



(12) 发明专利

(10) 授权公告号 CN 114722690 B

(45) 授权公告日 2022.09.02

(21) 申请号 202210643830.0

G06N 3/04 (2006.01)

(22) 申请日 2022.06.09

G06N 3/08 (2006.01)

(65) 同一申请的已公布的文献号
申请公布号 CN 114722690 A

(56) 对比文件

(43) 申请公布日 2022.07.08

CN 112115639 A, 2020.12.22

CN 114357636 A, 2022.04.15

(73) 专利权人 华中科技大学
地址 430000 湖北省武汉市洪山区珞喻路
1037号

CN 113361025 A, 2021.09.07

US 2019364362 A1, 2019.11.28

WO 2020263358 A1, 2020.12.30

CN 113627098 A, 2021.11.09

CN 112182938 A, 2021.01.05

(72) 发明人 周奇 吴金红 林泉 胡杰翔
刘华坪 黄旭丰 金朋 王胜一
毛义军 郑建国

Zhao Dong ET AL. Automated Recognition of Wood Damages using Artificial Neural Network.《2009 International Conference on Measuring Technology and Mechatronics Automation》.2009,

赵瑞等. 声学超表面抑制Mack第2模态机理与优化设计.《气体物理》.2018,

(74) 专利代理机构 武汉红观专利代理事务所
(普通合伙) 42247
专利代理师 陈凯

审查员 史雪飞

(51) Int. Cl.

G06F 30/23 (2020.01)

G06F 30/27 (2020.01)

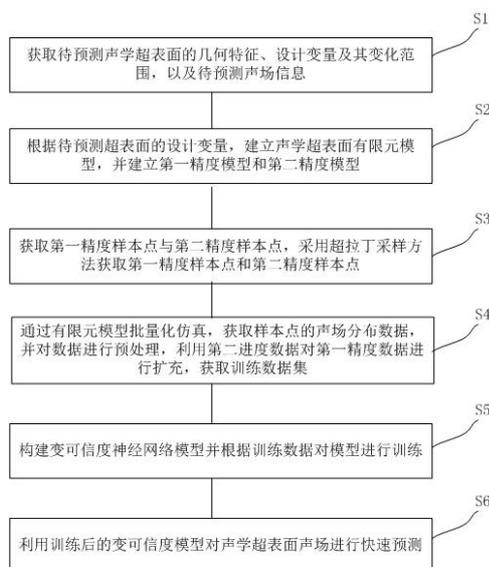
权利要求书3页 说明书9页 附图3页

(54) 发明名称

基于变可信度神经网络的声学超表面声场快速预测方法

(57) 摘要

本发明提供了基于变可信度神经网络的声学超表面声场快速预测方法,该预测方法包括如下步骤:获取待预测声学超表面的几何特征、设计变量及其变化范围,以及待预测声场信息;根据待预测声学超表面的设计变量,建立声学超表面的第一精度有限元模型和第二精度有限元模型;采用拉丁超立方采样法,第一精度样本点以及第二精度样本点;通过有限元模型批量化仿真,获取各个第一精度样本点及第二精度样本点的声场分布数据,并对数据进行预处理,利用第二精度样本点声场分布数据对第一精度样本点声场分布数据进行扩充,获取训练数据集;构建变可信度神经网络模型,并根据训练数据集对变可信度神经网络模型进行训练。



CN 114722690 B

1. 基于变可信度神经网络的声学超表面声场快速预测方法, 其特征在于, 该预测方法包括如下步骤:

S1: 获取待预测声学超表面的几何特征、设计变量及其变化范围, 以及待预测声场信息; 所述声学超表面的几何特征为厚度方向小于入射声波波长的结构, 其被均分为 m 个单元, 每个单元具有不同的密度和弹性模量属性值; 所述设计变量为单元密度 ρ 与单元弹性模量 E , 设计变量个数 $n = 2m$; 所述待预测声场信息为超表面周围均匀分布的采样点的声压值;

S2: 根据待预测声学超表面的设计变量, 建立声学超表面的有限元模型, 并进一步建立声学超表面的第一精度有限元模型和第二精度有限元模型;

S3: 采用拉丁超立方采样法, 获取第一精度有限元模型对应的第一精度样本点, 以及第二精度有限元模型对应的第二精度样本点;

S4: 通过有限元模型批量化仿真, 获取各个第一精度样本点及第二精度样本点的声场分布数据, 并对数据进行预处理, 利用第二精度样本点声场分布数据对第一精度样本点声场分布数据进行扩充, 获取训练数据集;

S5: 构建变可信度神经网络模型, 并根据训练数据集对变可信度神经网络模型进行训练; 变可信度神经网络模型通过学习第一精度样本点声场分布数据与第二精度样本点声场分布数据之间的线性或者非线性关系, 第二精度样本点声场分布数据提供趋势信息, 用第一精度样本点声场分布数据对预测值进行校正, 来融合不同精度的样本点声场分布数据, 从而提高神经网络模型的预测精度;

S6: 利用训练后的变可信度神经网络模型对声学超表面声场进行快速预测。

2. 根据权利要求1所述的基于变可信度神经网络的声学超表面声场快速预测方法, 其特征在于, 步骤S5中所述构建变可信度神经网络模型, 该变可信度神经网络模型包括三个部分, 第二精度预测部分 NN_L 、线性子网络 F_l 和非线性子网络 F_n ; 构建变可信度神经网络的流程为:

S501: 给定输入 \mathbf{x} , 给定输入为长度 $2m$ 的向量;

S502: 构建第二精度预测部分 NN_L , 其输入神经元个数为 $2m$, 通过全连接层、卷积层和池化层提取输入特征并输出预测声场, 得到变可信度神经网络模型的第二精度输出的预测结果 $\hat{\mathbf{y}}_L$;

S503: 将给定输入 \mathbf{x} 和变可信度神经网络模型的第二精度输出的预测结果 $\hat{\mathbf{y}}_L$ 拼接成新的输入 $\{\mathbf{x}, \hat{\mathbf{y}}_L\}$;

S504: 构建线性子网络 F_l 部分, 此部分网络不添加非线性激活函数, 通过全连接层、卷积层和池化层提取新的输入 $\{\mathbf{x}, \hat{\mathbf{y}}_L\}$ 特征, 输出线性子网络预测结果 $F_l(\mathbf{x}, \hat{\mathbf{y}}_L)$;

S505: 构建非线性子网络部分 F_n , 此部分网络添加非线性激活函数, 通过全连接层、卷

积层和池化层提取新的输入 $\{\mathbf{x}, \hat{y}_L\}$ 特征, 并输出非线性子网络预测结果 $F_m(\mathbf{x}, \hat{y}_L)$;

S506: 变可信度神经网络的第一精度输出的预测结果 \hat{y}_H 为

$$\hat{y}_H = \alpha F_l(\mathbf{x}, \hat{y}_L) + (1 - \alpha) F_m(\mathbf{x}, \hat{y}_L); \alpha \text{ 和 } 1 - \alpha \text{ 分别为线性子网络 } F_l \text{ 和非线性子网络 } F_m \text{ 的权值, } \alpha \in [0, 1].$$

3. 根据权利要求2所述的基于变可信度神经网络的声学超表面声场快速预测方法, 其特征在于, 非线性激活函数为relu函数或者tanh函数。

4. 根据权利要求1-3任一项所述的基于变可信度神经网络的声学超表面声场快速预测方法, 其特征在于, 步骤S2中根据待预测声学超表面的设计变量, 建立声学超表面的有限元模型, 并进一步建立声学超表面的第一精度有限元模型和第二精度有限元模型, 具体是: 将声学超表面放置于一矩形平板的上表面, 声学超表面具有矩形的边界; 首先建立声学超表面及矩形平板的有限元模型, 采用三角形非结构网格对该有限元模型进行网格划分; 进一步对声学超表面所在区域的网格进行加密处理, 并满足网格一致收敛性条件, 得到声学超表面的第一精度有限元模型; 声学超表面的第二精度有限元模型是在声学超表面的第一精度有限元模型的基础上, 保持声学超表面区域网格尺寸不变, 将有限元模型的非声学超表面区域的网格尺寸放大得到。

5. 根据权利要求1-3任一项所述的基于变可信度神经网络的声学超表面声场快速预测方法, 其特征在于, 步骤S3中所述采用拉丁超立方采样法, 获取第一精度有限元模型对应的第一精度样本点, 以及第二精度有限元模型对应的第二精度样本点, 是在设计变量的个数 n 的范围内, 采用拉丁超立方采样法在设计变量范围内生成 n_1 个第二精度样本点, 从生成的 n_1 个第二精度样本点中随机选取 n_h 个作为第一精度样本点。

6. 根据权利要求5所述的基于变可信度神经网络的声学超表面声场快速预测方法, 其特征在于, 步骤S4所述的通过有限元模型批量化仿真, 获取各个第一精度样本点及第二精度样本点的声场分布数据, 并对数据进行预处理, 利用第二精度样本点声场分布数据对第一精度样本点声场分布数据进行扩充, 获取训练数据集, 是将声学超表面的有限元模型划分为 $M \times N$ 的规则栅格矩阵, 通过插值获得每个栅格点的声压值, 对于栅格位于超表面或者实体上的点, 其声压值设定为0; 通过有限元分析软件自带的批量化仿真, 得到每个第二精度样本点或者第一精度样本点在每个栅格点处的声压值, 共获得 n_1 个 $M \times N$ 维度的第二精度样本点声场分布数据构成的第二精度数据集, 以及 n_h 个 $M \times N$ 维度的第一精度样本点声场分布数据; 第一精度样本点声场分布数据如果少于第二精度样本点声场分布数据的个数, 则将第一精度样本点声场分布数据中缺失的部分用对应位置的第二精度样本点声场分布数据进行扩充, 直到第一精度样本点声场分布数据的数量与第二精度样本点声场分布数据的数量相等, 得到第一精度数据集; 第二精度数据集与第一精度数据集构成了训练数据集。

7. 根据权利要求6所述的基于变可信度神经网络的声学超表面声场快速预测方法, 其特征在于, 步骤S5中所述对变可信度神经网络模型进行训练, 还包括对变可信度神经网络

模型训练的损失函数进行设置；变可信度神经网络模型训练时的损失函数 L 为：
$$L = \beta_i^L \gamma \|y_i^L - y_L\| + \beta_i^H (1 - \gamma) \|y_i^H - y_H\|$$
；其中 y_i^L 为变可信度神经网络模型的第 i 次给定输入的第二精度预测结果； y_i^H 为变可信度神经网络模型的第 i 次给定输入的第一精度预测结果； y_H 为变可信度神经网络模型的第一精度真实值； y_L 为变可信度神经网络模型的第二精度真实值； $\|\cdot\|$ 为二阶范数误差符号； $\|y_i^L - y_L\|$ 为第二精度损失，即变可信度神经网络模型的第二精度预测值与第二精度真实值之差的二阶范数误差； $\|y_i^H - y_H\|$ 为第一精度损失，即变可信度神经网络模型的第一精度预测值与第一精度真实值之差的二阶范数误差； γ 和 $1 - \gamma$ 分别为第二精度损失和第一精度损失的权值， $\gamma \in [0, 1]$ ； β_i^L 为第一精度数据集中来源于第二精度样本点声场分布数据的权值， β_i^H 为第一精度数据集中来源于自有第一精度样本点声场分布数据的权值， β_i^H 与 β_i^L 用于区分第一精度数据集中的样本点声场分布数据来源， β_i^L 、 $\beta_i^H \in [0, 1]$ 。

基于变可信度神经网络的声学超表面声场快速预测方法

技术领域

[0001] 本发明涉及声学超表面设计技术领域,尤其涉及一种基于变可信度神经网络的声学超表面声场快速预测方法。

背景技术

[0002] 声学超表面是一种二维超材料技术,通过在不同相界面处引入相位突变,能够对入射波的反射角和折射角进行调控,实现噪声抑制、声隐身、声聚焦等功能。因此,为了实现特定的功能,必须对声学超表面的物性参数进行设计,以构造特定的相位突变。这就需要人为评估不同物性参数分布下的散射声场分布信息。传统的声学超表面设计方法需要调用高性能的数值模型,耗时的仿真模拟往往会导致整个设计周期的延迟。随着人工智能技术的发展,神经网络已被证明能够有效地替代有限元仿真模型,实现对声场分布的快速预测,并且具有较高的精度。

[0003] 然而,神经网络的训练效果很大程度上依赖于数据集的数量和质量,现有的基于神经网络的声学超表面声场预测模型,需要执行大量的实验或仿真模拟来构建同一精度数据集,仍需耗费大量时间;同时,在超表面设计过程中,存在着不同精度的数据,其中高精度数据的获取时间和计算成本较高,而低精度数据相对容易获得。仅采用少量高精度数据训练的模型泛化能力较差,仅采用大量低精度数据训练的模型的精度较低。因此,如何有效利用不同精度的数据,来降低神经网络模型构建的开销,快速的对声学超表面声场进行预测,是提高超表面设计效率的关键因素之一。

发明内容

[0004] 有鉴于此,本发明提出了一种结合了不同精度数据的、降低神经网络模型构建的开销的、基于变可信度神经网络的声学超表面声场快速预测方法。

[0005] 本发明的技术方案是这样实现的:本发明提供了基于变可信度神经网络的声学超表面声场快速预测方法,包括如下步骤:

[0006] S1:获取待预测声学超表面的几何特征、设计变量及其变化范围,以及待预测声场信息;所述声学超表面的几何特征为厚度方向小于入射声波波长的结构,其被均分为 m 个单元,每个单元具有不同的密度和弹性模量属性值;所述设计变量为单元密度 ρ 与单元弹性模量 E ,设计变量个数 $n = 2m$;所述待预测声场信息为超表面周围均匀分布的采样点的声压值;

[0007] S2:根据待预测声学超表面的设计变量,建立声学超表面的有限元模型,并进一步建立声学超表面的第一精度有限元模型和第二精度有限元模型;

[0008] S3:采用拉丁超立方采样法,获取第一精度有限元模型对应的第一精度样本点,以及第二精度有限元模型对应的第二精度样本点;

[0009] S4:通过有限元模型批量化仿真,获取各个第一精度样本点及第二精度样本点的

声场分布数据,并对数据进行预处理,利用第二精度样本点声场分布数据对第一精度样本点声场分布数据进行扩充,获取训练数据集;

[0010] S5:构建变可信度神经网络模型,并根据训练数据集对变可信度神经网络模型进行训练;变可信度神经网络模型通过学习第一精度样本点声场分布数据与第二精度样本点声场分布数据之间的线性或者非线性关系,第二精度样本点声场分布数据提供趋势信息,用第一精度样本点声场分布数据对预测值进行校正,来融合不同精度的样本点声场分布数据,从而提高神经网络模型的预测精度;

[0011] S6:利用训练后的变可信度神经网络模型对声学超表面声场进行快速预测。

[0012] 在以上技术方案的基础上,优选的,变可信度神经网络模型的真实值数学表示形式为: $y_H = \alpha F_l(x, y_L) + (1 - \alpha) F_{nl}(x, y_L)$, $\alpha \in [0, 1]$;其中, y_H 为变可信度神经网络模型的第一精度真实值; y_L 为变可信度神经网络模型的第二精度真实值; x 为给定输入; $F_l(x, y_L)$ 为变可信度神经网络模型的线性子网络基于给定输入和第二精度真实值的输出结果,用于学习第二精度样本点声场分布数据与第一精度样本点声场分布数据之间的线性关系; $F_{nl}(x, y_L)$ 为变可信度神经网络模型的非线性子网络基于给定输入和第二精度真实值的输出结果,用于学习第二精度样本点声场分布数据与第一精度样本点声场分布数据之间的非线性关系; α 和 $1 - \alpha$ 分别为线性子网络的输出结果和非线性子网络的输出结果的权值, $\alpha \in [0, 1]$;

[0013] 步骤S5中所述构建变可信度神经网络模型,该变可信度神经网络模型包括三个部分,第二精度预测部分 NN_L 、线性子网络 F_l 和非线性子网络 F_{nl} ;构建变可信度神经网络的流程为:

[0014] S501:给定输入 x ,给定输入为长度 $2m$ 的向量;

[0015] S502:构建第二精度预测部分 NN_L ,其输入神经元个数为 $2m$,通过全连接层、卷积层和池化层提取输入特征并输出预测声场,得到变可信度神经网络模型的第二精度输出的预测结果 \hat{y}_L ;

[0016] S503:将给定输入 x 和变可信度神经网络模型的第二精度输出的预测结果 \hat{y}_L 拼接成新的输入 $\{x, \hat{y}_L\}$;

[0017] S504:构建线性子网络 F_l 部分,此部分网络不添加非线性激活函数,通过全连接层、卷积层和池化层提取新的输入 $\{x, \hat{y}_L\}$ 特征,并输出线性子网络预测结果 $F_l(x, \hat{y}_L)$;

[0018] S505:构建非线性子网络部分 F_{nl} ,此部分网络添加非线性激活函数,通过全连接层、卷积层和池化层提取新的输入 $\{x, \hat{y}_L\}$ 特征,并输出非线性子网络预测结果

$F_{nl}(\mathbf{x}, \hat{y}_L)$;

[0019] S 5 0 6 : 变可信度神经网络的第一精度输出的预测结果 \hat{y}_H 为 $\hat{y}_H = \alpha F_l(\mathbf{x}, \hat{y}_L) + (1 - \alpha) F_{nl}(\mathbf{x}, \hat{y}_L)$; α 和 $1 - \alpha$ 分别为线性子网络 F_l 和非线性子网络 F_{nl} 的权值, $\alpha \in [0, 1]$ 。

[0020] 优选的,非线性激活函数为relu函数或者tanh函数。

[0021] 优选的,步骤S2中根据待预测声学超表面的设计变量,建立声学超表面的有限元模型,并进一步建立声学超表面的第一精度有限元模型和第二精度有限元模型,具体是:将声学超表面放置于一矩形平板的上表面,声学超表面具有矩形的边界;首先建立声学超表面及矩形平板的有限元模型,采用三角形非结构网格对该有限元模型进行网格划分;进一步对声学超表面所在区域的网格进行加密处理,并满足网格一致收敛性条件,得到声学超表面的第一精度有限元模型;声学超表面的第二精度有限元模型是在声学超表面的第一精度有限元模型的基础上,保持声学超表面区域网格尺寸不变,将有限元模型的非声学超表面区域的网格尺寸放大得到。

[0022] 优选的,步骤S3中所述采用拉丁超立方采样法,获取第一精度有限元模型对应的第一精度样本点,以及第二精度有限元模型对应的第二精度样本点,是在设计变量的个数 n 的范围内,采用拉丁超立方采样法在设计变量范围内生成 n_l 个第二精度样本点,从生成的 n_l 个第二精度样本点中随机选取 n_h 个作为第一精度样本点。

[0023] 优选的,步骤S4所述的通过有限元模型批量化仿真,获取各个第一精度样本点及第二精度样本点的声场分布数据,并对数据进行预处理,利用第二精度样本点声场分布数据对第一精度样本点声场分布数据进行扩充,获取训练数据集,是将声学超表面的有限元模型划分为 $M \times N$ 的规则栅格矩阵,通过插值获得每个栅格点的声压值,对于栅格位于超表面或者实体上的点,其声压值设定为0;通过有限元分析软件自带的批量化仿真,得到每个第二精度样本点或者第一精度样本点在每个栅格点处的声压值,共获得 n_l 个 $M \times N$ 维度的第二精度样本点声场分布数据构成的第二精度数据集,以及 n_h 个 $M \times N$ 维度的第一精度样本点声场分布数据;第一精度样本点声场分布数据如果少于第二精度样本点声场分布数据的个数,则将第一精度样本点声场分布数据中缺失的部分用对应位置的第二精度样本点声场分布数据进行扩充,直到第一精度样本点声场分布数据的数量与第二精度样本点声场分布数据的数量相等,得到第一精度数据集;第二精度数据集与第一精度数据集构成了训练数据集。

[0024] 优选的,步骤S5中所述对变可信度神经网络模型进行训练,还包括对变可信度神经网络模型训练的损失函数进行设置;变可信度神经网络模型训练时的损失函数 L 为:

$L = \beta_l^L \gamma \|y_l^L - y_L\| + \beta_l^H (1 - \gamma) \|y_l^H - y_H\|$; 其中 y_l^L 为变可信度神经网络模型的第

i 次给定输入的第二精度预测结果; y_i^H 为变可信度神经网络模型的第 i 次给定输入的第一精度预测结果; y_H 为变可信度神经网络模型的第一精度真实值; y_L 为变可信度神经网络模型的第二精度真实值; $\|\cdot\|$ 为二阶范数误差符号; $\|y_i^L - y_L\|$ 为第二精度损失,即变可信度神经网络模型的第二精度预测值与第二精度真实值之差的二阶范数误差; $\|y_i^H - y_H\|$ 为第一精度损失,即变可信度神经网络模型的第一精度预测值与第一精度真实值之差的二阶范数误差; γ 和 $1 - \gamma$ 分别为第二精度损失和第一精度损失的权值, $\gamma \in [0, 1]$; β_i^L 为第一精度数据集中来源于第二精度样本点声场分布数据的权值, β_i^H 为第一精度数据集中来源于自有第一精度样本点声场分布数据的权值, β_i^H 与 β_i^L 用于区分第一精度数据集中的样本点声场分布数据来源, $\beta_i^L, \beta_i^H \in [0, 1]$ 。

[0025] 本发明提供的基于变可信度神经网络的声学超表面声场快速预测方法,相对于现有技术,具有以下有益效果:

[0026] (1)本方案能够通过第二精度子网络部分提取第二精度数据的特征,通过两个线性和非线性子网络部分分别学习高第二精度数据之间的线性和非线性关系,从而有效利用不同精度的数据来提高神经网络模型的预测精度,两个子网络的输出加权之和即为第一精度预测结果,本方案可以降低对第一精度数据的需求,降低数据集构建成本;

[0027] (2)本方案能够以较低的数据成本构建精度较高的神经网络模型,同时利用神经网络快速预测的优点,实现对不同物性参数声学超表面声场分布的快速预测,从而提高超表面设计效率。

附图说明

[0028] 为了更清楚地说明本发明实施例或现有技术中的技术方案,下面将对实施例或现有技术描述中所需要使用的附图作简单地介绍,显而易见地,下面描述中的附图仅仅是本发明的一些实施例,对于本领域普通技术人员来讲,在不付出创造性劳动的前提下,还可以根据这些附图获得其他的附图。

[0029] 图1为本发明基于变可信度神经网络的声学超表面声场快速预测方法的流程图;

[0030] 图2为本发明基于变可信度神经网络的声学超表面声场快速预测方法的一种声学超表面模型的示意图;

[0031] 图3为本发明基于变可信度神经网络的声学超表面声场快速预测方法的第一精度模型与第二精度模型的有限元网格划分示意图;

[0032] 图4为本发明基于变可信度神经网络的声学超表面声场快速预测方法的预测散射声场示意图;

[0033] 图5为本发明基于变可信度神经网络的声学超表面声场快速预测方法的一种变可信度神经网络模型的结构图。

具体实施方式

[0034] 下面将结合本发明实施方式,对本发明实施方式中的技术方案进行清楚、完整地描述,显然,所描述的实施方式仅仅是本发明一部分实施方式,而不是全部的实施方式。基于本发明中的实施方式,本领域普通技术人员在没有做出创造性劳动前提下所获得的所有其他实施方式,都属于本发明保护的范围。

[0035] 如图1—3所示,本发明提供了本发明提供了基于变可信度神经网络的声学超表面声场快速预测方法,包括如下步骤:

[0036] S1:获取待预测声学超表面的几何特征、设计变量及其变化范围,以及待预测声场信息;所述声学超表面的几何特征为厚度方向小于入射声波波长的结构,其被均分为 m 个单元,每个单元具有不同的密度和弹性模量属性值;所述设计变量为单元密度 ρ 与单元弹性模量 E ,设计变量个数 $n = 2m$;所述待预测声场信息为超表面周围均匀分布的采样点的声压值;

[0037] S2:根据待预测声学超表面的设计变量,建立声学超表面的有限元模型,并进一步建立声学超表面的第一精度有限元模型和第二精度有限元模型;

[0038] 本步骤的具体内容是:将声学超表面放置于一矩形平板的上表面,声学超表面具有矩形的边界;首先建立声学超表面及矩形平板的有限元模型,采用三角形非结构网格对该有限元模型进行网格划分;进一步对声学超表面所在区域的网格进行加密处理,并满足网格一致收敛性条件,得到声学超表面的第一精度有限元模型;声学超表面的第二精度有限元模型是在声学超表面的第一精度有限元模型的基础上,保持声学超表面区域网格尺寸不变,将有限元模型的非声学超表面区域的网格尺寸放大一定倍数得到,放大倍数为正实数。可见第一精度有限元模型的精度高于第二精度有限元模型。

[0039] S3:采用拉丁超立方采样法,获取第一精度有限元模型对应的第一精度样本点,以及第二精度有限元模型对应的第二精度样本点;

[0040] 具体过程是:在设计变量的个数 n 的范围内,采用拉丁超立方采样法在设计变量范围内生成 N_1 个第二精度样本点,从生成的 N_1 个第二精度样本点中随机选取 N_h 个作为第一精度样本点。拉丁超立方采样法是一种从变量的分布区间进行高效采样的方法,对于本领域技术人员来说,拉丁超立方采样法是一种公知常识,在此不再赘述。本方案中,第一精度样本点或者第二精度样本点的数量通常可以根据设计变量的维度进行确定,本方案的设计变量具有单元密度和单元弹性模量两个维度。

[0041] S4:通过有限元模型批量化仿真,获取各个第一精度样本点及第二精度样本点的声场分布数据,并对数据进行预处理,利用第二精度样本点声场分布数据对第一精度样本点声场分布数据进行扩充,获取训练数据集;

[0042] 具体内容是:本方案可采用有限元分析软件COMSOL进行有限元仿真,通过自动化程序批量化仿真生成数据,得到每个样本点中每个网格端点处的声压值。数据预处理的程序是:将声学超表面的有限元模型划分为 $M \times N$ 的规则栅格矩阵,通过插值获得栅格矩阵的各栅格点的声压值,对于栅格位于超表面或者实体上的点,其声压值设定为0;通过有限元分析软件自带的批量化仿真,得到每个第二精度样本点或者第一精度样本点在每个栅

格点处的声压值,预处理后的各样本点声场分布数据表示为:

$$[0043] \quad \begin{bmatrix} M_{11} & M_{12} & \cdots & M_{1N} \\ M_{21} & M_{22} & \cdots & M_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ M_{M1} & M_{M2} & \cdots & M_{MN} \end{bmatrix}, \text{该声场分布数据中的每个元素对应了每个栅格点的}$$

声压值。共可获得 n_l 个 $M \times N$ 维度的第二精度样本点声场分布数据构成的第二精度数据集,以及 n_h 个 $M \times N$ 维度的第一精度样本点声场分布数据;第一精度样本点声场分布数据如果少于第二精度样本点声场分布数据的个数,则将第一精度样本点声场分布数据中缺失的部分用对应位置的第二精度样本点声场分布数据进行扩充,直到第一精度样本点声场分布数据的数量与第二精度样本点声场分布数据的数量相等,得到第一精度数据集;第二精度数据集与第一精度数据集构成了训练数据集。

[0044] 这部分被第二精度样本点声场分布数据扩充的第一精度样本点声场分布数据可称为“伪第一精度”数据,为了区分第一精度数据集中样本点声场分布数据的实际来源,可以进一步将自有的第一精度声场数据,以及从第二精度声场数据中扩充而来的第一精度声场分别添加权重。

[0045] S5: 构建变可信度神经网络模型,并根据训练数据集对变可信度神经网络模型进行训练;变可信度神经网络模型通过学习第一精度样本点声场分布数据与第二精度样本点声场分布数据之间的线性或者非线性关系,第二精度样本点声场分布数据提供趋势信息,用第一精度样本点声场分布数据对预测值进行校正,来融合不同精度的样本点声场分布数据,从而提高神经网络模型的预测精度;

[0046] 变可信度神经网络模型包括三个部分,第二精度预测部分 NN_L 、线性子网络 F_l 和非线性子网络 F_n ;构建变可信度神经网络的具体流程为:

[0047] S501: 给定输入 \mathbf{x} , 给定输入为长度 $2m$ 的向量;每一个给定输入 \mathbf{x} 都有对应的第二精度样本点和第一精度样本点;当然,这里的第一精度样本点,既有自有部分第一精度样本点声场分布数据对应的第一精度样本点,也有从第二精度声场数据中扩充而来的“伪第一精度”数据对应的第二精度样本点;

[0048] S502: 构建第二精度预测部分 NN_L , 其输入神经元个数为 $2m$, 通过全连接层、卷积层和池化层提取输入特征并输出预测声场,得到变可信度神经网络模型的第二精度输出的预测结果 \hat{y}_L ;

[0049] S503: 将给定输入 \mathbf{x} 和变可信度神经网络模型的第二精度输出的预测结果 \hat{y}_L 拼接成新的输入 $\{\mathbf{x}, \hat{y}_L\}$;

[0050] S504: 构建线性子网络 F_l 部分,此部分网络不添加非线性激活函数,通过全连接层、卷积层和池化层提取新的输入 $\{\mathbf{x}, \hat{y}_L\}$ 特征,并输出线性子网络预测结果 $F_l(\mathbf{x}, \hat{y}_L)$;

[0051] S505: 构建非线性子网络部分 F_{nl} , 此部分网络添加非线性激活函数, 通过全连接层、卷积层和池化层提取新的输入 $\{\mathbf{x}, \hat{y}_L\}$ 特征, 并输出非线性子网络预测结果 $F_{nl}(\mathbf{x}, \hat{y}_L)$;

[0052] S506: 变可信度神经网络的第一精度输出的预测结果 \hat{y}_H 为 $\hat{y}_H = \alpha F_l(\mathbf{x}, \hat{y}_L) + (1 - \alpha) F_{nl}(\mathbf{x}, \hat{y}_L)$; α 和 $1 - \alpha$ 分别为线性子网络 F_l 和非线性子网络 F_{nl} 的权值, $\alpha \in [0, 1]$ 。

[0053] 全连接层、卷积层、池化层以及非线性激活函数均是本领域惯用术语。上述步骤中的非线性激活函数可以是relu函数或者tanh函数。

[0054] 变可信度神经网络模型的真实值数学表示形式为:

$y_H = \alpha F_l(x, y_L) + (1 - \alpha) F_{nl}(x, y_L)$, $\alpha \in [0, 1]$; 其中, y_H 为变可信度神经网络模型的第一精度真实值; y_L 为变可信度神经网络模型的第二精度真实值; x 为给定输入; $F_l(x, y_L)$ 为变可信度神经网络模型的线性子网络基于给定输入和第二精度真实值的输出结果, 用于学习第二精度样本点声场分布数据与第一精度样本点声场分布数据之间的线性关系; $F_{nl}(x, y_L)$ 为变可信度神经网络模型的非线性子网络基于给定输入和第二精度真实值的输出结果, 用于学习第二精度样本点声场分布数据与第一精度样本点声场分布数据之间的非线性关系。该公式与S506的公式结构类似, 由S506的公式和上式可知, 对变可信度神经网络模型进行训练的过程, 就是变可信度神经网络的第一精度输出的预测结果 \hat{y}_H 向变可信度神经网络模型的第一精度真实值 y_H 逐步逼近的过程。

[0055] 作为本方案的一种优选实施方式, 在对变可信度神经网络训练时, 由于变可信度神经网络既有第一精度输出, 又有第二精度输出, 因此第一精度与第二精度输出的损失均需被考虑。令变可信度神经网络模型训练时的损失函数 L 为:

$L = \beta_i^L \gamma \|y_i^L - y_L\| + \beta_i^H (1 - \gamma) \|y_i^H - y_H\|$; 其中 y_i^L 为变可信度神经网络模型的第 i 次给定输入的第二精度预测结果; y_i^H 为变可信度神经网络模型的第 i 次给定输入的第一精度预测结果; y_H 为变可信度神经网络模型的第一精度真实值; y_L 为变可信度神经网络模型的第二精度真实值; $\|\cdot\|$ 为二阶范数误差符号; $\|y_i^L - y_L\|$ 为第二精度损失, 即变可信度神经网络模型的第二精度预测值与第二精度真实值之差的二阶范数误差; $\|y_i^H - y_H\|$ 为第一精度损失, 即变可信度神经网络模型的第一精度预测值与第一精度真实值之差的二阶范数误差; γ 和 $1 - \gamma$ 分别为第二精度损失和第一精度损失的权值,

$\gamma \in [0, 1]$; β_i^L 为第一精度数据集中来源于第二精度样本点声场分布数据的权值, β_i^H 为第一精度数据集中来源于自有第一精度样本点声场分布数据的权值, β_i^H 与 β_i^L 用于区分第一精度数据集中的样本点声场分布数据来源, β_i^L 、 $\beta_i^H \in [0, 1]$ 。

[0056] S6:利用训练后的变可信度神经网络模型对声学超表面声场进行快速预测。

[0057] 利用所构建的变可信度神经网络,只要给定任意设计变量范围内的给定输入,就能得到相应的预测声场,从而实现超表面声场快速预测。

[0058] 为了更加全面直观的说明本发明的技术方案,如图2所示,该图展示了应用于超表面散射声场的一个实施例。从图2可以看出,入射声波沿着铅垂方向竖直朝下入射,背景介质为水,仿真区域边界为平面波辐射条件,超表面区域被均分为25个单元,故 $m=25$,设计变量个数为50,密度范围为 $1/3-2\text{kg}/\text{m}^3$;弹性模量范围为 $1/3 \times 2.25 \times 10^6-6 \times 2.25 \times 10^6 \text{N}/\text{m}^2$ 。声学超表面位于挡板的上表面。

[0059] 如图3为所示为第一精度模型和第二精度模型有限元网格划分示意图左图为高精度模型,即第一精度模型的有限元网格划分示意图;右图为低精度模型,即第二精度模型的有限元网格划分示意图。建立声学超表面、挡板和背景的有限元模型;采用三角形非结构网格对有限元模型进行网格划分,超表面区域网格最大尺寸为0.02m,第一精度模型其他区域最大网格尺寸为0.1m,第二精度模型其他区域最大网格尺寸为1.5m。

[0060] 本实施例中,采用拉丁超立方采样法在设计变量范围内获取500个采样点,作为第二精度样本点,从中随机选取50个作为第一精度样本点。

[0061] 如图4所示为实施例中待预测散射声场示意图,将仿真区域划分为 48×64 维的规则栅格,通过插值获得每个点处的散射声压值,对于位于超表面和挡板等固体区域的点,其声压值设定为0,通过MATLAB程序脚本批量化仿真生成500个第二精度数据和50个第一精度数据。

[0062] 本实施例中,所构建的变可信度神经网络模型由全连接层、卷积层、上采样层、池化层组成,采用relu激活函数。图5为网络结构图,输入设计变量参数经全连接、卷积和上采样层提取特征后得到 48×64 维的输出矩阵,此为第二精度输出。然后通过卷积、下采样层提取第二精度输出的特征,并与输入拼接为新的向量输入给两个并行的子网络,两个子网络结构一致,均由卷积核上采样层组成,上部分子网络无非线性激活函数,用于学习高第二精度数据之间的线性关系;下半部分子网络含有非线性激活函数,用于学习高第二精度数据之间的非线性关系。两个子网络的输出加权和即为最终的第一精度预测结果。图5下方的图例依次代表向量维度转换、卷积、池化、上采样或者向量拼接的处理步骤。

[0063] 需要说明的是,本说明书给出的具体实施例仅为示意的,并不构成本发明具体实施案例的唯一限定,对本领域技术人员而言,可在本发明提供的实施例的基础下,同理采用上述提供的基于变可信度神经网络模型的超表面散射声场快速预测方法,实现对不同超表面散射声场分布的快速预测。

[0064] 为了更好地展示所提出的基于变可信度神经网络的声学超表面声场快速预测方法的优点,本实施例同时采用应用广泛的迁移学习法、基于高斯过程的多精度神经网络以及仅采用第一精度数据的单精度神经网络以及仅采用第二精度数据的单精度神经网络进

行对比。对比方法的模型结构与图5中第二精度网络部分保持一致。采用RMSE、MMAE和RE为全局误差和局部误差的评价准则,其计算公式为:

$$[0065] \quad MAE = \frac{1}{N_{samples}} \sum_{i=1}^{N_{samples}} mean(|y_i - \hat{y}_i|);$$

$$[0066] \quad MMAE = \frac{1}{N_{samples}} \sum_{i=1}^{N_{samples}} \max|y_i - \hat{y}_i|;$$

$$[0067] \quad RE = \frac{\|y_i - \hat{y}_i\|}{\|y_i\|};$$

其中 $N_{samples}$ 为测试样本点总数; y_i 和 \hat{y}_i 分别为第i个测试

样本点的真实散射声场和预测散射声场;最终的对比结果如下。

模型	MAE	MMAE	RE(%)		
			平均	最大	最小
变可信度神经网络	0.0794	0.5548	20.55	36.20	11.73
基于高斯过程	0.0980	0.5799	21.33	38.38	11.48
迁移学习	0.0859	0.5770	21.52	41.78	11.73
第二精度	0.1005	0.6315	25.81	41.26	17.19
第一精度	0.1253	0.7614	31.55	55.42	19.53

[0069] 从表中可以看出,采用所提出方法对超表面声场进行预测,无论是全局精度和局部精度,相较于常规的单精度模型和迁移学习、基于高斯过程神经网络等模型都有一定的提升。

[0070] 以上所述仅为本发明的较佳实施方式而已,并不用以限制本发明,凡在本发明的精神和原则之内,所作的任何修改、等同替换、改进等,均应包含在本发明的保护范围之内。

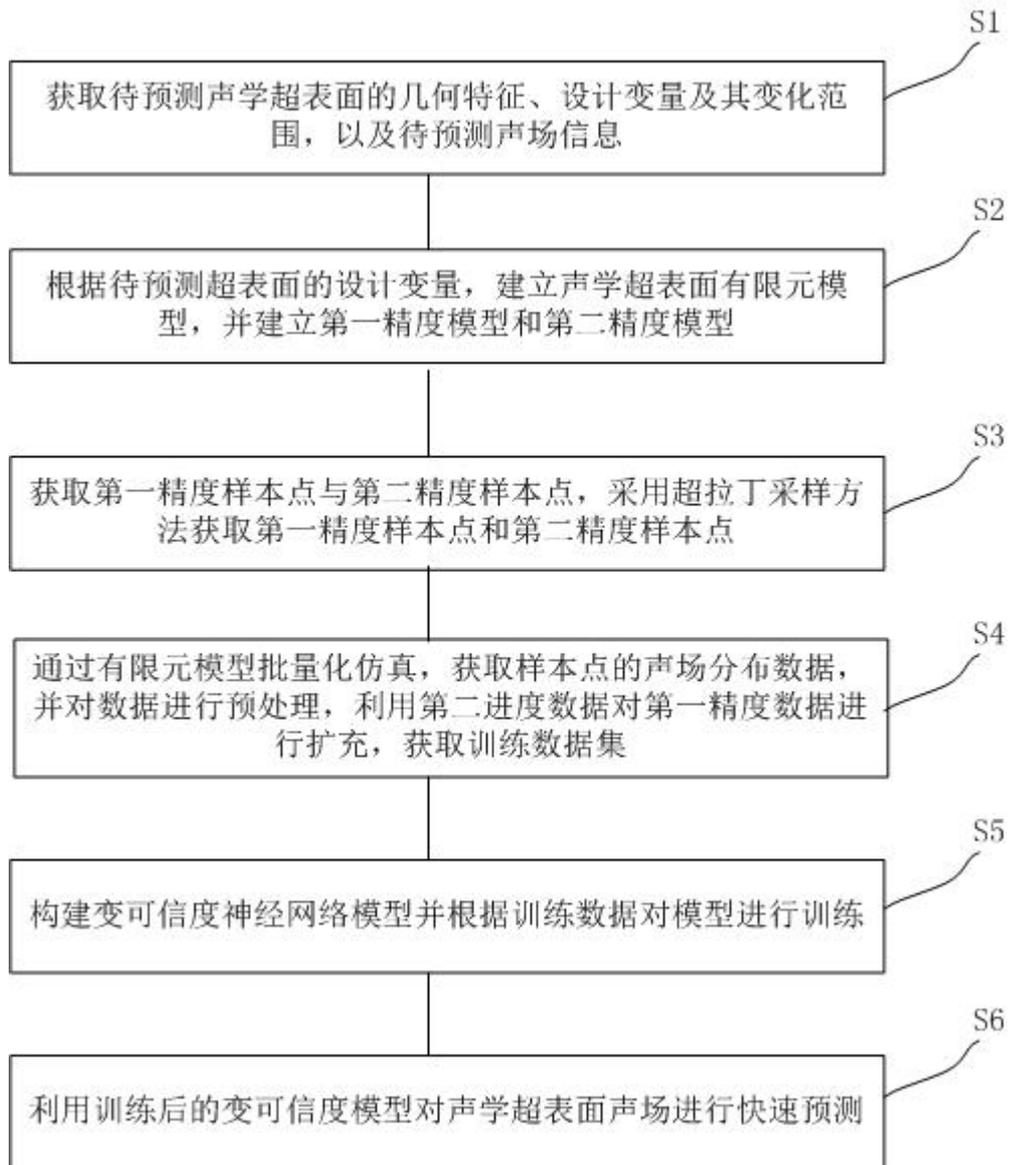


图1

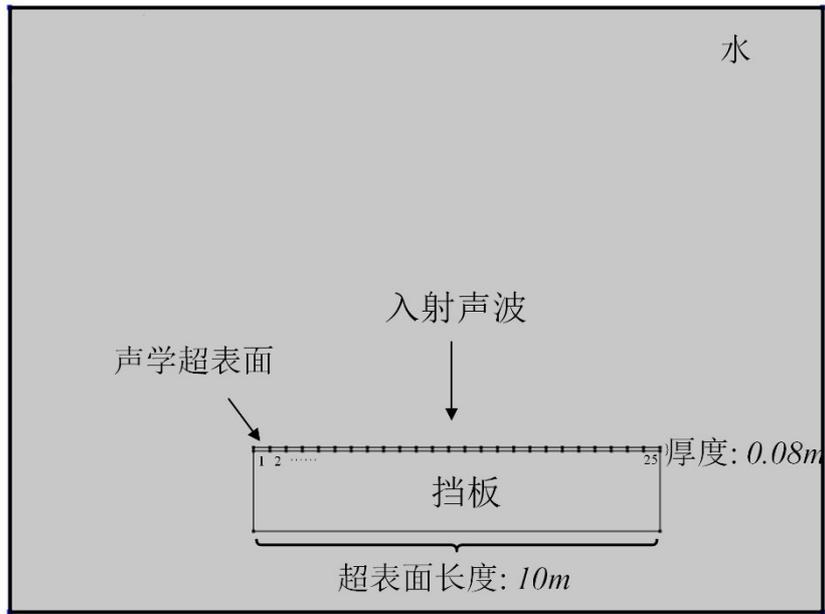


图2

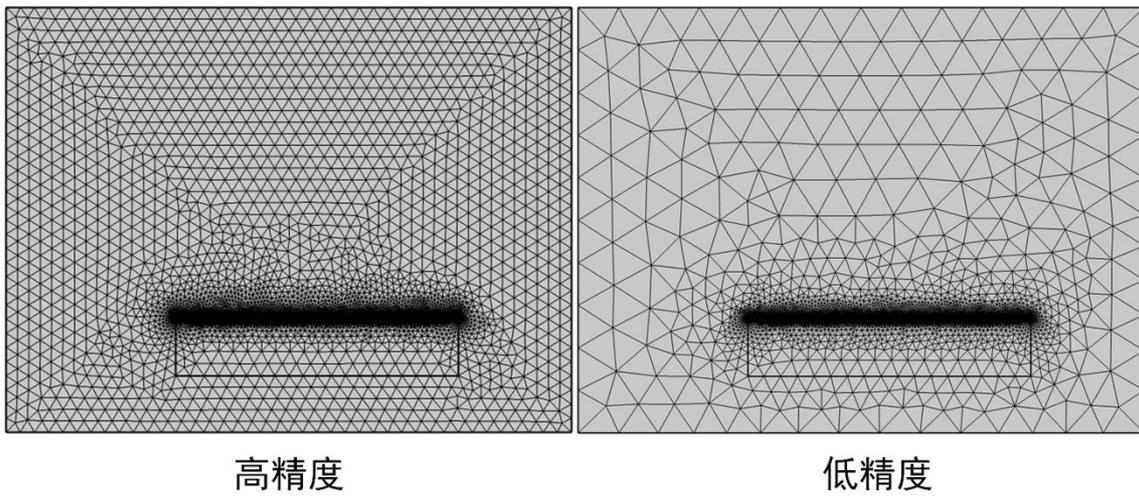


图3

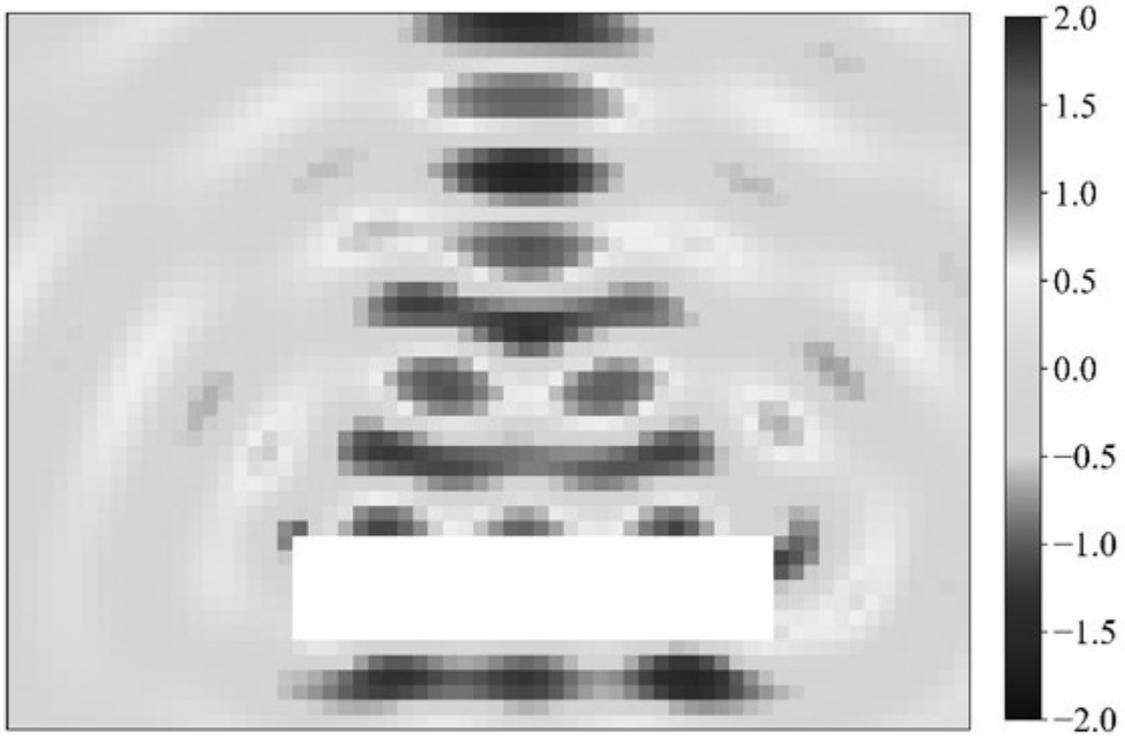


图4

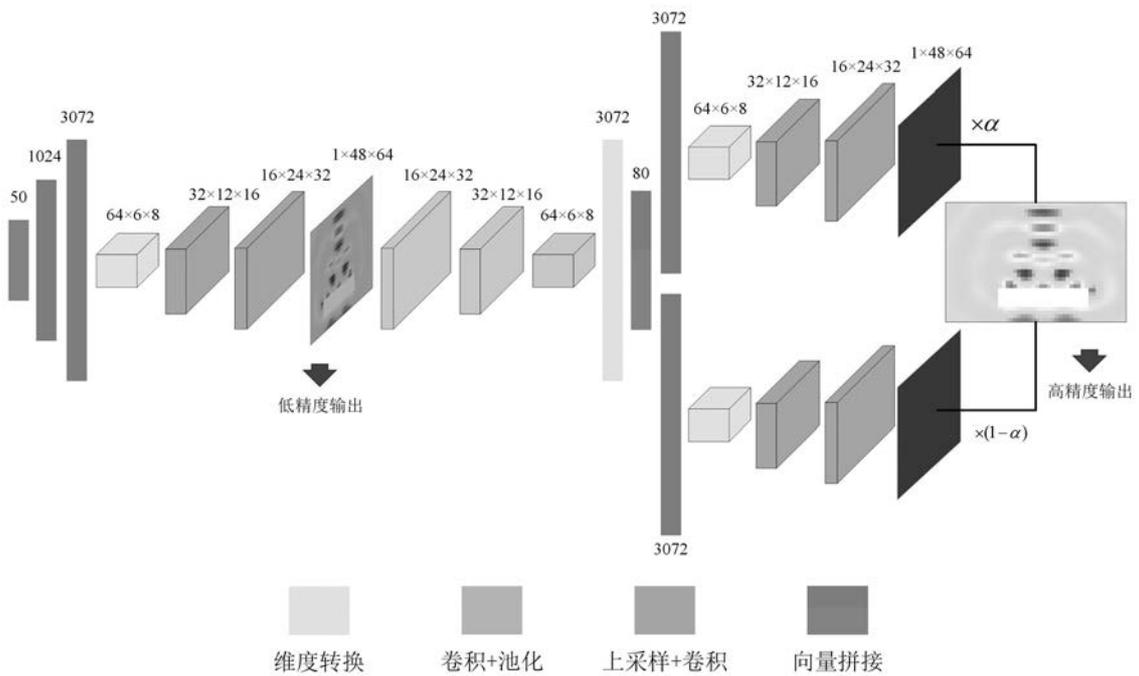


图5