

# 基于深度学习的微纳结构光谱设计研究进展



马文壮<sup>1,2</sup>, 游可唯<sup>1,2</sup>, 张胤<sup>1,2</sup>, 周阳<sup>1,2</sup>, 张丽<sup>1,2\*</sup>

(1. 电子科技大学 国家电磁辐射控制材料工程技术研究中心, 成都 611731;

2. 电子科技大学 多频谱吸波材料与结构教育部重点实验室 (B 类), 成都 611731)

**摘要** 随着人工智能技术的快速发展, 深度学习在微纳结构光谱调控领域展现出了巨大的应用潜力。深度学习可以在无明确物理解析模型的情况下, 通过构建复杂的神经网络, 从实验或仿真数据中学习微纳结构的光谱响应特性, 从而实现高效的设计优化, 这为微纳结构的设计提供了一种新的思路和方法。该文综述了近年来深度学习在微纳结构设计中的研究进展, 重点讨论了其在结构色、热辐射控制以及窄带光谱传感等光谱调控领域的应用, 并展望了该领域未来的发展机遇与挑战。

**关键词** 人工智能; 深度学习; 微纳结构; 光谱设计

中图分类号 TN213; O43

文献标志码 A

DOI 10.12178/1001-0548.2024196

## Research Progress on Deep Learning-Based Spectral Design of Micro-Nano Structures

MA Wenzhuang<sup>1,2</sup>, YOU Kewei<sup>1,2</sup>, ZHANG Yin<sup>1,2</sup>, ZHOU Yang<sup>1,2</sup>, and ZHANG Li<sup>1,2\*</sup>

(1. National Engineering Research Center of Electromagnetic Radiation Control Materials, University of Electronic Science and Technology of China, Chengdu 611731, China;

2. Key Laboratory of Multi-Spectral Absorbing Materials and Structures of Ministry of Education, University of Electronic Science and Technology of China, Chengdu 611731, China)

**Abstract** With the rapid development of artificial intelligence technology, deep learning has shown tremendous potential in the field of spectral regulation of micro-nano structures. By constructing complex neural network models, deep learning can learn the spectral response characteristics of micro-nano structures from experimental or simulation data without the need for explicit physical analytical models, thereby achieving efficient design optimization. This provides a new approach and methodology for the design of micro-nano structures. This paper reviews the recent research progress of deep learning in micro-nano structure design, focusing on its applications in structural color, thermal radiation control, and narrowband spectral sensing, and also discusses future opportunities and challenges in this field.

**Key words** artificial intelligence; deep learning; micro-nano structures; spectral design

微纳结构光谱调控的核心在于利用光与物质的相互作用, 通过精确设计和优化微纳米尺度的结构参数, 实现对光谱特性的有效控制。如, 在表面等离激元<sup>[1]</sup>和光子晶体<sup>[2]</sup>结构设计中, 通过在纳米尺度上的几何形状设计, 可以对特定波长的光进行选择增强或抑制, 从而在特定的光谱范围内获得所需的光学特性。在传统的设计方法中, 研究人员通常采用数值模拟 (如有限元法和时域有限差分法) 来迭代求解麦克斯韦方程组, 以计算材料的光谱响应, 随后通过实验验证, 对微纳结构进行多次设计

和优化。虽然这种方法能够获得高精度的结果, 但其计算成本高昂, 耗时较长, 且需要历经大量的试错过程。

随着深度学习技术的发展, 基于数据驱动的设计方法逐渐成为解决这些问题的有效途径。深度学习的优势在于其强大的模式识别和泛化能力, 通过大量的数据训练, 深度学习网络可以捕捉到材料设计中隐含的复杂非线性关系。一旦模型训练完成, 就能快速预测新材料结构的光谱响应, 从而大大缩短了设计周期。此外, 深度学习技术还可以用于逆

收稿日期: 2024-07-30; 修回日期: 2024-09-05

基金项目: 国家自然科学基金 (52021001, 52022018, 52472147)

作者简介: 马文壮, 博士生, 主要从事深度学习在光谱调控方面的研究。

\*通信作者 E-mail: lzhang129@uestc.edu.cn

向设计,即在给定目标光谱的情况下,能够快速推导出满足要求的材料结构。这种逆向设计能力使研究人员能够更灵活、更高效地探索新的材料设计空间。

本文基于深度学习在微纳结构光谱调控方面的研究进展,结合具体的应用案例,介绍了该领域的设计思路,并对目前面临的机遇与挑战进行总结与展望。

## 1 深度学习概述

深度学习(Deep Learning)是机器学习的一个子领域,它通过神经网络模型来理解和分析复杂的数据模式。深度学习借鉴了人脑的结构和功能,使用大量的神经元和层级连接来处理和分析数据<sup>[3-4]</sup>。每个神经网络具有多层结构,包括输入层、隐藏层和输出层。每个网络层执行不同的功能:输入层接收数据,隐藏层通过加权连接和非线性激活函数处理数据,输出层生成最终的预测结果。随着隐藏层层数的增加,网络能够学习到更抽象、更高级的特征,从而在图像识别、语音识别、自然语言处理等领域展示出更出色的性能。通过去除不必要的神经元和连接,可以降低模型复杂度,减少计算资源的占用,从而提高效率。此外,将复杂的任务分解为若干子问题的策略,能够有效简化网络的学习过程,提高预测的精度和泛化能力。深度学习的成功依赖于大量的数据和计算资源,以及先进的算法和优化技术,使其能够从海量数据中自动提取有用的特征和模式。

根据隐藏层网络架构的不同,常见的深度学习神经网络模型如图 1 所示,主要包括多层感知机(Multilayer Perceptron, MLP)、卷积神经网络(Convolutional Neural Networks, CNN)、循环神经网络(Recurrent Neural Network, RNN)、生成对抗网络(Generative Adversarial Networks, GAN)和 Transformer 等。其中,MLP 是一种基础的神经网络模型,具有全连接层结构,适用于处理结构化数据。虽然简单易实现,但在处理高维度或复杂结构数据时,其效果可能不如其他模型。CNN 引入了卷积层,这使其相比于 MLP 更擅长提取空间特征,适用于图像处理任务。RNN 因其循环结构能有效捕捉序列数据中的时间相关性,常用于自然语言处理和时序序列预测。GAN 通过生成器和判别器的对抗训练,能够生成与真实数据分布相似的虚拟样本,广泛应用于数据增强和图像生成领域。Transformer 通过自注意力机制,在捕捉序列数据

的长程依赖性方面相比于 RNN 表现更为出色,尤其适合处理更加复杂的序列关系,在自然语言处理和图像分析中得到广泛应用。上述框架各有优势,适用于不同类型的任务,通过合理选择,可以在各种复杂的应用场景中实现优异的性能。

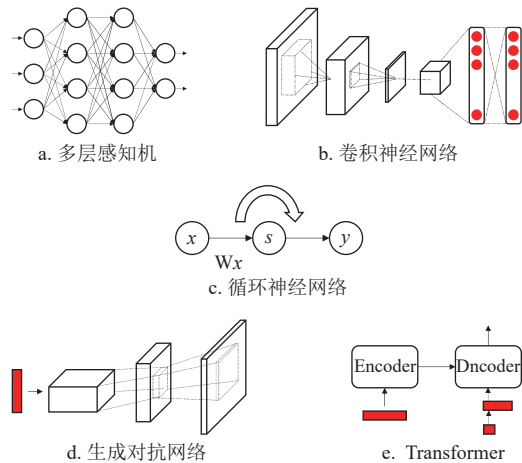


图 1 常见的深度学习神经网络模型图

## 2 深度学习在微纳结构光谱调控中的应用

深度学习在光谱调控领域的应用具有重要意义,能够显著推动该领域的研究和创新。通过引入深度学习技术,研究人员可以克服传统设计方法中的许多限制,实现更高效、更精确的光谱调控。本节主要介绍了深度学习在微纳结构光谱调控中的研究进展,涵盖了结构色、热辐射控制和窄带光谱传感等应用领域。

### 2.1 结构色

结构色是一种由微纳结构引发的光学效应,广泛存在于自然界中,如鸟类的羽色和昆虫的外壳颜色等。通过设计和制造亚波长尺度的人工纳米结构,可以有效控制结构色,这是微纳结构光谱调控的一个重要应用。结构色的形成主要依赖于光在纳米结构之间的多次反射和干涉效应,不同波长的光会发生相干叠加,从而产生特定的颜色。此外,周期性纳米结构可以利用衍射效应将入射光分散成不同方向的颜色,而金属纳米结构则可以通过表面等离子体共振效应,实现对特定波长光的增强或抑制<sup>[5-6]</sup>。

传统的结构色设计方法依赖于复杂的物理模型和大量的试错过程,计算成本高昂且效率低下。近年来,随着人工智能技术的发展,深度学习在结构色设计中的应用逐渐成为研究热点。深度学习能够

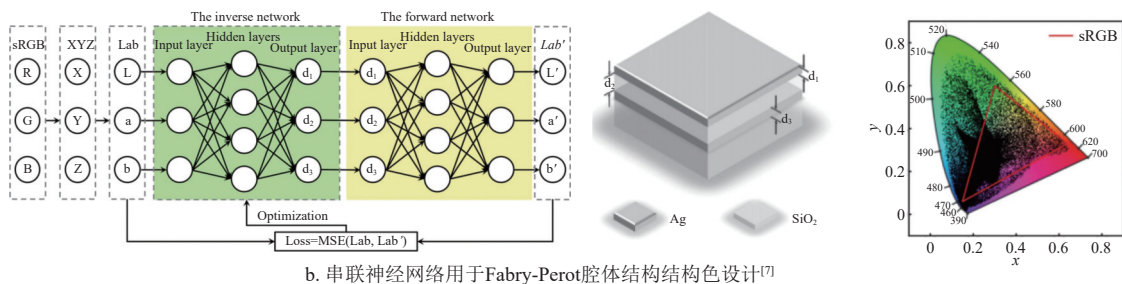
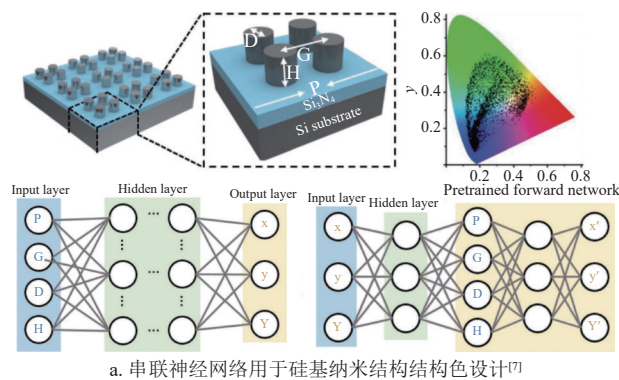
从大量数据中学习复杂的模式和关系, 直接建立色彩空间与结构参数之间的映射, 从而显著提高设计效率。

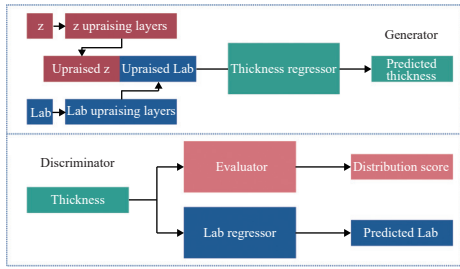
### 2.1.1 静态结构色

2019 年, 文献 [7] 率先将深度学习应用于结构色设计, 开展了利用神经网络进行硅基纳米结构的结构色设计的研究 (图 2a)。研究团队首先通过时域有限差分法生成了 4 660 组不同参数组合的硅基纳米结构的反射光谱数据, 并将其转化为  $xyY$  色域空间。这些数据被用作神经网络的训练集。在此基础上, 他们建立了前向建模网络, 实现了从结构参数到颜色的高精度预测。为了实现颜色的逆向设计, 研究人员还建立了逆向设计网络, 通过输入颜色值来输出相应的结构参数。研究团队采用了串联神经网络架构, 将预训练的前向网络连接到逆向设计网络中, 确保每一组颜色都收敛于一组结构参数, 克服了颜色与结构参数之间的“一对多”映射问题, 避免了神经网络的不收敛现象。通过这种方法, 深度学习模型能够从目标颜色值直接生成相应的几何参数, 实现了超过一百万种不同颜色的硅基纳米结构的逆向设计。2021 年, 文献 [8] 在 Fabry-Perot 腔体结构色滤光片的逆向设计研究中, 进一步优化了这种方法 (图 2b)。他们在串联神经网络的基础上, 定义了统一的 CIE 1976-Lab 色域空间作为损失函数的标准, 使相同的欧几里得距离表示相同的颜色差异, 从而进一步提高了结构色设计的精度。

尽管串联网络结构加速了逆向设计网络的收敛, 但其本质上是“一对一”的映射关系, 即每个输入的目标颜色只能映射到一组特定的几何参数。这种一对一的映射关系不仅无法充分挖掘所有可能的设计方案, 限制了设计空间的全面探索, 而且在实际应用中存在一定的局限性, 由于材料的物理特性和制造工艺的限制, 某些几何参数可能难以实现或制造成本过高。为了提高逆向设计的灵活性, 就需要更多的候选设计方案, 以便在制备过程中进一步选择最优或最具可行性的方案。

2022 年, 文献 [9] 通过使用条件生成对抗网络 (Conditional Generative Networks, CGAN), 成功解决了串联网络结构色逆向设计中的“一对一”输出问题, 实现了“一对多”的多解生成 (图 2c)。该研究团队采用的 CGAN 模型由生成器和鉴别器组成。生成器根据目标颜色和潜在向量生成多种结构解, 鉴别器则评估这些解的性能和分布差异。通过引入参考数据的分布, 生成器能够学习数据的分布并生成与真实数据分布相近的解。研究团队使用了 50 000 组不同厚度组合的数据集进行训练, 范围覆盖了大部分解空间, 从而确保生成的多解覆盖所有可能的解组。通过使用 CGAN 模型, 为每种颜色提供了平均 3.58 个解组, 覆盖了 93.9% 的所有真值解, 且平均色差  $\Delta E$  低至 0.44。这一结果表明, 引入生成式网络可有效地挖掘设计方案, 拓展设计空间, 从而为实际应用提供更大的灵活性和选择余地。





| Target D<br>( $d_1-d_2-d_3$ ) nm | Target color<br>(sRGB) | Designed D<br>( $d_1-d_2-d_3$ ) nm | Designed color<br>(sRGB) | Comparison<br>(target, design) | $\Delta E$ | $(\delta_r, \delta_b)$ |
|----------------------------------|------------------------|------------------------------------|--------------------------|--------------------------------|------------|------------------------|
| 33-118-27                        | (-1.549)-0.534-0.426   | 34-118-26                          | (-1.481)-0.532-0.421     |                                | 0.45       | (2.03, 2.22)           |
|                                  |                        | 16-284-32                          | (-1.475)-0.536-0.420     |                                | 0.73       | (1.03, 1.08)           |
|                                  |                        | 25-460-19                          | (-1.544)-0.528-0.417     |                                | 0.69       | (0.60, 0.63)           |
| 3-550-41                         | 0.302-0.274-0.453      | 21-39-18                           | 0.193-0.268-0.470        |                                | 7.65       | (0.19, 0.19)           |
|                                  |                        | 7-183-35                           | 0.298-0.262-0.451        |                                | 1.08       | (0.44, 0.45)           |
|                                  |                        | 3-550-41                           | 0.302-0.275-0.453        |                                | 0.12       | (0.30, 0.29)           |
|                                  |                        | 33-722-28                          | 0.296-0.273-0.446        |                                | 0.53       | (0.42, 0.42)           |
|                                  |                        | 28-985-30                          | 0.305-0.272-0.443        |                                | 0.75       | (0.27, 0.27)           |

c. 生成对抗网络用于结构色设计实现“多解”<sup>[8]</sup>

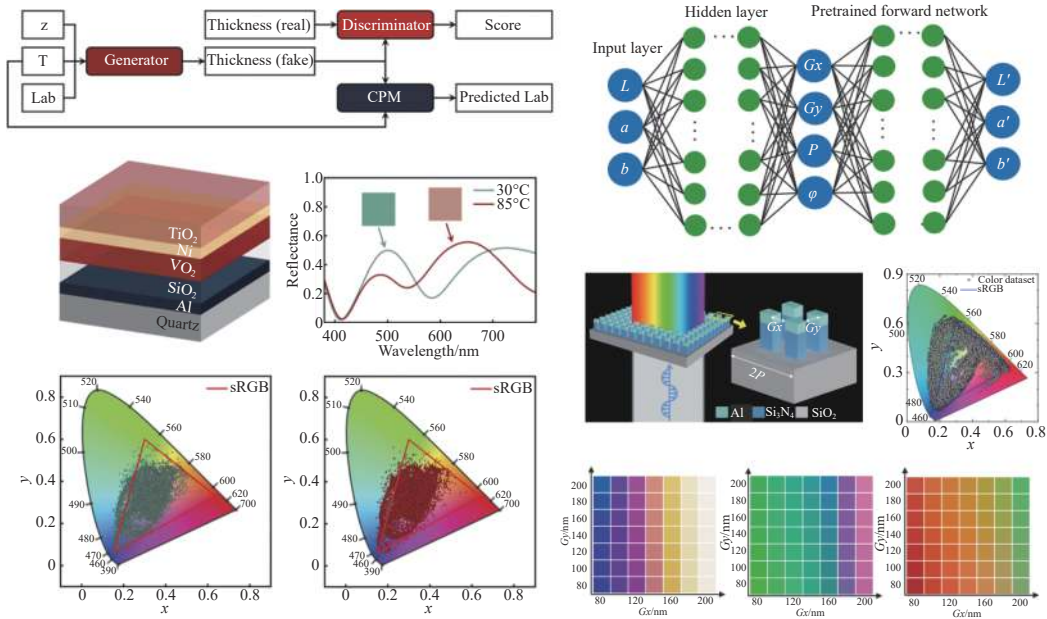
图 2 深度学习在静态结构色中的应用

2.1.2 动态结构色

传统的结构色通过固定的结构实现，其颜色一旦确定便无法随着环境变化而改变，这在一定程度上限制了其应用范围。相比之下，动态结构色引入时间维度，能够在外界条件变化时调节颜色，从而极大地丰富了信息载荷和功能。动态结构色通常通过嵌入具有可调光学常数的功能材料来实现。这些材料的光学常数在外界刺激（如温度、电场或化学反应）下会发生变化，从而导致结构色的变化。典型的功能材料如相变材料（如二氧化钒 VO<sub>2</sub>）<sup>[10]</sup>。2022 年，文献 [11] 利用 CGAN 成功实现了基于 VO<sub>2</sub> 的动态结构色的逆向设计（图 3a）。研究团队设计了一个非对称的 Fabry-Pérot 腔体结构，并通过 CGAN 进行逆向设计。在 CGAN 网络的生成器中嵌入了温度条件，通过将低温（30℃）数字化为 0，高温（85℃）数字化为 1，确保生成器能够在不同温度条件下生成相应的结构参数。最终设计

的结构可以在 VO<sub>2</sub> 的绝缘态下覆盖 117% 的 sRGB 色域，且在 VO<sub>2</sub> 层发生相变后产生 5% 的色域变化。训练后的 CGAN 模型能够以  $\Delta E=0.98$  的平均色差进行逆向设计。

此外，还有一些研究利用超表面结构的偏振敏感性，通过改变偏振角来实现结构色的变化。2022 年，文献 [12] 提出了一种深度学习辅助设计的极化控制动态可切换全色超表面（图 3b），通过改变入射光的极化角度，该超表面能够实现全色显示和动态颜色调节。当入射光极化角度从 0° 变化到 45° 时，结构色从蓝色逐渐变为红色，整个过程中无须改变材料的结构和性质。研究团队通过一个串联深度学习网络来预测混合超表面的颜色，其中影响结构色动态变化的入射光极化角度被作为输入参数参与了神经网络的训练过程。研究结果显示，颜色预测的准确率为 93.18%，逆向参数设计的准确率为 92.37%。



a. 通过条件生成网络实现 VO<sub>2</sub> 的动态结构色的逆向设计<sup>[11]</sup>

b. 过串联神经网络实现极化控制动态结构色的逆向设计<sup>[12]</sup>

图 3 深度学习在动态结构色中的应用

### 2.1.3 小结

在结构色领域, 如表 1 所示, 深度学习的应用正逐步突破传统设计的限制, 通过将色域空间与结构参数直接建立联系, 取消了光谱计算的中间过程, 从而大大简化了设计流程。串联神经网络有效解决了颜色与结构参数“一对多”映射导致神经网络不收敛

的问题, 而 CGAN 网络的引入则进一步挖掘了颜色与结构之间的设计空间, 显著提高了设计的灵活性。特别是对于结构更加复杂的超材料, 深度学习的引入极大地提高了设计精度与效率。未来, 深度学习技术将进一步开发出更复杂、高效的结构色设计方法, 大大拓宽其在新材料和绿色技术中的应用范围。

表 1 用于结构色设计的深度学习模型比较

| 输入            | 输出          | 结构类型 | DL模型  | 数据集规模   | MSE                       | 精度                       | 文献   |
|---------------|-------------|------|-------|---------|---------------------------|--------------------------|------|
| 目标颜色 (xyY)    | 单组结构参数      | 超表面  | 串联MLP | 4 660   | $10^{-5}$                 | $\Delta x, y, Y < 0.01$  | [7]  |
| 目标颜色 (Lab)    | 单组结构参数      | 多层膜  | 串联MLP | 101 000 | $10^{-6}$                 | $\Delta E_{2000} < 1.2$  | [8]  |
| 目标颜色 (Lab)    | 平均3.58组结构参数 | 多层膜  | CGAN  | 40 000  | Evaluator: 1 Generator: 0 | $\Delta E_{2000} < 0.4$  | [9]  |
| 温度和目标颜色 (Lab) | 单组结构参数      | 多层膜  | CGAN  | 50 000  | Evaluator: 1 Generator: 0 | $\Delta E_{2000} < 0.98$ | [11] |
| 目标颜色 (Lab)    | 单组结构参数和偏振角  | 超表面  | 串联MLP | 6 160   | $10^{-5}$                 | 92.37%                   | [12] |

## 2.2 热辐射控制

除了在结构色设计中的重要作用, 光谱调控在热辐射领域也具有重要应用。所有温度高于绝对零度的物体都会向外散发热辐射, 这种辐射的强度和波长分布取决于物体的温度。常见的热辐射现象包括太阳的可见光和红外辐射、地球的地热辐射以及日常生活中的红外辐射。通过精确控制微纳结构的光谱响应, 研究人员可以优化其热辐射特性, 从而

在多个关键应用领域中取得显著进展。

### 2.2.1 太阳能光热转换

太阳能光热转换技术通过吸收太阳辐射并将其转换为热能, 广泛应用于太阳能集热<sup>[13-14]</sup>、海水淡化领域<sup>[15]</sup>, 如图 4a 所示。其基本原理依赖于材料对太阳光谱的吸收特性。光热转换材料的理想光谱如图 4b 所示, 在太阳辐射波段具有高吸收率, 在热红外波段具有低发射率, 以最大化能量收集效率。

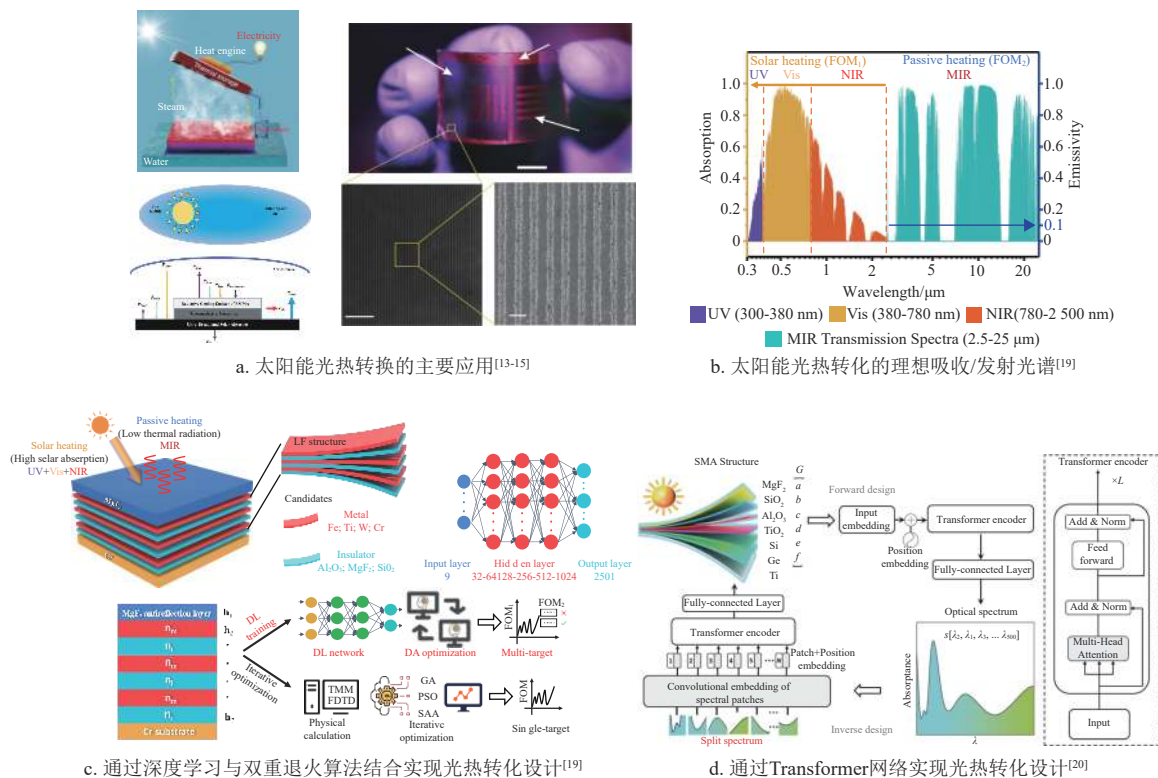


图 4 深度学习在光热转化中的应用

传统的设计方法通常采用优化算法, 如粒子群算法<sup>[16]</sup>和遗传算法<sup>[17-18]</sup>等。这些算法通过迭代更新, 不断调整设计参数以优化吸收性能。然而, 这些优化算法在每一次迭代中都强烈依赖于数值模拟的结果。因此, 其本质上仍然受到数值模拟计算时间和资源成本的限制。

通过将深度学习网络与优化算法相结合, 可以充分利用两者的优势, 从而显著提高设计效果。2023年, 文献<sup>[19]</sup>通过将深度学习与多目标退火算法相结合, 设计了一种选择性太阳能吸收器(图4c)。具体来说, 开发了一种高性能设计范式, 通过深度学习网络和多目标双重退火算法优化多层纳米结构, 以最大化太阳光谱吸收并最小化红外辐射。深度学习网络可以实时预测复杂纳米结构参数与光学响应光谱之间的关系, 消除了迭代和耗时的计算。结合双重退火算法进行全局优化, 深度学习网络可以在毫秒时间尺度内预测光学响应, 大大加快设计速度。该算法还提供了多种候选方案, 允许选择适合的材料和每层的厚度, 以满足期望的光谱响应需求。

同年, 文献<sup>[20]</sup>提出了一种基于Transformer的深度学习网络, 用于设计宽带太阳能超材料吸收器(图4d)。Transformer的独特机制为解决复杂的光谱调控问题提供了强大的工具。Transformer模型最初应用于自然语言处理领域, 以其在处理序列数据方面的卓越能力而闻名。其核心优势在于自

注意力机制, 能够在不依赖固定窗口大小的情况下捕捉输入数据的全局依赖关系。通过将光谱响应分成多个小块, 并按照自注意力机制进行学习, 能够在处理光谱数据时灵活地关注不同光谱响应中的关键特征, 从而避免了传统深度学习模型中常见的过拟合问题, 并显著提升了学习能力。另外, 通过建立双向串联网, 可以解决光谱逆向设计中的“一对多”问题。

目前, 深度学习在太阳能光热转换领域的研究尚处于早期阶段, 其在材料性能优化和系统设计中已显示出巨大潜力。通过预测和改进吸热材料的光吸收效率和热稳定性, 以及优化系统布局以最大化能量捕获, 深度学习技术未来可望大幅提升太阳能光热转换效率和系统可靠性。

### 2.2.2 辐射制冷

辐射制冷是一种被动制冷技术, 通过将热辐射输出至外太空来实现制冷效果, 其在织物<sup>[21]</sup>、医疗<sup>[22]</sup>、生态<sup>[23]</sup>和建筑<sup>[24-26]</sup>等领域均有重要价值(图5a)。辐射制冷材料的理想光谱如图5b所示。与光热转化材料“互补”, 理想的辐射制冷材料应在太阳光谱范围(0.3~2.5 μm)具有高反射率, 以最大限度减少太阳热量的吸收, 同时在中红外范围(8~13 μm)具有高发射率, 以通过向外太空辐射热量实现有效冷却<sup>[27]</sup>。因此, 部分辐射制冷的的设计方法与光热转换相似, 利用优化算法同时优化这两个波段的特性<sup>[28-30]</sup>。

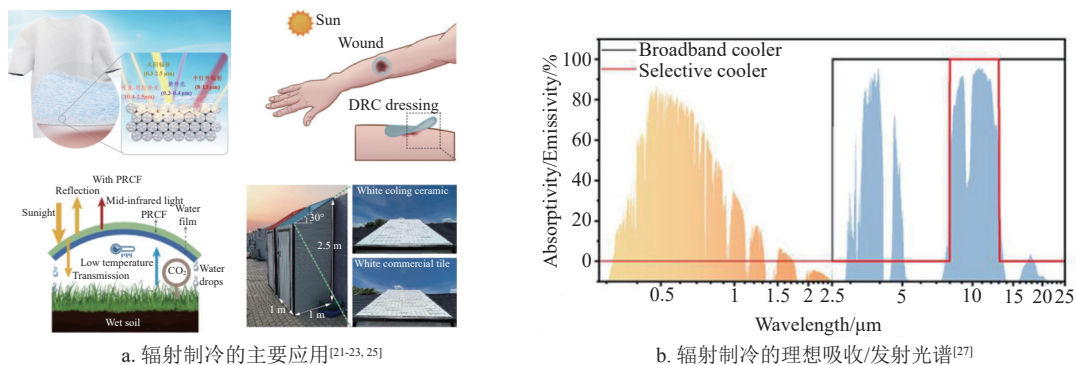


图5 辐射制冷

然而, 传统的设计方法在应对复杂、多目标的优化问题时存在诸多局限。尤其是在彩色辐射制冷的设计中, 这种局限性尤为突出。深度学习的出现则可以突破传统辐射制冷优化方法的瓶颈, 进一步提升设计效率。

#### 1) 白色辐射制冷

在白色辐射制冷材料的设计领域, 深度学习最

常见的应用是采用简单的正向网络来代替仿真软件, 以加速光谱结果的输出。2022年, 文献<sup>[31]</sup>开发了一种基于深度学习的热辐射控制微结构材料的设计方法(图6a)。该方法利用正向深度神经网络来模拟有限差分时间域仿真输出, 从而模拟不同材料、波长和温度条件下微结构的光学性能, 显著提高了设计优化的效率和效果。

2024 年, 文献 [32] 利用深度学习模型来理解仿生超材料与光谱响应之间的复杂关系, 从而确定最佳性能参数范围 (图 6b)。其团队构建了 3 种 SiO<sub>2</sub> 仿生超表面 (圆柱阵列、截锥阵列和锥阵

列), 并利用正向深度学习模型学习不同模型的光谱特性与设计参数之间的关系。通过参数扫描, 该团队确定了最佳的截锥阵列高度/直径比, 设计的平均发射率高达 0.985。

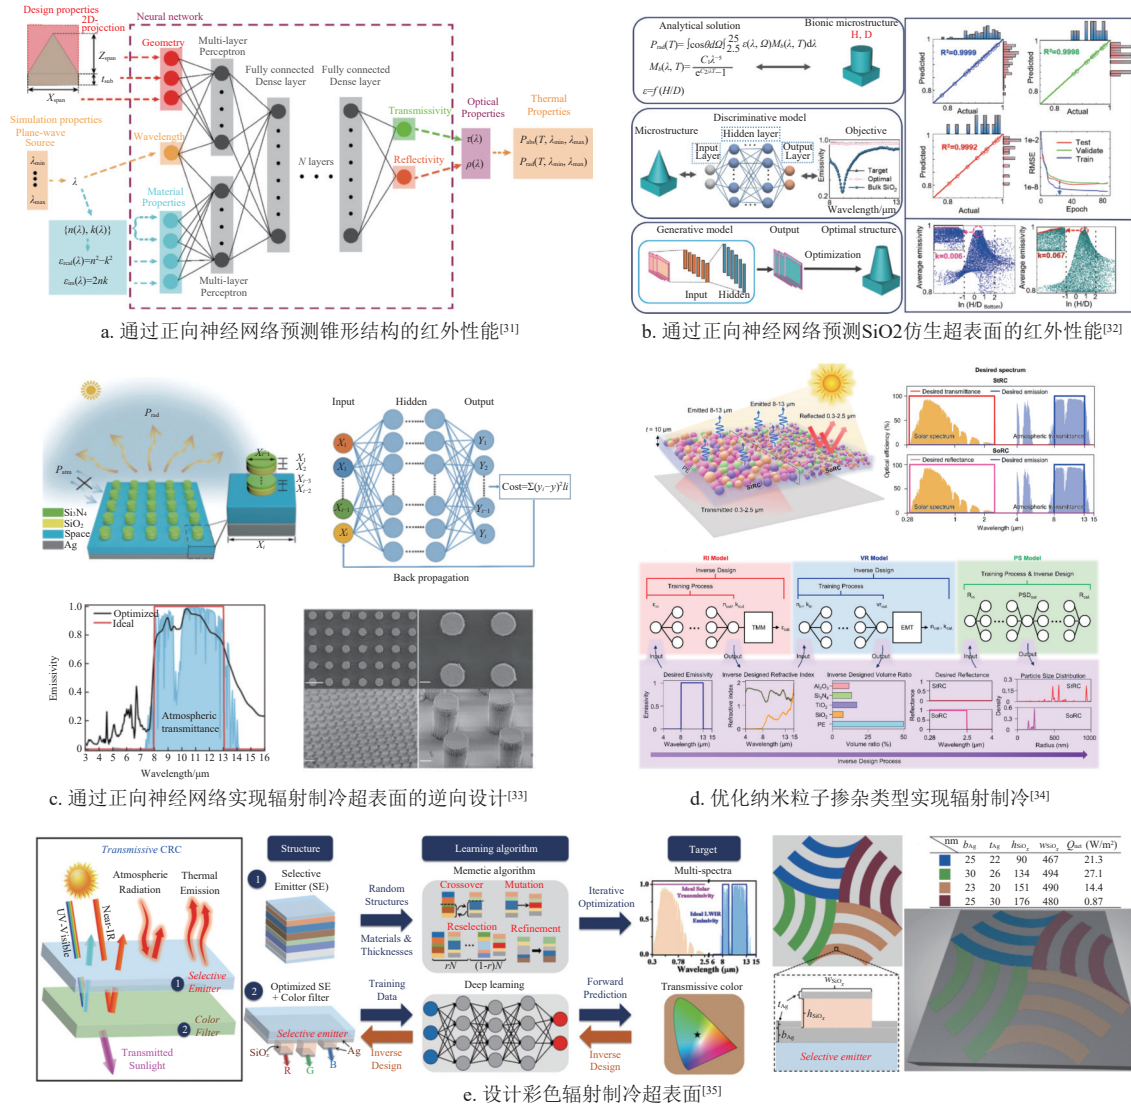


图 6 深度学习在辐射制冷中的应用

同年, 文献 [33] 提出了一种基于深度学习的混合极性介电超表面热发射器的设计方法 (图 6c)。研究团队采用有限差分时域法生成大量样本数据, 并使用这些样本数据训练正向网络, 建立结构参数与热发射光谱之间的映射关系。训练完成后, 固定神经网络的权重和偏置, 将其用于逆向设计。

除了代替仿真软件外, 在白色辐射制冷材料的设计中, 深度学习网络还可以直接根据输入的目标光谱实现微纳结构的逆向设计, 文献 [34] 提出了一种基于深度学习辅助设计嵌入纳米粒子的辐射冷却器的方法 (图 6d)。该团队通过深度学习算法

优化纳米粒子掺杂类型辐射冷却器的光学常数、材料体积分数和粒子尺寸分布, 从而实现优异的光学性能。

## 2) 彩色辐射制冷

利用深度学习技术优化设计, 不仅可以实现较好的辐射制冷效果, 还可以赋予材料特定的颜色, 从而满足建筑外墙、车辆涂层等需要兼顾功能性和美观的应用需求。2023 年, 文献 [35] 通过深度学习设计颜色辐射制冷器, 解决了传统辐射制冷器由于高反射率要求而导致表面颜色单调的问题 (图 6e)。研究人员提出了一种基于深度学习的逆向设计方

法, 利用金属-绝缘体-金属 (MIM) 结构, 通过 Fabry-Pérot 干涉效应生成减色法原色 (青色、品红和黄色)。他们首先采用时域有限差分法生成大量光谱数据, 然后训练神经网络进行光谱预测。通过串联神经网络架构, 研究人员有效解决了纳米光子结构设计中的“一对多”问题, 使得网络能够快速准确地进行逆向设计。

2024 年, 文献 [36] 进一步研究了通过深度学习逆向设计彩色辐射制冷器。该研究结合了选择性发射体和 MIM 腔体结构, 成功实现了在高反射率和高发射率基础上生成不同颜色的能力。研究团队通过深度神经网络训练, 解决了设计结构与光谱响应之间的复杂关系。通过预先训练前向神经网络和串联逆向神经网络, 研究人员能够快速设计出同时满足冷却功率和特定颜色要求的结构。结果表明, 设计的制冷器在可见光范围内能够生成高饱和度的 CMY 颜色, 并在近红外范围内具有较高的反射率, 有效减少了太阳辐射吸收。

综上所述, 将深度学习引入到辐射制冷技术中, 能够极大地优化制冷系统的设计效率和性能。通过利用深度学习模型来模拟和预测材料的辐射特

性, 研究人员可以更精确地制定出适应各种环境条件的制冷解决方案, 从而推动这一技术向更广泛的应用领域扩展。

### 2.2.3 热伪装

深度学习在热伪装领域也展现出巨大的应用潜力。热伪装技术通过控制材料表面与环境之间的热辐射交换, 使得目标物体在红外热成像设备中变得不可见<sup>[37]</sup>。与辐射制冷类似, 热伪装技术也需要精确控制材料的红外光谱特性, 以实现所需的伪装效果。

2023 年, 文献 [38] 提出了一种基于深度学习的逆向设计方法, 旨在设计兼具激光和红外伪装功能的高性能超表面, 同时实现有效的热辐射管理, 其理想的光谱特征如图 7a 所示。研究团队采用机器学习驱动的逆向设计方法, 通过物理基础的数据降维, 提高了神经网络的准确性和效率。该方法能够快速生成满足多波段性能要求的多种非唯一解, 从而匹配所需的多波段光谱。其构建了两个全连接神经网络: 前向反射预测网络和逆向结构设计网络。前向反射预测网络用于从高维参数空间预测单波长的反射率。

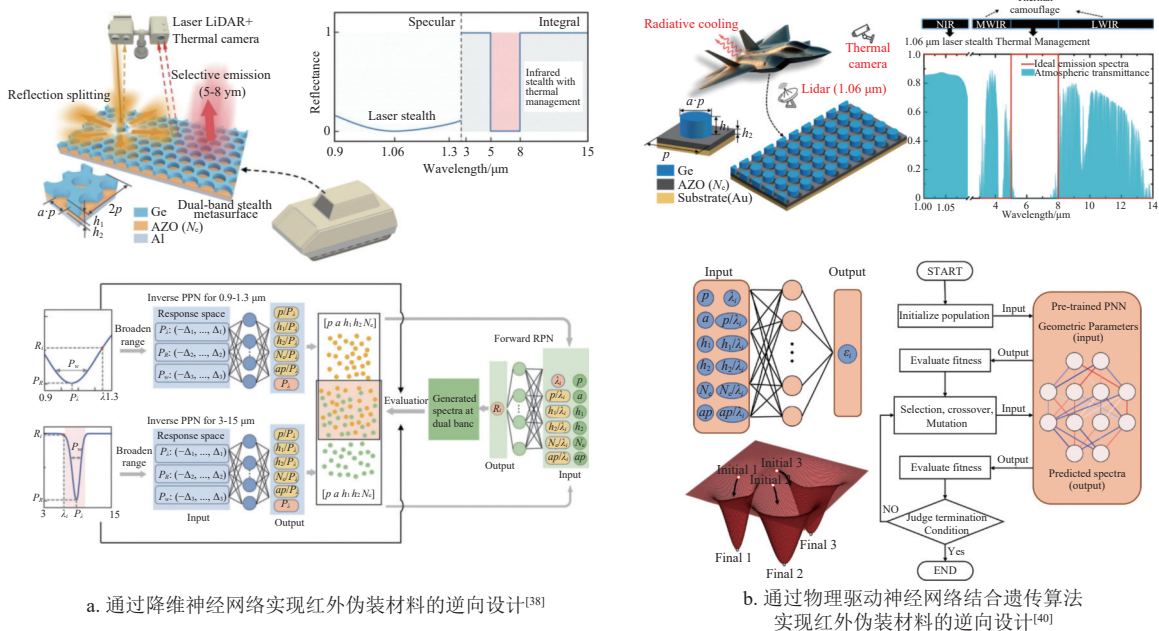


图 7 深度学习在热伪装中的应用

这种方法通过将结构参数 (如周期、孔径比、厚度等) 和波长派生的变量 (如波长、孔径比与波长的比值) 作为输入, 实现了光谱数据的降维处理。逆向结构设计网络则通过从反射光谱中提取峰值特征 (波长、强度和带宽), 生成结构参数。该

方法通过波长派生变量形成输出向量, 确保了输出的唯一性。

同年, 文献 [39] 也做了类似的研究工作, 通过结合严格耦合波分析和深度学习, 设计了一种 Ge/Ag/Ge 多层圆孔超表面, 同时实现了红外伪装

和热辐射管理。该研究同样采用了串联神经网络, 包括一个预训练的光谱预测网络和一个几何预测网络。与其他方法不同, 该团队在网络训练过程中引入惩罚策略, 确保在前 300 个训练周期内, 网络预测的结构参数不偏离基本物理规律, 从而增强了网络的鲁棒性和精度。2024 年, 文献 [40] 进一步提出了一种结合物理驱动神经网络 (Physics-Driven Neural Network, PNN) 和遗传算法的逆向设计方法, 旨在设计一种能够实现 1.06  $\mu\text{m}$  激光伪装、中红外热伪装和高效热管理的 AZO-Ge 圆盘超表面 (图 7b)。在前向预测中, 团队开发了两个 PNN 网络分别预测超表面在 1.06  $\mu\text{m}$  和 3~14  $\mu\text{m}$  波段的发射光谱。PNN 通过预计算的波长派生参数显

著提高了预测精度, 加速了神经网络的收敛。在逆向设计中, 将预训练的神经网络嵌入到遗传算法中, 以预测种群的发射光谱。通过该框架, 设计出了几种 1.06  $\mu\text{m}$  激光兼容红外伪装超表面的结构解决方案。

除了上述在热伪装方面的应用, 深度学习在微波雷达伪装领域<sup>[41-43]</sup>也展现出巨大的潜力, 预示着其在未来军事和民用领域的广泛应用前景。

#### 2.2.4 小结

深度学习在热辐射控制领域的应用, 包括太阳能光热转化、辐射制冷和热伪装, 因其目标光谱不同, 其设计思路在具体实现上也略有差异 (如表 2 所示)。

表 2 用于热辐射控制材料设计的深度学习模型比较

| 输入              | 输出             | 结构类型 | DL模型        | 数据集规模      | MSE               | 精度                                | 文献      |
|-----------------|----------------|------|-------------|------------|-------------------|-----------------------------------|---------|
| 结构参数和材料范围       | 结构参数和材料        | 多层膜  | 优化算法+MLP    | 30 000     | $10^{-3}$         | -                                 | [19]    |
| 目标光谱 (太阳辐射吸收率)  | 单组结构参数         | 多层膜  | Transformer | 141 791    | $10^{-7}$         | -                                 | [20]    |
| 结构参数            | 光谱 (反射率, 透过率)  | 超表面  | MLP         | 35 500     | $10^{-4}$         | $\Delta R < 0.1$ $\Delta T < 0.2$ | [31]    |
| 结构参数            | 目标光谱 (红外发射率)   | 超表面  | MLP         | 200/20 000 | $10^{-8}/10^{-3}$ | -                                 | [32-33] |
| 目标光谱            | 光学常数、体积分数、尺寸分布 | 纳米粒子 | MLP         | 1 000      | $10^{-3}$         | -                                 | [34]    |
| 目标颜色 (Lab)      | 单组结构参数         | 超表面  | 串联MLP       | 11 000     | $10^{-4}$         | $\Delta E < 0.69$                 | [35]    |
| 目标颜色 (Lab)      | 单组结构参数         | 多层膜  | 串联MLP       | 10 000     | $10^{-3}$         | -                                 | [36]    |
| 光谱特征 (波长、强度、宽度) | 单组结构参数         | 超表面  | MLP         | 200 000    | $10^{-3}$         | -                                 | [38]    |
| 结构参数            | 光谱 (红外发射率)     | 超表面  | 优化算法+PNN    | 8 640      | $10^{-4}$         | 0.997                             | [39]    |

在太阳能光热转化领域, 深度学习用于设计高效的光热转换材料。其设计目标包括在太阳辐射波段具有高吸收率, 同时在红外波段具有低发射率。

这种多目标优化问题可以通过深度学习与优化算法结合的方式来解决, 利用深度学习加速优化算法的迭代过程, 从而提高设计效率和性能。

辐射制冷与光热转化材料的目标光谱“互补”, 即红外波段具有高发射率, 同时在太阳辐射波段具有低吸收率。相似的光谱结构使得这两类材料在设计上具有一定的共性。深度学习网络在这些材料的设计中常用于正向预测, 加速设计过程。然而, 色彩的引入为辐射制冷材料的设计带来了更加复杂的需求。目前彩色辐射制冷器的设计方法与结构色的设计方法相似, 在默认选择红外高发材料的基础上, 通过深度学习网络直接建立色域空间与结构参数的联系, 通过输入目标颜色实现结构参数的逆向设计。

在热伪装领域, 目标光谱表现为在红外探测波段 (通常为 3~5  $\mu\text{m}$  和 8~13  $\mu\text{m}$ ) 具有与背景环

境相匹配的发射率, 同时非探测波段 (通常为 5~8  $\mu\text{m}$ ) 具有较高的发射率。除了将其转化为多目标优化问题, 通过深度学习与优化算法相结合来解决外, 还可以提取目标光谱的峰值特征 (如波长、强度和带宽等) 作为输入, 通过深度学习模型逆向设计出满足要求的结构。

### 2.3 窄带光谱传感

窄带光谱设计通常用于特定波段的检测和识别, 如气体传感、化学传感和生物传感等。窄带光谱传感器通常需要在特定波长范围内实现极高的选择性, 以便精确检测和区分微弱的光谱信号。通过精准的光谱控制, 传感器能够实现高选择性和高灵敏度, 满足各种复杂检测需求。然而, 传统的窄带光谱设计方法由于涉及复杂的光学计算和多维参数优化, 效率低下且难以实现全局最优解。深度学习技术的引入, 为窄带光谱设计提供了新的思路和方法。

#### 2.3.1 金属基窄带光谱传感

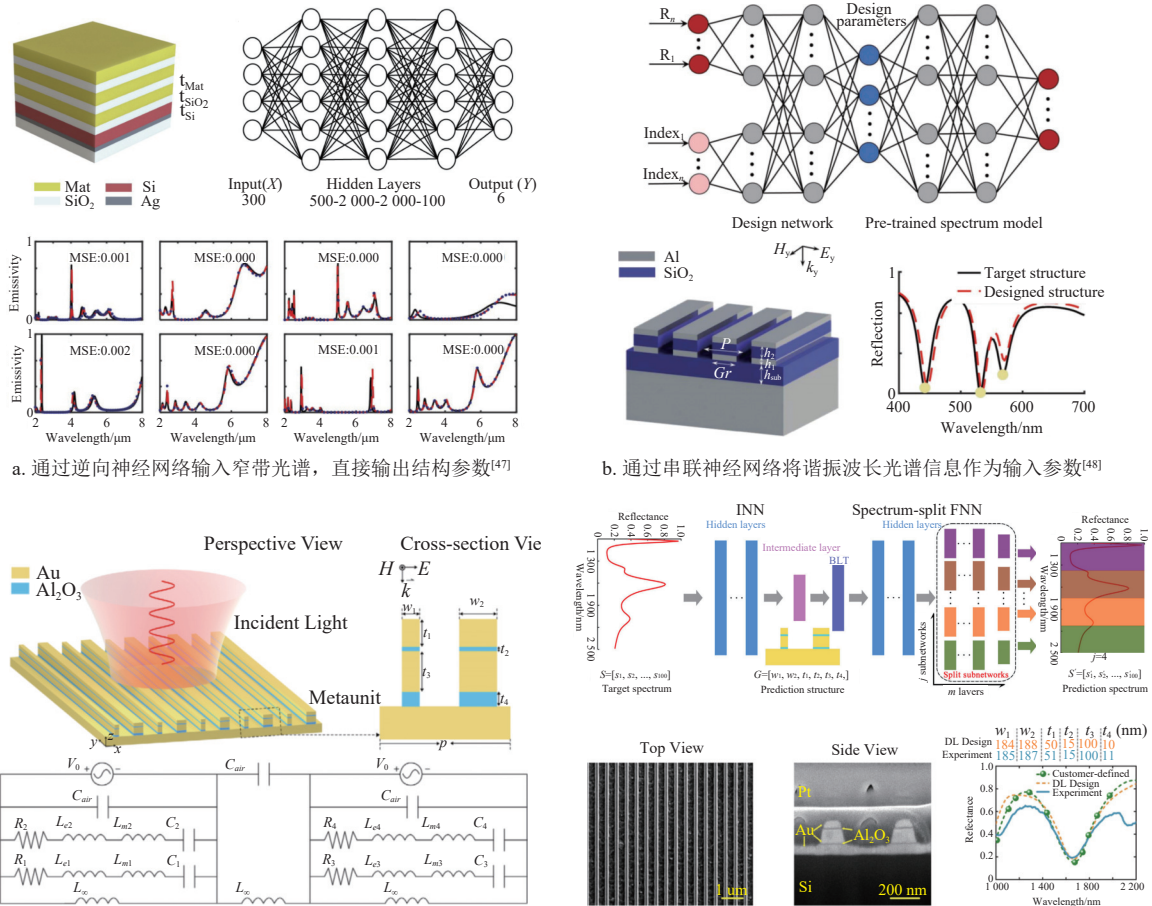
金属基窄带光谱传感技术主要依赖于金属纳米

结构（如光栅或纳米孔）在特定条件下的局部表面等离子共振（LSPR）现象。当光波与这些金属纳米结构相互作用时，会激发出表面等离子共振，从而导致在特定波长处光的强烈吸收和散射<sup>[44-46]</sup>。通过监测这种共振峰的位置和强度的变化，可以实现对环境化学或生物分子的高灵敏度检测。

2021 年，文献 [47] 通过训练神经网络进行光子器件的逆向设计，成功生成了在  $2\sim 8\ \mu\text{m}$  波长范围内工作的超窄带选择性热发射器（图 8a）。通过训练后的神经网络，研究团队成功设计了品质因子（Q 因子）高达 109.2 的超窄带热发射器，平均均方误差（MSE）小于 0.006。同年，文献 [48] 又提出了一种利用深度学习技术设计在可见光范围内工作的光谱敏感多波段吸波器的方法（图 8b）。该文献提出了一种由铝和二氧化硅组成的五层金属-绝缘体-金属光栅结构。为了实现光谱敏感的设计，研究团队将谐振波长光谱信息作为输入参数之

一，结合反射光谱一起输入神经网络。该神经网络的设计具有高度鲁棒性，其平均均方误差为 0.023。研究团队还训练了一个不包含谐振波长光谱信息的网络。结果表明，不包含谐振波长信息的网络在光谱准确性上较差，而包含谐振波长信息的网络表现出更高的光谱准确性。

2023 年，文献 [49] 提出了一种基于双向人工神经网络的分而治之深度学习方案，用于高效、精准地设计具有复杂光谱特征的等离子堆积超材料（图 8c）。具体来说，就是在前向网络中，将最后的几层全连接层划分成多个子网络，每个子网络单独预测光谱的一部分。这样就可以将复杂的光谱预测问题分解为多个子问题，每个子问题的采样点数远小于原始问题。此外，该工作还面向用户端提出了一个交互式客户端，通过在光谱布局中自由操作多个点，可以快速设计具有多种功能的光谱结构，包括多波段滤波、带阻、短通和长通滤波等。



a. 通过逆向神经网络输入窄带光谱，直接输出结构参数<sup>[47]</sup>

b. 通过串联神经网络将谐振波长光谱信息作为输入参数<sup>[48]</sup>

c. 在串联神经网络的基础上将全连接层划分成多个子网络<sup>[49]</sup>

图 8 深度学习在金属基窄带光谱传感中的应用

### 2.3.2 介质基无损窄带光谱传感

在金属基共振系统中，金属材料的引入会存在

一定的能量耗散，因此它们的 Q 因子是有限的。相比之下，连续域束缚态（Bound States in the

Continuum, BIC) 可以通过完美的相消干涉来避免辐射损失, 从而实现理论上的无损共振。这使得 BIC 在某些高精度的光学传感和激光应用中具有非常大的吸引力<sup>[50-51]</sup>。2022 年, 文献 [52] 提出了一种共振信息深度学习策略, 用于快速准确地预测具有超高 Q 因子共振的光学响应, 并开发了逆向设计算法, 用于设计具有无限 Q 因子的 BIC (图 9a)。网络的架构使用了 CNN 和 MLP 的组合。CNN 网络接收电场分布, 以区分不同的共振模式。MLP 接收几何参数和其他输入, 输出背景光谱的反射率

和 Fano 共振的参数。通过将共振信息纳入深度学习算法, 实现了对光学响应的高精度预测。2023 年, 文献 [53] 提出了一种基于准束缚态 (Q-BIC) 的全介质表面增强拉曼散射 (SERS) 超表面的设计方法, 通过 Transformer 驱动深度学习网络进行优化设计, 实现了高 Q 因子共振和显著的 SERS 增强 (图 9b)。2024 年, 文献 [54] 将经典的串联深度学习网络架构引入高 Q 因子 BIC 共振的逆向设计中, 成功设计出波长范围在 400~1 200 nm 范围内、Q 因子从几百到几十万的 BIC 共振结构。

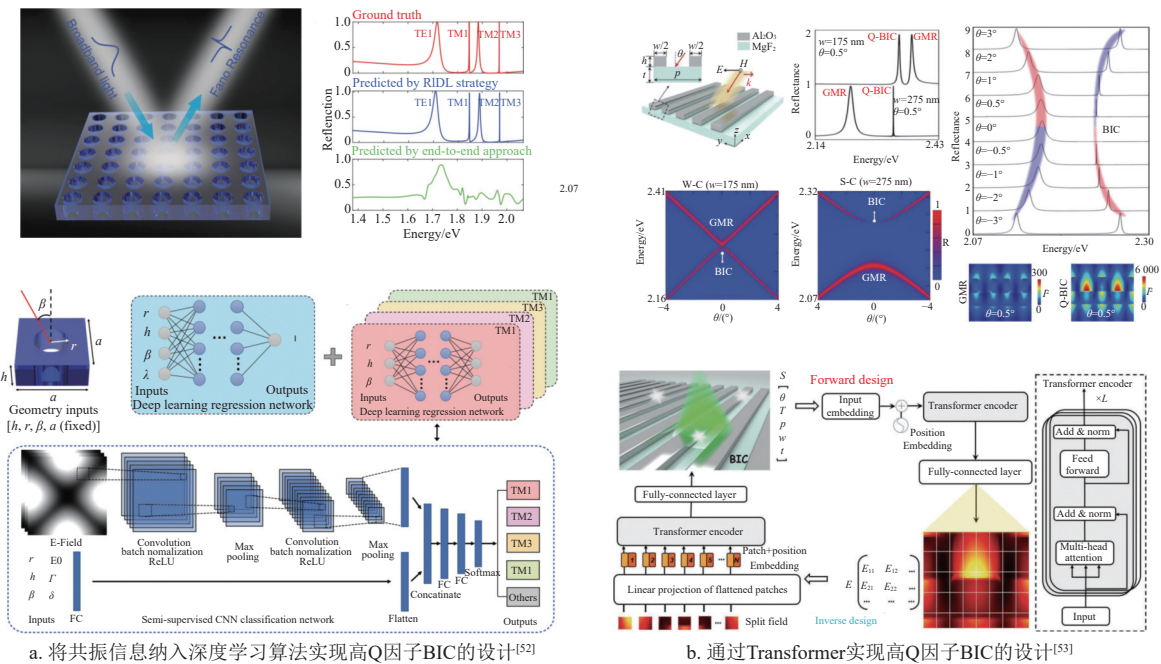


图 9 深度学习在介质基无损窄带光谱传感中的应用

### 2.3.3 小结

相比于前面提到的结构色和热辐射控制, 窄带光谱传感的目标光谱设计更为复杂。这种复杂性主要体现在其对高分辨率和高灵敏度的严格要求上。在这一领域, 深度学习的应用广泛采用逆向设计方法。如表 3 所示, 通过不同的深度学习模型 (如 MLP、串联 MLP、CNN 和 Transformer 等), 引入更多维度的光谱信息, 可以有效地设计出满足复杂光谱需求的材料结构, 从而显著提高设计效率和精确度。具体来

说, 在传统的金属基窄带光谱传感中, 通过将谐振波长作为输入参数, 结合反射光谱一起输入深度学习网络, 可以进一步提升设计的精确度和效率。而在 BIC 领域, 深度学习网络的应用则进一步拓展了设计的维度和复杂性。例如, CNN 网络擅长处理图像或二维数据, 特别适合分析复杂的电场分布; 而 Transformer 模型在处理序列数据和高维度输入方面表现出色, 在光谱信息的高效编码和解码方面尤为适用, 从而更好地满足复杂光谱控制任务的需求。

表 3 用于窄带光谱传感材料设计的深度学习模型的比较

| 输入                            | 输出                  | 结构类型 | DL模型        | 数据集规模  | MSE       | Q因子    | 文献   |
|-------------------------------|---------------------|------|-------------|--------|-----------|--------|------|
| 结构参数                          | 光谱                  | 多层膜  | MLP         | 31 838 | $10^{-3}$ | 109.2  | [47] |
| 光谱信息 (共振波长)                   | 单组结构参数              | 超表面  | 串联MLP       | 12 100 | $10^{-2}$ | —      | [48] |
| 目标光谱 (1.0~2.5 $\mu\text{m}$ ) | 单组结构参数              | 超表面  | 串联MLP       | 55 000 | $10^{-4}$ | —      | [49] |
| 结构参数、光谱信息 (能量、电场分布)           | 光谱反射系数、共振信息         | 超表面  | CNN、MLP     | 4 000  | $10^{-2}$ | $10^6$ | [52] |
| 电场分布                          | 光谱信息 (入射角、透射率)、结构参数 | 超表面  | Transformer | 26 881 | $10^{-4}$ | —      | [53] |
| 共振波长、Q因子                      | 单组结构参数              | 超表面  | 串联MLP       | 1 891  | $10^{-3}$ | $10^5$ | [54] |

随着材料科学和纳米技术的进步,窄带光谱传感技术的未来发展预计将集中在提高灵敏度和选择性以及设备的迷你化上。此外,深度学习的融入将为窄带光谱传感器的设计和性能优化带来革命性的改变,通过智能算法优化结构设计和实时处理数据,可以极大地提升光谱分析的准确性和速度。这些进展将为环境监测、疾病诊断和安全检测等多个领域带来前所未有的技术突破。

### 3 结束语

深度学习已在微纳结构光谱设计的应用中展现出了显著的潜力和优势。在结构色设计中,深度学习能够快速预测和优化纳米结构的颜色表现;在热辐射领域,深度学习技术通过高效的逆向设计实现了复杂光谱特性的调控;在窄带光谱传感方面,深度学习模型提供了高选择性和高灵敏度的解决方案。总的来说,深度学习在光谱设计中的优势主要包括以下两点。1)深度学习技术的引入可以显著提升计算效率。通过使用深度学习网络,可以有效替代传统的数值模拟,快速预测结构参数的光谱响应,大幅缩短设计周期。2)神经网络模型通过结合前向和逆向网络,不仅提高了预测的精度,而且简化了设计的复杂性。生成网络(如GAN和CGAN)能够产生多种满足设计要求的结构方案,从而进一步简化设计过程。除此之外,深度学习还具备跳脱传统人工结构设计局限性的能力。通过学习大量数据,深度学习模型能够设计出一些不规则甚至是非常规的图案和结构<sup>[55]</sup>。这些设计不仅突破了传统方法的束缚,展现出更具多样性的特征,更重要的是,这些非常规结构还有可能揭示新的物理机制。这使其能够在其他材料科学领域中也具有重要意义<sup>[56]</sup>。

尽管深度学习在微纳结构光谱设计中的应用已取得重要进展,但仍存在一些挑战和机遇。

1)训练成本挑战。构建和训练深度学习网络需要大量计算资源,尤其是在数据难以获取的领域。为降低成本和优化数据获取,可采用迁移学习和数据增强技术,提升模型在有限数据上的表现。

2)泛化能力问题。许多网络仅针对特定结构或材料组合的优化,限制了其泛化能力。未来研究可开发大规模数据模型,如ChatGPT,通过联合学习不同材料和结构的数据,提高模型的泛化能力。

3)制备误差问题。理论设计往往忽略了实际制造过程中不可避免的误差,如材料不均和工艺偏

差等,从而影响最终的光谱特性。未来研究可结合模拟与实验,预测和控制这些误差,或在设计阶段引入容错机制,增强实际应用中的鲁棒性。

展望未来,深度学习在微纳结构设计中的发展趋势将可能朝着以下几个新方向前进。

1)多物理场耦合设计。通过将多种物理场的耦合特性纳入深度学习模型,实现对微纳结构更为全面的设计。

2)自适应深度学习。通过引入自适应学习机制,使网络能够动态调整其结构和参数,不再依赖预设的设计框架,实现自主化设计,提高设计效率和灵活性。

3)量子计算与深度学习结合。利用量子计算的超强并行计算能力,提升设计复杂微纳结构的效率,突破现有计算资源的限制。

总之,深度学习为微纳光谱调控带来了革命性的变化,其应用不仅提升了设计效率和精度,还为解决复杂光谱设计问题提供了新的思路。随着技术的不断进步和完善,深度学习在光谱调控领域的应用将越来越广泛,助力实现更加智能化、高效化的纳米结构设计和应用。

### 参考文献

- [1] SMITH D R, PENDRY J B, WILTSHIRE M C K. Metamaterials and negative refractive index[J]. *Science*, 2004, 305(5685): 788-792.
- [2] JOANNOPOULOS J D, JOHNSON S G, WINN J N, et al. Molding the flow of light[M]. Princeton, NJ: Princeton University Press, 2008: 33-43.
- [3] JIANG J, CHEN M, FAN J A. Deep neural networks for the evaluation and design of photonic devices[J]. *Nature Reviews Materials*, 2021, 6(8): 679-700.
- [4] MA W, LIU Z, KUDYSHEV Z A, et al. Deep learning for the design of photonic structures[J]. *Nature Photonics*, 2021, 15(2): 77-90.
- [5] XUAN Z, LI J, LIU Q, et al. Artificial structural colors and applications[J]. *The Innovation*, 2021, 2(1): 15.
- [6] LI Y, HU J, ZENG Y, et al. Recent progress on structural coloration[J]. *Photonics Insights*, 2024, 3(2): R03.
- [7] GAO L, LI X, LIU D, et al. A bidirectional deep neural network for accurate silicon color design[J]. *Advanced Materials*, 2019, 31(51): 1905467.
- [8] DAI P, WANG Y, HU Y, et al. Accurate inverse design of Fabry-Perotcavity-based color filters far beyond sRGB via a bidirectional artificial neural network[J]. *Photonics Research*, 2021, 9(5): B236-B246.
- [9] DAI P, SUN K, YAN X, et al. Inverse design of structural color: Finding multiple solutions via conditional generative adversarial networks[J]. *Nanophotonics*, 2022, 11(13): 3057-3069.

- [10] XIE R R, ZHU H, XING R, et al. Femtosecond laser modification of vanadium dioxide for color display applications[J]. *Applied Physics Letters*, 2023, 123(9): 093101.
- [11] DAI P, SUN K, MUSKENS O L, et al. Inverse design of a vanadium dioxide based dynamic structural color via conditional generative adversarial networks[J]. *Optical Materials Express*, 2022, 12(10): 3970-3981.
- [12] HU L, MA L, WANG C, et al. Machine learning-assisted design of polarization-controlled dynamically switchable full-color metasurfaces[J]. *Optics Express*, 2022, 30(15): 26519-26533.
- [13] LIN K T, LIN H, YANG T, et al. Structured graphene metamaterial selective absorbers for high efficiency and omnidirectional solar thermal energy conversion[J]. *Nature Communications*, 2020, 11(1): 1389.
- [14] LIN H, STURMBERG B C P, LIN K T, et al. A 90-nm-thick graphene metamaterial for strong and extremely broadband absorption of unpolarized light[J]. *Nature Photonics*, 2019, 13(4): 270-276.
- [15] XU N, LI J, FINNERTY C, et al. Going beyond efficiency for solar evaporation[J]. *Nature Water*, 2023, 1(6): 494-501.
- [16] LIU J, DOU C, CHEN W, et al. Inverse design a patternless solar energy absorber for maximizing absorption[J]. *Solar Energy Materials and Solar Cells*, 2022, 244: 111822.
- [17] XIAO W, DAI P, SINGH H J, et al. Flexible thin film optical solar reflectors with Ta<sub>2</sub>O<sub>5</sub>-based multimaterial coatings for space radiative cooling[J]. *APL Photonics*, 2023, 8(9): 090802.
- [18] ZHANG W W, QI H, YU Z Q, et al. Optimization configuration of selective solar absorber using multi-island genetic algorithm[J]. *Solar Energy*, 2021, 224: 947-955.
- [19] MA W, CHEN W, LI D, et al. Deep learning empowering design for selective solar absorber[J]. *Nanophotonics*, 2023, 12(18): 3589-3601.
- [20] CHEN W, GAO Y, LI Y, et al. Broadband solar metamaterial absorbers empowered by transformer-based deep learning[J]. *Advanced Science*, 2023, 10(13): 2206718.
- [21] ZENG S, PIAN S, SU M, et al. Hierarchical-morphology metafabric for scalable passive daytime radiative cooling[J]. *Science*, 2021, 373(6555): 692-696.
- [22] ZHANG Q, QI C, WANG X, et al. Daytime radiative cooling dressings for accelerating wound healing under sunlight[J]. *Nature Chemical Engineering*, 2024, 1(4): 301-310.
- [23] LI J, JIANG Y, LIU J, et al. A photosynthetically active radiative cooling film[J]. *Nature Sustainability*, 2024, 7: 786-795.
- [24] HUANG G, YENGANNAGARI A R, MATSUMORI K, et al. Radiative cooling and indoor light management enabled by a transparent and self-cleaning polymer-based metamaterial[J]. *Nature Communications*, 2024, 15(1): 3798.
- [25] LIN K, CHEN S, ZENG Y, et al. Hierarchically structured passive radiative cooling ceramic with high solar reflectivity[J]. *Science*, 2023, 382(6671): 691-697.
- [26] WANG S, JIANG T, MENG Y, et al. Scalable thermochromic smart windows with passive radiative cooling regulation[J]. *Science*, 2021, 374(6574): 1501-1504.
- [27] ZHANG Q, RAO Z, MA R. Radiative cooling: Arising from practice and in turn serving practice[J]. *Nanophotonics*, 2024, 13(5): 563-582.
- [28] KIM S, WU S, JIAN R, et al. Design of a high-performance titanium nitride metastructure-based solar absorber using quantum computing-assisted optimization[J]. *ACS Applied Materials & Interfaces*, 2023, 15(34): 40606-40613.
- [29] SO S, YANG Y, SON S, et al. Highly suppressed solar absorption in a daytime radiative cooler designed by genetic algorithm[J]. *Nanophotonics*, 2022, 11(9): 2107-2115.
- [30] KIM S, SHANG W, MOON S, et al. High-performance transparent radiative cooler designed by quantum computing[J]. *ACS Energy Letters*, 2022, 7(12): 4134-4141.
- [31] SULLIVAN J, MIRHASHEMI A, LEE J. Deep learning based analysis of microstructured materials for thermal radiation control[J]. *Scientific Reports*, 2022, 12(1): 9785.
- [32] DING Z, LI X, JI Q, et al. Machine-learning-assisted design of a robust biomimetic radiative cooling metamaterial[J]. *ACS Materials Letters*, 2024, 6: 2416-2424.
- [33] ZHANG Y, CHEN Y, WANG T, et al. Ultrahigh performance passive radiative cooling by hybrid polar dielectric metasurface thermal emitters[J]. *Opto-Electronic Advances*, 2024, 7(4): 230194-1-230194-9.
- [34] KIM M J, KIM J T, HONG M J, et al. Deep learning-assisted inverse design of nanoparticle-embedded radiative coolers[J]. *Optics Express*, 2024, 32(9): 16235-16247.
- [35] GUAN Q, RAZA A, MAO S S, et al. Machine learning-enabled inverse design of radiative cooling film with on-demand transmissive color[J]. *ACS Photonics*, 2023, 10(3): 715-726.
- [36] KEAWMUANG H, BADLOE T, LEE C, et al. Inverse design of colored daytime radiative coolers using deep neural networks[J]. *Solar Energy Materials and Solar Cells*, 2024, 271: 112848.
- [37] XU C, STIUBIANU G T, GORODETSKY A A. Adaptive infrared-reflecting systems inspired by cephalopods[J]. *Science*, 2018, 359(6383): 1495-1500.
- [38] LIU X, WANG P, XIAO C, et al. Compatible stealth metasurface for laser and infrared with radiative thermal engineering enabled by machine learning[J]. *Advanced Functional Materials*, 2023, 33(11): 2212068.
- [39] WANG L, DONG J, ZHANG W, et al. Deep learning assisted optimization of metasurface for multi-band compatible infrared stealth and radiative thermal management[J]. *Nanomaterials*, 2023, 13(6): 1030.
- [40] WANG L, DONG J, ZHANG W, et al. Inverse design for laser-compatible infrared camouflage metasurface enabled

- by physics-driven neural network and genetic algorithm[J]. *Optical Materials*, 2024, 153: 115639.
- [41] HUANG Y, LIU X, LIU M, et al. Deep learning-based inverse design of multi-functional metasurface absorbers[J]. *Optics Letters*, 2024, 49(10): 2733-2736.
- [42] XIE H, YUE X, WEN K, et al. Deep-learning based broadband reflection reduction metasurface[J]. *Optics Express*, 2023, 31(9): 14593-14603.
- [43] QIAN C, ZHENG B, SHEN Y, et al. Deep-learning-enabled self-adaptive microwave cloak without human intervention[J]. *Nature photonics*, 2020, 14(6): 383-390.
- [44] FANO U. The theory of anomalous diffraction gratings and of quasi-stationary waves on metallic surfaces (Sommerfeld's waves)[J]. *JOSA*, 1941, 31(3): 213-222.
- [45] NGUYEN H H, PARK J, KANG S, et al. Surface plasmon resonance: A versatile technique for biosensor applications[J]. *Sensors*, 2015, 15(5): 10481-10510.
- [46] NAN X, LAI W, PENG J, et al. In situ photoelectric biosensing based on ultranarrowband near-infrared plasmonic hot electron photodetection[J]. *Advanced Photonics*, 2024, 6(2): 026007.
- [47] SO S, LEE D, BADLOE T, et al. Inverse design of ultranarrowband selective thermal emitters designed by artificial neural networks[J]. *Optical Materials Express*, 2021, 11(7): 1863-1873.
- [48] SO S, YANG Y, LEE T, et al. On-demand design of spectrally sensitive multiband absorbers using an artificial neural network[J]. *Photonics Research*, 2021, 9(4): B153-B158.
- [49] XIONG J, SHEN J, GAO Y, 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.
- [50] ZHEN B, HSU C W, LU L, et al. Topological nature of optical bound states in the continuum[J]. *Physical Review Letters*, 2014, 113(25): 257401.
- [51] TITTL A, LEITIS A, LIU M, et al. Imaging-based molecular barcoding with pixelated dielectric metasurfaces[J]. *Science*, 2018, 360(6393): 1105-1109.
- [52] MA X, MA Y, CUNHA P, et al. Strategic deep learning for photonic bound states in the continuum[J]. *Laser & Photonics Reviews*, 2022, 16(10): 2100658.
- [53] CHEN W, LI Y, LIU Y, et al. All-dielectric SERS metasurface with strong coupling quasi-BIC energized by transformer-based deep learning[J]. *Advanced Optical Materials*, 2024, 12(4): 2301697.
- [54] WANG L, WANG W, DONG Q, et al. Deep learning enabled inverse design of bound states in the continuum with ultrahigh Q factor[J]. *JOSA B*, 2024, 41(2): A146-A151.
- [55] HAN X, FAN Z, LIU Z, et al. Inverse design of metasurface optical filters using deep neural network with high degrees of freedom[J]. *InfoMat*, 2020, 3(4): 432-442.
- [56] MERCHANT A, BATZNER S, SCHOENHOLZ S S, et al. Scaling deep learning for materials discovery[J]. *Nature*, 2023, 624(7990): 80-85.

编辑 刘飞阳