

基于深度学习的超材料设计及光纤光束控制研究进展

罗仪豪¹, 张峻², 杜世银², 颜求泉², 赵泽宇², 陶梓隆², 周侗¹, 江天^{3*}

¹国防科技大学前沿交叉学科学院, 湖南 长沙 410073;

²国防科技大学计算机学院量子信息研究所兼高性能计算国家重点实验室, 湖南 长沙 410073;

³国防科技大学理学院量子信息研究所, 湖南 长沙 410073

摘要 超材料设计和光纤光束控制是光场调控研究的两个重要议题。传统方法取得一定研究进展的同时,也面临着有效性和适应性的问题。为弥补传统方法的不足,研究者们尝试将深度学习方法应用于以上两个议题。介绍了基于深度学习进行超材料设计和光纤光束控制的近期研究工作。超材料设计方面,重点回顾了采用多层感知机、卷积神经网络、循环神经网络、生成对抗网络等经典神经网络模型的相关工作;光纤光束控制方面,主要介绍了典型的搜索方法与深度强化学习方法。基于深度学习进行超材料设计和光纤光束控制的方法,具有速度快和自动化程度高的优势,为光场调控集成化、智能化提供新思路。

关键词 材料; 光纤光学; 神经网络; 光场调控; 超材料设计; 光学系统控制

中图分类号 O439 文献标志码 A

DOI: 10.3788/CJL230540

1 引言

超材料设计和光纤光束控制是光场调控中两个重要的研究内容。超材料是一种具有人为设计的周期性结构,并具有某种自然界不存在的物理特性的材料。设计合适的结构对于实现超材料的功能具有重要意义。超材料设计通常采用数值计算与参数优化相结合的方法。数值计算方面,当前主流的方法包括时域有限差分法(FDTD)^[1-2]、有限元法(FEM)^[3]和严格耦合波分析法(RCWA)^[4]等。参数优化方面,经过发展,演变出了以遗传算法为代表的参数搜索方法。然而,当前数值计算方法存在计算开销大和对专家经验依赖性强的问题。具体而言,计算开销大是偏微分方程求解过程复杂导致的;而对专家经验依赖性源于这些数值计算方法依赖物理建模。此外,参数优化算法也存在计算开销大的问题。这类问题是参数组合爆炸以及重复调用数值计算方法导致的^[5]。于是,不少研究者将目光着眼于深度学习方法^[6-13],试图以数据驱动的方式使神经网络模型在特征学习过程中学习超材料结构与光学响应间的映射关系,从而在屏蔽底层物理细节的同时实现准确、高效的超材料设计^[14-22]。

光纤光束控制是指对光纤光束的振幅、相位和偏振等参量进行调控,获得具有新颖特性的光纤光束^[23],或者具有稳定状态的光束^[24]。传统方法主要包括遗传

算法、随机并行梯度下降算法、PID等搜索方法。这些方法的共同缺陷在于,它们的策略都是对环境刺激机械式的反应,在面临复杂环境时,无法有效解决系统控制问题,例如速度与精度等问题。一方面,此类优化方法由于策略简单难以生成好的行为路径,致使到达目标状态的步数过多^[25];另一方面,它们机械式地应对环境状态容易受到系统噪声的干扰,导致系统输出精度受限^[26-27]。深度强化学习(DRL)通过引入学习机制,可实现对环境刺激的能动式反应,弥补了传统方法的缺陷^[28]。光纤光束控制作为动力学过程,能够被抽象为状态机,天然地适合基于深度强化学习的调控方法。因此,对于这种系统以及更复杂的系统,基于深度强化学习的方法具备相当的应用前景。

基于上述背景,本文将从超材料设计和光纤光束控制这两方面应用出发,对面向二者的深度学习研究进展作进一步的回顾与探讨。在介绍深度学习的相关理论与模型及其主要特点之后,先探讨了深度学习在超材料设计中的应用,并对比了各种深度学习方法的效果,然后介绍深度学习在光纤光束控制中的应用,并分析了各个工作的特点。最后对面向超材料设计和光纤光束控制的深度学习方法进行了总结,并对未来可能努力的方向进行了展望。

2 深度学习基本原理

近年来,随着计算机算力的飞速提升,以神经网络

收稿日期: 2023-02-17; 修回日期: 2023-03-27; 录用日期: 2023-04-23; 网络首发日期: 2023-05-01

基金项目: 国家重点研发计划(2020YFB2205804, 2020YFB2205800)

通信作者: *tjiang@nudt.edu.cn

为主要计算模型的深度学习取得了显著成果。经过几十年的发展,深度学习领域先后发展出了众多不同类型的神经网络,常用的包括以乘累加计算为核心的多层感知机(MLP)网络、以卷积运算为核心的卷积神经网络(CNN)、带有反馈回路的循环神经网络(RNN)等。这些基本构型的网络相互组合又引申出了一些更加复杂的网络,比如常见的自编码器、生成对抗网络(GAN)等。伴随着多种多样的神经网络,深度学习在生物、医疗、图像、物理等众多领域发挥了巨大的作用^[29]。

作为机器学习的一个重要分支,深度学习的理论思想本质上可以抽象为利用统计学习方法寻找一个特定的函数实现输入到输出的快速映射。深度学习的核心在于寻找一个能够实现输入到输出的映射的函数。为了得到满足需求的函数,需要先定义假说集,也就是基本的函数构型。假说集可以是线性函数、多项式函数、指数函数、对数函数等。深度学习区别于一般机器学习之处就在于深度学习的假说集就是构建好的神经网络。假设选定的假说集是一个确定结构的全连接神经网络,接下来就需要确定全连接神经网络中不同神经元之间连接的权重值、神经元本身的偏置以及非线性激活函数中的超参数等参数值。具体的方法就是统计学习,即根据现有的数据集,使用随机梯度下降(SGD)、自适应矩估计(Adam)等统计学习算法得到一组满足目标需求的网络参数。这样得到的神经网络就能够服务于数据集所对应的应用场景。因此,对于深度学习服务于光场调控而言,核心的三要素就是神经网络模型、模型训练策略以及目标问题所对应的数据集^[30]。本文重点关注神经网络模型和模型训练策略。

2.1 神经网络模型

1943年,心理学家 McCulloch 和数理逻辑学家 Pitts^[31]发现单个神经元可以完成逻辑运算,在此发现的基础上,他们通过模拟人脑神经元之间的信号传递,开发了世界上第一个神经网络模型,即 MP 模型。此后,随着神经科学的发展,人们了解到了生物神经系统中更多的作用方式,并相继提出了 CNN^[32]、RNN^[33]等神经网络模型。与此同时,人们通过实验发现,当动物的许多神经元一起工作时会变得更加聪明,而单个神经元或者少量神经元并不是特别有用。于是,自引入隐藏层以来,人工神经网络的规模大约每 2.4 年翻一番。大数据、大网络成为了近些年人工神经网络的发展趋势^[30]。

2.1.1 多层感知机网络

多层感知机网络是最简单的人工神经网络,通常也被称为全连接神经网络和深度前馈网络。如图 1(a)所示,这种网络是一种单向层状网络,模型输出与模型本身以及模型内部层与层之间不存在反馈连接,同一层的神经元之间也不存在连接关系。因而

这种网络是一种链式网络,链的长度取决于网络的层数。组成网络的基本单元是感知机,其数学过程如图 1(b)所示。不难发现,感知机的计算可以分为两部分,一部分是乘累加计算(向量乘法),另一部分是激活函数的非线性计算。多层感知机网络的数学函数由这些感知机函数组合而成。假设输入层也就是网络的第一层表示为 $f^{(1)}$,第二层表示为 $f^{(2)}$,以此类推,最后一层也就是输出层表示为 $f^{(n)}$ 。最终,整个网络就可以表示为^[30]

$$f^*(x) = f^{(n)}(f^{(n-1)}(f^{(n-2)}(\dots(f^{(2)}(f^{(1)}(x)))))) \quad (1)$$

根据感知机的数学过程可知,第 i 层网络的函数 $f^{(i)}$ 为

$$f^{(i)}(x) = f_i(\mathbf{w}_i \mathbf{x}_i) \quad (2)$$

式中: f_i 表示网络中第 i 层的激活函数,它的存在克服了模型只能表示线性空间的局限性; \mathbf{x}_i 表示第 i 层的输入向量,也就是第 $i-1$ 层的输出; \mathbf{w}_i 表示第 $i-1$ 层与第 i 层之间的权重矩阵。




图 1 多层感知机网络结构图^[29]。(a)网络结构;(b)感知机数学过程

Fig. 1 Architecture of multi-layer perceptron network^[29]. (a) Network structure; (b) mathematics process of perceptron

当然,网络第 1 层的权重矩阵可以认为是全 1 矩阵,而输入则是网络的输入。那么在网络训练的过程中,数据集提供了在不同输入 x 上的含有噪声的标签值 y 。而训练的目标就是尽可能实现对所有输入 x 都有

$$y = f^*(x) \quad (3)$$

因此,学习算法的作用就是调整网络中的参数值,得到最佳的函数近似。

除了将多层感知机网络的每一层简单理解为向量到向量的函数,还可以从神经科学的角度出发将每一层理解成一系列并行的神经元。每个神经元会接收来自上一层的所有神经元的的信息,然后在乘累加计算和

激活函数计算后得到自己的信息值。故无论是从神经元角度还是函数角度看,神经网络的规模都会深刻影响到网络的智能程度。从函数角度看,大网络意味着更多的可调整参数,因而函数空间会更大;从神经元角度看,大网络意味着更多的神经元,因而智能程度会更高。当然,网络规模变大,模型的训练难度也自然而然会变大。

事实上,在面向光场调控问题时,采用最朴素的多层感知神经网络往往能够收到奇效,因为下一层的神经元会接收上一层所有神经元的信息,从而不同层次间的神经元之间是紧耦合的,有利于充分利用输入数据^[34-36]。但是多层感知神经网络只能处理一维数据,对于高维数据可能需要降维或者维度变换,这一过程可能会导致数据信息丢失,进而影响网络性能。

2.1.2 卷积神经网络

卷积神经网络是一种专门处理具有类似网格结构的数据的神经网络,比如图像、时间序列等。与多层感知神经网络一样,卷积神经网络也是单向层状网络。但是,卷积神经网络至少在网络的一层中使用了卷积运算来替代一般的矩阵乘法运算。卷积运算是对两个实变函数的一种数学计算,其数学表达式为^[30]

$$s(t)=(x*\omega)(t)=\int x(a)\omega(t-a)da, \quad (4)$$

式中:函数 x 通常被称为输入;函数 ω 通常被称为核函数; t 表示卷积运算的当前位置; a 表示与当前位置的间隔。

在某些情况下,当前位置 t 和 a 可能只能取离散值。此时,卷积运算可以表示为

$$s(t)=(x*\omega)(t)=\sum_{a=-\infty}^{\infty} x(a)\omega(t-a)。 \quad (5)$$

值得注意的是,由于卷积运算中会出现相对输入发生翻转的情况,即输入的索引在变大但是核的索引在变小的情况。于是,为了提高计算效率,在一些神经网络架构中,也会定义互相关函数,将互相关函数称之为卷积运算,即

$$s(t)=(x*\omega)(t)=\sum_{a=-\infty}^{\infty} x(a)\omega(t+a)。 \quad (6)$$

与多层感知神经网络中使用矩阵乘法构建输入和输出的连接关系不同的是,卷积运算通过稀疏交互、参数共享改进了神经网络计算,其模型来源于生物视觉系统中的感受野细胞。稀疏交互指的是下一层的神经元与上一层的神经元的连接是稀疏的。以图像处理为例,通常使用的卷积核大小是 3×3 或者 5×5 ,这意味着下一层的神经元只会与上一层 3×3 或者 5×5 范围内的神经元产生连接,而不会像全连接神经网络一样,下一层的神经元会与上一层的所有神经元建立连接。这样的稀疏交互大大减少了网

络的计算量。参数共享指的是单个卷积核在计算中参数是一致的,卷积核中的每一个元素都会作用在输入的每一个位置上。而在全连接神经网络中,上一层与下一层的神经元之间的连接权重是独立的。参数共享保证了只需要学习卷积核这一个较小的参数集合,减少了参数训练量,使网络训练变得更简单。

当然,除了基本的卷积运算外,卷积神经网络的一个典型层还包含非线性激活以及池化运算。池化是通过池化函数实现的,它使用某一位置周围的一系列相邻输出的统计特征替换这一系列的输出,常用的包括最小值池化、最大值池化、平均值池化等。池化的存在消除了卷积运算过程中平移不变性带来的信息冗余,有利于进一步减少卷积神经网络的计算量。

然而卷积神经网络也有一系列的缺点。例如,在训练过程中,需要大量的标记数据,在数据资源有限的情况下,难以得到较好的模型。而且卷积神经网络由于其大量的参数,容易出现过拟合。此外,由于卷积神经网络被设计用于固定大小的输入,因此不擅长处理可变大小的输入^[37]。

2.1.3 循环神经网络

循环神经网络是一类用于处理序列数据的神经网络,其最大的特点是在层状网络中引入了反馈回路。反馈回路的存在可以使得模型具有一定的记忆性,使网络的决策能够结合上下文信息。以最简单的自然语言处理为例,中文中经常出现一词多义的情况,只有结合上下文信息才能准确判断词语的含义。因此,循环神经网络是专门用于处理序列的神经网络,并且可以扩展到很长的序列。

图 2 给出了一个典型的循环神经网络及其计算图。图 2 中 y 、 L 、 o 、 h 以及 x 分别代表目标、损失、输出层、隐藏层以及输入层,而 U 、 V 、 W 则是不同层的权重参数。图中的循环神经网络仅仅包含了一个从输出层到隐藏层的反馈连接。不难发现,在每个时间步,隐藏层的计算都会结合前一个时间步的输出层结果,从而上一个时间步的计算结果会影响到当前时间步的计算。因此,循环神经网络在处理具有很强上下文联系的序列信息时,能够发挥出无与伦比的优势。然而,它们也有一些缺点^[38]。例如梯度消失问题:受到梯度消失问题的困扰,在反向传播过程中,梯度变得太小,无法用于学习。这使得循环神经网络很难捕获序列数据中的长期依赖关系。又如梯度爆炸问题:在某些情况下,梯度也可能在训练过程中变得过大,这可能会导致权重更新过多、训练不稳定。

2.1.4 复杂神经网络及其扩展

前面介绍了当前深度学习中最基本的三种神经网络。然而,面对一些复杂应用场景时,基本神经网络难以满足目标需求,由此在基本神经网络的基础上诞生




图 2 一个简单的循环神经网络及其计算图

Fig. 2 Simple recurrent neural network and its computational graph

了一些复杂神经网络及其扩展的新型网络。这里主要介绍三种典型代表,分别是尝试将输入复制到输出以解决数据标注问题的自编码器^[39-41]、引入博弈对抗思想以进行无监督学习的生成对抗网络^[42]以及借助深度学习模型进行强化学习的深度强化学习模型^[43-44]。

自编码器是一种特殊的神经网络,经过训练后能够尝试将输入复制到输出。如图 3 所示,自编码器可以看作是由编码器和生成重构的解码器两部分级联构成。编码器是一个由函数 $r = g(x)$ 表示的神经网络,它能够由输入向量 x 变换为隐藏向量 r 。而解码器是一个由函数 $y = h(r)$ 表示的神经网络,它的作用是将隐藏向量尽可能地还原回输入向量 x 。当然如果自编码器只是简单地实现了 $x = h[g(x)]$,那么这个自编码器实际的意义并不是很大。因此,自编码器的损失函数中还会额外对隐藏向量 r 增加约束,从而自编码器的输出将会近似等于输入。而隐藏向量的约束就等于迫使模型强制考虑输入数据的某些特征被优先复制到输出中。通常,自编码器可以用于数据维度变换、特征学习、降噪等领域,其最显著的特征就是数据标签即输入数据。尽管近年来研究者对自编码器及其改进算法进行了深入研究,但仍存在一些问题需要解决^[45]。例如,与监督学习相比,无监督学习模式摆脱了对样本标签的依赖,并避免了手动标记的困难,但它也失去了样本标签的帮助,标签信息难以有效地应用于特征提取,使得自编码器的性能与监督学习之间存在一定差




图 3 自编码器示意图

Fig. 3 Architecture of autoencoder

距。自编码器及其深层结构由于模型结构复杂,需要大量样本来训练自编码器。在小样本条件下训练自编码器容易出现过拟合,从而降低模型的泛化性能。

生成对抗网络是无监督深度学习的典型代表^[42]。在介绍生成对抗网络之前,需要简要了解生成模型和判别模型。在当前的深度学习领域,神经网络根据用途可以大致划分为两类模型:生成模型和判别模型。所谓判别模型就是根据输入变量进行预测,比如手写字母识别,根据输入的手写字母图片判断它的类别。至于生成模型,则是根据输入数据中包含的变量概率分布,来随机产生观测数据,比如根据一些小狗的图片来随机产生新的小狗的图片。而生成对抗网络就是基于博弈对抗思想,其中包括了一组生成网络和一组判别网络。生成网络的目标是产生一系列“伪造”数据,确保“伪造”数据尽可能与原始数据相似以至于判别网络无法分辨出来;而判别网络的目标就是尽可能地提高网络识别能力,能够区分原始数据和生成网络的“伪造”数据。二者在对抗训练中相互提升。使用零和博弈形式化描述生成对抗网络学习过程就是:假设判别网络的收益是函数 $v(\theta^{(g)}, \theta^{(d)})$ 刻画的,那么相应的生成网络的收益就是函数 $-v(\theta^{(g)}, \theta^{(d)})$ 刻画的,所以在学习过程中,两种网络都要最大化自己的收益,即

$$\arg \min_{\theta^{(g)}} \max_{\theta^{(d)}} v(\theta^{(g)}, \theta^{(d)}) \quad (7)$$

如何解决模式崩溃问题是生成对抗网络面临的主要挑战,同时生成对抗网络还会遇到由于噪声带来的鲁棒性问题^[46]。

至于借用深度学习模型的深度强化学习严格意义上已经不属于深度学习的范畴,但是可以认为是深度学习的扩展。当前,基于强化学习思想利用神经网络实现超材料设计和光纤光束控制取得了不少进展。强化学习的核心概念是 Agent。Agent 能够依据自身策略,对环境状态做出适应性行为^[47]。强化学习的整个学习过程就是 Agent 与环境不断交互的过程。首先 Agent 通过观察环境得到当前环境的状态,然后根据

当前环境状态, Agent 需要作出决策采取与当前状态相适应的动作, 而奖励函数就会对采取的动作进行评价, 进而根据评价结果优化和提升 Agent 的决策使其能够针对环境状态做出最好的动作。因此, 对于强化学习而言, 目标就是希望 Agent 能够针对环境做出最理智的行为。而在 Agent 内部, 需要根据状态找到相应的动作, 这一映射过程给神经网络提供了极大的发挥空间。与此同时, 在 Agent 做出动作后, 奖励函数需要对动作进行评价, 这个过程中也存在一个从动作到奖励值的映射, 从而奖励函数也可以采用神经网络实现。

强化学习算法从策略上区分, 主要包括了马尔可夫决策过程、动态规划、蒙特卡罗法^[48]、时序差分算法、深度 Q 学习 (DQN)^[49] 和深度确定性策略梯度 (DDPG)^[50] 等。随着深度学习的发展和计算机算力的不断增强, DQN 和 DDPG 逐渐成为强化学习的应用中主要使用的策略模型, 而强化学习更新的算法模型也是基于二者实现的进一步优化。因此, 接下来对此二者进行介绍。

DQN 是一种使用时序差分思路求解相关控制问题的方法^[51]。其求解过程无需依赖环境的状态转移模型, 而是通过价值迭代完成。随着价值函数的更新来选择动作的策略, 并通过策略产生新的状态和激励值, 从而更新价值函数, 直到价值函数和策略函数都收敛。其使用的技巧主要是经验回放, 当每次算法与环境交互时, 都会将计算的激励值与状态更新保存到一个集合中, 用于未来目标 Q 值的更新。在网络模型的训练过程中, 参数不断优化, 直到目标 Q 值和实际 Q 值误差在可接受范围内, 即得到近似 Q 值求解函数。但该网络模型奏效的前提在于 Q 网络能够收敛, 但实际情况下 DQN 很难确保网络的收敛, 导致最终效果不佳。

DDPG 算法是在 DQN 算法基础之上改进的。由于 DQN 只能解决含有离散和低维度动作空间中的问题, 而很多系统中动作空间连续, 故 DQN 的应用会有所限制。Google Deepmind 团队在 2016 年提出了 DDPG 算法^[50]。DDPG 算法主要有以下几个特点: (1) 包含了 4 个网络, 分别是 2 个 actor 网络和 2 个 critic 网络, 分别对应训练网络与目标网络; (2) 设计了经验回放机制, 算法中包含了回放缓冲区, 用于存储执行器和环境之间交互的数据, 也就是其训练集; (3) 算法更新目标网络模型参数策略是采取软更新, 其更新机制提高了网络稳定性; (4) 网络模型训练中会引入一定的动作随机性, 从而提升系统在环境中的稳定性。其 critic 网络模型训练过程损失函数被定义为均方误差:

$$J(\omega) = \frac{1}{m} \sum_{j=1}^m \left\{ y_j - Q[\phi(S_j), A_j, \omega] \right\}^2. \quad (8)$$

而 actor 网络的损失函数则是对 Q 函数的取反, 定义如下:

$$J(\theta) = -\frac{1}{m} \sum_{i=1}^m Q(s_i, a_i, \omega). \quad (9)$$

相比 DQN, DDPG 的一大优势在于能够在连续的动作空间对应的问题中搜索路径, 快速到达目标状态, 因而更适用于动态系统。

深度强化学习中不同的策略大多是为了解决以下几个问题^[52]: 高维状态动作空间任务上的算法收敛问题, 复杂应用场景下的算法样本效率提高问题, 奖励函数稀疏或无明确定义情况下的算法探索问题, 多任务场景下的算法泛化性能增强问题。这些也是深度强化学习面临的挑战。

2.2 统计学习策略

前面提到, 统计学习算法的目标是调整神经网络中的参数值, 得到最佳的函数近似。因此, 统计学习算法本质上是求解一类特定的优化问题: 寻找神经网络的一组参数, 使其能够显著地降低损失值。通常, 神经网络的训练采用经验风险最小化策略, 即在给定数据集中最小化平均训练误差, 数学上表示为^[30]

$$\arg \min_{\theta} \frac{1}{m} \sum_{i=1}^m L[f^*(x^{(i)}; \theta), y^{(i)}], \quad (10)$$

式中: m 为训练样本数目; θ 为神经网络中的参数; L 为定义的损失函数。

不难发现, 定义良好的损失函数对于神经网络的优化至关重要。

为了最小化经验风险, 基于梯度的优化策略比如随机梯度下降算法^[53]、动量算法^[54] (基于动量的随机梯度下降、Nesterov 动量算法^[55] 等)、自适应学习率算法 (AdaGrad 算法^[56]、RMSProp 算法^[57]、Adam^[58] 算法等) 等相继被提出。这些算法已经被证明是有效且实用的神经网络优化算法。然而, 这些算法的前提是自动微分技术——计算梯度。而最常见的一种自动微分技术就是反向传播算法^[59], 允许来自损失函数的信息通过网络由后向前流动, 以便计算梯度。需要指出的是, 反向传播并不是神经网络的学习算法, 而是一种计算梯度的算法; 随机梯度下降等优化算法才是对神经网络进行优化的算法, 它们利用了反向传播计算得到的梯度。

当然, 作为推动神经网络向深度化发展的反向传播算法原理上很简单, 其核心就是微积分中的链式法则。所谓链式法则, 就是假设 $x \in R^m, y \in R^n$, 如果 $y = g(x)$ 并且 $z = f(y)$, 那么

$$\frac{\partial z}{\partial x_i} = \sum_j \frac{\partial z}{\partial y_j} \frac{\partial y_j}{\partial x_i}. \quad (11)$$

依托链式法则, 整个损失函数的误差梯度计算可以由后至前展开, 而反向传播算法只需要在计算过程中维护整个计算图, 确保误差的反向传播序列。当然, 单个节点可能会被反复展开多次, 因此现阶段一般化的反向传播算法中还引入了动态规划策略避免算法重复计算子表达式, 降低时间开销。

3 深度学习在超材料设计中的应用

第 2 节主要介绍了深度学习的相关理论,本节主要介绍近年来深度学习在超材料设计领域的应用及常用的设计方法。

3.1 超材料在光场调控中的作用

随着对各种光学现象的研究日渐深入,人们逐渐掌握了光与物质相互作用的规律,并利用这些规律,采用各种介质对光信号进行调控。在电磁场理论中,介电常数与磁导率是表征介质特性的两个基本参数,基于上述电磁参数在数值上的差异,各种材料的参数空间可以划分为如图 4 所示的四个部分^[5]。

自然界中存在的大多数介质的电磁特性均位于第一象限内,一些较为特殊的铁氧体材料和铁电材料等则分别具有负磁导率和负介电常数。遗憾的是,迄今为止,研究人员尚未发现介电常数和磁导率同时为负的天然材料。这种“不存在”的材料在理论上具有良好的电磁特性^[60],在该材料中,电磁波的电场矢量、磁场矢量及波矢量满足左手定则,因而能够表现出一些特殊的物理效应,如逆多普勒效应^[61]、逆切伦科夫辐射^[62]和负折射率效应^[63-64]等。在 Veselago^[60]证明这种材料的存在合理性 30 多年后,Pendry 等^[65-67]利用人工设计的周期性结构实现了负介电常数材料、负磁导率材料和二者同时为负的材料,由此打开了“超材料”世界的大门。

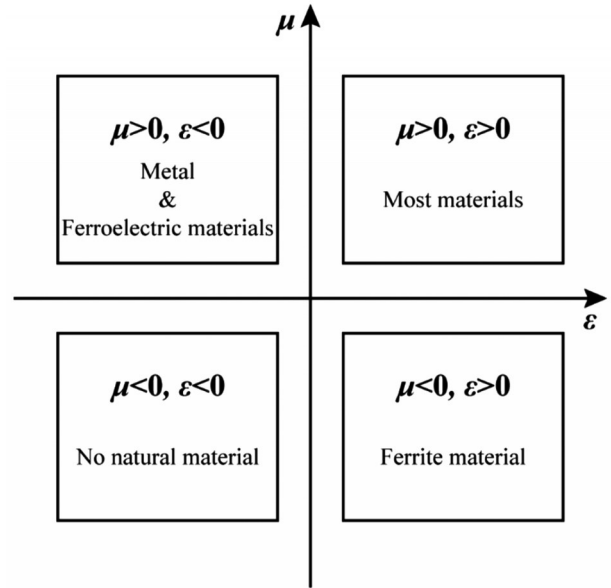


图 4 基于介电常数和磁导率划分的材料参数空间^[5]
Fig. 4 Partition of material parameter space based on dielectric constant and permeability^[5]

超材料可以利用其具有的天然材料难以具备的物理特性实施光场调控,对电磁波的振幅、相位、偏振等信息进行任意调制。这类独特性质来自其周期性排列的人工结构,而非制备材料自身。超材料问世以来,已经在光通信^[68]、灵敏探测^[69]、生物医学^[70]等领域发挥了重要作用,如图 5 所示。




图 5 超材料在各领域的应用。(a)光通信^[68]; (b)生物医学^[70]; (c)灵敏探测^[69]
Fig. 5 Applications of metamaterials in various fields. (a) Optical communication^[68]; (b) biomedicine^[70]; (c) sensitive detection^[69]

随着纳米技术的发展,研究者通过设计结构各异的超材料满足光场调控的需求。超材料设计的传统方法主要是各种数值计算方法叠加参数优化,它们严格满足各种物理规律,能够得到较好完成调控任务的解,具有较好的可解释性,但也面临着时间开销较大、难以设计复杂形状器件和难以满足复杂光场调控需求的问题。

近年来,随着计算机技术的发展和人工智能的兴起,越来越多的研究人员将目光投向了这一新兴领域,希望借助新的方法加速超材料器件的设计,更好地对各种光场进行调控。常见的超材料设计方法如图 6 所示。数值计算方法为深度学习提供基础的训练数

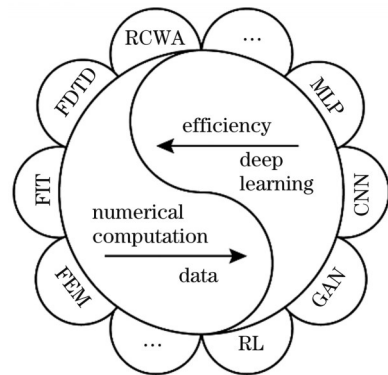


图 6 常见的超材料设计方法
Fig. 6 Common metamaterial design methods

据,而完成训练的深度学习模型能够取得远超数值计算方法的设计效率。

3.2 超材料设计方法

3.2.1 数值计算方法与参数优化相结合

数值计算结合参数优化的方法是一种依赖先验的方法,主要借助已知的物理规律进行建模,确定超材料器件的大致结构,再通过迭代调整器件结构参数并计算其光学响应达到设计目标。数值计算的本质是将电磁学、数值计算学和计算机技术结合起来,求解不同形式的麦克斯韦方程组。常见的数值计算方法有 RCWA、FDTD、有限积分法(FIT)和 FEM 等,本文主要简单介绍前两种方法。

严格耦合波分析是一种应用于(近似)周期结构衍射光学元件的分析设计的微分方法,自问世以来历经多次发展完善^[71-75],已经在超材料设计领域广泛应用^[76-78]。从数学原理上看,该方法的准确性来源于其求解过程中不存在近似。随着计算机技术的发展,RCWA 已经被集成到众多商用软件中(如 RSoft、GSolver),使得研究人员能够更简单地使用 RCWA。但是,高精度也带来了一些问题。由于 RCWA 计算精度与傅里叶展开的级数密切相关,因此,计算精度越高,计算复杂度也越高,而对傅里叶级数的截断又会造成理论上严格的方法在数学处理上不再严格^[79]。此外,RCWA 的计算量与光栅划分的层数和光栅材料的介电常数也有关,因而在面对更高的精度或复杂的器件结构需求时,也会受到计算开销快速上升的困扰。

时域有限差分法是 20 世纪 60 年代出现的一类时域微分方程数值计算方法^[80]。FDTD 的优势主要在于^[81-82]:它是对麦克斯韦方程组的直接离散,形式简单,具有较好的通用性;它是一种时域方法,宽频带的信息只需对结果进行傅里叶变换即可获取;它能够利用划分的网格区域进行并行计算,提高了效率,有效降低了计算的时间开销。该方法的主要不足是:将计算区域划分为四边形网格,在很多情况下难以得到高精度的解。

参数优化是在数值计算与目标光谱对照结果的基础上,凭借已知物理原理和先验经验,通过微调结构参数使器件能够达到预期的光场调控目标,从而完成超材料器件的设计。为了提高参数优化的效率,研究人员建立了丰富的模板库^[83],随着超材料器件结构日趋复杂,又逐渐使用以遗传算法为代表的参数搜索方法^[84]提高效率,但这类方法在参数数量较多时仍然面临着参数组合爆炸、时间开销过大等难以解决的问题。

3.2.2 深度学习设计方法

深度学习是一种数据驱动的统计学习方法,它主要通过训练各种神经网络模型完成任务。使用深度学习方法进行超材料设计的一般步骤是:首先,用数值计算方法生成目标光谱数据集,这些数据用于训练神经网络模型和检验模型效果,数据量的多少、质的高低,

都对模型训练起到举足轻重的作用。其次,构建合适的神经网络模型并进行训练,以期使其通过对大量数据的学习,完成对目标光谱与超材料结构之间高度非线性关系的建模。最后,使用新的光谱数据对模型的超材料设计效果进行检验,若神经网络模型给出的结构能够较好地进行光信号的调控,则可以认为设计成功。此过程的难点在于,如何选取恰当的神经网络模型对目标光信号与超材料之间的非线性关系进行拟合,这往往需要多次尝试和优化才能完成。深度学习设计超材料器件常用的方法有多层感知机、卷积神经网络、生成对抗网络、深度强化学习和循环神经网络等。这些方法并不是孤立的,在某些任务场景下,组合使用这些模型可以有效改善器件设计效果^[85-88]。

MLP 是一种最简单、基础的神经网络模型,在各种超材料设计工作中被广泛应用,如图 7 所示。该模型在纳米光子器件设计领域的初次使用可追溯到 2018 年,Peurifoy 等^[89]利用 MLP 完成了对 8 层球壳状纳米材料的逆向设计,如图 7(a)所示。在此工作中,他们首先训练了球壳状纳米材料光学响应的正向预测网络,而后将输出固定为目标光谱,并逐步迭代神经网络,使其能够给出对应的几何结构参数。MLP 设计结果对应的光谱与目标光谱的拟合水平显著高于传统的数值优化方法,并且大大节省了时间开销。另外,该工作还使用 MLP 成功地以高精度模拟了球壳状纳米材料的散射光谱,相比数值计算方法,同样减少了大量时间开销。

随着 MLP 应用于超材料设计,人们发现器件结构与光谱不是一一对应的,即同样的目标光谱有可能对应多组结构参数,这会影响模型的收敛,降低模型的设计能力。针对这一问题,Liu 等^[90]提出了一种将光谱的正向预测网络和器件的逆向设计网络串联的方法,如图 7(b)所示,有效克服了设计过程的多解问题。这样,包含非唯一电磁信号实例的数据集可以对 MLP 进行有效训练,从而为需要大量训练数据的复杂结构的设计奠定了基础。

随着各种器件设计任务愈发复杂,研究人员也通过多种多样的方式不断提升模型的器件设计能力和水平^[20-22]。Du 等^[34]开发了一种用于设计低维纳米结构的可扩展多任务学习(SMTL)模型,如图 7(c)所示。该模型以有限元法生成的光谱数据为基础,可以高速精确地完成光谱分类、器件设计等工作,在不同的石墨烯-硅杂化结构上都取得了很好效果,并且可以按照需求,较为容易地扩展到新器件上,大大提高了器件设计的效率。Zhao 等^[91]发布了一种基于数据增强的少样本学习(DEIFS)算法,如图 7(d)所示,首先利用正向预测的 MLP 扩展 RCWA 生成的数据集,从而降低对数值计算方法的依赖,减少数据生成的时间开销,再将前序设计结果作为后续网络模型的附加输入,经过多个 MLP 的迭代,逐步获得所需结构参数,这种迭代有效压缩了潜在解的空间,提高了设计的效度和信度。

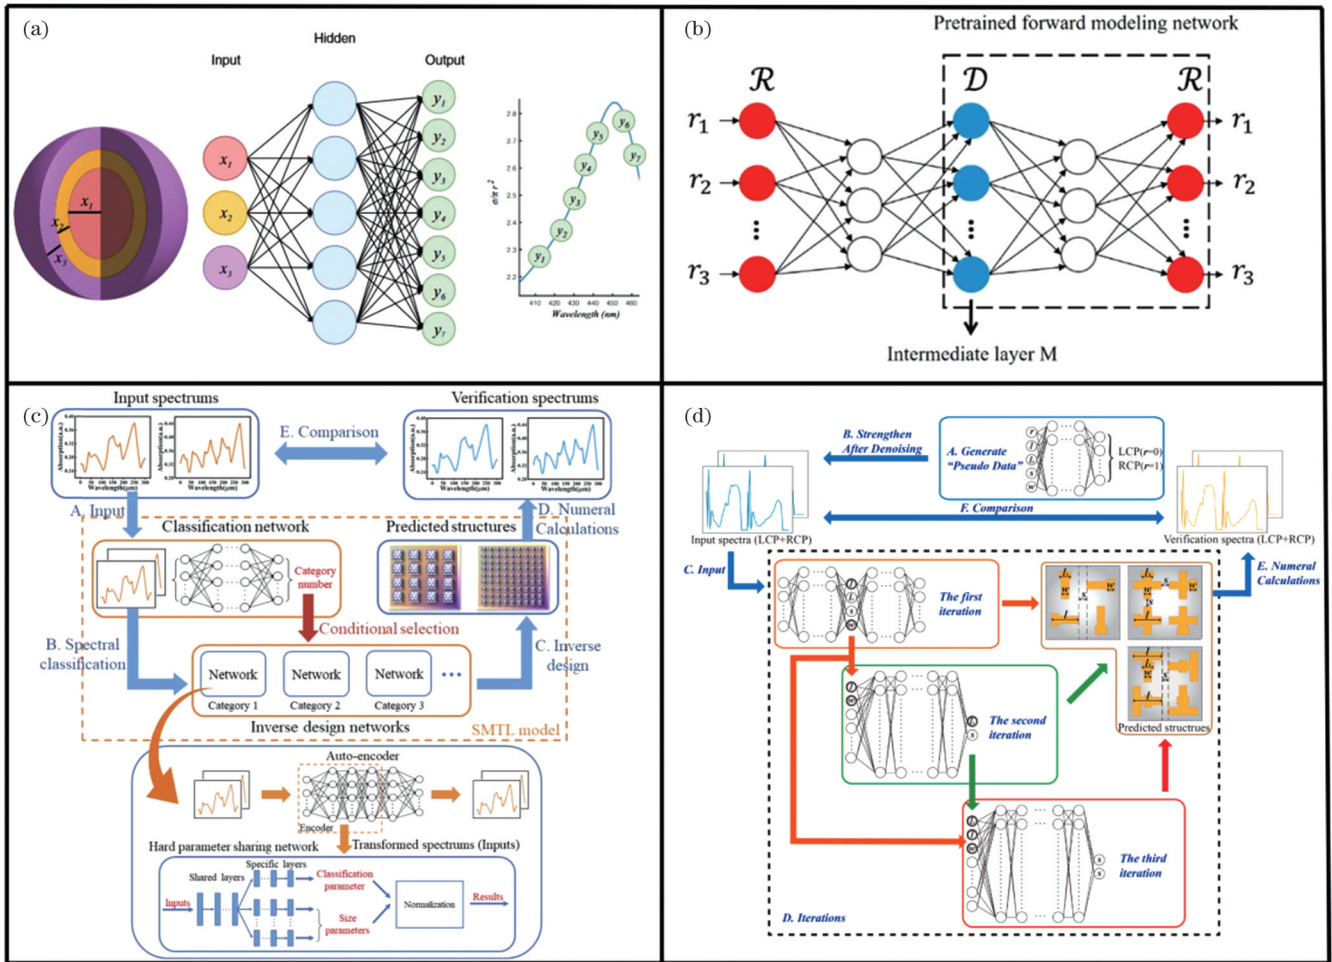


图 7 MLP 在超材料设计中的应用。(a)MLP 设计球壳状纳米材料^[89]；(b)MLP 串联解决多解问题^[90]；(c)MLP 的优化改进——SMTL 模型^[34]；(d)MLP 的优化改进——DEIFS 算法^[91]

Fig. 7 Application of MLP in metamaterial design. (a) Using MLP to design nanoparticle^[89]; (b) using MLP series to solve multi-solution problems^[90]; (c) optimization and improvement of MLP—SMTL model^[34]; (d) optimization and improvement of MLP—DEIFS algorithm^[91]

除 MLP 以外, CNN 和 GAN 等也是研究人员常用的网络模型。相比于预测结构参数的 MLP, 以上两种模型更多地将器件结构转换成图像, 从而将器件设计转换成图像预测任务, 以便更好地发挥自身优势。Zhu 等^[92]提出了一种基于迁移学习的快速精确地对功能超材料进行预测的方法, 如图 8(a) 所示。他们利用经过图像数据预训练的 Inception V3 模型, 较好地完成了对二值化超材料的预测, 设计结果的光场调控能力和实验结果高度吻合, 取得了远超其他模型的水平。Jiang 等^[93]将 GAN 用于拓扑复杂的纳米器件设计, 如图 8(b) 所示, 有效解决了迭代优化方法设计复杂器件耗时过长的的问题, 减少了约 80% 的设计时间。

近年来, 研究人员还通过结合强化学习思想或使用深度强化学习模型改善器件设计效果。利用强化学习, 可以实现器件结构的快速动态优化, 从而避免深度学习中普遍存在的“输入确定则输出确定”的静态设计带来的弊端。Sajedian 等^[94]利用双深度 Q 网络 (DDQN) 在 23 种不同材料类型和几何参数中高效地

确定了具有三层结构的超材料器件的最佳参数, 如图 8(c) 所示, 大幅提高了超材料的计算透射效率。Zhao 等^[95]将强化学习的思想融入模型, 设计了一种基于数据增强的深度贪婪优化 (DEDGO) 算法, 如图 8(d) 所示, 通过吸收强化学习的要素改善模型并引入决策过程, 实现了对在强耦合状态下工作的多种结构低维异质结的快速准确设计, 弥补了以往研究中重视神经网络模型构建而忽视决策的不足, 同时避免了强化学习方法寻找全局最优解造成的模型训练困难。在此工作中, RCWA 为 DEDGO 生成了相对较小的训练数据集, 用于训练光谱预测网络进行数据增强。

除此之外, Sajedian 等^[18]将 CNN 与 RNN 相结合以预测纳米器件结构的吸收光谱, 对器件设计起到辅助作用。如图 8(e) 所示, 使用 CNN 从图像中收集空间信息, 并利用这些数据训练 RNN, 使其学习结构信息和吸收光谱之间的关系。结果表明, 这种图像处理方法是准确的, 可以用来代替费时的数值模拟。训练成功的模型可以在不到 1 s 的时间内给出对光学结果的预测。

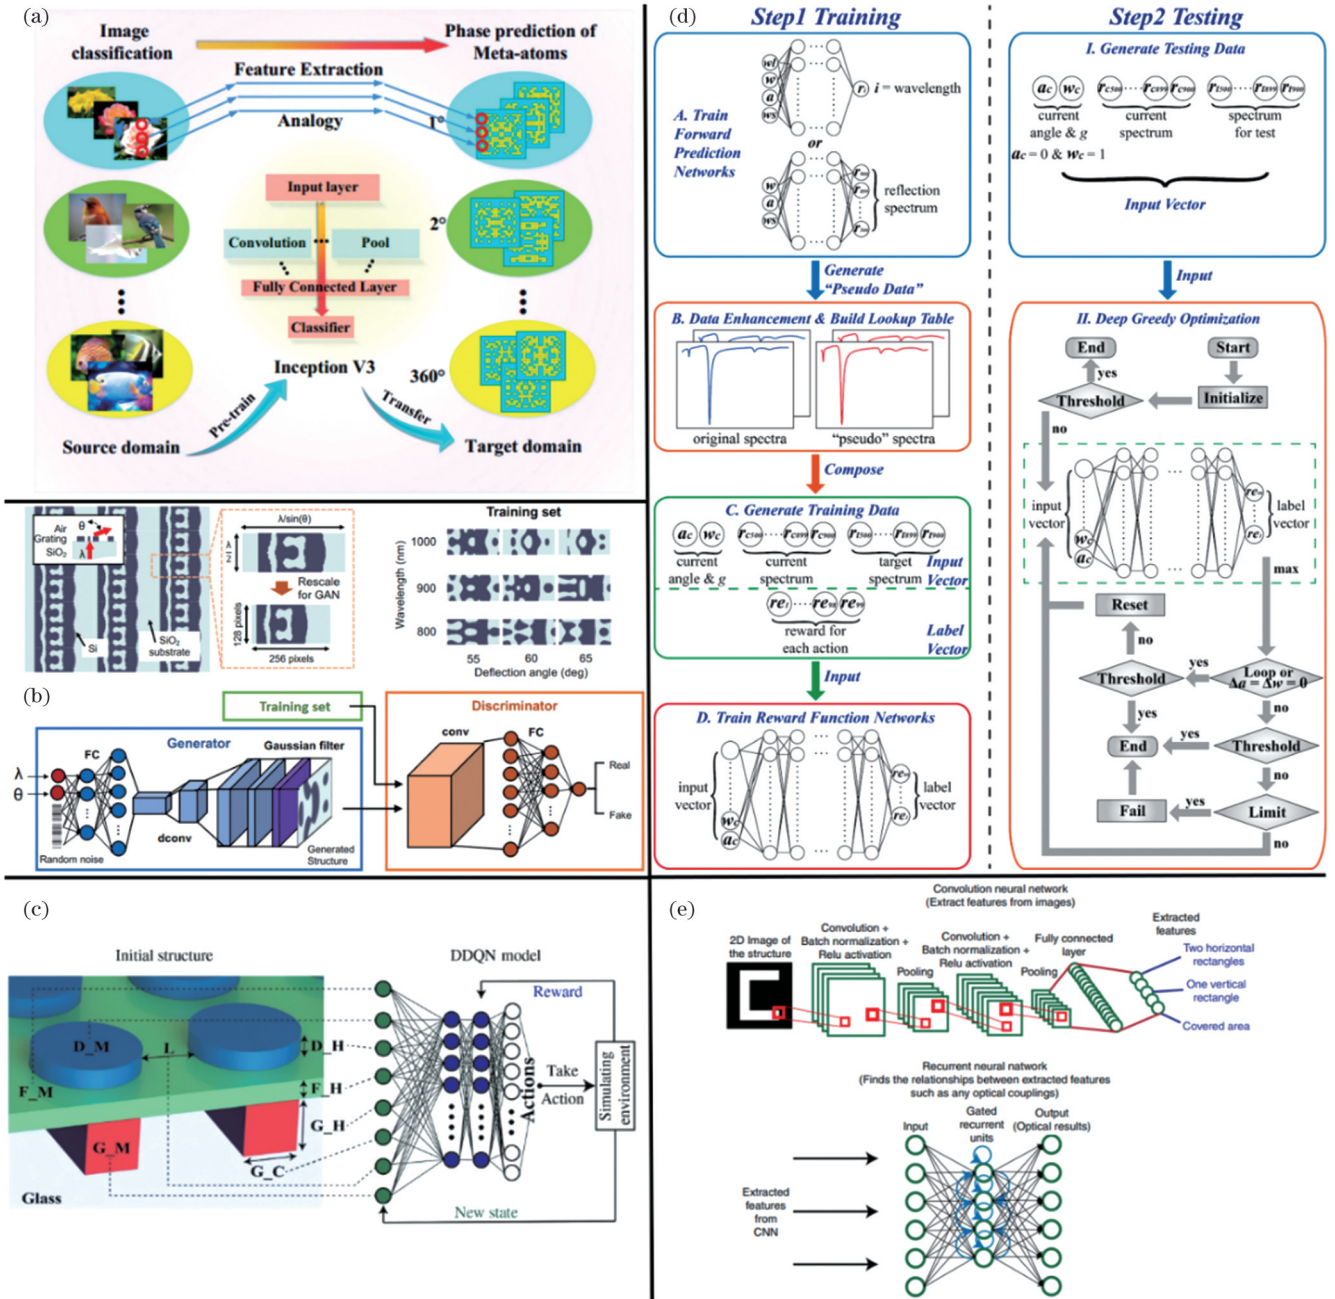


图 8 深度学习进行超材料设计的其他方法。(a)利用 CNN 对二值图像化的超材料器件进行设计^[92]；(b)利用 GAN 对具有复杂拓扑结构的超材料器件进行设计^[93]；(c)利用 DDQN 对器件材料类型和结构参数进行动态设计^[94]；(d)利用 DEDGO 对多种低维异质结构进行设计^[95]；(e)利用 RNN 对超材料器件进行设计^[18]

Fig. 8 Other deep learning methods for metamaterial design. (a) Using CNN to design binary imaged metasurface devices^[92]; (b) using GAN to design metamaterial devices with complex topology^[93]; (c) using DDQN to dynamically design device material types and structure parameters^[94]; (d) using DEDGO to design a variety of low-dimensional heterostructures^[95]; (e) using RNN to design metamaterial devices^[18]

4 深度学习在光纤光束控制中的应用

前面介绍的工作是以深度学习方法为基础,对超材料的结构进行设计,从而满足特定的调控目标。除了这一方面,深度学习在光纤光束控制中也发挥着越来越重要的作用。光纤光束控制主要是指针对某一个具体的光学系统,为了使其保持在一个稳定的输出状态或期望的目标状态,主动对系统中的某些可调参数

进行不断调节的过程。随着深度强化学习在动态环境的控制中愈发出色的表现,它在光纤光束控制中的应用也在不断丰富。

此类工作存在一些共性特征,比如均需要监测光学系统中的输出信号用于判定系统的当前状态,并根据系统设计恰当的奖励函数和损失函数,结合智能优化算法对系统可调节的参数进行数字化控制,最终使得整个系统达到并保持期望状态。这一类优化算法

的基本模型如图 9 所示,其中“state”表示光学系统中被监测的一系列信号,比如光学系统输出端口的峰值功率、光谱带宽、单脉冲能量、中心波长和重复频率等;“reward”是前面所提及的奖励函数,它的设计与期望达到的系统状态有关,因此在不同的工作中奖励函数有所不同;“action”则表示智能优化算法根据当前系统的状态和得到的奖励值确定下一步调整的系统中的可控参数。通过不断循环迭代,光学系统的输出会随着参数的调整逐步到达目标状态。




图 9 光学系统中的智能优化算法基本模型

Fig. 9 Basic model of intelligent optimization algorithm in optical system

总而言之,在光学系统中的光纤光束控制问题可以近似于反馈控制问题,这类问题在过去通常是利用 PID 算法、随机并行梯度下降 (SPGD) 算法或自适应优化算法来解决的。随着深度学习的发展,近几年来深度强化学习越来越频繁地应用在光学系统的光束控制中,并取得了相比传统技术更好的效果。下面将主要介绍利用智能算法控制激光器自动锁模和控制相干光学系统相位稳定的部分工作。

4.1 锁模光纤激光器控制研究进展

锁模光纤激光器是产生光频梳的重要手段之一,通过设计适当的结构,它能够生成飞秒 (10^{-15} s) 或皮秒 (10^{-12} s) 脉冲,被应用于各个领域,包括非线性光学、精密测量等^[96-101]。但其应用前提在于激光器需要保持长时间的稳定锁模状态,且在锁模状态被扰乱时能够快速恢复。要恢复锁模激光器的锁模状态,仅依赖手动调节

偏振态的方法会效率极低。这一缺陷被发现后,电动偏振控制器 (EPC) 得以发明,使得人们可以实现系统偏振态的自动控制^[102-104]。EPC 利用的是对电压的调控,当把 EPC 加入激光器后,激光器的偏振状态调控就可以通过多次改变 EPC 的多路输入电压来实现。在多次改变偏振态的同时监测激光器的输出状态,即可使得激光器达到目标状态,这是一个典型的反馈控制过程。

到目前为止,激光器的自动锁模算法已经有较多的研究工作^[105-111],其中大部分都是基于非线性偏振旋转 (NPR) 被动锁模技术实现的。这一技术基于自相位调制引起的非线性相移的可饱和吸收体实现。2010 年,德国明斯特大学 Hellwig 等^[107]在锁模激光器腔内加入了压电式挤压器件作为自动偏振控制器,并且使用偏振测量仪测量了腔内的偏振态,得到了基于 NPR 的锁模特征庞加莱球分布,为自动锁模的实现奠定了基础。

图 10 (a) 展示了 2016 年英国帝国理工学院 Woodward 等^[112]提出的基于遗传算法 (GA) 的自动锁模控制实验结构。他们以激光器输出功率作为反馈,计算机控制 EPC 的电压和泵浦电流形成反馈控制回路。由于激光器在锁模状态时输出功率会保持稳定,而处于其他状态时输出功率很可能不稳定,故而作者使用功率计探测输出功率作为系统状态的反馈。在锁模激光器中,影响激光器输出状态的因素主要包括偏振态和泵浦光源的输出功率,只有二者均合适时,才能得到稳定的锁模状态,因此作者采取对偏振态和泵浦源同时控制的方法实现对激光器系统的反馈,以确保激光器能够稳定产生锁模状态。实验中的遗传算法使用了每代 30 个个体,这样的设置能够满足遗传算法的多样性要求并达到目标状态速度平衡。该算法平均能够在 20 代内搜索到目标状态,且实现锁模的时间在 30 min 左右。其收敛时间较慢的主要原因在于 EPC、泵浦源与计算机之间的交互延迟。

2019 年,上海交通大学义理林教授团队 Pu 等^[113]开发了基于 Rosenbrock 搜索的类人算法 (HLA),同样

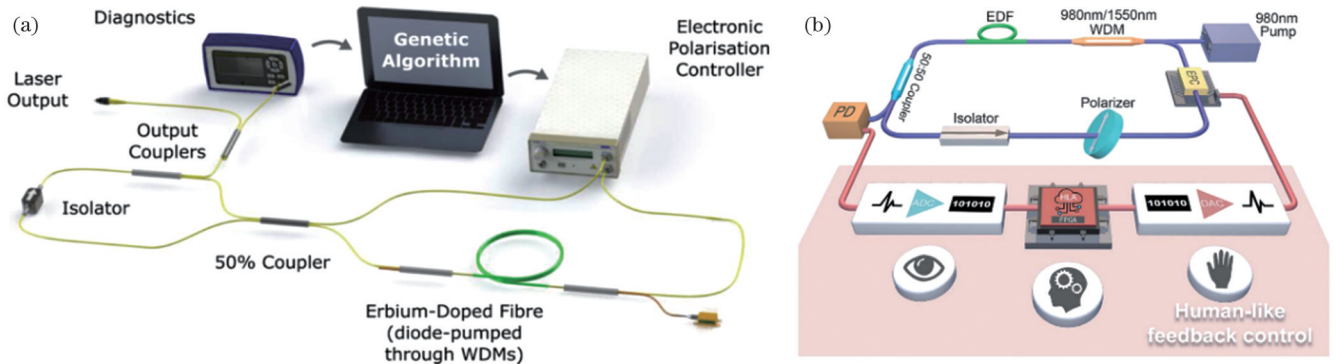


图 10 基于不同搜索方法实现的智能锁模激光器结构。(a) 基于遗传算法的自优化锁模激光器实验结构^[112]; (b) 基于 HLA 算法的智能锁模光纤激光器实验结构^[113]

Fig. 10 Intelligent mode-locked laser structures based on different search methods. (a) Experimental structure of self-optimizing mode-locked laser based on genetic algorithm^[112]; (b) experimental structure of intelligent mode-locked fiber laser based on HLA algorithm^[113]

实现了 NPR 激光器的自动锁模,相关工作发表在光学期刊 *Optica* 上,其具体实验结构如图 10(b)所示。该团队将 HLA 算法部署于现场可编程门阵列(FPGA)开发板中,且该工作能够在不改变激光器光路结构的基础上定位到不同的工作状态,如基频锁模、谐波锁模和调 Q 锁模等,该方案得到的最短锁模时长为 0.22 s,最短恢复时间为 14.8 ms。由于自动锁模控制和锁模恢复的算法都部署于 FPGA 中,因此激光器与 FPGA 之间的交互速度大大提升,从而加快了锁模恢复时间。更值得一提的是,2022 年,该团队基于遗传算法设计了更复杂的 MAIS 优化算法,并将其应用于单腔双光梳锁模激光器的自动锁模搜索中^[114],为搭建稳定的锁模双光梳光源提供了新思路。

美国华盛顿大学 Kutz 团队 Sun 等^[115]在 2020 年从强化学习的角度出发,从仿真层面提出使用深度强化学习算法实现对锁模激光器的自动锁模控制,算法的结构如图 11(a)所示。作者通过抽象锁模激光器的结构,将其输出结果和偏振态作为深度强化学习的状态输入,并与锁模激光器输出信号的激励组合,训练出一个神经网络模型,用于决策偏振态的调整方案。该工作的发表为后续设计深度强化学习算法以及其他神经网络算法部署于锁模激光器的自动锁模应用奠定了基础。

2021 年,国防科技大学江天研究员团队 Yan 等^[24]基于 DDPG 策略设计了 DELAY 强化学习算法,并基于该算法与所搭建的锁模激光器,设计了一个自动锁模控制的激光器系统,结构如图 11(b)所示,以实现激光器的稳定锁模状态的保持和恢复。这一工作的出发点在于解决基于饱和吸收体的锁模激光器在产生或恢复稳定的锁模光频梳时需要耗费大量时间的问题。为了能够控制激光器的锁模状态,激光器系统中的偏振控制器使用的也是 EPC。通过将 DELAY 算法部署在计算机上,并与 FPGA 进行交互反馈输出 EPC 的 4 路电压,实现了对整个激光器系统的快速控制。实验结果表明,DELAY 算法可以在锁模激光器锁模状态因环境抖动丢失后快速恢复其锁模状态。统计发现,DELAY 算法的平均恢复时长为 1.948 s。该团队还验证了 DELAY 算法可在 15~40 °C 的任意环境温度下恢复激光器的稳定锁模状态。

将深度强化学习应用于锁模光纤激光器中,需要解决算法与实际系统的结合、交互以及网络模型的训练和验证等问题。要将算法和锁模激光器结合,首要的是对激光器的输出和控制参量进行抽象,变为强化学习算法中可以训练的数据。强化学习算法训练所需的数据集主要包括锁模激光器的当前状态、对激光器的抽象动作、执行这一动作后的激励值和后期状态,以及后期状态是否属于目标状态这 5 组参数。这些参数需根据实际系统来设计和抽象。以 DELAY 算法为例,该工作中将 EPC 的电压值及激光器输出时域稳定性和频域稳定度作为状态值,将动作定义为 EPC 的

4 路输入电压值,激励值可由定义的激励函数决定。激励函数的设计基本原则就是越接近目标状态,激励值越大,该函数由算法监测的输出状态决定。

要将算法与实际系统交互,需要考虑如何自动控制激光器中的器件以及将输出结果采集到处理板卡中。同样以上一工作为例,所控制的参数为激光器中的 EPC,因此只需要控制板卡中的输出电压,并通过杜邦线将板卡和 EPC 的供电端口连接起来,即可完成对激光器系统的调节。接收数据方面,该算法通过示波器采集探测器探测的时域和频域电信号,并以合适的命令接收示波器上的采集数据。板卡上通过预处理算法完成对时频信号的处理,并基于现有标准判断激光器状态是否属于目标状态。

在训练网络模型过程中,算法和系统是实时交互的。在训练过程中不断地修改锁模激光器中 EPC 的输入电压,会得到不同参数下的输出结果。通过持续记录系统参数与输出结果,并基于所设计的奖励函数计算出当前参数配置下的激励值,共同组成训练数据集。在训练初期数据集不足的情况下,通过不断修改参数并采集输出结果构成一定规模可用于网络训练的数据集,即达到深度强化学习算法中所定义的缓冲池。在训练过程中,参数优化的过程同样会持续进行,因此,数据集也在持续扩充和更新。

网络模型训练到一定的阶段后,就可以应用于激光器的锁模状态搜索。具体的运行过程为:通过示波器读取探测器输出的时频数据,再利用网络传输的方式将数据传输到处理板卡上。处理板卡得到数据后,会依据固定策略判断系统是否处于锁模状态,当到达该状态时,就不会改变 EPC 的 4 路电压。为实现对系统的持续监测,间隔 0.5 s 后会重新读取系统输出状态。当发现系统未处于锁模状态时,则会依据当前状态使用训练好的 actor 网络模型计算需要执行的动作,即改变 EPC 的 4 路电压。等待 0.1 s 后,系统基本达到某个稳定状态,实时监测算法将进入新一轮迭代,在达到目标锁模状态前会持续改变 EPC 电压。该过程可以持续运行,以用于激光器系统稳定锁模状态的监测和保持,直到受到中断才会结束相应的流程。

在深度强化学习方法被实际应用于锁模光纤激光器的自动锁模控制后,许多科研人员开始将深度学习算法应用到各类光纤激光器的状态控制当中。2022 年,中国科学院 Li 等^[116]基于深度强化学习和长短期记忆(LSTM)网络模型设计反馈控制算法用于稳定锁模激光器的状态,其控制参数主要包括 EPC 的电压与泵浦光源的光功率。激光器的具体结构如图 11(c)所示。该团队基于深度强化学习和光谱学习方法实现了锁模模式的搜索算法和锁模状态切换算法。通过仿真和实验发现,该方法能够在平均 0.69 s 的时间内将激光器的状态从随机状态恢复到基频锁模状态。此外,该团队基于光谱学习方法实现了不同锁模状态与泵浦

光源功率之间的映射,从而能够在 300 ms 内切换锁模的状态。这显示了深度强化学习在锁模激光器的稳定控制研究中的重要性,它可以显著提高激光器的稳定性和锁模恢复效率。

同样在 2022 年,南京理工大学 Luo 等^[117]受到深度强化学习中的 TD3 算法启发,将该算法应用到了超快绿光波段 Ho:ZBLAN 激光器,结构如图 11(d) 所示。这一类激光器与前面所提到的工作中的激光器类似,

同样面临锁模状态难以调节的问题,然而,此前还没有人将强化学习方法应用到此类激光器的锁模控制中。因此该团队通过 TD3 算法对激光器中的波片和偏振片进行数字控制,并通过监测激光器系统的输出能量和峰值功率抽象出系统的奖励函数,从而实现 NPR 自动锁模。加入了 TD3 算法后,该激光器系统得到的最大输出功率可达 288 mW,最小脉宽为 19.7 ps,最大脉冲能量为 0.98 nJ。

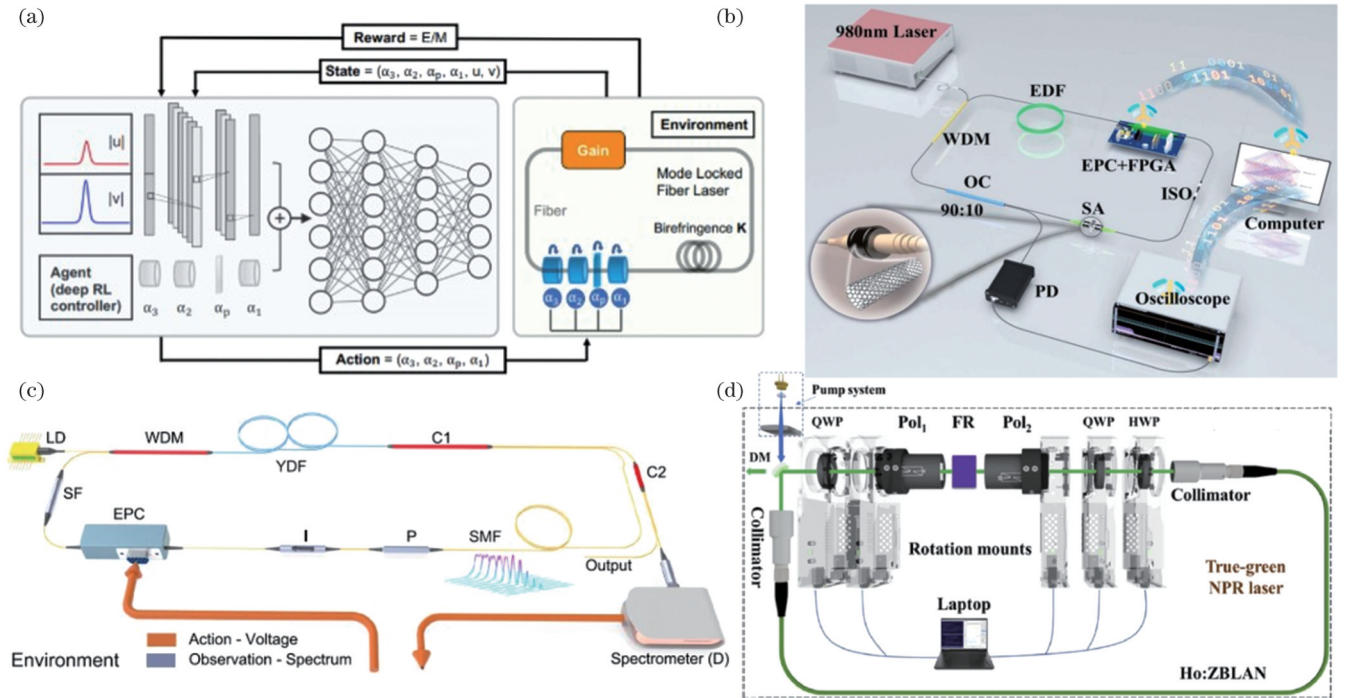


图 11 基于不同深度强化学习算法的智能锁模激光器结构。(a)使用DQN算法设计的自适应锁模激光器模型^[115]; (b)基于DELAY算法的自动锁模激光器系统^[24]; (c)基于强化学习和光谱学习的锁模激光器系统^[116]; (d)基于TD3算法实现的智能锁模激光器架构^[117]

Fig. 11 Intelligent mode-locked laser structures based on different deep reinforcement learning algorithms. (a) Adaptive mode-locked laser model designed using DQN algorithm^[115]; (b) automatic mode-locked laser system based on DELAY algorithm^[24]; (c) mode-locked laser system based on reinforcement learning and spectral learning^[116]; (d) intelligent mode-locked laser architecture based on TD3 algorithm^[117]

表 1 展示了近年来随着算法的不断优化和成熟,锁模激光器的平均锁模恢复时间的发展情况,其中 EA 表示进化算法,MDRL 指对应工作中所设计的深度强化学习算法。容易发现,相比传统的启发式搜索方法,基于深度强化学习设计的锁模状态搜索算法效

率高一个数量级,这也反映了深度强化学习方法在光学系统中状态搜索应用的强适配性。

强化学习方法能展现出如此优异的性能,原因主要有以下两点:一方面,深度强化学习中的网络模型训练过程是基于实际系统中获取的数据完成的。无论系

表 1 不同算法锁模时间对比

Table 1 Comparison of different algorithms in mode-locking time

Year	Algorithm name	Mode-locked state search time	
2015	EA ^[118]	~30 min	
2016	GA ^[112]	~30 min	
2017	GA ^[102]	~30 s	
2019	HLA ^[113]	0.22 s least recovery time	3.1 s average recovery time
2021	DELAY ^[24]	0.472 s least recovery time	1.948 s average recovery time
2022	MDRL ^[116]	0.2 s least recovery time	0.69 s average recovery time

统初始状态的随机性如何,训练好的深度强化学习网络模型都能够记忆目标状态,因此能够在很短的时间内调节系统的参数,从而实现稳定系统的目标。另一方面,深度强化学习网络模型在控制系统到达目标状态的同时,也在不断扩充其本身的数据集,并不断更新网络模型。这一网络更新机制也使得深度强化学习算法能持续适应系统环境的变化,对噪声的容忍性更强。而传统的智能算法或者没有记忆性,或者只能在某一个特定的环境具备良好的控制能力。这两个问题会导致传统智能算法在控制光纤光束系统到达目标状态的速度和稳定性上都存在一定的缺陷,而深度强化学习恰好借助其特性解决了这些问题。

正因深度强化学习算法在激光器系统的反馈控制中展现的高效性和稳定性,智能光纤锁模激光器的搭建和稳定锁模搜索过程将会不断简化,而且激光器的环境自适应性和抗噪性可以得到大幅度提升。随着深度强化学习算法逐步完善,它与锁模激光器系统的耦合程度也将越来越高。尽管智能锁模激光器目前仅出现在论文中,但未来有望推出商业化产品。

4.2 相干光纤光学系统的相位噪声控制研究进展

在利用智能学习算法对锁模激光器进行自动锁模状态搜索的相关工作中所取得的效果能够反映出深度强化学习在光纤光束控制中的有效性和稳定性。在光纤光束控制的任任务中,除锁模激光器的锁模恢复过程以外,相干光学系统的稳定过程也逐步引入了智能控制算法。由于相干光学系统中存在多路并行传输光载波的过程,系统中不同路之间的相位难免会产生一定的误差,若相位差未加校正,则多路合束后输出的功率将会不稳定,从而导致系统信号传输时效率降低。因此,相干光学系统中的相位控制也十分重要。若仅手动调节不同路之间的相位差,效率明显无法满足实际应用中的需求,因此需要使用智能优化算法对相干光学系统进行反馈控制。下面介绍相干光纤光学系统相位噪声控制技术的研究进展,包括非信息处理的相干

合成系统和包含计算操作的相干光纤光计算系统中相位噪声控制的研究进展。

4.2.1 相干合成系统

相干合成是一种利用多路来自不同光源的相干光信号进行叠加和合成的技术。在相干合成过程中,光波间具有一定的相位关系,而这种相位关系的调节和控制是实现高质量相干合成的关键因素。但是相干合成过程中系统会面临由环境带来的相位噪声,从而导致输出功率波动。在相干合成系统中,控制算法的优化目标为补偿相位噪声,从而提升光功率。2009年,国防科技大学周朴研究员^[119]所在团队提出基于SPGD算法控制二维高功率光纤放大器阵列进行相干合成,具体结构如图12(a)所示。该团队利用光电探测器探测合束后信号的强度作为反馈来源,在DSP中部署SPGD算法,并用于控制4路传输通道中的相位调制器,从而稳定4路信号之间的相位差,尽可能得到高功率信号。实验结果表明,这一系统的总输出功率可达60.1 W,这也意味着基于SPGD算法的相干光束很有可能被应用于高功率光载波的产生。后续该团队扩展了更多路数的相干波束进行合成,并同样基于SPGD算法进行相位控制,也取得了较好的效果^[27]。到2020年,该团队已经实现107路相干光合成的系统,而这107路中的相位调制器同样是由部署了SPGD算法的DSP进行控制,从而实现合束信号输出的最大化^[23]。2019年,该团队首次将深度学习引入相干合成系统,旨在准确估计和补偿相干合成系统的相位误差。该工作采用两级相控策略,结合了深度学习模型和SPGD算法,可以缓解长期存在的问题:随着阵列元素数量的增加,相控带宽会逐渐减小。而且,通过区分具有共轭相位分布的轨道角动量光束,该相位控制技术还可用于产生不同阶次的轨道角动量光束^[120]。此外,Tünnermann等^[121]探讨了在相干合成系统中使用强化学习和神经网络的方法。从随机初始化的神经网络开始,系统收敛到一种相位稳定策略,这种策略与软件实

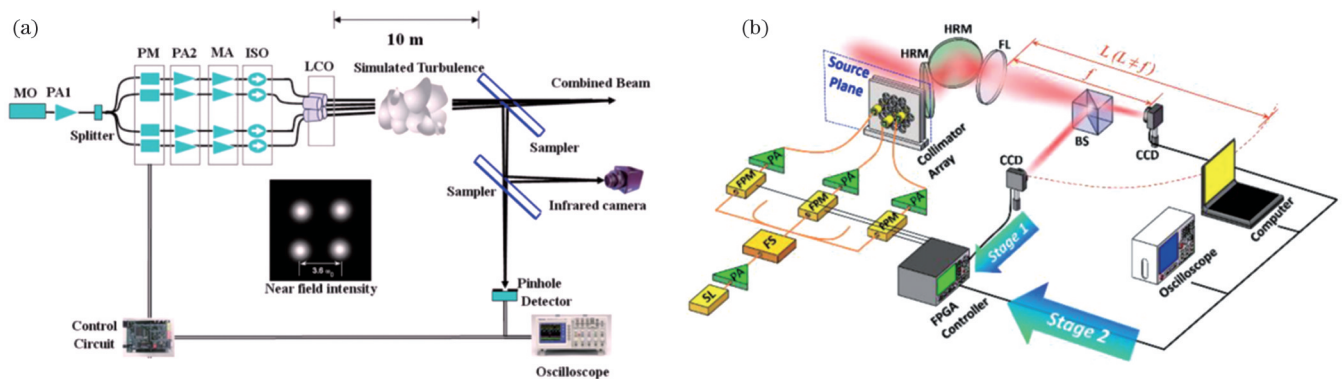


图 12 部分相干光学系统控制结构。(a)基于SPGD算法的4路光纤放大器相干合成系统^[119]; (b)基于深度学习模型和SPGD算法的两级相控系统^[120]

Fig. 12 Control structure of partially coherent optical systems. (a) Coherent beam combination system for 4-beam fiber amplifier based on SPGD algorithm^[119]; (b) two-stage phase control system based on deep learning model and SPGD algorithm^[120]

现的 PID 控制器相当。此外,该工作还展示了神经网络预测相对相位噪声的能力,这是应用强化学习和神经网络的一个潜在优势。

4.2.2 相干光纤光计算系统

近年来,随着计算机技术的不断发展和光学技术的不断进步,光计算作为一个新兴领域受到了越来越多的关注和研究。其中相干光纤光学计算系统基于相干探测技术,突破了传统非相干型架构无符号数运算的限制,实现了复数运算。计算过程中系统同样面临器件本身和环境带来的相位失配,从而导致计算错误^[122]。不同于相干合成系统,相干光计算系统中携带了信息,不能简单地将其优化目标设置为光功率达到最大值,而是需要在计算结果变化的情况下稳定其计算值。2023年,国防科技大学江天研究员团队 Zhang 等^[123]再次基于强化学习设计了 DRCON 用于控制相干光子神经元系统的稳定性,具体结构如图 13 所示。在相干光子神经元系统中,由

于同类型器件的工艺无法达到绝对一致且环境中存在噪声的影响,两路光载波信号的相位存在一定差异,从而会导致计算结果不稳定。因此该团队在其中一路中加入了相位调制器进行外力调控,从而控制两路光载波相位的一致性。他们将 DRCON 部署于硬件中对整个光子神经元系统进行反馈控制,使得整个系统最终的输出保持稳定。他们将该算法与 SGD 算法在系统的稳定中进行性能对比,最终发现,在稳定输出结果方面,DRCON 方法相比 SGD 速度快了 33%,光子神经元的计算精度可达 5.5 bit;当环境中产生抖动噪声时,DRCON 只需几个周期即可将系统恢复到稳定状态,而 SGD 方法需要 20~50 个周期。这也证明了深度强化学习在相干光学系统的相位控制上可以提供有效的技术支撑。随着相干光计算技术的发展,相关的噪声问题将会更加凸显,需要进一步研究和探索如何控制噪声,从而将相干光计算应用到各个领域。




图 13 相干光子神经元系统^[123]

Fig. 13 Coherent optical neuron system^[123]

5 结 语

本文重点关注了深度学习在超材料设计和光纤光束控制中应用的近期研究工作。深度学习的引入极大地推动了超材料设计和光纤光束控制的发展。面对日益复杂的光学系统,传统方法存在以下问题:(1) 无法有效迁移专家经验;(2) 传统方法无法避免数值计算;(3) 可求解问题空间有限。相较于传统方法,深度学习方法在一定程度上能够帮助人们隔绝底层的物理细节,从而降低设计和控制的难度。在超材料设计方面,人们可以积累传统的材料设计经验,利用深度学习方法设计结构更复杂、功能更丰富的全新超材料。在光纤光束控制方面,人们可以借助现有的深度强化学习框架解决更多光学系统中的控制问题,降低人工调控的成本,增强系统的稳定性。这将使得许多光学系统的应用场景不再受限于实验室,而是能够更好地适应自然环境。

然而,深度学习方法依然存在不少的挑战。第一个问题是数据集问题。一方面,神经网络的训练依赖于统计学习方法,这就意味着得到一个智能高效的神经网络必须依赖于规模宏大的数据集。然而,在一些光学场景中,数据集的产生往往需要消耗极其庞大的人力和物力。数据集的匮乏将在很大程度上限制神经

网络的性能和推广。针对这一问题,一个好的解决方案就是倡议推动数据集的标准化工作。以深度学习的主流应用场景计算机视觉为例,众多组织和团体设计了许多标准化数据集作为领域的基准,从而能够推动深度学习算法在计算机视觉领域的发展。另一方面,对超材料设计而言,深度学习已经得到了广泛应用,但是训练神经网络的数据集还是百家争鸣,基本上每一项工作的数据集都是各研究团队自主使用传统数值方法计算得来的,造成了算法横向性能比较困难、模型广泛推广困难的问题。

第二个问题是深度学习的不确定性问题。这一问题本质上是由于统计学习方法本身的不确定性导致的。这种不确定性使得深度学习的计算结果在一定程度上需要物理实验的检验。当然,良好的数据集设计能够在一定程度上缓解这一问题,但是噪声等干扰因素以及统计本身的特点使得这一问题难以从根本上解决。

最后一个是深度学习的解释性问题。在诸多情况下,深度学习这一工具应用于各个领域时,均把模型当作黑盒处理,模型内部的情况对于研究者而言不可见,导致深度学习的一些行为缺乏理论依据。

综上,现阶段深度学习应用于超材料设计和光纤光束控制领域取得了突出进展,但也伴随着不少的挑战。这些挑战也为相关研究指明了方向。

参 考 文 献

- [1] Akyurtlu A, Werner D H. A novel dispersive FDTD formulation for modeling transient propagation in chiral metamaterials[J]. *IEEE Transactions on Antennas and Propagation*, 2004, 52(9): 2267-2276.
- [2] Hao Y, Mittra R. FDTD modeling of metamaterials: theory and applications[M]. Boston: Artech House, 2009.
- [3] Polycarpou A C. Introduction to the finite element method in electromagnetics[J]. *Synthesis Lectures on Computational Electromagnetics*, 2006, 1(1): 1-126.
- [4] Moharam M G, Gaylord T K. Rigorous coupled-wave analysis of planar-grating diffraction[J]. *Journal of the Optical Society of America*, 1981, 71(7): 811-818.
- [5] 陶梓隆. 基于神经网络算法的二维手性超材料的预测与设计[D]. 长沙: 国防科技大学, 2020.
- [6] Tao Z L. Prediction and design of two-dimensional chiral metamaterials based on artificial neural network algorithm[D]. Changsha: National University of Defense Technology, 2020.
- [7] Puzyrev V. Deep learning electromagnetic inversion with convolutional neural networks[J]. *Geophysical Journal International*, 2019, 218(2): 817-832.
- [8] An Y, Huang L J, Li J, et al. Learning to decompose the modes in few-mode fibers with deep convolutional neural network[J]. *Optics Express*, 2019, 27(7): 10127-10137.
- [9] Dong Y, Wu C H, Zhang C, et al. Bandgap prediction by deep learning in configurationally hybridized graphene and boron nitride [J]. *NPJ Computational Materials*, 2019, 5: 26.
- [10] Li X Z, Shu J, Gu W H, et al. Deep neural network for plasmonic sensor modeling[J]. *Optical Materials Express*, 2019, 9(9): 3857-3862.
- [11] Kiarashinejad Y, Abdollahramezani S, Adibi A. Deep learning approach based on dimensionality reduction for designing electromagnetic nanostructures[J]. *NPJ Computational Materials*, 2020, 6: 12.
- [12] Kiarashinejad Y, Zandehshahvar M, Abdollahramezani S, et al. Knowledge discovery in nanophotonics using geometric deep learning[J]. *Advanced Intelligent Systems*, 2020, 2(2): 1900132.
- [13] Xiong J K, Shen J Q, Gao Y A, et al. Real-time on-demand design of circuit-analog plasmonic stack metamaterials by divide-and-conquer deep learning[J]. *Laser & Photonics Reviews*, 2023, 17(3): 2100738.
- [14] Chen W, Gao Y A, Li Y Y, et al. Broadband solar metamaterial absorbers empowered by transformer-based deep learning[J]. *Advanced Science*, 2023: 2206718.
- [15] Chen Y S, Zhu J F, Xie Y N, et al. Smart inverse design of graphene-based photonic metamaterials by an adaptive artificial neural network[J]. *Nanoscale*, 2019, 11(19): 9749-9755.
- [16] Rajaraman G, Sood K, Anbazhagan S. A novel method to compute resonant frequency of metamaterial based patch antennas using neural networks[J]. *International Journal for Research in Applied Science & Engineering Technology*, 2016, 4: 321-325.
- [17] Peurifoy J, Shen Y C, Jing L, et al. Nanophotonic particle simulation and inverse design using artificial neural networks[J]. *Science Advances*, 2018, 4(6): eaar4206.
- [18] Inampudi S, Mosallaei H. Neural network based design of metagratings[J]. *Applied Physics Letters*, 2018, 112(24): 241102.
- [19] Sajedian I, Kim J, Rho J. Finding the optical properties of plasmonic structures by image processing using a combination of convolutional neural networks and recurrent neural networks[J]. *Microsystems & Nanoengineering*, 2019, 5: 27.
- [20] Qu Y R, Jing L, Shen Y C, et al. Migrating knowledge between physical scenarios based on artificial neural networks[J]. *ACS Photonics*, 2019, 6(5): 1168-1174.
- [21] Malkiel I, Mrejen M, Nagler A, et al. Plasmonic nanostructure design and characterization via deep learning[J]. *Light: Science & Applications*, 2018, 7: 60.
- [22] Ma W, Cheng F, Liu Y M. Deep-learning-enabled on-demand design of chiral metamaterials[J]. *ACS Nano*, 2018, 12(6): 6326-6334.
- [23] Wiecha P R, Muskens O L. Deep learning meets nanophotonics: a generalized accurate predictor for near fields and far fields of arbitrary 3D nanostructures[J]. *Nano Letters*, 2020, 20(1): 329-338.
- [24] Chang H X, Chang Q, Xi J C, et al. First experimental demonstration of coherent beam combining of more than 100 beams [J]. *Photonics Research*, 2020, 8(12): 1943-1948.
- [25] Yan Q Q, Deng Q H, Zhang J, et al. Low-latency deep-reinforcement learning algorithm for ultrafast fiber lasers[J]. *Photonics Research*, 2021, 9(8): 1493-1501.
- [26] Katoch S, Chauhan S S, Kumar V. A review on genetic algorithm: past, present, and future[J]. *Multimedia Tools and Applications*, 2021, 80(5): 8091-8126.
- [27] Ang K H, Chong G, Li Y. PID control system analysis, design, and technology[J]. *IEEE Transactions on Control Systems Technology*, 2005, 13(4): 559-576.
- [28] Zhou P, Liu Z J, Ma Y X, et al. Bandwidth analysis and improvement of the beam phasing of fiber amplifiers using the stochastic parallel gradient descent algorithm[J]. *Optics & Laser Technology*, 2010, 42(7): 1059-1065.
- [29] Nguyen T T, Nguyen N D, Nahavandi S. Deep reinforcement learning for multiagent systems: a review of challenges, solutions, and applications[J]. *IEEE Transactions on Cybernetics*, 2020, 50(9): 3826-3839.
- [30] Zhu S Q, Yu T, Xu T, et al. Intelligent computing: the latest advances, challenges, and future[J]. *Intelligent Computing*, 2023, 2: 6.
- [31] Goodfellow I, Bengio Y, Courville A. Deep learning[M]. Cambridge: The MIT Press, 2016.
- [32] McCulloch W S, Pitts W. A logical calculus of the ideas immanent in nervous activity[J]. *Bulletin of Mathematical Biology*, 1943, 5: 115-133.
- [33] LeCun Y, Bengio Y. Convolutional networks for images, speech, and time series[M]//Arbib M A. The handbook of brain theory and neural networks. Cambridge: The MIT Press, 1995.
- [34] Graves A. Long short-term memory[M]//Graves A. Supervised sequence labelling with recurrent neural networks. Studies in computational intelligence. Berlin: Springer, 2012, 385: 37-45.
- [35] Du S Y, You J, Tang Y H, et al. Achieving efficient inverse design of low-dimensional heterostructures based on a vigorous scalable multi-task learning network[J]. *Optics Express*, 2021, 29(13): 19727-19742.
- [36] Du S Y, You J E, Zhang J, et al. Expedited circular dichroism prediction and engineering in two-dimensional diffractive chiral metamaterials leveraging a powerful model-agnostic data enhancement algorithm[J]. *Nanophotonics*, 2021, 10(3): 1155-1168.
- [37] Tao Z L, Zhang J, You J E, et al. Exploiting deep learning network in optical chirality tuning and manipulation of diffractive chiral metamaterials[J]. *Nanophotonics*, 2020, 9(9): 2945-2956.
- [38] Hadji I, Wildes R P. What do we understand about convolutional networks? [EB/OL]. (2018-03-23) [2023-03-05]. <https://arxiv.org/abs/1803.08834>.
- [39] Pascanu R, Mikolov T, Bengio Y. On the difficulty of training recurrent neural networks[EB/OL]. (2012-11-21) [2023-03-02]. <https://arxiv.org/abs/1211.5063>.
- [40] LeCun Y, Fogelman-Soulié F. Modèles connexionnistes de l'apprentissage[J]. *Intellectica Revue De L'Association Pour La Recherche Cognitive*, 1987, 2(1): 114-143.
- [41] Broulard H, Kamp Y. Auto-association by multilayer perceptrons and singular value decomposition[J]. *Biological Cybernetics*, 1988, 59(4): 291-294.
- [42] Hinton G E, Zemel R S. Autoencoders, minimum description length and Helmholtz free energy[C]//Proceedings of the 6th International Conference on Neural Information Processing Systems, November 29, 1993, Denver, Colorado, USA. New York: ACM Press, 1993: 3-10.

- [42] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks[J]. Communications of the ACM, 2020, 63(11): 139-144.
- [43] Sutton R S, Barto A G. Reinforcement learning: an introduction [M]. 2nd ed. Cambridge: The MIT Press, 2018.
- [44] van Hasselt H, Guez A, Silver D. Deep reinforcement learning with double Q-learning[C] // Proceedings of the Thirtieth AAAI Conference on Artificial Intelligence, February 12-17, 2016, Phoenix, Arizona, USA. New York: ACM Press, 2016: 2094-2100.
- [45] 来杰, 王晓丹, 向前, 等. 自编码器及其应用综述[J]. 通信学报, 2021, 42(9): 218-230.
Lai J, Wang X D, Xiang Q, et al. Review on autoencoder and its application[J]. Journal on Communications, 2021, 42(9): 218-230.
- [46] 王正龙, 张保稳. 生成对抗网络研究综述[J]. 网络与信息安全学报, 2021, 7(4): 68-85.
Wang Z L, Zhang B W. Survey of generative adversarial network [J]. Chinese Journal of Network and Information Security, 2021, 7(4): 68-85.
- [47] Russell S J, Norvig P, Davis E. Artificial intelligence: a modern approach[M]. 3rd ed. Upper Saddle River: Prentice Hall, 2010.
- [48] Ma J H, Piao Z, Huang S, et al. Monte Carlo simulation fused with target distribution modeling via deep reinforcement learning for automatic high-efficiency photon distribution estimation[J]. Photonics Research, 2021, 9(3): B45-B56.
- [49] Mnih V, Kavukcuoglu K, Silver D, et al. Human-level control through deep reinforcement learning[J]. Nature, 2015, 518(7540): 529-533.
- [50] Lillicrap T P, Hunt J J, Pritzel A, et al. Continuous control with deep reinforcement learning[EB/OL]. (2015-09-09) [2023-02-05]. <https://arxiv.org/abs/1509.02971>.
- [51] Mnih V, Kavukcuoglu K, Silver D, et al. Playing Atari with deep reinforcement learning[EB/OL]. (2013-12-19) [2023-02-05]. <https://arxiv.org/abs/1312.5602>.
- [52] 杨思明, 单征, 丁煜, 等. 深度强化学习研究综述[J]. 计算机工程, 2021, 47(12): 19-29.
Yang S M, Shan Z, Ding Y, et al. Survey of research on deep reinforcement learning[J]. Computer Engineering, 2021, 47(12): 19-29.
- [53] Bottou L. Stochastic gradient descent tricks[M] // Montavon G, Orr G B, Müller K B. Neural networks: tricks of the trade. Lecture notes in computer science. Berlin: Springer, 2012, 7700: 421-436.
- [54] Polyak B T. Some methods of speeding up the convergence of iteration methods[J]. USSR Computational Mathematics and Mathematical Physics, 1964, 4(5): 1-17.
- [55] Sutskever I, Martens J, Dahl G, et al. On the importance of initialization and momentum in deep learning[C] // Proceedings of the 30th International Conference on Machine Learning, 2013, June 16-21, 2013, Atlanta, GA, USA. Cambridge: JMLR, 2013: 2176-2184.
- [56] Duchi J C, Hazan E, Singer Y. Adaptive subgradient methods for online learning and stochastic optimization[J]. Journal of Machine Learning Research, 2011, 12: 2121-2159.
- [57] Hinton G. Graduate summer school: deep learning, feature learning [EB/OL]. [2023-02-03]. <https://www.ipam.ucla.edu/schedule.aspx?pc=gss2012>.
- [58] Kingma D P, Ba J. Adam: a method for stochastic optimization[EB/OL]. (2014-12-22) [2023-02-05]. <https://arxiv.org/abs/1412.6980>.
- [59] Rumelhart D E, Hinton G E, Williams R J. Learning representations by back-propagating errors[J]. Nature, 1986, 323(6088): 533-536.
- [60] Veselago V G. The electrodynamics of substances with simultaneously negative values of ϵ and μ [J]. Soviet Physics Uspekhi, 1968, 10(4): 509-514.
- [61] Seddon N, Bearpark T. Observation of the inverse Doppler effect [J]. Science, 2003, 302(5650): 1537-1540.
- [62] Luo C Y, Ibanescu M, Johnson S G, et al. Cerenkov radiation in photonic crystals[J]. Science, 2003, 299(5605): 368-371.
- [63] Veselago V G, Narimanov E E. The left hand of brightness: past, present and future of negative index materials[J]. Nature Materials, 2006, 5(10): 759-762.
- [64] Pendry J B, Smith D R. Reversing light with negative refraction [J]. Physics Today, 2004, 57(6): 37-43.
- [65] Pendry J B, Holden A J, Stewart W J, et al. Extremely low frequency plasmons in metallic mesostructures[J]. Physical Review Letters, 1996, 76(25): 4773-4776.
- [66] Pendry J B, Holden A J, Robbins D J, et al. Magnetism from conductors and enhanced nonlinear phenomena[J]. IEEE Transactions on Microwave Theory and Techniques, 1999, 47(11): 2075-2084.
- [67] Smith D R, Padilla W J, Vier D C, et al. Composite medium with simultaneously negative permeability and permittivity[J]. Physical Review Letters, 2000, 84(18): 4184-4187.
- [68] Hu Y Z, Jiang T A, Sun H, et al. Ultrafast frequency shift of electromagnetically induced transparency in terahertz metaphotonic devices[J]. Laser & Photonics Reviews, 2020, 14(3): 1900338.
- [69] Lee Y Y, Kim R M, Im S W, et al. Plasmonic metamaterials for chiral sensing applications[J]. Nanoscale, 2020, 12(1): 58-66.
- [70] Yao K, Zheng Y B. Near-ultraviolet dielectric metasurfaces: from surface-enhanced circular dichroism spectroscopy to polarization-preserving mirrors[J]. The Journal of Physical Chemistry C, 2019, 123(18): 11814-11822.
- [71] Kogelnik H. Coupled wave theory for thick hologram gratings[J]. The Bell System Technical Journal, 1969, 48(9): 2909-2947.
- [72] Lee W, Degertekin F L. Rigorous coupled-wave analysis for multilayered grating structures[J]. Proceedings of SPIE, 2003, 4987: 264-273.
- [73] Moharam M G, Gaylord T K. Rigorous coupled-wave analysis of grating diffraction: E-mode polarization and losses[J]. Journal of the Optical Society of America, 1983, 73(4): 451-455.
- [74] Peng S, Morris G M. Efficient implementation of rigorous coupled-wave analysis for surface-relief gratings[J]. Journal of the Optical Society of America A, 1995, 12(5): 1087-1096.
- [75] Weismann M, Gallagher D F G, Panou N C. Accurate near-field calculation in the rigorous coupled-wave analysis method[J]. Journal of Optics, 2015, 17(12): 125612.
- [76] 李亚. 基于 RCWA 法的红外超材料设计分析方法研究[D]. 成都: 电子科技大学, 2020.
Li Y. Design and analysis of infrared metamaterials based on RCWA method[D]. Chengdu: University of Electronic Science and Technology of China, 2020.
- [77] 邵天宇, 谷建强, 师文桥. 太赫兹导模谐振滤波器的自动化设计方法研究[J]. 中国激光, 2021, 48(20): 2014001.
Shao T Y, Gu J Q, Shi W Q. Automated design study of guided-mode resonance filters working at terahertz frequencies[J]. Chinese Journal of Lasers, 2021, 48(20): 2014001.
- [78] 徐董董. 中红外波段超材料完美吸收机理及动态辐射调制[D]. 南京: 南京信息工程大学, 2022.
Xu D D. Perfect absorption mechanism and dynamic radiation modulation of metamaterials in mid-infrared band[D]. Nanjing: Nanjing University of Information Science & Technology, 2022.
- [79] 陈德伟. 衍射光学中的严格耦合波分析方法[D]. 合肥: 中国科学技术大学, 2004.
Chen D W. Strict coupled wave analysis method in diffractive optics [D]. Hefei: University of Science and Technology of China, 2004.
- [80] Yee K E. Numerical solution of initial boundary value problems involving Maxwell's equations in isotropic media[J]. IEEE Transactions on Antennas and Propagation, 1966, 14(3): 302-307.
- [81] 牛凯坤. 时域有限差分方法的改进及在多物理场中的应用[D]. 合肥: 安徽大学, 2019.
Niu K K. Improvement of finite-difference time-domain method and its application in multiple physical fields[D]. Hefei: Anhui University, 2019.
- [82] 牛凯坤, 徐辉, 朱东, 等. 电磁超材料与增益材料研究现状与进展[J]. 安徽大学学报(自然科学版), 2017, 41(4): 24-33.

- Niu K K, Xu H, Zhu D, et al. Recent progress and future development of metamaterial and gain material[J]. Journal of Anhui University (Natural Science Edition), 2017, 41(4): 24-33.
- [83] Molesky S, Lin Z, Piggott A Y, et al. Inverse design in nanophotonics[J]. Nature Photonics, 2018, 12(11): 659-670.
- [84] Yu Z J, Cui H R, Sun X K. Genetic-algorithm-optimized wideband on-chip polarization rotator with an ultrasmall footprint [J]. Optics Letters, 2017, 42(16): 3093-3096.
- [85] Ma L F, Li J, Liu Z H, et al. Intelligent algorithms: new avenues for designing nanophotonic devices[J]. Chinese Optics Letters, 2021, 19(1): 011301.
- [86] Wang X Y, Wu T Y, Dong C, et al. Integrating deep learning to achieve phase compensation for free-space orbital-angular-momentum-encoded quantum key distribution under atmospheric turbulence[J]. Photonics Research, 2021, 9(2): B9-B17.
- [87] Zhen Z, Qian C, Jia Y T, et al. Realizing transmitted metasurface cloak by a tandem neural network[J]. Photonics Research, 2021, 9(5): B229-B235.
- [88] Liu C, Yu W M, Ma Q, et al. Intelligent coding metasurface holograms by physics-assisted unsupervised generative adversarial network[J]. Photonics Research, 2021, 9(4): B159-B167.
- [89] Peurifoy J, Shen Y C, Jing L, et al. Nanophotonic particle simulation and inverse design using artificial neural networks[J]. Proceedings of SPIE, 2018, 10526: 1052607.
- [90] Liu D J, Tan Y X, Khoram E, et al. Training deep neural networks for the inverse design of nanophotonic structures[J]. ACS Photonics, 2018, 5(4): 1365-1369.
- [91] Zhao Z Y, You J E, Zhang J, et al. Data enhanced iterative few-sample learning algorithm-based inverse design of 2D programmable chiral metamaterials[J]. Nanophotonics, 2022, 11(20): 4465-4478.
- [92] Zhu R C, Qiu T S, Wang J F, et al. Phase-to-pattern inverse design paradigm for fast realization of functional metasurfaces via transfer learning[J]. Nature Communications, 2021, 12: 2974.
- [93] Jiang J Q, Sell D, Hoyer S, et al. Free-form diffractive metagrating design based on generative adversarial networks[J]. ACS Nano, 2019, 13(8): 8872-8878.
- [94] Sajedian I, Lee H, Rho J. Double-deep Q-learning to increase the efficiency of metasurface holograms[J]. Scientific Reports, 2019, 9(1): 10899.
- [95] Zhao Z Y, You J, Zhang J, et al. Data-enhanced deep greedy optimization algorithm for the on-demand inverse design of TMDC-cavity heterojunctions[J]. Nanomaterials, 2022, 12(17): 2976.
- [96] Zhao X, Li T, Liu Y, et al. Polarization-multiplexed, dual-comb all-fiber mode-locked laser[J]. Photonics Research, 2018, 6(9): 853-857.
- [97] Yin K, Li Y M, Wang Y B, et al. Self-starting all-fiber PM Er: laser mode locked by a biased nonlinear amplifying loop mirror[J]. Chinese Physics B, 2019, 28(12): 124203.
- [98] Zou J H, Dong C C, Wang H J, et al. Towards visible-wavelength passively mode-locked lasers in all-fiber format[J]. Light: Science & Applications, 2020, 9: 61.
- [99] Li W S, Zhu C H, Rong X F, et al. Bidirectional red-light passively Q-switched all-fiber ring lasers with carbon nanotube saturable absorber[J]. Journal of Lightwave Technology, 2018, 36(13): 2694-2701.
- [100] Liu J, Wu J D, Chen H L, et al. Short-pulsed Raman fiber laser and its dynamics[J]. Science China Physics, Mechanics & Astronomy, 2021, 64(1): 214201.
- [101] Huang D M, Shang C, Li F, et al. Discrete Fourier domain harmonically mode locked laser by mode hopping modulation[C]// 2019 24th OptoElectronics and Communications Conference (OECC) and 2019 International Conference on Photonics in Switching and Computing (PSC), July 7-11, 2019, Fukuoka, Japan. New York: IEEE Press, 2019.
- [102] Winters D G, Kirchner M S, Backus S J, et al. Electronic initiation and optimization of nonlinear polarization evolution mode-locking in a fiber laser[J]. Optics Express, 2017, 25(26): 33216-33225.
- [103] Pu G Q, Yi L L, Zhang L, et al. Genetic algorithm-based fast real-time automatic mode-locked fiber laser[J]. IEEE Photonics Technology Letters, 2020, 32(1): 7-10.
- [104] Pu G Q, Yi L L, Zhang L, et al. Intelligent control of mode-locked femtosecond pulses by time-stretch-assisted real-time spectral analysis[J]. Light: Science & Applications, 2020, 9: 13.
- [105] Fu X, Kutz J N. High-energy mode-locked fiber lasers using multiple transmission filters and a genetic algorithm[J]. Optics Express, 2013, 21(5): 6526-6537.
- [106] Kokhanovskiy A, Bednyakova A, Kuprikov E, et al. Machine learning-based pulse characterization in figure-eight mode-locked lasers[J]. Optics Letters, 2019, 44(13): 3410-3413.
- [107] Hellwig T, Walbaum T, Groß P, et al. Automated characterization and alignment of passively mode-locked fiber lasers based on nonlinear polarization rotation[J]. Applied Physics B, 2010, 101(3): 565-570.
- [108] Brunton S L, Fu X, Kutz J N. Extremum-seeking control of a mode-locked laser[J]. IEEE Journal of Quantum Electronics, 2013, 49(10): 852-861.
- [109] Kutz J N, Brunton S L. Intelligent systems for stabilizing mode-locked lasers and frequency combs: machine learning and equation-free control paradigms for self-tuning optics[J]. Nanophotonics, 2015, 4(4): 459-471.
- [110] Meng F C, Dudley J M. Toward a self-driving ultrafast fiber laser [J]. Light: Science & Applications, 2020, 9: 26.
- [111] Kokhanovskiy A, Shevelev A, Serebrennikov K, et al. A deep reinforcement learning algorithm for smart control of hysteresis phenomena in a mode-locked fiber laser[J]. Photonics, 2022, 9(12): 921.
- [112] Woodward R I, Kelleher E J R. Towards 'smart lasers': self-optimisation of an ultrafast pulse source using a genetic algorithm [J]. Scientific Reports, 2016, 6: 37616.
- [113] Pu G Q, Yi L L, Zhang L, et al. Intelligent programmable mode-locked fiber laser with a human-like algorithm[J]. Optica, 2019, 6(3): 362-369.
- [114] Pu G Q, Liu R M, Luo C, et al. Intelligent single-cavity dual-comb source with fast locking[J]. Journal of Lightwave Technology, 2023, 41(2): 593-598.
- [115] Sun C, Kaiser E, Brunton S L, et al. Deep reinforcement learning for optical systems: a case study of mode-locked lasers[J]. Machine Learning: Science and Technology, 2020, 1(4): 045013.
- [116] Li Z, Yang S S, Xiao Q, et al. Deep reinforcement with spectrum series learning control for a mode-locked fiber laser[J]. Photonics Research, 2022, 10(6): 1491-1500.
- [117] Luo S Y, Tang X A, Geng X A, et al. Ultrafast true-green Ho: ZBLAN fiber laser inspired by the TD3 AI algorithm[J]. Optics Letters, 2022, 47(22): 5881-5884.
- [118] Andral U, Fodil R S, Amrani F, et al. Fiber laser mode locked through an evolutionary algorithm[J]. Optica, 2015, 2(4): 275-278.
- [119] Zhou P, Liu Z J, Wang X L, et al. Coherent beam combination of two-dimensional high power fiber amplifier array using stochastic parallel gradient descent algorithm[J]. Applied Physics Letters, 2009, 94(23): 231106.
- [120] Hou T Y, An Y, Chang Q, et al. Deep learning-based phase control method for coherent beam combining and its application in generating orbital angular momentum beams[EB/OL]. (2019-03-10) [2023-03-05]. <https://arxiv.org/abs/1903.03983>.
- [121] Tünnermann H, Shirakawa A. Deep reinforcement learning for coherent beam combining applications[J]. Optics Express, 2019, 27(17): 24223-24230.
- [122] Hirose A. Applications of complex-valued neural networks to coherent optical computing using phase-sensitive detection scheme [J]. Information Sciences-Applications, 1994, 2(2): 103-117.
- [123] Zhang J, Yan Q Q, Liu H Z, et al. Coherent optical neuron control based on reinforcement learning[J]. Optics Letters, 2023, 48(4): 1084-1087.

Research Progress in Metamaterial Design and Fiber Beam Control Based on Deep Learning

Luo Yihao¹, Zhang Jun², Du Shiyin², Yan Qiuquan², Zhao Zeyu², Tao Zilong², Zhou Tong¹,
Jiang Tian^{3*}

¹College of Advanced Interdisciplinary Studies, National University of Defense Technology, Changsha 410073,
Hunan, China;

²Institute for Quantum Information and the State Key Laboratory of High Performance Computing, College of
Computer Science and Technology, National University of Defense Technology, Changsha 410073, Hunan, China;

³Institute of Quantum Information Science and Technology, College of Science, National University of Defense
Technology, Changsha 410073, Hunan, China

Abstract

Significance Metamaterial design and fiber beam control are two important topics in the study of optical field manipulation. Metamaterials are artificial materials with periodic structures and physical properties that do not exist naturally in the world. Suitable structural designs are crucial for achieving the potential of metamaterials. Numerical calculations and parameter optimization methods such as finite difference time domain (FDTD), finite element method (FEM), rigorous coupled wave analysis (RCWA), and genetic algorithms are commonly used in metamaterials design. However, these methods suffer from high computational costs and strong dependence on expert experience. Specifically, the high computational cost is due to the complexity of solving partial differential equations, while the reliance on expert experience stems from the fact that these numerical calculation methods depend on physical modeling. Additionally, parameter optimization algorithms also suffer from high computational costs due to the explosion of parameter combinations and repeated calls to numerical computation methods. Therefore, many researchers have turned to deep learning methods, attempting to use a data-driven approach to allow neural network models to learn the mapping relationship between metamaterial structure and optical response during the feature learning process, thus achieving accurate and efficient metamaterial design while shielding underlying physical details.

Fiber beam control refers to adjusting parameters such as amplitude, phase, and polarization of a fiber optic beam to obtain novel features or stable states. Traditional methods mainly include genetic algorithms, stochastic parallel gradient descent (SPGD) algorithm, PID, and other search methods, which are limited by their inability to effectively solve system control problems in complex environments, i. e., speed and accuracy issues. These optimization methods have simple strategies that are unable to generate good behavioral paths, resulting in too many steps to reach the target state. Moreover, they mechanically respond to environmental states, making them vulnerable to system noise interference and limiting the accuracy of system output. Deep reinforcement learning overcomes these limitations by introducing a learning mechanism that can actively respond to environmental stimuli, making up for the shortcomings of traditional methods. Fiber beam control is a dynamic process that can be abstracted into a state machine, which is naturally suitable for control methods based on deep reinforcement learning. Therefore, for such or even more complex systems, deep reinforcement learning-based methods have considerable application prospects.

Progress Multi-layer perceptron (MLP) is a simple and basic neural network model widely used in various metamaterial design works. Peurifoy *et al.* used MLP to complete the inverse design of an 8-layer spherical shell nanostructure [Fig. 7(a)]. Liu *et al.* proposed a method that combines forward prediction networks for spectra and inverse design networks for devices [Fig. 7(b)]. Du *et al.* developed a scalable multi-task learning (SMTL) model for designing low-dimensional nanostructures [Fig. 7(c)]. Zhao *et al.* released a data-enhanced iterative few-sample (DEIFS) algorithm based on data augmentation [Fig. 7(d)]. In addition to MLP, convolutional neural network (CNN) and generative adversarial network (GAN) are also commonly used network models. Zhu *et al.* proposed a transfer learning-based method for predicting metamaterials accurately and quickly using the pre-trained Inception V3 model on image data, achieving good results for binary metamaterial prediction [Fig. 8(a)]. Jiang *et al.* used GAN for the topology design of complex nano-devices, effectively solving the problem of time-consuming iterative optimization methods for designing complex devices, reducing design time by about 80% [Fig. 8(b)]. Sajedian *et al.* efficiently determined the optimal parameters for three-layer metamaterial devices among 23 different material types and geometry parameters using the double deep Q network (DDQN), greatly improving the computational transmittance efficiency of metamaterials [Fig. 8(c)]. Zhao *et al.* integrated the idea of reinforcement learning into the model and designed a data-enhanced deep greedy optimization (DEDGO) algorithm [Fig. 8(d)]. Sajedian *et al.* combined CNN with recurrent neural network (RNN) to predict the absorption spectra of nano-devices, which played an auxiliary role in device design [Fig. 8(e)].

In fiber beam control, the J. N. Kutz team at the University of Washington proposed using deep reinforcement learning algorithms to achieve automatic mode locking control of lasers from a simulation perspective in 2020 [Fig. 11(a)]. In 2021, the team led by researcher Jiang Tian at the National University of Defense Technology designed an automatic mode locking control laser

system based on the DDPG strategy and the DELAY reinforcement learning algorithm [Fig. 11(b)]. In mid-2022, Li Zhan *et al.* from the Chinese Academy of Sciences designed a feedback control algorithm based on deep reinforcement learning and long short-term memory (LSTM) network models to stabilize the state of mode-locked lasers [Fig. 11(c)]. In the latter half of 2022, Luo Saiyu *et al.* from Nanjing University of Science and Technology applied the TD3 algorithm from deep reinforcement learning to an ultrafast green Ho:ZBLAN laser [Fig. 11(d)]. In 2023, the research team led by Jiang Tian at the National University of Defense Technology once again designed DRCON using reinforcement learning to control the stability of coherent optical neuron systems (Fig. 13).

Conclusion and Prospect This article focuses on recent research on deep learning in metamaterial design and fiber beam control. The introduction of deep learning has greatly promoted the development of both fields. Traditional methods face the following problems when dealing with increasingly complex optical systems: (1) inability to effectively transfer expert experience; (2) inability to avoid numerical calculations; and (3) a limited solvable problem space. Compared with traditional methods, deep learning methods can help isolate the underlying physical details to some extent, reducing the difficulty of design and control.

Key words materials; fiber optics; neural networks; optical field manipulation; metamaterial design; optical system control