



(12) 发明专利申请

(10) 申请公布号 CN 114239114 A

(43) 申请公布日 2022. 03. 25

(21) 申请号 202111572929.8

(22) 申请日 2021.12.21

(71) 申请人 浙江工业大学台州研究院

地址 318057 浙江省台州市椒江区滨海工
业区海丰路2479号

(72) 发明人 彭翔 邵宇杰 李吉泉 姜少飞

(74) 专利代理机构 杭州求是专利事务有限公
司 33200

代理人 林超

(51) Int. Cl.

G06F 30/13 (2020.01)

G06F 30/23 (2020.01)

G06F 30/27 (2020.01)

G06N 3/04 (2006.01)

G06N 3/08 (2006.01)

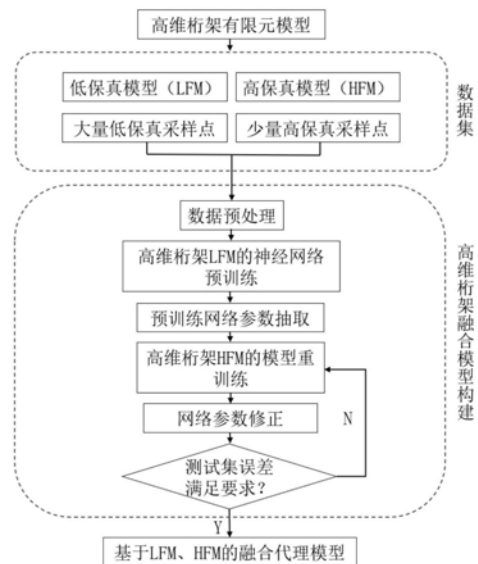
权利要求书2页 说明书4页 附图6页

(54) 发明名称

一种基于迁移学习融合模型的桁架应力预测及轻量化方法

(57) 摘要

本发明公开了一种基于迁移学习融合模型的桁架应力预测及轻量化方法。以横截面积和材料为设计参数,不确定性量化建立源数据集;输入构建有限元模型得低高保真模型;对低高保真模型进行随机采样,获得保真点,构建获得目标数据;将低保真模型的数据输入到深度神经网络DNN模型初步训练确定模型参数;保留前n-1层初始化最后一层,将高保真模型的数据再次训练修正,优化网络节点数得到融合代理模型;将实际数据输入到融合代理模型处理输出目标数据。本发明通过低保真采样点预训练深度神经网络,保证了深度神经网络泛化能力同时降低了构建成本,在高保真采样点数量较少时,也能构建高精度的代理模型,提高了桁架结构轻量化设计的可靠性。



1. 一种基于迁移学习融合模型的桁架应力预测及轻量化方法,其特征在于:

1) 针对多杆桁架,选择以横截面积和材料作为设计参数,对多杆桁架的设计参数进行不确定性量化,建立源数据集;

2) 将步骤1)获得的源数据集输入构建多杆桁架的有限元模型,获得低保真模型(LFM)和高保真模型(HFM);

3) 针对低保真模型和高保真模型进行随机采样,获得低保真模型中的 m 个低保真点和高保真模型中的 n 个高保真点,构建获得目标数据;

4) 构建深度神经网络DNN模型,将低保真模型的源数据集和目标数据输入到深度神经网络DNN模型进行初步训练确定模型参数 $\theta = \{W^{(j)}, b^{(j)}\}^{L+1}$;

5) 根据4)确定模型参数 $\theta = \{W^{(j)}, b^{(j)}\}^{L+1}$ 后的深度神经网络DNN模型,保留其中前 $n-1$ 层的网络结构, n 表示为深度神经网络DNN模型中的层总数,初始化最后一层的网络结构中的参数;

将高保真模型的源数据集和目标数据输入再次进行训练,对最后一层网络结构的参数修正,比较不同网络节点数对模型精度的影响,在设定范围内获取最优的网络节点数量,得到应用于桁架的融合代理模型;

6) 在得到的融合代理模型后,将实际的多杆桁架的横截面积和材料输入到融合代理模型处理输出目标数据,用于表征应力预测结果和桁架节点的位移,再通过遗传优化算法在满足节点位移的约束下实现多杆桁架的最优设计。

2. 根据权利要求1所述的一种基于迁移学习融合模型的桁架应力预测及轻量化方法,其特征在于:所述1)中,不确定性量化具体是设置杆件的横截面积符合正态分布 $A_i \sim N(10^{-4}, 10^{-5})$,预先选择三种备选材料。

3. 根据权利要求1所述的一种基于迁移学习融合模型的桁架应力预测及轻量化方法,其特征在于:所述2)具体为,

将不确定性量化后的设计参数输入和较大的网格尺寸使用粗网格多杆桁架有限元模型,构建获得低保真模型;

将不确定性量化后的设计参数输入和较小的网格尺寸使用细网格多杆桁架有限元模型,构建获得高保真模型。

4. 根据权利要求1所述的一种基于迁移学习融合模型的桁架应力预测及轻量化方法,其特征在于:所述4)中的深度神经网络DNN模型是由多个隐藏层组成的神经网络,神经网络每一层都包含不同的参数,并连接到下一层,通过激活函数将第 j 层的输入转化为输出信号,第 j 个隐藏层计算为:

$$z^{(j)} = f(W^{(j)}z^{(j-1)} + b^{(j)}), \forall j \in \{1, 2, \dots, L\}$$

其中, $W^{(j)}$, $b^{(j)}$ 分别是在深度神经网络DNN模型的权值和偏差, j 表示隐藏层位置, $z^{(j)}$ 表示第 j 个隐藏层的输出, L 表示隐藏层的数量, $f()$ 是激活函数。

5. 根据权利要求1所述的一种基于迁移学习融合模型的桁架应力预测及轻量化方法,其特征在于:在所述4)训练过程中,使用损失函数进行比较优化,为输出层中的每个神经元计算误差值,通过最小化损失函数来获得模型参数 θ ,模型参数 θ 包含权值 $W^{(j)}$ 和偏差 $b^{(j)}$,损失函数计算为:

$$E(\theta) = \frac{1}{N} \sum_{i=1}^N E_i = \frac{1}{N} \sum_{i=1}^N (y_i^D - \hat{f}(x_i^D; \theta))^2$$

其中, $E(\theta)$ 表示对应 θ 下的最终损失函数输出值, i 表示训练数据的序数, E_i 表示第 i 组训练数据对应的损失函数值, N 表示训练数据的总组数, y_i^D 表示第 N 组训练数据的真实输出值, $\hat{f}()$ 表示第 N 组训练数据的预测输出值, x_i^D 表示第 N 组训练数据的真实输入值;

最小化损失函数时使用随机梯度下降算法来优化求解获得深度神经网络DNN模型的权值 $W^{(j)}$ 和偏差 $b^{(j)}$ 的参数, 通过自适应矩Adam算法进行参数更新。

6. 根据权利要求1所述的一种基于迁移学习融合模型的桁架应力预测及轻量化方法, 其特征在于: 通过遗传优化算法, 在满足节点位移的约束下, 实现多杆桁架的最优设计, 具体按照以下公式计算:

$$M = L_1 \rho A_1^2 + L_2 \rho A_2^2 + L_3 \rho A_3^2 + \dots + L_i \rho A_i^2$$

其中, M 表示桁架总质量, i 表示第 i 组杆组, L_i 表示第 i 组杆组的长度, A_i 表示第 i 组杆组的横截面积, ρ 表示材料密度。

一种基于迁移学习融合模型的桁架应力预测及轻量化方法

技术领域

[0001] 本发明涉及桁架有限元处理方法,特别是一种基于迁移学习融合模型对桁架节点目标参数进行预测及轻量化设计方法。

背景技术

[0002] 桁架结构,是一种高性能结构,便于结构设计。由于桁架结构特殊的优点,使其广泛应用于高铁、机场、桥梁等建筑物中。随着有限元分析方法、优化算法和计算机技术的应用,多杆桁架结构优化设计的研究也取得了巨大发展。参数空间维度高、搜索量大、局部最优点众多为高维桁架结构不确定性分析带来了挑战。同时,大多数现有的代理建模技术无法扩展到高维问题,训练样本数量随着输入维度的增长呈指数增长。

发明内容

[0003] 本发明的目的在于解决多杆桁架在设计参数维数较高,普通代理模型精度不高的问题,提供了一种基于迁移学习的桁架结构融合代理模型构建方法,并实现桁架的轻量化设计。

[0004] 为实现上述目的,如图1所示,本发明的技术方案如下:

[0005] 1) 针对多杆桁架,选择以横截面积和材料作为设计参数,对多杆桁架的设计参数进行不确定性量化,建立源数据集;

[0006] 多杆桁架是由杆件连接搭建而成,每根杆分别单独设置横截面积和材料,不同的杆件可以设置不同的横截面积、材料,也可以设置相同的横截面积和材料。

[0007] 2) 将步骤1)获得的源数据集输入构建多杆桁架的有限元模型,获得低保真模型(LFM)和高保真模型(HFM);

[0008] 3) 针对低保真模型和高保真模型进行随机采样,获得低保真模型中的 m 个低保真点和高保真模型中的 n 个高保真点,构建获得目标数据;低保真点和高保真点中包含了应力的数据,能够用于表征应力和桁架节点的位移。

[0009] 所述3)中,低保真点的个数远远大于高保真点的个数,具体是大于十倍以上。

[0010] 4) 构建深度神经网络DNN模型,将低保真模型的源数据集和目标数据输入到深度神经网络DNN模型进行初步训练确定模型参数 $\theta = \{w^{(j)}, b^{(j)}\}^{L+1}$,初始化DNN;

[0011] 5) 根据4)确定模型参数 $\theta = \{w^{(j)}, b^{(j)}\}^{L+1}$ 后的深度神经网络DNN模型,保留其中前 $n-1$ 层的网络结构, n 表示为深度神经网络DNN模型中的层总数,初始化最后一层的网络结构中的参数,参数为权值和偏差;

[0012] 将高保真模型的源数据集和目标数据输入再次进行训练,对最后一层网络结构的参数修正,比较不同网络节点数对模型精度的影响,在设定范围内获取最优的网络节点数量,得到应用于桁架的融合代理模型;

[0013] 具体实施中,计算融合代理模型的误差。通过计算测试集的预测值与真实值的均方根误差RRMSE和 R^2 评估模型精度。

[0014] 6) 在得到满足精度要求的融合代理模型后,将实际的多杆桁架的横截面积和材料输入到融合代理模型处理输出目标数据,用于表征应力预测结果和桁架节点的位移,再通过遗传优化算法在满足节点位移的约束下实现多杆桁架的最优设计,即实现轻量化。

[0015] 所述1)中,不确定性量化具体是设置杆件的横截面积符合正态分布 $A_i \sim N(10^{-4}, 10^{-5})$,预先选择三种备选材料。具体实施中,三种备选材料分别为低合金钢Q235、普通结构钢Q345和45#。

[0016] 所述2)具体为,

[0017] 将不确定性量化后的设计参数输入和较大的网格尺寸使用粗网格多杆桁架有限元模型,构建获得低保真模型;具体实施的较小的网格尺寸为10cm。

[0018] 将不确定性量化后的设计参数输入和较小的网格尺寸使用细网格多杆桁架有限元模型,构建获得高保真模型。具体实施的较小的网格尺寸为0.1cm。

[0019] 本发明同时建立了低保真模型和高保真模型,高保真模型具有比低保真模型更高的模型精度,但低保真模型可以在更短时间内得到设计空间内的大量样本点,具有更高的模型计算效率。

[0020] 所述4)中的深度神经网络DNN模型是由多个隐藏层组成的神经网络,神经网络每一层都包含不同的参数,并连接到下一层,通过激活函数将第j层的输入转化为输出信号,第j个隐藏层计算为:

$$[0021] \quad z^{(j)} = f(W^{(j)}z^{(j-1)} + b^{(j)}), \forall j \in \{1, 2, \dots, L\}$$

[0022] 其中, $W^{(j)}$, $b^{(j)}$ 分别是在深度神经网络DNN模型训练之前的权值和偏差,j表示隐藏层位置, $z^{(j)}$ 表示第j个隐藏层的输出,L表示隐藏层的数量, $f(\cdot)$ 是激活函数。

[0023] 在深度神经网络DNN模型中,采用线性整流单元(ReLU)函数作为每一层的激活函数。

[0024] 在所述4)训练过程中,使用损失函数进行比较优化,为输出层中的每个神经元计算误差值,通过最小化损失函数来获得模型参数 θ ,模型参数 θ 包含权值 $W^{(j)}$ 和偏差 $b^{(j)}$,损失函数计算为:

$$[0025] \quad E(\theta) = \frac{1}{N} \sum_{i=1}^N E_i = \frac{1}{N} \sum_{i=1}^N (y_i^D - \hat{f}(x_i^D; \theta))^2$$

[0026] 其中, $E(\theta)$ 表示对应 θ 下的最终损失函数输出值,i表示训练数据的序数, E_i 表示第i组训练数据对应的损失函数值,N表示训练数据的总组数, y_i^D 表示第N组训练数据的真实输出值, $\hat{f}(\cdot)$ 表示第N组训练数据的预测输出值, x_i^D 表示第N组训练数据的真实输入值;

[0027] 最小化损失函数时使用随机梯度下降算法来优化求解获得深度神经网络DNN模型的权值 $W^{(j)}$ 和偏差 $b^{(j)}$ 的参数,通过自适应矩Adam算法进行参数更新。

[0028] 通过遗传优化算法,在满足节点位移的约束下,实现多杆桁架的最优设计,具体按照以下公式计算:

$$[0029] \quad M = L_1 \rho A_1^2 + L_2 \rho A_2^2 + L_3 \rho A_3^2 + \dots + L_i \rho A_i^2$$

[0030] 其中,M表示桁架总质量,i表示第i组杆组, L_i 表示第i组杆组的长度, A_i 表示第i组杆组的横截面积, ρ 表示材料密度。由此通过自适应遗传算法实现桁架轻量化。

[0031] 首先,本发明从大规模的低保真度数据集中提取源领域(Source Domain)的知识,构建预训练模型。然后,将学习到的知识转移到新模型中,用目标数据集的信息(小规模

高保真度数据集)进行重训练。最后,进行重训练网络超参数优化,使用超参数优化缓解过拟合,即学习率选择、动量因子、激活函数和节点数量。这样方法最终能降低将迁移学习用于机构可靠性分析的障碍。

[0032] 本发明的有益效果如下:

[0033] 1) 本发明从设计参数维数较高出发,在高保真采样点获取成本较高的问题上,运用迁移学习,通过低保真采样点预训练深度神经网络,保证了深度神经网络泛化能力的同时,降低了神经网络代理模型构建成本;

[0034] 2) 相较于传统代理模型,融合代理模型在保证低成本的同时,仍能实现较高的模型计算精度。在高保真采样点数量较少时,也能构建高精度的代理模型;

[0035] 3) 使用了迁移学习的思想,大大减小了设计人员与计算机的负担,大大提高了计算效率,提高了桁架结构轻量化设计的可靠性,也更加符合实际工程中的应用。

附图说明

[0036] 图1为本发明的方法流程图;

[0037] 图2为实施例的多杆桁架示意图;

[0038] 图3为融合模型与普通多感知机神经网络对比图;

[0039] 图4为融合模型节点数优化对比图;

[0040] 图5为融合模型激活函数优化对比图;

[0041] 图6为融合模型学习函数优化对比图;

[0042] 图7为10杆桁架结构示意图;

[0043] 图8为25杆桁架结构示意图;

[0044] 图9为72杆桁架结构示意图;

[0045] 图10为十杆桁架稀疏网格划分下的有限元分析云图;

[0046] 图11为十杆桁架精细网格划分下的有限元分析云图。

具体实施方式

[0047] 下面结合附图和具体实施对本发明作进一步说明。

[0048] 如图1所示,按照本发明完整方法实施的实施例及其实施情况如下:

[0049] 本实施例以10杆桁架为例,基于迁移学习思想的多保真度代理模型构建,此方法也可应用于25杆、72杆、200杆等多杆桁架结构。

[0050] 如图2所示是十杆桁架的例子,显示了该桁架的几何形状、载荷和支撑条件,材料密度和弹性模量分别为 $0.11\text{lb}/\text{in}^3$ ($2768.0\text{kg}/\text{m}^3$) 和 10000ksi (68950MPa),外加载荷 P_1 、 P_2 、 P_3 如图所示。

[0051] 在机器学习问题中,数据集分为两部分,训练集和测试集。前者是一组用于学习的示例,后者是一组仅用于评估泛化的新数据。

[0052] 在本发明中,十杆桁架融合模型构建的训练集由多杆桁架杆组的设计变量(横截面积、外加载荷)的随机分布生成,杆组的横截面积范围从 0.1 到 35.0in^2 (从 0.6 到 225.8cm^2),所有输入数据都相对于正则化的最大横截面积 35.0 进行了标准化。并根据有限元分析网格划分疏密不同(分别是以 0.1cm^2 和 10cm^2 作为基础网格进行划分),得到了1000

组低保真数据集和100组高保真数据集,用于训练神经网络。其中,网格划分方式及相应网格划分下的有限元分析示意图如图10、图11所示,图10表示十杆桁架稀疏网格划分下有限元分析云图,图11表示十杆桁架精细网格划分下有限元分析云图。用1000组低保真数据集进行了网络预训练,利用模型融合技术,保留了隐藏层前(n-1)层的网络参数,用100组高保真数据集进行重训练,最终得到了基于十杆桁架结构的融合模型。

[0053] 图3对比了模型融合方法(训练数据为1000组低保真数据集和100组高保真数据集)和普通多感知机神经网络(训练数据为1000组高保真数据集)方法随迭代次数增加模型精度逐渐提高的过程。可以看出模型融合方法在处理高保真数据集构建成本较高时,利用少量高保真数据集也能使模型融合的神经网络具有较高精确度和较好的泛化能力。此外还可以进行融合模型的超参数(节点数量、激活函数、学习函数)优化,图4、图5、图6对比了不同节点数、激活函数、学习函数对融合模型精度的影响,进一步提高了融合模型计算效率和准确性。并最终得到的融合模型为隐藏层节点数为25,激活函数为logsig,学习函数为trainlm时可以得到最优的融合模型。在该融合模型的指导下,运用遗传优化算法,在成本和节点位移的约束下,优化十杆桁架的设计参数,实现轻量化设计要求。此外,融合模型并不仅适用于十杆桁架的代理模型构建(图7所示),还适用于25杆、72杆等多杆桁架的代理模型构建,25杆、72杆的结构如图8、图9所示。

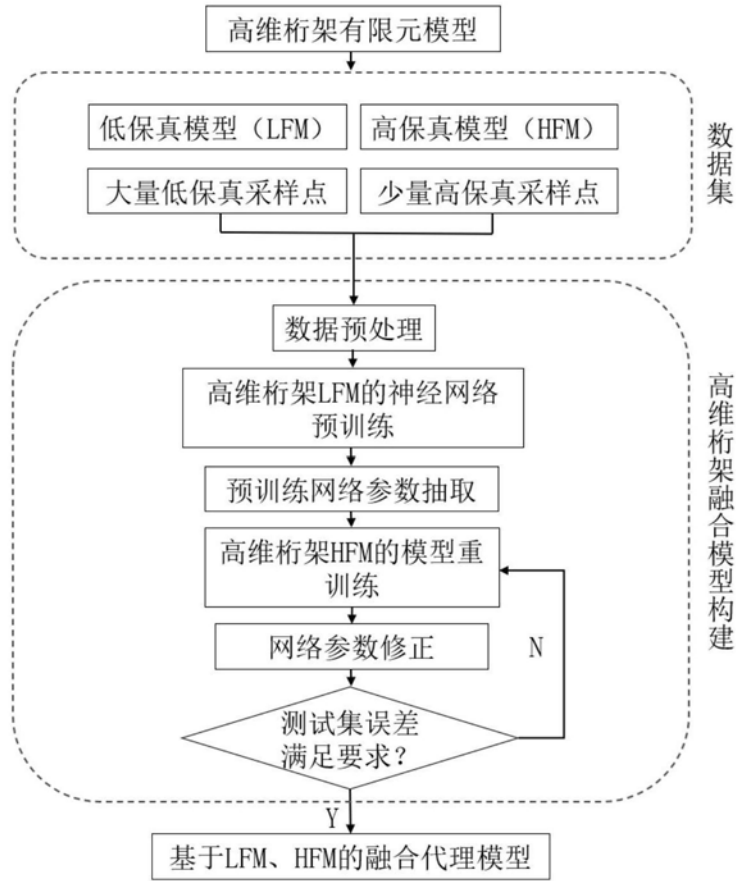


图1




图2




图3




图4




图5




图6




图7




图8




图9

A: 瞬态结构
总变形
类型: 总变形
单位: m





图10

A: 瞬态结构
总变形
类型: 总变形
单位: m





图11