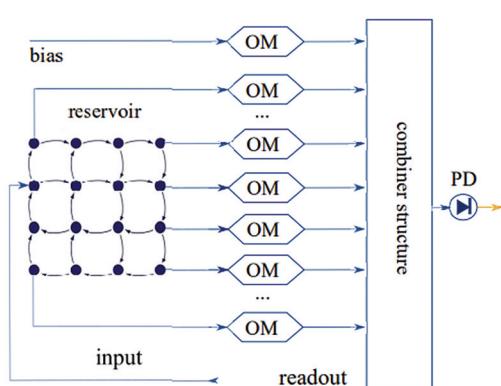


图 18 全光输出层实现方案^[59]

Fig. 18 Implementation scheme of all-optical readout layer^[59]

表3 串并混联架构光蓄水池的性能比较

Table 3 Performance comparison among serial-parallel optical reservoirs

Institute	Publication time	Implementation	Node type	Multiplexing mechanism	Optical delay	Reservoir size	Benchmark testing	Simulation/experiment
Vrije Universiteit Brussel ^[52]	2015	All-optical	Semiconductor ring laser (SRL) (CW and CCW) in SRL	Two directional optical modes	-	-	Santa Fe chaotic time serie prediction, NMSE (CW) is 0.031, NMSE (CCW) is 0.040; equalization of a wireless communication channel, BER (CW) is 0.14%, BER(CCW) is 0.15%	Simulation
Xidian University ^[53]	2019	All-optical	VCSEL	Two polarization-resolved modes in VCSEL	Nonlinearity of laser with optical injection and feedback	Delay time is 0.5 ns	50	Santa Fe chaotic time serie prediction; signal classification of sine wave, square wave and triangular wave
Southwest University ^[54]	2021	Optoelectronic	Semiconductor lasers	Two serial reservoirs are connected in parallel	-	-	100	Santa Fe chaotic time serie prediction, NMSE is 0.007, processing speed is faster than that of single serial reservoir
NTT ^[56]	2021	All-optical	Passive cavities on chip	Several serial reservoirs are connected in parallel	Delay time is $(290+20) \times 1 \text{ ps}$, 1 is cavity number	512	Santa Fe chaotic time serie prediction, NMSE is 0.06; image classification based on MNIST, accuracy is 91.3%	Experiment
University of West Attica ^[15]	2021	All-optical	F-P laser	Wavelength division multiplexing	Nonlinear photoelectric conversion in detectors	-	Image classification, accuracies are comparable to those of single wavelength experiments	
				8 longitudinal modes in F-P laser	Delay time is 1 ns	50	Nonlinear channel equalization of PAM-4 25 Gbaud signals, different tasks can be processed in parallel	Simulation

5 结束语

光蓄水池神经网络有望突破电神经网络的局限性,相对于传统的光神经网络,具有训练简单等优点,逐渐引起了人们的研究兴趣。目前,已有使用多种光电子器件实现蓄水池的方案,通过仿真或实验证明了光蓄水池神经网络在语音识别^[18,37]、信号预测^[38,44]、信道均衡^[39,61]、分组头识别^[42,62]等方面的应用潜力。

然而,目前对于光蓄水池神经网络的研究仍然处在起步阶段,还存在着一些问题。1) 目前实现的光蓄水池神经网络大多数规模较小,能够处理的任务也较为简单,更大规模的光蓄水池神经网络的构建和系统集成是一个值得研究的方向。片上并行结构光蓄水池可通过单纯地增加节点数量提升规模,但是需要面对能耗和制造精度的问题。基于衍射和散射的并行结构光蓄水池容易实现大量节点,但是难以集成。目前研究较多的是对串行结构进行波分、偏振、模式复用等处理以增加节点数,或是利用多个串行结构并联以增大蓄水池规模、提高性能,基于无源节点的片上串并混联光蓄水池可能是实现大规模光蓄水池神经网络的一个较好思路。2) 现有的光蓄水池神经网络仍然需要借助电学器件在输入层和输出层分别进行调制和读出,训练也是在计算机上进行。输入和输出时的光电/电光转换会降低处理速度,使光蓄水池神经网络难以发挥出相对于电神经网络的固有优势。实现全光学的输入输出以及在光学领域的在线训练是光蓄水池神经网络研究中比较前沿的方向。为此需要深入研究能够提供可调节非易失权重的光学器件。3) 光蓄水池神经网络存在最佳的工作状态,该状态受到节点间时延、输入强度、反馈强度、输入信号速率等多种因素的影响。对于以半导体激光器为节点的串行结构光蓄水池,已有比较系统的关于如何选取合适工作状态的研究,而其他类型的光蓄水池的研究大部分仅观察了这些因素对蓄水池性能的影响,仍然需要进一步的理论分析和方法总结。

光蓄水池神经网络正朝着高速率、低功耗、规模化、实用化的方向发展。作为光神经网络的一种,它有着极大的潜力,可能会在未来全光通信网络构建、人工智能等前沿领域发挥重要的推动作用。

参 考 文 献

- [1] Chen H W, Yu Z M, Zhang T, et al. Advances and challenges of optical neural networks [J]. Chinese Journal of Lasers, 2020, 47(5): 0500004.
- [2] Bai B, Yang Z, Yu B, et al. Photonic neural network: redefining AI chip [J]. AI-View, 2018, 5(2): 96-105.
- [3] de Marinis L, Cococcioni M, Castoldi P, et al. Photonic neural networks: a survey [J]. IEEE Access, 2019, 7: 175827-175841.
- [4] Bogaerts W, Pérez D, Capmany J, et al. Programmable photonic circuits [J]. Nature, 2020, 586(7828): 207-216.
- [5] Stark P, Horst F, Dangel R, et al. Opportunities for integrated photonic neural networks [J]. Nanophotonics, 2020, 9(13): 4221-4232.
- [6] Jaeger H. The “echo state” approach to analysing and training recurrent neural networks [EB/OL]. (2010-01-26) [2021-07-15]. <http://www.faculty.jacobs-university.de/hjaeger/pubs/EchoStatesTechRep.pdf>.
- [7] Maass W, Natschläger T, Markram H. Real-time computing without stable states: a new framework for neural computation based on perturbations [J]. Neural Computation, 2002, 14(11): 2531-2560.
- [8] Verstraeten D, Schrauwen B, D’Haene M, et al. An experimental unification of reservoir computing methods [J]. Neural Networks, 2007, 20(3): 391-403.
- [9] van der Sande G, Brunner D, Soriano M C. Advances in photonic reservoir computing [J]. Nanophotonics, 2017, 6(3): 561-576.
- [10] Haynes N D, Soriano M C, Rosin D P, et al. Reservoir computing with a single time-delay autonomous Boolean node [J]. Physical Review E, 2015, 91(2): 020801.
- [11] Marković D, Leroux N, Riou M, et al. Reservoir computing with the frequency, phase, and amplitude of spin-torque nano-oscillators [J]. Applied Physics Letters, 2019, 114(1): 012409.
- [12] Hauser H, Ijspeert A J, Füchslin R M, et al. Towards a theoretical foundation for morphological computation with compliant bodies [J]. Biological Cybernetics, 2011, 105(5/6): 355-370.
- [13] Yang L, Wu Y X, Wang J L, et al. Research on recurrent neural network [J]. Journal of Computer Applications, 2018, 38(S2): 1-6, 26.
- 杨丽, 吴雨茜, 王俊丽, 等. 循环神经网络研究综述 [J]. 计算机应用, 2018, 38(S2): 1-6, 26.

- [14] Paquot Y, Duport F, Smerieri A, et al. Optoelectronic reservoir computing [J]. *Scientific Reports*, 2012, 2: 287.
- [15] Bogris A, Mesaritakis C, Deligiannidis S, et al. Fabry-Perot lasers as enablers for parallel reservoir computing [J]. *IEEE Journal of Selected Topics in Quantum Electronics*, 2021, 27(2): 1-7.
- [16] Jaeger H, Haas H. Harnessing nonlinearity: predicting chaotic systems and saving energy in wireless communication [J]. *Science*, 2004, 304 (5667): 78-80.
- [17] Tanaka G, Yamane T, Héroux J B, et al. Recent advances in physical reservoir computing: a review [J]. *Neural Networks*, 2019, 115: 100-123.
- [18] Larger L, Soriano M C, Brunner D, et al. Photonic information processing beyond Turing: an optoelectronic implementation of reservoir computing [J]. *Optics Express*, 2012, 20(3): 3241-3249.
- [19] Vandoorne K, Dierckx W, Schrauwen B, et al. Toward optical signal processing using Photonic Reservoir Computing [J]. *Optics Express*, 2008, 16 (15): 11182-11192.
- [20] 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.
- [21] Vandoorne K, Mechet P, van Vaerenbergh T, et al. Experimental demonstration of reservoir computing on a silicon photonics chip [J]. *Nature Communications*, 2014, 5: 3541.
- [22] Mesaritakis C, Papataxiaris 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.
- [23] Laporte F, Katumba A, Dambre J, et al. Numerical demonstration of neuromorphic computing with photonic crystal cavities [J]. *Optics Express*, 2018, 26(7): 7955-7964.
- [24] Brunner D, Fischer I. Reconfigurable semiconductor laser networks based on diffractive coupling [J]. *Optics Letters*, 2015, 40(16): 3854-3857.
- [25] 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.
- [26] Maktoobi S, Froehly L, Andreoli L, et al. Diffractive coupling for photonic networks: how big can we go? [J]. *IEEE Journal of Selected Topics in Quantum Electronics*, 2020, 26(1): 1-8.
- [27] Dong J, Rafayelyan M, Krzakala F, et al. Optical reservoir computing using multiple light scattering for chaotic systems prediction [J]. *IEEE Journal of Selected Topics in Quantum Electronics*, 2020, 26 (1): 1-12.
- [28] Rafayelyan M, Dong J, Tan Y Q, et al. Large-scale optical reservoir computing for spatiotemporal chaotic systems prediction [J]. *Physical Review X*, 2020, 10 (4): 041037.
- [29] Paudel U, Luengo-Kovac M, Pilawa J, et al. Classification of time-domain waveforms using a speckle-based optical reservoir computer [J]. *Optics Express*, 2020, 28(2): 1225-1237.
- [30] Katumba A, Yin X, Dambre J, et al. A neuromorphic silicon photonics nonlinear equalizer for optical communications with intensity modulation and direct detection [J]. *Journal of Lightwave Technology*, 2019, 37(10): 2232-2239.
- [31] Fiers M A A, van Vaerenbergh T, Wyffels F, et al. Nanophotonic reservoir computing with photonic crystal cavities to generate periodic patterns [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2014, 25(2): 344-355.
- [32] Coarer F D L, Sciamanna M, Katumba A, et al. All-optical reservoir computing on a photonic chip using silicon-based ring resonators [J]. *IEEE Journal of Selected Topics in Quantum Electronics*, 2018, 24 (6): 1-8.
- [33] Mesaritakis C, Sozos K, Dermanis D, et al. Spatial photonic reservoir computing based on non-linear phase-to-amplitude conversion in micro-ring resonators [C] // *Optical Fiber Communication Conference 2021*, June 6-11, 2021, Washington, DC United States. Washington, D. C.: OSA, 2021: Tu1H.2.
- [34] Appeltant L, Soriano M C, van der Sande G, et al. Information processing using a single dynamical node as complex system [J]. *Nature Communications*, 2011, 2: 468.
- [35] Li L, Fang N, Wang L T, et al. Research progress in hardware implementations of reservoir computing [J]. *Laser & Optoelectronics Progress*, 2017, 54 (8): 080005.
李磊, 方捻, 王陆唐, 等. 储备池计算硬件实现方案研究进展 [J]. 激光与光电子学进展, 2017, 54(8): 080005.
- [36] Duport F, Schneider B, Smerieri A, et al. All-optical reservoir computing [J]. *Optics Express*, 2012, 20 (20): 22783-22795.
- [37] Brunner D, Soriano M C, Mirasso C R, et al. Parallel photonic information processing at gigabyte per second data rates using transient states [J].

- Nature Communications, 2013, 4: 1364.
- [38] Nakayama J, Kanno K, Uchida A. Laser dynamical reservoir computing with consistency: an approach of a chaos mask signal[J]. Optics Express, 2016, 24 (8): 8679-8692.
- [39] Vatin J, Rontani D, Sciamanna M. Enhanced performance of a reservoir computer using polarization dynamics in VCSELs[J]. Optics Letters, 2018, 43(18): 4497-4500.
- [40] Muller M, Hofmann W, Grundl T, et al. 1550-nm high-speed short-cavity VCSELs[J]. IEEE Journal of Selected Topics in Quantum Electronics, 2011, 17 (5): 1158-1166.
- [41] Han M, Shi Z W, Guo W. Reservoir neural state reconstruction and chaotic time series prediction[J]. Acta Physica Sinica, 2007, 56(1): 43-50.
韩敏, 史志伟, 郭伟. 储备池状态空间重构与混沌时间序列预测[J]. 物理学报, 2007, 56(1): 43-50.
- [42] Qin J, Zhao Q C, Yin H X, et al. Numerical simulation and experiment on optical packet header recognition utilizing reservoir computing based on optoelectronic feedback[J]. IEEE Photonics Journal, 2017, 9(1): 1-11.
- [43] Hou Y S, Xia G Q, Jayaprakash E, et al. Prediction and classification performance of reservoir computing system using mutually delay-coupled semiconductor lasers[J]. Optics Communications, 2019, 433: 215-220.
- [44] Guo X X, Xiang S Y, Zhang Y H, et al. High-speed neuromorphic reservoir computing based on a semiconductor nanolaser with optical feedback under electrical modulation[J]. IEEE Journal of Selected Topics in Quantum Electronics, 2020, 26(5): 1-7.
- [45] Guo X X, Xiang S Y, Qu Y, et al. Enhanced prediction performance of a neuromorphic reservoir computing system using a semiconductor nanolaser with double phase conjugate feedbacks[J]. Journal of Lightwave Technology, 2021, 39(1): 129-135.
- [46] Dejonckheere A, Duport F, Smerieri A, et al. All-optical reservoir computer based on saturation of absorption[J]. Optics Express, 2014, 22(9): 10868-10881.
- [47] Vinckier Q, Duport F, Smerieri A, et al. High-performance photonic reservoir computer based on a coherently driven passive cavity[J]. Optica, 2015, 2 (5): 438-446.
- [48] Nguimdo R M, Erneux T. Enhanced performances of a photonic reservoir computer based on a single delayed quantum cascade laser[J]. Optics Letters, 2019, 44(1): 49-52.
- [49] Katumba A, Heyvaert J, Schneider B, et al. Low-loss photonic reservoir computing with multimode photonic integrated circuits[J]. Scientific Reports, 2018, 8: 2653.
- [50] Katumba A, Freiberger M, Bienstman P, et al. A multiple-input strategy to efficient integrated photonic reservoir computing[J]. Cognitive Computation, 2017, 9(3): 307-314.
- [51] Sackesyn S, Ma C H, Katumba A, et al. A power-efficient architecture for on-chip reservoir computing [M] // Tetko I V, Kürková V, Karpov P, et al. Artificial neural networks and machine learning-ICANN 2019: workshop and special sessions. Lecture notes in computer science. Cham: Springer, 2019, 11731: 161-164.
- [52] Nguimdo R M, Verschaffelt G, Danckaert J, et al. Simultaneous computation of two independent tasks using reservoir computing based on a single photonic nonlinear node with optical feedback[J]. IEEE Transactions on Neural Networks and Learning Systems, 2015, 26(12): 3301-3307.
- [53] Guo X X, Xiang S Y, Zhang Y H, et al. Polarization multiplexing reservoir computing based on a VCSEL with polarized optical feedback[J]. IEEE Journal of Selected Topics in Quantum Electronics, 2020, 26 (1): 1-9.
- [54] Yue D Z, Wu Z M, Hou Y S, et al. Reservoir computing based on two parallel reservoirs under identical electrical message injection[J]. IEEE Photonics Journal, 2021, 13(1): 1-11.
- [55] Sugano C, Kanno K, Uchida A. Reservoir computing using multiple lasers with feedback on a photonic integrated circuit[J]. IEEE Journal of Selected Topics in Quantum Electronics, 2020, 26(1): 1-9.
- [56] Nakajima M, Tanaka K, Hashimoto T. Scalable reservoir computing on coherent linear photonic processor[J]. Communications Physics, 2021, 4: 20.
- [57] Li S, Dev S, Jamshidi K, et al. Photonic reservoir computing enabled by active silicon micro-rings with transparent signal injection[C]//Conference on Lasers and Electro-Optics, May 10-15, 2020, Washington, D.C. Washington, D.C.: OSA, 2020: 19965947.
- [58] Shen Y C, Harris N C, Skirlo S, et al. Deep learning with coherent nanophotonic circuits[J]. Nature Photon, 2017, 11: 441-446.
- [59] Freiberger M, Katumba A, Bienstman P, et al. Training passive photonic reservoirs with integrated optical readout[J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30 (7): 1943-1953.
- [60] Stark P, Kremer J G, Eltes F, et al. Non-volatile

- photonic weights and their impact on photonic reservoir computing systems[C]//2019 Conference on Lasers and Electro-Optics Europe & European Quantum Electronics Conference (CLEO/Europe-EQEC), June 23-27, 2019, Munich, Germany. New York: IEEE Press, 2019.
- [61] da Ros F, Ranzini S M, Bülow H, et al. Reservoir-computing based equalization with optical pre-processing for short-reach optical transmission [J]. IEEE Journal of Selected Topics in Quantum Electronics, 2020, 26(5): 1-12.
- [62] Zhao Q C, Yin H X, Zhu H G. Simultaneous recognition of two channels of optical packet headers utilizing reservoir computing subject to mutual-coupling optoelectronic feedback [J]. Optik, 2018, 157: 951-956.

Recent Progress in Photonic Reservoir Neural Network

Yang Lingyan, Zhang Lin^{*}

School of Precision Instrument and Opto-Electronics Engineering, Tianjin University, Tianjin 300072, China

Abstract

Significance Optical computing has been proposed for a few decades, although not yet widely applied in practice. This is partially because large-scale electronic circuits have been successfully developed as universal computing platforms. In recent years, it has been witnessed that the Moore's law faces a bottleneck and photonic chips exhibit increasingly larger integrated arrays of tiny devices. Meanwhile, the emerging artificial intelligence has been inspiring a ubiquitous interest, which is featured by large amounts of matrix computation. This particularly triggers a renewed interest in optical neural networks for voice/image recognition, channel equalization in communications, and other data processing applications.

Compared with electronic neural networks, photonic neural networks potentially have the advantages of high speed and low power consumption. As a result, it has gradually attracted people's research interests in recent years. The photonic reservoir neural network is a kind of photonic recurrent neural network. Reservoir computing is expected to be suitable for processing sequence signals, and the training process is relatively simple. This could be greatly useful for optical fiber communications and wireless mobile communications.

This paper first introduces in detail the system configurations and technological characteristics of reservoir computing and presents the essential conditions to realize a reservoir. Then, the research progress in photonic reservoir computing is introduced through two different hardware implementations, which are called parallel and delay-based structures. Finally, the bottlenecks and corresponding solutions are discussed.

Progress Parallel photonic reservoirs are composed of optical node arrays. They have the potential to perform large-scale parallel computing. In 2008, researchers proposed a parallel photonic reservoir using semiconductor optical amplifiers. It outperformed traditional reservoirs on signal classification tasks at that time. This research team also reported a power-efficient experimental prototype in 2014, which only consists of passive waveguides, splitters, and combiners (Fig. 5). Microring resonators and photonic crystal cavities can also be used as nodes in parallel photonic reservoirs. Another kind of parallel optical reservoir is based on space optics. Maktoobi *et al.* demonstrated a reservoir with diffractively coupled nodes (Fig. 7), Rafayelyan *et al.* reported a reservoir based on multiple light scattering (Fig. 8), and Paudel *et al.* demonstrated a reservoir using speckles generated by mode interference in a multimode waveguide.

A delay-based photonic reservoir, also called a serial photonic reservoir, contains a single optical node with time-delayed feedback. Delay-based photonic reservoirs are easier to manufacture than parallel photonic reservoirs, but their parallel-computing capability is slightly poor. In 2012, Larger *et al.* demonstrated an optoelectronic delay-based photonic reservoir using a Mach-Zehnder modulator as the nonlinear node. Duport *et al.* reported the implementation of a photonic reservoir based on a semiconductor optical amplifier in the same year and it is the first delay-based all-optical reservoir (Fig. 11). In 2013, Brunner *et al.* used a semiconductor laser as the nonlinear node in a delay-based reservoir. Semiconductor lasers are power efficient, high-bandwidth, and widely used in modern fiber communications. In 2014, Dejonckheere *et al.* used a semiconductor saturable absorber mirror as a nonlinear node. It is the first photonic reservoir using fully passive nonlinearity.

There are schemes to improve the performance of reservoirs through a so-called hybrid configuration. In 2021, Nakajima *et al.* reported a photonic reservoir consisting of several delay-based reservoirs connected in parallel. The nodes are on-chip passive coherent cavities. This experiment realized the first image classification using an on-chip passive photonic reservoir.

By comprehensively comparing the recently proposed photonic reservoir computing schemes, we show a few features and evaluators, which can be used to estimate the capacity of new reservoir computing systems, including node type, nonlinearity mechanism, optical delay, array size, and input optical power. By organizing three tables (Tables 1–3), we clearly show the technical advantages and disadvantages of different reservoir neural network configurations, with an emphasis on the practical characteristics of nonlinear actuation functions. The nonlinear functional devices are based on semiconductor optical amplifiers, nonlinear microresonators, optical lasers with feedback, semiconductor saturable absorbers, and Mach-Zehnder modulators with a nonlinear transfer function.

Conclusions and Prospects Photonic reservoir neural networks can overcome some limitations of electronic neural networks, and their training processes are very simple. Photonic reservoirs have a broad development prospect. They have been used to implement speech recognition, chaotic time series prediction, channel equalization, header recognition, and other functions.

We share some high-level perspectives on the future directions of photonic reservoir computing systems, by pointing out the potential technical issues and problems competing with an electronic version of reservoir computing. The array size, speed and accuracy of computation, and all-optical processing capability have been identified as three major tasks to advance the future development of photonic reservoir computing. According to these, some representative works recently published have been discussed, and the hybrid configuration of photonic reservoirs is particularly analyzed. We believe that all-optical input and output, hybrid configuration, on-chip implementation, and large-scale reservoirs are the future development directions of photonic reservoirs.

We believe this review would be of interest to the community of optical computing and neural networks as well as the community of integrated photonics.

Key words optics in computing; reservoir computing; neural network; optical waveguides; resonant cavity

OCIS codes 200.4260; 200.3050; 250.5300