



(12) 发明专利

(10) 授权公告号 CN 114993604 B

(45) 授权公告日 2023.01.17

(21) 申请号 202210571249.2

(22) 申请日 2022.05.24

(65) 同一申请的已公布的文献号
申请公布号 CN 114993604 A

(43) 申请公布日 2022.09.02

(73) 专利权人 中国科学院力学研究所
地址 100190 北京市海淀区北四环西路15号

(72) 发明人 汪运鹏 聂少军 姜宗林

(74) 专利代理机构 北京和信华成知识产权代理
事务所(普通合伙) 11390
专利代理师 焦海峰

(51) Int. Cl.

G01M 9/06 (2006.01)

G06N 3/0464 (2023.01)

G06N 3/08 (2023.01)

(56) 对比文件

CN 113970420 A, 2022.01.25

CN 113537319 A, 2021.10.22

CN 113094953 A, 2021.07.09

CN 112257759 A, 2021.01.22

CN 111473947 A, 2020.07.31

CN 105699043 A, 2016.06.22

CN 103364169 A, 2013.10.23

WO 2020125839 A1, 2020.06.25

JP H08184527 A, 1996.07.16

聂少军等. 循环神经网络在智能天平研究中的应用.《力学学报》.2021, 第53卷(第8期), 第2336-2344页.

战培国. 2020版AIAA风洞天平校准标准浅析.《标准科学》.2020, (第08期), 第99-102页.

审查员 李小矛

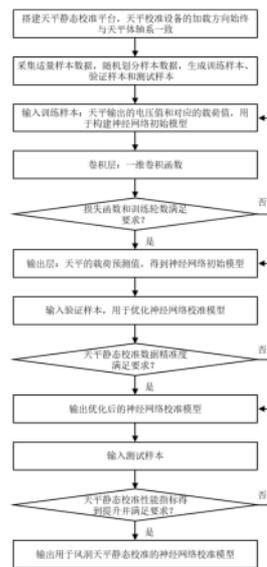
权利要求书2页 说明书10页 附图2页

(54) 发明名称

一种基于深度学习的风洞天平静态校测方法

(57) 摘要

本发明提供一种基于深度学习的风洞天平静态校测方法,选择施加载荷方向始终与天平体轴系一致的风洞天平校准设备,进行风洞试验采集样本数据;利用训练样本数据构建神经网络初始模型,结合验证样本数据优化神经网络初始模型的网络参数,得到进一步减少训练时间、节省成本的神经网络校准模型;在优化得到的神经网络校准模型的基础上,结合测试样本数据,对神经网络校准模型进行数据精准度分析,得到用于天平静态校准的神经网络校准模型。本发明通过对多分量天平公式拟合方法进行改进,解决了目前线性插值拟合方法中应变天平分量间存在较大的相互干扰的问题,提高了应变天平静态校准性能指标。



1. 一种基于深度学习的风洞天平静态校测方法,其特征在于,包括如下步骤:

步骤1、选择施加载荷方向始终与天平体轴系一致的风洞天平校准设备,进行风洞试验采集样本数据,将所述样本数据随机划分为训练样本、验证样本、测试样本;

所述样本数据包括法向力Y、俯仰力矩Mz、轴向力X、滚转力矩Mx、侧向力Z、偏航力矩My六个载荷分量的加载过程输入信号和对应一致的应用受载过程输出信号;

步骤2、将所述训练样本导入初始状态下的神经网络初始模型,基于训练样本中的数据训练更新所述神经网络初始模型的网络参数进行建模;

步骤3、对步骤2训练得到的建模数据,通过判断损失函数和训练轮数是否满足要求,以判断步骤2得到的所述神经网络初始模型的质量;如果不满足要求则返回步骤2继续训练更新所述神经网络初始模型的网络参数,如果损失函数和训练轮数满足要求,进行步骤4;

步骤4、输出天平载荷的预测值,得到训练完成的所述神经网络初始模型;

步骤5、将所述验证样本输入步骤4构建的所述神经网络初始模型中,进行迭代优化训练,以得到较之步骤4构建的所述神经网络初始模型进一步减少训练时间、节省成本的神经网络校准模型;

步骤6、对步骤5优化得到的所述神经网络校准模型,判断天平静态校准数据精准度是否满足要求;如果不满足要求则返回步骤4,继续迭代优化训练更新所述神经网络初始模型的网络参数;如果天平静态校准数据精准度满足要求,进行步骤7;

步骤7、输出优化后的网络参数及优化后的网络参数构成的所述神经网络校准模型;

步骤8、将所述测试样本输入步骤7得到的所述神经网络校准模型进行校准数据精准度分析,判断天平静态校准性能指标是否得到提升并满足要求;如果天平静态校准性能指标得到提升并满足要求,则得到用于天平静态校准的所述神经网络校准模型;否则,则返回步骤7继续校准数据精准度分析。

2. 根据权利要求1所述的一种基于深度学习的风洞天平静态校测方法,其特征在于,

步骤5中的所述迭代优化训练内容为:在训练过程中,改变网络参数中的一个参数,控制其他参数不变,记录训练结果,通过判断天平静态校准数据精准度是否满足要求选择此参数的最适应值;逐个更换网络参数,重复上述步骤,直至所有网络参数都找到最适应值,优化训练结束,得到神经网络校准模型。

3. 根据权利要求1所述的一种基于深度学习的风洞天平静态校测方法,其特征在于,

步骤1中的所述风洞天平校准设备具备体轴系加载复位功能以自动调整加载系统保证加载状态不变,进行风洞试验采集的样本数据中校准施加载荷方向与天平体轴坐标系一致。

4. 根据权利要求1所述的一种基于深度学习的风洞天平静态校测方法,其特征在于,所述损失函数为均方误差函数MSE,公式为

$$MSE = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (1)$$

式中,m是样本总数, y_i 和 \hat{y}_i 分别是天平载荷的真实值和预测值。

5. 根据权利要求1所述的一种基于深度学习的风洞天平静态校测方法,其特征在于,

所述神经网络初始模型为卷积神经网络模型或长短期记忆网络模型或双向长短期记忆网络模型中的一种。

6. 根据权利要求5所述的一种基于深度学习的风洞天平静态校测方法,其特征在于,所述卷积神经网络模型的网络参数为:卷积层数为4,训练轮数为50000,学习率为 10^{-5} 。

7. 根据权利要求1所述的一种基于深度学习的风洞天平静态校测方法,其特征在于,步骤8中的所述校准数据精准度分析,选择天平校准数据误差分析方法、天平静态校测综合加载误差和精度分析方法、天平静态校测不确定度分析方法中的一种或任意组合方法。

一种基于深度学习的风洞天平静态校测方法

技术领域

[0001] 本发明属于航空航天风洞天平气动力测量技术领域,涉及一种基于深度学习的风洞天平静态校测方法。

背景技术

[0002] 在风洞试验中,气动力测量是最主要的测试项目之一,其主要技术是天平技术。天平的测量不确定度是风洞测力试验数据的主要不确定度源。为满足航空航天器不断提高的气动性能设计要求,对风洞天平的技术性能要求、试验环境适应性要求也不断提高。因此,需要天平技术不断创新,尤其是在天平校准方面,仍然需要持续开展相关技术研究,以进一步提高天平测试性能。天平静态校准是依据天平校准原理,利用天平校准装置,按照一定的校准方法,建立天平测量信号与所受气动载荷(六个载荷分量,即法向力 Y 、俯仰力矩 M_z 、轴向力 X 、滚转力矩 M_x 、侧向力 Z 、偏航力矩 M_y)关系的过程,即获取天平公式和天平其他性能参数的过程。

[0003] 由于风洞天平静态校决定天平校准的效率和天平公式的准确性,关系到天平未来应用中模型气动数据测量的精准度,所以天平静态校被认为是天平设计过程中最重要的环节。但是风洞天平是一种特殊的力计量设备,其特殊性在于国际上没有统一的计量标定标准。因此,一台已完成硬件加工的待校测天平采用不同的校准设备、不同的校准手段或方法,获得的天平公式是有差异的,并直接影响测量不确定度。

[0004] 目前普遍采用线性插值拟合的方法获取天平公式系数,然而多分量(六个载荷分量,即法向力 Y 、俯仰力矩 M_z 、轴向力 X 、滚转力矩 M_x 、侧向力 Z 、偏航力矩 M_y)应变天平的分量间存在相互干扰,并且通常二次干扰和组合干扰会出现非线性特性,采用线性拟合方法会产生一定误差,使得应变天平静态校准性能受到线性拟合方法局限性影响而无法进一步提高。

发明内容

[0005] 本发明提供一种风洞天平静态校准方法,通过对多分量天平公式拟合方法进行改进,解决了目前线性插值拟合方法中应变天平分量间存在较大的相互干扰的问题,提高了应变天平静态校准性能指标。

[0006] 一种基于深度学习的风洞天平静态校测方法,包括如下步骤:

[0007] 步骤1、选择施加载荷方向始终与天平体轴系一致的风洞天平校准设备,进行风洞试验采集样本数据,将所述样本数据随机划分为训练样本、验证样本、测试样本;

[0008] 所述样本数据包括法向力 Y 、俯仰力矩 M_z 、轴向力 X 、滚转力矩 M_x 、侧向力 Z 、偏航力矩 M_y 六个载荷分量的加载过程输入信号和对应一致的应用受载过程输出信号;

[0009] 步骤2、将所述训练样本导入初始状态下的神经网络初始模型,基于训练样本中的数据训练更新所述神经网络初始模型的网络参数进行建模;

[0010] 步骤3、对步骤2训练得到的建模数据,通过判断损失函数和训练轮数是否满足要

求,以判断步骤2得到的所述神经网络初始模型的质量;如果不满足要求则返回步骤2继续训练更新所述神经网络初始模型的网络参数,如果损失函数和训练轮数满足要求,进行步骤4;

[0011] 步骤4、输出天平载荷的预测值,得到训练完成的所述神经网络初始模型;

[0012] 步骤5、将所述验证样本输入步骤4构建的所述神经网络初始模型中,进行迭代优化训练,以得到较之步骤4构建的所述神经网络初始模型进一步减少训练时间、节省成本的神经网络校准模型;

[0013] 步骤6、对步骤5优化得到的所述神经网络校准模型,判断天平静态校准数据精准度是否满足要求;如果不满足要求则返回步骤4,继续迭代优化训练更新所述神经网络初始模型的网络参数;如果天平静态校准数据精准度满足要求,进行步骤7;

[0014] 步骤7、输出优化后的网络参数及优化后的网络参数构成的所述神经网络校准模型;

[0015] 步骤8、将所述测试样本输入步骤7得到的所述神经网络校准模型进行数据精准度分析,判断天平静态校准性能指标是否得到提升并满足要求;如果天平静态校准性能指标得到提升并满足要求,则得到用于天平静态校准的所述神经网络校准模型;否则,则返回步骤7继续校准数据精准度分析。

[0016] 优选地,步骤5中的所述迭代优化训练内容为:在训练过程中,改变网络参数中的一个参数,控制其他参数不变,记录训练结果,通过判断天平静态校准数据精准度是否满足要求选择此参数的最适应值;逐个更换网络参数,重复上述步骤,直至所有网络参数都找到最适应值,优化训练结束,得到神经网络校准模型。

[0017] 优选地,步骤1中的所述风洞天平衡准设备具备体轴系加载复位功能以自动调整加载系统保证加载状态不变,进行风洞试验采集的样本数据中校准施加载荷方向与天平体轴坐标系一致。

[0018] 优选地,所述损失函数为均方误差函数MSE,公式为

$$[0019] \quad MSE = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (1)$$

[0020] 式中,m是样本总数, y_i 和 \hat{y}_i 分别是天平载荷的真实值和预测值。

[0021] 优选地,所述神经网络初始模型为卷积神经网络模型或长短期记忆网络模型或双向长短期记忆网络模型中的一种。

[0022] 优选地,所述卷积神经网络校准模型的网络参数为:卷积层数为4,训练轮数为50000,学习率为 10^{-5} 。

[0023] 优选地,步骤8中的所述校准数据精准度分析,选择天平校准数据误差分析方法、天平静态校测综合加载误差和精度分析方法、天平静态校测不确定度分析方法中的一种或任意组合方法。

[0024] 本发明和现有技术相比具有如下有益效果:

[0025] 较之传统的天平校准公式中,需要采用最小二乘法求解超定方程,当不考虑三次立方项和非对称干扰系数,仅考虑主系数、一次干扰系数、二次平方项干扰系数和二次交叉项干扰系数时,参数个数为144个,其精准度在一定程度上比较高。但本发明中神经网络校准模型的网络参数可以达到几万甚至几十万,其静态校准性能指标较天平传统公式得到了

较大幅度的提升。同时,神经网络校准模型在训练过程中,天平输出信号的各个分量单独训练,有效降低了分量间的载荷干扰,体现了神经网络校准模型在天平静态校准中的优势。

附图说明

[0026] 为了更清楚地说明本发明的实施方式或现有技术中的技术方案,下面将对实施方式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示例性的,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,还可以根据提供的附图引申获得其它的实施附图。

[0027] 图1为本发明中基于深度学习的风洞天平静态校测方法的流程示意图;

[0028] 图2为CNN初始模型的训练流程图。

具体实施方式

[0029] 下面将结合本发明实施例中的附图,对本发明实施例中的技术方案进行清楚、完整地描述,显然,所描述的实施例仅仅是本发明一部分实施例,而不是全部的实施例。基于本发明中的实施例,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例,都属于本发明保护的范围。

[0030] 风洞天平校准设备按照加载坐标轴系的不同,可分为体轴系天平校准设备和地轴系天平校准设备。对于地轴系校准台,施加载荷的方向假设与地轴系一致,对天平受载后产生的变形不作调整,为了提高天平精校的准确度,一般通过测量天平受载后产生的变形量,对施加载荷进行坐标轴系修正,获得近似于在体轴系天平校准设备上校准天平的结果。对于体轴系校准设备而言,其施加载荷方向始终与天平体轴系一致,从而保证校准加载过程与实际风洞测试受载过程基本一致。因此,相较于地轴系设备,其具有更高的校准精准度。但体轴系中也大致分为两类,即补偿型和非补偿型设备。补偿型体轴系天平校准设备结构复杂、造价高,但是其校准得到的天平公式中,干扰项数明显减少,干扰量也明显降低,精准度提高。非补偿型校准台虽然具有设备结构简化、不需调整系统的优点,但是其不考虑施加载荷方向随天平受载变形后的变化会引入一定误差,相对降低了校测精准度。通过以上地轴系与体轴系设备校准差别的介绍和讨论,显然补偿型体轴系天平校准设备具有更高的校准性能。原因是天平受载变形后,该类型设备可实时跟踪测量变形量大小并换算复位量,使得施加载荷方向与天平体轴系一致,即其可自动调整加载系统保证天平加载状态不变。

[0031] 其次,天平系统刚度不足等因素会增加非线性和交叉项干扰,使得天平校准复杂化,传统的多项式拟合方法无法处理这种非线性干扰。神经网络是一种模拟人脑的神经网络以期能够实现类人工智能的机器学习技术,目前已经在各个领域开展了广泛的应用研究,包括风洞测试中测力天平技术的智能化探索。神经网络建模方法的优点是可以更好的消除天平分量间非线性干扰引起的误差。将神经网络模型(如人工神经网络、卷积神经网络等)应用于天平静态校准数据处理建模,主要是通过对加载数据开展训练建模,得到校准模型,取代基于最小二乘法的多项式拟合得到的传统天平校准公式。

[0032] 需要注意的是,神经网络方法是对一组输入信号和一组输出信号之间的关系进行建模,通过调整内部大量节点(神经元)之间相互连接的权重,从而达到处理信息的目的。作为一种黑箱方法,它不会给出模型处理过程和内部解算机制,这意味着如果天平校准状态

(加载过程)与天平使用状态(应用受载过程)不一致,那么这种由于不一致而产生的误差将被无条件的作为“有效”信息增加到训练模型中。因此,前面讨论的地轴系设备运行中,如果采用神经网络方法对校准数据进行处理建模,那么加载载荷方向与天平体轴系的不一致问题导致的一定误差量将被包含在建模信息中处理。早期部分天平校准台不具备天平校准回零功能,国内外一些技术研究人員也采用了一些修正措施,因此一些地轴系天平校准台也可实现体轴系静态校准,但前提条件是对校准结果要进行准确评估并满足使用要求。

[0033] 综上所述,本发明提供一种基于深度学习的风洞天平静态校准方法,结合神经网络方法在天平静态校准中的有效应用,天平建模所需样本数据应尽可能满足校准施加载荷方向与天平体轴坐标系一致的条件,如图1所示,包括如下步骤:

[0034] 步骤1、选择施加载荷方向始终与天平体轴系一致的风洞天平校准设备,进行风洞试验采集样本数据,将所述样本数据随机划分为训练样本、验证样本、测试样本;

[0035] 所述样本数据包括法向力 Y 、俯仰力矩 M_z 、轴向力 X 、滚转力矩 M_x 、侧向力 Z 、偏航力矩 M_y 六个载荷分量的加载过程输入信号和对应一致的应用受载过程输出信号。

[0036] 步骤2、将所述训练样本导入初始状态下的神经网络初始模型,基于训练样本中的数据训练更新所述神经网络初始模型的网络参数进行建模;所述神经网络初始模型为卷积神经网络模型或循环神经网络模型中的一种,其中发明人已经验证了循环神经网络模型中的长短期记忆网络模型和双向长短期记忆网络模型在本方法中的应用。

[0037] 步骤3、对步骤2训练得到的建模数据,通过判断损失函数和训练轮数是否满足要求,以判断步骤2得到的所述神经网络初始模型的质量;如果不满足要求则返回步骤2继续训练更新所述神经网络初始模型的网络参数,如果损失函数和训练轮数满足要求,进行步骤4。

[0038] 步骤4、输出天平载荷的预测值,得到训练完成的所述神经网络初始模型。

[0039] 步骤5、将所述验证样本输入步骤4构建的所述神经网络初始模型中,进行迭代优化训练,以得到较之步骤4构建的所述神经网络初始模型进一步减少训练时间、节省成本的神经网络校准模型。

[0040] 本实施例中,迭代优化训练内容为:在训练过程中,改变网络参数中的一个参数,控制其他参数不变,记录训练结果,通过判断天平静态校准数据精准度是否满足要求选择此参数的最适应值;逐个更换网络参数,重复上述内容,直至所有网络参数都找到最适应值,优化训练结束,得到神经网络校准模型。

[0041] 步骤6、对步骤5优化得到的所述神经网络校准模型,判断天平静态校准数据精准度是否满足要求;如果不满足要求则返回步骤4,继续迭代优化训练更新所述神经网络初始模型的网络参数;如果天平静态校准数据精准度满足要求,进行步骤7。

[0042] 步骤7、输出优化后的网络参数及优化后的网络参数构成的所述神经网络校准模型。

[0043] 步骤8、将所述测试样本输入步骤7得到的所述神经网络校准模型进行数据模拟测试,判断天平静态校准性能指标是否得到提升并满足要求;如果天平静态校准性能指标得到提升并满足要求,则得到用于天平静态校准的所述神经网络校准模型;否则,则返回步骤7继续校准数据精准度分析,确保测试样本的有效性,确保训练得到的校准模型的正确性和精准度性能指标。

[0044] 本实施例中,校准数据精准度分析,可以选择天平校准数据误差分析方法、天平静态校测综合加载误差和精度分析方法、天平静态校测不确定度分析方法中的一种或任意组合方法。

[0045] 传统的机器学习算法采用人工的方式提取问题的特征,而深度学习算法具有学习能力强、适应能力强、可移植性好且需要样本量小等特点,能够自动提取问题的关键特征。在处理天平校准数据的过程中,天平测量输出的信号与所受的气动载荷信号具有一一映射的关系,神经网络通过对样本数据进行学习后能够自动地提取天平输出信号中的关键特征,通过自动组合特征从而完成从天平输出信号到载荷信号的拟合。由于神经网络具有局部连接和权值共享的特点,能够大大降低参数的数量。因此,采用神经网络校准模型对天平进行静态校准训练,能够高效的完成从天平输出信号到载荷信号的拟合任务。

[0046] 此外,一台多分量天平,其各分量的输出信号是多个待测量载荷分量的函数。传统的基于最小二乘法的多项式天平校准公式拟合方法中各个分量的存在耦合干扰作用,如在计算第1个分量的载荷时,不仅需要考虑到第1分量的天平主输出,还需要考虑其他分量对其产生的一阶干扰和高阶干扰等。在采用深度学习对天平数据进行建模时,将天平各个分量作为单独通道进行训练学习,有效避免了各个分量间的载荷干扰。因此,基于深度学习算法的建模方法深层次解耦了各方向之间的载荷,优化了高阶项干扰系数,提升了传感器精准度和鲁棒性。

[0047] 在一个优选实施例中,神经网络初始模型优选为卷积神经网络模型,构件过程相似,如图1所示,具体构建过程如下:

[0048] 卷积神经网络校准模型的构建流程为:针对六分量应变天平在体轴系校准设备中输出的电压值和载荷值,构建风洞天平静态校测数据的CNN初始模型(即卷积神经网络初始模型)。在构建初始模型之前需要采集适量的样本,包括训练样本、验证样本和测试样本,三者特征上应该尽可能保持一致。首先在体轴系校准设备上采集144组样本,将样本集随机划分为训练样本集和验证样本集,其中80%的样本集作为训练样本用于更新网络参数,剩余20%的样本集作为验证样本用于进一步优化网络参数,得到CNN校准模型。在CNN校准模型构建完成之后,在体轴系校准设备采集适量样本作为测试样本用于校准数据精准度分析,主要包括精度、误差以及不确定度分析。

[0049] 构建模型:CNN初始模型包括输入层、卷积层和输出层,输入层是六分量的天平电压值与其对应的载荷值;卷积层采用一维卷积函数,卷积层的数目和大小会影响模型的训练结果;输出层是六分量的天平载荷预测值。

[0050] 在CNN初始模型的训练过程中,随着训练轮数(epochs)的增加,通过不断优化各个网络层的参数达到最终的目标任务。常用损失函数(loss)作为模型质量的衡量指标,通过不断缩小损失函数的值调节网络的权重,最终使模型达到收敛状态。CNN初始模型采用均方误差(Mean Square Error, MSE)函数作为损失函数, MSE是反映模型的目标值与输出预测值的离散程度,其值越小,说明模型输出值与真实值越接近,拟合效果越好,精确度越高。MSE的计算公式为

$$[0051] \quad MSE = \frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2 \quad (1)$$

[0052] 式中, m 是样本总数, y_i 和 \hat{y}_i 分别是真实值与预测值, i 表示第 i 个样本。。

[0053] CNN初始模型训练流程图如图2所示。在构建CNN初始模型过程中,由于样本集的数据长度比较小,不需要采用池化层,所以隐藏层仅包括卷积层。首先在体轴系校准设备上采集适量的样本作为输入层,然后通过卷积层更新模型的网络参数,当损失函数和训练轮数满足要求后,输出天平的载荷预测值,即完成CNN初始模型的训练。

[0054] 进一步优化网络参数:在确定CNN初始模型的结构之后,需要通过验证集进一步优化神经网络参数得到CNN校准模型,优化目标是在保证模型精准度足够高的情况下,尽可能减少模型的训练时间,节省计算成本。当样本集数量确定时,常通过调节CNN初始模型的结构参数和训练参数来优化模型。结构参数主要包括卷积层的数量、卷积核的大小、移动步长等参数;训练参数主要包括训练轮数、学习率等参数。结构参数和训练参数相互影响,同时对模型的质量起到决定性的作用,考虑到参数较多,而CNN模型比较简单,因此,针对训练轮数和卷积层数对CNN初始模型进行优化。在训练过程中,改变其中某个参数,控制其他参数不变,研究对训练结果的影响。经过经验性分析,初始参数设定为:卷积层数为4,学习率为 10^{-5} ,训练轮数为10000。

[0055] 当其他参数不变时,一定程度上,随着训练轮数的增加,模型的损失函数会降低,训练结果的精准度会相应提高,同时计算时间也会相应增加。表1展示的是训练轮数分别是10000、50000和100000时的验证样本集的损失函数值,当训练轮数是10000时,损失函数的值由初始的 10^3 量级降低到 10^2 量级;当训练轮数增加到50000时,损失函数的值降低到 10^{-2} 量级;继续增加训练轮数至100000,此时的损失函数稳定在 10^{-2} 量级保持不变,但计算时间明显增加,说明在一定范围内,增加训练轮数可以有效降低损失函数值。因此,综合损失函数值与计算时间,选取训练轮数为50000。

[0056] 表1不同训练轮数的CNN校准模型的loss对比

	训练轮数	初始 loss	终止 loss
[0057]	10000	2.74×10^3	1.14×10^2
	50000	2.74×10^3	3.72×10^{-2}
[0058]	100000	2.74×10^3	4.75×10^{-2}

[0059] 在确定训练轮数之后,研究卷积层数对模型训练结果的影响,通过比较验证样本集的损失函数值来优化模型参数。在卷积层数是4的基础上,分别增加卷积层数至8和12,将损失函数值整理至表2中。由表2中的数据可知,当训练轮数为50000时,卷积层数为4、8和12的CNN校准模型的最终损失函数值均能由 10^3 量级降低到 10^{-2} 量级,并且最终保持稳定趋势。随着卷积层数的增加,模型结构更加复杂,相应的计算时间也会增加,因此,综合选取卷积层数为4层。

[0060] 表2不同卷积层数的CNN校准模型的loss对比

	卷积层数	初始 loss	终止 loss
[0061]	4	2.74×10^3	3.72×10^{-2}
	8	2.74×10^3	5.69×10^{-2}
	12	2.75×10^3	4.63×10^{-2}

[0062] 综上所述,在保证最终损失函数值足够小且稳定的情况下,尽可能缩短计算时间,优化后的CNN校准模型的卷积层数为4,训练轮数为50000,学习率为 10^{-5} 。

[0063] 天平校准数据误差分析方法:在确定CNN校准模型的结构参数和训练参数之后,为了进一步评估训练轮数对训练结果的影响,随机选取验证样本集中的一组数据进行相对误差分析,以天平输出电压值对应的载荷值为真实值 F ,CNN校准模型输出的天平载荷值为预测值 \hat{F} ,计算两者的相对误差 δ ,计算公式为

$$[0064] \quad \delta = \frac{\hat{F} - F}{F} \times 100\% \quad (2)$$

[0065] 表3展示的是卷积层数为4,采用不同训练轮数时,CNN校准模型的相对误差的计算结果。由表中的数据得知,当训练轮数为10000时,相对误差值比较大,甚至出现了错误情况;增加训练轮数至50000时,天平各分量的相对误差明显降低,基本在1%量级;而训练轮数为50000和100000时,两者的相对误差比较相近,此时继续增加训练轮数并不能提升模型的精准度。

[0066] 表3不同训练轮数的CNN校准模型的相对误差(%)对比

	分量\训练轮数	10000	50000	100000
[0067]	Y	4.06	-0.03	-0.04
	M_z	-25.89	-0.89	1.79
	M_x	-64.00	-2.50	-3.00
	X	-19.42	0.79	0.90
	Z	-34.55	0.60	0.60
	M_y	-182.43	0.91	-0.54

[0068] 表4展示的是训练轮数为50000,采用不同卷积层数时,CNN校准模型的相对误差的计算结果。由表中数据可以得出,当卷积层数由4增加至8和12时,天平各分量的相对误差并没有明显的降低,反而出现了增加的趋势。因此,综合选取训练轮数为50000,卷积层数为4,此时CNN校准模型的天平各分量的相对误差基本控制在1%以内,具有较高的精准度,且需要的计算时间相对较少,验证了该CNN校准模型的可行性,为将该方法应用于天平静态校准提供了可靠的数据支撑。

[0069] 表4不同卷积层数的CNN校准模型的相对误差(%)对比

[0070]	分量\卷积层数	4	8	12
	Y	-0.03	-0.07	-0.10
	M_x	-0.89	0.89	1.34
	M_x	-2.50	-4.00	-3.50
[0071]	X	0.79	0.81	0.92
	Z	0.60	0.85	0.73
	M_y	0.91	0.95	1.09

[0072] 天平静态校测综合加载误差和精度分析方法:通过对采用CNN模型后的天平训练样本信号的结果分析,处理后的天平各分量载荷与电压信号对应的真实载荷值之间的相对误差非常小,精准度较高。

[0073] 采用已训练的CNN校准模型对测试样本进行处理,根据不同的测试样本对天平静态校准综合加载误差和精度参数指标进行分析。

[0074] 天平静态校准的综合加载误差指天平静态校准过程中,经过CNN校准模型处理后输出的载荷值(近似值)与所施加的载荷基准(真实值)之间的标准偏差,反映了测量过程中的系统误差,一般常用天平各分量设计载荷的百分比表示。根据正交设计原则,在天平各分量的设计载荷范围内编制综合加载表,然后对天平依次实施加载,采用CNN校准模型对获得的天平输出电压信号进行处理,将得到的处理结果与实际载荷值进行对比,计算天平综合加载误差。计算公式为

$$W_{zi} = \frac{1}{P_{i\max} \sqrt{(m-1)}} \times \sqrt{\sum_{j=1}^m (F_{ij} - P_{ij})^2} \times 100\% \quad (3)$$

($i=1, 2, \dots, 6; j=1, 2, \dots, m$)

[0076] 式(3)中 W_{zi} 表示天平第*i*分量的综合加载误差; $P_{i\max}$ 表示天平第*i*分量的最大设计载荷;*i*表示天平的第*i*分量;*j*表示对天平各分量在第*j*点施加的一组综合检验载荷;*m*表示对天平各分量施加载荷的总组数,一般推荐综合加载组数不小于9组; F_{ij} 和 P_{ij} 分别表示天平第*i*分量第*j*点的近似载荷值和真实载荷值。

[0077] 表5天平综合加载误差(%FS)

	分量	天平 校准 公式	CNN 校准模型	国军标 合格指标	国军标 先进指标
	Y	0.05	0.015	0.4	0.1
[0078]	M_z	0.11	0.047	0.4	0.1
	M_x	0.21	0.357	0.5	0.2
	X	0.02	0.176	0.5	0.2
	Z	0.04	0.044	0.4	0.1
	M_y	0.24	0.067	0.4	0.1

[0079] 表5中展示了经过传统天平校准公式和CNN校准模型处理后的天平综合加载误差与国军标先进指标的对比情况,可以发现CNN校准模型较天平校准公式的综合加载误差得到了大幅度降低,且基本达到了国军标先进指标要求。

[0080] 在相同的加载条件下,根据天平各个分量的设计载荷对天平进行重复性加载,以评估测量过程中的随机误差。用于天平各分量的综合加载重复性计算的公式为

$$[0081] \quad S_{zi} = \frac{1}{X_{i\max}} \times \sqrt{\sum_{j=1}^n \left(X_{ij} - \frac{1}{n} \sum_{j=1}^n X_{ij} \right)^2} \times 100\% \quad (4)$$

$(i=1, 2, \dots, 6; j=1, 2, \dots, n)$

[0082] 式(4)中, S_{zi} 表示天平第*i*分量的综合加载重复性; $X_{i\max}$ 表示天平第*i*分量的设计载荷值; n 表示对天平分量重复性加载的次数,一般推荐重复测量次数不小于6次; X_{ij} 表示天平第*i*分量第*j*次加载时天平输出的载荷值。

[0083] 表6天平综合加载重复性(%FS)

	分量	天平 校准公式	CNN 校准模型	国军标 合格指标	国军标 先进指标
	Y	0.02	0.037	0.2	0.06
[0084]	M_z	0.02	0.013	0.2	0.06
	M_x	0.04	0.025	0.3	0.1
	X	0.03	0.009	0.3	0.1
	Z	0.02	0.036	0.2	0.06
	M_y	0.14	0.042	0.2	0.06

[0085] 表6展示的是经过传统天平校准公式和CNN校准模型处理后的天平综合加载重复性与国军标先进指标的对比结果,可以发现CNN校准模型的重复性较好,精度得到了较大幅度的提升,达到了国军标的先进指标要求。

[0086] 天平静态校测不确定度分析方法:天平的不确定度指CNN校准模型和理论公式得到的载荷值之间的接近程度,同时反映测量过程中的系统误差和随机误差。不确定度按照数值计算方法可以分为A类不确定度和B类不确定度,天平的A类不确定度主要包括天平综合加载误差和天平综合加载重复性;B类不确定度主要包括载荷源不确定度、数据采集系统引入的不确定度和校准设备引入的不确定度。

[0087] 计算天平校准公式和CNN校准模型的不确定度,并整理至表7中,表7中k表示置信水平为95%时的包含因子。天平校准公式和CNN校准模型的B类不确定度保持一致,其差别主要体现在A类不确定度中,由于校准公式大幅度提升了天平静态校准的精准度,因此,CNN校准模型获得的不确定度也远小于天平校准公式计算得到的不确定度。

[0088] 表7天平扩展不确定度(k=2)(%FS)

分量	天平	CNN	国军标	国军标
	校准公式	校准模型	合格指标	先进指标
Y	1.0	0.26	1.0	0.3
M_z	0.98	0.27	1.0	0.3
M_x	2.74	0.78	1.2	0.5
X	0.51	0.47	1.2	0.5
Z	0.87	0.27	1.0	0.3
M_y	1.0	0.29	1.0	0.3

[0090] 以上实施例仅为本申请的示例性实施例,不用于限制本申请,本申请的保护范围由权利要求书限定。本领域技术人员可以在本申请的实质和保护范围内,对本申请做出各种修改或等同替换,这种修改或等同替换也应视为落在本申请的保护范围内。

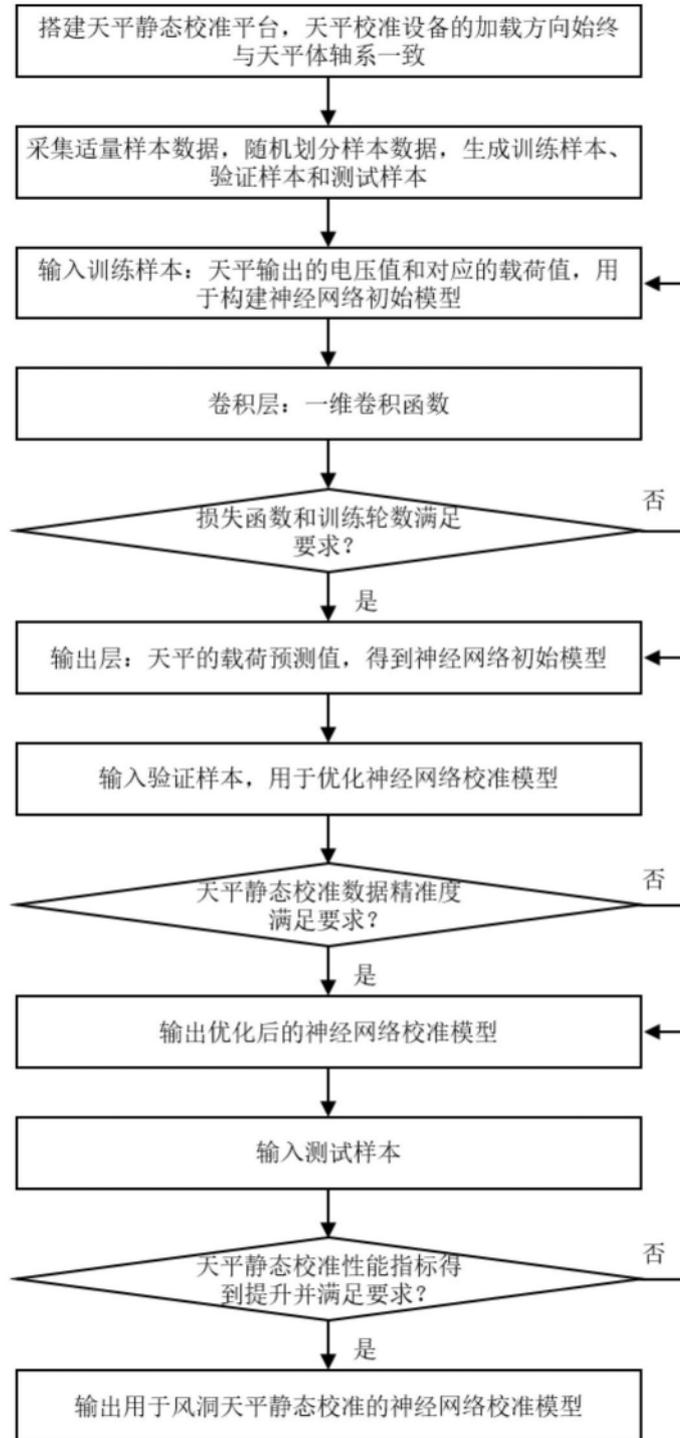


图1

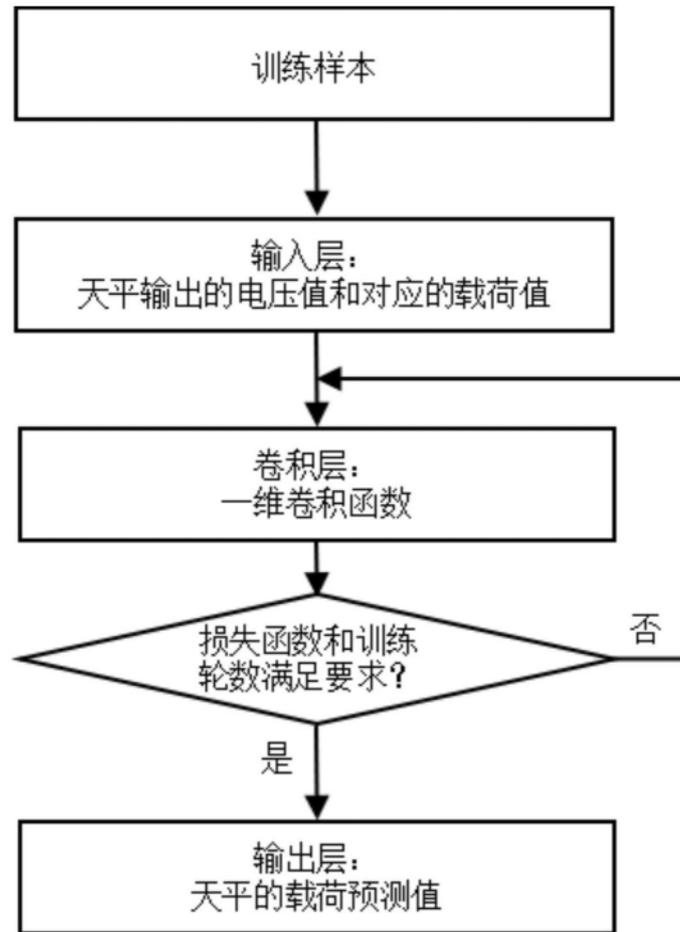


图2