



(12) 发明专利

(10) 授权公告号 CN 113970420 B

(45) 授权公告日 2022. 04. 05

(21) 申请号 202111192663.4

(22) 申请日 2021.10.13

(65) 同一申请的已公布的文献号  
申请公布号 CN 113970420 A

(43) 申请公布日 2022.01.25

(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  
代理人 焦海峰

(51) Int. Cl.  
G01M 9/06 (2006.01)

(56) 对比文件

CN 111473947 A, 2020.07.31

CN 106706207 A, 2017.05.24

WO 2021139337 A1, 2021.07.15

汪运鹏等.基于深度学习技术的激波风洞智能测力系统研究.《力学学报》.2020,全文.

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,全文.

Xin Bi等.Explainable time-frequency convolutional neural network for microseismic waveform classification.《Information Sciences》.2020,全文.

审查员 陈英杰

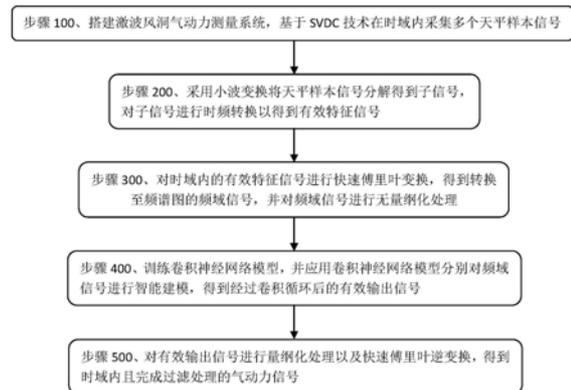
权利要求书3页 说明书9页 附图3页

(54) 发明名称

一种基于深度学习的激波风洞测力信号频域分析方法

(57) 摘要

本发明公开了一种基于深度学习的激波风洞测力信号频域分析方法,搭建激波风洞气动力测量系统,基于SVDC技术在时域内采集多个天平样本信号;采用小波变换将天平样本信号分解得到子信号,对子信号进行时频转换以得到有效特征信号;对时域内的有效特征信号进行快速傅里叶变换,得到转换至频谱图的频域信号,并对频域信号进行无量纲化处理;训练卷积神经网络模型,并应用卷积神经网络模型分别对频域信号进行智能建模,得到经过卷积循环后的有效输出信号;对所述有效输出信号进行量纲化处理以及快速傅里叶逆变换,得到时域内且完成过滤处理的气动力信号;本发明过滤惯性振动信号并获得真实气动力信号,提高脉冲风洞测力结果的可靠性和精度指标。



1. 一种基于深度学习的激波风洞测力信号频域分析方法,其特征在于,包括以下步骤:

步骤100、搭建高超声速飞行器模型的激波风洞气动力测量系统,基于SVDC技术在时域内采集多个天平样本信号;

步骤200、采用小波阈值降噪方法对天平样本信号中的天平阶跃信号进行小波分解得到子信号,对所述子信号进行相关性分析,并滤除高频噪声信号,以得到有效特征信号;

步骤300、对时域内的所述有效特征信号进行快速傅里叶变换,得到转换至频谱图的频域信号,并对所述频域信号进行无量纲化处理;

步骤400、训练卷积神经网络模型,并应用卷积神经网络模型分别对所述频域信号进行智能建模,得到经过卷积循环后的有效输出信号;

步骤500、对所述有效输出信号进行量纲化处理以及快速傅里叶逆变换,得到时域内且完成过滤处理的气动力信号。

2. 根据权利要求1所述的一种基于深度学习的激波风洞测力信号频域分析方法,其特征在于,在步骤100中,获取天平样本信号的实现方式为:

利用单矢量动态自校准技术对标准测力模型和测力系统进行动态校准,在所述标准测力模型的尖端悬挂钢丝加载,瞬间剪断钢丝卸载,产生阶跃载荷信号,以模拟风洞试验时对测力系统的冲击作用。

3. 根据权利要求2所述的一种基于深度学习的激波风洞测力信号频域分析方法,其特征在于,所述步骤100获取的所述天平样本信号包括剪断钢丝前的跳变前信号以及瞬间剪断钢丝卸载的天平阶跃信号,所述天平阶跃信号包含真实气动力信号和惯性振动信号,且将所述跳变前信号和天平阶跃信号的中心值作为理想阶跃信号,所述理想阶跃信号不含惯性振动信号。

4. 根据权利要求3所述的一种基于深度学习的激波风洞测力信号频域分析方法,其特征在于:在步骤200中,所述小波阈值降噪方法对所述天平阶跃信号进行近似分解和细节分解,分解得到低频系数和高频系数,其中,所述低频系数用于展示整个所述天平阶跃信号的趋势,所述高频系数用于展示整个所述天平阶跃信号的细节成分,所述小波阈值降噪方法进行小波分解以及过滤高频噪音的具体实现方式为:

步骤201、利用一维离散小波变换对降噪后的所述天平阶跃信号进行多级小波分解,以得到所述天平阶跃信号经过多级小波分解的低频系数和高频系数;

步骤202、对低频系数、高频系数和理想阶跃信号进行快速傅里叶变换,并计算经过快速傅里叶变换后的所述低频系数、高频系数和理想阶跃信号的99%占用带宽;

步骤203、以所述理想阶跃信号的99%占用带宽为基准,将所述高频系数和低频系数的99%占用带宽与基准对比,过滤完全不符合所述理想阶跃信号的99%占用带宽的高频系数和低频系数。

5. 根据权利要求3所述的一种基于深度学习的激波风洞测力信号频域分析方法,其特征在于,在步骤300和步骤400中,完成卷积神经网络模型训练的实现方式为:采用快速傅里叶变换将时域内的所述天平样本信号转换成频域内的幅度相位频谱信号;

对快速傅里叶变换后的幅度相位频谱信号的实部和虚部分别进行卷积神经网络模型训练,将训练后得到的实部和虚部组合成复数;

将卷积神经网络模型训练后的复数经过快速傅里叶逆变换投影到时域内。

6. 根据权利要求5所述的一种基于深度学习的激波风洞测力信号频域分析方法,其特征在于,对转换至频域的幅度相位频谱信号进行无量纲化处理的实现方式为:

在卷积神经网络模型训练前,确定所述幅度相位频谱信号实部和虚部中绝对值最大的数据;

将绝对值最大的数据作为特征数据,然后将所述幅度相位频谱信号实部和虚部的所有数据映射到 $[-1,1]$ 之间,生成标准数据,具体的映射公式为:

$$x^* = \frac{x}{\max(|x|)};$$

在卷积神经网络模型训练结束时,采用逆变换将标准数据还原到原始区间内,具体的逆变换公式为:

$$x = \max(|x|) x^*;$$

其中, $x$ 为无量纲化前的幅度相位频谱信号, $x^*$ 为无量纲化后的标准数据。

7. 根据权利要求5所述的一种基于深度学习的激波风洞测力信号频域分析方法,其特征在于:在步骤400中,所述卷积神经网络的智能模型包含输入层、隐藏层和输出层,其中,所述隐藏层包括卷积层、池化层和全连接层;

所述输入层为所述标准测力模型的天平三分量信号,所述三分量信号依次是法向力 $Y$ 、俯仰力矩 $M_z$ 和轴向力 $X$ ,三分量信号对应转换到频域的信号包含实部和虚部;

所述卷积层中的损失函数随着训练轮数的增加而减小,且所述三分量信号的频域信号最终达到收敛状态。

8. 根据权利要求7所述的一种基于深度学习的激波风洞测力信号频域分析方法,其特征在于:在步骤400中,对所述卷积神经网络进行参数优化以优化筛选卷积神经网络训练模型,可优化的参数分别包括训练参数和结构参数,其中,所述训练参数包括学习率、训练轮数和批量尺寸,所述结构参数为卷积层中卷积核的数量、尺寸和移动步长,以及池化层中的池化尺寸和移动步长,优化筛选卷积神经网络训练模型的具体实现方式为:

根据步骤300得到的频谱图,获取所述有效特征信号的频域信号以及所述理想阶跃信号经过快速傅里叶逆变换的信号,生成理想频谱数据;

根据所述理想频谱数据与有效特征信号的频域信号之间的差值幅值确定惯性振动频率;

调整所述卷积神经网络训练模型的训练参数和结构参数,以使得所述卷积神经网络训练模型的有效输出信号与所述理想频谱数据重合。

9. 根据权利要求8所述的一种基于深度学习的激波风洞测力信号频域分析方法,其特征在于:调整所述卷积神经网络训练模型的训练参数和结构参数的具体实现步骤为:

选择时域内对应天平阶跃信号的连续时段作为目标对象,并确定目标对象的有效特征信号;

以目标对象的理想阶跃信号在频域内的平均值为真实值 $\bar{F}$ ,将不同卷积层和不同训练轮数对应的卷积神经网络训练模型对所述有效特征信号处理后的频域信号的平均值为近似值 $\bar{F}^*$ ;

对比真实值 $\bar{F}$ 和近似值 $\bar{F}^*$ 之间的相对误差 $\delta$ 和相对标准偏差RSD,来确定所述卷积神经网络训练模型的卷积层和训练轮数;

其中,相对误差 $\delta$ 和相对标准偏差RSD的定义式分别为

$$\delta = \frac{\bar{F}^* - \bar{F}}{\bar{F}} \times 100\%$$

$$RSD = \frac{1}{\bar{F}^*} \sqrt{\frac{1}{n-1} \sum_{i=1}^n (F_i^* - \bar{F}^*)^2} \times 100\% ;$$

式中 $n$ 表示连续时段内的天平阶跃信号总数, $F_i^*$ 表示所述卷积神经网络训练模型对连续时段内第 $i$ 点时输出的近似值。

10. 根据权利要求9所述的一种基于深度学习的激波风洞测力信号频域分析方法,其特征在于:根据所述相对误差 $\delta$ 和相对标准偏差RSD的权重选择所述卷积神经网络训练模型的训练轮数和卷积层层数。

## 一种基于深度学习的激波风洞测力信号频域分析方法

### 技术领域

[0001] 本发明涉及风洞测力信号试验技术领域,具体涉及一种基于深度学习的激波风洞测力信号频域分析方法。

### 背景技术

[0002] 脉冲型应变天平的测量方式,大多为测量快速响应模型在冲击载荷作用下的变形引起应变片的电压变化,进而反映出模型载荷,因其整体结构刚度大、分量间干扰低、输出灵敏度高、稳定性强和精准度高等特点广泛应用于高超声速飞行器测力试验等。在开展测力试验时,测力系统在风洞流场瞬间起动的脉冲冲击激励作用下产生惯性振动,由于受到风洞的有效运行时间的限制和测力结构复杂性的影响,测力系统的惯性振动信号无法在短时间内快速衰减,天平的输出信号中包含了气动力信号和惯性振动干扰信号。目前为了消除惯性振动干扰发展的特种天平技术方法主要有压电天平、应力波天平、磁悬挂天平、加速度计天平和惯性自补偿型技术等。

[0003] 然而当测力系统的惯性振动频率与气动力频率相近时,传统的惯性自补偿测力技术和滤波处理可能无法有效滤除干扰信号,从而影响气动力测量的精准度。

### 发明内容

[0004] 本发明的目的在于提供一种基于深度学习的激波风洞测力信号频域分析方法,以解决现有技术中无法有效滤除干扰信号,从而影响气动力测量的精准度的技术问题。

[0005] 为解决上述技术问题,本发明具体提供下述技术方案:

[0006] 一种基于深度学习的激波风洞测力信号频域分析方法,包括以下步骤:

[0007] 步骤100、搭建高超声速飞行器模型激波风洞气动力测量系统,基于SVDC技术在时域内采集多个天平样本信号;

[0008] 步骤200、采用小波阈值降噪方法对天平样本信号中的天平阶跃信号进行小波分解得到子信号,对所述子信号进行时频转换,以滤除所述天平样本信号中的高频噪声信号,得到有效特征信号;

[0009] 步骤300、对时域内的所述有效特征信号进行快速傅里叶变换,得到转换至频谱图的频域信号,并对所述频域信号进行无量纲化处理;

[0010] 步骤400、训练卷积神经网络模型,并应用卷积神经网络模型分别对所述频域信号进行智能建模,得到经过卷积循环后的有效输出信号;

[0011] 步骤500、对所述有效输出信号进行量纲化处理以及快速傅里叶逆变换,得到时域内且完成过滤处理的气动力信号。

[0012] 作为本发明的一种优选方案,在步骤100中,获取天平样本信号的实现方式为:

[0013] 利用单矢量动态自校准技术对标准测力模型和测力系统进行动态校准,在所述标准测力模型的尖端悬挂钢丝加载,瞬间剪断钢丝卸载,产生阶跃载荷信号,以模拟风洞试验时对测力系统的冲击作用。

[0014] 作为本发明的一种优选方案,所述步骤100获取的所述天平样本信号包括剪断钢丝前的跳变前信号以及瞬间剪断钢丝卸载的天平阶跃信号,所述天平阶跃信号包含真实气动力信号和惯性振动信号,且将所述跳变前信号和天平阶跃信号的中心值作为理想阶跃信号,所述理想阶跃信号不含惯性振动信号。

[0015] 作为本发明的一种优选方案,在步骤200中,所述小波阈值降噪方法对所述天平阶跃信号进行近似分解和细节分解,分解得到低频系数和高频系数,其中,所述低频系数用于展示整个所述天平阶跃信号的趋势,所述高频系数用于展示整个所述天平阶跃信号的细节成分,所述小波阈值降噪方法进行小波分解以及过滤高频噪音的具体实现方式为:

[0016] 步骤201、利用一维离散小波变换对降噪后的所述天平阶跃信号进行多级小波分解,以得到所述天平阶跃信号经过多级小波分解的低频系数和高频系数;

[0017] 步骤202、对低频系数、高频系数和理想阶跃信号进行快速傅里叶变换,并计算经过快速傅里叶变换后的所述低频系数、高频系数和理想阶跃信号的99%占用带宽;

[0018] 步骤203、以所述理想阶跃信号的99%占用带宽为基准,将所述高频系数和低频系数的99%占用带宽与基准对比,过滤完全不符合所述理想阶跃信号的99%占用带宽的高频系数和低频系数。

[0019] 作为本发明的一种优选方案,采用快速傅里叶变换将时域内的所述天平样本信号转换成频域内的幅度相位频谱信号;

[0020] 对快速傅里叶变换后的幅度相位频谱信号的实部和虚部分别进行卷积神经网络模型训练,将训练后得到的实部和虚部组合成复数;

[0021] 将卷积神经网络模型训练后的复数经过快速傅里叶逆变换投影到时域内。

[0022] 作为本发明的一种优选方案,对转换至频域的幅度相位频谱信号进行无量纲化处理的实现方式为:

[0023] 在卷积神经网络模型训练前,确定所述幅度相位频谱信号实部和虚部中绝对值最大的数据;

[0024] 将绝对值最大的数据作为特征数据,然后将所述幅度相位频谱信号实部和虚部的所有数据映射到 $[-1,1]$ 之间,生成标准数据,具体的映射公式为:

$$[0025] \quad x^* = \frac{x}{\max(|x|)};$$

[0026] 在卷积神经网络模型训练结束时,采用逆变换将标准数据还原到原始区间内,具体的逆变换公式为:

$$[0027] \quad x = \max(|x|) x^*;$$

[0028] 其中, $x$ 为无量纲化前的幅度相位频谱信号, $x^*$ 为无量纲化后的标准数据。

[0029] 作为本发明的一种优选方案,在步骤400中,所述卷积神经网络的智能模型包含输入层、隐藏层和输出层,其中,所述隐藏层包括卷积层、池化层和全连接层;

[0030] 所述输入层为所述标准测力模型的天平三分量信号,所述三分量信号依次是法向力 $Y$ 、俯仰力矩 $M_z$ 和轴向力 $X$ ,三分量信号对应转换到频域的信号包含实部和虚部;

[0031] 所述卷积层中的损失函数随着训练轮数的增加而减小,且所述三分量信号的频域信号最终达到收敛状态。

[0032] 作为本发明的一种优选方案,在步骤400中,对所述卷积神经网络进行参数优化以

优化筛选卷积神经网络训练模型,可优化的参数分别包括训练参数和结构参数,其中,所述训练参数包括学习率、训练轮数和批量尺寸,所述结构参数为卷积层中卷积核的数量、尺寸和移动步长,以及池化层中的池化尺寸和移动步长,优化筛选卷积神经网络训练模型的具体实现方式为:

[0033] 根据步骤300得到的频谱图,获取所述有效特征信号的频域信号以及所述理想阶跃信号经过快速傅里叶逆变换的信号,生成理想频谱数据;

[0034] 根据所述理想频谱数据与有效特征信号的频域信号之间的差值幅值确定惯性振动频率;

[0035] 调整所述卷积神经网络训练模型的训练参数和结构参数,以使得所述卷积神经网络训练模型的有效输出信号与所述理想频谱数据重合。

[0036] 作为本发明的一种优选方案,调整所述卷积神经网络训练模型的训练参数和结构参数的具体实现步骤为:

[0037] 选择时域内对应天平阶跃信号的连续时段作为目标对象,并确定目标对象的有效特征信号;

[0038] 以目标对象的理想阶跃信号在频域内的平均值为真实值 $\bar{F}$ ,将不同卷积层和不同训练轮数对应的卷积神经网络训练模型对所述有效特征信号处理后的频域信号的平均值为近似值 $\bar{F}^*$ ;

[0039] 对比真实值 $\bar{F}$ 和近似值 $\bar{F}^*$ 之间的相对误差 $\delta$ 和相对标准偏差RSD,来确定所述卷积神经网络训练模型的卷积层和训练轮数;

[0040] 其中,相对误差 $\delta$ 和相对标准偏差RSD的定义式分别为

$$\delta = \frac{\bar{F}^* - \bar{F}}{\bar{F}} \times 100\%$$

[0041]

$$RSD = \frac{1}{\bar{F}^*} \sqrt{\frac{1}{n-1} \sum_{i=1}^n (F_i^* - \bar{F}^*)^2} \times 100\% ;$$

[0042] 式中n表示连续时段内的天平阶跃信号总数, $F_i^*$ 表示所述卷积神经网络训练模型对连续时段内第i点时输出的近似值。

[0043] 作为本发明的一种优选方案,根据所述相对误差 $\delta$ 和相对标准偏差RSD的权重选择所述卷积神经网络训练模型的训练轮数和卷积层层数。

[0044] 本发明与现有技术相比较具有如下有益效果:

[0045] 本发明复现风洞的测力系统的天平输出信号,通过频域分析方法转换为频域信号数据,训练能够准确识别系统惯性振动信号动态特征的CNN智能模型,以过滤统惯性振动信号并获得真实气动力信号,提高脉冲风洞测力结果的可靠性和精度指标。

## 附图说明

[0046] 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伸获得其它的实施附图。

- [0047] 图1为本发明实施例提供的测力信号频域分析方法的流程示意图；
- [0048] 图2为本发明实施例提供的天平阶跃信号和理想阶跃信号的时域图；
- [0049] 图3为本发明实施例提供的天平阶跃信号和理想阶跃信号的频谱图；
- [0050] 图4为本发明实施例提供的时频转换过滤后的有效特征信号时域图；
- [0051] 图5为本发明实施例提供的CNN训练输出信号的频谱图曲线图；
- [0052] 图6为本发明实施例提供的CNN训练输出信号的时域信号图。

### 具体实施方式

[0053] 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。

[0054] 如图1所示,本发明提供了一种基于深度学习的激波风洞测力信号频域分析方法,本实施方式复现风洞的测力系统的天平输出信号,通过频域分析方法转换为频域信号数据,训练能够准确识别系统惯性振动信号动态特征的CNN智能模型,以过滤统惯性振动信号并获得真实气动力信号,提高脉冲风洞测力结果的可靠性和精度指标。具体包括以下步骤:

[0055] 步骤100、搭建高超声速飞行器模型激波风洞气动力测量系统,基于SVDC技术在时域内采集多个天平样本信号。

[0056] 在步骤100中,获取天平样本信号的实现方式为:

[0057] 利用单矢量动态自校准技术对标准测力模型和测力系统进行动态校准,在所述标准测力模型的尖端悬挂钢丝加载,瞬间剪断钢丝卸载,产生阶跃载荷信号,以模拟风洞试验时对测力系统的冲击作用。

[0058] 需要补充说明的是,本实施方式的标准测力模型和测力系统为在风洞外搭建与风洞内测力试验时相同的测力系统,激波风洞气动力测量系统包括高超声速飞行器测力模型、高精度脉冲型应变天平以及大刚度模型尾支撑机构,具体的,高超声速飞行器测力模型为尖锥角度为 $10^{\circ}$ ,长度为750mm;使用的高精度脉冲型应变天平为三分量脉冲型杆式应变天平,三分量依次是法向力Y、俯仰力矩 $M_z$ 和轴向力X。

[0059] 传统的标准动态信号发生的方法主要有脉冲响应法和阶跃响应法,脉冲响应法是采用冲击锤敲击模型表面施加脉冲力,冲击载荷的方向和作用点无法准确控制,无法用于天平动态校准。阶跃响应法是在天平的固定方向上悬挂砝码加载,瞬间卸载产生阶跃载荷信号。为了准确模拟风洞测力试验时模型的气动力,采用单矢量动态自校准技术对整个测力系统进行动态校准,通过在模型尖端悬挂钢丝施加载荷,剪断钢丝瞬间生成阶跃载荷,在一定程度上,其载荷大小、方向和作用点不受限制,且能自动分解并实时输出数值,更加符合气动力的加载方式。

[0060] 所述步骤100获取的所述天平样本信号包括剪断钢丝前的跳变前信号以及瞬间剪断钢丝卸载的天平阶跃信号,天平阶跃信号包含真实气动力信号和惯性振动信号,且将跳变前信号和天平阶跃信号的中心值作为理想阶跃信号,理想阶跃信号不含惯性振动信号。

[0061] 即基于SVDC技术在时域内采集了适量的天平样本信号,采用剪断钢丝的方法产生的阶跃载荷信号(简称“天平阶跃信号”)模拟风洞测力试验时对测力系统的冲击作用,采用

理想阶跃信号模拟测力系统的真实气动力信号。

[0062] 具体的天平阶跃信号和理想阶跃信号在时域中的分布如图2所示,图2代表的时域信号的总时间为150ms,以激波风洞测力试验时风洞流场起动瞬间为时间点划分为两段,信号中跳变前的零值信号对应风洞流场起动前的准备阶段;在第55ms时,信号产生跳变,忽略边沿触发时间,对应风洞流场瞬间起动时测力系统受到的冲击激励;在后续时间内,天平阶跃信号包含气动力和惯性振动信号,理想阶跃信号不含惯性振动信号,保持稳定不变。

[0063] 步骤200、采用小波变换将天平样本信号中的天平阶跃信号分解得到子信号,对子信号进行时频转换,以滤除天平样本信号中的高频噪声信号,得到有效特征信号。

[0064] 由于天平的输出信号一般是时域内的波形信号,该信号能够直观地反映出信号随时间的变化趋势。而频谱图可以更加充分地展示出信号的频率分布信息,通过对频谱图的分析可以迅速分辨出信号中的惯性振动成分。

[0065] 在步骤200中,所述小波阈值降噪方法对所述天平阶跃信号进行近似分解和细节分解,分解得到低频系数和高频系数,其中,所述低频系数用于展示整个所述天平阶跃信号的趋势,所述高频系数用于展示整个所述天平阶跃信号的细节成分,所述小波阈值降噪方法进行小波分解以及过滤高频噪音的具体实现方式为:

[0066] 步骤201、利用一维离散小波变换对降噪后的所述天平阶跃信号进行多级小波分解,以得到所述天平阶跃信号经过多级小波分解的低频系数和高频系数;

[0067] 步骤202、对低频系数、高频系数和理想阶跃信号进行快速傅里叶变换,并计算经过快速傅里叶变换后的所述低频系数、高频系数和理想阶跃信号的99%占用带宽;

[0068] 步骤203、以所述理想阶跃信号的99%占用带宽为基准,将所述高频系数和低频系数的99%占用带宽与基准对比,过滤完全不符合所述理想阶跃信号的99%占用带宽的高频系数和低频系数。

[0069] 作为时频变换分析中最基本的方法之一,传统的快速傅里叶变换分析针对整体进行线性变换,可以快速分析出信号中存在的频率和幅值信息,但是不能表示随时间变化的频率信号,不宜分析非线性、非平稳的突变信号。小波降噪分解通过小波函数的伸缩和平移实现信号的时频分析局部化,具有多分辨率性,很适合分析非平稳信号和提取信号的局部特征,常用于信号降噪和信号分解。

[0070] 傅里叶变换是一种常用的信号处理方法,通过三角函数基将时域内的信号线性分解到频域内各种不同频率的信号。同理,傅里叶逆变换可以将频域内的信号线性转换到时域内。

[0071] 对图2中的时域信号进行快速傅里叶变换,将其转换成频域内的频谱图,如图3所示。图3代表天平样本信号在频域内的频谱图,截取频率为500Hz,当频率大于500Hz时,信号的幅值基本为零。可以发现天平阶跃信号的主要频率为380Hz左右,而理想阶跃信号无该频率,说明测力系统的惯性振动频率为380Hz左右。

[0072] 采用快速傅里叶逆变换将频域内的信号转换到时域内,采用快速傅里叶变换和快速傅里叶逆变换在一定程度上可能会造成频谱损失,将原始的天平样本信号与经过快速傅里叶逆变换后的信号进行对比,过滤快速傅里叶变换(FFT)和快速傅里叶逆变换(IFFT)的时频变换中频谱损失较大的信号,过滤后的频谱图如如图4所示。图4中的信号图显示了气动力信号和系统惯性振动信号经过快速傅里叶变换和快速傅里叶逆变换后的数据与天平

样本信号基本完全重合。

[0073] 步骤300、对时域内的有效特征信号进行快速傅里叶变换,得到转换至频谱图的频域信号,并对频域信号进行无量纲化处理。

[0074] 步骤400、训练卷积神经网络模型,并应用卷积神经网络模型分别对频域信号进行智能建模,得到经过卷积循环后的有效输出信号。

[0075] 卷积神经网络的智能模型包含输入层、隐藏层和输出层,其中,隐藏层包括卷积层、池化层和全连接层。

[0076] 输入层为标准测力模型的天平三分量信号,三分量信号依次是法向力Y、俯仰力矩 $M_z$ 和轴向力X,三分量信号对应转换到频域的信号包含实部和虚部,卷积层中的损失函数随着训练轮数的增加而减小,且三分量信号的频域信号最终达到收敛状态。

[0077] 卷积层中卷积核的数目和尺寸会影响网络模型的训练结果;池化层的作用是加快计算速度并且防止产生过拟合问题;输出层是经过模型训练后的三分量输出信号。

[0078] 在频域内搭建卷积神经网络(CNN)智能模型时,需要先将时域内过滤后的有效特征信号映射到频域内,采用快速傅里叶变换FFT将时域内的样本信号转换成频域内的幅度和相位频谱信号,由于卷积神经网络CNN的输入数据类型不能是复数形式,为了便于训练,对进行FFT后的频域数据的实部和虚部分别进行训练,将训练后分别得到的实部和虚部组合成复数,再经过IFFT投影到时域内,完成CNN模型的训练。

[0079] 即在步骤300和步骤400中,完成卷积神经网络模型训练的实现方式为:

[0080] (1)采用快速傅里叶变换将时域内的天平样本信号转换成频域内的幅度相位频谱信号;

[0081] (2)对快速傅里叶变换后的幅度相位频谱信号的实部和虚部分别进行卷积神经网络模型训练,将训练后得到的实部和虚部组合成复数;

[0082] (3)将卷积神经网络模型训练后的复数经过快速傅里叶逆变换投影到时域内。

[0083] 在实际采集训练样本信号时,由于受到钢丝的强度限制,理想阶跃信号的值相对于激波风洞试验时天平的输出信号显得比较小。为了保证训练样本与测试样本信号的一致性,统一对样本数据进行无量纲化处理,将经过FFT后频域数据的实部和虚部统一映射到相同的小区间内,以便于模型的训练,加快收敛速度并提升计算精度。

[0084] 对转换至频域的幅度相位频谱信号进行无量纲化处理的实现方式为:

[0085] 在卷积神经网络模型训练前,确定幅度相位频谱信号实部和虚部中绝对值最大的数据;

[0086] 将绝对值最大的数据作为特征数据,然后将幅度相位频谱信号实部和虚部的所有数据映射到 $[-1, 1]$ 之间,生成标准数据,具体的映射公式为:

$$[0087] \quad x^* = \frac{x}{\max(|x|)};$$

[0088] 在卷积神经网络模型训练结束时,采用逆变换将标准数据还原到原始区间内,具体的逆变换公式为:

$$[0089] \quad x = \max(|x|) x^*。$$

[0090] 而由于CNN模型的参数可以优化,以降低训练时间和处理数据的精准度,可优化的参数分别包括训练参数和结构参数,其中,训练参数包括学习率、训练轮数和批量尺寸,结

构参数为卷积层中卷积核的数量、尺寸和移动步长,以及池化层中的池化尺寸和移动步长,卷积层中卷积核的数目和尺寸会影响网络模型的训练结果;池化层的作用是加快计算速度并且防止产生过拟合问题。

[0091] 因此本实施方式首先在频域内训练CNN智能模型,以天平阶跃信号作为训练样本中的输入数据,以理想阶跃信号作为训练样本中的期望输出数据;然后将智能模型应用于复现风洞的测力试验中,以期获得理想的气动力信号。

[0092] 在步骤400中,优化筛选卷积神经网络训练模型的具体实现方式为:

[0093] 根据步骤300得到的频谱图,获取有效特征信号的频域信号以及理想阶跃信号经过快速傅里叶逆变换的信号,生成理想频谱数据;

[0094] 根据理想频谱数据与有效特征信号的频域信号之间的差值幅值确定惯性振动频率;

[0095] 调整卷积神经网络训练模型的训练参数和结构参数,以使得卷积神经网络训练模型的有效输出信号与理想频谱数据重合。

[0096] 需要补充说明的是,增加卷积层可以在网络模型达到同样的表现力时减少网络的参数数量,卷积层的层数能够直接影响模型的训练时间和精准度。为了便于更加直观的分析训练结果的质量,将频域内的计算结果转换到时域内,然后进行比较分析。保证其余参数相同,通过改变卷积层的层数来提升网络的训练质量。

[0097] 具体的,调整卷积神经网络训练模型的训练参数和结构参数的具体实现步骤为:

[0098] 选择时域内对应天平阶跃信号的连续时段作为目标对象,并确定目标对象的有效特征信号;

[0099] 以目标对象的理想阶跃信号在频域内的平均值为真实值 $\bar{F}$ ,将不同卷积层和不同训练轮数对应的卷积神经网络训练模型对有效特征信号处理后的频域信号的平均值为近似值 $\bar{F}^*$ ;

[0100] 对比真实值 $\bar{F}$ 和近似值 $\bar{F}^*$ 之间的相对误差 $\delta$ 和相对标准偏差RSD,来确定卷积神经网络训练模型的卷积层和训练轮数;

[0101] 其中,相对误差 $\delta$ 和相对标准偏差RSD的定义式分别为

$$\delta = \frac{\bar{F}^* - \bar{F}}{\bar{F}} \times 100\%$$

[0102]

$$RSD = \frac{1}{\bar{F}^*} \sqrt{\frac{1}{n-1} \sum_{i=1}^n (F_i^* - \bar{F}^*)^2} \times 100\%;$$

[0103] 式中n表示连续时段内的天平阶跃信号总数, $F_i^*$ 表示卷积神经网络训练模型对连续时段内第i点时输出的近似值。

[0104] 最后,根据相对误差和相对标准偏差RSD的权重选择卷积神经网络训练模型的训练轮数和卷积层层数。

[0105] 截取图2中的截取70~110ms的时间段进行相对误差和相对标准偏差分析,通过改变不同卷积层层数,对比CNN模型的结果,具体的结果如下表1所示。

[0106] 表1不同卷积层层数的CNN模型的结果对比

	layers	$\bar{F}$ (N)	$\bar{F}^*$ (N)	$\delta$ (%)	RSD(%)
	24	2.549	2.547	-0.08	0.94
[0107]	48	2.549	2.519	-1.18	0.41
	<b>64</b>	<b>2.549</b>	<b>2.506</b>	<b>-1.69</b>	<b>0.39</b>
	96	2.549	2.495	-2.12	0.29

[0108] 表1展示的是当卷积层数分别为24、48、64和96层时CNN模型的训练结果。可以发现当卷积层数由24层增加至96层时,训练结果的相对误差逐渐增加,而相对标准偏差明显降低,训练时间明显增加,综合考虑相对误差、相对标准偏差以及训练时间,选取卷积层数为64。

[0109] 在确定了卷积层数之后,考虑训练轮数的进一步优化。在一定范围内,一般增加训练轮数会提高模型精度,但是训练时间也会明显增加,同时训练轮数过多会导致数据出现过拟合现象。由表2中训练开始和结束时的损失函数可知,当训练轮数由10000增加到100000时,初始的损失函数是 $10^{-1}$ 量级左右,结束的损失函数是 $10^{-8}$ 量级,此时训练轮数为100000的损失函数已经足够小并且达到稳定状态,因此增加训练轮数可以有效降低模型的损失函数。

[0110] 表2不同训练轮数的CNN模型的损失函数量级对比

	epochs	Initial loss	Final loss
[0111]	10000	0.41	7.03e-7
	50000	2.34	3.27e-7
	<b>100000</b>	<b>0.94</b>	<b>4.53e-8</b>

[0112] 计算不同训练轮数对应的CNN模型处理训练样本的相对误差和相对标准偏差,整理至表3中。表3展示了训练轮数分别为10000、50000和100000时的模型训练样本处理结果,发现当训练轮数增加时,其相对误差逐渐增加,而相对标准偏差逐渐降低。因此,综合考虑最终选取训练轮数为100000。

[0113] 表3不同训练轮数的CNN模型的结果对比

	epochs	$\bar{F}$ (N)	$\bar{F}^*$ (N)	$\delta$ (%)	RSD(%)
[0114]	10000	2.549	2.544	-0.20	2.19
	50000	2.549	2.516	-1.29	1.00
	<b>100000</b>	<b>2.549</b>	<b>2.506</b>	<b>-1.69</b>	<b>0.39</b>

[0115] 步骤500、对有效输出信号进行无量纲化逆处理以及快速傅里叶逆变换,得到时域内且完成过滤处理的气动力信号。

[0116] 利用优化后的CNN智能模型对高频过滤后的有效特征信号进行处理,将模型在频域和时域内的输出与理想阶跃信号进行对比,如图5和图6所示,点划线表示训练样本的输入信号,虚线表示理想阶跃信号,实线是经过CNN智能模型处理后的输出信号。由图5可以发现经过CNN训练后的输出信号的频谱图曲线与理想阶跃信号的频谱图曲线基本重合,由图6可以发现经过CNN训练后的输出信号的时域信号曲线与理想阶跃信号的时域信号曲线基本重合,完全消除了输入信号中频率为380Hz的信号,经过CNN处理后的信号完全滤掉了惯性振动干扰,达到了理想阶跃信号的要求。

[0117] 本发明的激波风洞天平测力信号在频域内进行CNN智能模型训练,智能模型有效

识别了系统的惯性振动频率信号,滤除了惯性振动干扰信号,有效输出了更接近实际的气动力信号,提高脉冲风洞测力结果的可靠性和精度指标。

[0118] 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。

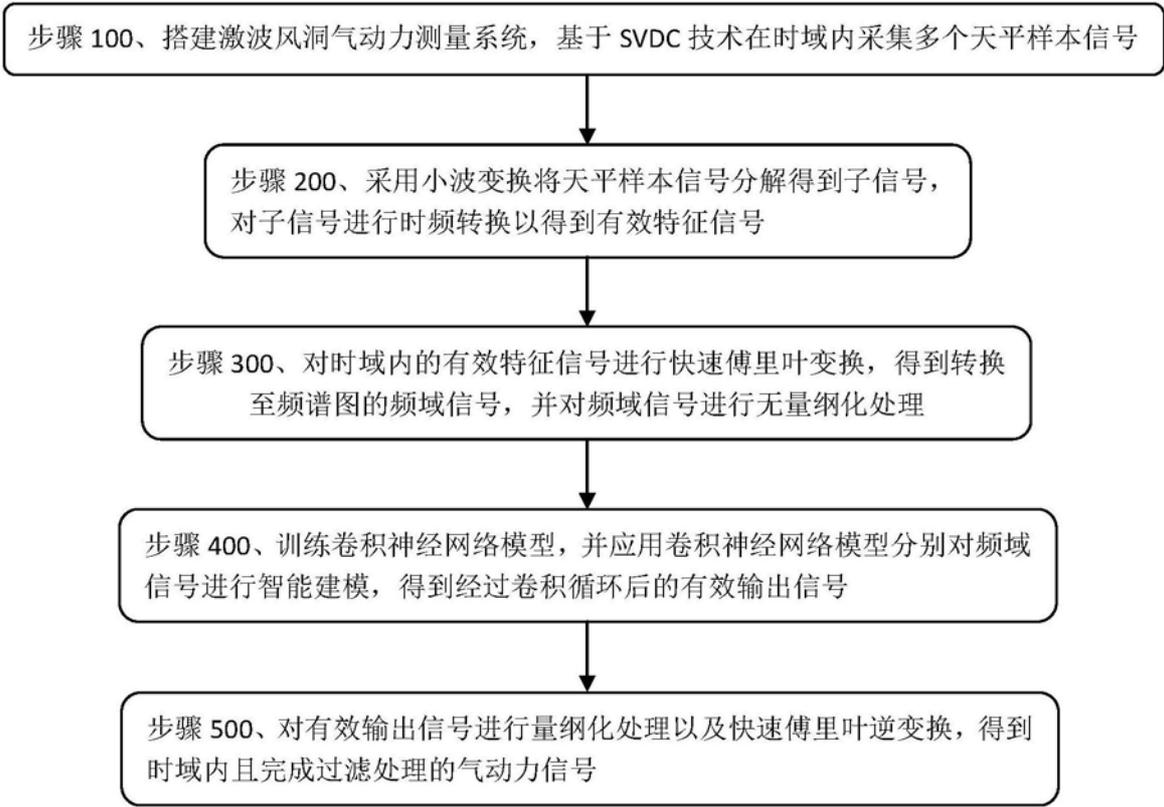


图1

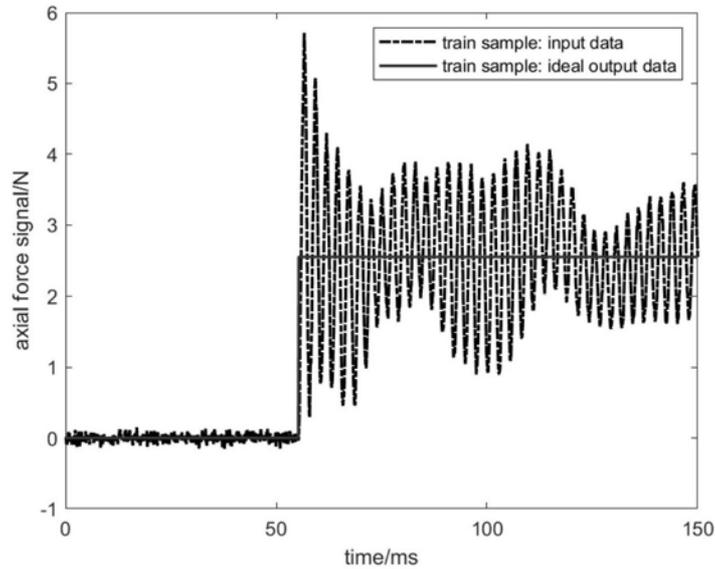


图2

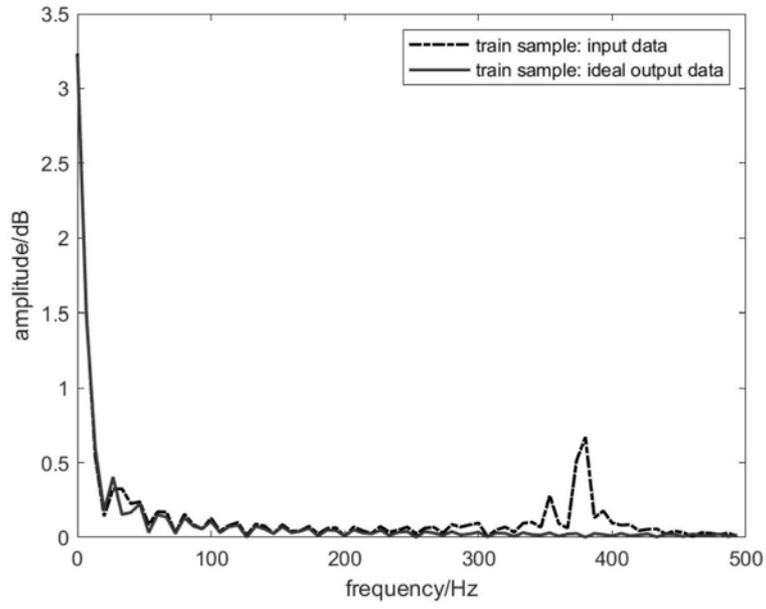


图3

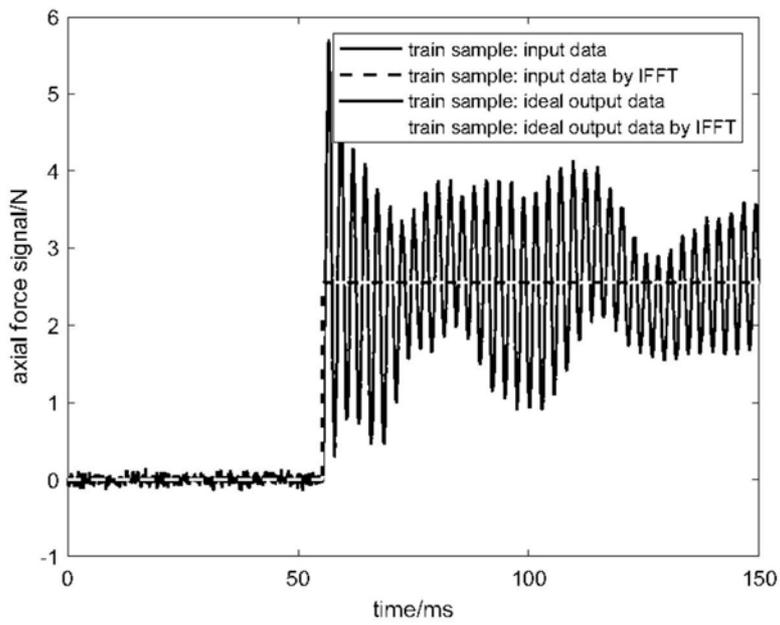


图4

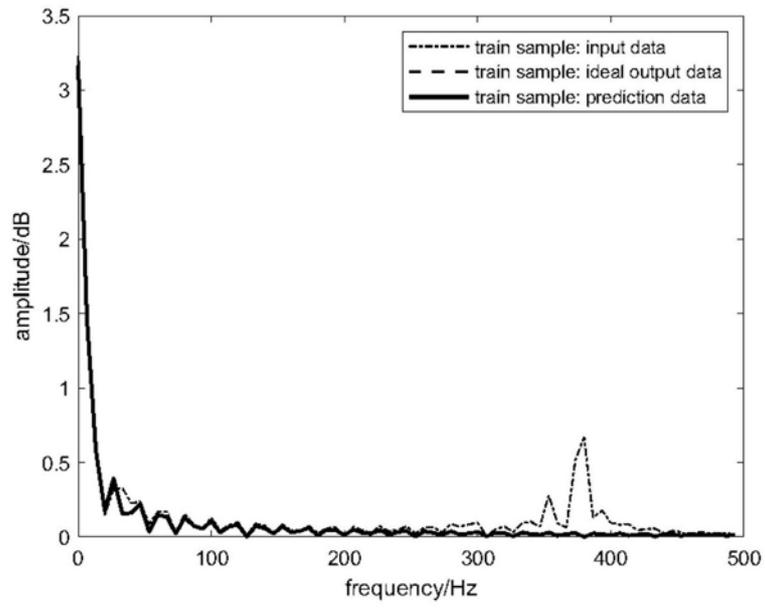


图5

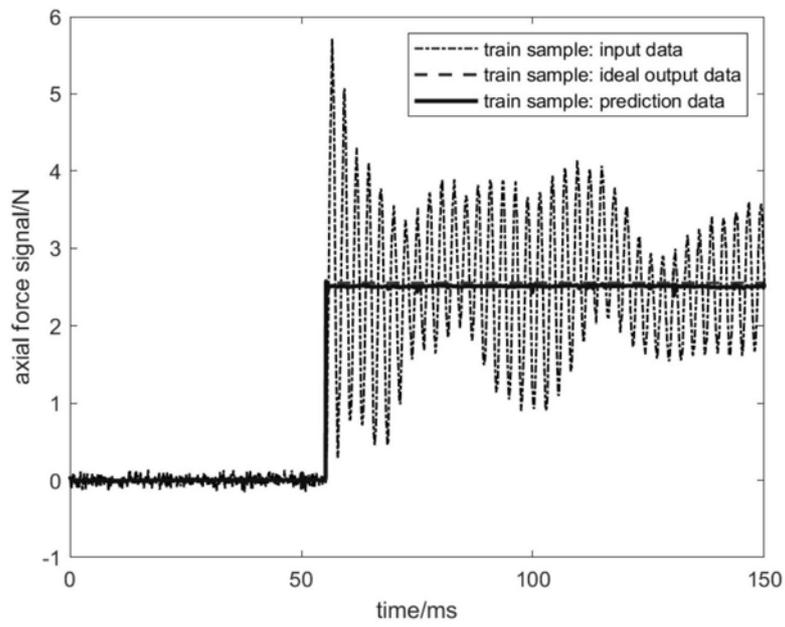


图6