中国光学（中英文） Chinese Optics 核心期刊

基于深度学习的Fano共振超材料设计

杨知虎 傅佳慧 张玉萍 张会云

Fano resonances design of metamaterials based on deep learning

YANG Zhi-hu, FU Jia-hui, ZHANG Yu-ping, ZHANG Hui-yun

引用本文:
杨知虎, 傅佳慧, 张玉萍, 张会云. 基于深度学习的Fano共振超材料设计[J]. 中国光学, 2023, 16(4): 816-823. doi: 10.37188/CO.2022-0208
YANG Zhi-hu, FU Jia-hui, ZHANG Yu-ping, ZHANG Hui-yun. Fano resonances design of metamaterials based on deep learning[J]. *Chinese Optics*, 2023, 16(4): 816-823. doi: 10.37188/CO.2022-0208

在线阅读 View online: https://doi.org/10.37188/CO.2022-0208

您可能感兴趣的其他文章

Articles you may be interested in

电环形谐振腔表面几何参数对太赫兹超材料吸收体性能的影响

Influence of the geometric parameters of the electrical ring resonator metasurface on the performance of metamaterial absorbers for terahertz applications

中国光学（中英文）. 2018, 11(1): 47 https://doi.org/10.3788/CO.20181101.0047

电磁编码超材料的理论与应用

Theory and application of coding metamaterials

中国光学（中英文）. 2017, 10(1): 1 https://doi.org/10.3788/CO.20171001.0001

基于小波神经网络的光纤陀螺误差补偿方法

A fiber optic gyro error compensation method based on wavelet neural network

中国光学（中英文）. 2018, 11(6): 1024 https://doi.org/10.3788/CO.20181106.1024

基于卷积神经网络的候选区域优化算法

Region proposal optimization algorithm based on convolutional neural networks

中国光学（中英文）. 2019, 12(6): 1348 https://doi.org/10.3788/CO.20191206.1348

太赫兹偏振测量系统及其应用

Polarization sensitive terahertz measurements and applications

中国光学（中英文）. 2017, 10(1): 98 https://doi.org/10.3788/CO.20171001.0098

变换光学透镜天线研究进展

Research progress of transformation optics lens antenna

中国光学（中英文）. 2017, 10(2): 164 https://doi.org/10.3788/CO.20172002.0164

文章编号 2097-1842(2023)04-0816-08

基于深度学习的 Fano 共振超材料设计

杨知虎，傅佳慧，张玉萍，张会云*
（山东科技大学 电子信息工程学院 青岛市太赫兹技术重点实验室，山东 青岛，266590）

摘要：本文提出了一种基于深度学习的超材料 Fano 共振设计方法，能够获得高 Q 共振的线宽、振幅和光谱位置特性。利用深度神经网络建立结构参数和透射谱曲线之间的映射，正向网络实现对透射谱的预测，逆向网络实现对高 Q 共振按需设计，设计过程中实现了低均方误差 (MSE)，训练集的均方误差为 0.007。与传统方法需要耗时的逐个数值模拟相比，深度学习设计方法大大简化了设计过程，实现了高效、快速的设计目标。对 Fano 共振的设计也可推广应用到其它类型的超材料的自动逆向设计，显著提高了更复杂的超材料设计的可行性。

关 键 词：超材料；神经网络；Fano 共振；逆向设计；深度学习
中图分类号：O436.3 **文献标志码：**A **doi:** 10.37188/CO.2022-0208

Fano resonances design of metamaterials based on deep learning

YANG Zhi-hu, FU Jia-hui, ZHANG Yu-ping, ZHANG Hui-yun*
(*Qingdao Key Laboratory of Terahertz Technology*, *College of Electronic and Information Engineering*, *Shandong University of Science and Technology*, *Qingdao* 266590, *China*)
* *Corresponding author*, *E-mail*: *sdust_thz*@126.*com*

Abstract: In this paper, a metamaterial Fano resonance design method based on deep learning is proposed to obtain high-quality factor (high-Q) resonances with desired characteristics, such as linewidth, amplitude, and spectral position.The deep neural network is used to establish the mapping between the structural parameters and the transmission spectrum curve. In the design, the forward network is used to predict the transmission spectrum, and the inverse network is used to achieve the on-demand design of high Q resonance. The low mean square error (MSE) is achieved in the design process, and the mean square error of the training set is 0.007. The results indicate that compared with the traditional design process, using deep learning to guide the design can achieve faster, more accurate, and more convenient purposes. The design of Fano resonance can also be extended to the automatic inverse design of other types of metamaterials, significantly improving the feasibility of more complex metamaterial designs.

Key words: metamaterials; neural networks; Fano resonance; reverse engineering; deep learning

收稿日期：2022-10-10；**修订日期：**2022-11-11
基金项目：国家自然科学基金（No. 61875106, No. 62105187）；山东省自然科学基金（No. ZR2021QF010）
Supported by National Natural Science Foundation of China (No. 61875106, No. 62105187); Natural Science Foundation of Shandong Province (No. ZR2021QF010)

1　引　言

1961 年, Fano U[1] 在其原子自电离态的量子力学机理的研究中, 发现了 Fano 共振现象。在原子系统中, 当分立的激发态能级与连续的激发态能级重叠时, 会发生相干耦合与干涉, 从而产生一种尖锐的非对称线型, 并且具有显著的局部电场增强效应。自从 Fedotov V A 等人[2] 首次观察到由不对称分裂环阵列组成的超材料(MMs)中的 Fano 共振以来, 近年来, MMs 和等离子纳米结构中的 Fano 共振特性引起了科研人员极大的兴趣[3-9]。Fano 共振在非线性光学、超快开关、生化传感器等领域具有潜在的应用价值[10-16]。但传统 Fano 共振超材料设计方法需要反复调整结构或材料参数并重新计算响应, 耗费时间和精力, 因此, 对自动寻优的优化算法的需求与日俱增。

在过去的一段时间里, 学者对人工智能中许多成熟的优化算法进行了超材料按需设计的尝试, 如遗传算法[17], 拓扑优化[18-21] 等。但这些算法有着依赖中间结果和全随机搜索的局限性, 因此, 少约束条件下实现逆向设计仍是个具有挑战性的课题。深度学习在众多工程与科学领域的发展突飞猛进[22-25]。用深度学习方法代替费力的数值模拟方法可以节省大量时间和精力。因此, 将深度学习与超材料的结构设计相结合是目前的一个热门研究方向。Ma W 等人[26] 利用双向神经网络实现了的三维手性超材料设计。Nadell C C 等人[27] 设计了一个深度神经网络, 其能够快速准确地预测全介电超表面。Xu L 等人[28] 设计了一种可以对介电纳米结构的线宽、振幅和光谱位置进行参数优化的深度学习方法, 该方法可进一步用于实现具有非常规散射响应的结构。Hou ZH Y 等人[29] 基于深度学习的超材料逆向设计, 提出了一种根据目标实现一对多的结构设计方法。Zhou X SH 等人[30] 使用深度学习方法建立超材料数据库, 实现超材料的快速设计和分析。原则上, 深度神经网络经过层宽度和网络深度的结合可以处理复杂的映射[31]。然而, 计算机的内存和计算能力等存在上限。通过对深度学习模型的调整可实现结构参数的优化, 关键是在生成训练数据和设计深度学习网络模型之间找到最佳平衡。

本文基于深度神经网络(DNN)提出了一种不对称开口环谐振器(ASRR)的设计方法, 可实现正向光谱预测和高 Q 共振的按需设计。神经网络的均方误差为 0.007, 使用该模型可以实现超材料的正向预测和逆向结构设计。深度学习方法可使超材料结构设计周期缩短到几天甚至几小时, 其设计速度是传统设计方法无法比拟的。此外, 该方法还具有良好的可扩展性, 通过建立相应数据集、调整超参数也可实现其他超材料功能器件的预测和按需设计。

2　材料与方法

ASRR 的 Fano 共振特性高度依赖于结构参数, 本文提出的深度学习设计方法可以建立 ASRR 结构参数与电磁响应之间的映射, 实现 ASRR 的正向光谱预测和以高 Q 共振为目标的按需设计。在本文中, 通过使用 DNN 来优化 ASRR 的几何参数(P、H、D、G、W), 以增强高 Q 共振。

2.1　模型构建

建立了一个仿真模型, 以验证所设计网络能够实现超材料结构逆向设计。本文采用的 ASRR 结构如图 1(a) 所示, 选择的结构参数变量如下: 铝环厚度 H、臂宽 W、周期性 P、间隙 G、不对称性 D(D 为间隙相对于谐振器中心垂直轴的偏移量, 以打破系统对称性)。当线偏振光束正入射超材料时, 通过改变结构变量, 可以得到不同结构下的波长透射曲线。铝环的尺寸固定为 40 μm, 电导率 σ 设置为 3.56×10^7 S/m, 衬底材料为硅, 折射率设置为 n=3.42, 厚度为 500 μm。利用 CST 仿真软件进行建模并使用频域求解器进行求解, 在 x 和 y 方向上设置单位单元边界条件, z 方向上为开放边界条件。仿真频段为 0.4~1.45 THz, 输出为对应结构 721 个频率点下的透射系数 S_{21}。

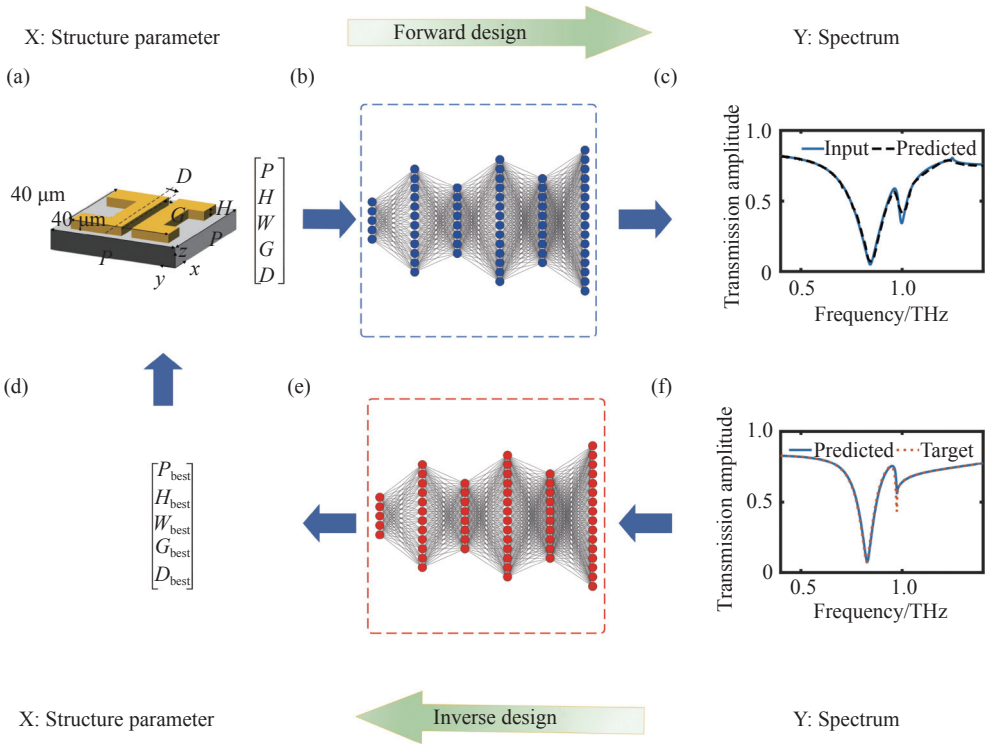

图 1 用于双向神经网络设计的框架示意图。(a)ASRR 的单位单元结构图；(b)正向神经网络图；(c)正向预测输出的透射谱；(d)逆向设计输出的最优参数；(e)逆向神经网络图；(f)逆向设计输入的透射谱

Fig. 1 Schematic diagram of the framework used for the bidirectional neural network design process. (a) The unit cell structure diagram of ASRR; (b) the forward neural network diagram; (c) transmission spectrum of the forward prediction output; (d) optimal parameters of the reverse design output; (e) inverse neural network diagram; (f) transmission spectrum of the inverse design input

2.2 数据集获取

神经网络训练需要足够数据，因此，需要获得不同结构超材料 Fano 共振相对应的传输光谱，但 CST 每次只能对一个结构进行仿真，对于大量的数据需求，单纯地使用 CST 进行建模费时费力。为了解决这个问题，本文利用 Matlab 编写程序来控制 CST 自动建模仿真并保存所需的数据。采样范围 $P\in[70, 125]$，间隔为 1 μm；$H\in[10, 15]$，间隔为 1 μm；$D\in[1, 3]$，间隔为 1 μm；$G\in[1, 3]$，间隔为 1 μm，$W\in[5, 7]$，间隔为 1 μm。56×6×3×3×3 为数据集取值的总个数，经过筛选去掉质量差、不适合参与训练的数据，最终获得 7500 个数据。其中 80% 作为训练集，20% 作为测试集，如表 1 所示。

表 1 训练神经网络的数据值

Tab. 1 Data values of training neural network (μm)

P	*H*	*W*	*G*	*D*
70	10	5	1	1
71	11	6	2	2
⋮	⋮	⋮	⋮	⋮
125	15	7	3	3

2.3 数据预处理

在神经网络训练过程中，较大输入值通常会引起较大的误差，为了减少神经网络中输入值与输出值的差异，保证结果的可靠性，需要对输入数据进行预处理。在正向网络中，光谱数据中不同频率点的透射率范围相同(均为 0 到 1)。然而，不同结构参数具有不同的取值范围。因此，在逆向网络中，预测结构参数也需要使用便于数据恢复的数据预处理方法。本文选择 Min-Max 归一化数据预处理方法，将所有原始输入数据 x_0 缩放到(0, 1)范围，如式(1)所示：

$$x=\frac{x_0-\min x_0}{\max x_0-\min x_0}\quad . \tag{1}$$

这种预处理方法不仅可以让不同维度间的特征在数值上有一定比较性，而且有助于恢复逆向预测数据[24]。

2.4　神经网络模型

如图 2 所示, 整个网络由全连接层组成, 上一层中的每个神经元以其自身的唯一权重和下一层中的所有神经元相连, 在信号正向传播期间, 每个神经元的输出由式(2)给出:

$$a_j^l = \sigma\left(\sum_k w_{jk}^l a_k^{l-1} + b_j^l\right) \quad . \tag{2}$$

记w_{jk}^l为第$l-1$层第k个神经元到第l层第j个神经元的权重, b_j^l为第l层第j个神经元的偏置, σ代表激活函数, a_j^l为第l层第j个神经元的输出。

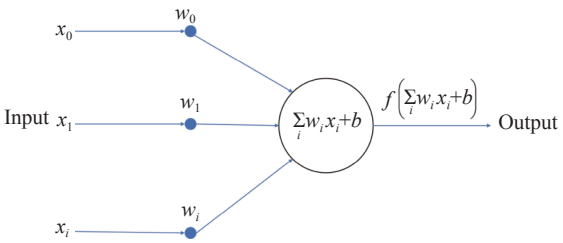

图 2　神经网络模型

Fig. 2　Neural network model

在神经网络中, 使用均方误差 (MSE) 损失函数作为神经网络训练的截止判据, 由式(3)给出:

$$L = \frac{1}{N}\sum_{i=1}^{N}(y_i - f(x_i))^2 \quad , \tag{3}$$

其中, N 代表训练过程中的样本数, y_i 是训练期间给出的标签值, 假设输入样本数据为 x, 模型输出结果表示为 $f(x)$, 损失函数用于计算 $f(x)$ 与样本实际标签值 y 之间的误差。

根据链式求导法则进行误差反向传播, 沿梯度最小方向将误差回传, 误差反向传播过程中使用了 Adam 优化算法。

考虑到 Sigmoid 激活函数在物理意义上最为接近生物神经元, 故选择 Sigmoid 函数作为激活函数, 由式(4)给出:

$$f(x) = \frac{1}{1+e^x} \quad . \tag{4}$$

Sigmoid 函数如图 3 所示。原始输入数据 x_0经过预处理缩放到 (0, 1) 区间, 而 Sigmoid 的输出是以 (0, 0.5) 为中心对称的 (0, 1) 区间, 是一个非常良好的阈值函数。这样, 有利于减轻神经网络的梯度消失, 使网络更容易收敛。另外, Sigmoid 函数的导数是其本身的函数, 从而节省了计算时间。

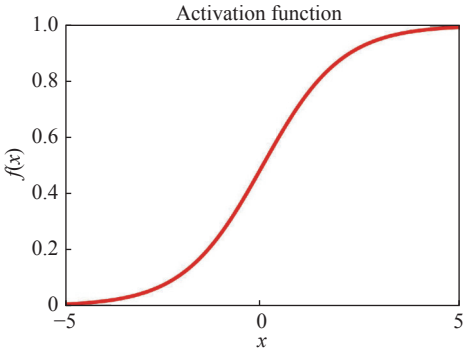

图 3　Sigmoid 激活函数

Fig. 3　Sigmoid activation function

本文采用的神经网络结构如图 4 所示, 其具有 4 个全连接层。经过训练与调试, 全连接层中神经元的个数分别为 90, 50, 110, 75。

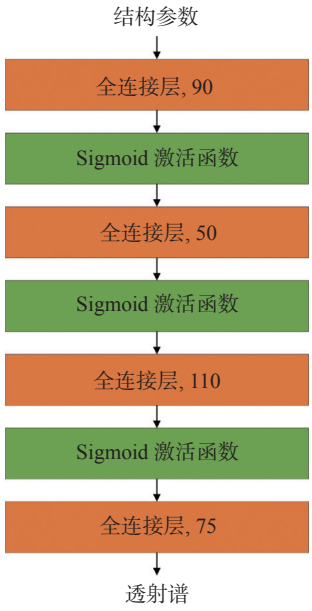

图 4　DNN 的结构参数

Fig. 4　Structural parameters of DNN

上述网络均在配备 AMD 4800U 处理器和 Radeon Graphics 显卡的计算机上运行。

3　结果与讨论

3.1　模型优化

损失函数是用来度量模型预测值与真实值差异程度的运算函数, 损失函数越小, 模型的预测效果和鲁棒性就越好。本文深度学习模型的 MSE 损失函数如图 5 所示, 经过一万次训练后, 验证集

的 MSE 损失函数可以降低到 0.000 17。本文提出的神经网络模型可以快速准确地预测任意 ASRR 结构参数的响应光谱，便于详尽研究所提出的 ASRR 结构的特性。

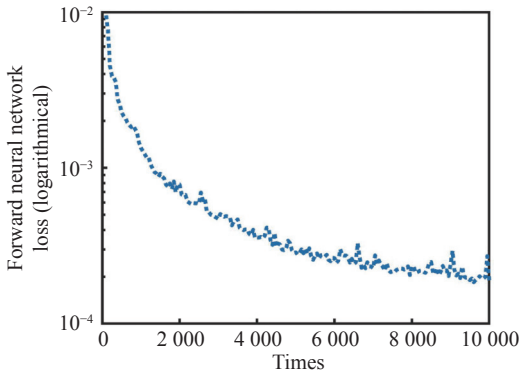

图 5　正向神经网络损失

Fig. 5　Forward neural network loss

将学习率设置为 0.015，对深度神经网络的网络层数进行选择，全连接层深度为 3、4、5 时对应的 MSE 损失函数如图 6（彩图见期刊电子版）所示，从图中可以看出，在 10 000 次训练中，三层神经网络的 MSE 损失函数收敛最差，四层神经网络和五层神经网络都有较好的收敛，但四层神经网络收敛更快且稳定性高于五层神经网络，因此本文深度学习模型的网络深度选择为四层。

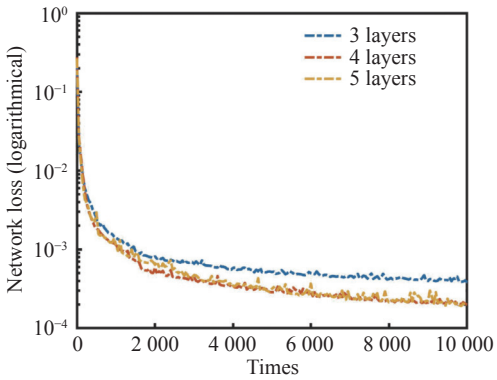

图 6　不同网络层数对损失函数的影响对比

Fig. 6　Comparison of the influence of different network layers on the loss function

3.2　正向预测

正向神经网络预测结果如图 7 所示，随机选取测试集中 6 组几何参数作为输入数据，得到了神经网络输出的透射光谱预测曲线（实线），为了增强预测结果的说服力，引入了给定结构的 CST 仿真结果（虚线）。从图中可以看出，神经网络的预测结果与仿真结果几乎完全吻合，充分证明了神经网络正向预测的准确性。

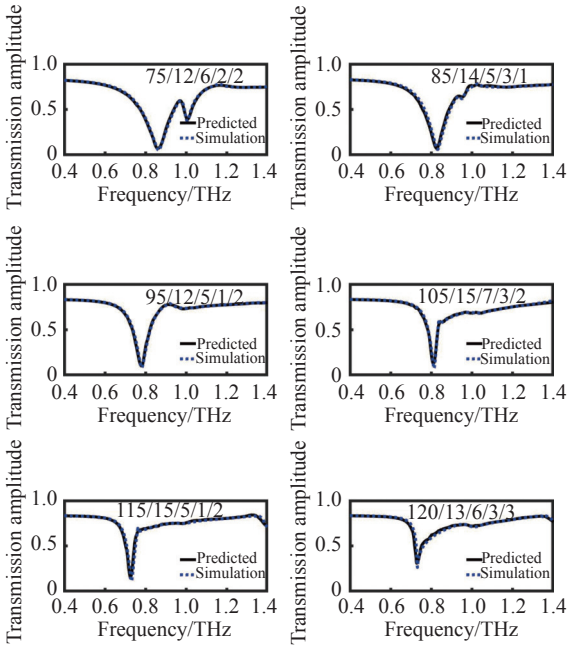

图 7　正向预测结果和数值模拟结果

Fig. 7　Forward prediction results and numerical simulation results

3.3　逆向设计

为了实现逆向网络的按需设计，需要对窄带宽曲线进行学习。

实验结果如图 8（彩图见期刊电子版）所示，

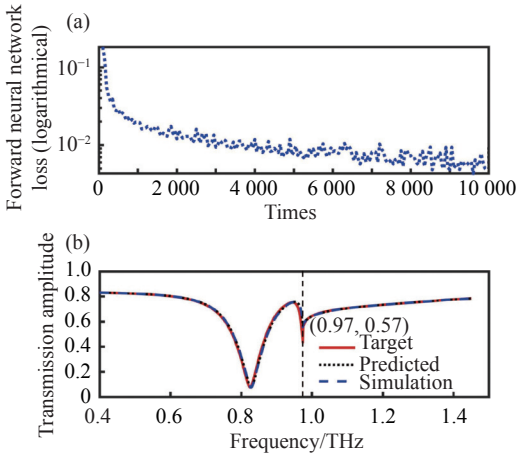

图 8　（a）逆向神经网络的模型训练损失演变。（b）逆向神经网络输出，CST 仿真结果和目标频谱比较

Fig. 8　(a) Evolution of model training loss for an inverse neural network. (b) Comparison of inverse neural network output, CST simulation results and target spectrum

与正向神经网络相比, 因大输入与小输出导致其逆向神经的 MSE 损耗更高。通过对逆向神经网络超参数进行重新调试, 调试后的超参数为 [150, 1 000, 200, 888], 获得的 MSE 如图 8(a)所示, 可以看出逆向神经网络的收敛效果很好。对逆向神经网络输入一个设计目标, 目标光谱曲线如图 8(b)中红色曲线所示, 网络输出的优化结构参数为 [90, 14, 6, 3,3]。

将得到的结构参数输入到正向预测网络中并将得到的预测曲线及 CST 仿真结果做对比, 如图 8(b)中黑色虚线和蓝色虚线所示, 可以看出两条曲线非常吻合。逆向神经网络对目标光谱的逆向设计结果误差为 0.007, 具有很高的设计精度。

根据设计目标优化后的 ASRR 结构参数如图 9 所示, [90, 14, 6, 3, 3] 分别代表优化后 ASRR 的周期性、铝环厚度、谐振臂宽、间隙及非对称性。

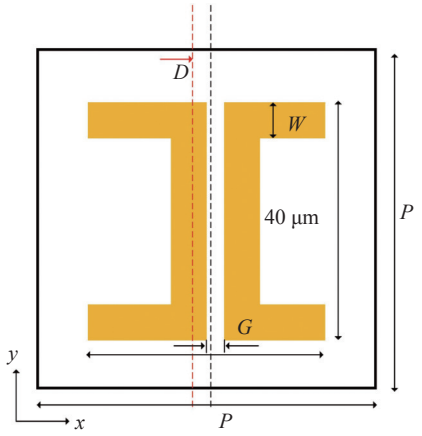

图 9　优化后的模型俯视图。沿 y 轴入射, 周期性 P=90 μm, 铝环厚度 H=14 μm, 铝环臂宽 W=6 μm, 间隙 G=3 μm, 非对称性 D=3 μm

Fig. 9　Top view of the optimized model. Incident along the y-axis, periodicity P=90 μm. Aluminum ring thickness H=14 μm, aluminum ring arm width W=6 μm, gap G=3 μm, asymmetric tuning factor D=3 μm

3.4　优化结构分析

窄共振特征由Q因子定量描述, 由$Q=\omega_0/\Delta\omega$估计, 其中ω_0是共振频率, $\Delta\omega$是共振的半峰全宽(FWHM)。Fano 共振的明显特征是具有高Q因子, 特别地, 当 Fano 共振具有低强度(透射率)时, 高强度共振表现不明显。因此, 为更准确描述 Fano 共振, 本文引入了品质因数(FoM), $FoM=Q\times I$(Q是品质因子, I是共振的透射强度)。根据计算, 优化后的 ASRR 结构在 0.97 THz 处的共振深度为 0.57, Q 值为 60, 则FoM= 33。

通过调整晶格的结构参数 P, 可以控制模式频率f_{LM}的位置, 实现耦合验证。在正入射下, f_{LM}被定义为:

$$f_{\mathrm{LM}}=\frac{c}{np}\sqrt{i^2+j^2}\quad , \tag{5}$$

其中c是真空中的光速, n是晶格模式传播的介质折射率, p是 ASRR 晶格的周期性, (i, j)是定义晶格模式顺序的非负整数[32]。

在本文中, 在超材料硅衬底中传播的一阶晶格模式 FOLM(0,1)与 ASRR 的 Fano 共振发生相互作用。在本文考虑的频率范围内, 超材料不会在空气中发生衍射。由于 FOLM 在 ASRR 表面捕获了太赫兹能量, 因此加强了超材料的共振近场限制, 经计算优化后的周期性 P_{best} = 90 μm 符合一阶晶格模式耦合时的周期性, 同时与优化后的其他结构参数共同实现了高 Q 因子的 Fano 共振。

图 10(彩图见期刊电子版)显示了结构参数分别为 [70, 14, 6, 3, 3] 和 [90, 14, 6, 3, 3] 时的 FOLM 失配和匹配的 Fano 共振的电磁场分布。

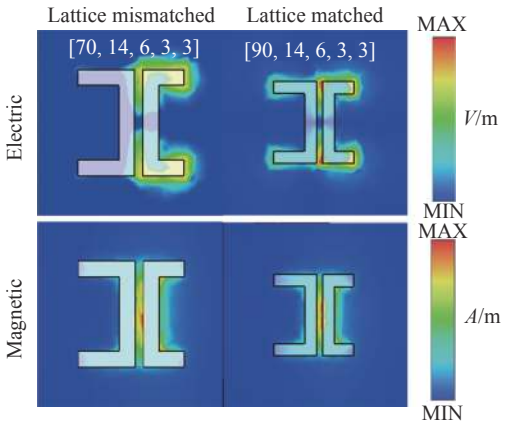

图 10　在 0.97 THz 处, 结构参数为 [70,14,6,3,3] 晶格失配和 [90,14,6,3,3] 晶格匹配条件下, Fano 的近场总电场和磁场振幅|E|和|B|。同一场的所有贴图共享相同范围的颜色比例。

Fig. 10　The near-field total electric and magnetic field amplitude, |E| and |B| of the Fano resonance under the conditions of the structural parameters of [70, 14, 6, 3, 3] lattice mismatched and [90, 14, 6, 3, 3] lattice matched. All maps of the same field share a color scale with the same range

在晶格匹配条件下，可以观察到左谐振器臂端部和沿间隙的电场增强。由于 Fano 共振产生于电感耦合的谐振器臂，因此可看到间隙中的磁场的强烈增强。由于 Fano共振耦合到晶格模式，这种增强推动了间隙中受限光的增强，FOLM 增强场证明了辐射损失的降低，证明存在高 Q 晶格匹配超材料 Fano 共振。同时说明通过深度学习可以对 Fano 共振超材料 ASRR 结构进行逆向设计。

4 结 论

本文从理论上证明可以通过建立深度神经网络方法设计 Fano 共振超材料结构，神经网络能够通过调整网络参数来创建各种效果。基于深度学习优化结构参数的设计方法，实现了以高 Q 共振为目标的超材料结构的逆向设计，正向网络实现了对结构参数的光谱预测，逆向网络可以根据输入的目标透射光谱预测高 Q 共振。结果表明，正向网络在预测方面具有较高的精度，逆向网络可以解决按需设计问题。还分析了超材料结构的 Fano 共振机制。利用深度学习来优化超材料的结构设计，可以自动获得更准确的超材料结构参数，和传统设计方法相比节约了设计时间，提高了效率。深度学习设计方法对纳米光子学的理论发展也有极其重要的价值和意义。

参考文献：

[1] FANO U. Effects of configuration interaction on intensities and phase shifts[J]. *Physical Review*, 1961, 124(6): 1866-1878.

[2] FEDOTOV V A, ROSE M, PROSVIRNIN S L, *et al*.. Sharp trapped-mode resonances in planar metamaterials with a broken structural symmetry[J]. *Physical Review Letters*, 2007, 99(14): 147401.

[3] HAO F, SONNEFRAUD Y, VAN DORPE P, *et al*.. Symmetry breaking in plasmonic nanocavities: subradiant LSPR sensing and a tunable Fano resonance[J]. *Nano Letters*, 2008, 8(11): 3983-3988.

[4] RAHMANI M, LUK'YANCHUK B, HONG M H. Fano resonance in novel plasmonic nanostructures[J]. *Laser & Photonics Reviews*, 2013, 7(3): 329-349.

[5] KUZNETSOV A I, MIROSHNICHENKO A E, BRONGERSMA M L, *et al*.. Optically resonant dielectric nanostructures[J]. *Science*, 2016, 354(6314): eaag2472.

[6] CHEN J J, GAN F Y, WANG Y J, *et al*.. Plasmonic sensing and modulation based on Fano resonances[J]. *Advanced Optical Materials*, 2018, 6(9): 1701152.

[7] LIMONOV M F. Fano resonance for applications[J]. *Advances in Optics and Photonics*, 2021, 13(3): 703-771.

[8] 付娆, 李子乐, 郑国兴. 超构表面的振幅调控及其功能器件研究进展[J]. 中国光学, 2021, 14(4): 886-899.
FU R, LI Z L, ZHENG G X. Research development of amplitude-modulated metasurfaces and their functional devices[J]. *Chinese Optics*, 2021, 14(4): 886-899. (in Chinese)

[9] 林婧, 李琦, 邱孟, 等. 人工原子间耦合: 超构表面调控电磁波的新自由度[J]. 中国光学, 2021, 14(4): 717-735.
LIN J, LI Q, QIU M, *et al*.. Coupling between Meta-atoms: a new degree of freedom in metasurfaces manipulating electromagnetic waves[J]. *Chinese Optics*, 2021, 14(4): 717-735. (in Chinese)

[10] 王锋, 刘星辰, 王政平, 等. 基于手性超材料的太赫兹波非对称传输的研究[J]. 哈尔滨工程大学学报, 2015, 36(12): 1638-1641.
WANG F, LIU X CH, WANG ZH P, *et al*.. A study of asymmetric transmission of terahertz waves based on chiral metamaterials[J]. *Journal of Harbin Engineering University*, 2015, 36(12): 1638-1641. (in Chinese)

[11] MIROSHNICHENKO A E, FLACH S, KIVSHAR Y S. Fano resonances in nanoscale structures[J]. *Reviews of Modern Physics*, 2010, 82(3): 2257-2298.

[12] LIU SH D, YANG ZH, LIU R P, *et al*.. High sensitivity localized surface plasmon resonance sensing using a double split nanoring cavity[J]. *The Journal of Physical Chemistry C*, 2011, 115(50): 24469-24477.

[13] CHANG W SH, LASSITER J B, SWANGLAP P, *et al*.. A plasmonic Fano switch[J]. *Nano Letters*, 2012, 12(9): 4977-4982.

[14] PIAO X J, YU S, PARK N. Control of Fano asymmetry in plasmon induced transparency and its application to plasmonic waveguide modulator[J]. *Optics Express*, 2012, 20(17): 18994-18999.

[15] WU C, KHANIKAEV A B, SHVETS G. Broadband slow light metamaterial based on a double-continuum Fano resonance[J]. *Physical Review Letters*, 2011, 106(10): 107403.

[16] JAFAR-ZANJANI S, INAMPUDI S, MOSALLAEI H. Adaptive genetic algorithm for optical metasurfaces design[J]. *Scientific Reports*, 2018, 8(1): 11040.

[17] PHAN T, SELL D, WANG E W, *et al*.. High-efficiency, large-area, topology-optimized metasurfaces[J]. *Light:Science & Applications*, 2019, 8(1): 48.

[18] RONG J J, YE W J. Multifunctional elastic metasurface design with topology optimization[J]. *Acta Materialia*, 2020, 185: 382-399.

[19] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. *Nature*, 2015, 521(7553): 436-444.

[20] 刘硕, 张霜, 崔铁军. 拓扑电路——新奇拓扑物理现象的研究平台[J]. 中国光学, 2021, 14(4): 736-753.
LIU SH, ZHANG SH, CUI T J. Topological circuit: a playground for exotic topological physics[J]. *Chinese Optics*, 2021, 14(4): 736-753. (in Chinese)

[21] 苏照贤, 姚恩旭, 黄玲玲, 等. 二维人工超材料的光学拓扑性质[J]. 中国光学, 2021, 14(4): 955-967.
SU ZH X, YAO E X, HUANG L L, *et al*.. Optical topological characteristics of two dimensional artificial metamaterials[J]. *Chinese Optics*, 2021, 14(4): 955-967. (in Chinese)

[22] LI H, OTA K, DONG M X. Learning IoT in edge: deep learning for the internet of things with edge computing[J]. *IEEE Network*, 2018, 32(1): 96-101.

[23] SILVER D, HUANG A, MADDISON C J, *et al*.. Mastering the game of Go with deep neural networks and tree search[J]. *Nature*, 2016, 529(7587): 484-489.

[24] NASSIF A B, SHAHIN I, ATTILI I, *et al*.. Speech recognition using deep neural networks: a systematic review[J]. *IEEE Access*, 2019, 7: 19143-19165.

[25] NODA K, ARIE H, SUGA Y, *et al*.. Multimodal integration learning of robot behavior using deep neural networks[J]. *Robotics and Autonomous Systems*, 2014, 62(6): 721-736.

[26] MA W, CHENG F, LIU Y M. Deep-learning-enabled on-demand design of chiral metamaterials[J]. *ACS Nano*, 2018, 12(6): 6326-6334.

[27] NADELL C C, HUANG B H, MALOF J M, *et al*.. Deep learning for accelerated all-dielectric metasurface design[J]. *Optics Express*, 2019, 27(20): 27523-27535.

[28] XU L, RAHMANI M, MA Y X, *et al*.. Enhanced light–matter interactions in dielectric nanostructures via machine-learning approach[J]. *Advanced Photonics*, 2020, 2(2): 026003.

[29] HOU ZH Y, ZHANG P Y, GE M F, *et al*.. Metamaterial reverse multiple prediction method based on deep learning[J]. *Nanomaterials*, 2021, 11(10): 2672.

[30] ZHOU X SH, XIAO Q D, WANG H. Metamaterials design method based on deep learning database[J]. *Journal of Physics:Conference Series*, 2022, 2185: 012023.

[31] KHATIB O, REN S M, MALOF J, *et al*.. Deep learning the electromagnetic properties of metamaterials —a comprehensive review[J]. *Advanced Functional Materials*, 2021, 31(31): 2101748.

[32] TAN T C W, PLUM E, SINGH R. Lattice-enhanced Fano resonances from bound states in the continuum metasurfaces[J]. *Advanced Optical Materials*, 2020, 8(6): 1901572.

作者简介：

杨知虎(1998—)，男，黑龙江牡丹江人，硕士研究生，2020 年于山东科技大学获得学士学位，主要研究方向为基于深度学习的超材料设计。E-mail: 383048999@qq.com

张会云(1974—)，男，山东沂水人，博士，教授，博士生导师，2008 年于天津大学获得博士学位，主要从事太赫兹功能器件方面的研究。E-mail: sdust_thz@126.com