



(12) 发明专利

(10) 授权公告号 CN 117540648 B

(45) 授权公告日 2025. 09. 30

(21) 申请号 202311252989.0

G06F 113/08 (2020.01)

(22) 申请日 2023.09.26

G06F 119/14 (2020.01)

(65) 同一申请的已公布的文献号

申请公布号 CN 117540648 A

(56) 对比文件

CN 114282448 A, 2022.04.05

(43) 申请公布日 2024.02.09

审查员 张丽红

(73) 专利权人 香港理工大学

地址 中国香港九龙红磡育才道11号

(72) 发明人 陈争卫 倪一清 芮恩泽 曾广志

(74) 专利代理机构 深圳中一联合知识产权代理

有限公司 44414

专利代理师 甘莹

(51) Int. Cl.

G06F 30/28 (2020.01)

G06N 3/04 (2023.01)

G01M 10/00 (2006.01)

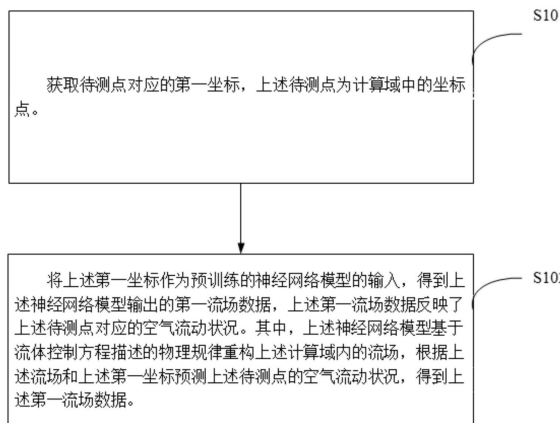
权利要求书3页 说明书15页 附图2页

(54) 发明名称

流场预测方法、装置、终端设备及存储介质

(57) 摘要

本申请适用于流场预测技术领域,提供了流场预测方法、装置、终端设备及存储介质,包括:获取待测点对应的第一坐标,所述待测点为计算域中的坐标点;将所述第一坐标作为预训练的神经网络模型的输入,得到所述神经网络模型输出的第一流场数据,所述第一流场数据反映了所述待测点对应的空气流动状况;其中,所述神经网络模型基于流体控制方程描述的物理规律重构所述计算域内的流场,根据所述流场和所述第一坐标预测所述待测点的空气流动状况,得到所述第一流场数据。本申请可以提高流场预测的准确性。



1. 一种流场预测方法,其特征在于,包括:

获取待测点对应的第一坐标,所述待测点为计算域中的坐标点;

将所述第一坐标作为预训练的神经网络模型的输入,得到所述神经网络模型输出的第一流场数据,所述第一流场数据反映了所述待测点对应的空气流动状况;

其中,所述神经网络模型基于流体控制方程描述的物理规律重构所述计算域内的流场,根据所述流场和所述第一坐标预测所述待测点的空气流动状况,得到所述第一流场数据;

其中,所述流体控制方程为雷诺时均方程,所述预训练的神经网络模型根据如下步骤得到:

根据所述雷诺时均方程确定所述计算域对应的雷诺时均残差函数;

基于所述雷诺时均残差函数确定待训练的神经网络模型的损失函数,得到所述待训练的神经网络模型,所述损失函数包括雷诺时均残差项和数据残差项,所述雷诺时均残差项包括多个空间方向对应的动量残差函数;

获取训练数据,所述训练数据包含从所述计算域中的采样点采集到的多个第二流场数据;

根据所述训练数据对所述待训练的神经网络模型进行训练,基于所述雷诺时均残差项和采样点的预测值计算雷诺时均残差,以及,基于所述数据残差项、所述采样点的所述预测值和实测值计算数据残差,所述雷诺时均残差中不同空间方向对应的动量残差基于不同的采样点计算得到;

根据所述雷诺时均残差和所述数据残差确定所述待训练的神经网络模型的损失值,根据所述损失值对所述待训练神经网络模型进行更新,直至训练后的神经网络模型满足预设要求,得到所述预训练的神经网络模型。

2. 如权利要求1所述的流场预测方法,其特征在于,所述根据所述雷诺时均方程确定所述计算域对应的雷诺时均残差函数,包括:

根据所述雷诺时均方程分别确定多个空间方向对应的动量残差函数;

根据各个所述空间方向对应的所述动量残差函数确定所述雷诺时均残差函数。

3. 如权利要求2所述的流场预测方法,其特征在于,在所述根据所述雷诺时均方程分别确定多个空间方向对应的动量残差函数之前,还包括:

根据所述雷诺时均方程和零方程确定封闭后的所述雷诺时均方程;

对应地,所述根据所述雷诺时均方程分别确定多个空间方向对应的动量残差函数,包括:

根据封闭后的所述雷诺时均方程分别确定各个所述空间方向对应的所述动量残差函数。

4. 如权利要求3所述的流场预测方法,其特征在于,所述根据所述雷诺时均方程和零方程确定封闭后的所述雷诺时均方程,包括:

将李丞零方程嵌入所述雷诺时均方程,得到封闭后的所述雷诺时均方程,其中,封闭后的所述雷诺时均方程中的湍流动力粘度根据所述计算域中近壁面的湍流动力粘度和远端处的湍流动力粘度中的较大值确定。

5. 如权利要求1至4任一项所述的流场预测方法,其特征在于,所述根据所述训练数据

对所述待训练的神经网络模型进行训练,基于所述雷诺时均残差项和采样点的预测值计算所述采样点的雷诺时均残差,以及,基于所述数据残差项、所述采样点的所述预测值和实测值计算数据残差,包括:

将所述采样点对应的第二坐标作为所述待训练的神经网络模型的输入,得到所述待训练的神经网络模型输出的所述采样点对应的第三流场数据;

根据所述损失函数中的所述雷诺时均残差项和不同的采样点对应的所述第三流场数据分别计算各个空间方向对应的动量残差,得到所述雷诺时均残差;

根据所述损失函数中的所述数据残差项、所述采样点对应的第二流场数据和所述第三流场数据确定所述采样点对应的数据残差。

6.如权利要求5所述的流场预测方法,其特征在于,所述第二流场数据和所述第三流场数据均包括压强以及不同空间方向上的流速,所述流速用于反映所述采样点对应的空间方向上的空气流动状况,所述根据所述损失函数中的所述数据残差项、所述采样点对应的第二流场数据和所述第三流场数据确定所述采样点对应的数据残差,包括:

根据所述损失函数中的所述数据残差项、所述采样点对应的第二流场数据和所述第三流场数据分别计算所述采样点的压强的残差以及各个所述空间方向上的流速的残差;

根据所述采样点的压强的残差以及各个所述空间方向对应的流速的残差以及各个所述残差对应的权重系数确定所述采样点对应的所述数据残差。

7.一种流场预测装置,其特征在于,包括:

第一坐标获取模块,用于获取待测点对应的第一坐标,所述待测点为计算域中的坐标点;

预测模块,用于将所述第一坐标作为预训练的神经网络模型的输入,得到所述神经网络模型输出的第一流场数据,所述第一流场数据反映了所述待测点对应的空气流动状况;

其中,所述神经网络模型基于流体控制方程描述的物理规律重构所述计算域内的流场,根据所述流场和所述第一坐标预测所述待测点的空气流动状况,得到所述第一流场数据;

雷诺残差函数获取模块,用于根据雷诺时均方程确定所述计算域对应的雷诺时均残差函数;

损失函数确定模块,用于基于所述雷诺时均残差函数确定待训练的神经网络模型的损失函数,得到待训练的神经网络模型,所述损失函数包括雷诺时均残差项和数据残差项,所述雷诺时均残差项包括多个空间方向对应的动量残差函数;

训练数据获取模块,用于获取训练数据,所述训练数据包含从所述计算域中的采样点采集到的多个第二流场数据;

训练模块,用于根据所述训练数据对所述待训练的神经网络模型进行训练,基于所述雷诺时均残差项和采样点的预测值计算雷诺时均残差,以及,基于所述数据残差项、所述采样点的所述预测值和实测值计算数据残差,所述雷诺时均残差中不同空间方向对应的动量残差基于不同的采样点计算得到;

更新模块,用于根据所述雷诺时均残差和所述数据残差确定所述待训练的神经网络模型的损失值,根据所述损失值对所述待训练神经网络模型进行更新,直至训练后的神经网络模型满足预设要求,得到所述预训练的神经网络模型。

8. 一种终端设备,包括存储器、处理器以及存储在所述存储器中并可在所述处理器上运行的计算机程序,其特征在于,所述处理器执行所述计算机程序时实现如权利要求1至6任一项所述的方法。

9. 一种计算机可读存储介质,所述计算机可读存储介质存储有计算机程序,其特征在于,所述计算机程序被处理器执行时实现如权利要求1至6任一项所述的方法。

流场预测方法、装置、终端设备及存储介质

技术领域

[0001] 本申请属于流场预测技术领域,尤其涉及流场预测方法、装置、终端设备及计算机可读存储介质。

背景技术

[0002] 流场是指某一区域内的流速风向等分布,对城市的气候、污染物扩散等存在直接的影响。在实际工程应用中,流场的研究对建筑设计、城市气候分析等应用具有重要意义。

[0003] 目前,通常采用计算流体力学(Computational Fluid Dynamics,CFD)模拟的方式求解流体流动的微分方程来模拟流场的空气流动状况,但CFD模拟需要构建大量的网格,且准确性受网格分辨率等因素影响,计算量复杂且准确性较低,不利于实际应用。

发明内容

[0004] 本申请实施例提供了流场预测方法、装置、终端设备及存储介质,可以提高流场预测的准确性。

[0005] 第一方面,本申请实施例提供了一种流场预测方法,包括:

[0006] 获取待测点对应的第一坐标,所述待测点为计算域中的坐标点;

[0007] 将所述第一坐标作为预训练的神经网络模型的输入,得到所述神经网络模型输出的第一流场数据,所述第一流场数据反映了所述待测点对应的空气流动状况;

[0008] 其中,所述神经网络模型基于流体控制方程描述的物理规律重构所述计算域内的流场,根据所述流场和所述第一坐标预测所述待测点的空气流动状况,得到所述第一流场数据。

[0009] 第二方面,本申请实施例提供了一种流场预测装置,包括:

[0010] 第一坐标获取模块,用于获取待测点对应的第一坐标,所述待测点为计算域中的坐标点;

[0011] 预测模块,用于将所述第一坐标作为预训练的神经网络模型的输入,得到所述神经网络模型输出的第一流场数据,所述第一流场数据反映了所述待测点对应的空气流动状况;

[0012] 其中,所述神经网络模型基于流体控制方程描述的物理规律重构所述计算域内的流场,根据所述流场和所述第一坐标预测所述待测点的空气流动状况,得到所述第一流场数据。

[0013] 第三方面,本申请实施例提供了一种终端设备,包括存储器、处理器以及存储在所述存储器中并可在所述处理器上运行的计算机程序,所述处理器执行所述计算机程序时实现上述第一方面所述的流场预测方法的步骤。

[0014] 第四方面,本申请实施例提供了一种计算机可读存储介质,所述计算机存储介质存储有计算机程序,所述计算机程序被处理器执行时实现上述第一方面中所述的流场预测方法的步骤。

[0015] 第五方面,本申请实施例提供了一种计算机程序产品,当计算机程序产品在终端设备上运行时,使得终端设备执行上述第一方面中任一项所述的流场预测方法。

[0016] 本申请实施例与现有技术相比存在的有益效果是:

[0017] 本申请实施例中,由于神经网络模型能够基于流体控制方程描述的物理规律来重构计算域中的流场,即,将流体控制方程描述的物理信息嵌入神经网络模型中,预训练的神经网络模型能够求解流体控制方程,从流体控制方程描述的物理规律的角度出发重构计算域内的流场,相对于通过CFD模拟求解流体控制方程,不需要构建大量的网格,在减少流场重构的复杂度的同时,重构流场的准确性不受网格分辨率的影响,因此,通过嵌入流体控制方程的神经网络模型重构计算域内的流场,并根据重构的流场和第一坐标查询到待测点的空气流动状况,得到所需的第一流场数据,在减小流场重构和预测的计算成本的同时,不受网格分辨率的影响,从而能够提高流场预测的准确性,便于实际工程应用。

附图说明

[0018] 为了更清楚地说明本申请实施例中的技术方案,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。

[0019] 图1是本申请一实施例提供的一种流场预测方法的流程示意图;

[0020] 图2是本申请实施例提供的一种坐标系结构示意图;

[0021] 图3是本申请实施例提供的流场预测装置的结构示意图;

[0022] 图4是本申请实施例提供的终端设备的结构示意图。

具体实施方式

[0023] 以下描述中,为了说明而不是为了限定,提出了诸如特定系统结构、技术之类的具体细节,以便透彻理解本申请实施例。然而,本领域的技术人员应当清楚,在没有这些具体细节的其它实施例中也可以实现本申请。在其它情况中,省略对众所周知的系统、装置、电路以及方法的详细说明,以免不必要的细节妨碍本申请的描述。

[0024] 应当理解,当在本申请说明书和所附权利要求书中使用时,术语“包括”指示所描述特征、整体、步骤、操作、元素和/或组件的存在,但并不排除一个或多个其它特征、整体、步骤、操作、元素、组件和/或其集合的存在或添加。

[0025] 还应当理解,在本申请说明书和所附权利要求书中使用的术语“和/或”是指相关列出的项中的一个或多个的任何组合以及所有可能组合,并且包括这些组合。

[0026] 另外,在本申请说明书和所附权利要求书的描述中,术语“第一”、“第二”、“第三”等仅用于区分描述,而不能理解为指示或暗示相对重要性。

[0027] 在本申请说明书中描述的参考“一个实施例”或“一些实施例”等意味着在本申请的一个或多个实施例中包括结合该实施例描述的特定特征、结构或特点。由此,在本说明书中的不同之处出现的语句“在一个实施例中”、“在一些实施例中”、“在其他一些实施例中”、“在另外一些实施例中”等不是必然都参考相同的实施例,而是意味着“一个或多个但不是所有的实施例”,除非是以其他方式另外特别强调。

[0028] 实施例一:

[0029] 图1示出了本发明实施例提供的一种流场预测方法的流程示意图,详述如下:

[0030] 步骤S101,获取待测点对应的第一坐标,上述待测点为计算域中的坐标点。

[0031] 上述计算域是指用于分析直流流动和热传递计算等相关的区域,在进行流场重构时,通常需要确定一个具体的计算域(即计算域的范围)和该计算域对应的各个边界条件,以重构该计算域内的流场。

[0032] 具体地,在需要预测计算域中的某个位置(即待测点)的空气流动状况时,获取该待测点的空间坐标,得到第一坐标。

[0033] 步骤S102,将上述第一坐标作为预训练的神经网络模型的输入,得到上述神经网络模型输出的第一流场数据,上述第一流场数据反映了上述待测点对应的空气流动状况。

[0034] 其中,上述神经网络模型基于流体控制方程描述的物理规律重构上述计算域内的流场,根据上述流场和上述第一坐标预测上述待测点的空气流动状况,得到上述第一流场数据。

[0035] 可选地,上述流体控制方程可以是雷诺方程或欧拉方程等控制方程。在一些实施例中,由于时间相关的流体控制方程的求解计算量大且求解难度高,如求解高雷诺数下的纳维斯托克斯方程和利用纳维斯托克斯方程解决湍流相关的工程问题等目前还没有有效的求解方案,因此,本申请实施例中,上述流体控制方程可以是纳维斯托克斯方程的变体,即雷诺时均方程或其它时均流体控制方程,即,该流体控制方程是稳态的与时间无关的流体控制方程,其最终得到的解也是稳态解,如时均压力等,以在保障流场预测的准确性的同时减小流体控制方程的求解难度和计算量。

[0036] 上述流场是指流体(包括气体和液体)的运动所占据的空间区域,即流体流动的空间分布。

[0037] 具体地,由于神经网络模型能够基于流体控制方程描述的物理规律重构计算域内的流场,因此,在需要预测计算域内的待测点的空气流动状况时,可以将该待测点对应的第一坐标作为神经网络模型的输入,神经网络模型在重构的流场中查询该第一坐标对应的待测点的空气流动状况,得到该第一流场数据。

[0038] 可以理解的是,上述待测点的空气流动状况由计算域中的流体(如液体和/或气体)决定,上述第一流场数据可以包括流体在该待测点的流速和/或压强,其中,该流速可以是流体在该待测点的合速度,也可以是该待测点在不同的空间方向的流速,即,该第一流场数据可以包括流体的不同空间方向的流速分量,例如,在计算域中建立如图2所示的坐标系,第一流场数据可以包括流体在x方向、y方向以及z方向上的流速。

[0039] 本申请实施例中,由于在神经网络模型中嵌入流体控制方程,使预训练的神经网络模型能够求解嵌入的流体控制方程,从流体控制方程所描述的物理规律出发重构计算域内的流场,相对于通过CFD模拟求解流体控制方程的方式,不需要构建大量的网格,进而,不受网格分辨率的影响,因此,通过预训练的嵌入流体控制方程的神经网络模型能够快速、准确地重构计算域内的流场,并根据重构的流场和第一坐标查询到待测点的空气流动状况,得到所需的第一流场数据。并且,由于神经网络模型中嵌入了物理信息约束,相对于纯数据驱动神经网络模型,能够基于少量的实测数据得到预训练的神经网络模型,同时,相对于不考虑实际环境中的温度、湿度等影响的流体控制方程,嵌入流体控制方程的神经网络模型基于实测数据训练得到,能够同时基于流体控制方程描述的物理规律和计算域的实际情况重构计算域的流场进行预测,能够提高流场预测的准确性,有利于实际工程应用。

[0040] 在一些实施例中,上述流体控制方程为雷诺时均方程,上述预训练的神经网络模型根据如下步骤得到:

[0041] A1、根据上述雷诺时均方程确定上述计算域对应的雷诺时均残差函数。

[0042] A2、基于上述雷诺时均残差函数确定上述待训练的神经网络模型的损失函数,得到上述待训练的神经网络模型。

[0043] A3、获取训练数据,上述训练数据包含从上述计算域中的采样点采集到的多个第二流场数据。

[0044] A4、根据上述训练数据对上述待训练的神经网络模型进行训练,直至训练后的神经网络模型满足预设要求,得到上述预训练的神经网络模型。

[0045] 具体地,由于雷诺时均方程能够较好地描述流体的流动特性,因此,本申请实施例中,采用雷诺时均方程作为嵌入神经网络模型的物理方程,根据该雷诺时均方程确定计算域对应的雷诺时均残差函数,并根据雷诺时均残差函数来确定待训练的神经网络模型的损失函数,即,在采用训练数据对待训练的神经网络模型进行训练的过程中,结合雷诺时均方程描述的物理规律分析确定神经网络模型的预测值和实测值(即第二流场数据)之间的误差,从而提高训练得到的神经网络模型的准确度。其中,在神经网络模型的训练过程中,训练后的神经网络模型满足预设要求(如准确度达预设阈值0.98,和/或迭代次数达预设次数1000等),则可以停止神经网络模型的训练,得到预训练的神经网络模型。

[0046] 本申请实施例中,采用雷诺时均方程作为神经网络模型中嵌入的流体控制方程,而雷诺时均方程在能够较好地描述气体等流体的流动特性,使得嵌入雷诺时均方程的神经网络模型能够基于雷诺时均方程描述的流体流动特性较好地重构流场,从而提高神经网络模型的预测的准确性。并且,由于神经网络模型中嵌入了物理信息约束,相对于纯数据驱动的神经网络模型,能够基于少量的实测数据得到预训练的神经网络模型,同时,相对于不考虑实际环境中的温度、湿度等影响的流体控制方程,嵌入流体控制方程的神经网络模型基于实测数据训练得到,能够同时基于流体控制方程描述的物理规律和计算域的实际情况重构计算域的流场进行预测,能够提高训练得到的神经网络模型的预测准确性,有利于实际应用

[0047] 在一些实施例中,上述步骤A1包括:

[0048] A11、根据上述雷诺时均方程分别确定多个空间方向对应的动量残差函数。

[0049] A12、根据各个上述空间方向对应的上述动量残差函数确定上述雷诺时均残差函数。

[0050] 具体地,由于空气等流体的流动存在如空间竖直方向等多个空间方向的流动,因此,为了更准确地重构计算域中的流场,提高计算域中的空气流动状况的预测准确率,本申请实施例中,基于自动微分,根据该雷诺时均方程分别构建至少两个空间方向(如图2所示的x方向和z方向)对应的动量残差函数,再根据构建的多个空间方向的动量残差函数确定整体的雷诺时均残差函数。

[0051] 在一些实施例中,还可以基于自动微分和雷诺时均方程构建结合多个空间方向的连续性方程残差函数,以充分结合空气流体的整体流动性对空气流动状况产生的影响,提高预测准确率。

[0052] 本申请实施例中,由于在确定雷诺时均残差函数时,从多个空间方向考虑空气的

流动对计算域中的流场的影响,根据雷诺时均方程确定多个空间方向的动量残差函数后,再根据多个空间方向的动量残差函数综合确定最终的雷诺时均残差函数,因此,基于该雷诺残差函数确定神经网络模型的损失函数,能够提高神经网络模型的预测准确率。

[0053] 在一些实施例中,在上述步骤A11之前,还包括:

[0054] A10、根据上述雷诺时均方程和零方程确定封闭后的上述雷诺时均方程。

[0055] 对应地,上述步骤A11包括:

[0056] 根据封闭后的上述雷诺时均方程分别确定各个上述空间方向对应的上述动量残差函数。

[0057] 上述零方程是指使用代数关系式将涡粘系数与时均值联系起来的方程。

[0058] 具体地,为了方便对雷诺时均方程进行求解,减小计算难度和提高神经网络模型的准确性,本申请实施例中,先采用零方程(如李丞零方程)对雷诺时均方程进行封闭,进而,使得根据封闭后的雷诺时均方程能够较好地确定各个空间方向对应的动量残差函数。

[0059] 在一些实施例中,上述雷诺时均方程可以表示为:

$$[0060] \quad \frac{\partial \rho}{\partial t} + \frac{\partial}{\partial i} (\rho V_i) = 0$$

$$[0061] \quad \frac{\partial}{\partial t} (\rho V_i) + \frac{\partial}{\partial i} (\rho V_i V_j) = -\frac{\partial p}{\partial i} + \frac{\partial}{\partial i} [\mu_{eff} (\frac{\partial V_i}{\partial i} + \frac{\partial V_j}{\partial i})]$$

[0062] 其中, ρ 为流体密度,上述 μ_{eff} 表示等效动力粘度, t 表示时间, i 表示空间方向,包括 x 方向、 y 方向和 z 方向, V_i 包括各个空间方向的流速, V_x ($i=x$)即 x 方向的流速 u , V_y ($i=y$)表示 y 方向的流速 v , V_z ($i=z$)表示 z 方向的流速 w ,同理地, j 同样表示空间方向,包括 x 方向、 y 方向和 z 方向。

[0063] 其中,上述等效动力粘度可以表示为如下形式:

$$[0064] \quad \mu_{eff} = \mu_t + \mu$$

[0065] 其中, μ_t 为湍流动力粘度, μ 为层流动力粘度。

[0066] 可选地,第三流场数据包括采样点的 x 方向的流速 u 、 y 方向的流速 v 以及 z 方向的流速 w ,根据上述封闭的雷诺时均方程确定的多个空间方向的动量残差函数可以是如下的形式:

$$[0067] \quad f_1 = u \frac{\partial u}{\partial x} + v \frac{\partial u}{\partial y} + w \frac{\partial u}{\partial z} + \frac{1}{\rho} \frac{\partial p}{\partial x} - \frac{1}{\rho} (\mu + \mu_t) \left(\frac{\partial^2 u}{\partial x^2} + \frac{\partial^2 u}{\partial y^2} + \frac{\partial^2 u}{\partial z^2} \right)$$

$$[0068] \quad f_2 = u \frac{\partial v}{\partial x} + v \frac{\partial v}{\partial y} + w \frac{\partial v}{\partial z} + \frac{1}{\rho} \frac{\partial p}{\partial y} - \frac{1}{\rho} (\mu + \mu_t) \left(\frac{\partial^2 v}{\partial x^2} + \frac{\partial^2 v}{\partial y^2} + \frac{\partial^2 v}{\partial z^2} \right)$$

$$[0069] \quad f_3 = u \frac{\partial w}{\partial x} + v \frac{\partial w}{\partial y} + w \frac{\partial w}{\partial z} + \frac{1}{\rho} \frac{\partial p}{\partial z} - \frac{1}{\rho} (\mu + \mu_t) \left(\frac{\partial^2 w}{\partial x^2} + \frac{\partial^2 w}{\partial y^2} + \frac{\partial^2 w}{\partial z^2} \right)$$

[0070] 其中, f_1 、 f_2 和 f_3 分别对应 x 方向、 y 方向和 z 方向的动量残差函数, u 为第三流场数据中的 x 方向的流速, v 为第三流场数据中的 y 方向的流速, w 为第三流场数据中的 z 方向的流速, ρ 为该第三流场数据对应的采样点的流体(如空气)的密度, t 表示时间, μ 表示层流动力粘度, μ_t 表示湍流动力粘度。

[0071] 在一些实施例中,在根据上述封闭的雷诺时均方程确定的多个空间方向的动量残差函数时,还可以根据封闭的雷诺时均方程确定结合连续性方程残差函数,上述连续性方程残差函数可以表示为如下的形式:

$$[0072] \quad f_4 = \frac{\partial u}{\partial x} + \frac{\partial v}{\partial y} + \frac{\partial w}{\partial z}$$

[0073] 本申请实施例中,将零方程嵌入到雷诺时均方程中,以封闭湍流动力粘度,得到封闭的雷诺时均方程,从而便于求解雷诺时均控制方程,进而便于确定多个空间方向的动量残差函数,在根据预测得到的第三流场数据和实测的第二流场数据对神经网络模型进行训练时,能够从多个空间方向分别分析预测得到的第三流场数据的误差,以结合该误差对神经网络模型进行优化,提高神经网络模型的准确度和减小训练难度。

[0074] 在一些实施例中,上述步骤A10包括:

[0075] 将李丞零方程嵌入上述雷诺时均方程,得到封闭后的上述雷诺时均方程,其中,封闭后的上述雷诺时均方程中的湍流动力粘度根据上述计算域中近壁面的湍流动力粘度和远端处的湍流动力粘度中的较大值确定。

[0076] 具体地,本申请实施例中,将李丞零方程模型嵌入到雷诺时均方程中,通过李丞零方程将雷诺时均方程中未封闭的湍流应力与湍流粘度联合起来,使得未知量转化为湍流粘度变量,从而使得封闭后的雷诺时均方程能够轻松准确地求解得到计算域中的湍流动力粘度,而湍流动力粘度是描述流体动力学和流动性质的指标,能够反映计算域中的流体拖拽力的强度,并反映流体的流态和温度场的分布,因此,通过嵌入李丞零方程封闭的雷诺时均方程能够更好地描述计算域内的流体运动,从而提高嵌入雷诺时均方程的神经网络模型重构的流场的准确性。

[0077] 在一些实施例中,上述嵌入李丞零方程的封闭后的雷诺时均方程可以表示为如下的形式:

$$[0078] \quad \frac{\partial}{\partial t}(\rho V_i) + \frac{\partial}{\partial i}(\rho V_i V_j) = -\frac{\partial p}{\partial i} + \frac{\partial}{\partial i} \left\{ [\max(\mu_{in}, \mu_{out}) + \mu] \left(\frac{\partial V_i}{\partial i} + \frac{\partial V_j}{\partial i} \right) \right\}$$

[0079] 其中, ρ 为流体密度, μ 为层流动力粘度, i 表示空间方向,包括x方向、y方向和z方向, V_i 包括各个空间方向的流速, V_x ($i=x$)即x方向的流速 u , V_y ($i=y$)表示y方向的流速 v , V_z ($i=z$)表示z方向的流速 w ,同理地, j 同样表示空间方向,包括x方向、y方向和z方向。

[0080] 在本申请实施例中,将李丞零方程嵌入到雷诺时均方程之后,封闭后的雷诺时均方程中的湍流动力粘度 μ_t 表示为如下的形式:

$$[0081] \quad \mu_t = \max(\mu_{in}, \mu_{out})$$

[0082] 其中, μ_{in} 和 μ_{out} 分别表示计算域中的近壁面以及远端处的湍流动力粘度,即,在嵌入李丞零方程后,取近壁面的湍流动力粘度 μ_{in} 与远端处的湍流动力粘度 μ_{out} 中的较大值作为封闭后的雷诺时均方程中的湍流动力粘度,而湍流动力粘度能够反映计算域中的流体拖拽力的强度,采用近壁面和远端处对应的两个湍流动力粘度中较大的湍流动力粘度作为求解得到的湍流动力粘度,即通过强度较大的流体拖拽力来重构计算域内的流场,以提高重构的流场的准确性。

[0083] 可选地,上述近壁面的湍流动力粘度 μ_{in} 可以采用普朗特混合长度模型的形式,表

示为如下形式:

$$[0084] \quad \mu_{in} = (C_{in} \cdot 1)^2 S$$

[0085] 其中,参数C_{in}可以表示为如下形式:

$$[0086] \quad C_{in} = 1.8 \times \left(1 - \exp \left(-0.645 \left(\frac{C}{H} \right)^{0.8} \right) \right) \times \exp \left(-2 \times \min \left(\frac{z}{H}, 1 \right) \right)$$

[0087] 其中,C表示计算域中的建筑物的迎风面的宽度,H表示计算域中的建筑物的迎风面的高度。

[0088] 参数S可以表示为如下形式:

$$[0089] \quad S = \sqrt{\frac{1}{2} \left(\frac{\partial u_i}{\partial x_j} + \frac{\partial u_j}{\partial x_i} \right)^2}$$

[0090] 可选地,上述远端处的湍流动力粘度 μ_{out} 可以表示为如下的形式:

$$[0091] \quad \mu_{out} = C_{out} V l$$

[0092] 其中,V为湍流的合速度,l为湍流长度尺度,根据湍流与壁面的最近距离确定,C_{out}为动力粘度系数。

[0093] 其中,该动力粘度系数可以表示为如下形式:

$$[0094] \quad C_{out} = \frac{C_{\mu}^{0.5} I_G^2 z_G^{2\alpha+0.1} z^{0.9-2\alpha}}{\alpha}$$

[0095] 其中,参数C_μ、参数I_G、参数z_G、参数α为预设的数值,在一些实施例中,可设置参数C_μ=0.09,参数I_G=0.1,参数z_G=350,参数α=0.22。

[0096] 本申请实施例中,将李丞零方程嵌入到雷诺时均方程,使得雷诺时均方程中的未知量转化为湍流粘度变量,从而使得封闭后的雷诺时均方程能够轻松准确地求解得到计算域中的湍流动力粘度,同时,将近壁面和远端处对应的两个湍流动力粘度中较大的湍流动力粘度作为封闭后的雷诺时均方程的湍流动力粘度,使得雷诺时均方程能够通过强度更大的流体的拖拽力更准确地描述计算域内流场的流体运动规律,从而更准确地重构计算域内的流场,提高流场预测的准确性。

[0097] 在一些实施例中,上述损失函数包括雷诺时均残差项和数据残差项,上述步骤A4包括:

[0098] A41、将上述采样点对应的第二坐标作为待训练的神经网络模型的输入,得到上述待训练的神经网络模型输出的上述采样点对应的第三流场数据。

[0099] A42、根据上述损失函数中的上述雷诺时均残差项和上述第三流场数据确定上述采样点对应的雷诺时均残差。

[0100] A43、根据上述损失函数中的上述数据残差项、上述采样点对应的第二流场数据和上述第三流场数据确定上述采样点对应的数据残差。

[0101] A44、根据上述采样点对应的上述雷诺时均残差和上述数据残差确定上述待训练的神经网络模型的损失值。

[0102] A45、根据上述损失值对上述待训练的神经网络模型进行更新,直至更新后的上述待训练的神经网络模型满足预设要求,得到训练后的上述神经网络模型。

[0103] 具体地,在训练神经网络模型的过程中,将采样点对应的第二坐标作为神经网络模型的输入,通过神经网络模型预测该采样点的空气流动状况,得到第三流场数据,然后通过损失函数中的雷诺时均残差项和预测得到的第三流场数据计算该采样点的雷诺时均残差,并根据损失函数中的数据残差项计算该采样点的预测的第三流场数据和实测的第二流场数据之间的误差,得到该采样点对应的数据残差。

[0104] 在计算得到采样点的雷诺时均残差和数据残差之后,根据该雷诺时均残差、数据残差综合确定神经网络模型的损失值,并根据该损失值对神经网络模型进行更新,直至更新后的神经网络模型满足预设要求(如迭代次数达预设次数5000次),得到训练后的神经网络模型。

[0105] 在一些实施例中,上述神经网络模型的损失函数可以是如下的形式:

$$[0106] \quad L_{\text{total}} = l_f + l_c$$

[0107] 其中, L_{total} 为神经网络模型的损失函数, L_f 为雷诺时均残差项, L_c 为数据残差项。

[0108] 在一些实施例中,上述数据残差项中包含不同空间方向上的流速残差和压强残差,上述数据残差项可以是如下的形式:

$$[0109] \quad L_c = L_u + L_v + L_w + L_p$$

[0110] L_u 、 L_v 和 L_w 分别对应x方向、y方向和z方向的流速残差, L_p 为压强残差。对应地,上述损失函数可以是如下的形式:

$$[0111] \quad L_{\text{total}} = L_f + L_u + L_v + L_w + L_p$$

[0112] 可选地,上述雷诺时均残差项可以是如下的形式:

$$[0113] \quad L_f = \sum_{n=1,2,3,4} \frac{1}{N} \sum_{i=1}^N |f_n^i|^2$$

[0114] 其中,n为上述动量残差函数的标号, f_n (n取值包括1、2、3、4)对应上述多个空间方向的动量残差函数和连续性方程残差函数,如 f_1 即x方向的动量残差函数, f_4 即结合了多个空间方向的连续性方程残差函数;

[0115] i为训练数据所对应的采样点的序号,N为训练数据所对应的采样点的数量, f^i 即第i个采样点对应的雷诺时均残差, f_n^i 即第i个采样点的雷诺时均残差对应的各个空间方向的动量残差。

[0116] 由上述雷诺时均残差项可知,损失函数中的雷诺时均残差项包含各个采样点的各个动量残差,根据各个动量残差的平方均值确定采样点的雷诺时均残差。

[0117] 可选地,上述数据残差项中的压强残差可以是如下的形式:

$$[0118] \quad L_p = \sum_{m=1,2,3} \frac{1}{N} \sum_{i=1}^N |x_m^i|^2$$

[0119] 其中,m为压强残差函数的标号, x_m (n取值包括1、2、3)对应压强残差函数,其中,各个压强残差函数可以是如下的形式:

$$[0120] \quad x_1 = p_{zpb}$$

[0121] 其中, x_1 为出口边界残差函数, p_{zpb} 为预测的采样点的出口边界的压强。

$$[0122] \quad x_2 = \frac{\partial p_{swb1}}{\partial y}$$

[0123] 其中, x_2 为竖直对称边界压强残差函数, p_{zpb} 为预测的竖直对称边界的压强。

$$[0124] \quad x_3 = \frac{\partial p_{swb2}}{\partial y}$$

[0125] 其中, x_3 为水平对称边界压强残差函数, p_{zpb} 为预测的水平对称边界的压强。

[0126] 可以理解的是, 上述各个压强残差函数根据计算域的各个边界条件构建得到。

[0127] 可选地, 在数据残差项中, x 方向对应的流速残差可以是如下的形式:

$$[0128] \quad L_u = \sum_{l=1,2,3,4,5} \frac{1}{N} \sum_{i=1}^N |y_l^i|^2$$

[0129] 其中, l 为预设的残差函数的标号, y_l (l 取值包括 1、2、3、4、5) 分别对应预设的各个残差函数, i 为训练数据所对应的采样点的序号, N 为训练数据所对应的采样点的数量, y^i 即第 i 个采样点对应的数据残差, y_l^i 即第 i 个采样点的数据残差对应的各个残差。

[0130] 可选地, 上述残差函数 y_l 对应的各个残差函数可以是如下的形式:

$$[0131] \quad y_1 = u_{isb} - u_{initial}$$

$$[0132] \quad y_2 = \frac{\partial u_{swb1}}{\partial y}$$

$$[0133] \quad y_3 = \frac{\partial u_{swb2}}{\partial y}$$

$$[0134] \quad y_4 = u_{wb}$$

$$[0135] \quad y_5 = u - u_{label}$$

[0136] 其中, y_1 为计算域的 x 方向的入口边界残差函数, u_{isb} 为预测的采样点上的入口边界的 x 方向的流速, $u_{initial}$ 为已知的计算域的入口边界的 x 方向的流速;

[0137] y_2 为计算域的 x 方向的竖直对称边界残差函数, u_{swb1} 为预测的采样点上的竖直对称边界的 x 方向的流速;

[0138] y_3 为计算域的 x 方向的水平对称边界残差函数, u_{swb2} 为预测的采样点上的水平对称边界的 x 方向的流速;

[0139] y_4 为计算域的 x 方向的壁面边界残差函数, u_{wb} 为预测的采样点上的壁面边界的 x 方向的流速;

[0140] y_5 为 x 方向的流速残差函数, 用于计算预测的第三采样数据与实测的第二采样数据在 x 方向的流速的差值, u 为采样点对应的第三流场数据中包含的 x 方向的流速, u_{label} 为该采样点对应的第二流场数据中包含的 x 方向的流速。

[0141] 可以理解的是, 采样点的 x 方向的流速残差根据该采样点在 x 方向对应的各个边界条件的残差以及预测的第三流场数据和实测的第二流场数据的残差综合确定, 充分考虑计算域的边界条件对计算域中的采样点的流场数据的影响, 以通过神经网络模型预测的流场数据的准确性。同理地, y 方向和 z 方向对应的流速残差也由 y 方向、 z 方向对应的各个边界条

件残差函数和流速残差函数确定,本申请实施例不再赘述。

[0142] 在一些实施例中,可以根据不同的采样点分别计算各个空间方向对应的动量残差,和/或,根据不同的采样点计算数据残差(例如,根据不同的采样点分别计算各个边界对应的压强残差,和/或,根据不同的采样点分别计算各个空间方向对应的流速残差),即,在计算各个空间方向的动量残差,和/或数据残差时,可以基于不同的采样点进行计算。例如,在计算x、y和z方向的动量残差时,可以基于采样点1-100来计算采样点的x方向的动量残差,基于采样点101-200来计算采样点的y方向的动量残差,基于采样点201-300来计算采样点的z方向的动量残差,使得各个方向的残差(动量残差和/或数据残差)是基于不同的采样点计算得到的,不需要基于每一个采样点计算各个残差,减小训练过程中的计算量。

[0143] 本申请实施例中,根据采样点对应的预测值(即第三流场数据)计算雷诺时均残差和该预测的第三流场数据相对于实测的第二流场数据的数据残差,即,同时从物理规律和实测数据出发分析预测的第三流场数据的误差,再根据综合得到的较为准确的损失值对神经网络模型进行更新,能够减小神经网络模型的训练难度,同时提高训练得到的神经网络模型的准确性。

[0144] 在一些实施例中,上述第二流场数据和上述第三流场数据均包括压强以及不同空间方向上的流速,上述流速用于反映上述采样点在对应的空间方向上的空气流动状况,上述步骤A43包括:

[0145] 根据上述损失函数中的上述数据残差项、上述采样点对应的第二流场数据和上述第三流场数据分别计算上述采样点的压强的残差以及各个上述空间方向上的流速的残差。

[0146] 根据上述采样点的压强的残差以及各个上述空间方向对应的流速的残差以及各个上述残差对应的权重系数确定上述采样点对应的上述数据残差。

[0147] 可选地,上述多个空间方向可以包括地球空间坐标系中的x、y和z坐标轴的方向,即包括x方向、y方向和z方向。

[0148] 具体地,由于流体在不同空间方向上的流速对空气流动状况的影响程度通常存在差异,因此,本申请实施例中,为了进一步提高神经网络模型的准确性,根据损失函数中的数据残差项、采样点对应的第二流场数据和第三流场数据分别计算采样点的各个空间方向上的流速的残差(即流速残差)和采样点的压强的残差(即压强残差),然后将得到的残差(即压强残差以及x方向的流速残差、y方向的流速残差和z方向的流速残差)分别与其对应的权重系数计算各个残差对应的加权残差,再根据各个加权残差确定采样点所对应的数据残差。可选地,上述各个残差对应的权重系数可以是不同的权重系数,以充分考虑不同空间方向的流速对空气流动状况的影响程度,提高神经网络模型的预测准确性。

[0149] 在一些实施例中,上述神经网络模型的损失函数可以是如下的形式:

$$[0150] \quad L_{\text{total}} = L_f + w_u L_u + w_v L_v + w_w L_w + w_p L_p$$

[0151] 其中, L_{total} 为神经网络模型的损失函数, L_f 为雷诺时均残差项, L_u 、 L_v 和 L_w 分别对应数据残差项中的x方向、y方向和z方向的流速残差, w_u 、 w_v 、 w_w 分别对应x方向、y方向和z方向的流速残差的权重系数, L_p 为数据残差项中的压强残差, w_p 为压强残差的权重系数。

[0152] 可选地,压强残差的权重系数 w_p 可以设置为1。此时,上述损失函数可以是如下的形式:

$$[0153] \quad L_{\text{total}} = L_f + w_u L_u + w_v L_v + w_w L_w + L_p$$

[0154] 在一些实施例中,上述各个空间方向的数据残差项对应的权重系数可以是动态权重,在神经网络模型训练过程中,可以根据神经网络模型预测的采样点的第三流场数据和对应的第二流场数据之间的相对误差对各个空间方向的数据残差项对应的权重系数进行更新,通过动态权重使得各个空间方向的数据残差项对应的权重系数保持在合适的量级上,以平衡各个残差项,使得训练后的神经网络模型能够更好地重构计算域中的流场,提高流场预测的准确率。

[0155] 可选地,第三流场数据和对应的第二流场数据之间的相对误差可以表示为如下的形式:

$$[0156] \quad k_i = \frac{\|\mathbf{U}_{T_i} - \tilde{\mathbf{U}}_{T_i}\|_2}{\|\mathbf{U}_{T_i}\|_2}, i = u, v, w$$

[0157] 其中, k_i 为采样点对应的第三流场数据和对应的第二流场数据在空间方向上的流速的相对误差,如在x方向上的流速u的相对误差, $\|\cdot\|_2$ 表示二范数, \mathbf{U}_{T_i} 表示采样点对应的第二流场数据所构成的向量, $\tilde{\mathbf{U}}_{T_i}$ 表示该采样点对应的第三流场数据所构成的向量。

[0158] 可选地,在根据该相对误差对对应的空间方向的数据残差项的权重系数进行更新时,可以根据如下公式进行更新:

$$[0159] \quad w_i = \left[\frac{k_i}{\min_j(k_j)} \right]^\gamma, i, j = u, v, w$$

[0160] 其中, γ 为自定义系数,i和j为空间方向对应的流速,可以取值x方向的流速u、y方向的流速v和z方向的流速w, $\min_j(k_j)$ 即在空间方向对应的流速的相对误差中取最小的相对误差。

[0161] 本申请实施例中,在计算采样点对应的数据残差时,根据各个空间方向上的流速的残差及其对应的权重系数来确定采样点最终的数据残差,充分考虑流体在不同空间方向的流动对空气流动状况的影响程度的差异性,平衡各个空间方向的流速的残差,从而提高神经网络模型预测的准确性。

[0162] 应理解,上述实施例中各步骤的序号的大小并不意味着执行顺序的先后,各过程的执行顺序应以其功能和内在逻辑确定,而不对本申请实施例的实施过程构成任何限定。

[0163] 实施例二:

[0164] 对应于上文实施例所述的流场预测方法,图3示出了本申请实施例提供的流场预测装置的结构框图,为了便于说明,仅示出了与本申请实施例相关的部分。

[0165] 参照图3,该装置包括:第一坐标获取模块31和预测模块32。其中,

[0166] 第一坐标获取模块,用于获取待测点对应的第一坐标,上述待测点为计算域中的坐标点。

[0167] 预测模块,用于将上述第一坐标作为预训练的神经网络模型的输入,得到上述神经网络模型输出的第一流场数据,上述第一流场数据反映了上述待测点对应的空气流动状况;

[0168] 其中,上述神经网络模型基于流体控制方程描述的物理规律重构上述计算域内的流场,根据上述流场和上述第一坐标预测上述待测点的空气流动状况,得到上述第一流场数据。

[0169] 本申请实施例中,由于在神经网络模型中嵌入流体控制方程,使预训练的神经网络模型能够求解嵌入的流体控制方程,从流体控制方程所描述的物理规律出发重构计算域内的流场,相对于通过CFD模拟求解流体控制方程的方式,不需要构建大量的网格,进而,不受网格分辨率的影响,因此,通过预训练的嵌入流体控制方程的神经网络模型能够快速、准确地重构计算域内的流场,并根据重构的流场和第一坐标查询到待测点的空气流动状况,得到所需的第一流场数据。并且,由于神经网络模型中嵌入了物理信息约束,相对于纯数据驱动的神经网络模型,能够基于少量的实测数据得到预训练的神经网络模型,同时,相对于不考虑实际环境中的温度、湿度等影响的流体控制方程,嵌入流体控制方程的神经网络模型基于实测数据训练得到,能够同时基于流体控制方程描述的物理规律和计算域的实际情况重构计算域的流场进行预测,能够提高流场预测的准确性,有利于实际工程应用。

[0170] 在一些实施例中,上述流场预测装置还包括:

[0171] 雷诺残差函数获取模块,用于根据上述雷诺时均方程确定上述计算域对应的雷诺时均残差函数。

[0172] 损失函数获取模块,用于基于上述雷诺时均残差函数确定上述待训练的神经网络模型的损失函数,得到上述待训练的神经网络模型。

[0173] 训练数据获取模块,用于获取训练数据,上述训练数据包含从上述计算域中的采样点采集到的多个第二流场数据。

[0174] 训练模块,用于根据上述训练数据对上述待训练的神经网络模型进行训练,直至训练后的神经网络模型满足预设要求,得到上述预训练的神经网络模型。

[0175] 在一些实施例中,上述雷诺残差函数获取模块包括:

[0176] 动量残差函数确定单元,用于根据上述雷诺时均方程分别确定多个空间方向对应的动量残差函数。

[0177] 雷诺时均残差函数确定单元,用于根据各个上述空间方向对应的上述动量残差函数确定上述雷诺时均残差函数。

[0178] 在一些实施例中,上述流场预测装置还包括:

[0179] 雷诺时均方程确定模块,用于根据上述雷诺时均方程和零方程确定封闭后的上述雷诺时均方程。

[0180] 对应地,上述动量残差函数确定单元还用于根据封闭后的上述雷诺时均方程分别确定各个上述空间方向对应的上述动量残差函数。

[0181] 在一些实施例中,上述雷诺时均方程确定模块包括:

[0182] 雷诺时均方程封闭单元,用于将李丞零方程嵌入上述雷诺时均方程,得到封闭后的上述雷诺时均方程,其中,封闭后的上述雷诺时均方程中的湍流动力粘度根据上述计算域中近壁面的湍流动力粘度和远端处的湍流动力粘度中的较大值确定。

[0183] 在一些实施例中,上述损失函数包括雷诺时均残差项和数据残差项,上述训练模块包括:

[0184] 第三流场数据获取单元,用于将上述采样点对应的第二坐标作为上述待训练的神经

经网络模型的输入,得到上述待训练的神经网络模型输出的上述采样点对应的第三流场数据。

[0185] 雷诺时均残差确定单元,用于根据上述损失函数中的上述雷诺时均残差项和上述第三流场数据确定上述采样点对应的雷诺时均残差。

[0186] 数据残差确定单元,用于根据上述损失函数中的上述数据残差项、上述采样点对应的第二流场数据和上述第三流场数据确定上述采样点对应的数据残差。

[0187] 损失值确定单元,用于根据上述采样点对应的上述雷诺时均残差和上述数据残差确定上述待训练的神经网络模型的损失值。

[0188] 更新单元,用于根据上述损失值对上述待训练神经网络模型进行更新,直至更新后的上述待训练的神经网络模型满足预设要求,得到训练后的上述神经网络模型。

[0189] 在一些实施例中,上述第二流场数据和上述第三流场数据均包括压强以及不同空间方向上的流速,上述流速用于反映上述采样点对应的空间方向上的空气流动状况,上述训练模块包括:

[0190] 流速残差确定单元,用于根据上述损失函数中的上述数据残差项、上述采样点对应的第二流场数据和上述第三流场数据分别计算上述采样点的压强的残差以及各个上述空间方向上的流速的残差。

[0191] 加权单元,用于根据上述采样点的压强的残差以及各个上述空间方向对应的流速的残差以及各个上述残差对应的权重系数确定上述采样点对应的上述数据残差。

[0192] 需要说明的是,上述装置/单元之间的信息交互、执行过程等内容,由于与本申请方法实施例基于同一构思,其具体功能及带来的技术效果,具体可参见方法实施例部分,此处不再赘述。

[0193] 实施例三:

[0194] 图4为本申请一实施例提供的终端设备的结构示意图。如图4所示,该实施例的终端设备4包括:至少一个处理器40(图4中仅示出一个处理器)、存储器41以及存储在所述存储器41中并可在所述至少一个处理器40上运行的计算机程序42,所述处理器40执行所述计算机程序42时实现上述任意各个方法实施例中的步骤。

[0195] 所述终端设备4可以是桌上型计算机、笔记本、掌上电脑及云端服务器等计算设备。该终端设备可包括,但不仅限于,处理器40、存储器41。本领域技术人员可以理解,图4仅仅是终端设备4的举例,并不构成对终端设备4的限定,可以包括比图示更多或更少的部件,或者组合某些部件,或者不同的部件,例如还可以包括输入输出设备、网络接入设备等。

[0196] 所称处理器40可以是中央处理单元(Central Processing Unit,CPU),该处理器40还可以是其他通用处理器、数字信号处理器(Digital Signal Processor,DSP)、专用集成电路(Application Specific Integrated Circuit,ASIC)、现场可编程门阵列(Field-Programmable Gate Array,FPGA)或者其他可编程逻辑器件、分立门或者晶体管逻辑器件、分立硬件组件等。通用处理器可以是微处理器或者该处理器也可以是任何常规的处理器等。

[0197] 所述存储器41在一些实施例中可以是所述终端设备4的内部存储单元,例如终端设备4的硬盘或内存。所述存储器41在另一些实施例中也可以是所述终端设备4的外部存储设备,例如所述终端设备4上配备的插接式硬盘,智能存储卡(Smart Media Card,SMC),安

全数字 (Secure Digital, SD) 卡, 闪存卡 (Flash Card) 等。进一步地, 所述存储器 41 还可以既包括所述终端设备 4 的内部存储单元也包括外部存储设备。所述存储器 41 用于存储操作系统、应用程序、引导装载程序 (BootLoader)、数据以及其他程序等, 例如所述计算机程序的程序代码等。所述存储器 41 还可以用于暂时地存储已经输出或者将要输出的数据。

[0198] 所属领域的技术人员可以清楚地了解到, 为了描述的方便和简洁, 仅以上述各功能单元、模块的划分进行举例说明, 实际应用中, 可以根据需要而将上述功能分配由不同的功能单元、模块完成, 即将所述装置的内部结构划分成不同的功能单元或模块, 以完成以上描述的全部或者部分功能。实施例中的各功能单元、模块可以集成在一个处理单元中, 也可以是各个单元单独物理存在, 也可以两个或两个以上单元集成在一个单元中, 上述集成的单元既可以采用硬件的形式实现, 也可以采用软件功能单元的形式实现。另外, 各功能单元、模块的具体名称也只是为了便于相互区分, 并不用于限制本申请的保护范围。上述系统中单元、模块的具体工作过程, 可以参考前述方法实施例中的对应过程, 在此不再赘述。

[0199] 本申请实施例还提供了一种网络设备, 该网络设备包括: 至少一个处理器、存储器以及存储在所述存储器中并可在所述至少一个处理器上运行的计算机程序, 所述处理器执行所述计算机程序时实现上述任意各个方法实施例中的步骤。

[0200] 本申请实施例还提供了一种计算机可读存储介质, 所述计算机可读存储介质存储有计算机程序, 所述计算机程序被处理器执行时实现可实现上述各个方法实施例中的步骤。

[0201] 本申请实施例提供了一种计算机程序产品, 当计算机程序产品在终端设备上运行时, 使得终端设备执行时实现可实现上述各个方法实施例中的步骤。

[0202] 所述集成的单元如果以软件功能单元的形式实现并作为独立的产品销售或使用, 可以存储在一个计算机可读存储介质中。基于这样的理解, 本申请实现上述实施例方法中的全部或部分流程, 可以通过计算机程序来指令相关的硬件来完成, 所述的计算机程序可存储于一计算机可读存储介质中, 该计算机程序在被处理器执行时, 可实现上述各个方法实施例的步骤。其中, 所述计算机程序包括计算机程序代码, 所述计算机程序代码可以为源代码形式、对象代码形式、可执行文件或某些中间形式等。所述计算机可读介质至少可以包括: 能够将计算机程序代码携带到拍照装置/终端设备的任何实体或装置、记录介质、计算机存储器、只读存储器 (ROM, Read-Only Memory)、随机存取存储器 (RAM, Random Access Memory)、电载波信号、电信信号以及软件分发介质。例如 U 盘、移动硬盘、磁碟或者光盘等。在某些司法管辖区, 根据立法和专利实践, 计算机可读介质不可以是电载波信号和电信信号。

[0203] 在上述实施例中, 对各个实施例的描述都各有侧重, 某个实施例中未详述或记载的部分, 可以参见其它实施例的相关描述。

[0204] 本领域普通技术人员可以意识到, 结合本文中所公开的实施例描述的各示例的单元及算法步骤, 能够以电子硬件、或者计算机软件和电子硬件的结合来实现。这些功能究竟以硬件还是软件方式来执行, 取决于技术方案的特定应用和设计约束条件。专业技术人员可以对每个特定的应用来使用不同方法来实现所描述的功能, 但是这种实现不应认为超出本申请的范围。

[0205] 在本申请所提供的实施例中, 应该理解到, 所揭露的装置/网络设备和方法, 可以

通过其它的方式实现。例如,以上所描述的装置/网络设备实施例仅仅是示意性的,例如,所述模块或单元的划分,仅仅为一种逻辑功能划分,实际实现时可以有另外的划分方式,例如多个单元或组件可以结合或者可以集成到另一个系统,或一些特征可以忽略,或不执行。另一点,所显示或讨论的相互之间的耦合或直接耦合或通讯连接可以是通过一些接口,装置或单元的间接耦合或通讯连接,可以是电性,机械或其它的形式。

[0206] 所述作为分离部件说明的单元可以是或者也可以不是物理上分开的,作为单元显示的部件可以是或者也可以不是物理单元,即可以位于一个地方,或者也可以分布到多个网络单元上。可以根据实际的需要选择其中的部分或者全部单元来实现本实施例方案的目的。

[0207] 以上所述实施例仅用以说明本申请的技术方案,而非对其限制;尽管参照前述实施例对本申请进行了详细的说明,本领域的普通技术人员应当理解:其依然可以对前述各实施例所记载的技术方案进行修改,或者对其中部分技术特征进行等同替换;而这些修改或者替换,并不使相应技术方案的本质脱离本申请各实施例技术方案的精神和范围,均应包含在本申请的保护范围之内。

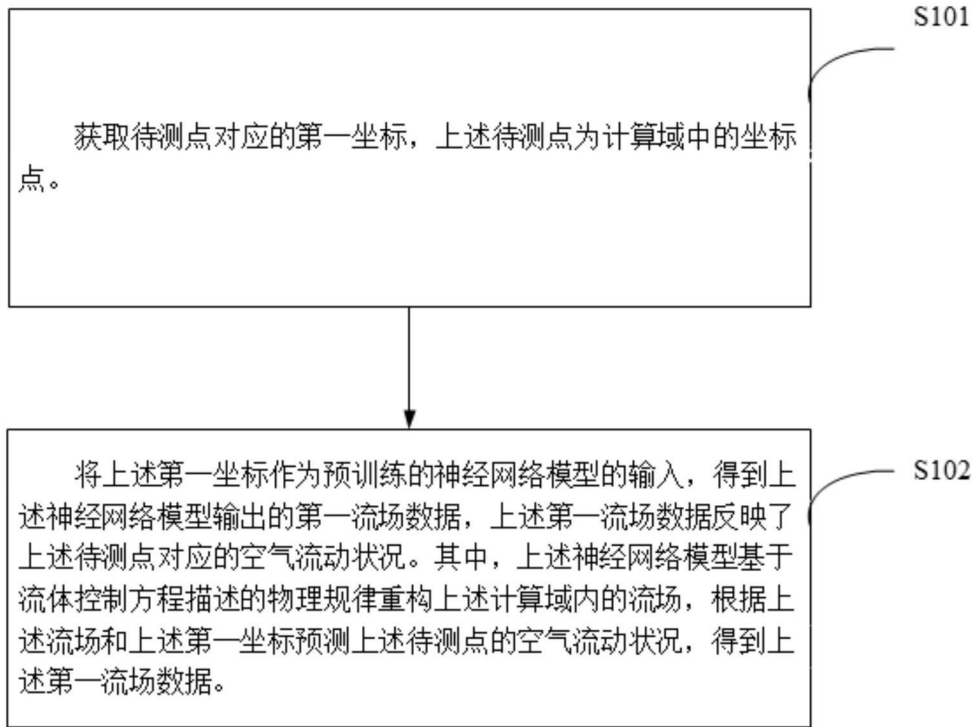


图1




图2




图3

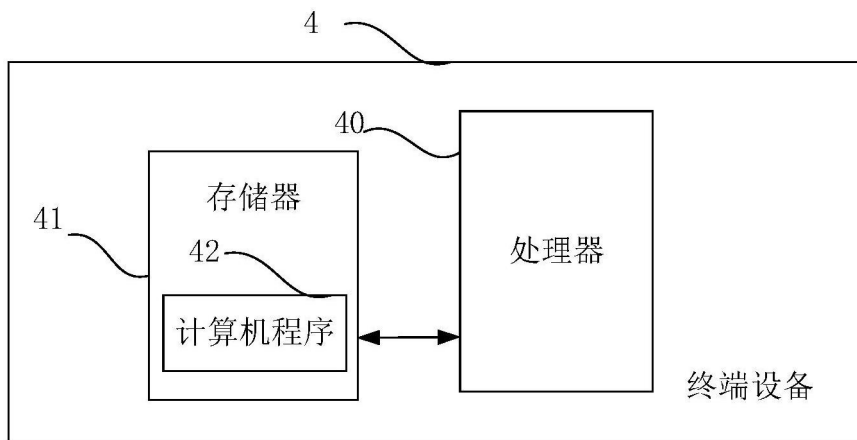


图4