



(12) 发明专利

(10) 授权公告号 CN 120448823 B

(45) 授权公告日 2025. 09. 30

(21) 申请号 202510955351.6

G06F 18/15 (2023.01)

(22) 申请日 2025.07.11

G06F 30/28 (2020.01)

(65) 同一申请的已公布的文献号

G06F 30/27 (2020.01)

申请公布号 CN 120448823 A

G06F 18/27 (2023.01)

(43) 申请公布日 2025.08.08

G06N 3/042 (2023.01)

(73) 专利权人 香港理工大学深圳研究院

G06N 3/045 (2023.01)

地址 518057 广东省深圳市南山区粤海街

G06N 3/0464 (2023.01)

道高新技术产业园南区粤兴一道18号

G06N 3/082 (2023.01)

香港理工大学产学研大楼205室

G06N 3/084 (2023.01)

(72) 发明人 陈争卫 彭程 郭展豪 陆嘉豪

G06F 113/08 (2020.01)

曾广志 郭子健 芮恩泽 曾元江

G06F 119/14 (2020.01)

(74) 专利代理机构 广州嘉权专利商标事务所有  
限公司 44205

(56) 对比文件

CN 115936108 A, 2023.04.07

CN 115564155 A, 2023.01.03

专利代理师 周翀

审查员 李若童

(51) Int. Cl.

G06F 18/214 (2023.01)


权利要求书3页 说明书20页 附图3页

(54) 发明名称

列车表面风压的预测模型训练方法、预测方法及相关装置

(57) 摘要

本申请公开了一种列车表面风压的预测模型训练方法、预测方法及相关装置,其中,该方法包括:采用训练集对预设混合模型进行训练,直至预设混合模型的第一损失函数值满足训练停止条件,得到目标预测模型。其中,预设混合模型包括第一预设模型和第二预设模型,第一预设模型用于基于训练样本预测得到失效压力测点对应的第一预测风压数据,第二预设模型用于基于图结构信息和第一预测风压数据,预测得到失效压力测点对应的第二预测风压数据。如此,可以整合来自不同模型的信息,提高整体预测性能,而第二预设模型利用图结构信息,可以通过图结构帮助预测或插补缺失值,因此,目标预测模型可以应用到任何场景下预测风压数据,提高了应用的广泛性。



1. 一种列车表面风压的预测模型训练方法,其特征在于,包括:

获取训练集;所述训练集包括多个训练样本,其中,各所述训练样本包括风压的影响参数以及列车表面的多个压力测点的风压数据标签,所述多个压力测点的风压数据标签中存在失效压力测点的风压数据标签;

采用所述训练集对预设混合模型进行训练,直至所述预设混合模型的第一损失函数值满足训练停止条件,得到目标预测模型;其中,所述预设混合模型包括第一预设模型和第二预设模型,所述第一预设模型用于基于所述训练样本预测得到所述失效压力测点对应的第一预测风压数据,所述第二预设模型用于基于图结构信息和所述第一预测风压数据,预测得到所述失效压力测点对应的第二预测风压数据,所述第一损失函数值由所述第二预测风压数据与对应的风压数据标签确定,所述图结构信息用于表征所述多个压力测点的空间位置关系,所述目标预测模型用于预测失效压力测点的风压数据;

所述训练样本包括实验训练样本和仿真训练样本,所述采用所述训练集对预设混合模型进行训练,直至所述预设混合模型的第一损失函数值满足训练停止条件,得到目标预测模型,包括:

采用所述训练集对预设混合模型进行训练,直至所述预设混合模型的第一损失函数值满足训练停止条件,得到初始预测模型;

获取验证集;所述验证集包括多个训练样本;

基于高斯过程回归模型,采用所述验证集对所述初始预测模型进行模型性能评估,以调整所述初始预测模型的网络参数,得到所述目标预测模型;其中,所述高斯过程回归模型表示:高保真数据为低保真数据的线性变换加上预设的偏差函数,且所述低保真数据和所述偏差函数服从多变量高斯过程,所述多变量高斯过程的均值为0,以及所述多变量高斯过程的协方差矩阵由低保真数据的协方差函数和所述偏差函数的协方差函数构成,所述高保真数据为实验训练样本对应的第二预测风压数据,所述低保真数据为仿真训练样本对应的第二预测风压数据。

2. 根据权利要求1所述的方法,其特征在于,所述第一损失函数值通过第一目标损失函数计算得到;

其中,所述第一目标损失函数包括第一损失函数和第二损失函数;所述第一损失函数用于确定所述第二预测风压数据与对应的训练样本中风压数据标签之间的均方差,所述第二损失函数为雷诺-纳维斯托克斯方程的残差项。

3. 根据权利要求1所述的方法,其特征在于,所述采用所述训练集对预设混合模型进行训练,直至所述预设混合模型的第一损失函数值满足训练停止条件,得到目标预测模型,包括:

采用所述训练集对预设混合模型进行训练,直至所述预设混合模型的第一损失函数值满足训练停止条件,得到初始预测模型;

获取测试集;所述测试集包括多个训练样本;

采用所述测试集对所述初始预测模型进行测试训练,直至所述初始预测模型的第二损失函数值满足训练停止条件,得到目标预测模型;其中,所述第二损失函数值通过第二目标损失函数计算得到;所述第二目标损失函数包括第三损失函数和第四损失函数,所述第三损失函数用于确定所述第二预测风压数据与对应的训练样本中风压数据标签之间的损失

均值,所述第四损失函数由权重的平方和、正则化参数以及预设系数的乘积得到。

4. 根据权利要求1所述的方法,其特征在于,所述第一预设模型为后向传播神经网络模型,所述第二预设模型为图神经网络模型。

5. 一种列车表面风压的预测方法,其特征在于,包括:

获取目标列车的列车表面的风压的目标影响参数、各有效压力测点的目标风压数据以及多个压力测点的目标图结构信息;

将所述目标影响参数、所述目标风压数据以及所述目标图结构信息输入至目标预测模型,得到所述目标预测模型输出的失效压力测点的风压数据;其中,所述目标预测模型由权利要求1-4任一项所述的列车表面风压的预测模型训练方法得到。

6. 一种列车表面风压的预测模型训练装置,其特征在于,所述装置包括:

第一获取模块,用于获取训练集;所述训练集包括多个训练样本,其中,各所述训练样本包括风压的影响参数以及列车表面的多个压力测点的风压数据标签,所述多个压力测点的风压数据标签中存在失效压力测点的风压数据标签;

训练模块,用于采用所述训练集对预设混合模型进行训练,直至所述预设混合模型的第一损失函数值满足训练停止条件,得到目标预测模型;其中,所述预设混合模型包括第一预设模型和第二预设模型,所述第一预设模型用于基于所述训练样本预测得到所述失效压力测点对应的第一预测风压数据,所述第二预设模型用于基于图结构信息和所述第一预测风压数据,预测得到所述失效压力测点对应的第二预测风压数据,所述第一损失函数值由所述第二预测风压数据与对应的风压数据标签确定,所述图结构信息用于表征所述多个压力测点的空间位置关系,所述目标预测模型用于预测失效压力测点的风压数据;所述训练样本包括实验训练样本和仿真训练样本,采用所述训练集对预设混合模型进行训练,直至所述预设混合模型的第一损失函数值满足训练停止条件,得到初始预测模型;获取验证集;所述验证集包括多个训练样本;基于高斯过程回归模型,采用所述验证集对所述初始预测模型进行模型性能评估,以调整所述初始预测模型的网络参数,得到所述目标预测模型;其中,所述高斯过程回归模型表示:高保真数据为低保真数据的线性变换加上预设的偏差函数,且所述低保真数据和所述偏差函数服从多变量高斯过程,所述多变量高斯过程的均值为0,以及所述多变量高斯过程的协方差矩阵由低保真数据的协方差函数和所述偏差函数的协方差函数构成,所述高保真数据为实验训练样本对应的第二预测风压数据,所述低保真数据为仿真训练样本对应的第二预测风压数据。

7. 一种列车表面风压的预测装置,其特征在于,所述装置包括:

第二获取模块,用于获取目标列车的列车表面的风压的目标影响参数、各有效压力测点的目标风压数据以及多个压力测点的目标图结构信息;

预测模块,用于将所述目标影响参数、所述目标风压数据以及所述目标图结构信息输入至目标预测模型,得到所述目标预测模型输出的失效压力测点的风压数据;其中,所述目标预测模型由权利要求1-4任一项所述的列车表面风压的预测模型训练方法得到。

8. 一种电子设备,其特征在于,所述电子设备包括:处理器以及存储有计算机程序指令的存储器;

所述处理器执行所述计算机程序指令时实现如权利要求1-4任意一项所述的列车表面风压的预测模型训练方法;

或者实现如权利要求5所述的列车表面风压的预测方法。

9.一种计算机可读存储介质,其特征在于,所述计算机可读存储介质上存储有计算机程序指令,所述计算机程序指令被处理器执行时实现如权利要求1-4任意一项所述的列车表面风压的预测模型训练方法;

或者实现如权利要求5所述的列车表面风压的预测方法。

## 列车表面风压的预测模型训练方法、预测方法及相关装置

### 技术领域

[0001] 本申请属于模型应用技术领域,尤其涉及一种列车表面风压的预测模型训练方法、预测方法及相关装置。

### 背景技术

[0002] 磁悬浮列车作为高速运输系统,其压力测点的风压数据主要通过传感器测量,然而,在实际测试中,这些传感器易受振动、冲击、压力变化、电气干扰和化学腐蚀等影响而失效,导致关键数据丢失。

[0003] 因此,在高速运行和环境因素(如横风)的影响下,很有可能导致压力测点的失效问题频发。

[0004] 目前,一般采用传统的数据插补技术对失效压力测点进行预测和插补,但传统的数据插补技术在一些情况下有效,在处理因传感器故障导致的数据缺失问题时表现不佳,故传统的数据插补技术具有一定局限性。

### 发明内容

[0005] 本申请实施例提供一种列车表面风压的预测模型训练方法、预测方法、装置、设备及存储介质,能够提高预测风压数据的应用广泛性。

[0006] 第一方面,本申请实施例提供一种列车表面风压的预测模型训练方法,方法包括:

[0007] 获取训练集;所述训练集包括多个训练样本,其中,各所述训练样本包括风压的影响参数以及列车表面的多个压力测点的风压数据标签,所述多个压力测点的风压数据标签中存在失效压力测点的风压数据标签;

[0008] 采用所述训练集对预设混合模型进行训练,直至所述预设混合模型的第一损失函数值满足训练停止条件,得到目标预测模型;其中,所述预设混合模型包括第一预设模型和第二预设模型,所述第一预设模型用于基于所述训练样本预测得到所述失效压力测点对应的第一预测风压数据,所述第二预设模型用于基于图结构信息和所述第一预测风压数据,预测得到所述失效压力测点对应的第二预测风压数据,所述第一损失函数值由所述第二预测风压数据与对应的风压数据标签确定,所述图结构信息用于表征所述多个压力测点的空间位置关系,所述目标预测模型用于预测失效压力测点的风压数据。

[0009] 在一些实施例中,上述第一损失函数值通过第一目标损失函数计算得到;其中,所述第一目标损失函数包括第一损失函数和第二损失函数;所述第一损失函数用于确定所述第二预测风压数据与对应的训练样本中风压数据标签之间的均方差,所述第二损失函数为雷诺-纳维斯托克斯方程的残差项。

[0010] 在一些实施例中,上述采用所述训练集对预设混合模型进行训练,直至所述预设混合模型的第一损失函数值满足训练停止条件,得到目标预测模型,包括:采用所述训练集对预设混合模型进行训练,直至所述预设混合模型的第一损失函数值满足训练停止条件,得到初始预测模型;获取测试集;所述测试集包括多个所述训练样本;采用所述测试集对所

述初始预测模型进行测试训练,直至所述初始预测模型的第二损失函数值满足训练停止条件,得到目标预测模型;其中,第二损失函数值通过第二目标损失函数计算得到;所述第二目标损失函数包括第三损失函数和第四损失函数,所述第三损失函数用于确定所述第二预测风压数据与对应的训练样本中风压数据标签之间的损失均值,所述第四损失函数由权重的平方和、正则化参数以及预设系数的乘积得到。

[0011] 在一些实施例中,上述训练样本包括实验训练样本和仿真训练样本,所述采用所述训练集对预设混合模型进行训练,直至所述预设混合模型的第一损失函数值满足训练停止条件,得到目标预测模型,包括:采用所述训练集对预设混合模型进行训练,直至所述预设混合模型的第一损失函数值满足训练停止条件,得到初始预测模型;获取验证集;所述验证集包括多个训练样本;基于高斯过程回归模型,采用所述验证集对所述初始预测模型进行模型性能评估,以调整所述初始预测模型的网络参数,得到所述目标预测模型;其中,所述高斯过程回归模型表示高保真数据为低保真数据的线性变换加上预设的偏差函数,且所述低保真数据和所述偏差函数服从多变量高斯过程,所述多变量高斯过程的均值为0以及协方差矩阵由低保真数据的协方差函数和所述偏差函数的协方差函数构成,所述高保真数据为实验训练样本对应的第二预测风压数据,所述低保真数据为仿真训练样本对应的第二预测风压数据。

[0012] 在一些实施例中,上述第一预设模型为后向传播神经网络模型,所述第二预设模型为图神经网络模型。

[0013] 第二方面,本申请实施例提供了一种列车表面风压的预测方法,方法包括:

[0014] 获取目标列车的列车表面的风压的目标影响参数、各有效压力测点的目标风压数据以及多个压力测点的目标图结构信息;

[0015] 将所述目标影响参数、所述目标风压数据以及所述目标图结构信息输入至目标预测模型,得到所述目标预测模型输出的失效压力测点的的风压数据;其中,所述目标预测模型由第一方面任一项所述的列车表面风压的预测模型训练方法得到。

[0016] 第三方面,本申请实施例提供了一种列车表面风压的预测模型训练装置,装置包括:

[0017] 第一获取模块,用于获取训练集;所述训练集包括多个训练样本,其中,各所述训练样本包括风压的影响参数以及列车表面的多个压力测点的的风压数据标签,所述多个压力测点的的风压数据标签中存在失效压力测点的的风压数据标签;

[0018] 训练模块,用于采用所述训练集对预设混合模型进行训练,直至所述预设混合模型的第一损失函数值满足训练停止条件,得到目标预测模型;其中,所述预设混合模型包括第一预设模型和第二预设模型,所述第一预设模型用于基于所述训练样本预测得到所述失效压力测点对应的的第一预测风压数据,所述第二预设模型用于基于图结构信息和所述第一预测风压数据,预测得到所述失效压力测点对应的第二预测风压数据,所述第一损失函数值由所述第二预测风压数据与对应的风压数据标签确定,所述图结构信息用于表征所述多个压力测点的空间位置关系,所述目标预测模型用于预测失效压力测点的的风压数据。

[0019] 第三方面,本申请实施例提供了一种列车表面风压的预测模型训练装置,装置包括:

[0020] 第二获取模块,用于获取目标列车的列车表面的风压的目标影响参数、各有效压

力测点的目标风压数据以及多个压力测点的目标图结构信息；

[0021] 预测模块,用于将所述目标影响参数、所述目标风压数据以及所述目标图结构信息输入至目标预测模型,得到所述目标预测模型输出的失效压力测点的风压数据;其中,所述目标预测模型由第一方面任一项所述的列车表面风压的预测模型训练方法得到。

[0022] 第五方面,本申请实施例提供了一种电子设备,电子设备包括:处理器以及存储有计算机程序指令的存储器;处理器执行计算机程序指令时实现如第一方面所述的列车表面风压的预测模型训练方法;

[0023] 或者实现如第二方面所述的列车表面风压的预测方法。

[0024] 第六方面,本申请实施例提供了一种计算机可读存储介质,计算机可读存储介质上存储有计算机程序指令,计算机程序指令被处理器执行时实现如第一方面所述的列车表面风压的预测模型训练方法;

[0025] 或者,实现如第二方面所述的列车表面风压的预测方法。

[0026] 第七方面,本申请实施例提供了一种计算机程序产品,计算机程序产品中的指令由电子设备的处理器执行时,使得所述电子设备执行如第一方面所述的列车表面风压的预测模型训练方法;

[0027] 或者,执行如第二方面所述的列车表面风压的预测方法。

[0028] 本申请实施例的列车表面风压的预测模型训练方法、预测方法、装置、设备及存储介质,通过采用训练集对预设混合模型进行训练,直至预设混合模型的第一损失函数值满足训练停止条件,得到目标预测模型。如此,实现第一预设模型捕捉到一些第二预设模型未能捕捉到的数据特征,通过结合两者的预测结果,可以整合来自不同模型的信息,从而能提高整体预测性能,而第二预设模型利用图结构信息,能够学习风压测点之间的空间关系,使每个节点(风压测点)可以接收来自其邻居节点的信息,在插补任务中,已知节点的风压数据可以通过图结构传播到未知节点,帮助预测或插补缺失值,因此,本申请中得到的目标预测模型可以应用到列车的任何场景下预测失效风压测点的风压数据,提高了应用的广泛性。

## 附图说明

[0029] 为了更清楚地说明本申请实施例的技术方案,下面将对本申请实施例中所需要使用的附图作简单的介绍,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。

[0030] 图1是本申请实施例提供的列车表面风压的预测模型训练方法的流程示意图;

[0031] 图2是本申请实施例提供的BPNN与GNN混合神经网络模型示意图;

[0032] 图3为本申请实施例提供的预设列车的示意图;

[0033] 图4为本申请实施例提供的数值仿真计算区域与边界条件策略的三维视图;

[0034] 图5是本申请实施例提供的列车表面风压的预测方法的流程示意图;

[0035] 图6为本申请实施例提供的列车表面风压的预测模型训练装置的结构示意图;

[0036] 图7为本申请实施例提供的列车表面风压的预测装置的结构示意图;

[0037] 图8是本申请实施例提供的电子设备的结构示意图。

## 具体实施方式

[0038] 下面将详细描述本申请的各个方面的特征和示例性实施例,为了使本申请的目的、技术方案及优点更加清楚明白,以下结合附图及具体实施例,对本申请进行进一步详细描述。应理解,此处所描述的具体实施例仅意在解释本申请,而不是限定本申请。对于本领域技术人员来说,本申请可以在不需要这些具体细节中的一些细节的情况下实施。下面对实施例的描述仅仅是为了通过示出本申请的示例来提供对本申请更好的理解。

[0039] 需要说明的是,在本文中,诸如第一和第二等之类的关系术语仅仅用来将一个实体或者操作与另一个实体或操作区分开来,而不一定要求或者暗示这些实体或操作之间存在任何这种实际的关系或者顺序。而且,术语“包括”、“包含”或者其任何其他变体意在涵盖非排他性的包含,从而使得包括一系列要素的过程、方法、物品或者设备不仅包括那些要素,而且还包括没有明确列出的其他要素,或者是还包括为这种过程、方法、物品或者设备所固有的要素。在没有更多限制的情况下,由语句“包括……”限定的要素,并不排除在包括所述要素的过程、方法、物品或者设备中还存在另外的相同要素。

[0040] 为了解决相关技术问题,本申请实施例提供了一种列车表面风压的预测模型训练方法、装置、设备、存储介质及计算机程序产品。下面首先对本申请实施例所提供的列车表面风压的预测模型训练方法进行介绍。

[0041] 图1示出了本申请实施例提供的列车表面风压的预测模型训练方法的流程示意图。如图1所示,该列车表面风压的预测模型训练方法具体包括如下步骤:

[0042] 步骤S101,获取训练集。

[0043] 步骤S102,采用训练集对预设混合模型进行训练,直至预设混合模型的第一损失函数值满足训练停止条件,得到目标预测模型。

[0044] 上述训练集包括多个训练样本。

[0045] 其中,各训练样本包括风压的影响参数以及列车表面的多个压力测点的风压数据标签。

[0046] 上述影响参数可以为列车运行状态信息以及与列车表面所受的风的相关联信息,比如速度、加速度、环境风速(列车表面所受的风的风速)、风向以及偏航角等。

[0047] 上述多个压力测点的风压数据标签中存在失效压力测点的风压数据标签。

[0048] 上述失效压力测点可以是无法测量到风压数据的压力测点或者测量出的风压数据具有较大误差的压力测点。

[0049] 在一种实施方式中,上述失效压力测点的风压数据标签具有失效标识,即通过对失效压力测点的风压数据标签进行失效标识,来指示风压数据标签为失效风压数据标签,可以是对失效压力测点的风压数据标签进行标记。

[0050] 在一种实施方式中,上述风压数据标签可以具有对应的压力测点标识,来指示风压数据标签所对应的压力测点。

[0051] 比如,假设列车表面有 $\gamma$ 个压力测点,每个压力测点的风压数据为 $y_{\xi}$ ,状态标记为 $\varphi_{\xi}$ , $\xi$ 取值1至 $\gamma$ ,影响参数为 $s_{\alpha}$ , $\alpha$ 取值1至G,G为影响参数包括的参数的数量,则训练样本可以构成测点特征矩阵Y和影响参数特征信息s如下:

[0052] 测点特征矩阵Y:

$$[0053] \quad Y = \begin{bmatrix} y_1 & \varphi_1 \\ y_2 & \varphi_2 \\ y_3 & \varphi_3 \\ \vdots & \vdots \\ y_\gamma & \varphi_\gamma \end{bmatrix};$$

[0054] 其中,每一行表示一个压力测点的风压数据和状态标记。

$$[0055] \quad s = [s_1, s_2, s_3, \dots, s_G];$$

[0056] 其中,  $s_1, s_2, s_3, \dots, s_G$  分别表示不同的影响参数。

[0057] 上述预设混合模型包括第一预设模型和第二预设模型。

[0058] 上述第一预设模型用于基于训练样本预测得到失效压力测点对应的第一预测风压数据。

[0059] 上述第二预设模型用于基于图结构信息和第一预测风压数据,预测得到失效压力测点对应的第二预测风压数据。

[0060] 上述失效压力测点对应的第一预测风压数据可以是训练样本中各个失效风压数据标签对应的第一预测风压数据。上述失效压力测点对应的第二预测风压数据可以是训练样本中各个失效风压数据标签对应的第二预测风压数据。

[0061] 上述第一损失函数值由第二预测风压数据与对应的风压数据标签确定。

[0062] 上述图结构信息用于表征多个压力测点的空间位置关系。

[0063] 上述目标预测模型用于预测失效压力测点的风压数据。

[0064] 在一种实施方式中,上述采用训练集对预设混合模型进行训练,直至预设混合模型的第一损失函数值满足训练停止条件,得到目标预测模型,可以是将训练样本输入至预设混合模型,采用第一预设模型基于训练样本预测得到失效压力测点对应的第一预测风压数据,并将图结构信息和第一预测风压数据输入至第二预设模型,采用第二预设模型基于图结构信息和第一预测风压数据,输出失效压力测点对应的第二预测风压数据,基于失效压力测点对应的第二预测风压数据和失效压力测点对应的风压数据标签,确定第一损失函数值,并基于第一损失函数值调整预设混合模型的网络参数,继续训练迭代,直至第一损失函数值满足训练停止条件,得到目标预测模型。

[0065] 在一些实施方式中,上述训练样本还可以包括图结构信息。

[0066] 上述图结构信息用于描述节点(顶点)之间的关系,图结构信息可以由邻接矩阵来定义。

[0067] 邻接矩阵(Adjacency Matrix)是一个二维矩阵,用于表示节点之间的连接关系。

[0068] 矩阵维度:假设图中有  $\gamma$  个节点,邻接矩阵  $A$  是一个  $\gamma \times \gamma$  的矩阵。

[0069] 矩阵元素:  $A_{cd}=1$  表示节点  $c$  和节点  $d$  之间存在边,  $A_{cd}=0$  表示节点  $c$  和节点  $d$  之间不存在边。

[0070] 在本实施例中,上述节点可以为压力测点,当列车表面有  $\gamma$  个压力测点时,邻接矩阵  $A$  可以表示为:

$$[0071] \quad A = \begin{bmatrix} A_{11} & A_{12} & \cdots & A_{1y} \\ A_{21} & A_{22} & \cdots & A_{2y} \\ \vdots & \vdots & \ddots & \vdots \\ A_{y1} & A_{y2} & \cdots & A_{yy} \end{bmatrix}。$$

[0072] 因此,模型的输入流程可以如下:

[0073] 首先,数据准备:获取所有压力测点的风压数据为  $y_\xi$ 、每个测点的状态标记  $\varphi_\xi$  以及影响参数  $s_\alpha$ 。

[0074] 数据组织:将风压数据和状态标记组合成测点特征矩阵  $Y$ ,构建影响参数特征向量  $s$ ,以及构建邻接矩阵  $A$ ,将测点特征矩阵  $Y$ 、影响参数特征向量  $s$  以及邻接矩阵  $A$  作为训练样本。

[0075] 模型处理:将训练样本输入到第一预设模型,第一预设模型提取全局信息,并输出中间特征(失效压力测点对应的第一预测风压数据),将第一预设模型输出的中间特征和邻接矩阵  $A$  输入到第二预设模型,第二预设模型利用压力测点之间的空间关系,进一步处理数据,并输出失效压力测点对应的第二预测风压数据。

[0076] 在一种实施方式中,上述第一预设模型可以用于基于训练样本预测得到各个压力测点对应的第一预测风压数据,各个压力测点对应的第一预测风压数据包括失效压力测点对应的第一预测风压数据,上述第二预设模型用于基于图结构信息和第一预测风压数据,预测得到各个压力测点对应的第二预测风压数据,各个压力测点对应的第二预测风压数据包括失效压力测点对应的第二预测风压数据。

[0077] 以第一预设模型为后向传播神经网络(BPNN)和第二预设模型为图神经网络(GNN)为例,参照图2,图2为本申请实施例提供的BPNN与GNN混合神经网络模型示意图,模型的输入流程可以如下:

[0078] 首先,数据准备:获取所有压力测点的风压数据为  $y_\xi$ 、每个测点的状态标记  $\varphi_\xi$  以及影响参数  $s_\alpha$ 。

[0079] 数据组织:将风压数据和状态标记组合成测点特征矩阵  $Y$ ,构建影响参数特征向量  $s$ ,以及构建邻接矩阵  $A$ ,将测点特征矩阵  $Y$ 、影响参数特征向量  $s$  以及邻接矩阵  $A$  作为训练样本。

[0080] 模型处理:将训练样本  $x_i$  经由输入层输入到后向传播神经网络(BPNN),后向传播神经网络(BPNN)提取全局信息,并输出中间特征(失效压力测点对应的第一预测风压数据),将后向传播神经网络(BPNN)输出的中间特征和邻接矩阵  $A$  输入到图神经网络(GNN),图神经网络(GNN)利用压力测点之间的空间关系,进一步处理数据,并通过输出层输出训练样本  $x_i$  对应的失效压力测点对应的第二预测风压数据  $\hat{y}_i$  (预测值)。其中, $i$ 取值从1至 $m$ , $m$ 为训练样本的数量。通过第二预测风压数据  $\hat{y}_i$  与对应的风压数据标签(真实值),进行后向传播以及更新迭代。

[0081] 在一种实施例中,上述训练集可以包括多个不同型号的列车对应的训练样本,训练样本还可以包括表征列车型号的型号信息,型号信息可以包括列车的高度、宽度以及列车形状等中至少一项。

[0082] 在一些实施例中,上述第一损失函数值通过第一目标损失函数计算得到。

[0083] 其中,上述第一目标损失函数包括第一损失函数和第二损失函数。

[0084] 上述第一损失函数用于确定第二预测风压数据与对应的训练样本中风压数据标签之间的均方差,第二损失函数为雷诺-纳维斯托克斯方程的残差项。

[0085] 在一种实施方式中,上述第一目标损失函数可以如下公式(1)、(2)、(3)所示:

$$Loss = Loss_{data} + \omega Loss_{NS} \quad (1);$$

$$Loss_{data} = \frac{1}{N} \sum_{i=1}^N \|\hat{y}_i - y_i\|^2 \quad (2);$$

$$Loss_{NS} = \frac{1}{M} \sum_{j=1}^M \left\| (u \cdot \nabla)u + \frac{1}{\rho} \nabla p - \nu \nabla^2 u \right\|_{x_j}^2 \quad (3);$$

[0088] 其中,Loss表示第一目标损失函数,用于反向传播更新参数。 $Loss_{data}$ 表示第一损失函数, $Loss_{data}$ 为纯数据拟合损失,一般衡量预测值与真实值之间的差异。 $Loss_{NS}$ 表示第二损失函数, $Loss_{NS}$ 为方程残差损失,用以“软约束”网络满足流体力学方程。 $\omega$ 为控制两部分损失权重的超参数,通常需通过交叉验证或经验调优来选取。 $N$ 是用于计算数据损失的样本总数,即 $N$ 可以表示针对训练样本输出的第二预测风压数据的数量。 $y_i$ 表示第 $i$ 个样本的真实标签, $i$ 表示在针对训练样本输出的第二预测风压数据中的序号, $y_i$ 表示第 $i$ 个第二预测风压数据对应的风压数据标签。 $\hat{y}_i$ 表示网络对第 $i$ 个输入样本的预测值,使得与 $y_i$ 同维度,即 $\hat{y}_i$ 表示第 $i$ 个第二预测风压数据。 $\|\hat{y}_i - y_i\|^2$ 表示预测与真实之间的平方误差。

$Loss_{data}$ 的因子 $\frac{1}{N}$ 表示平均化所有样本的均方误差。 $M$ 为在约束损失中用于采样残差的空间/时间点总数。 $u = u(x) \in \mathbf{R}^3$ 表示流场的速度向量函数,依赖空间坐标 $x$ ,即三维速度场 $(u_x, u_y, u_z)$ 。 $\nabla$ 表示空间梯度算子,作用于标量或矢量场。 $(u \cdot \nabla)u$ 表示对速度做对流项(即 $\sum_g u_g \partial_{x_g} u$ ),描述流体对自身速度的传输。 $\nabla p$ 为压力梯度。 $\nu$ :运动黏性系数,通常 $\nu = \mu/\rho$ ,其中 $\mu$ 是动力黏度。 $\nabla^2 u$ :拉普拉斯算子作用于速度向量,等同于 $\sum_g \partial_{x_g}^2 u$ 。

$\|\cdots\|_{x_j}^2$ :在第 $j$ 个空间点 $x_j$ 上,将括号内的矢量残差求二范数平方。

[0089] 在一些实施例中,上述步骤S102还可以包括但不限于包括如下:

[0090] 采用训练集对预设混合模型进行训练,直至预设混合模型的第一损失函数值满足训练停止条件,得到初始预测模型。

[0091] 获取测试集。

[0092] 上述测试集包括多个训练样本。

[0093] 在一种实施方式中,测试集中的训练样本与训练集中的训练样本不同。

[0094] 采用测试集对初始预测模型进行测试训练,直至初始预测模型的第二损失函数值满足训练停止条件,得到目标预测模型。

[0094] 采用测试集对初始预测模型进行测试训练,直至初始预测模型的第二损失函数值满足训练停止条件,得到目标预测模型。

[0095] 其中,上述第二损失函数值通过第二目标损失函数计算得到。

[0096] 上述第二目标损失函数包括第三损失函数和第四损失函数。

[0097] 上述第三损失函数用于确定第二预测风压数据与对应的训练样本中风压数据标签之间的损失均值。

[0098] 上述第四损失函数由权重的平方和、正则化参数以及预设系数的乘积得到。

[0099] 在一种实施方式中,上述第二目标损失函数可以如下公式(4)所示:

$$[0100] \quad R(\theta) = \frac{1}{N} \sum_{i=1}^N \ell(y_i, f(x_i; \theta)) + \gamma \lambda \|\theta\|_2^2 \quad (4);$$

[0101] 其中,  $\theta \in \mathbf{R}^d$  为预设混合模型的网络参数向量,  $\ell$  为单点损失,  $\ell$  表示第二预测风压数据与对应的训练样本中风压数据标签之间的损失, 可以为平方误差或交叉熵等,  $N$  表示针对训练样本输出的第二预测风压数据的数量。

[0102] 第三损失函数为  $\frac{1}{N} \sum_{i=1}^N \ell(y_i, f(x_i; \theta))$ , 即  $\frac{1}{N} \sum_{i=1}^N \ell(y_i, f(x_i; \theta))$  可以表示训练样本对应的各个第二预测风压数据与训练样本中对应的风压数据标签的损失之间的均值。

[0103] 第四损失函数为  $\gamma \lambda \|\theta\|_2^2$ , 其中,  $\gamma$  表示预设系数,  $\lambda$  表示正则化参数,  $\lambda > 0$  为约束强度,  $\|\theta\|_2^2$  表示权重的平方和,  $\gamma$  可以取值为  $\frac{1}{4}$ 。

[0104] 在一些实施例中, 上述训练样本包括实验训练样本和仿真训练样本, 上述实验训练样本来源于实际的实验操作, 上述仿真训练样本通过计算机仿真生成, 上述仿真训练样本可以与实验训练样本对应相同工况, 即在与实验训练样本的相同工况下通过计算机仿真得到仿真训练样本。

[0105] 上述列车可以为磁悬浮列车、高铁、飞机等。

[0106] 在一种实施方式中, 可以利用雷诺平均纳维-斯托克斯方程模拟列车在不同偏航角和风速下的气动表现, 生成仿真训练样本, 比如, 模拟列车在不同偏航角 ( $15^\circ$ 、 $30^\circ$ 、 $45^\circ$ 、 $60^\circ$ ) 和统一风速 ( $60\text{m/s}$ ) 下的气动表现。在与实验训练样本的相同工况下进行风洞实验, 收集列车模型在相同条件下的气动力数据, 得到实验训练样本, 上述气动力数据可以包括影响参数和对应的风压数据。

[0107] 在一种实施方式中, 上述仿真训练样本可以通过如下方式获取:

[0108] 构建预设尺寸的预设列车以及围绕预设列车定义的计算域。

[0109] 上述预设尺寸可以包括列车的特征高度  $H_{\text{高度}}$ 、列车的特征长度  $L_{\text{长度}}$ 、列车的特征宽度  $W_{\text{宽度}}$  以及列车的横截面积等。

[0110] 上述计算域为数值仿真计算区域。

[0111] 参照图3, 图3为本申请实施例提供的预设列车的示意图, 如图3所示, 预设列车的特征高度  $H_{\text{高度}}$  为  $4.2$ 、特征长度  $L_{\text{长度}}$  为  $19.04H_{\text{高度}}$ 、特征宽度  $W_{\text{宽度}}$  为  $0.88H_{\text{高度}}$ , 单位 Unit 为米 (m), 其中, 特征长度  $L_{\text{长度}}$  包括列车头部 Head 的特征长度、列车中部 Middle 的特征长度以及列车尾部 Tail 的特征长度, 列车头部 Head 的特征长度、列车中部 Middle 的特征长度以及列车尾部 Tail 的特征长度分别为  $6.42H_{\text{高度}}$ 、 $6.20H_{\text{高度}}$  以及  $6.42H_{\text{高度}}$ 。

[0112] 基于预设列车沿着预设列车定义的计算域的目标方向行驶, 模拟预设列车处于横

风下的运行状态,在模拟预设列车处于横风下的运行状态下,获取气动力数据。

[0113] 其中,通过计算域的第一速度入口引入主来流,以及通过计算域的第二速度入口模拟横风,计算域的第一边界面和计算域的第二边界面被配置为零压出口,以模拟预设列车远端的实际大气环境。

[0114] 根据气动力数据,构建仿真训练样本。

[0115] 参照图4,图4为本申请实施例提供的数值仿真计算区域与边界条件策略的三维视图,如图4所示,三维视图包括第一速度入口1、第二速度入口2、第一压力出口1(第一边界面)、第一压力出口2(第二边界面)。

[0116] 其中,列车的横截面积与计算域的横截面积之比小于预设值,预设值可以小于1,预设值可以为0.01,计算域的高度不低于列车的特征高度的第一预设倍数,第一预设倍数可以为8倍,计算域的上游距离至少为列车的特征高度的第一预设倍数,计算域的下游距离至少为列车的特征高度的第二预设倍数,第二预设倍数可以为第一预设倍数的两倍,比如,第一预设倍数可以为8倍,第二预设倍数可以为16倍。流场的横向宽度在迎风侧至少为列车的特征高度的第一预设倍数,流场的横向宽度在背风侧至少为列车的特征高度的第二预设倍数。

[0117] 比如,模拟列车在开阔场地环境中沿  $x$  方向运行,围绕列车所定义的计算域为矩形区域,并遵循严格规范。列车横截面积与计算域横截面积之比小于 0.01,计算域高度不低于特征高度的 8 倍,上游距离至少为特征高度的 8 倍,下游距离至少为特征高度的 16 倍,此外,流场的横向宽度在迎风侧至少为特征高度的 8 倍,在背风侧至少为特征高度的 16 倍。模拟基于相对运动原理,列车保持静止,通过在前方施加来流以模拟列车的前进。参照图4,边界  $ABB_1A_1$  被设置为速度入口 1,用于引入主来流,边界  $ADD_1A_1$  被设置为速度入口 2,用于模拟横风作用。此两入口处的速度分量分别定义为  $v_1 = v \cos \theta$ ,  $v_1$  为列车的行驶速度,  $v_2 = v \sin \theta$ ,  $v_2$  为横风作用的速度,  $v$  为横风的速度。二者构建合成CFD计算中的速度来流。边界面  $CDD_1C_1$  (压力出口1)和  $CBB_1C_1$  (压力出口2)被配置为零压出口,以模拟列车远端的实际大气环境。地面和轨道表面(ABCD)被处理为移动无滑移壁面,其运动速度与列车速度相反,以确保相对运动的准确模拟。顶面  $A_1B_1C_1D_1$  被指定为对称面,禁止任何对流通量,并确保垂直速度分量为零。列车表面被定义为无滑移壁面,以精确模拟流体与列车表面的相互作用。在图4中,列车的特征长度为  $L$ ,计算域的沿  $x$  方向的长度为  $2L + L + L$ ,计算域的沿  $y$  方向的宽度为  $L + 2L$ ,计算域的沿  $z$  方向的高度为  $L$ 。

[0118] 在一种实施方式中,上述步骤S102还可以包括但不限于包括如下:

[0119] 采用训练集对预设混合模型进行训练,直至预设混合模型的第一损失函数值满足训练停止条件,得到初始预测模型。

[0120] 获取验证集。

[0121] 上述验证集包括多个训练样本。

[0122] 在一种实施方式中,上述验证集中的训练样本可以与训练集和测试集中的训练样本不同。

[0123] 基于高斯过程回归模型,采用验证集对初始预测模型进行模型性能评估,以调整初始预测模型的网络参数,得到目标预测模型。

[0124] 其中,高斯过程回归模型表示高保真数据为低保真数据的线性变换加上预设的偏

差函数,且低保真数据和偏差函数服从多变量高斯过程,多变量高斯过程的均值为0以及协方差矩阵由低保真数据的协方差函数和偏差函数的协方差函数构成,高保真数据为实验训练样本对应的第二预测风压数据,低保真数据为仿真训练样本对应的第二预测风压数据。

[0125] 在一种实施方式中,上述高斯过程回归模型可以如下公式(5)所示:

$$[0126] \quad y_H(\mathbf{x}) = \delta y_L(\mathbf{x}) + \delta(\mathbf{x}), (\delta) \sim \mathcal{GP}(\mathbf{0}, \begin{bmatrix} k_{LL} & \mathbf{0} \\ \mathbf{0} & k_{\delta\delta} \end{bmatrix}) \quad (5);$$

[0127] 其中, $y_L$ 、 $y_H$ 分别为低保真数据和高保真数据, $\delta$ 经最大似然估计获得。 $\delta(\mathbf{x})$ 表示偏差函数,刻画 $y_H(\mathbf{x})$ 与 $\delta y_L(\mathbf{x})$ 之间的非线性差异,被假定为高斯过程。 $\mathcal{GP}(\mathbf{0}, \zeta)$ 表示高斯过程先验,均值为0,协方差矩阵为 $\zeta$ ,即 $\begin{bmatrix} k_{LL} & \mathbf{0} \\ \mathbf{0} & k_{\delta\delta} \end{bmatrix}$ 。 $k_{LL}$ 表示低保真数据自身的协方差核函数,对应于 $\text{cov}(y_L(\mathbf{x}), y_L(\mathbf{x}'))$ 。 $k_{\delta\delta}$ 表示偏差函数 $\delta$ 的协方差核函数,对应于 $\text{cov}(\delta(\mathbf{x}), \delta(\mathbf{x}'))$ 。协方差矩阵中 $\begin{bmatrix} k_{LL} & \mathbf{0} \\ \mathbf{0} & k_{\delta\delta} \end{bmatrix}$ 表示 $y_L$ 与 $\delta$ 之间相互独立,且各自满足对应的高斯过程先验。

[0128] 在一些实施例中,上述步骤S102还可以包括:

[0129] 采用训练集对预设混合模型进行训练,直至预设混合模型的第一损失函数值满足训练停止条件,得到第一预测模型。

[0130] 获取测试集。

[0131] 采用测试集对第一预测模型进行测试训练,直至第一预测模型的第二损失函数值满足训练停止条件,得到第二预测模型。

[0132] 获取验证集。

[0133] 基于高斯过程回归模型,采用验证集对第二预测模型进行模型性能评估,以调整第二预测模型的网络参数,得到目标预测模型。

[0134] 上述采用测试集对第一预测模型进行测试训练,直至第一预测模型的第二损失函数值满足训练停止条件,得到第二预测模型,可以参照前述的采用测试集对初始预测模型进行测试训练,直至初始预测模型的第二损失函数值满足训练停止条件,得到目标预测模型的方法步骤。

[0135] 上述基于高斯过程回归模型,采用验证集对第二预测模型进行模型性能评估,以调整第二预测模型的网络参数,得到目标预测模型,可以参照前述的基于高斯过程回归模型,采用验证集对初始预测模型进行模型性能评估,以调整初始预测模型的网络参数,得到目标预测模型的方法步骤。

[0136] 在一些实施例中,上述步骤S102还可以包括:

[0137] 采用训练集对预设混合模型进行训练,直至预设混合模型的第一损失函数值满足训练停止条件,得到第一预测模型。

[0138] 获取验证集。

[0139] 基于高斯过程回归模型,采用验证集对第一预测模型进行模型性能评估,以调整第一预测模型的网络参数,得到第二预测模型。

[0140] 获取测试集。

[0141] 采用测试集对第二预测模型进行测试训练,直至第二预测模型的第二损失函数值满足训练停止条件,得到目标预测模型。

[0142] 上述基于高斯过程回归模型,采用验证集对第一预测模型进行模型性能评估,以调整第一预测模型的网络参数,得到第二预测模型,可以参照前述的基于高斯过程回归模型,采用验证集对初始预测模型进行模型性能评估,以调整初始预测模型的网络参数,得到目标预测模型的方法步骤。

[0143] 上述采用测试集对第二预测模型进行测试训练,直至第二预测模型的第二损失函数值满足训练停止条件,得到目标预测模型,可以参照前述的采用测试集对初始预测模型进行测试训练,直至初始预测模型的第二损失函数值满足训练停止条件,得到目标预测模型的方法步骤。

[0144] 在一些实施例中,在上述采用测试集对第二预测模型进行测试训练,直至第二预测模型的第二损失函数值满足训练停止条件,得到目标预测模型,还可以包括:

[0145] 获取数据集,其中,数据集包括多个训练样本。数据集中的训练样本可以与验证集、测试集或训练集中的训练样本不同。

[0146] 基于数据集,采用交叉验证方法对第二预测模型进行训练,得到第三预测模型。

[0147] 其中,具体为,将数据集划分为K个模块, $\{D_1, \dots, D_K\}$ 。对折k以外的数据训练得  $w^{(-k)}(\varrho)$ 。最终选取:

$$[0148] \quad \hat{\varrho} = \arg \min_{\varrho} \frac{1}{K} \sum_{k=1}^K L_{\text{val}}^{(k)}(w^{(-k)}(\varrho));$$

[0149] 通过在未见数据上的验证,避免了超参数向训练集的过度记忆。其中,K为总共的折数,即把数据集划分为 K 份,得到K个子集。 $D_k$ 表示第k个子集,k取值从1至K,即  $k = 1, \dots, K$ 。 $w^{(-k)}(\varrho)$ 表示使用超参数 $\varrho$ 在数据集中去掉第k折数据(第k个子集)后的数据训练

得到的参数向量,即  $\bigcup_{j \neq k} D_j$  训练得到的参数向量。 $\varrho$ 表示模型的超参数,如正则化系数、

学习率等,在此需要通过交叉验证选择最优值。 $L_{\text{val}}^{(k)}(w)$ 表示将训练好的参数w在第k折数

据 $D_k$ 上得到的验证损失(可以是均方误差、交叉熵等)。 $\frac{1}{K} \sum_{k=1}^K L_{\text{val}}^{(k)}(w^{(-k)}(\varrho))$ 为对所有

K 折数据的验证损失求平均,作为 $\varrho$ 值的总体评估指标。

[0150] 采用测试集对第三预测模型进行测试训练,直至第三预测模型的第二损失函数值满足训练停止条件,得到目标预测模型。

[0151] 在一些实施例中,上述第一预设模型为后向传播神经网络模型(BPNN),上述第二预设模型为图神经网络模型(GNN)。

[0152] 为了更好地实现上述列车表面风压的预测模型训练方法,本申请实施例提供了完整实施例流程,如下:

[0153] Step 1:

[0154] 利用雷诺平均纳维-斯托克斯方程模拟列车在不同偏航角和风速下的气动表现,

生成大量初步数据集(气动力数据)。

[0155] Step 2:

[0156] 在控制环境下进行风洞实验,收集列车模型在相同条件下的气动力数据。气动力数据包括影响参数和各个压力测点对应的风压数据。

[0157] Step 3:

[0158] 将数值模拟和风洞实验得到的数据进行清洗、格式化,并进行特征工程,为神经网络训练准备数据,特征工程公式如下:

$$[0159] \quad x_i = \frac{x'_i - \frac{1}{Q} \sum_{i=1}^Q x'_i}{\sqrt{\frac{1}{Q} \sum_{i=1}^Q (x'_i - \&)^2}};$$

[0160] 其中, $x'_i$ 为特征工程前的第*i*个特征值,可以为特征工程前的第*i*个数据点, $x_i$ 为特征工程后的第*i*个特征值,可以为特征工程后的第*i*个数据点, $Q$ 为该特征在原始数据集中所有样本的总数(即样本数), $\&$ 表示均值(平均值),是所有样本值(特征值)的总和除以样本数量,公式为 $\& = \frac{1}{Q} \sum_{i=1}^Q x'_i$ ,上述数据点可以为训练样本。

[0161] Step 4:

[0162] Step 4:

[0162] 使用后向传播神经网络(BPNN)和图神经网络(GNN)混合的神经网络,对两种神经单元模块进行初步配置。不同于传统的数据子集聚类或分类划分,本发明专门构建压力测点的空间关联图矩阵,通过自注意力权重矩阵捕捉测点之间非线性的空间关联关系。为BPNN设计适当数量的隐藏层和神经元,并为GNN设置适当的图结构。其中,BPNN网络则单独处理单点压力预测,网络独立训练过程与GNN结构之间的协作关系,与传统的交替训练有所区别。在原有GNN框架中引入自注意力机制,让模型自动学习列车测点之间的关联权重。实现方法如下:

$$[0163] \quad e_{cd} = \text{LeakyReLU}(\mathbf{a}^T [\mathbf{W}\mathbf{h}_c \parallel \mathbf{W}\mathbf{h}_d]);$$

$$[0164] \quad \alpha_{cd} = \frac{\exp(e_{cd})}{\sum_{k \in \mathcal{N}(c)} \exp(e_{ck})};$$

$$[0165] \quad \mathbf{h}'_c = \sigma\left(\sum_{d \in \mathcal{N}(c)} \alpha_{cd} \mathbf{W}\mathbf{h}_d\right);$$

[0166] 其中, $\mathbf{h}_c \in R^f$ 为节点*c*在输入到GNN之前压力读数的特征向量(风压数据)。 $\mathbf{W} \in R^{f' \times f}$ 为可训练的线性变换矩阵(共有 $f \rightarrow f'$ 维度变换),用于将原始节点特征映射到新的表示空间。 $\mathbf{W}\mathbf{h}_c \in R^{f'}$ 、 $\mathbf{W}\mathbf{h}_d \in R^{f'}$ 分别是节点*c*和节点*d*映射到 $f'$ 维空间后的特征向量。 $\mathbf{a} \in R^{2f'}$ 为可训练的注意力权重向量,用于对拼接后的 $[\mathbf{W}\mathbf{h}_c \parallel \mathbf{W}\mathbf{h}_d]$ 作线性映射,输出一个标量。 $\mathbf{a}^T [\mathbf{W}\mathbf{h}_c \parallel \mathbf{W}\mathbf{h}_d]$ :注意力机制中的打分函数,对应一个“未激活”的注意力得分。

[0167]  $\mathcal{N}(c)$ 为节点*c*在图中的邻居节点集合(通常包括所有与*c*有边相连的节点索引)。

$e_{cq}$ :对于邻居节 $k \in \mathcal{N}(c)$ ,计算出的未归一化注意力分数。 $\sum_{q \in \mathcal{N}(c)} \exp(e_{cq})$ 为对所有邻居节点  $q$  的 $\exp(e_{cq})$ 求和,实现归一化。 $\alpha_{cd}$ :节点 $c$ 对节点 $d$ 的最终注意力权重(归一化后),满足 $\sum_{d \in \mathcal{N}(c)} \alpha_{cd} = 1$ 。

[0168]  $h'_c \in R^f$ :节点 $c$ 在当前图卷积层(GAT层)输出的更新后的特征向量。

$\sum_{d \in \mathcal{N}(c)} \alpha_{cd}(\mathbf{W}h_d)$ :按注意力权重 $\alpha_{cd}$ 对邻居节点 $d$ 的映射特征 $\mathbf{W}h_d$ 加权求和,得到聚合后的信息;然后再把和传入激活函数 $\sigma$ ,得到最终的新特征 $h'_c$ 。

[0169] Step 5:

[0170] 为神经网络选择激活函数和优化器,设置学习率和其他超参数。将预处理后的数据分割为训练集、验证集和测试集。使用训练集数据训练神经网络,监控训练过程中的损失和准确率,进行模型调优,其中损失函数使用了多权重方法,在训练过程中,除了拟合数据损失,还在网络损失中加入雷诺-纳维斯托克斯方程的残差项,以软约束模型满足流体力学基本方程:

[0171]  $Loss = Loss_{data} + \omega Loss_{NS}$  (1);

[0172]  $Loss_{data} = \frac{1}{N} \sum_{i=1}^N \|\hat{y}_i - y_i\|^2$  (2);

[0173]  $Loss_{NS} = \frac{1}{M} \sum_{j=1}^M \left\| (u \cdot \nabla)u + \frac{1}{\rho} \nabla p - \nu \nabla^2 u \right\|_{x_j}^2$  (3);

[0174] 其中, $Loss$ 为神经网络的总损失(第一目标损失函数),用于反向传播更新参数。 $Loss_{data}$ 为纯数据拟合损失(第一损失函数),一般衡量预测值与真实值之间的差异。 $Loss_{NS}$ 为方程残差损失(第二损失函数),用以“软约束”网络满足流体力学方程。 $\omega$ 为控制两部分损失权重的超参数,通常需通过交叉验证或经验调优来选取。

[0175]  $N$ 是用于计算数据损失的样本总数。 $y_i$ :第 $i$ 个样本的真实标签。 $\hat{y}_i$ :网络对第 $i$ 个输入样本的预测值,使得与 $y_i$ 同维度。 $\|\hat{y}_i - y_i\|^2$ :预测与真实之间的平方误差。 $Loss_{data}$ 因子 $\frac{1}{N}$ 表示平均化所有样本的均方误差。

[0176]  $M$ 为在约束损失中用于采样残差的空间/时间点总数。 $u = u(x) \in R^3$ 为流场的速度向量函数,依赖空间坐标  $x$ ,即三维速度场  $(u_x, u_y, u_z)$ 。 $\nabla$ 为空间梯度算子,作用于标量或矢量场。 $(u \cdot \nabla)u$ 为对速度做对流项(即 $\sum_g u_g \partial_{x_g} u$ ),描述流体对自身速度的传输。 $\nabla p$ 为压力梯度。 $\nu$ :运动黏性系数,通常 $\nu = \mu/\rho$ ,其中 $\mu$ 是动力黏度。 $\nabla^2 u$ :拉普拉斯算子作用于

速度向量,等同于  $\sum_g \partial_{x_g}^2 \mathbf{u} \cdot \|\cdots\|_{x_j}^2$ : 在第j个空间点  $x_j$  上,将括号内的矢量残差求二范数平方。

[0177] 使用验证集评估模型性能,调整超参数以优化模型表现,联合CFD数值模拟与风洞实验数据进行混合建模,充分利用了两类数据的优势,有效提升了模型的泛化能力和在实际工程中的预测精度,将低保真数值模拟和高保真实验数据联合建模,用自回归高斯过程捕捉两者差异,充分利用大量 CFD 数据与少量实验数据的互补优势。

$$[0178] \quad \mathbf{y}_H(\mathbf{x}) = \delta \mathbf{y}_L(\mathbf{x}) + \delta(\mathbf{x}), (\delta) \sim \mathcal{GP}(0, \begin{bmatrix} k_{LL} & 0 \\ 0 & k_{\delta\delta} \end{bmatrix});$$

[0179] 其中  $\mathbf{y}_L, \mathbf{y}_H$  分别为低保真数值模拟数据和高保真实验数据,  $\delta$  经最大似然估计获得。  $\delta(\mathbf{x})$ : 偏差函数,刻画  $\mathbf{y}_H(\mathbf{x})$  与  $\delta \mathbf{y}_L(\mathbf{x})$  之间的非线性差异,本身被假定为高斯过程。

$\mathcal{GP}(0, \zeta)$ : 高斯过程先验,均值为 0,协方差矩阵为  $\zeta$ ,即  $\begin{bmatrix} k_{LL} & 0 \\ 0 & k_{\delta\delta} \end{bmatrix}$ 。  $k_{LL}$ : 低保真模型自身的协方差核函数,对应于  $\text{cov}(\mathbf{y}_L(\mathbf{x}), \mathbf{y}_L(\mathbf{x}'))$ 。  $k_{\delta\delta}$ : 偏差函数  $\delta$  的协方差核函数,对应于  $\text{cov}(\delta(\mathbf{x}), \delta(\mathbf{x}'))$ 。协方差矩阵中  $\begin{bmatrix} k_{LL} & 0 \\ 0 & k_{\delta\delta} \end{bmatrix}$  表示  $\mathbf{y}_L$  与  $\delta$  之间相互独立,且各自满足对应的高斯过程先验。

[0180] Step 6:

[0181] 采用交叉验证方法确保模型的泛化能力和稳定性。将数据集划分为  $K$  个模块,  $\{\mathbf{D}_1, \dots, \mathbf{D}_K\}$ 。对折  $k$  以外的数据训练得  $\mathbf{w}^{(-k)}(\boldsymbol{\rho})$ 。最终选取

$$[0182] \quad \hat{\boldsymbol{\rho}} = \arg \min_{\boldsymbol{\rho}} \frac{1}{K} \sum_{k=1}^K L_{\text{val}}^{(k)}(\mathbf{w}^{(-k)}(\boldsymbol{\rho}));$$

[0183] 通过在未见数据上的验证,避免了超参数向训练集的过度记忆。其中,  $K$  为总共的折数,即把数据集划分为  $K$  份。  $\mathbf{D}_k$ : 第  $k$  个子集,其中  $k = 1, \dots, K$ 。  $\mathbf{w}^{(-k)}(\boldsymbol{\rho})$ : 使用超参数  $\boldsymbol{\rho}$

在数据集中去掉第  $k$  折数据后,即  $\bigcup_{j \neq k} \mathbf{D}_j$  训练得到的参数向量。  $\boldsymbol{\rho}$ : 模型的超参数(如正则化系数、学习率等),在此需要通过交叉验证选择最优值。  $L_{\text{val}}^{(k)}(\mathbf{w})$ : 将训练好的参数  $\mathbf{w}$  在第  $k$

折数据  $\mathbf{D}_k$  上得到的验证损失(可以是均方误差、交叉熵等)。  $\frac{1}{K} \sum_{k=1}^K L_{\text{val}}^{(k)}(\mathbf{w}^{(-k)}(\boldsymbol{\rho}))$  为对

所有  $K$  折的验证损失求平均,作为  $\boldsymbol{\rho}$  值的总体评估指标。

[0184] Step 7:

[0185] 利用独立的测试集对神经网络进行性能评估,评估预测压力测点失效数据上的准确性和稳健性,根据测试结果进行进一步的调整和优化,在原始经验风险最小化目标上增加参数惩罚项(第二目标损失函数):

$$[0186] \quad \mathcal{R}(\theta) = \frac{1}{N} \sum_{i=1}^N \ell(y_i, f(x_i; \theta)) + \frac{\lambda}{4} \|\theta\|_2^2;$$

[0187] 其中,  $\theta \in \mathbf{R}^d$  为风压数据模型参数向量,  $\ell$  为单点损失 (如平方误差、交叉熵等),  $\lambda > 0$  为约束强度。由于存在对应的梯度下降更新有效抑制参数过大的问题, 为了减少对训练噪声的过度拟合, 提出以下公式:

$$[0188] \quad \theta \leftarrow \theta - \eta \left[ \nabla_{\theta} \frac{1}{N} \sum_i \ell_i + \lambda \theta \right];$$

[0189] 之后, 令训练过程中在每个循环周期  $t$  计算验证集损失  $\text{Loss}_{\text{val}}(t)$ , 当

[0190]  $\text{Loss}_{\text{val}}(t+1) > \text{Loss}_{\text{val}}(t)$  且持续  $p$  个循环周期时, 停止训练, 并取参数为:

$$[0191] \quad \theta^* = \theta(t_{\min}), \quad t_{\min} = \arg \min_t \text{Loss}_{\text{val}}(t);$$

[0192] 在神经网络的每一层引入随机“丢弃”机制。给第  $l$  层激活向量施加  $\text{Mask } r^{(l-1)} \sim \text{Bernoulli}(p)$ :

$$[0193] \quad \tilde{h}^{(l-1)} = r^{(l-1)} \odot h^{(l-1)}, h^{(l)} = \sigma(W^{(l)} \tilde{h}^{(l-1)} + b^{(l)});$$

[0194] 训练时丢弃概率为  $1-p$ , 测试时缩放权重为  $pW^{(l)}$ 。这种随机化在模型空间做了指数级的集成, 能显著降低过拟合。

[0195] 在模型使用后, 还可以实时接收新的气动力数据, 预测和插补可能失效的压力测点数据。定期监控模型的预测性能, 确保其在新的操作条件下保持高准确性。根据新的数据和实际运行反馈调整模型参数, 重复执行 Step6 及其以后环节, 以适应环境和操作条件的变化。

[0196] 本实施例应用混合神经网络模型, 该模型结合了后向传播神经网络 (BPNN) 和图神经网络 (GNN), 通过这种结合实现对磁悬浮列车在横风条件下失效的压力测点的准确预测和数据插补, 以达到提高列车运行安全性和监控系统准确性的目的。

[0197] 在本实施例中, 可以设计网络结构, 确定隐藏层的层数、每层的神经元数量, 以及适合本问题的特殊网络结构 (如图神经网络的拓扑结构)。针对原始从 CFD 仿真和风洞实验中获取的数据进行清洗、格式化, 这包括处理缺失值、异常值以及数据标准化。进行特征工程, 包括选择对预测结果影响显著的特征, 以及创建新的特征来改善模型的学习效率和预测准确性。确定最佳的训练策略, 使用损失函数和优化器, 调整学习率和其他训练参数。实施带有 Dropout 和 Early Stopping 的正则化技术, 以避免过拟合。

[0198] 并且可以进行多轮验证和模型比较, 以确定哪一种模型结构或参数配置在实际应用中表现最佳。

[0199] 上述神经网络模型包括自适应学习机制, 能够根据不同的环境变化自动调整网络参数, 如学习率和权重, 以优化模型在新环境中的性能, 从而应对不同风速和风向条件下的数据预测需求。

[0200] 在数据预处理阶段, 采用高级的数据清洗、归一化及标准化处理, 并结合特征工程

技术提取关键特征,这些处理和技术提升了输入数据的质量和一致性,增强了模型训练的有效性和预测数据的准确性。

[0201] 还可以引入正则化技术、Dropout和Early Stopping,以及优化算法选择,例如使用Adam或SGD优化器,这些技术帮助减少模型过拟合,提高模型对未见数据的泛化能力。

[0202] 使用图神经网络处理列车表面压力测点的空间数据,通过图结构学习压力点之间的复杂关系,能够有效地捕捉和预测空间上相互依赖的压力测点数据,为复杂空间数据提供更精确的分析和预测。

[0203] 本发明利用图神经网络处理压力测点的空间关系和依赖性,GNN能够有效捕捉测点间的复杂相互作用,特别适合处理压力测点分布在列车表面的空间数据,并且引入自注意力机制,显著提升了空间数据处理的精准性与模型稳健性。

[0204] 本发明使用后向传播神经网络和图神经网络,评估其性能以选择最佳模型。为减少了模型过拟合现象,通过Dropout、Early Stopping和软约束等技术,确保了模型的泛化性能,避免了模型对训练数据的过度依赖。这种混合使用方法可以优化模型性能。本发明通过使用反向传播神经网络和图神经网络进行压力测点预测,显著提高了压力测量的精度和可靠性,尤其在风速和偏航角条件下,预测结果优于传统方法,能够有效应对复杂环境。

[0205] 本发明提出了基于深度学习模型的数据插补方法,用于处理因压力测点失效导致的数据缺失。此方法不依赖传统的统计插补方法,而是通过学习数据的深层次特征来预测失效数据。此方法相较于传统的方法,直接利用原始压力测点数据进行预测,不进行任何形式的模态降维或分解,最大限度保留了测点数据之间真实的空间相关性特征。本发明采用深度神经网络,能够捕捉传感器数据中的复杂非线性关系,实现高效的数据重构。在高速磁悬浮列车的运行中,传感器由于震动、外力冲击等因素可能发生故障,造成压力数据丢失,本发明通过深度学习模型对故障测点进行重构,确保了缺失数据的准确预测和补充。

[0206] 本发明的神经网络模型能够根据不同的气象条件和测点失效模式自适应地调整其参数,以优化预测性能。模型的自适应学习机制,能动态调整参数以适应环境变化,适用于磁悬浮列车乃至高速铁路、航空等更广泛的高速交通运输领域。这种自适应学习机制提高了模型在变化环境下的适应性和稳定性。本发明通过对不同偏航角和多点故障情景下的模型鲁棒性测试,展示了在动态环境下模型的稳定性和适应性,即使在多个传感器故障的情况下,本发明仍能保持较高的预测准确性和可靠性。

[0207] 在高速度列车的风环境仿真中,处理大量传感器数据具有较高的计算成本,通过优化的神经网络结构,本发明在保证准确性的前提下,显著提升了数据处理的效率,减少了计算资源的消耗。

[0208] 在一些实施方式中,该目标预测模型还可以用于预测桥梁、高架道路等城市基础设施的表面的风压数据。

[0209] 在本申请实施例中,通过第一预设模型捕捉到一些第二预设模型未能捕捉到的数据特征,通过结合两者的预测结果,可以整合来自不同模型的信息,从而可能提高整体预测性能,而第二预设模型利用图结构信息,能够学习压力测点之间的空间关系,使每个节点(风压测点)可以接收来自其邻居节点的信息,在插补任务中,已知节点的风压数据可以通过图结构传播到未知节点,帮助预测或插补缺失值,因此,本申请中得到的目标预测模型可

以应用到列车的任何场景下预测失效压力测点的风压数据,提高了应用的广泛性。

[0210] 在一些实施例中,本申请实施例还提供了一种列车表面风压的预测方法,参照图5,图5为本申请实施例提供的列车表面风压的预测方法的流程示意图,该列车表面风压的预测方法具体包括如下步骤:

[0211] 步骤S501,获取目标列车的列车表面的风压的目标影响参数、各有效压力测点的目标风压数据以及多个压力测点的目标图结构信息。

[0212] 步骤S502,将目标影响参数、目标风压数据以及目标图结构信息输入至目标预测模型,得到目标预测模型输出的失效压力测点的风压数据。

[0213] 其中,上述目标预测模型由上述列车表面风压的预测模型训练方法得到。

[0214] 在一些实施方式中,上述目标风压数据可以标记有指示对应目标压力测点的标识信息。

[0215] 在一些实施方式中,在执行步骤S502之前还可以获取目标列车的目标型号数据,上述步骤S502还可以是将目标影响参数、目标风压数据、目标图结构信息以及目标型号数据输入至目标预测模型,得到目标预测模型输出的失效压力测点的风压数据。

[0216] 在本申请实施例中,目标预测模型结合了第一预设模型和第二预设模型,通过这种结合可以实现对列车在横风条件下失效的压力测点的准确预测和数据插补。

[0217] 为了更好地实现上述列车表面风压的预测模型训练方法,本申请实施例提供了一种列车表面风压的预测模型训练装置,参照图6,图6为本申请实施例提供的列车表面风压的预测模型训练装置的结构示意图,该列车表面风压的预测模型训练装置600包括如下:

[0218] 第一获取模块601,用于获取训练集;训练集包括多个训练样本,其中,各训练样本包括风压的影响参数以及列车表面的多个压力测点的风压数据标签,多个压力测点的风压数据标签中存在失效压力测点的风压数据标签。

[0219] 训练模块602,用于采用训练集对预设混合模型进行训练,直至预设混合模型的第一损失函数值满足训练停止条件,得到目标预测模型;其中,预设混合模型包括第一预设模型和第二预设模型,第一预设模型用于基于训练样本预测得到失效压力测点对应的第一预测风压数据,第二预设模型用于基于图结构信息和第一预测风压数据,预测得到失效压力测点对应的第二预测风压数据,第一损失函数值由第二预测风压数据与对应的风压数据标签确定,图结构信息用于表征多个压力测点的空间位置关系,目标预测模型用于预测失效压力测点的风压数据。

[0220] 在一些实施例中,上述训练模块602中的第一损失函数值通过第一目标损失函数计算得到,其中,第一目标损失函数包括第一损失函数和第二损失函数;第一损失函数用于确定第二预测风压数据与对应的训练样本中风压数据标签之间的均方差,第二损失函数为雷诺-纳维斯托克斯方程的残差项。

[0221] 在一些实施例中,上述训练模块602具体用于:采用训练集对预设混合模型进行训练,直至预设混合模型的第一损失函数值满足训练停止条件,得到初始预测模型;获取测试集;测试集包括多个训练样本;采用测试集对初始预测模型进行测试训练,直至初始预测模型的第二损失函数值满足训练停止条件,得到目标预测模型;其中,第二损失函数值通过第二目标损失函数计算得到;第二目标损失函数包括第三损失函数和第四损失函数,第三损失函数用于确定第二预测风压数据与对应的训练样本中风压数据标签之间的损失均值,第

四损失函数由权重的平方和、正则化参数以及预设系数的乘积得到。

[0222] 在一些实施例中,上述训练模块602具体用于:采用训练集对预设混合模型进行训练,直至预设混合模型的第一损失函数值满足训练停止条件,得到初始预测模型;获取验证集;验证集包括多个训练样本;基于高斯过程回归模型,采用验证集对初始预测模型进行模型性能评估,以调整初始预测模型的网络参数,得到目标预测模型;其中,高斯过程回归模型表示高保真数据为低保真数据的线性变换加上预设的偏差函数,且低保真数据和偏差函数服从多变量高斯过程,多变量高斯过程的均值为0以及协方差矩阵由低保真数据的协方差函数和偏差函数的协方差函数构成,高保真数据为实验训练样本对应的第二预测风压数据,低保真数据为仿真训练样本对应的第二预测风压数据。

[0223] 在一些实施例中,上述训练模块602中的第一预设模型为后向传播神经网络模型,第二预设模型为图神经网络模型。

[0224] 本申请实施例提供的列车表面风压的预测模型训练装置600可以执行上述方法实施例所示的技术方案,其实现原理以及有益效果类似,此次不再进行赘述。

[0225] 为了更好地实现上述列车表面风压的预测方法,本申请实施例提供了一种列车表面风压的预测装置,参照图7,图7为本申请实施例提供的列车表面风压的预测装置的结构示意图,该列车表面风压的预测装置700包括如下:

[0226] 第二获取模块701,用于获取目标列车的列车表面的风压的目标影响参数、各有效压力测点的目标风压数据以及多个压力测点的目标图结构信息。

[0227] 预测模块702,用于将目标影响参数、目标风压数据以及目标图结构信息输入至目标预测模型,得到目标预测模型输出的失效压力测点的风压数据。其中,目标预测模型由上述列车表面风压的预测模型训练方法得到。

[0228] 本申请实施例提供的列车表面风压的预测装置700可以执行上述方法实施例所示的技术方案,其实现原理以及有益效果类似,此次不再进行赘述。

[0229] 图8示出了本申请实施例提供的电子设备的硬件结构示意图。

[0230] 电子设备可以包括处理器801以及存储有计算机程序指令的存储器802。

[0231] 具体地,上述处理器801可以包括中央处理器(CPU),或者特定集成电路(Application Specific Integrated Circuit,ASIC),或者可以被配置成实施本申请实施例的一个或多个集成电路。

[0232] 存储器802可以包括用于数据或指令的大容量存储器。举例来说而非限制,存储器802可包括硬盘驱动器(Hard Disk Drive,HDD)、软盘驱动器、闪存、光盘、磁光盘、磁带或通用串行总线(Universal Serial Bus,USB)驱动器或者两个或更多个以上这些的组合。在合适的情况下,存储器802可包括可移除或不可移除(或固定)的介质。在合适的情况下,存储器802可在综合网关容灾设备的内部或外部。在特定实施例中,存储器802是非易失性固态存储器。

[0233] 在一些实施例中,存储器802可包括只读存储器(ROM),随机存取存储器(RAM),磁盘存储介质设备,光存储介质设备,闪存设备,电气、光学或其他物理/有形的存储器存储设备。因此,通常,存储器包括一个或多个编码有包括计算机可执行指令的软件的有形(非暂态)计算机可读存储介质(例如,存储器设备),并且当该软件被执行(例如,由一个或多个处理器)时,其可操作来执行参考根据本公开的一方面的方法所描述的操作。

[0234] 处理器801通过读取并执行存储器802中存储的计算机程序指令,以实现上述实施例中的任意一种列车表面风压的预测模型训练方法或列车表面风压的预测方法。

[0235] 在一个示例中,电子设备还可包括通信接口803和总线810。其中,如图8所示,处理器801、存储器802、通信接口803通过总线810连接并完成相互间的通信。

[0236] 通信接口803,主要用于实现本申请实施例中各模块、装置、单元和/或设备之间的通信。

[0237] 总线810包括硬件、软件或两者,将电子设备的部件彼此耦接在一起。举例来说而非限制,总线可包括加速图形端口 (AGP) 或其他图形总线、增强工业标准架构 (EISA) 总线、前端总线 (FSB)、超传输 (HT) 互连、工业标准架构 (ISA) 总线、无限带宽互连、低引脚数 (LPC) 总线、存储器总线、微信道架构 (MCA) 总线、外围组件互连 (PCI) 总线、PCI-Express (PCI-X) 总线、串行高级技术附件 (SATA) 总线、视频电子标准协会局部 (VLB) 总线或其他合适的总线或者两个或更多个以上这些的组合。在合适的情况下,总线810可包括一个或多个总线。尽管本申请实施例描述和示出了特定的总线,但本申请考虑任何合适的总线或互连。

[0238] 该电子设备可以执行本申请实施例中的列车表面风压的预测模型训练方法或列车表面风压的预测方法,从而实现结合图1和图6描述的列车表面风压的预测模型训练方法和装置,或者实现结合图5和图7描述的列车表面风压的预测方法和装置。

[0239] 另外,结合上述实施例中的列车表面风压的预测模型训练方法或列车表面风压的预测方法,本申请实施例可提供一种计算机可读存储介质来实现。该计算机可读存储介质上存储有计算机程序指令;该计算机程序指令被处理器执行时实现上述实施例中的任意一种列车表面风压的预测模型训练方法,或者,实现上述实施例中的任意一种列车表面风压的预测方法。

[0240] 结合上述实施例中的列车表面风压的预测模型训练方法或列车表面风压的预测方法,本申请实施例提供了一种计算机程序产品,计算机程序产品中的指令由电子设备的处理器执行时,使得电子设备执行上述实施例中的任意一种列车表面风压的预测模型训练方法,或者,使得电子设备执行上述实施例中的任意一种列车表面风压的预测方法。

[0241] 需要明确的是,本申请并不局限于上文所描述并在图中示出的特定配置和处理。为了简明起见,这里省略了对已知方法的详细描述。在上述实施例中,描述和示出了若干具体的步骤作为示例。但是,本申请的方法过程并不限于所描述和示出的具体步骤,本领域的技术人员可以在领会本申请的精神后,作出各种改变、修改和添加,或者改变步骤之间的顺序。

[0242] 以上所述的结构框图中所示的功能块可以实现为硬件、软件、固件或者它们的组合。当以硬件方式实现时,其可以例如是电子电路、专用集成电路 (ASIC)、适当的固件、插件、功能卡等等。当以软件方式实现时,本申请的元素是被用于执行所需任务的程序或者代码段。程序或者代码段可以存储在机器可读介质中,或者通过载波中携带的数据信号在传输介质或者通信链路上传送。“机器可读介质”可以包括能够存储或传输信息的任何介质。机器可读介质的例子包括电子电路、半导体存储器设备、ROM、闪存、可擦除ROM (EROM)、软盘、CD-ROM、光盘、硬盘、光纤介质、射频 (RF) 链路,等等。代码段可以经由诸如因特网、内联网等的计算机网络被下载。

[0243] 还需要说明的是,本申请中提及的示例性实施例,基于一系列的步骤或者装置描

述一些方法或系统。但是,本申请不局限于上述步骤的顺序,也就是说,可以按照实施例中提及的顺序执行步骤,也可以不同于实施例中的顺序,或者若干步骤同时执行。

[0244] 上面参考根据本公开的实施例的方法、装置(系统)和计算机程序产品的流程图和/或框图描述了本公开的各方面。应当理解,流程图和/或框图中的每个方框以及流程图和/或框图中各方框的组合可以由计算机程序指令实现。这些计算机程序指令可被提供给通用计算机、专用计算机、或其它可编程数据处理装置的处理器,以产生一种机器,使得经由计算机或其它可编程数据处理装置的处理器执行的这些指令使能对流程图和/或框图的一个或多个方框中指定的功能/动作的实现。这种处理器可以是但不限于是通用处理器、专用处理器、特殊应用处理器或者现场可编程逻辑电路。还可理解,框图和/或流程图中的每个方框以及框图和/或流程图中的方框的组合,也可以由执行指定的功能或动作的专用硬件来实现,或可由专用硬件和计算机指令的组合来实现。

[0245] 以上所述,仅为本申请的具体实施方式,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,上述描述的系统、模块和单元的具体工作过程,可以参考前述方法实施例中的对应过程,在此不再赘述。应理解,本申请的保护范围并不局限于此,任何熟悉本技术领域的技术人员在本申请揭露的技术范围内,可轻易想到各种等效的修改或替换,这些修改或替换都应涵盖在本申请的保护范围之内。

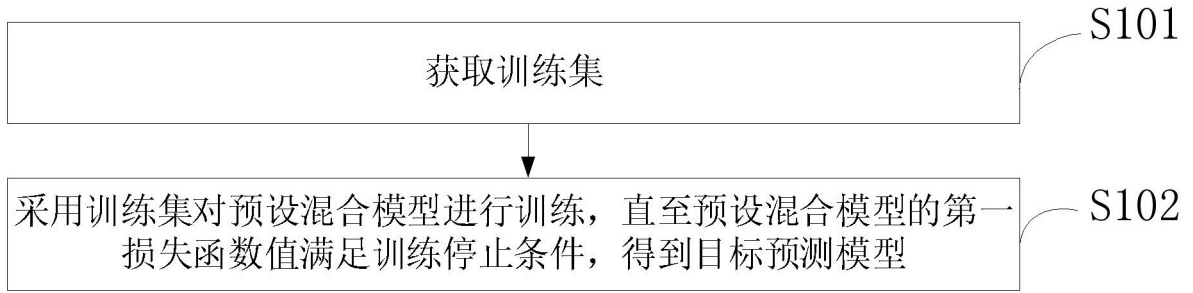


图1

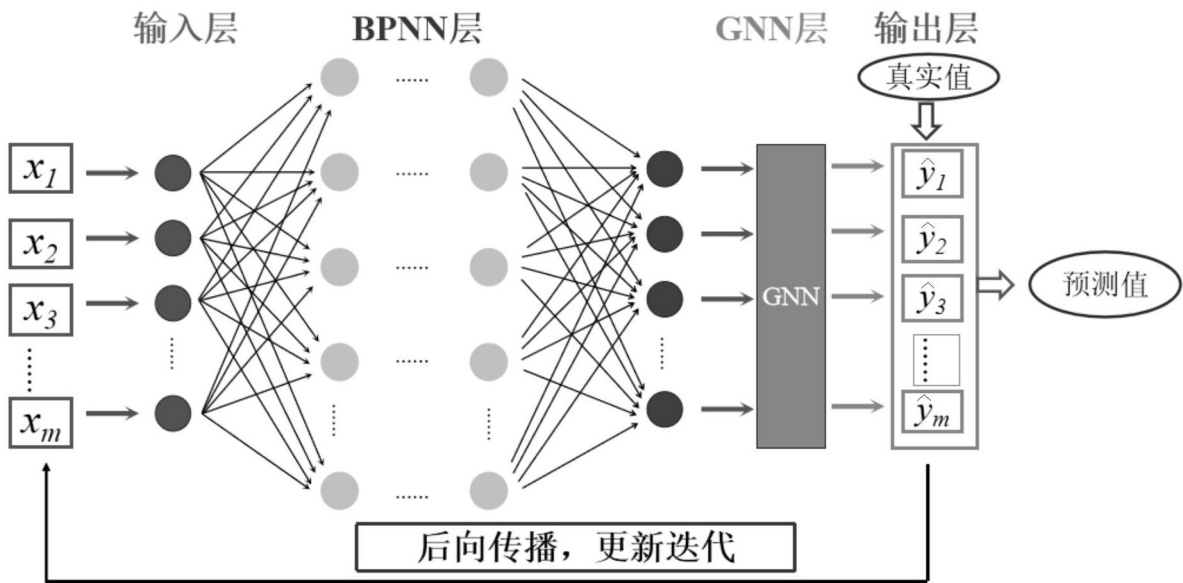


图2




图3




图4

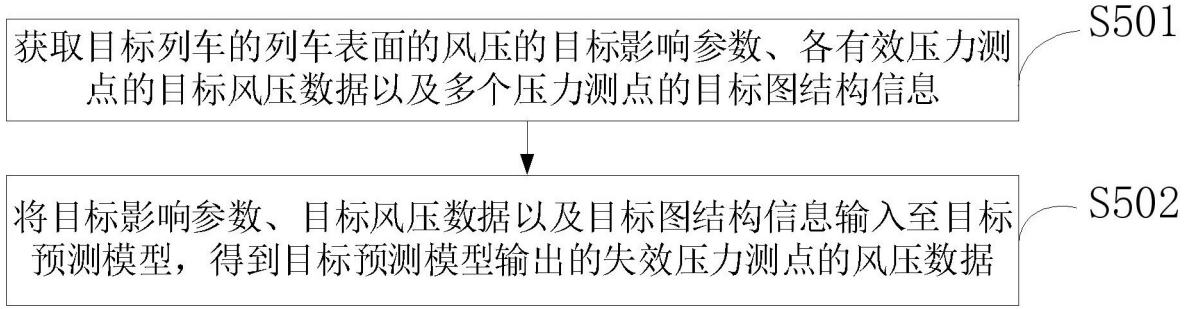


图5




图6




图7




图8