DOI:10.27055/j.1674-5590.2026.05.009

空间折叠超材料低频吸声特性优化

徐建新,毛伟康,刘兵飞
(中国民航大学航空工程学院,天津 300300)

摘 要: 针对飞机发动机的低频噪声和传统飞机发动机降噪结构优化方式(人工调参)效率低下问题,首先,本文设计了一种空间折叠超材料结构,并利用有限元仿真方法和阻抗管法证实了该结构优越的低频特性;其次,基于实验与仿真数据,采用机器学习算法作为优化方法对空间折叠超材料的吸声特性进行了优化分析;最后,通过分析机器学习结果,利用并联耦合的方式快速构建了可以满足飞机发动机低频宽带降噪需求的复合宽频空间折叠超材料模型,证实了机器学习优化方法的可行性和高效性。本研究可为声学超材料的吸声特性优化和发动机低频降噪设计提供新方法和新思路。

关键词: 折叠超材料;机器学习;有限元分析; 阻抗管法;低频宽带;飞机发动机降噪
中图分类号: V25;TB34 **文献标志码:** A **文章编号:** 1674-5590(2026)05-0078-12

Optimization of the low-frequency sound absorption characteristics of spatially folded metamaterials

XU Jianxin, MAO Weikang, LIU Bingfei
(*College of Aeronautical Engineering, CAUC, Tianjin* 300300, *China*)

Abstract: To address the low-frequency noise of aircraft engines and the inefficiency of manual parameter tuning in traditional noise-reduction structure optimization, this paper firstly designs a spatially folded metamaterial structure and verifies its superior low-frequency characteristics by finite element simulation and the impedance tube method. Secondly, based on experimental and simulation data, machine learning algorithms are adopted as the optimization method to optimize and analyze the sound absorption characteristics of the spatially folded metamaterial. Finally, by analyzing the machine learning results, a composite broadband spatially folded metamaterial model that meets the low-frequency broadband noise reduction requirements of aircraft engines is rapidly constructed by parallel coupling. This confirms the feasibility and efficiency of the machine learning optimization method. This study can provide new methods and ideas for optimizing the sound absorption characteristics of acoustic metamaterials and for the low-frequency noise reduction design of engines.

Key words: ffolded metamaterial; machine learning; finite element analysis; impedance tube method; low-frequency broadband; aircraft engine noise reduction

以飞机发动机低频噪声为主的航空噪声问题日益突出,不仅危害人体健康,而且制约飞机性能,因此开展低频降噪研究意义重大。然而传统降噪技术对低频噪声的吸收效果有限,亟须发展新技术。声学超材料逐渐得到人们重视,其不仅具有超常特性且能实现薄层材料对低频声波的吸收[1-6],为飞机发动机降噪提供了新方向。但传统飞机发动机降噪结构的参数优化方法有一定局限,传统发动机的降噪方案也存在轻薄与低频降噪两者难以兼顾,并且存在效率低、成本高问题[7-8]。近年来,机器学习方法在各领域发展迅速,在超材料相关领域也有应用[9-11]。文献[12]提出利用深度学习模型对超材料结构和电磁特性模型之间的关系进行建模, 实现自动结构设计和手性等特性的优化;文献[13]提出一种集成深度神经网络的方法,实现超材料和超表面的频谱正向预测和反向结构设计;文献[14]结合深度学习实现了可根据场景、全息图分布等

收稿日期:2024-11-27; **修回日期:**2025-03-04 **基金项目:**中央高校基本科研业务费专项(3122023PY08)
作者简介:徐建新(1967—),男,江苏苏州人,教授,博士,研究方向为复合材料结构力学.

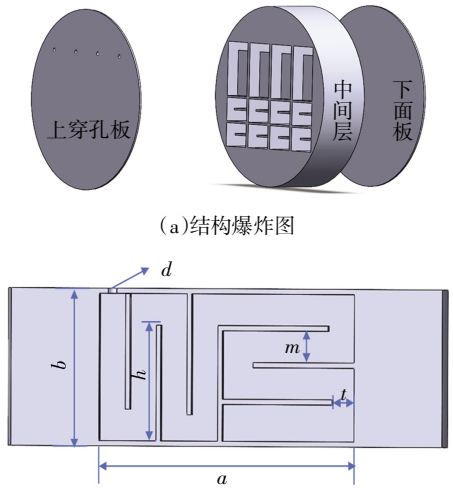
设计要求快速实现候选结构筛选；文献[15]提出了一种深度学习与超材料相结合的方法来解决亚波长无损成像的局限性等。以上研究表明，机器学习在光学以及电磁领域对超材料的优化设计展现出优良性能，提高了优化设计效率，但该方法在声学领域的应用发展较为缓慢[16–17]，因此利用机器学习算法作为优化方法对空间折叠声学超材料进行优化，将极大地提高声学超材料优化效率，并且可以根据实际需求，满足不同目标频率的低频降噪性能需求。

综上所述，本文首先设计了一种空间折叠超材料结构，并以空间折叠超材料的吸声特性分析数据为基础，选用梯度提升决策树（GBDT，gradient boosting decision tree）算法[18]对该结构进行了优化分析，并给出了机器学习可解释性分析结果[19–21]，最终得到了满足飞机发动机降噪需求的复合宽频空间折叠超材料结构。此方法可推广到其他声学超材料结构的优化，为声学超材料和发动机低频降噪设计提供新方法和新思路。

1　空间折叠超材料模型

1.1　超材料有限元模型

本文提出的空间折叠超材料是由周期性排列的单胞构建而成，其单胞结构模型由 3 个部分组合而成，包括上、下面板和中间折叠卷曲空腔，如图 1 所示。上面板开有圆形小孔，下面板不开孔，声波由上面板正上方沿垂直结构表面方向入射，穿过圆孔后声波会沿着折叠卷曲通道传播，其内部组成与各结构参数信息如表 1 所示。各结构参数的尺寸确定后，超材料的吸声特性随之固定。



（a）结构爆炸图

（b）结构剖面图

图 1　空间折叠超材料结构示意图

Fig.1　Schematic diagram of the spatially folded metamaterial structure

表 1　空间折叠超材料结构参数信息

Tab.1　Structural parameter information of the spatially folded metamaterial

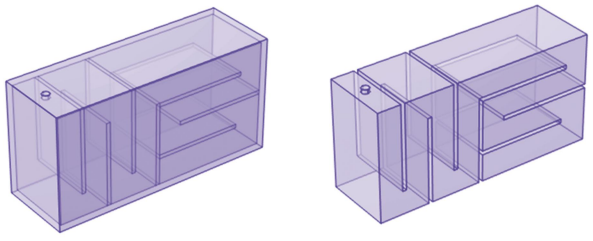
单位：mm

参数缩写	参数含义	数值
a	单胞长度	60
b	单胞厚度	30
m	折叠腔厚度	4
h	折叠板高度	26
t	折叠板缝隙	2
d	穿孔直径	2

本文选择 COMSOL Multiphysics 6.1 版本（简称 COMSOL）作为研究工具，利用其中的有限元方法对所设计的空间折叠超材料结构进行吸声性能的深入分析。具体的设置条件和参数如下所述，旨在通过仿真手段，对结构的吸声特性进行精准评估。

（1）材料定义。空间折叠超材料结构的固体材料定义为光敏树脂，折叠通道层和背腔内部的流体定义为空气，光敏材料的具体结构参数：杨氏模量为 2.65 GPa；泊松比 0.41；密度为 1 120 kg/m^3。

（2）区域划分及物理场定义。建立模型时忽略声能在背景压力场中传播的耗散，空间折叠声学超材料结构的吸声原理主要依靠内壁和空气的相互作用，故在 COMSOL 中选择声–固相互作用模块。另外考虑到狭窄区域内的黏性损失和热损失会造成声波的衰减，因此添加热黏性声学物理场。将结构外侧的入射区域设置为压力声学域，结构固体边界设置为固体力学域，如图 2（a）所示。内部折叠空腔区域设置为热黏性区域来计算声传播损耗，如图 2（b）所示。



（a）固体外壳与内腔隔板　　（b）内部折叠空腔

图 2　结构仿真模型渲染示意图

Fig.2　Schematic diagram of the rendered structural simulation model

（3）边界条件及加载方式。在压力声学域中将声波入射区域设置为压力幅值为 1 Pa 的平面波，并使其垂直入射到结构表面。在固体力学域中将结构四周设置为固定约束，以模拟结构在阻抗管中的受力。

（4）划分网格时，网格的大小和类型决定了网格的质量，而网格质量直接决定了运算时间以及计算结果的精确性。本文将内部折叠通道用细化网格进行划

分，模型其他部分均采用自由四面体网格常规划分方式，其中单元的大小要小于最小波长的 1/6，如图 3 所示。

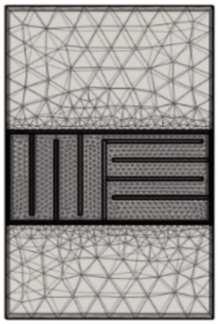


图 3　网格划分

Fig.3　Mesh generation

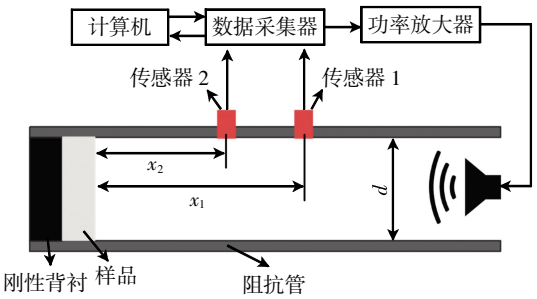
（5）仿真模型求解器配置。网格剖分完毕后，将模型的求解频率范围设置为250~450 Hz。本文所选用的求解器为 PARDISO 求解器。

（6）结果后处理。在 COMSOL 中定义变量 P_{in} 为入射压力场，P_{out} 为散射压力场，则反射系数 $R_f = P_{out}/P_{in}$，吸声系数可由公式 $\alpha = 1 - |R_f|^2$ 求得。

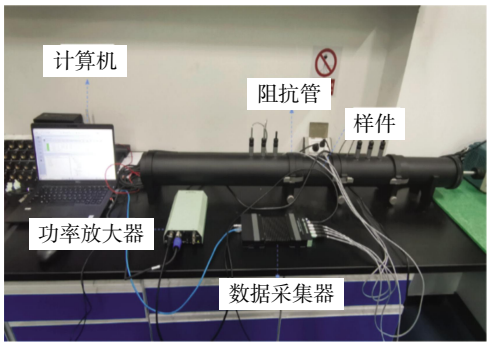
1.2　超材料实验验证与有限元仿真

对设计的空间折叠超材料进行仿真和阻抗管声学实验测试，以验证本文仿真方法的正确性。本节实验测试采用传递函数法[22]测试吸声系数，该系统依托阻抗管测试平台构建，主要包括阻抗管（内直径 100 mm）、功率放大器、NI 数据采集卡、麦克风传感器以及 VA-LAB 测试软件，实验测试系统组成如图 4 所示，其中 x_1 和 x_2 分别为超材料到传感器 1 和 2 的声波传输距离。

通过声学实验测试和仿真所得出的空间折叠超材料的吸声特性曲线如图 5 所示。由图 5 可知，实验与仿真结果宏观趋势保持一致，但吸声峰值仍有误差，主要原因可归结为 3 点：①仿真软件模拟吸声过程存在一定差异；②3D 打印过程中可能产生的加工误差，实验模型有一定粗糙度，导致各单元的固有频率发生细微变化，这进一步影响了实验中的吸声峰值频率和频带宽度；③测试环境的复杂性，包括声源稳定性、阻抗管几何尺寸、试件安装精度、传声器性能以及管壁材料特性等多重因素，都可能对驻波声场造成干扰，同时结构声还可能引发管壁振动，进一步影响传声器信号。总体来说，实验与仿真虽有误差，但误差不大，在允许的合理范围内，证明了本文仿真方法的准确性和实验方法的可靠性，也说明该空间折叠超材料具有较好的低频吸声特性。



（a）系统构建图



（b）系统实物图

图 4　阻抗管实验测试系统

Fig.4　Impedance tube experimental test system

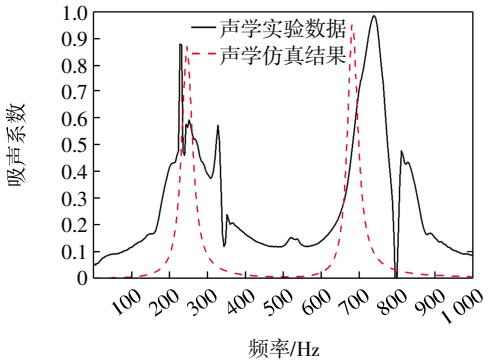
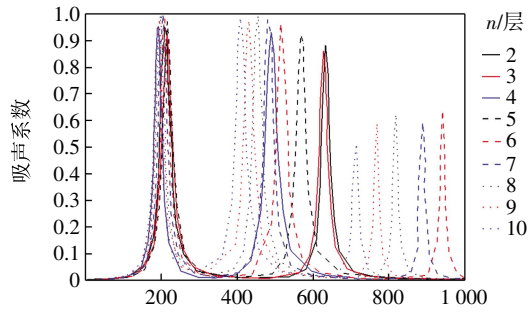


图 5　空间折叠超材料吸声特性的仿真与实验结果

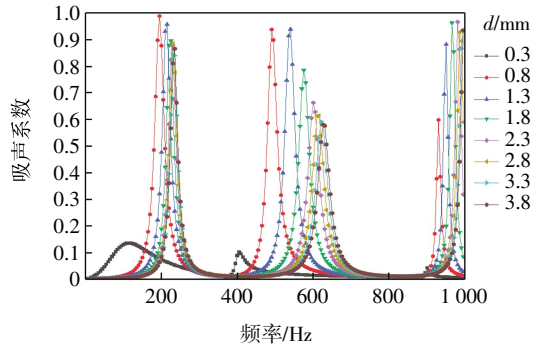
Fig.5　Simulation and experimental results of the sound absorption characteristics of the spatially folded metamaterial

随后，为了建立后续机器学习优化环节所需的数据集，本节针对空间折叠超材料展开了详细的参数仿真研究。分别对 d、h、m、t、折叠层数（n）等关键的结构参数进行了逐一分析，重点关注在这些参数发生变化时吸声系数峰值（R_c）和吸声峰值频率（f）的相应变化情况。所获得的多种结构参数下的空间折叠超材料吸声系数曲线如图 6 所示。由图 6 可知，仅依据这些数据信息，无法得出多种结构参数对于空间折叠超材料的综合影响，无法明确每个参数的最佳取值范围。基于此，后续的机器学习优化过程就显得尤为关键，其目的在于通过先进的算法和模型，挖掘数据中的潜在规律，从而获得满足性能要求的结构参数值。因此，后

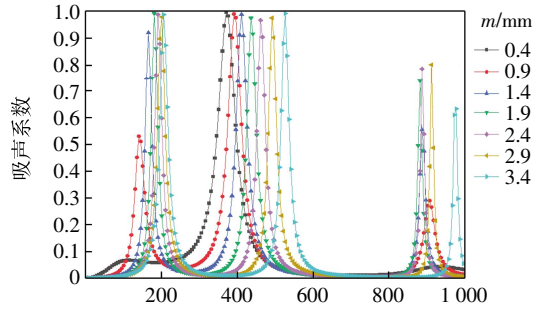
续研究将选择上述的参数化仿真数据作为建立机器学习数据集的基础。这一数据集将为机器学习模型的训练和优化提供重要的数据支撑，对于实现空间折叠超材料结构参数的优化目标具有重要意义。



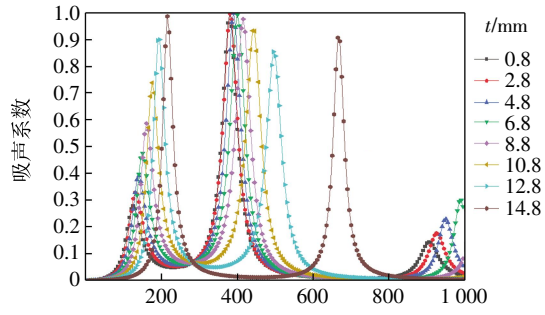
(a)折叠层数 n



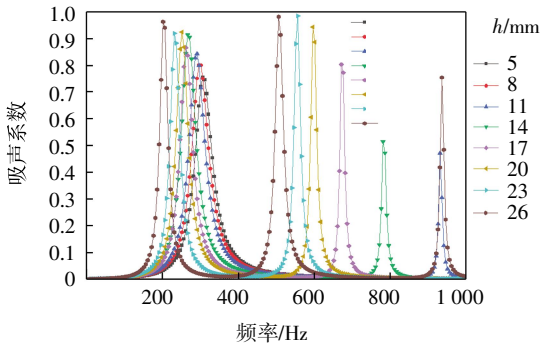
(b)穿孔直径 d



(c)折叠腔厚度 m



(d)折叠板缝隙 t



(e)折叠板高度 h

图 6　不同结构参数变化下的空间折叠超材料吸声特性曲线

Fig.6　Sound absorption characteristic curves of the spatially folded metamaterial under variations of different structural parameters

2　机器学习预测模型

2.1　预测模型选择

为了建立更具高效性与可解释性的机器学习模型，针对本文研究数据的适用性，在开展优化预测工作之前，对不同优化预测算法展开了比较。首先，对不同预测模型的真实值与预测值拟合情况进行对比。本文选取了轻量级梯度提升机(LightGBM，light gradient boosting machine)、极端梯度提升(XGBoost，eXtreme gradient boosting)、随机森林(RF，random forest)、决策树(DT，decision tree)和 GBDT 5 种预测算法，对比结果如图 7 所示。就本研究数据集而言，GBDT 在真实值数据和预测值数据的重合度方面表现更佳。对不同预测模型的适用性评估系数展开详尽的比较分析，结果如图 8 所示。在决定系数 R^2 的评估中，GBDT 模型呈现出显著的领先优势；在均方根误差(RMSE，root mean square error)和均方误差(MSE，mean square error)方面，GBDT 模型同样表现出最优性能，具有最小的误差值；就平均绝对误差(MAE，mean absolute error)和平均绝对百分比误差(MAPE，mean absolute percentage error)而言，DT 模型取得最小值，GBDT 模型紧随其后。通过上述结果可以清晰地看出，对于本文所研究的数据集，GBDT 模型展现出更优异的预测性能。因此，本文选取 GBDT 预测模型作为主要的优化算法。

2.2　特征选择与数据集建立

本文在开展机器学习优化研究之前，已经对具体单胞尺寸的空间折叠超材料进行了吸声性能研究，其自身的结构在 h = 26 mm，m = 4 mm，t = 2 mm，d = 2 mm 和 n = 3 时已具有一定的吸声性能。为了利用机

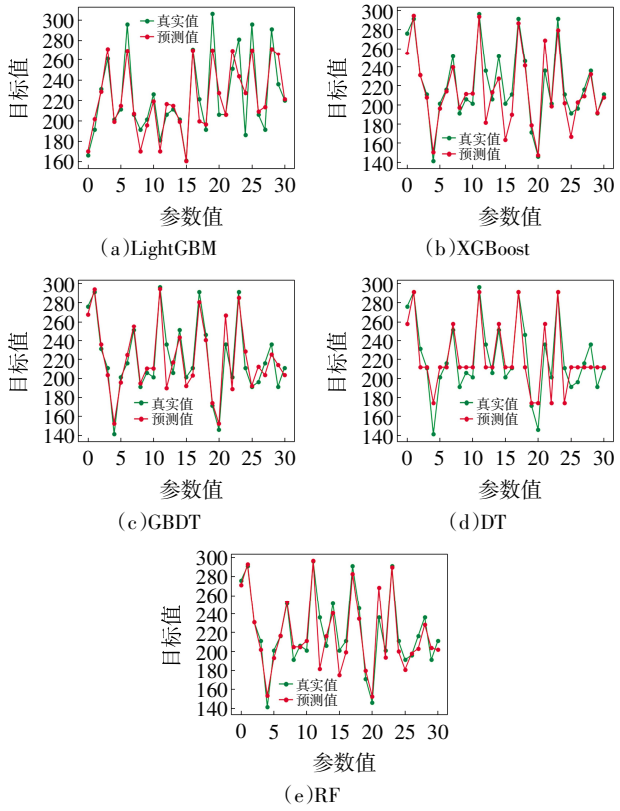
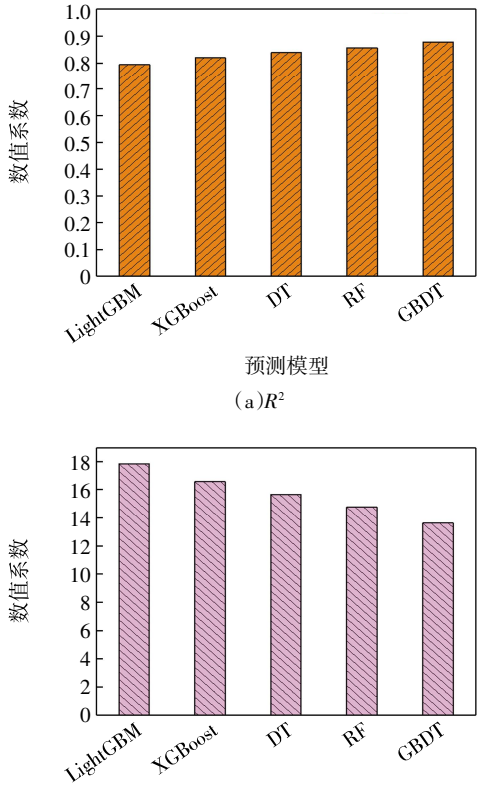


图 7　不同预测模型真实值与预测值对比

Fig.7　Comparison between the true values and the predicted values of different prediction models



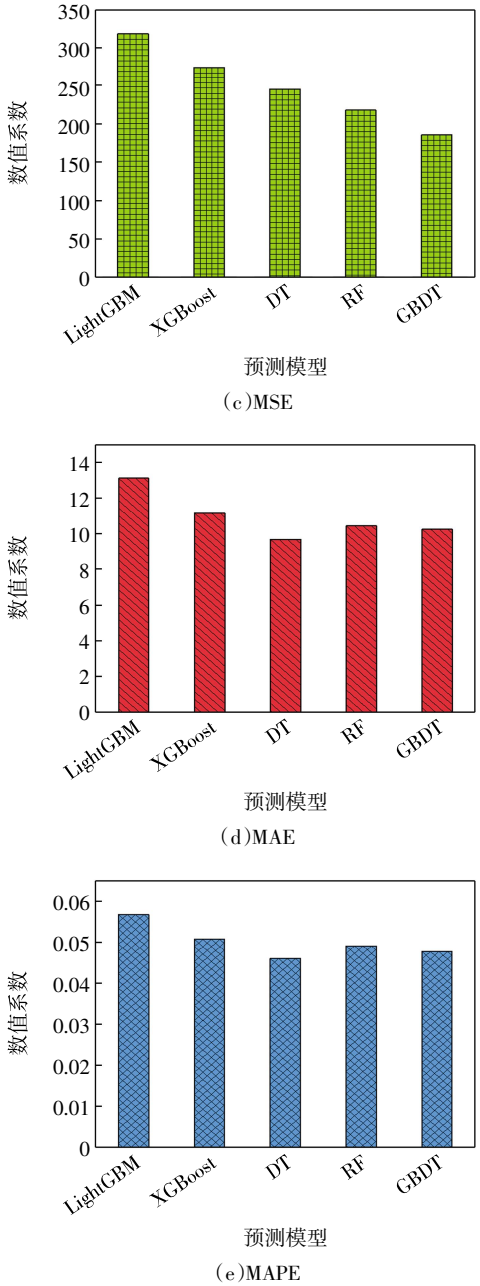


图 8　不同预测模型适用性评估系数

Fig.8　Applicability evaluation coefficients of different prediction models

器学习快速得到具有不同吸声峰值频率的单胞结构参数,需要得到不同吸声峰值频率结果的数据。因此,本文选择的结构参数范围也相应地在此基础上进行扩展。最终确定空间超材料的参数范围为 d = 0.6 ~ 5 mm、h = 5~26 mm、m = 0.7~8.0 mm、t = 0.5~14.8 mm 以及 n = 2~10。同时,设定了 2 个优化目标,即吸声系数峰值 R_c 趋近于 1,以及吸声峰值频率 f 在研究的结构参数范围内达到最小值。5 个特征变量与这 2 个目标变量分别共同构成机器学习模型的 2 组数据集,每

组各 162 个数据，部分数据集结构如表 2 所示。

表 2　数据集结构（部分）

Tab.2　Structure of the data set (partial)

m/mm	h/mm	d/mm	t/mm	n/层	f/Hz	R_c
3.1	26	0.6	2	6	171	0.822 41
4.0	26	0.6	2	5	181	0.836 15
2.6	26	1.0	2	7	161	0.595 79
2.6	18	1.0	2	7	271	0.970 31

为探索各特征变量之间的相关性，不同特征变量间关系的热图矩阵如图 9 所示。热图可显示每一对变量之间的皮尔逊相关系数，颜色越深，相关性越高。一般而言，皮尔逊相关系数大于 0.95 的 2 个特征变量相关性极高，故选取其中 1 个作为特征变量即可[23]。在图 9(a)中，对于以 R_c 为优化目标的数据集，可发现 5 个特征变量之间的相关性较小，并且可认为相互独立，因此可选择这 5 个变量建立机器学习模型。同理，分析图 9(b)可知，以 f 为优化目标的数据集亦有同样的独立性。

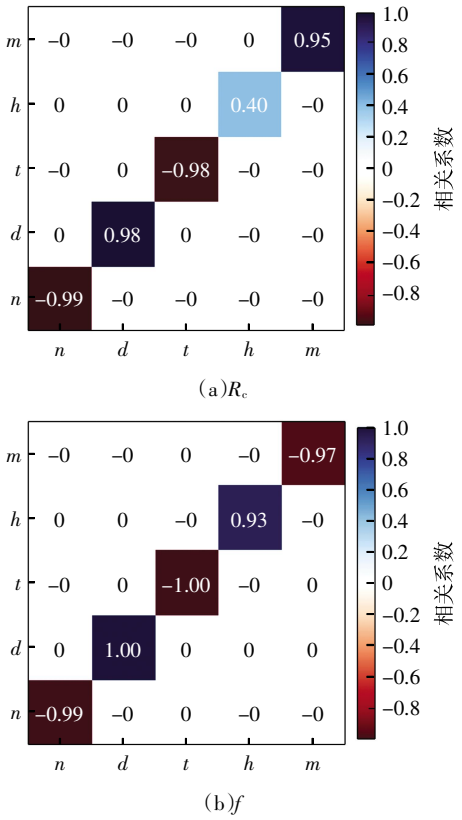


图 9　变量之间的相关热图矩阵

Fig.9　Correlation heat map matrices between variables

2.3　预测模型评估

将已有试验数据的 80% 代入 GBDT 算法以进行模型预测和评估，预测结果与真实试验数据结果的比较情况如图 10 蓝色数据所示，其中横坐标为真实试验数据，纵坐标为预测结果，可见蓝色数据均位于 45° 斜线附近，这表明真实测试值与模型预测值极为接近。利用剩余 20%的数据进行模型验证，预测结果与真实试验数据结果的比较情况如图 10 红色数据所示，可见红色数据亦位于 45°斜线附近，这表明机器学习结果的正确性，进而说明本文模型预测的有效性。

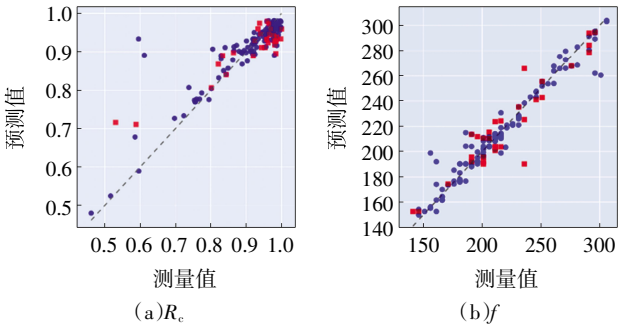


图 10　训练集与测试集对比

Fig.10　Comparison between the training set and the test set

机器学习模型测试集的 RMSE、MSE、MAE、MAPE 以及决定系数 R^2 的计算公式可表达为

$$e_{\mathrm{RMSE}}=\sqrt{\frac{1}{k}\sum_{i=1}^{k}(y_i-\hat{y}_i)^2} \tag{1}$$

$$e_{\mathrm{MSE}}=\frac{1}{k}\sum_{i=1}^{k}(y_i-\hat{y}_i)^2 \tag{2}$$

$$e_{\mathrm{MAE}}=\frac{1}{k}\sum_{i=1}^{k}|y_i-\hat{y}_i| \tag{3}$$

$$e_{R^2}=\frac{\sum_{i=1}^{k}(x_i-\hat{x}_i)(y_i-\hat{y}_i)}{\sqrt{\sum_{i=1}^{k}(x_i-\hat{x}_i)^2\sum_{i=1}^{k}(y_i-\hat{y}_i)^2}} \tag{4}$$

式中：$\hat{y}_i$ 和 y_i 分别表示吸声系数峰值的真实值和预测值；$\hat{x}_i$ 和 x_i 分别表示吸声系数峰值的真实值与预测值的对应频率；k 为数据集个数，测试集误差计算结果如表 3 和表 4 所示。

表 3　测试集误差结果（吸声系数峰值）

Tab. 3　Test set error results (sound absorption coefficient peak)

RMSE	MSE	MAE	MAPE	R^2
0.056 1	0.003 15	0.042 9	0.052 7	0.729

表 4　测试集误差结果（吸声峰值频率）

Tab.4　Test set error results (sound absorption peak frequency)

RMSE	MSE	MAE	MAPE	R^2
12.69	176.79	10.035	0.046 7	0.883

由计算结果可知，基于 GBDT 模型预测空间折叠声学超材料的吸声系数峰值和吸声峰值频率的误

差值极小，模型的拟合度分别可达 0.729 和 0.883，二者都比较接近 1。由此可见，本文针对空间折叠声学超材料吸声性能优化所构建的模型具备较好的有效性与合理性。

2.4　预测模型解释

一般而言，机器学习过程常被视作一种“黑箱过程”，难以直接洞察特征变量与目标变量间隐含的复杂关系。为对机器学习流程予以解释和可视化处理，本文从总体解释和探究特征交互作用下的影响以及局部解释 3 个维度，系统地探究特征变量与目标变量之间的关系。同时，借助沙普利加性解释（SHAP，Shapley additive explanations）量化特征变量对样本目标值的贡献程度，并最终获取满足优化需求的各参数值大小。SHAP 是一种用于解释模型预测结果的方法，其基于合作博弈论中的沙普利值概念，旨在为每个特征分配一个与该特征对预测结果的贡献度相对应的重要性值。SHAP 值求解表达式可表达为

$$\varphi_j(x)=\sum_{t_1=1}^{T}\sum_{n_0\in P_t(x)}\frac{I(n_0\text{ is not root})}{2}\left[\omega_{L(n_0)}\frac{I(j\text{ splits on the left at }n_0)}{N_{L(n_0)}}+\omega_{R(n_0)}\frac{I(j\text{ splits on the right at }n_0)}{N_{R(n_0)}}\right] \tag{5}$$

式中：T 是 GBDT 的树总数；$P_t(x)$ 是样本 x 在第 t_1 棵树中路径上的节点集合；$I()$ 是指示函数，满足括号内条件为 1，否则为 0；$\omega_{L(n_0)}$ 和 $\omega_{R(n_0)}$ 分别是节点 n_0 的左、右子节点权重；j 为模态序号；$N_{L(n_0)}$ 和 $N_{R(n_0)}$ 分别是到达节点 n_0 的左、右子节点数量。

2.4.1　特征变量对目标的总体解释

首先，输出每个样本在所有特征下的 SHAP 值和平均 SHAP 值来进行分析。在机器学习中，模型的预测结果通常由多个特征共同决定。SHAP 值通过计算每个特征对于不同可能特征子集的平均贡献来确定每个特征的重要性，通过分析 SHAP 值，能够了解每个特征在模型预测中的相对作用，进而理解模型的决策过程和特征之间的相互影响。

各个特征变量对吸声系数峰值的影响关系如图 11 所示，其中图 11(a)展示了所有特征变量的重要程度，并计算出相应的平均 SHAP 值的绝对值。由图 11(a)可知，m 的贡献值最高，h 和 n 次之。同时，从图 11(b)可发现 d、t、m 和 n 呈负相关，h 呈正相关。通过样本的平均 SHAP 值不难看出，m 对折叠超材料吸声系数峰值影响最大，且随着 m 的增大，吸声系数峰值不断降低，d、t、n 亦如此。后续若要迅速提高吸声效果，可优先考虑减小 m 的参数值，当然，相应地增大 h 或减小 t、n、m 也可逐步实现提高吸声系数峰值的目的。

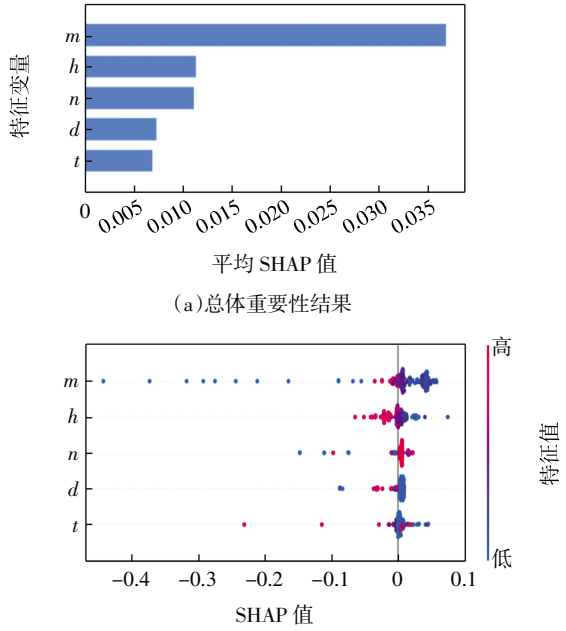


图 11　每个特征变量对模型输出的影响（吸声系数峰值）

Fig.11　Effect of each feature variable on the model output (sound absorption coefficient peak)

同理，可得到各特征变量对吸声峰值频率的影响，如图 12(a)所示，对于吸声峰值频率而言，h 的贡献最大，m、t、d 和 n 次之；图 12(b)显示，d、t、m 和 n 与吸声峰值频率正相关，h 呈负相关。因此，若想获得所研

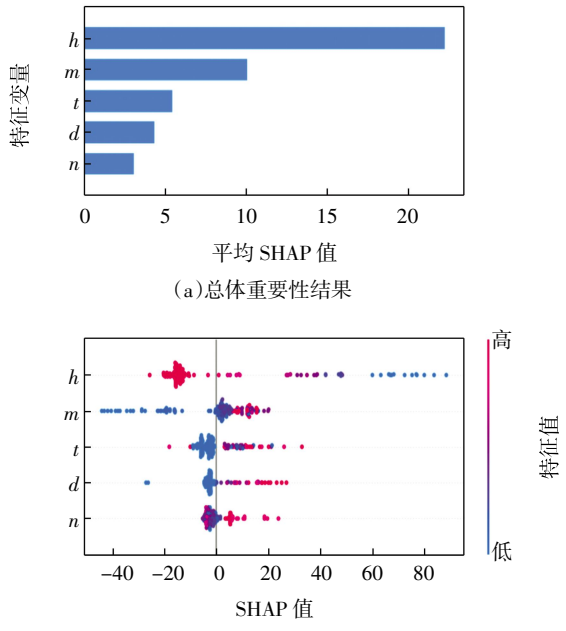


图 12　每个特征变量对模型输出的影响（吸声峰值频率）

Fig.12　Effect of each feature variable on the model output (sound absorption peak frequency)

究参数范围内的最低频率，可依据重要程度增加负相关参数、减少正相关参数，尤其要注重控制重要性强度高的参数，即着重增加 h 的大小。

2.4.2 特征变量交互影响

总体解释无法完全洞悉特征变量与目标值之间的规律。为进一步探究其隐含关系和变化趋势，需要通过研究特征交互作用对目标变量的影响来达成此目的。本节基于 GBDT 算法绘制了重要特征的 SHAP 值，如图 13 和图 14 所示。在图中，横坐标为特征变量的数值大小，纵坐标为特征变量对目标变量的影响。当数据的纵坐标大于 0 时，可认定该数据对目标变量产生正影响；当纵坐标小于 0 时，则认定该数据对目标变量产生负影响。右侧的彩色坐标则展示了该特征变量与横坐标所展示的特征变量之间的相互影响。

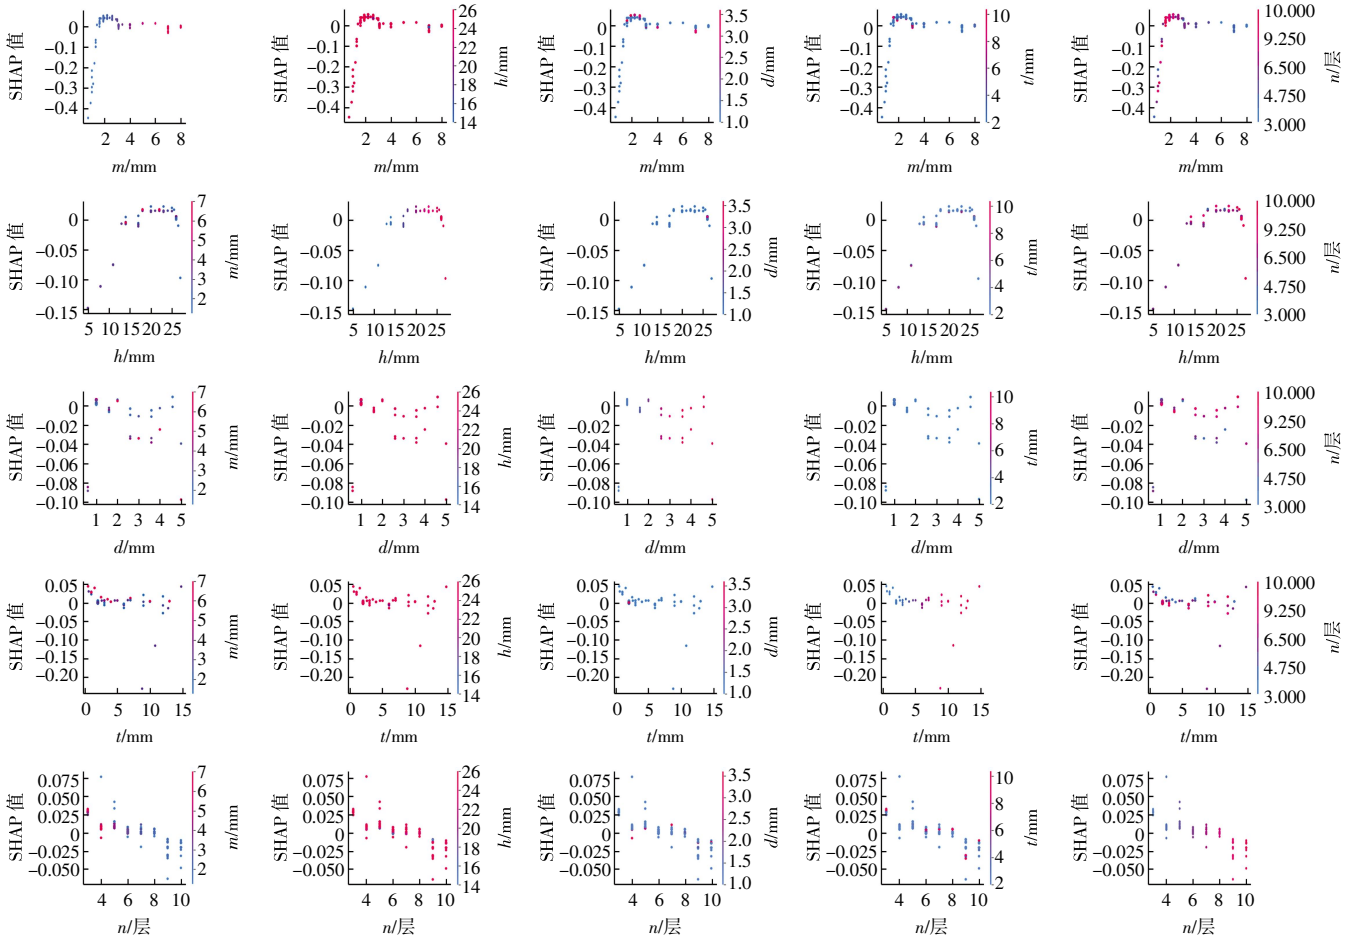


图 13　交互作用下特征变量对吸声系数峰值的影响

Fig.13　Effects of feature variables on the sound absorption coefficient peak under interactions

从图 13 可以看出，m 和 h 对吸声系数峰值影响最大，故选用这两个参数作为交互影响的重点分析参数。依据图 13 中 5 个特征变量在不同数值时对吸声系数峰值的影响结果，可得出以下结论：m 增大时，对吸声系数峰值影响由负转正且程度渐小；h 增加时，对吸声系数峰值影响由负转正后因参数过大再转负，程度先降后升。

除此之外，本节还对其余参数与这两个重点分析参数之间的交互影响展开研究，图 13 结果显示：总体上，随着 h 增大，m 对吸声系数峰值的影响降低。当 m < 2.5 mm 时，随着 d 增大，m 对吸声系数峰值的影响逐渐减小，当 m > 2.5 mm 时，随着 d 增大，m 对吸声系数峰值的影响增强。当 m < 2.0 mm 时，随着 t 增加，m 对吸声系数峰值的影响减小。

同样，图 14 所示的不同特征变量交互作用对吸声峰值频率的影响，可归纳如下：m 对吸声系数峰值的影响由负转正，且随 m 增大，影响程度递减；h 的影响则由正向转为负向，当 h < 23 mm 时，h 对吸声系数峰值产生正向影响，随 h 增大，影响程度递减。

就其余参数对这 2 个重要调节参数的交互影响而言，h 和 t 的增加会削弱 m 对吸声峰值频率的正向影响程度；n 和 d 产生的交互影响可以忽略。t 的增大

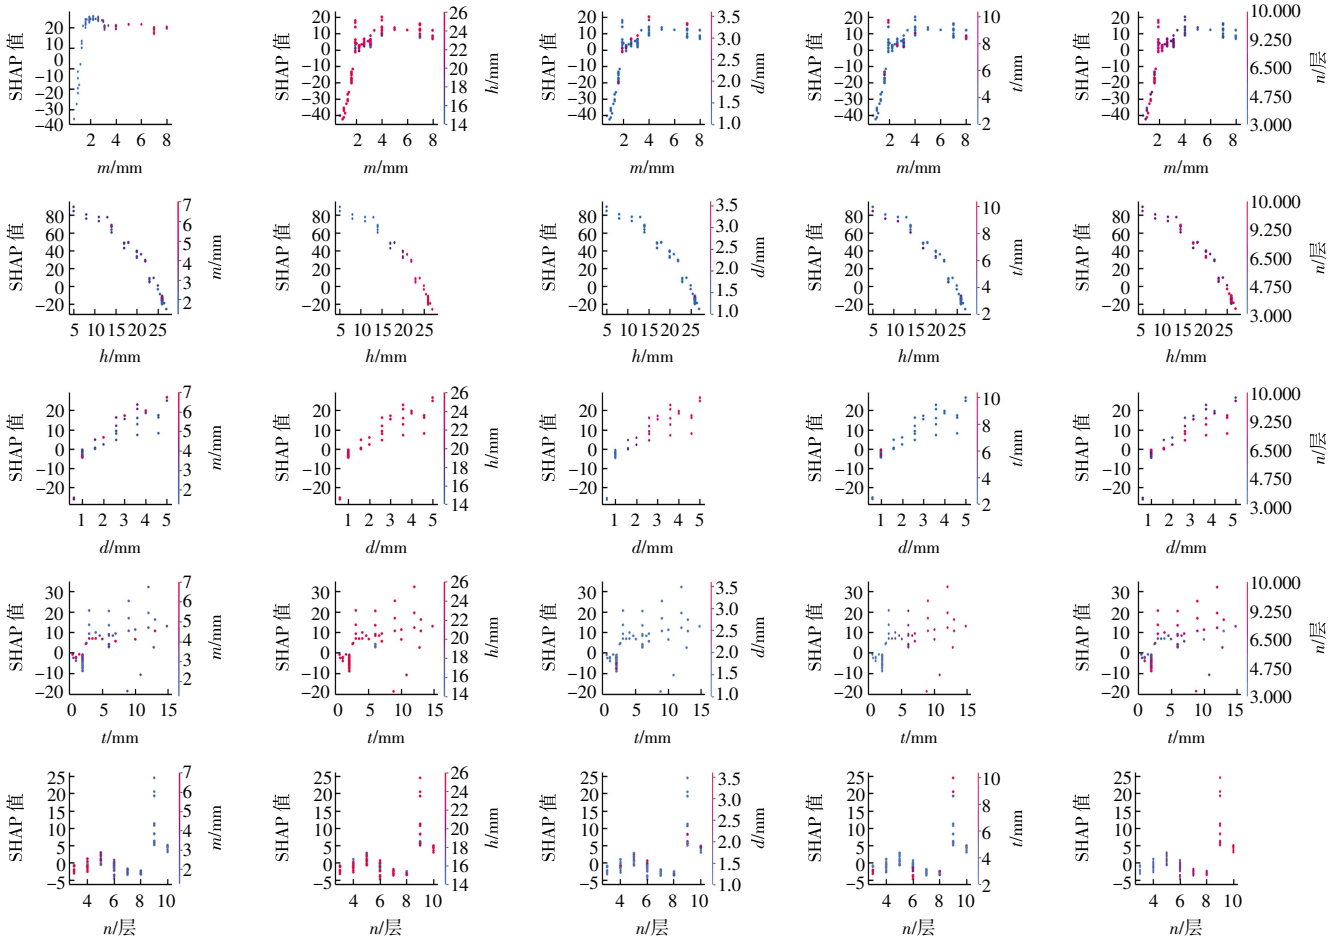


图 14　交互作用下特征变量对吸声峰值频率的影响

Fig.14　Effects of feature variables on the sound absorption peak frequency under interactions

会使 h 对吸声系数峰值的影响降低。

上述分析结论可作为后续吸声峰值频率和吸声系数峰值优化的依据，根据具体优化目标调整参数数值。

2.4.3　样本局部解释

为说明机器学习模型对任何一个样本均得到了有效训练，此处输出某个样本（m = 1.9，n = 9，d = 4.6，t = 2，h = 26）的 SHAP 值，以探究该样本在所有特征变量共同作用下对目标值的具体贡献大小。如图 15所示，其中 $f(x)$ 为该单个样本的贡献值，代表该样本对目标值产生正影响，$E[f(x)]$ 为所有样本的平均贡献值。图 15(a)给出了各特征变量对该样本吸声系数峰值的贡献值，从图 15 中可以看出 m、d 和 t 具有正向影响，n 产生负向影响，而 h 几乎无影响。同样，图 15(b)给出了各特征变量对该样本吸声峰值频率的贡献，可看出 d 和 n 具有正向影响，而 h、t 和 m 呈负相关。

在实际应用中，可通过考察特征变量与目标变量之间的关系来预测空间折叠吸声超构材料的性能。

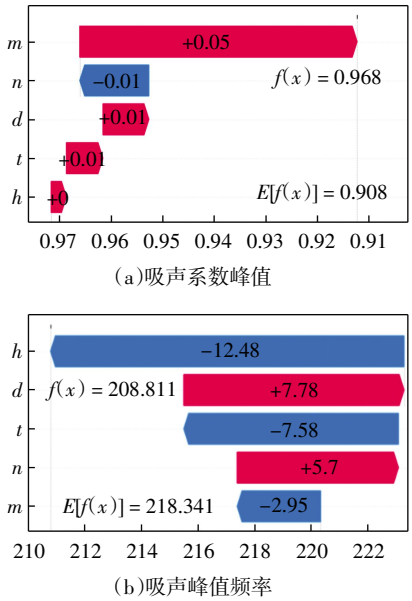


图 15　根据 SHAP 值对样品的局部解释

Fig.15　Local explanation of samples based on SHAP values

如表 5 所示，空间折叠超材料结构各变量对峰值吸声系数峰值的平均贡献率（基准值）为 0.908，加上特征变量的 SHAP 值等于输出值，即单个样本的输出值为 0.968。同样，如表 6 所示，折叠超材料结构各变量对吸声峰值频率的平均贡献率（基准值）为 218.341，加上特征变量的 SHAP 值等于输出值，即单个样本的输出值为 208.811。

表 5　单个样本特征的贡献值（吸声系数峰值）

Tab.5　Contribution values of single-sample features (sound absorption coefficient peak)

特征变量值	基准值	SHAP 值/%	贡献值
m=1.9 mm	0.908	+0.05	0.968
n=9 层	—	−0.01	—
d=4.6 mm	—	+0.01	—
t=2 mm	—	+0.01	—
h=26 mm	—	+0	—

表 6　单个样本特征的贡献值（吸声峰值频率）

Tab.6　Contribution values of single-sample features (sound absorption peak frequency)

特征变量值	基准值	SHAP 值/%	贡献值
m=1.9 mm	218.341	−2.95	208.811
n=9 层	—	+5.70	—
d=4.6 mm	—	+7.78	—
t=2 mm	—	−7.58	—
h=26 mm	—	−12.48	—

为验证局部样本预测的准确性，将该样本参数下的模型数据代入 COMSOL 进行仿真验证。结果如图 16 和表 7 所示，其中 A 为模拟吸声系数峰值，f_m 为模拟吸声峰值频率。从表 7 可以看出，A 为 0.988，与预测结果 0.968 相差较小，f_m 为 211.000 Hz，与 208.811 Hz 非常接近。因此，本文基于机器学习预测和优化空间折叠超材料吸声性能的可行性和准确性再次得到了验证。

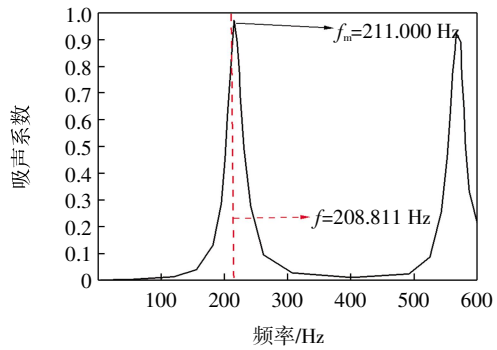


图 16　局部样本预测与仿真结果对比

Fig.16　Comparison between the predictions of local samples and the simulation results

表 7　局部样本有限元仿真结果

Tab.7　Finite element simulation results of local samples

m/mm	d/mm	h/mm	n	t/mm	A	f_m/Hz
1.9	4.6	26	9	2	0.988	211.000

2.5　优化结果讨论

通过对各参数关于目标特性的整体影响、特性变量间交互作用对目标值的影响以及样本局部影响予以综合考量，能够得出 5 个参数对目标特性的总体影响。具体步骤如下：

（1）整体影响分析，针对每个参数对目标特性的独立影响展开评估；

（2）交互作用考量，剖析参数间的相互作用是如何影响目标值的；

（3）局部影响研究，考察样本内部各参数对目标特性所产生的局部效应。

进一步而言，经由对模型解释结果的分析，在所研究的空间折叠超材料结构参数范围内，明确了各参数在满足吸声峰值频率最小化以及吸声系数峰值趋近于 1 这两个优化目标时的两组最优值。这一发现为超材料的设计与优化提供了重要的指导依据。

首先，针对研究参数范围内吸声峰值频率的优化展开研究，给出了在本文研究范围内具备最低吸声峰值频率的超材料模型，具体参数数值如表 8 所示，其优化结果与仿真数据的对比如图 17 所示。

表 8　参数范围内最低吸声峰值频率优化结果

Tab.8　Optimization results of the lowest sound absorption peak frequency within the parameter range

m/mm	d/mm	h/mm	n	t/mm	R_c	f_m/Hz
1.0	2	26	4	2.5	0.815	116

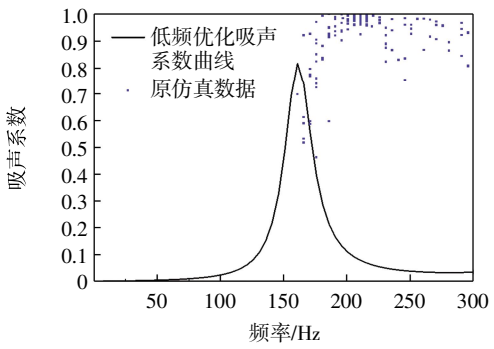


图 17　吸声峰值频率优化仿真结果对比

Fig.17　Comparison of simulation results of the sound absorption peak frequency optimization

由图 17 能够看出，机器学习优化结果的频率确实低于原始仿真结果，低频优化目标得以达成。

其次，对吸声系数峰值实施了优化，促使吸声系

数峰值趋近于 1,同样给出了实现最优吸声的超材料模型,具体参数如表 9 所示,其优化结果与仿真数据的对比情况如图 18 所示。通过对该结果的观察同样能够得出,吸声系数峰值趋近于 1 的优化目标已然实现。

表 9　参数范围内最优吸声系数峰值优化结果

Tab.9　Optimization results of the optimal sound absorption coefficient peak within the parameter range

m/mm	d/mm	h/mm	n	t/mm	R_c	f_m/Hz
4.0	1.2	26	4	2	0.997	205

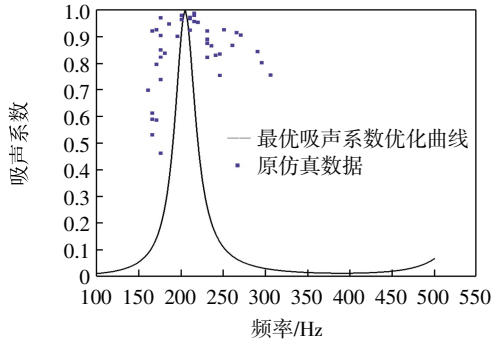


图 18　吸声系数峰值优化仿真结果对比

Fig.18　Comparison of simulation results of the sound absorption coefficient peak optimization

通过上述两个优化实例的结果对比,得以验证利用 GBDT 算法对空间折叠超材料进行结果优化具有较高的可行性。

在进行最终优化之前,通过查阅 CCAR-36 部《航空器型号和适航合格审定噪声规定》以及发动机噪声研究的相关文献,了解到飞机发动机频率处于 50~12 000 Hz(低高频不等),噪声强度主要处于 60~140 dB。本文的优化需求是对 150~400 Hz 低频噪声进行降噪,优化目标是获得满足发动机噪声需求的复合宽频空间折叠超材料结构。在此基础上,通过分析机器学习结果,综合考量吸声系数峰值和吸声峰值频率,高效且快速地得到了 8 个能够满足较好吸声要求且吸声峰值频率不同的空间折叠超材料并联单胞参数情况如表 10 所示。随后通过并联耦合的方式构建了复合宽频空间折叠超材料结构,其结构模型如图 19 所示。

为验证该宽频模型的低频吸声特性,利用COMSOL 对其进行了声学仿真,仿真结果如图 20 所示。可以发现,此模型在 170~380 Hz 这一宽频范围内吸声系数峰值平均值为 0.758,具有 210 Hz 的低频宽带降噪性能,呈现出了较好的低频吸声效果,实现了低频、宽带吸声性能,进而达成了对 150~400 Hz 低频噪声降噪的优化需求和快速构建复合宽频空间折叠超材料模型的优化目标。

表 10　满足要求的低频宽带空间折叠超材料并联单胞参数情况

Tab.10　Parameter status of parallel unit cells of the low-frequency broadband spatially folded metamaterial satisfying the requirements

单元序号	m/mm	h/mm	t/mm	d/mm	n
1	1.4	26.5	12.8	1.5	6
2	1.8	25	13.8	1.4	6
3	3.2	22	15.8	1.6	6
4	3.1	20	16.8	1.8	5
5	3.1	18	17.8	1.9	5
6	3.1	18	20.8	2.2	5
7	3.1	18	24.8	2.4	5
8	3.1	18	26.8	2.6	5

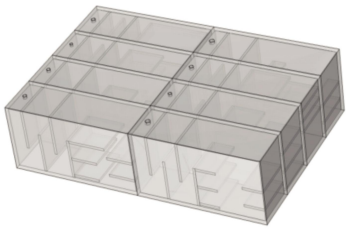


图 19　复合宽频空间折叠超材料模型

Fig.19　Model of the composite broadband spatially folded metamaterial

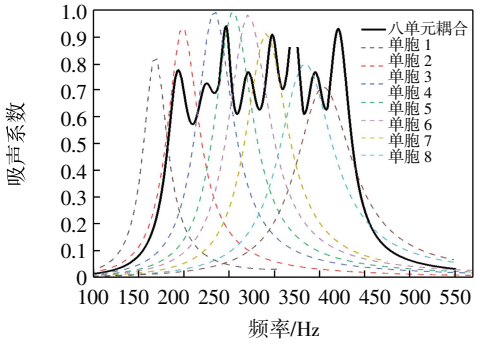


图 20　复合宽频空间折叠超材料的吸声曲线

Fig.20　Sound absorption curves of the composite broadband spatially folded metamateria

3　结语

本文设计了一种空间折叠超材料,利用 COMSOL 对空间折叠超材料进行了声学仿真,并采用阻抗管法完成了声学测试。随后,将 GBDT 算法作为优化算法对空间折叠超材料进行了优化预测。最终,基于机器学习优化结果设计并构建了复合宽频空间折叠超材料结构。得到了以下结论。

(1)实验与仿真结果总体趋势基本一致,验证了本文仿真方法的正确性,同时证实了本文所设计空间折叠超材料优越的低频吸声特性。

(2)分析 GBDT 结果可以得到,m 和 h 对吸声系数

设计要求峰值和吸声峰值频率的综合影响最大。

（3）GBDT 算法给出的以最低吸声峰值频率和最优吸声系数峰值为目标的优化效果良好，证实了利用机器学习对空间折叠超材料进行优化的可行性和高效性。

（4）给出了 8 个具有不同吸声峰值频率的空间折叠超材料的结构参数，进而通过并联耦合建立了在 170~380 Hz 频段具有良好吸声性能的复合宽频空间折叠超材料，满足了飞机发动机低频降噪需求，解决了传统人工调参优化方法效率低下的问题。

参考文献：

[1] 张忠刚, 朱浩宇, 罗剑, 等. 吸声型薄膜声学超材料低频宽带吸声性能研究[J]. 应用声学, 2019, 38(5): 869–875.

[2] Chen Meng, Jiang Heng, Zhang Han, et al. Design of an acoustic superlens using single–phase metamaterials with a star–shaped lattice structure[J]. Scientific Reports, 2018, 8: 1861.

[3] Do N A G, Vergara E F, Barbosa L R, et al. Sound absorption metasurface with symmetrical coiled spaces and micro slit of variable depth[J]. Applied Acoustics, 2021, 183: 108312.

[4] 张宪旭, 刘怡然, 李丽君. 基于 Helmholtz 共振腔阵列的声学超材料研究[J]. 工程设计学报, 2020, 27(4): 441–447.

[5] 陈应航, 徐驰, 黄唯纯, 等. 基于微缝折叠空间结构的宽带吸声超材料设计[J]. 振动与冲击, 2024, 43(3): 171–178.

[6] Huang Chenyan, Yang Shu, Talukder E, et al. Research progress of noise reduction of composite structures of porous materials and acoustic metamaterials[J]. Physica Scripta, 2024, 99(5): 052004.

[7] 梁春华, 孙广华. 商用飞机发动机先进降噪技术[J]. 航空科学技术, 2011, 22(4): 48–52.

[8] 伍赛特. 民用航空发动机降噪技术研究及展望[J]. 机电产品开发与创新, 2019, 32(4): 55–57.

[9] 赵哲, 杨来侠, 吴玲玲, 等. 一种基于机器学习的零刚度隔振超材料设计及性能验证[J]. 复合材料学报, 2024, 41(5): 2599–2608.

[10] 刘文俭, 熊家军, 范亚, 等. 机器学习在超材料智能设计中的研究现状[J]. 信阳师范学院学报(自然科学版), 2021, 34(3): 501–509.

[11] Qiu Yisong, Ye Hongfei, Zhang Hongwu, et al. Machine learning–driven optimization design of hydrogel–based negative hydration expansion metamaterials[J]. Computer–Aided Design, 2024, 166: 103631.

[12] Ma Wei, Cheng Feng, Liu Yongmin. Deep–learning–enabled on–demand design of chiral metamaterials[J]. ACS Nano, 2018, 12(6): 6326–6334.

[13] Malkiel I, Mrejen M, Nagler A, et al. Plasmonic nanostructure design and characterization via Deep Learning[J]. Light: Science & Applications, 2018, 7: 60.

[14] Jiang Qiang, Jin Guofan, Cao Liangcai. When metasurface meets hologram: Principle and advances[J]. Advances in Optics and Photonics, 2019, 11(3): 518–576.

[15] Orazbayev B, Fleury R. Far–field subwavelength acoustic imaging by deep learning[J]. Physical Review X, 2020, 10(3): 031029.

[16] Robeck C, Cipolla J, Kelly A. Convolutional neural network driven design optimization of acoustic metamaterial microstructures[J]. The Journal of the Acoustical Society of America, 2019, 146 (4_Supplement): 2830.

[17] Amirkulova F, Tran T, Khatami E. Generative deep learning model for broadband acoustic metamaterial design[J]. The Journal of the Acoustical Society of America, 2021, 150(4): A209.

[18] 黄桂灶, 马同鑫, 杨泽锋, 等. 基于 GBDT 算法的弓网动态匹配特性预测模型[J]. 振动与冲击, 2024, 43(16): 26–32.

[19] 廖勇, 韩小金, 刘金林, 等. 可解释性人工智能研究进展[J/OL]. 计算机工程, 2024–10–30. https://doi.org/10.19678/j.issn. 1000–3428.0069925.

[20] 曹放, 孙徐, 张钰. 基于“XGBoost—SHAP”的可解释性崩塌落石风险预测在公路工程中的应用[J]. 工程技术研究, 2024, 9(14): 1–4.

[21] 崔婷婷, 安雪莲, 孙德亮, 等. 基于 SHAP 的可解释机器学习的滑坡易发性评价模型[J]. 成都理工大学学报(自然科学版), 2025, 52(1): 153–172.

[22] 姚广春, 代阳, 马训鸣, 等. 基于传递函数法的吸声系数测试系统设计与实现[J]. 仪表技术与传感器, 2022(11): 55–59.

[23] Zhang Wengang, Zhang Runhong, Wu Chongzhi, et al. State–of–the–art review of soft computing applications in underground excavations [J]. Geoscience Frontiers, 2020, 11(4): 1095–1106.

（责任编辑：刘雅婷）