



(12)发明专利申请

(10)申请公布号 CN 110045608 A

(43)申请公布日 2019.07.23

(21)申请号 201910261337.0

(22)申请日 2019.04.02

(71)申请人 太原理工大学

地址 030024 山西省太原市迎泽西大街79号

(72)发明人 丁华 杨亮亮 王义亮 高俊光 卢川川

(74)专利代理机构 太原晋科知识产权代理事务所(特殊普通合伙) 14110

代理人 任林芳

(51)Int.Cl.

G05B 13/04(2006.01)

权利要求书3页 说明书8页 附图3页

(54)发明名称

基于数字孪生的机械设备零部件结构参数动态优化方法

(57)摘要

本发明公开了一种基于数字孪生的机械设备零部件结构参数动态优化方法,通过构建高保真模型,在虚拟空间实现物理空间对应设备的数字化镜像,方便后期结构参数修改和超写实仿真;通过进行超写实仿真,在虚拟空间实时动态的同步反映物理空间对应实体的状态,在虚拟空间实现物理设备真实情况的写实运动;同时利用深度学习理论,构建神经网络结构,借助其强大的数字挖掘和映射能力,挖掘建立结构参数和疲劳寿命之间的关系,通过结合高保真模型和超写实仿真环境,实现结构参数的动态优化。通过本发明,实现虚拟空间对物理空间的结构参数的动态优化与反向指导,提高了优化效率和真实性。



1. 一种基于数字孪生的机械设备零部件结构参数动态优化方法,其特征在于,包括:

构建机械设备全部或部分结构的三维模型,研究三维模型动力学与运动状态的关联性,确定反映运动状态的参数,并根据参数分析确定机械设备全部或部分结构中所需的传感器类型及安装位置,按照分析结果在物理空间物理实体中布置传感器,通过传感器监测数据驱动虚拟空间参数更新,完成高保真建模;

依据物理实体的历史监测数据及物理空间传感器实时更新的监测数据,进行超写实仿真,获取高保真三维模型零件结构参数与对应疲劳寿命数据集作为数据分析样本;

构建深度卷积神经网络模型,用高保真三维模型零件结构参数与对应的疲劳寿命数据样本集训练模型,保存训练好的模型;

将目标疲劳寿命数据作为预测模型的输入,通过传感器实时监测数据动态更新虚拟空间参数和预测模型动态训练,得到动态优化后的零部件结构参数。

2. 根据权利要求1所述的基于数字孪生的机械设备零部件结构参数动态优化方法,其特征在于,在进行高保真建模的步骤中,包括步骤:

依据物理空间机械设备零部件结构的受力大小、力的类型、结构、工作时的姿态,轮廓尺寸、相对位置信息,用三维软件构建机械设备零部件结构的三维模型;

导入ANSYS软件中进行动力学分析,研究动力学与运动状态的关联性,确定反映运动状态的关键参数,其中,反映运动状态的关键参数至少包括应变、振型、节点位移、节点位置;

依据得到的关键参数布置需要的传感器的类型,以及传感器在机械设备零部件结构位置的布置;依据物理空间机械设备零部件结构的材料类型、几何尺寸,利用UG参数化建模在虚拟空间构建机械设备零部件结构的三维模型,实现高保真建模。

3. 根据权利要求2所述的基于数字孪生的机械设备零部件结构参数动态优化方法,其特征在于,所述传感器类型至少包括加速度、温度传感器和力传感器。

4. 根据权利要求2所述的基于数字孪生的机械设备零部件结构参数动态优化方法,其特征在于,传感器布置在机械设备零部件结构上应变大的位置;其中,应变大小通过分析结果的应变图进行判断。

5. 根据权利要求1所述的基于数字孪生的机械设备零部件结构参数动态优化方法,其特征在于,通过VR技术获得的机械设备零部件结构物理空间多物理参数,其中,机械设备零部件结构的物理空间多物理参数至少包括受力、速度、振动、温度、环境温度、位置参数。

6. 根据权利要求1所述的基于数字孪生的机械设备零部件结构参数动态优化方法,其特征在于,对机械设备零部件结构进行超写实仿真的步骤包括:

依据有限元参数化技术,通过传感器实时监测数据实时动态更新虚拟空间相关参数设置,实现动态疲劳仿真,得到对应的疲劳寿命值;其中,传感器实时监测机械设备零部件结构的监测数据至少包括力、速度、温度及位置参数;

通过调整机械设备零部件结构对应的结构参数,继续进行仿真,得到该参数下机械设备零部件结构对应的疲劳寿命值,构建参数与机械设备零部件的疲劳寿命的对应关系;

通过调整不同的参数,得到不同的疲劳寿命值,产生机械设备零部件结构参数与对应的疲劳寿命数据样本集。

7. 根据权利要求1所述的基于数字孪生的机械设备零部件结构参数动态优化方法,其特征在于,构建深度卷积神经网络模型的步骤包括:

利用python语言实现DCNN模型,用测试集进行DCNN模型的训练,进行参数优化,调整模型的层数、模型的具体结构及卷积核的大小,直至训练集中的预测值和实际值的均方误差达到最小,训练预测结果达到最优确定训练次数、模型层数、模型具体结构以及卷积核大小,保存模型;

其中,均方误差表达式为

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (y_{pi} - y_{ti})^2$$

N表示参加训练的数据量, $y_{pi}$ 表示对第i个输入的预测值, $y_{ti}$ 表示第i个输入对应的实际值;

基于训练好的模型,利用测试集测试模型预测性能,将模型的预测值和实际值做对比,得到模型预测的准确性;

其中,对模型预测结果进行评判时,采用均方根误差 (RMSE)、拟合优度检验 ( $R^2$ )、平均绝对百分误差 (MAPE) 和Score\_function三个指标进行评判;

表达式分别为:

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_{pi} - y_{ti})^2}$$

预测分析中RMSE越接近0,代表预测结果越精确;

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_{pi} - y_{ti})^2}{\sum_{i=1}^n (\bar{y} - y_{ti})^2}$$

$R^2$ 值越接近1,代表预测结果越好;

平均绝对百分误差 (MAPE) 不仅仅考虑预测值与真实值之间的误差,还考虑该误差占真实值的比例;

$$\text{MAPE} = \frac{1}{N} \sum_{i=1}^N \frac{|y_i - \hat{y}_i|}{y_i}$$

$$\text{score} = \begin{cases} \sum_{i=1}^N \left( e^{-\frac{d_i}{13}} - 1 \right) & \text{for } d_i < 0 \\ \sum_{i=1}^N \left( e^{\frac{d_i}{10}} - 1 \right) & \text{for } d_i \geq 0 \end{cases}$$

$$d_i = \hat{y}_i - y_i$$

Score值越接近0,代表预测结果越精确;

上述公式中, $y_i$ 表示实际值, $\hat{y}_i$ 表示预测值, $\bar{y}$ 表示预测的均值, $y_i$ 表示第i组的寿命对应参数。

8. 根据权利要求1所述的基于数字孪生的机械设备零部件结构参数动态优化方法,其特征在于,在将目标疲劳寿命数据作为结构参数预测模型的输入,对高保真三维模型的零件结构参数进行预测的步骤中,包括步骤:

预设机械设备零部件结构的目标寿命值,并将目标寿命值(目标寿命值)作为预测模型的输入,得到预测的机械设备零部件结构参数值;

以预测的机械设备零部件结构参数值作为指导,更新虚拟空间模型的对应的尺寸,通过有限元参数化进行模型的仿真,得到对应的疲劳寿命值;

比较仿真得到的疲劳寿命值与目标寿命值,若两者相等,则预测得到的参数就是优化后的参数;若不相等,进行训练集样本补充,继续训练模型,再将目标寿命值作为输入进行参数预测,依据预测参数更新虚拟空间模型结构,进行新一轮超写实仿真,比较目标寿命值与仿真寿命值;循环上述步骤,直至两个寿命值相等。

## 基于数字孪生的机械设备零部件结构参数动态优化方法

### 技术领域

[0001] 本发明涉及深度学习领域,特别是涉及一种基于数字孪生的机械设备零部件结构参数动态优化方法。

### 背景技术

[0002] 数字孪生为虚拟空间和物理空间的实时交互与双向连接提供了重要的理论依据和技术支撑,近几年在理论和应用层面均取得了快速发展,目前数字孪生技术被应用于航天设备和车间生产控制。对于通用机械这种工作环境复杂,条件多变的大型设备,其关键零部件结构参数优化手段落后,基本停留在经验设计、参数静态仿真设计,无法对实际运行情况进行高逼真度模拟仿真,这使得对真实工作面环境中机械设备零部件结构参数的优化准确性差、效率低、智能化程度滞后。在结构参数设计阶段,很少考虑到设备的实际工作环境。而机械设备的实际工作条件多变,存在诸多的不确定因素,因此,对机械设备关键零部件的结构参数设计,更应该实时动态的考虑其实际工作环境的影响。现有机械设备零部件结构参数优化手段落后,优化效率低,真实性有待提升,对于复杂工况条件下的零部件关键结构参数优化困难。

### 发明内容

[0003] 本发明的目的是为解决上述现有技术的不足之处而提供一种基于数字孪生的机械设备零部件结构参数动态优化方法。

[0004] 为解决上述技术问题,本发明采用的一个技术方案是:提供一种基于数字孪生的机械设备零部件结构参数动态优化方法,包括:

[0005] 构建机械设备全部或部分结构的三维模型,研究三维模型动力学与运动状态的关联性,确定反映运动状态的参数,并根据参数分析确定机械设备全部或部分结构中所需的传感器类型及安装位置,按照分析结果在物理空间物理实体中布置传感器,通过传感器监测数据驱动虚拟空间参数更新,完成高保真建模;

[0006] 依据物理实体的历史监测数据及物理空间传感器实时更新的监测数据,进行超写实仿真,获取高保真三维模型零件结构参数与对应疲劳寿命数据集作为数据分析样本;

[0007] 构建深度卷积神经网络模型,用高保真三维模型零件结构参数与对应的疲劳寿命数据样本集训练模型,保存训练好的模型;

[0008] 将目标疲劳寿命数据作为预测模型的输入,通过传感器实时监测数据动态更新虚拟空间参数和预测模型动态训练,得到动态优化后的零部件结构参数。

[0009] 其中,在进行高保真建模的步骤中,包括步骤:

[0010] 依据物理空间机械设备零部件结构的受力大小、力的类型、结构、工作时的姿态,轮廓尺寸、相对位置信息,用三维软件构建机械设备零部件结构的三维模型;

[0011] 导入ANSYS软件中进行动力学分析,研究动力学与运动状态的关联性,确定反映运动状态的关键参数,其中,反映运动状态的关键参数至少包括应变、振型、节点位移、节点位

置；

[0012] 依据得到的关键参数布置需要的传感器的类型,以及传感器在机械设备零部件结构位置的布置;依据物理空间机械设备零部件结构的材料类型、几何尺寸,利用UG参数化建模在虚拟空间构建机械设备零部件结构的三维模型,实现高保真建模。

[0013] 其中,所述传感器类型至少包括加速度、温度传感器和力传感器。

[0014] 其中,传感器布置在机械设备零部件结构上应变大的位置。

[0015] 其中,通过VR技术获得的机械设备零部件结构物理空间多物理参数,其中,机械设备零部件结构的物理空间多物理参数至少包括受力、速度、振动、温度、环境温度、位置参数。

[0016] 其中,对机械设备零部件结构进行超写实仿真的步骤包括:

[0017] 依据有限元参数化技术,通过传感器实时监测数据实时动态更新虚拟空间相关参数设置,实现动态疲劳仿真,得到对应的疲劳寿命值;其中,传感器实时监测机械设备零部件结构的监测数据至少包括力、速度、温度及位置参数;

[0018] 通过调整虚拟空间高保真模型对应的结构参数,继续进行仿真,得到该结构参数下机械设备零部件对应的疲劳寿命值,构建结构参数与机械设备零部件疲劳寿命的对应关系;

[0019] 通过调整不同的结构参数,得到不同的疲劳寿命值,产生机械设备零部件结构参数与对应的疲劳寿命数据样本集。

[0020] 其中,构建深度卷积神经网络模型的步骤包括:

[0021] 利用python语言实现DCNN模型,用测试集进行DCNN模型的训练,进行参数优化,调整模型的层数、模型的具体结构及卷积核的大小,直至训练集中的预测值和实际值的均方误差达到最小,训练预测结果达到最优确定训练次数、模型层数、模型具体结构以及卷积核大小,保存模型;

[0022] 其中,均方误差表达式为

$$[0023] \quad \text{MSE} = \frac{1}{N} \sum_{i=1}^N (y_{pi} - y_{ti})^2$$

[0024] N表示参加训练的数据量, $y_{pi}$ 表示对第i个输入的预测值, $y_{ti}$ 表示第i个输入对应的实际值;

[0025] 基于训练好的模型,利用测试集测试模型预测值,将模型的预测值和实际值做对比,得到模型预测的准确性;

[0026] 其中,对模型预测结果进行评判时,采用均方根误差(RMSE)、拟合优度检验<sup>(2)</sup>、平均绝对百分误差(MAPE)和Score\_function三个指标进行评判;

[0027] 表达式分别为:

$$[0028] \quad \text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_{pi} - y_{ti})^2}$$

[0029] 预测分析中RMSE越接近0,代表预测结果越精确;

$$[0030] \quad R^2 = 1 - \frac{\sum_{i=1}^n (y_{pi} - y_{ti})^2}{\sum_{i=1}^n (\bar{y} - y_{ti})^2}$$

[0031]  $R^2$ 值越接近1,代表预测结果越好;

[0032] 平均绝对百分误差 (MAPE) 不仅仅考虑预测值与真实值之间的误差,还考虑该误差占真实值的比例;

$$[0033] \quad \text{MAPE} = \frac{1}{N} \sum_{i=1}^N \frac{|y_i - \hat{y}_i|}{y_i}$$

$$[0034] \quad \text{score} = \begin{cases} \sum_{i=1}^N (e^{-\frac{d_i}{13}} - 1) & \text{for } d_i < 0 \\ \sum_{i=1}^N (e^{\frac{d_i}{10}} - 1) & \text{for } d_i \geq 0 \end{cases}$$

$$[0035] \quad d_i = \hat{y}_i - y_i$$

[0036] Score值越接近0,代表预测结果越精确;

[0037] 上述公式中, $y_i$ 表示实际值, $\hat{y}_i$ 表示预测值, $\bar{y}$ 表示预测的均值, $y_i$ 表示第*i*组的寿命对应参数。

[0038] 其中,在将目标疲劳寿命数据作为训练模型的输入,对高保真三维模型的零件结构参数进行预测的步骤中,包括步骤:

[0039] 预设机械设备零部件结构的目标寿命值,并将目标寿命值(目标寿命值)作为预测模型的输入,得到预测的机械设备零部件结构参数值;

[0040] 以预测的机械设备零部件结构参数值作为指导,更新虚拟空间模型的对应的尺寸,通过有限元参数化进行模型的仿真,得到对应的疲劳寿命值;

[0041] 比较仿真得到的疲劳寿命值与目标寿命值,若两者相等,则预测得到的参数就是优化后的参数;若不相等,进行训练集样本补充,继续训练模型,再将目标寿命值作为输入进行参数预测,依据预测的结构参数更新虚拟空间模型对应的参数,进行新一轮超写实仿真,比较目标寿命值与仿真寿命值;循环上述步骤,直至两个寿命值相等。

[0042] 区别于现有技术,本发明的基于数字孪生的机械设备零部件结构参数动态优化方法,通过构建高保真模型,在虚拟空间实现物理空间对应设备的数字化镜像,方便后期结构参数修改和超写实仿真;通过进行超写实仿真,在虚拟空间实时动态的同步反映物理空间对应实体的状态,在虚拟空间实现物理设备真实情况的写实运动;同时利用深度学习理论,构建神经网络结构,借助其强大的数字挖掘和映射能力,挖掘建立结构参数和疲劳寿命之间的关系,通过结合高保真模型和超写实仿真环境,实现结构参数的动态优化。通过本发明,实现虚拟空间对物理空间的结构参数的动态优化与反向指导,提高了优化效率和真实性。

## 附图说明

[0043] 图1是本发明提供的一种基于数字孪生的机械设备零部件结构参数动态优化方法

的流程示意图。

[0044] 图2是本发明提供的一种基于数字孪生的机械设备零部件结构参数动态优化方法中依据目标寿命得到模型对齿宽参数的动态优化效果图。

[0045] 图3是本发明提供的一种基于数字孪生的机械设备零部件结构参数动态优化方法中依据目标寿命进行变位系数的动态优化效果图。

[0046] 图4是本发明提供的一种基于数字孪生的机械设备零部件结构参数动态优化方法中依据目标寿命进行压力角值动态优化效果图。

[0047] 图5是本发明提供的一种基于数字孪生的机械设备零部件结构参数动态优化方法中依据目标寿命值进行重合度值动态优化效果图。

### 具体实施方式

[0048] 在下面的描述中阐述了很多具体细节以便于充分理解本发明。但是本发明能够以很多不同于在此描述的其它方式来实施,本领域技术人员可以在不违背本发明内涵的情况下做类似推广,因此本发明不受下面公开的具体实施的限制。

[0049] 其次,本发明利用示意图进行详细描述,在详述本发明实施例时,为便于说明,示意图只是实例,其在此不应限制本发明保护的范围。

[0050] 参阅图1,图1是本发明提供的一种基于数字孪生的机械设备零部件结构参数动态优化方法的流程示意图。该方法的步骤包括:

[0051] 构建机械设备全部或部分结构的三维模型,研究三维模型动力学与运动状态的关联性,确定反映运动状态的参数,并根据参数分析确定机械设备全部或部分结构中所需的传感器类型及安装位置,按照分析结果在物理空间物理实体中布置传感器,通过传感器监测数据驱动虚拟空间参数更新,完成高保真建模;

[0052] 依据物理实体的历史监测数据及物理空间传感器实时更新的监测数据,进行超写实仿真,获取高保真三维模型零件结构参数与对应疲劳寿命数据集作为数据分析样本;

[0053] 构建深度卷积神经网络模型,用高保真三维模型零件结构参数与对应的疲劳寿命数据样本集训练模型,保存训练好的模型;

[0054] 将目标疲劳寿命数据作为预测模型的输入,通过传感器实时监测数据动态更新虚拟空间参数和预测模型动态训练,得到动态优化后的零部件结构参数。

[0055] 其中,在进行高保真建模的步骤中,包括步骤:

[0056] 依据物理空间机械设备零部件结构的受力大小、力的类型、结构、工作时的姿态,轮廓尺寸、相对位置信息,用三维软件构建机械设备零部件结构的三维模型;

[0057] 导入ANSYS软件中进行动力学分析,研究动力学与运动状态的关联性,确定反映运动状态的关键参数,其中,反映运动状态的关键参数至少包括应变、振型、节点位移、节点位置;

[0058] 依据得到的关键参数布置需要的传感器的类型,以及传感器在机械设备零部件结构位置的布置;依据物理空间机械设备零部件结构的材料类型、几何尺寸,利用UG参数化建模在虚拟空间构建机械设备零部件结构的三维模型,实现高保真建模。

[0059] 其中,所述传感器类型至少包括加速度、温度传感器和力传感器。

[0060] 其中,传感器布置在机械设备零部件结构上应变大的位置。

[0061] 其中,通过VR技术获得的机械设备零部件结构物理空间多物理参数,其中,机械设备零部件结构的物理空间多物理参数至少包括受力、速度、振动、温度、环境温度、位置参数。对矿井设备而言,还包括煤尘的物理参数。

[0062] 其中,对机械设备零部件结构进行超写实仿真的步骤包括:

[0063] 依据有限元参数化技术,通过传感器实时监测数据实时动态更新虚拟空间相关参数设置,实现动态疲劳仿真,得到对应的疲劳寿命值;其中,传感器实时监测机械设备零部件结构的监测数据至少包括力、速度、温度及位置参数;

[0064] 通过调整机械设备零部件结构对应的结构参数,继续进行仿真,得到该参数下机械设备零部件结构对应的疲劳寿命值,构建结构参数与机械设备零部件疲劳寿命的对应关系;

[0065] 通过调整不同的参数,得到不同的疲劳寿命值,产生机械设备零部件结构参数与对应的疲劳寿命数据样本集。

[0066] 其中,构建深度卷积神经网络模型的步骤包括:

[0067] 利用python语言实现DCNN模型,用测试集进行DCNN模型的训练,使模型学习到不同阶段的特征,进行参数优化,调整模型的层数、模型的具体结构及卷积核的大小,直至训练集中的预测值和实际值的均方误差达到最小,训练预测结果达到最优确定训练次数、模型层数、模型具体结构以及卷积核大小,保存模型;

[0068] 其中,均方误差表达式为

$$[0069] \quad \text{MSE} = \frac{1}{N} \sum_{i=1}^N (y_{pi} - y_{ti})^2$$

[0070] N表示参加训练的数据量, $y_{pi}$ 表示对第i个输入的预测值, $y_{ti}$ 表示第i个输入对应的实际值;

[0071] 基于训练好的模型,利用测试集测试模型预测值,将模型的预测值和实际值做对比,得到模型预测的准确性;

[0072] 其中,对模型预测结果进行评判时,采用均方根误差(RMSE)、拟合优度检验( $R^2$ )、平均绝对百分误差(MAPE)和Score\_function三个指标进行评判;

[0073] 表达式分别为:

$$[0074] \quad \text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_{pi} - y_{ti})^2}$$

[0075] 预测分析中RMSE越接近0,代表预测结果越精确;

$$[0076] \quad R^2 = 1 - \frac{\sum_{i=1}^n (y_{pi} - y_{ti})^2}{\sum_{i=1}^n (\bar{y} - y_{ti})^2}$$

[0077]  $R^2$ 值越接近1,代表预测结果越好;

[0078] 平均绝对百分误差(MAPE)不仅仅考虑预测值与真实值之间的误差,还考虑该误差占真实值的比例;

$$[0079] \quad \text{MAPE} = \frac{1}{N} \sum_{i=1}^N \frac{|y_i - \hat{y}_i|}{y_i}$$

$$[0080] \quad \text{score} = \begin{cases} \sum_{i=1}^N \left( e^{-\frac{d_i}{13}} - 1 \right) & \text{for } d_i < 0 \\ \sum_{i=1}^N \left( e^{\frac{d_i}{10}} - 1 \right) & \text{for } d_i \geq 0 \end{cases}$$

$$[0081] \quad d_i = \hat{y}_i - y_i$$

[0082] Score值越接近0,代表预测结果越精确;

[0083] 上述公式中, $y_i$ 表示实际值, $\hat{y}_i$ 表示预测值, $\bar{y}$ 表示预测的均值, $y_i$ 表示第*i*组的寿命对应参数。

[0084] 其中,在将目标疲劳寿命数据作为训练模型的输入,对高保真三维模型的零件结构参数进行预测的步骤中,包括步骤:

[0085] 预设机械设备零部件结构的目标寿命值,并将目标寿命值(目标寿命值)作为训练模型的输入,得到预测的机械设备零部件结构参数值;

[0086] 以预测的机械设备零部件结构参数值作为指导,更新虚拟空间模型的对应的尺寸,通过有限元参数化进行模型的仿真,得到对应的疲劳寿命值;其中,对齿轮而言,其结构参数值至少包括齿宽、重合度、压力角、变位系数;

[0087] 比较仿真得到的疲劳寿命值与目标寿命值,若两者相等,则预测得到的参数就是优化后的参数;若不相等,进行训练集样本补充,继续训练模型,再将目标寿命值作为输入进行参数预测,依据预测参数更新虚拟空间模型结构,进行新一轮超写实仿真,比较目标寿命值与仿真寿命值。循环上述步骤,直至两个寿命值相等。

[0088] 具体以采煤机摇臂为例进行说明。

[0089] 首先,依据物理空间采煤机摇臂的受力大小、力的类型、结构、工作时的姿态,轮廓尺寸、相对位置等信息,用UG三维软件构建采煤机摇臂的三维模型,导入ANSYS软件中进行动力学分析,研究动力学与运动状态的关联性,确定反映运动状态的关键参数,如应变、振型、节点位移、节点位置等信息。依据得到的参数布置需要的传感器的类型(加速度、温度传感器、力传感器等),以及传感器在采煤机摇臂位置的布置(传感器布置在应变大的位置);依据物理空间采煤机的材料类型、几何尺寸(长、宽、高、孔尺寸,齿轮几何参数等),利用UG参数化建模在虚拟空间构建采煤机摇臂的三维模型,实现采煤机摇臂的高保真建模。

[0090] 通过VR技术获得的采煤机摇臂物理空间多物理参数(采煤机摇臂受力、速度、振动、温度、环境温度、煤尘、位置等),将UG中构建的采煤机摇臂三维模型导入有限元分析软件中,进行仿真分析。

[0091] 依采煤机摇臂齿轮为例,依据有限元参数化技术,通过传感器实时监测数据(力,速度,温度、位置等)实时动态更新虚拟空间相关参数设置,实现动态疲劳仿真,得到对应的疲劳寿命值。通过调整齿轮对应的结构参数(齿宽、重合度、压力角、变位系数等),继续进行仿真,得到该参数下齿轮对应的疲劳寿命值,构建参数与齿轮疲劳寿命的对应关系。通过调整不同的参数,得到不同的疲劳寿命值,产生齿轮结构参数与对应的疲劳寿命数据样本集。

为后期结构参数预测提供数据基础。

[0092] 依据上述得到的齿轮结构参数与对应的疲劳寿命数据样本集进行模型训练,保存训练好的模型。将齿轮应该具有的寿命值(目标寿命值)作为模型的输入,得到预测的齿轮参数值。以预测的齿轮结构参数值(齿宽、重合度、压力角、变位系数等)作为指导,更新虚拟空间模型的对应的尺寸,通过有限元参数化进行模型的仿真,得到对应的疲劳寿命值。比较仿真得到的疲劳寿命与目标寿命值,若两者相等,则预测得到的参数就是优化后的参数;若不相等,进行训练集样本补充,继续返回去训练模型,再将目标寿命值作为输入进行参数预测,依据预测参数更新虚拟空间模型结构,进行新一轮超写实仿真,比较目标寿命值与仿真寿命值。循环上述步骤,直至两个寿命值相等。最后,输出对应的预测的齿轮结构参数,此时的结构参数为动态优化后的结构参数,实现齿轮结构参数的动态优化。

[0093] 现有机械设备关键零部件的结构参数一般是采用经验值进行选取,并通过后期的强度校核验证设计的正确性。但在实际应用中,由于在设计阶段无法考虑到实际的工作环境。因此,无论是通过经验值设计经过校核的还是依据理论公式推导计算得到的结构参数值,都会和实际运行环境中要达到的寿命值对应的结构参数存在较大的偏差。

[0094] 实例验证中选取减速器齿轮的齿宽、变位系数、压力角和重合度作为变量,验证提出方法的有效性。

[0095] 依据目标寿命得到模型对齿宽参数的动态优化效果图如图2所示,齿宽优化指标值如表1所示。

[0096]

	RMSE	$R^2$	MAPE	Score
指标值	0.04317	0.98192	0.02158	0.23316

[0097] 表1齿宽优化指标值表

[0098] 由图2和表1可知,模型对齿宽的优化指标值接近理想值,若当优化值与实际值完全相等时,RMSE,MAPE应该等于0, $R^2$ 值应该等于1,Score应该接近0。观察实际值发现,各个指标值均接近理想值。因此,模型对齿宽的动态优化是有效的。

[0099] 依据目标寿命进行变位系数的动态优化,效果如图3所示,变位系数动态优化指标值如表2所示。

[0100]

	RMSE	$R^2$	MAPE	Score
指标值	0.01621	0.99171	0.01047	0.08366

[0101] 表2变位系数动态优化指标值

[0102] 由图3和表2分析,相比于模型对齿宽优化指标值,模型对变位系数的优化指标值更接近于理想值,也就是说模型对变位系数的优化更接近实际值,而相对百分误差为 $MAPE = 1.047\%$ 。

[0103] 依据目标寿命进行压力角值动态优化,效果如4所示,压力角优化指标值如表3所示。

[0104]

	RMSE	$R^2$	MAPE	Score
指标值	0.07517	0.97689	0.09155	0.67519

[0105] 表3压力角优化指标值

[0106] 由图4和表3分析可知,模型对压力角的动态优化误差比对齿宽和变位系数的优化误差大,相对百分误差为 $MAPE=9.155\%$ ,但是在误差允许的范围内,该优化结果是可以采取的。由于齿轮压力角对齿轮寿命的影响比齿宽和变位系数的影响小,所以导致对压力角的优化结构误差比较大,但是,该优化结果仍然可以指导实际生产。

[0107] 依据目标寿命值进行重合度值动态优化,效果如图5所示,重合度优化指标值如表4所示。

[0108]

	RMSE	$R^2$	MAPE	Score
指标值	0.05933	0.98745	0.04788	0.14859

[0109] 表4重合度优化指标值

[0110] 由图5和表4分析,模型对重合度的动态优化误差比压力角优化误差小,重合度的动态优化相对百分误差值 $MAPE=4.788\%$ ,故该动态优化结果是理想的。而且,重合度对寿命的影响比压力角对寿命的影响大。

[0111] 综合分析以上动态优化结果,该模型对减速器齿轮结构参数的动态优化结果是接近实际值的,各个参数的动态优化结果相对百分误差为,齿宽动态优化误差  $MAPE=2.158\%$ ,变位系数动态优化误差 $MAPE=1.047\%$ ,压力角动态优化误差  $MAPE=9.155\%$ ,重合度动态优化误差 $MAPE=4.788\%$ .故在误差允许的范围内,该动态优化结果是可取的,则该方法对于机械设备关键零部件结构参数的动态优化是有效的。

[0112] 区别于现有技术,本发明的基于数字孪生的机械设备零部件结构参数动态优化方法,通过构建高保真模型,在虚拟空间实现物理空间对应设备的数字化镜像,方便后期结构参数修改和超写实仿真;通过进行超写实仿真,在虚拟空间实时动态的同步反映物理空间对应实体的状态,在虚拟空间实现物理设备真实情况的写实运动;同时利用深度学习理论,构建神经网络结构,借助其强大的数字挖掘和映射能力,挖掘建立结构参数和疲劳寿命之间的关系,通过结合高保真模型和超写实仿真环境,实现结构参数的动态优化。通过本发明,实现虚拟空间对物理空间的结构参数的动态优化与反向指导,提高了优化效率和真实性。

[0113] 本发明虽然已以较佳实施例公开如上,但其并不是用来限定本发明,任何本领域技术人员在不脱离本发明的精神和范围内,都可以利用上述揭示的方法和技术内容对本发明技术方案做出可能的变动和修改,因此,凡是未脱离本发明技术方案的内容,依据本发明的技术实质对以上实施例所作的任何简单修改、等同变化及修饰,均属于本发明技术方案的保护范围。

构建机械设备全部或部分结构的三维模型，研究三维模型动力学与运动状态的关联性，确定反映运动状态的参数，并根据参数分析确定机械设备全部或部分结构中所需的传感器类型及安装位置，按照分析结果在物理空间物理实体中布置传感器，通过传感器监测数据驱动虚拟空间参数更新，完成高保真建模

依据物理实体的历史监测数据及物理空间传感器实时更新的监测数据，进行超写实仿真，获取高保真三维模型零件结构参数与对应疲劳寿命数据集作为数据分析样本

构建深度卷积神经网络模型，用高保真三维模型零件结构参数与对应的疲劳寿命数据样本集训练模型，保存训练好的模型

将目标疲劳寿命数据作为预测模型的输入，通过传感器实时监测数据动态更新虚拟空间参数和预测模型动态训练，得到动态优化后的零部件结构参数

图1

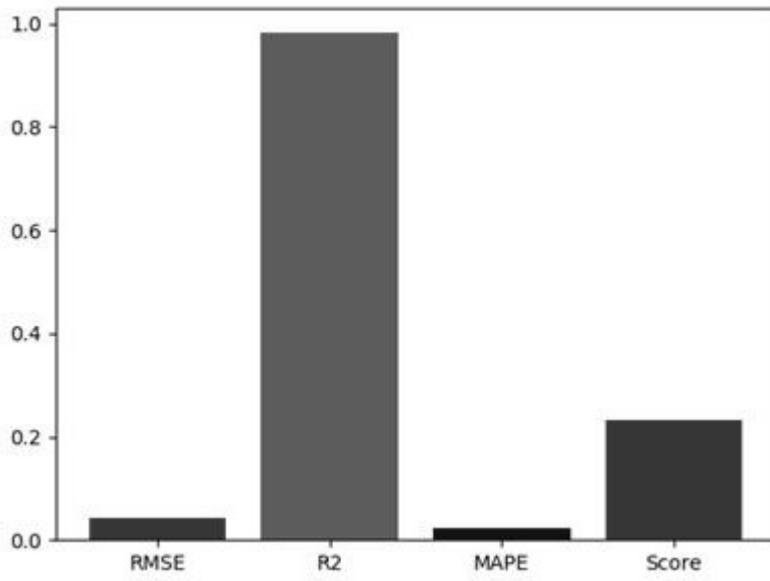


图2

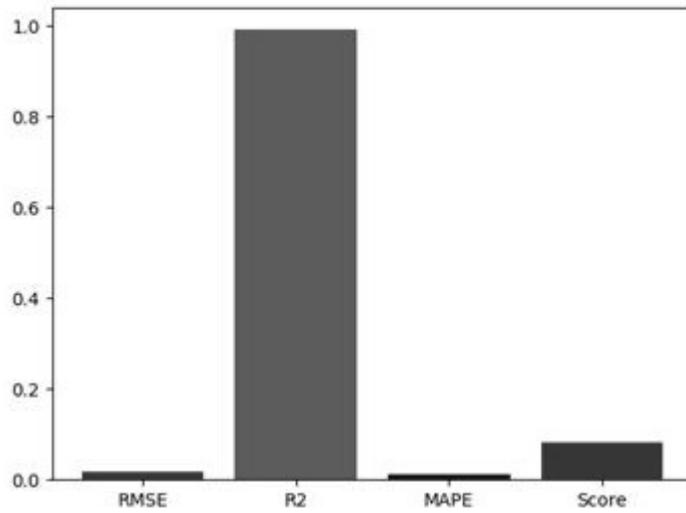


图3

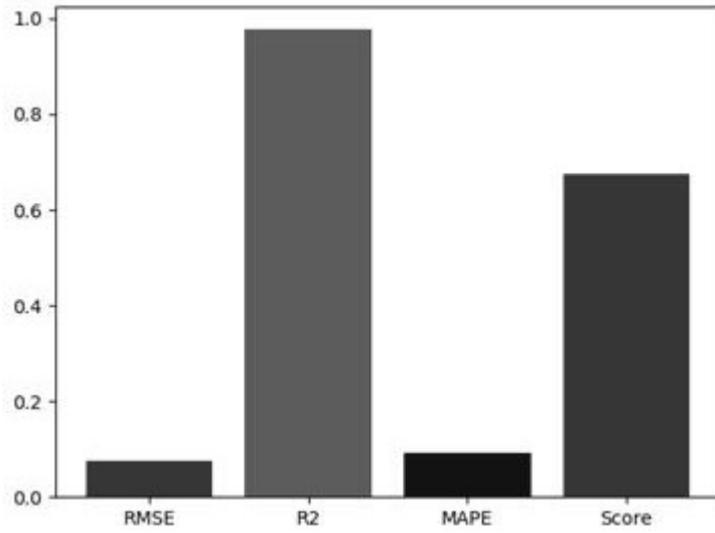


图4

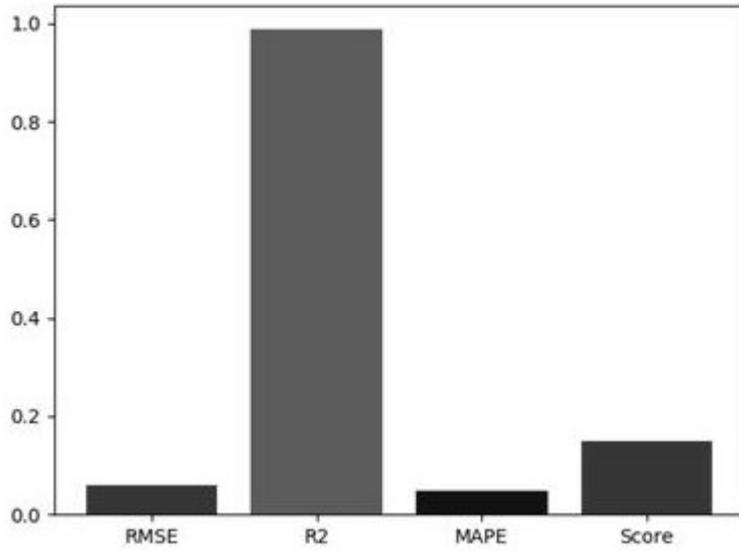


图5