文章编号: 1007-4252(2025)02-0088-11 DOI: 10.20027/j.gncq.2025.0016 CSTR: 32180.14.j.gncq.2025.0016

声学超材料中的智能设计:从优化到逆向设计

杭 银[1,2], 李秋彤[2,*], 刘 艳[2], 解丽丽[1], 吴新锋[1]
(1. 上海第二工业大学 能源与材料学院, 上海 201209; 2. 上海材料研究所有限公司, 上海 200437)

摘要: 声学超材料(Acoustic Metamaterials, AMs)具有独特的声学属性和物理性质,是声学领域中的重要发展方向。其耗时的设计过程和资源浪费,传统设计方法因已不再适应 AMs 设计的实际需求。人工智能(Artificial Intelligence, AI)技术的出现引发了对 AMs 智能设计的研究热潮, AI 已成为设计 AMs 结构的一种新方法。本文首先以机器学习(Machine Learning, ML)和智能优化算法(Intelligent Optimization Algorithm, IOA)为切入点,介绍了广泛应用于 AMs 智能设计的 AI 技术,具体包括 ML 和 IOA 的分类与研究进展。接着,重点探讨了 AI 技术在 AMs 智能设计中的应用潜力,尤其是结构优化和逆向设计方面的研究现状。最后,本文分析了现有技术在该领域所面临的困难和瓶颈,并对未来进行了展望。

关键词: 声学超材料; 人工智能; 智能设计; 结构优化; 逆向设计
中图分类号: TB535 **文献标志码:** A

The intelligent design in acoustic metamaterials: from optimization to inverse design

HANG Yin[1,2], LI Qiu-tong[2,*], LIU Yan[2], XIE Li-li[1], WU Xin-feng[1]
(1. Shanghai Polytechnic University School of Energy and Materials, Shanghai 201209, China; 2. Shanghai Research Institute of Materials Ltd., Shanghai 200437, China)

Abstract: Acoustic metamaterials (AMs) possess unique acoustic properties and physical characteristics, positioning them as a key direction for future advancements in the field of acoustics. Traditional design methods, due to their time-consuming processes and resource inefficiency, no longer meet the practical demands of acoustic metamaterial design tasks. The emergence of artificial intelligence (AI) has sparked a surge in research on the intelligent design of AMs, establishing it as a novel approach to their design. This paper first introduces the AI technologies widely applied in the intelligent design of AMs, including machine learning (ML) and intelligent optimization algorithms (IOA), covering the classification and research progress of ML and IOA. It then focuses on exploring the potential applications of AI techniques

收稿日期: 2025−02−19; **修订日期:** 2025−03−27
基金项目: 国家重点研发计划资助项目 (2021YFB3801804).
作者简介: 杭银 (1999-), 女, 硕士研究生, 主要研究方向为人工智能与超材料的交叉 (Email: 2579954361@qq.com).
通信作者: 李秋彤 (1991-), 女, 博士, 副研究员, 主要研究方向为振动与噪声控制 (Email: lqt910818@163.com).

in the intelligent design of AMs, with particular emphasis on the current state of research in structural optimization and inverse design. Finally, it analyzes the difficulties and bottlenecks faced by existing technologies in this field and provides a perspective on future developments.

Key words: acoustic metamaterials; artificial intelligence; intelligent design; structural optimization; inverse design

0 引言

近年来, 在现代科学与工程领域, 对声波进行精确控制与操纵的重要性日益凸显。声学超材料(AMs)能够在传统材料基础上, 对微观结构进行精细调控与巧妙组合, 进而实现宏观性能的显著改变, 获得天然材料所不具备的特殊声学属性与超常物理性质[1]。这使得 AMs 在减振降噪、声隐身、声学成像等领域[2-4]展现出广泛的应用前景。

AMs 的优化和设计涉及物理、材料科学和工程等多个领域。传统的基于解析和仿真的人工设计方法, 需要投入大量时间和计算资源, 引入 AI 技术可以大幅提高优化效率。此外, AI 技术还可以用于对 AMs 的逆向设计, 其目标是确定实现所需性能的相应 AMs 的结构参数。因此, 本文旨在回顾包括 ML 和 IOA 方法在内的 AI 技术及其在 AMs 设计中的最新进展, 重点探讨这些技术在结构优化和逆向设计中的应用。本综述希望为 AMs 领域的研究者提供一个全面的技术框架, 推动 AI 技术在这一新兴领域的应用和创新。

1 应用于 AMs 智能设计的 AI 技术

AI 技术为解决复杂的非线性问题提供了有效工具[5-7]。在面向 AMs 的智能设计研究中, 研究者们主要背靠 ML 和 IOA 两大核心领域。ML 主要通过监督学习、无监督学习和强化学习技术, 从数据中挖掘 AMs 结构与性能间的潜在规律, 从而实现对 AMs 的设计。IOA 是 AI 技术的另一个重要分支, 以自然进化或物理现象为原理, 高效搜索满足特定声学性能的 AMs 的结构参数, 加速设计过程并提升优化效果。针对不同的设计需求, 研究者们可以单独使用某种单一技术, 也可以将二者结合形成嵌套式智能设计框架。

1.1 ML 研究进展

1.1.1 监督学习

监督学习作为 ML 最常用的范式之一, 依赖于带有标签的数据, 通过训练模型来对未知数据的输出进行预测。传统监督学习以浅层模型(如支持向量机、朴素贝叶斯、随机森林等)为主, 在 AMs 智能设计中的应用研究较少, 但其作为中间环节在加速预测超材料特性方面仍具有一定优势和应用价值[8,9]。随着深度学习技术的快速发展, 神经网络相关模型在 AMs 智能设计中逐渐成为研究热点。这类模型主要基于人工神经网络(Artificial Neural Network, ANN)及其变体, 如图 1 所示。

20 世纪中期, Mcculloch W.S 和 Pitts W.A[10] 提出的 M-P 模型被视为 ANN 的最早原型。基于此, 首个实现二分类任务的感知机模型被提出, 但其在非线性问题上的能力受限; 多层感知机(Multi-Layer Perceptron, MLP)的出现突破了这一局限, 成为神经网络发展的关键。MLP 由输入层、输出层和中间的多个隐藏层组成, 层间的神经元相连形成密集的网络结构, 如图 1(a) 所示。随着计算机硬件和大数据的发展, MLP 演变成深度神经网络(Deep Neural Networks, DNN), 成为深度学习的基础。

除 DNN 外, 卷积神经网络(Convolutional Neural Network, CNN)[11] 等神经网络结构也在此时期大放异彩。CNN 的隐藏层由卷积层、池化层、全连接层及归一化层构成, 如图 1(b) 所示。这些层次结构的设置有效增强了对图像数据特征的学习能力, 从而能够实现复杂映射。然而, 随着网络深度的增加, CNN 面临网络退化等诸多问题。残差神经网络(Residual Network, ResNet)[12] 对传统 CNN 进行了改进和扩展, 如图 1(c) 所示。通过引入残差连接, 让信息直接跳跃传递, ResNet 有效解决了深度网络的退化问题。ResNet 的成功催生了大量变体, 使得监督学习更高效、更强大。

1.1.2 无监督学习

与监督学习不同, 无监督学习从无标签数据中提取信息, 适用于聚类、降维等任务。近年来, 研究人员利用无监督学习中的多种生成模型进行超材料设计, 取得了显著进展。如图 2(a) 所示, 自编

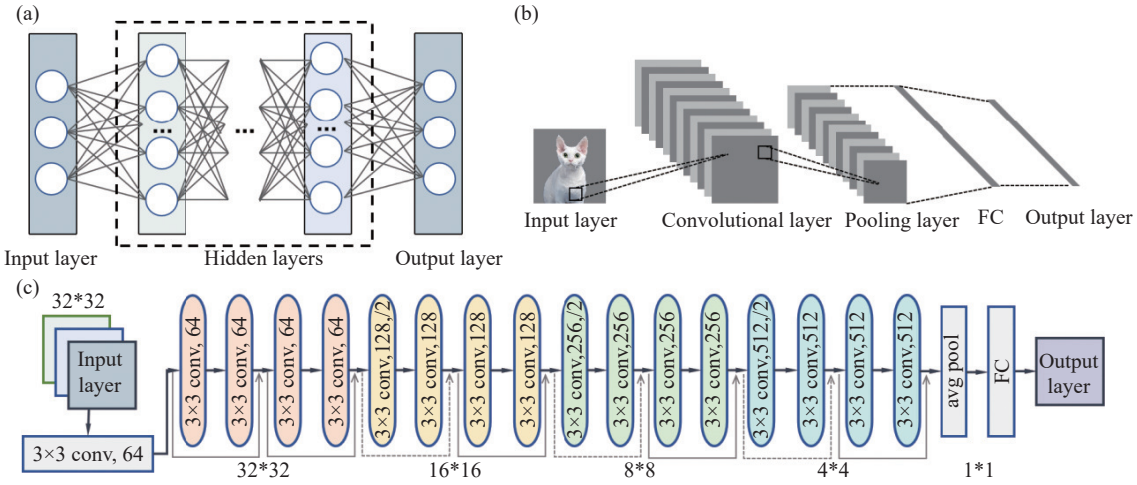

图 1 监督学习模型。(a) MLP; (b) CNN; (c) ResNet

Fig. 1 Supervised learning models. (a) MLP; (b) CNN; (c) ResNet

码器(Autoencoder, AE)[13]由编码器(Encoder)和解码器(Decoder)组成，编码器负责将输入转换为低维空间中的潜在表示，而解码器则重建出与输入相似的输出。变分自编码器(Variational AE, VAE)[14]引入了概率建模思想，模型不再局限于对原始输入的重构，极大提升了生成样本的丰富性和多样性。

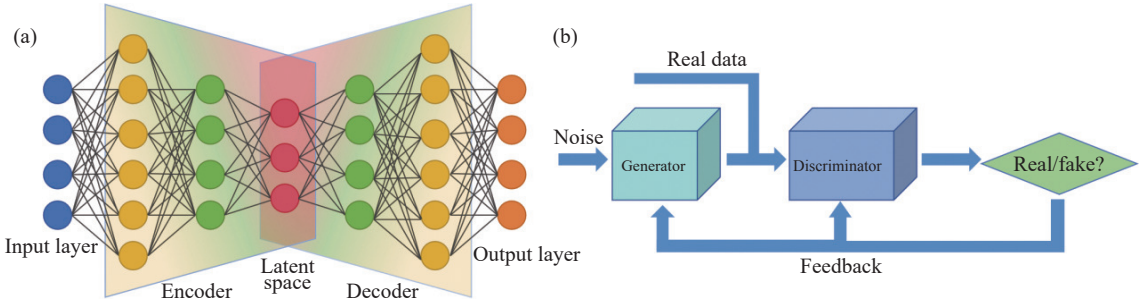

图 2 无监督学习模型。(a) AE; (b) GAN

Fig. 2 Unsupervised learning models. (a) AE; (b) GAN

生成对抗网络(Generative Adversarial Network, GAN)[15]则是另一种生成模型，它包含生成器(Generator)和判别器(Discriminator)，如图 2(b)所示。生成器接收噪声并生成样本，并与真实样本一起输入判别器。判别器则基于二分类原理辨别数据真伪，并将判断结果用于模型更新。通过它们之间的博弈过程对性进行优化，直到判别器的分类准确率达到 0.5 时博弈停止。

随着生成任务需求的增加，生成样本的可控性变得至关重要。条件变分自编码器(Conditional VAE, CVAE)和条件生成对抗网络(Conditional GAN, CGAN)[16,17]等模型应运而生，她们通过引入条件变量，来控制生成样本的属性。由于这些变体模型在训练中会用到标签数据，因此它们究竟属于监督学习还是无监督学习，存在模糊空间。

1.1.3 强化学习

强化学习(RL)[18]被描述为一种优化和决策过程，介于监督学习和无监督学习之间。它由代理(Agent)、环境(Environment)、奖励(Reward)三部分组成，如图 3 所示。其目标是学习代理如何在环境中执行动作以获得最大累积奖励。代理在当前状态下选择并执行一个动作，然后进入下一个状态，环境将对当前动作反馈一个奖励。系统根据奖励进行更新并存储当前状态的价值函数，以迫使代理在未来相同状态下执行正确的动作。强化学习的决策机制在 AMs 结构设计中展现出显著优势。

早期的强化学习算法在状态和动作空间的维度增加时，极易遇到维度灾难问题。深度 Q 网络(Deep Q-Network, DQN)[19]的提出是该领域的又一里程碑。它通过将 CNN 当作 Q 函数的逼近器

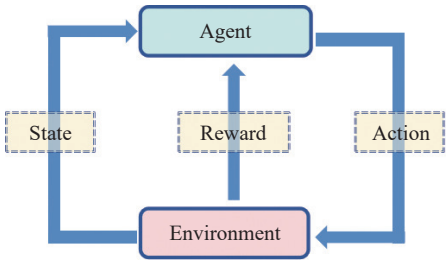

图 3　强化学习框架

Fig. 3　The framework of Reinforcement Learning

来处理高维输入, 并自动提取图像特征。这些特征随后被送入 Q 学习模块, 用于动作选择与策略优化 。

1.2　IOA 研究进展

根据其仿生学原理和优化机制, IOA 可分为进化算法和群智能算法[20], 它可以在复杂的解空间中高效地搜索最优解, 因此被广泛应用于超材料优化等领域[21-23]。

1.2.1 进化算法

进化算法作为模拟生物进化机制的 IOA 核心方法之一, 经历了从典型遗传算法(Genetic Algorithm, GA)到高效差分进化算法(Differential Evolution, DE)的演进, 逐步解决了复杂优化问题的理论与应用挑战。

Holland 于 1975 年提出的 GA[24] 首次将自然选择与遗传学原理引入优化领域, 奠定了进化算法的基础。其基本思想是将种群看作一个遗传基因序列, 并对其进行编码, 利用交叉、变异操作产生新个体, 以适应度函数为标准对染色体进行选择和更新。适应度强的个体有更大的进化机会, 经过不断迭代以得到最优解。GA 从最初的理论探索, 到组合优化、工程设计等实际场景中的成熟应用, 经历了一系列重要的发展与改进阶段, 其中从原始 GA 到非支配排序 GA(Non-dominated Sorting Genetic Algorithm, NSGA-II)的演变, 是其在多目标优化领域迈向成熟的关键。

为克服 GA 在高维连续优化中的局限性, Storn 与 Price 提出了专为连续空间优化设计的 DE 算法[25]。相比于 GA, DE 通过父代个体间的差分扰动来生成新解, 无需编码和解码, 参数复杂度较低, 因此在连续优化中能够显著提升效率[26]。理解二者的差异, 有助于针对具体问题选择更适配的算法。

1.2.2 群智能算法

群智能算法的核心在于通过群体中个体之间的信息交流与协作来共同探索解空间, 以找到最优解。粒子群优化(Particle Swarm Optimization Algorithm, PSO)和布谷鸟优化(Cuckoo Search, CS)是群智能算法的典型代表。

PSO 提出的灵感源自鸟群觅食时的集体行为[27]。在 PSO 中, 每个粒子代表一个潜在解, 通过跟踪个体最优和全局最优位置来更新自身速度和位置, 从而在解空间中移动以寻找最优解。PSO 原理简单、参数少且易于实现, 但存在缺乏对速度的动态调节、容易陷入局部最优等缺点, 适用于离散优化问题。CS 则模拟布谷鸟的寄生繁殖行为和莱维(Lévy)飞行特性[28]。布谷鸟会将蛋产在其他鸟的巢中, 且莱维飞行能产生长距离的随机步长, 使 CS 在全局搜索能力上表现突出, 适合高维复杂优化问题。

PSO 与 CS 在全局探索与局部开发上的互补性, 促使研究者构建混合算法[29], 通过动态切换搜索策略, 显著提升了高维非凸优化问题的优化效率。

2　基于 AI 技术的 AMs 结构优化

2.1　单目标优化

传统 AMs 设计方法, 往往需要大量的计算资源和时间。随着 3D 打印技术和计算能力的提升, IOA和 ML 方法可实现 AMs 设计参数的自动搜索与优化, 从而加速了满足声学需求的结构最优解的获取。

通过不同的 IOA 方法[30-32], 研究者们成功设计了多种低高频吸声器, 显著提高了其吸声性能和频谱调控能力。其中, PSO、CS 和 DE 为解决复杂优化问题提供了不同的视角和方法, 几种典型例子如图 4 所示。Yan 等[33] 采用 PSO 优化设计了不同腔深的单层蜂窝微穿孔板结构, 优化前后的吸声效果对比如图 4(a) 所示。仿真和实验结果表明, 该结构可以利用自身不同深度的蜂窝芯腔实现宽带吸声。Yang 等[34,35] 提出了一种由多个六边形亥姆霍兹共振器并行组成的 AMs, 结合有限元仿真和 CS 算法对具有不同颈部深度的 AMs 进行优化设计, 优化前后的吸声效果如图 4(b) 所示。赵等[36] 公开了一种 AMs 局域共振板, 并基于 DE 对局域共振板

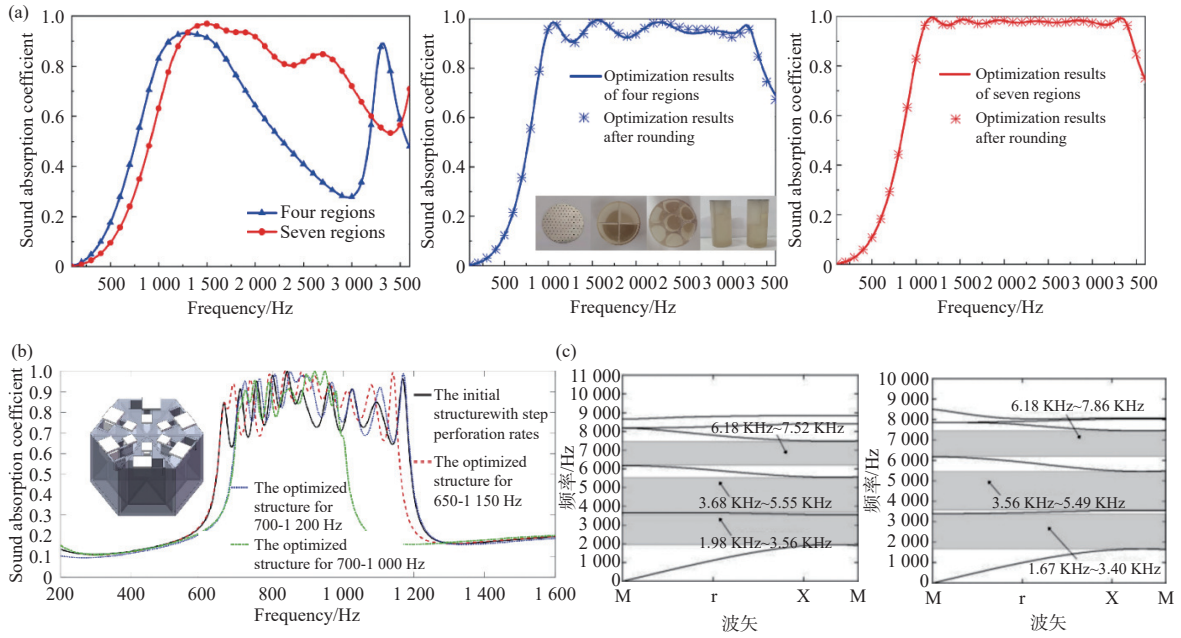

图 4 IOA 方法设计 AMs 的典型案例。(a) PSO 优化单层蜂窝微穿孔板前后的吸声效果对比[33]; (b) CS 优化六边形并行亥姆霍兹共振器前后的吸声效果对比[35]; (c) DE 优化 AMs 局域共振板单胞结构前后的能带结构对比[36]

Fig. 4 Typical cases of AMs design using IOA method. (a) The sound absorption effect of single-layer honeycomb micro-perforated plate optimized by PSO is compared with that before optimization[33]; (b) Comparison of sound absorption effects before and after CS optimization of multiple parallel hexagonal helmholtz resonators[35]; (c) Comparison of energy band structure before and after DE optimization of AMs local resonance plate unit cell structure[36]

的单胞参数进行优化，优化后的单胞结构拥有更好的归一化带宽，从而拓宽了减振降噪的频带范围，优化前后的对比如图 4(c) 所示。

目前，众多 IOA 方法中，GA 被应用最多[37-40]，大量国内外研究学者通过 GA 实现对不同类型的 AMs 的优化设计。在对空间卷曲型 AMs 的优化设计中，Gao 等[41] 使用 GA 对具有多个迷宫式单元格结构的吸声器的几何形状进行优化设计，优化后的声吸收器厚度小于 1/25 波长，具有宽带吸声和广角吸声功能，如图 5(a) 所示。顾等[42] 提出了一种基于卷曲空间共振器的通风型空气声吸收体，基于环形 AMs 的吸声计算方法，引入 GA 对结构参数进行优化，以 30 mm 的厚度在 303 Hz 处实现了 93% 以上的深度亚波长吸收。另外，GA 还被大量应用于空腔共振型 AMs 的优化设计，任等[43] 提出了膜腔耦合式 AMs，并基于传递矩阵法，采用 GA 对纯空腔型多层膜腔结构、复合型多层膜腔耦合式结构和直通孔膜腔结构分别进行优化设计，保证了三种结构的高效吸声和宽带吸声。Lv 等[44] 设计出由两个矩形亥姆霍兹共振器组成的声滤波器结构，并通过 GA 在保持体积不变的条件下对亥姆霍兹共振器的形状进行优化，得到最优声滤波器结构。仿真结果表明，最优亥姆霍兹共振器的共振频率比原矩形结构降低了约 10%，传输损耗曲线明显向低频移动，具有最优声滤波器结构的低频滤波的性能显著提高，如图 5(b) 所示。

基于数据驱动的 ML 算法，在复杂材料的结构优化问题中占据一定地位[45-47]。还有研究者们选择将 ML 中的强化学习与 IOA 方法相结合，来搜索最优的 AMs 结构参数；在此过程中，强化学习为 IOA 提供高性能的预测模型，IOA 则用于优化 AMs 结构参数。

Wu 等[48] 提出两个 ML 模型用于一维周期性和非周期性 AMs 的优化设计。对于周期性超材料，他们将强化学习应用于对一维双原子和六原子晶格的设计。相比于 GA，这种方法在寻找近最优解时能够降低计算成本，如图 6(a) 所示。对于非周期性超材料，他们提出了一种基于神经网络的方法，先通过神经网络预测超材料的动态响应，再由标准优化算法实现超材料设计。Shah 等[49,50] 提出了一种使用强化学习算法来抑制声散射的半解析方法，通过优化水中圆柱散射体的设计参数（包括位置、

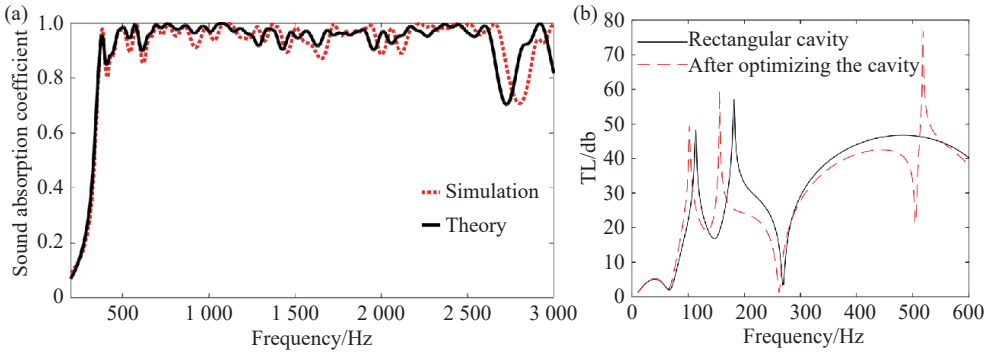

图 5　利用 GA 进行结构优化设计后的 AMs 的性能。(a) GA 优化后的迷宫式吸声器结构的吸声效果[41]; (b) GA 优化设计声滤波器结构前后的传输损失曲线对比[44]

Fig. 5 The performance of AMs after the structure optimization by GA. (a) The sound absorption effect of the labyrinth absorber structure optimized by GA[41]; (b) Comparison of transmission loss curves before and after GA optimization design of acoustic filter structure[44]

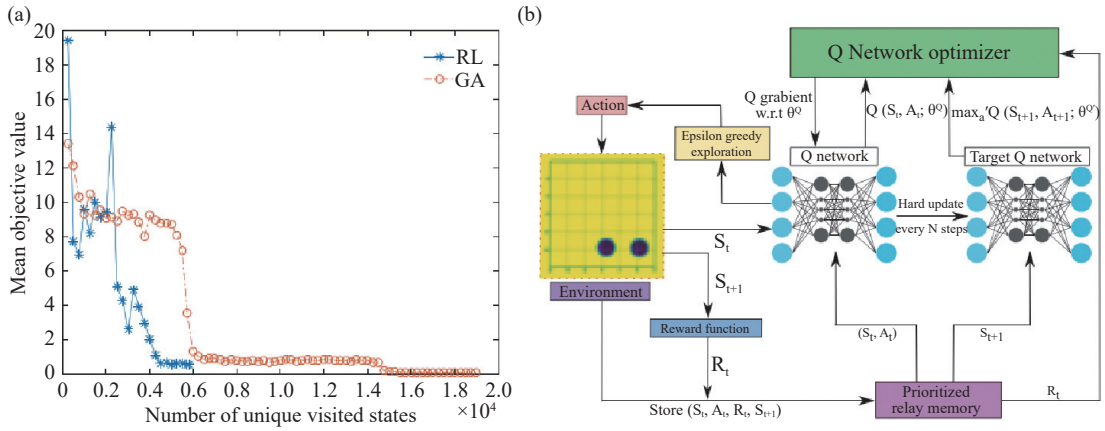

图 6　强化学习与 IOA 结合实现 AMs 的结构优化。(a) 强化学习与 GA 优化效果对比[48]; (b) 双深度 Q 学习网络与环境的交互示意图[50]

Fig. 6 Reinforcement learning and IOA combined to achieve structural optimization of AMs. (a) Comparison of optimization effects of Reinforcement learning and GA[48]; (b) Schematic diagram of interaction between dual-deep Q learning network and environment[50]

半径)来发现超材料的最佳设计, 以实现最小化散射效应。该研究使用了双深度 Q 学习网络和深度确定性策略梯度算法, 如图 6(b) 所示。与使用 fmincon 函数的先进优化算法相比, 强化学习算法的设计表现良好。

2.2　多目标优化

AMs 的设计问题可能会涉及多个且相互冲突的优化目标, 研究者们需要巧妙地对各优化目标进行平衡, 以确保设计方案在满足所有关键性能要求的同时, 能够实现整体性能的最优化。针对这种需求, 研究者们通常采用 NSGA-II 和多目标 PSO (Multi-objective PSO, MOPSO)来解决 AMs 的多目标优化问题。

例如, 和等[51] 利用拉丁超立方(LHS)采样和支持向量机构造代理模型, 结合 NSGA-II 算法对一种声学黑洞结构的结构参数进行了多目标优化, 优化目标为轻量化设计与隔声性能提升。与在之前的工作中提出的 PSO 和胞映射的混合优化算法相比, 该算法在保持与胞映射算法所得最优解高度一致的基础上, 大幅缩短了优化时间, 对比结果如图 7 所示。同样地, Peng 等[52] 聚焦于低频噪声(100-200 Hz)提出了一种膜型 AMs, 系统研究了膜参数(材料属性、厚度、边长和张力)和质量块参数(材料属性、位置、高度和半径)对 AMs 隔音性能的影响; 在此基础上, 基于 Kriging 和 NSGA-II 算法对其进行多目标优化设计, 成功设计出具有特定隔音频率和带宽的 AMs 结构。还有研究者[53] 将 MOPSO 应

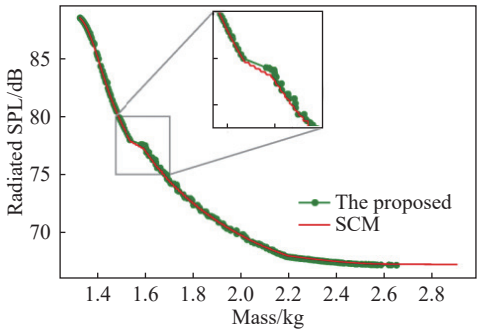

图 7 数据驱动算法与胞映射算法的帕累托前沿对比[51]

Fig. 7 Comparison of Pareto front between data-driven algorithm and cell mapping algorithm[51]

用于膜式 AMs 的轻量化设计，实验表明优化后结构的平均吸声系数比优化前增加了 22.2%，且总重量轻了 25.9%。

表 1 为不同的 IOA 方法在 AMs 结构优化中的表现对比。IOA 能有效处理复杂的优化问题，在 AMs 结构优化领域中展现出显著优势。然而，通过分析文献报道情况发现，GA 在 AMs 结构优化领域的应用和研究更为广泛，是该领域中更为成熟和可信的优化算法；而 PSO、CS、DE 等算法虽然各有特点，但在实际应用中的使用频次相对较少。究其原因，一方面，算法性能受收敛速度影响，如 PSO 在前期收敛太快，后期收敛慢，就可能导致局部最优，因此限制了其在 AMs 结构优化领域的应用；另一方面，GA 研究历史较长，形成了广泛的应用基础，进一步推动了 GA 在该领域的主导地位。而 CS 和 DE 的研究起步相对较晚，这也导致了相关研究的积累和推广不足。

表 1 AMs 结构优化中的典型 IOA 方法总结

Table1 Summary of typical IOA methods in AMs structural optimization.

IOA方法	更新机制	收敛速度	全局搜索能力	鲁棒性	适用场景
PSO	跟踪个体最优和全局最优位置	初期快，后期慢	中等	中等	高维连续优化、多目标优化
CS	寄生繁殖和莱维飞行策略	中等	强	较高	多峰/离散问题、复杂约束场景
GA	选择、交叉和变异	中等	较强	高	多峰/离散问题、复杂约束场景、多目标优化
DE	差分变异和交叉	较快	较强	高	高维连续优化

3 基于 AI 技术的 AMs 逆向设计

3.1 基于神经网络的 AMs 逆向设计

随着 AI 技术在 AMs 设计领域的深入应用，声学结构日趋复杂，设计参数维度显著增加，导致基于 IOA 方法的特定 AMs 结构设计时间呈指数级增长，逐渐难以满足实际需求。如何在较短的设计周期内获得满足实际应用需求的结构参数，是 AMs 设计应用中值得深入研究的问题。

大多数研究团队利用 DNN 构建前向和后向网络，以类似自编码器的形式组成逆向设计框架[54-63]，如图 8(a) 所示。例如，Zhang 等[58] 将目标

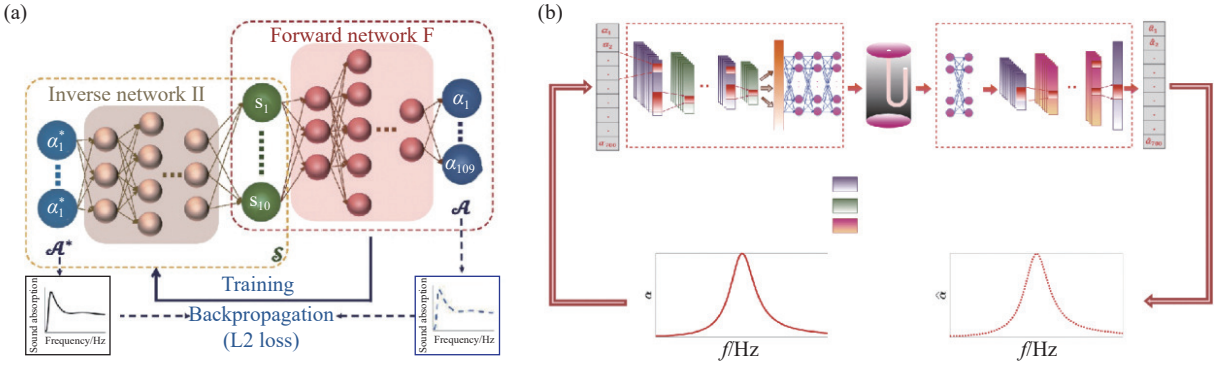

图 8 逆向设计框架。(a) 基于 DNN 的逆向设计框架[58]；(b) 基于一维 CNN 的逆向设计方案[66]

Fig. 8 Architecture of the inverse design framework. (a) Reverse design framework based on DNN[58]. (b) Reverse design scheme based on one-dimensional CNN[66]

吸声曲线作为输入, 并输出满足吸收曲线的 AMs 结构, 通过前向网络评估其性能。经过训练的前向网络能够以高精度和良好的泛化能力预测超出训练数据集范围的结构性能, 而反向网络则能够自主地采用超出原有范围的结构参数进行性能优化。

面对图像和空间数据时, 研究者在类似图 8(a) 的逆向设计框架基础上, 普遍采用两条 CNN 网络建立属性与结构之间的相互映射关系[64,65]。Mahesh 等[66,67] 提出了一种基于亥姆霍兹共振器的新型低频融合吸声器, 并采用一维 CNN 进一步构建了具有前向和后向连接的逆向设计方案, 如图 8(b) 所示。相比于使用 DNN 的逆向设计模型, 他们提出的模型具有更高的精度。当然, 适用于 AMs 逆向设计框架的神经网络不仅限于此。Oddiraju 等[68] 提出了一个使用可逆神经网络进行声学亚结构逆向设计的框架: 通过训练一个模型, 实现了周期性和非周期性声子结构的频率响应建模。该模型能够前向预测高保真样本, 并学习具有保证可逆性的逆向映射。

3.2　基于生成式模型的 AMs 逆向设计

针对具有复杂期望响应的结构逆向设计, 人们提出了与先前的逆向设计框架完全不同的深度生成模型。自经过多年对发展, 深度生成技术不断演变, 并应用于多种应用, 如光学隐身斗篷的设计[69] 等。例如, Wang 等[70] 提出了一种概率生成网络模型(如图 9 所示), 以揭示 AMs 结构与光谱响应之间的隐含关系, 并应用于声学吸收器的按需逆向设计。Gurbuz等[71] 开发了一种基于 CGAN 设计 AMs 的方法, 他们使用随机算法生成由流体元素和固体元素组成的单元格的二进制图像, 并利用有限元方法来获得传输损失谱。通过训练 CGAN 来捕捉传输损失谱与单元几何之间的潜在关系, 实现了对所需隔音结构的逆向设计。

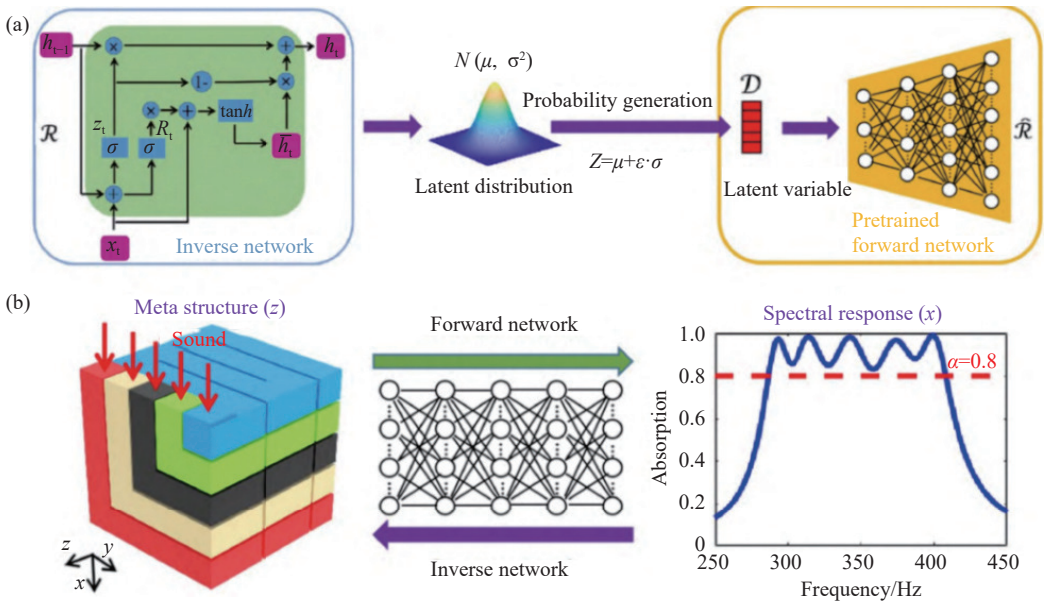

图 9　用于吸声器的按需逆向设计模型[70]。(a) 概率生成模型; (b) 声学磁立方体吸收器及其光谱响应示意图

Fig. 9　On-demand reverse design model for absorber[70]. (a) probabilistic generative model; (b) Schematic diagram of acoustic magic cube absorber and its spectral response

4　小结与展望

随着 AMs 结构的日益多样化和复杂化, 传统设计方法已无法满足实际需求。而 AI 技术的发展在 AMs 智能设计领域展现了巨大的应用潜力。本文介绍了以 ML 和 IOA 为代表的应用于 AMs 智能设计的 AI 技术的分类与发展, 同时阐述了这些技术在 AMs 智能设计领域中从结构优化到逆向设计的代表性应用研究。与此同时, 尽管针对 AMs 智能设计的研究已有不少并且取得了较大进展, 但现有研究仍然面临以下关键挑战:

1)数据稀缺性与质量瓶颈

随着 AMs 结构复杂性的提高, 高质量 AMs 数

据的获取变得更加困难，COMSOL 多物理场模拟耗时且计算资源密集，导致“结构-性能”数据集的规模受限，制约了监督学习的泛化能力。而实验数据的获取不仅成本高，实验中的噪声泄漏和设备误差都有可能导致数据标签失真，从而影响模型的可靠性。

2）计算效率与资源限制

大部分并联排列的 AMs 结构参数涉及数十至数百维变量，导致 IOA 方法（如 GA）在高维空间中的计算复杂度呈指数增长，单次优化迭代就可能耗时数小时。而在逆向设计中，ML 技术（如 CNN、CGAN）可能需要高性能 GPU 集群来进行训练，对硬件资源要求极高。

3）多物理场耦合建模的复杂性

现有 ML 技术难以有效捕捉声-结构、声-热等多物理场的耦合效应，可能导致优化或逆向设计结果在复杂工况下失效。

4）物理规律嵌入不足

现有的大部分逆向设计模型依赖于纯数据驱动，这可能违反基本物理约束，因而需通过混合建模（如物理引导损失函数）来平衡数据驱动与机理驱动。

为突破上述瓶颈，未来研究可通过结合迁移学习（如预训练物理仿真模型）来扩充数据集，以缓解数据稀缺性；通过研究更高效的模型架构和训练算法，来减少对计算资源对需求，或采用在线学习策略来动态更新模型，以减少重复训练时间；开发嵌入物理方程的混合 AI 架构（如 PINN-Transformer），增强跨尺度耦合预测能力。

展望未来，AMs 智能设计领域将着力攻克现有技术面临的瓶颈，推动其向更高效、更精准、更具解释性的方向发展，为相关领域的科研和工程应用带来深远影响。

参考文献：

[1] Liu N X, Hu K G, Huang L G, et al. An elastic metamaterial with simultaneously negative mass density and bulk modulus[J]. Applied Physics Letters, 2011, 98(25): 251907.

[2] 陈彪, 孔祥希, 陈长征. 宽频带薄膜型声学超材料隔声性能研究 [J]. 噪声与振动控制, 2024(5): 62-68.

[3] Zaremanesh M, Bahrami A. Two-dimensional honeycomb lattice structure for underwater acoustic cloaking using pentamode materials[J]. Physica Scripta, 2024, 99(01): 015946.

[4] 孟德世, 李丽君, 李敏. 声学超材料的结构设计概述 [J]. 功能材料与器件学报, 2021, 27(2): 67-76.

[5] 彭浩然, 胡贵华. 基于物理信息深度学习算法的 Flame D 热流场重构研究 [J]. 华东理工大学学报：自然科学版, 2024(6): 878-887.

[6] 陈华, 曲益明, 吴文豪, 等. 低功耗人工智能计算系统研究进展综述 [J]. 功能材料与器件学报, 2024(6): 300-309.

[7] 谭天晔, 林博. 基于人工智能和微流控液滴芯片的数字 PCR 芯片识别系统的研究 [J]. 功能材料与器件学报, 2024(6): 341-348.

[8] Liu W, Xu G, Fan W, et al. Machine-Learning-Based Characterization and Inverse Design of Metamaterials[J]. Materials, 2024, 17(14): 3512.

[9] Farajollahi A, Fakhrabadi S M M. Prediction and inverse design of bandgaps in acoustic metamaterials using deep learning and metaheuristic optimization techniques[J]. The European Physical Journal Plus, 2025, 140(3): 213.

[10] Mcculloch W. S, Pitts W. A logical calculus of the ideas immanent in nervous activity[J]. Bulletin of Mathematical Biology, 1990, 52: 99-115.

[11] Lecun Y, Bottou L. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.

[12] He K, Zhang X Y, Ren S Q, et al. Deep Residual Learning for Image Recognition [C]. Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), USA, 2016: 770-778.

[13] Hinton G E, Zemel R S. AutoEncoders, Minimum Description Length and Helmholtz Free Energy[J]. Advances in Neural Information Processing Systems, 1993, 6(1): 3-10.

[14] Kingma D P, Welling M. An Introduction to Variational Autoencoders[J]. Foundations and Trends® in Machine Learning, 2019, 12(4): 307-392.

[15] Goodfellow I, Pouget-abadie J, Mirza M, et al. Generative adversarial networks[J]. Communications of the ACM, 2020, 63(11): 139-144.

[16] Mirza M, Osindero S. Conditional Generative Adversarial Nets [J]. Computer Science, 2014: 2672-2680.

[17] Wang Z , Jeong H, Gan Y, et al. Pore-scale modeling of multiphase flow in porous media using a conditional generative adversarial network (cGAN) [J]. Physics of Fluids, 2022, 34(12): 123325.

[18] Kaelbling L P, Littman M L. Moore Reinforcement Learning: A Survey[J]. Journal of Artificial Intelligence Research,

1996, 4: 237-285.

[19] Mnih V, Kavukcuoglu K, Silver D, et al. Human-level control through deep reinforcement learning[J]. Nature, 2015, 518(7540): 529-533.

[20] 鲜勇, 郭靖, 任乐亮, 等. 无人机航迹规划智能算法研究综述 [J]. 火箭军工程大学学报, 2025, 39(01): 106-121.

[21] Vangelatos Z, Sheikh H M, Marcus P S, et al. Strength through defects: A novel Bayesian approach for the optimization of architected materials[J]. Science Advances, 2021, 7(41): eabk2218.

[22] Palanisamy S, Rubini S S, Khalaf I O, et al. Multi-objective hybrid split-ring resonator and electromagnetic bandgap structure-based fractal antennas using hybrid metaheuristic framework for wireless applications[J]. Scientific Reports, 2024, 14(1): 3288-3288.

[23] Meier T, Li R, Mavrikos S, et al. Obtaining auxetic and isotropic metamaterials in counterintuitive design spaces: an automated optimization approach and experimental characterization[J]. NPJ Computational Materials, 2024, 10(1): 3.

[24] Bushra A, Arafat A. Genetic algorithms: theory, genetic operators, solutions, and applications[J]. Evolutionary Intelligence, 2023, 17(3): 1245-1256.

[25] Storn R, Price K. Differential evolution: a simple and efficient heuristic for global optimization over continuous spaces[J]. Journal Global Optimization, 1997, 11(4): 341-359.

[26] 陈霞. 智能优化算法在证券投资组合中的应用研究 [D]. 郑州: 华北水利水电大学, 2019.

[27] 齐铖, 谢军伟, 王雪, 等. 基于精英引导的社会学习粒子群优化算法 [J]. 西北工业大学学报, 2024, 42(05): 948-958.

[28] Tian Y, Zhang D, Zhang H, et al. An improved cuckoo search algorithm for global optimization[J]. Cluster Computing, 2024, 27(6): 8595-8619.

[29] Huang S X, Lin N, Wang Z P, et al. A novel data-driven method for online parameter identification of an electrochemical model based on cuckoo search and particle swarm optimization algorithm[J]. Journal of Power Sources, 2024, 601: 234261.

[30] 黄蓓. 基于优化算法的声学超材料单元及器件设计 [D]. 徐州: 东南大学, 2018.

[31] Gao N S, Wang B Z, Lu K, et al. Teaching-learning-based optimization of an ultra-broadband parallel sound absorber[J]. Applied Acoustics, 2021, 178: 107969.

[32] Chen A, Xu Z X, Zheng B, et al. Machine learning-assisted low-frequency and broadband sound absorber with coherently coupled weak resonances[J]. Applied Physics Letters, 2022, 120(3): 033501.

[33] Yan S L, Wu J W, Chen J, et al. Optimization design and analysis of honeycomb micro-perforated plate broadband sound absorber[J]. Applied Acoustics, 2022, 186: 108487.

[34] Yang F, Wang E S, Shen X M, et al. Optimal Design of Acoustic Metamaterial of Multiple Parallel Hexagonal Helmholtz Resonators by Combination of Finite Element Simulation and Cuckoo Search Algorithm[J]. Materials, 2022, 15(18): 6450.

[35] Cheng H X, Yang F, Shen X M, et al. Study on a Hexagonal Acoustic Metamaterial Cell of Multiple Parallel-Connection Resonators with Tunable Perforating Rate[J]. Materials, 2023, 16(15): 5378.

[36] 中国船舶重工集团公司第七 0 三研究所, 哈尔滨工程大学. 一种声学超材料加筋板结构多目标优化设计方法, 中国, 202311259654.1[P], 2024-01-26.

[37] Dong H W, Zhao S D, Wei P J, et al. Systematic design and realization of double-negative acoustic metamaterials by topology optimization[J]. Acta Materialia, 2019, 172: 102-120.

[38] 廖琳, 向阳. 组合空腔声学覆盖层声学性能分析及其优化设计 [J]. 噪声与振动控制, 2022(2): 10-16.

[39] Lagarrigue C, Groby J P, Dazel O, et al. Design of metaporous supercells by genetic algorithm for absorption optimization on a wide frequency band[J]. Applied Acoustics, 2016, 102: 49-54.

[40] 高兆瑞, 李铮, 姜永烽, 等. 基于人工神经网络的共振吸声超材料声学性能快速预测及结构优化设计 [J]. 应用数学和力学, 2024, 45(08): 1058-1069.

[41] Gao Y X, Lin Y P, Zhu Y F, et al. Broadband thin sound absorber based on hybrid labyrinthine metastructures with optimally designed parameters[J]. Scientific Reports, 2020, 10(1): 10705.

[42] 顾页. 低频超材料声吸收体的优化设计 [D]. 南京: 南京大学, 2021.

[43] 任状. 膜腔耦合式声学超材料结构设计及其吸声性能研究 [D]. 哈尔滨: 哈尔滨工业大学, 2021.

[44] Lv C H, Wang X M, Mei Y L. Optimization Method of Acoustic Filter Structures Composed of Helmholtz Resonators Based on Genetic Algorithm[J]. Journal of Physics: Conference Series, 2023, 2468(1): 012019.

[45] Bacigalupo A, Gnecco G, Lepidi M, et al. Machine-Learning Techniques for the Optimal Design of Acoustic Metamaterials[J]. Journal of Optimization Theory and Applications, 2019, 187(3): 1-24. .

[46] Corbin R, Jeffrey C, Alex K. Convolutional neural network driven design optimization of acoustic metamaterial microstructures[J]. The Journal of the Acoustical Society of America, 2019, 146(4): 2830.

[47] 陈思危, 姚敦辉, 姚凌云. 圆柱壳声学超材料带隙的机器学习优化设计 [J]. 噪声与振动控制, 2024(4): 70-76.

[48] Wu R T, Liu T W, Jahanshahi R M, et al. Design of one-dimensional acoustic metamaterials using machine learning and cell concatenation [J]. Structural and Multidisciplinary Optimization, 2021, 63(5): 1-25.

[49] Shah T, Zhuo L W, Lai P, et al. Reinforcement learning applied to metamaterial design[J]. The Journal of the Acoustical Society of America, 2021, 150(1): 321-321.

[50] Shah T, Amirkulova F. Deep reinforcement learning-based framework for the design of broadband acoustic metamaterials[J]. The Journal of the Acoustical Society of America, 2022, 152(4): A170.

[51] 和梦欣. 基于多目标优化的结构减振与降噪研究 [D]. 天津: 天津大学, 2021.

[52] Peng W, Zhang J, Shi M, et al. Low-frequency sound insulation optimisation design of membrane-type acoustic metamaterials based on Kriging surrogate model[J]. Materials & Design, 2023, 225: 111491.

[53] Peng L Q, Bao B. Optimized membrane-type acoustic metamaterials for alleviating engineering fatigue damage via lightweight optimization[J]. Engineering Structures, 2023, 292: 116550.

[54] Cheng B Z, Wang M, Gao N S, et al. Machine learning inversion design and application verification of a broadband acoustic filtering structure[J]. Applied Acoustics, 2022, 187: 108522.

[55] Liu T W, Chan C T, Wu R T. Deep-Learning-Based Acoustic Metamaterial Design for Attenuating Structure-Borne Noise in Auditory Frequency Bands[J]. Materials, 2023, 16(5): 1879.

[56] Luo Y T, Li P, Li D T, et al. Probability-Density-Based Deep Learning Paradigm for the Fuzzy Design of Functional Metastructures[J]. Research, 2020, 2020: 1-11.

[57] 裴浩冰. 基于深度学习的微穿孔板结构参数设计 [D]. 长沙: 湖南大学, 2021.

[58] Zhang H G, Liu J W, Ma W T, et al. Learning to inversely design acoustic metamaterials for enhanced performance[J]. Acta Mechanica Sinica, 2023, 39(7): 722426.

[59] Hou Z Y, Tang T T, Shen J, et al. Prediction Network of Metamaterial with Split Ring Resonator Based on Deep Learning[J]. Nanoscale Research Letters, 2020, 15(1): 83.

[60] Li Y G, Chen D K, Li X B, et al. Vibration transmission characteristic prediction and structure inverse design of acoustic metamaterial beams based on deep learning[J]. Journal of Vibration and Control, 2024, 30(3-4): 807-821.

[61] Zhou Y, Ma L, Kang X, et al. Reverse design of broadband sound absorption structure based on deep learning method[J]. Scientific Reports, 2025, 15(1): 1946.

[62] Hamza B, Mahmoud A, Abdesselam B, et al. Design of acoustic absorbing metasurfaces using a data-driven approach[J]. Communications Materials, 2023, 4: 40.

[63] Li R C , Jiang Y T, Zou R R, et al. Design of ultra-thin underwater acoustic metasurface for broadband low-frequency diffuse reflection by deep neural networks[J]. Scientific Reports, 2022, 12(1): 12037.

[64] Liu L, Xie L X, Huang W C, et al. Broadband acoustic absorbing metamaterial via deep learning approach[J]. Applied Physics Letters, 2022, 120(25): 251701.

[65] Wu J H, Feng X X, Cai X, et al. A deep learning-based multi-fidelity optimization method for the design of acoustic metasurface[J]. Engineering with Computers, 2022, 39(5): 3421-3439.

[66] Mahesh K, Ranjith S K, Mini R S. Inverse design of a Helmholtz resonator based low-frequency acoustic absorber using deep neural network[J]. Journal of Applied Physics, 2021, 129(17): 174901.

[67] Mahesh K, Ranjith S. K, Mini R. S. A deep autoencoder based approach for the inverse design of an acoustic-absorber[J]. Engineering with Computers, 2023, 40(1): 279-300.

[68] Oddiraju M, Behjat A, Nouh M, et al. Inverse Design Framework With Invertible Neural Networks for Passive Vibration Suppression in Phononic Structures[J]. Journal of Mechanical Design, 2022, 144(2): 12.

[69] Pierre A D B, F. J O M. Successive training of a generative adversarial network for the design of an optical cloak[J]. OSA Continuum, 2021, 4(1): 87-95.

[70] Wang Z W, Chen A, Xu Z X, 等. On-demand inverse design of acoustic metamaterials using probabilistic generation network[J]. 中国科学: 物理学 力学 天文学: 英文版, 2023(2): 91-98.

[71] Gurbuz C, Kronowetter F, Dietz C, et al. Generative adversarial networks for the design of acoustic metamaterials[J]. The Journal of the Acoustical Society of America, 2021, 149(2): 1162-117.