

考虑噪声抑制的高超声速风洞气动力识别方法

马贵林, 李世超, 高宏力, 王钦超, 伍 广, 段志琴

(西南交通大学 机械学院, 成都 610031)

摘 要: 对于风洞试验中全尺寸模型试验的非平稳信号进行载荷辨识仍存在诸多问题。针对全尺度模型试验的非平稳信号载荷辨识提出了一种基于深度残差收缩网络(DRSN)深度学习技术的智能载荷辨识方法,该方法通过深度学习提取测力系统输出数据中的气动力、惯性力和噪声等特征,通过注意力机制对每组数据进行获取阈值,再通过软阈值函数对特征进行滤波降噪,有效辨识出测力系统响应信号中的惯性力分量并进行剔除,实现气动力载荷辨识。在测试验证中,均值法的辨识精度为 85% 以上,DRSN 模型的辨识精度为 94% 以上,证明 DRSN 模型能有效降低噪声和惯性力对于载荷辨识的干扰,用于非平稳信号的载荷辨识具有精度高、可靠性好等特点。

关 键 词: 高超声速; 测力系统; 非平稳信号; 人工智能; 载荷辨识

中图分类号: V221.3

文献标志码: A

Hypersonic wind tunnel aerodynamic identification method considering noise suppression

MA Guilin, LI Shichao, GAO Hongli, WANG Qinchao, WU Guang, DUAN Zhiqin

(College of Astronautics, Southwest Jiaotong University, Chengdu 610031, China)

Abstract: There are still many problems in load identification of non-stationary signals of full-size model test in wind tunnel test. A full scale model test of non-stationary signal load identification was proposed based on a deep residual shrinkage network (DRSN) deep learning technology of intelligent load identification method. This method extracted load system output data of aerodynamic force and inertial force and noise characteristics by deep learning, through attention mechanism it obtained data access threshold for each group, then the soft threshold function was used to filter the characteristics and reduce the noise. The inertial force component in the response signal of the force measurement system was identified and eliminated effectively, so as to realize the identification of aerodynamic load. In the test and verification, the identification accuracy of the mean value method was above 85%, and that of the DRSN model was above 94%, proving that the DRSN model can effectively reduce the interference of noise and inertia force on the load identification. It presented the characteristics of high accuracy and good reliability for the load identification of non-stationary signals.

Keywords: hypersonic; force measuring system; nonstationary signal; artificial intelligence; load identification

高超声速技术是未来航空航天的关键技术之一,高超声速飞行器的发展会进一步提升国家的

综合实力。高超声速飞行器的速度在马赫数 $Ma=5\sim 10$ 内,飞行器气动特性是决定飞行器研

收稿日期: 2021-08-10

基金项目: 国家自然科学基金(52105562, 51775452)

作者简介: 马贵林(1998—),男,硕士生,研究方向为风洞设计与测量技术。E-mail: mgl16@126.com

通信作者: 李世超(1990—),男,助理研究员,博士,研究方向为风洞设计与测量技术。E-mail: lsc13622162338@163.com

引用格式: 马贵林,李世超,高宏力,等.考虑噪声抑制的高超声速风洞气动力识别方法[J].航空动力学报,2023,38(2):420-430. MA Guilin, LI Shichao, GAO Hongli, et al. Hypersonic wind tunnel aerodynamic identification method considering noise suppression[J]. Journal of Aerospace Power, 2023, 38(2): 420-430.

制成败的关键因素之一^[1-4]。目前研究高超声速飞行器气动特性的研究方法包含计算流体力学(CFD)、飞行试验和地面试验。CFD以其高计算能力和完善的求解方法已经满足了大部分气动力载荷的辨识,但仍存在一些问题无法解决,如难以准确模拟高超声速情况下的高温高压、气动热等复杂物理现象^[5-7];飞行试验由于成本高、风险大、获取的有效气动信息较少等缺点,导致其只能成为技术验证试验;地面试验结合了CFD和飞行试验的优点,具有获取的有效气动信息较多、可真实还原飞行环境、可针对不同的飞行模型进行不同的试验等特点,是目前主要的研究手段。地面试验主要以风洞试验为主要研究方法,其中脉冲燃烧风洞是进行高超声速飞行器试验的主要设备之一,具有成本低、口径大等优点^[8]。

风洞试验的主要目的是获取飞行器模型在试验过程中受到的气动力载荷。由于风洞设备的空间尺寸限制,风洞试验往往采用飞行器缩比模型,在该试验条件下试验模型周围的流场稳定,气体总压和测力系统输出信号呈现平稳性,目前主流的载荷辨识方法在该条件下的辨识精度均较高,如图1所示为平稳信号(图中虚线框表示有效试验时间段);采用缩比模型会导致尺寸效应等问题的发生,为了能够获取真实的气动特性,目前逐渐向全尺寸试验模型发展,由于试验模型尺寸较大(长达7~8 m,重达数吨)、刚度相对较小,模型受到激励会产生振动,在模型周围会出现流场不稳定的情况,导致总压信号和测力系统输出信号呈现非平稳性,如图2所示为非平稳信号(图中虚线框表示有效试验时间段)。

目前对于非平稳信号进行载荷辨识仍存在诸多问题,常用的频域法对于非平稳信号无法进行精准辨识、对于非线性系统的求解误差大^[9];时域法受测力系统结构本身的非线性、测量精度等因素影响,导致建立高精度动力学方程较困难,对于气动力载荷的辨识过程较复杂^[4,10-11];现代信号处理方法如小波分解等算法对于非平稳信号的分辨率较低,载荷辨识误差较大;均值法只有在可以准确获得到整数个周期数据时才能得到准确的均值,但是在全尺寸模型试验条件下测力信号较为复杂,难以有效试验时间内截取到整数个周期,在该条件下的均值法辨识精度较差^[12];人工智能算法近几年在机械故障诊断、状态检测和寿命预测等方面应用广泛,该方法具有识别精度高、对于非线性系统抗干扰性强、系统稳定等特点,目




图1 平稳信号

Fig. 1 Stationary signal




图2 非平稳信号

Fig. 2 Nonstationary signal

前逐渐应用于高超声速试验的动态载荷辨识中,对该领域发挥了促进作用^[13-16]。

因此,本文针对全尺寸模型试验条件下的非平稳信号提出一种基于深度残差收缩网络(deep residual shrinkage networks, DRSN)的人工智能载荷辨识方法,使用该方法对测力系统输出信号进行智能化处理,对测力系统的振动特征(由固有模态引起)进行学习识别,降低惯性振动和噪声的干扰,提高了气动力载荷辨识精度,该方法进一步完善了风洞试验的测力技术,提升了风洞试验中全尺寸模型试验的载荷辨识精度,实现了风洞试验载荷辨识的智能化。

1 高超声速测力系统输出信号特性分析

目前脉冲燃烧风洞的有效试验时间为200~300 ms,在风洞启动时流场瞬时建立,模型-测力系统受到充分激励,从而产生瞬态冲击载荷,使得试验模型和测力系统开始振动,由于脉冲燃烧风洞有效试验时间较短,惯性力难以衰减完全,将会持续整个试验时间;风洞启动100 ms后的

100~200 ms 为风洞试验的有效试验时间,在该阶段产生真实气动力载荷,由于试验模型尺寸较大、刚度相对较小,模型周围的流场会出现不稳定的情况,使得总压和模型受到的气动力载荷发生变化,导致气动力信号呈现非平稳特性;同时在风洞试验中受试验仪器和采集仪器本身结构的影响,测力系统输出信号会夹杂着一定的噪声^[17]。

通过上述分析,可以得出全尺寸模型试验的测力系统有效输出信号主要由 3 个部分组成:非平稳的真实气动力载荷分量、不同频率下带衰减项的惯性力分量、噪声分量。有效段输出信号可由以下方程表示:

$$x(t) = F(t) + \sum_{j=1}^n A_j e^{-u_j t} \sin(2\pi f_j t + \varphi_j) + \varepsilon \quad (1)$$

式中 $F(t)$ 表示非平稳的真实气动力载荷分量; $\sum_{j=1}^n A_j e^{-u_j t} \sin(2\pi f_j t + \varphi_j)$ 表示惯性力分量; ε 表示噪声分量; 噪声分量具有幅值小、频率高等特点,可以通过滤波和求平均的手段有效降低其对气动力辨识精度的影响。惯性力分量 $\sum_{j=1}^n A_j e^{-u_j t} \sin(2\pi f_j t + \varphi_j)$ 是由风洞启动过程中,瞬态气流对飞行器模型瞬态冲击导致的瞬态振动引起的,由于高超声速风洞的有效时间短暂,仅有 100 ms 左右,在如此短暂的时间内振动难以衰减完全,因此模型气动力将

被惯性力掩盖,严重影响测试精度。测力系统的振动响应是由其各阶段固有模态(主要为前 10 阶模态)叠加而成,并且在测试系统本身阻尼的作用下逐渐衰减,因此在时域中的表现形式为指数形式振动衰减信号,其衰减特征(指数衰减特性)和振动特征(正余弦周期振动特性)稳定且容易辨识。目前人工智能方法在特征提取学习领域具有精度高、稳定性好等特点,因此,可以通过人工智能算法对惯性力分量特征进行提取学习,从而有效辨识高超声速风洞气动力测试数据中的惯性力信号并剔除,降低惯性力分量对气动力载荷辨识精度的影响,提高气动力测试精度。

2 高超声速测力试验气动力辨识方法

通过上述对测力系统输出信号的分析,本研究提出了一种基于 DRSN 的高超声速风洞试验气动力辨识方法。DRSN 是一种基于人工智能算法的特征学习模型,它具有较好的特征提取能力、降维能力等特点,因此可以有效提取气动力数据中的惯性力信号特征。如图 3 所示为技术流程图。首先进行测力系统输出信号采集和预处理,获取一定量的网络训练数据;其次,对数据进行归一化处理,并且将数据分为训练集、验证集和测试




图 3 基于 DRSN 网络的载荷辨识方法

Fig. 3 Load identification method based on DRSN network

集;随后,搭建训练网络并基于训练集对网络进行训练;最后,利用测试集对训练好的网络模型进行验证,输出气动力辨识结果。最终实现从测力系统输出信号中辨识气动力载荷的目的。

2.1 深度残差收缩网络

动态气动力载荷辨识需要学习测力系统输出信号与气动力载荷之间的关系。在风洞试验中,由于试验设备、采集设备等本身结构的影响,测力系统输出数据中都含有一定的噪声或者无关信号,这会导致深度学习算法的效果降低。对深度残差网络进行改进后得到的 DRSN 能有效改善噪声信号对深度学习效果的影响,同时该网络具有

较强的降维能力和特征提取能力。因此本文提出了使用 DRSN 来实现气动力载荷辨识。

本文提出的 DRSN 模型主要由深度残差网络、软阈值函数和注意力机制 3 个部分组成,如图 4 所示为 DRSN 模型,该模型是在深度残差网络的基础上添加了一个由软阈值函数和注意力机制组成的子网络,子网络用于学习得到一组阈值,进而对各个特征进行软阈值处理,剔除噪声等无效特征。深度残差网络可以有效提取惯性力分量特征和气动力分量特征。通过深度残差网络、软阈值函数和注意力机制 3 个部分对数据进行处理,可以对气动力载荷进行精确辨识。




图 4 DRSN 模型

Fig. 4 DRSN model

2.1.1 深度残差网络

深度残差网络首次提出在 2016 年^[18],其是传统卷积神经网络的一种变化结构,核心变化是添加了跨层的恒等映射,恒等映射可以有效降低网络学习难度,解决了网络退化和梯度消失的问题,进一步降低了网络的误差,提升气动力辨识精度。由于输入数据为一维时序数据,故采用一维卷积神经网络进行发现和挖掘数据中隐藏的特征如周期特征、幅值特征、相位特征等。

卷积层能够有效提取测力系统输出数据中的气动力信号、惯性力信号和噪声等特征,同时卷积层是通过使用卷积来实现运算,大大降低了需要训练的参数数量,避免网络训练过程中出现过拟合问题,使得网络具有较高的精度,卷积层的表达式为

$$Z_{i,j,k} = w_k x_{i,j} + b_k \quad (2)$$

式中 $Z_{i,j,k}$ 表示输出的 (i,j,k) 位置上的特征; $x_{i,j}$ 表示输入信号的 (i,j) 位置上的特征, w_k 表示第 k 个卷积

核的权重和阈值, b_k 表示第 k 个卷积核的偏差。

激活函数是卷积网络的重要组成部分,用于非线性变换,主要包括 sigmoid、tanh 和 ReLU(rectified linear unit)等。本文采用 ReLU 激活函数,该激活函数可以有效防止梯度消失、加快训练速度。ReLU 激活函数的导数为 0 或 1,这有助于特征在网络层间移动时范围保持不变。ReLU 激活函数(量符号记为 $R_{\text{eLU}}(\cdot)$)的表示如下:

$$a_{i,j,k} = R_{\text{eLU}}(Z_{i,j,k}) \quad (3)$$

式中 $a_{i,j,k}$ 、 $Z_{i,j,k}$ 表示激活函数输出和输入。

批标准化层(batch normalization, BN)是一种特征标准化技术,在训练中特征的分布通常在训练迭代中不断变化,在这种情况下,卷积层中的参数必须不断更新变化以适应变化的分布,这就增加了网络训练的难度。因此,需要将数据特征进行标准化处理到 0~1 之间的范围,然后将特征调整为理想分布。BN 层的工作过程如下:

计算上一层输出的平均值 μ_β

$$\mu_\beta = \frac{1}{m} \sum_{i=1}^m x_i \quad (4)$$

计算上一层输出的方差 σ_β^2

$$\sigma_\beta^2 = \frac{1}{m} \sum_{i=1}^m (x_i - \mu_\beta)^2 \quad (5)$$

标准化

$$\hat{x}_i = \frac{x_i + \mu_\beta}{\sqrt{\sigma_\beta^2 + \tau}} \quad (6)$$

重构

$$z_i = \gamma \hat{x}_i + \beta \quad (7)$$

式中 m 表示需要标准化的样本数; x_i 表示卷积层输出的第 i 个特征; τ 为一个很小的数, 用来防止分母变为零; β 和 γ 为需要训练的超参数。

本文构建的深度残差网络包含一个卷积层、一个残差模块、一个 BN 层、一个 ReLU 激活函数、一个全局平均池化(global average pooling, GAP)、一个全连接层。如图 5 所示为深度残差网络模型。




图 5 深度残差网络模型

Fig. 5 Deep residual network model

2.1.2 注意力机制

为了提高卷积神经网络的特征表达能力, 注意力机制模型被提出, 主要包括 CBMA(convolutional block attention module)、SENet(squeeze-and-excitation networks) 和 GCNet(global context network) 等。目前, 注意力机制被广泛应用于自然语言处理、图像识别、序列学习等不同类型的深度学习任务中, 是深度学习中的重要技术之一。

本文的注意力机制选择 SENet 注意力算法, 该模型是 ImageNet 2017 竞赛分类任务的冠军模型, 具有拓展性好、轻量化等特点, 可以嵌入当前大多数的深度学习网络^[19]。SENet 算法主要分为压缩(squeeze)和激发(excitation)两个步骤, 通过压缩和激发过程可以更有效注意有效特征信息

1) 压缩

为了解决通道关联性的问题, 需要将全局空间信息进行压缩, 本次是使用全局平均池化层得到提取的气动力、惯性力和噪声等特征的压缩特征量; 形式上通过将输入特征 U 进行压缩生成压缩特征 z , z 的第 c 个元素可以表示为

$$z_c = F_{sq}(U_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W U_c(i, j) \quad (8)$$

2) 激发

为了能够使用压缩后的特征信息, 需要得到通道特征间的关联关系。为了实现这一目的, 该部分功能需要满足两个要求: ①能够获取通道间的非线性关系; ②具有不互相排斥的能力。为了满足以上要求, 本次选择 sigmoid 激活函数

$$s = F_{ex}(z, W) = \sigma(g(z, W)) = \sigma(W_2 \delta(W_1 z)) \quad (9)$$

式中 $\delta(\cdot)$ 、 $\sigma(\cdot)$ 表示激活函数, $W_1 \in \mathbf{R}^{r \times c}$ 、 $W_2 \in \mathbf{R}^{c \times r}$ 。

为了简化模型, 本次使用两个全连接层来实现参数优化。激发模块的最终输出通过使用激活函数 s 重新缩放输入特征 U 来进行获得

$$x_c = F_{scale}(U_c, s_c) = s_c \times U_c \quad (10)$$

最后再与之前得到的全局压缩特征量进行相乘, 作为阈值输入下一层网络。

本文 SENet 算法的主要作用是对每一组训练样本进行分析获取一组阈值, 再将这组阈值与压缩后的气动力、惯性力和噪声等特征进行相乘, 进而调整各部分的特征大小, 即施加不同的注意力在各个特征上。如图 6 所示为 SENet 算法模型, 如图 7 为 SENet 算法工作流程, 图中特征 U 的维度为 $C \times W \times H$ 。




图6 SENet 模型

Fig. 6 SENet model




图7 SENet 模型工作流程

Fig. 7 SENet model workflow

2.1.3 软阈值函数

对于降噪滤波的处理, 本文选择软阈值函数, 其是由斯坦福大学教授 Donoho 提出, 是目前许多降噪滤波方法的核心步骤^[20]。

由于输入数据为一维时序数据, 所示本文使用一维时序软阈值函数如下:

$$F(\sigma) = \begin{cases} \sigma - \gamma & \sigma \geq \gamma \\ 0 & |\sigma| \leq \gamma \\ \sigma + \gamma & \sigma \leq -\gamma \end{cases} \quad (11)$$

式中 $F(\sigma)$ 为输出, σ 为输入, γ 为阈值。由上式可以看出软阈值函数是将在 $-\gamma \sim \gamma$ 阈值范围内的值进行置零处理, 其余值进行收缩处理。由于噪声幅值较小, 惯性力和气动力幅值较大, 本文软阈值函数的主要作用是当噪声 ε 小于阈值时进行剔除, 保留气动力和惯性力等有效特征。如图 8 所示为软阈值函数。

软阈值函数导数可以表示如下:

$$\frac{\partial F(\sigma)}{\partial \sigma} = \begin{cases} 1 & \sigma \geq \gamma \\ 0 & |\sigma| \leq \gamma \\ 1 & \sigma \leq -\gamma \end{cases} \quad (12)$$

由式(12)可以看出软阈值函数的导数值为 1 或 0, 这一特点可以有效减小深度学习过程中的梯度消失和梯度爆炸的问题。如图 9 所示为软阈值函数导数。如图 10 所示为软阈值函数的工作流程。




图8 软阈值函数

Fig. 8 Soft threshold function




图9 软阈值函数导数

Fig. 9 Soft threshold function derivative




图10 软阈值函数工作流程

Fig. 10 Soft threshold function workflow

2.2 网络参数

在网络训练过程中, 本文选择均方误差(MSE)损耗来优化网络参数和偏差, 优化器选择 Adam

来实现目标损失函数最小化。为了避免出现过拟合问题,采用小批量梯度下降和提前停止,其中小批量的大小为 16;而提前停止实际上是一种学习率自适应调整策略,学习率初始值为 0.05,随后的学习率随着验证集的丢失而变化,如果验证损失在 100 代后下降不超过 0.000 1,则训练提前结束。表 1 总结了用于训练 DRSN 的参数。

表 1 DRSN 参数
Table 1 DRSN parameters

参数	数值及说明
网络结构	DRSN
优化器	Adam
误差损失	MSE
初始学习率	0.05
最小批量	16
最大训练次数	500

2.3 性能评估

为了能够定量对本研究所提方法的有效性和准确性进行评估,本次引入 3 个评估指标,包括平均绝对误差(MAE,量符号记为 M_{ae})、预测结果相对误差(η)和预测精度(ω)。

$$\begin{cases} M_{ae} = \frac{1}{n} \sum_{i=1}^n |(y' - y)| \\ \eta = \frac{y' - y}{y} \times 100\% \\ \omega = 1 - \eta \end{cases} \quad (13)$$

式中 y' 表示预测值, y 表示实际值, n 表示样本数量。

3 试 验

3.1 试验装置

目前,在高超声速风洞中主要的气动力测试技术包括盒式天平、杆式天平和悬挂测力系统,由于盒式天平和杆式天平这两类设备安装在飞行器试验模型内部,占用了注油块、推进系统等功能部件的安装空间,导致试验模型的设计难度剧增。为此,本团队设计研发了一种悬挂测力系统,其核心思想是将原本安装在模型内部的测力传感器置于模型外,并与模型支撑系统融合为一体,有效克服了传统测力装置占用模型内部空间的缺陷,并且具有支撑刚度大、对流场干扰小的优点,对于全尺度模型试验具有较大的优势。目前该装置已成功应用于中国空气动力研究与发展中心的 $\phi 2.4$ m脉冲燃烧风洞,如图 11 所示悬挂测力系统。因此,本研究设计并搭建了悬挂测力试验台,其

结构及原理如图 12 所示,用于验证本文所提出的基于 DRSN 的全尺寸试验模型气动力载荷辨识方法的合理性。






图 11 悬挂测力系统

Fig. 11 Suspension force measuring system



(a) 悬挂测力系统结构



(b) 测试原理简图

图 12 悬挂测力系统结构及原理

Fig. 12 Structure and principle of suspension force measuring system

该试验台主要包含试验模型、悬挂测力装置、拉杆、S 传感器、轮辐应变传感器等,如图 13 所示为悬挂测力试验台装置。该悬挂测力装置通过拉杆与试验模型的连接位置和角度不同,可以实现试验模型在任意角度的安装,模拟飞行器实际

飞行过程中的任意飞行姿态。拉杆将试验模型所受到的气动力进行分解并传递至轮辐式传感器,该悬挂测力装置在 x 方向布置 2 个轮辐传感器, y

方向布置 4 个轮辐传感器, z 方向布置 3 个轮辐传感器,用来进行六分量测量。本文主要使用 3 个传感器(x 、 y 、 z 方向各一个)进行采集。




图 13 悬挂测力试验台装置

Fig. 13 Suspension force measuring system test bench

3.2 试验方法

为了实现多分量阶跃载荷的加载(模拟飞行器的真实气动力状态),获取试验训练样本,本文采用西门子采集仪和 LMS Test.Lab 软件进行多分量动态响应信号的采集。对于阶跃力的加载,本文选择将加载点固定在试验模型右上角表面,加载点通过钢丝和固定滑轮连接 S 型力传感器,再连接砝码盘,通过添加不同重量的砝码来实现不同的阶跃载荷,利用力分解的原理实现对试验模型六分量阶跃加载,如图 14 所示为力分解示意图,图中 F 表示加载力, F_x 、 F_y 和 F_z 表示分解力, M_x 、 M_y 和 M_z 表示分解扭矩。




图 14 力分解示意图

Fig. 14 Schematic diagram of force decomposition

试验过程为

- 1) 首先在空载情况下进行采集基准数据。
- 2) 对 S 型力传感器、轮辐传感器进行标定试验。
- 3) 对采集软件、仪器进行设置,采样频率为 10 240 Hz,带宽为 5 120 Hz,采样时间为 7 s,电压为 18.1 V。

4) 通过加载结构(砝码-砝码盘-S 型力传感器-钢丝-加载点)进行阶跃载荷加载,通过轮辐应变传感器进行实时记录测力系统 x 、 y 、 z 方向的测力系统输出信号。

5) 对数据进行预处理。

3.3 试验结果

3.3.1 DRSN 试验结果

本文以采集得到的测力系统 y 方向输出信号为例阐述方法验证分析的过程。本文试验共采集 126 组输出信号,首先对输出信号进行预处理,通过降采样处理提取有效段信号 2 000 个点作为训练样本,阶跃衰减完后稳定段主要成分为零频率的直流分量(真实气动力载荷),取稳定段 5 000 个点的均值(即真实气动力载荷)作为训练标签,以此建立测力系统输出信号与气动力载荷之间的关系,训练样本提取过程如图 15 所示。将 126 组数据进行划分,90% 的数据(114 组)分为训练集,10% 的数据(12 组)分为测试集,训练集中的 10% 作为验证集。

图 16 和图 17 显示了 DRSN 模型的训练结果,训练损失和训练误差如图 16(a)和图 16(b)所示,可以看出在训练过程中验证损失和验证误差最低分别为 0.256 4 和 0.341 3;测试集辨识结果如图 17(a)所示,在 12 组测试集数据中预测值与实际值的差值最大为 0.310 1,最小为 0.010 8;测试集辨识精度如图 17(b)所示,辨识精度最高为 99.746%,辨识精度最低为 95.563%。由上述结果




图 15 样本提取过程

Fig. 15 Sample extraction process




图 16 训练过程

Fig. 16 Training process




图 17 训练结果

Fig. 17 Training results

可以看出,本文方法在非平稳信号的载荷辨识中可以有效剔除噪声等无效信号,降低惯性力对载荷辨识的干扰,提高了气动力辨识精度。

3.3.2 均值法试验结果

对于风洞试验载荷辨识,均值法是当前最为常用的工程分析方法,主要原理是对测力系统输出信号进行滤波降噪后,对整个信号进行均值求解,该均值即为真实气动力载荷。对于本文研究

的全尺寸试验模型条件下的非平稳信号,均值法辨识结果如图 18(a)所示,在 12 组测试集中预测值与实际值的差值最大为 1.372 5,最小为 0.453 4;辨识精度如图 18(b)所示,辨识精度最高为 87.492%,最低为 82.226%。由上述分析可知,由于均值法求解的均值是一个常数,而非平稳信号的均值是非常数且会随时间发生变化,导致均值法的载荷辨识精度较低。




图 18 预测结果
Fig. 18 Prediction results

3.3.3 试验结果对比

表 2 为 DRSN 模型与均值法的试验结果对比, 从对比结果可以看出, 对于全尺寸试验模型条件下的非平稳信号, 本研究提出的基于 DRSN 的人工智能载荷辨识方法的精度优于均值法, 能够有效降低噪声和惯性力对载荷辨识的干扰。由于非平稳信号的均值、方差、协方差等会发生变化, 均值法不能有效识别变化的均值, 导致载荷辨识精度较低, 该方法较适用于缩比试验模型情况下的平稳信号载荷辨识。

表 2 试验结果对比
Table 2 Comparison of test results

组别序号	载荷识别精度/%	
	DRSN 法	均值法
1	97.486	85.170
2	95.563	87.029
3	98.922	85.105
4	99.813	84.127
5	99.746	82.226
6	96.910	85.263
7	98.897	87.492
8	98.214	85.600
9	94.715	83.827
10	96.413	83.690
11	98.673	86.260
12	99.512	85.830

4 结 论

1) 本文针对全尺寸试验模型条件下的测力系统输出信号为非平稳信号的情况, 提出了一种基于 DRSN 的智能载荷辨识方法, 弥补了传统的

滤波均值法对非平稳信号条件下的载荷辨识精度较低的缺陷。对网络进行了网络层和学习参数的设计, 通过分析验证了该方法的合理性和有效性。

2) 首先利用悬挂测力系统进行试验, 采集了训练数据, 其次构建网络模型并进行训练学习, 最后通过测试集进行载荷辨识验证, 得到了该方法的辨识结果和辨识精度。

3) 对比了传统均值法和 DRSN 的试验结果, 结果显示均值法的辨识精度最高为 87.492%, DRSN 的辨识精度最低为 94.715%, 证明了 DRSN 的辨识性能较好, 在全尺度试验模型条件下具有较高的载荷辨识精度。载荷辨识技术的智能化有助于我国开展高超声速飞行器的研制工作, 具有重要的实践意义。

致谢:

感谢西南交通大学机械工程学院于耀翔博士、由智超博士以及中国空气动力研究与发展中心张小庆副研究员、吕金洲博士对于本论文撰写、试验的帮助。

参考文献:

[1] 唐志共, 许晓斌, 杨彦广, 等. 高超声速风洞气动力试验技术进展[J]. 航空学报, 2015, 36(1): 86-97.
TANG Zhigong, XU Xiaobin, YANG Yanguang, et al. Progress in aerodynamic test technology of hypersonic wind tunnel[J]. Acta Aeronautica et Astronautica Sinica, 2015, 36(1): 86-97. (in Chinese)

[2] 田建明, 景建斌, 韩广岐. 高超声速飞行器地面试验方法[J]. 探测与控制学报, 2013, 35(5): 57-60.
TIAN Jianming, JING Jianbin, HAN Guangqi. Ground test method of hypersonic vehicle[J]. Journal of Detection and Control, 2013, 35(5): 57-60. (in Chinese)

[3] LI S, LI K, LIU B, et al. A new dynamic modelling methodology of a force measuring system for hypersonic impulse wind tunnel[J].

- Measurement, 2020, 164(11): 108012.1-108012.15.
- [4] 李世超, 高宏力, 刘勃锴, 等. 脉冲燃烧风洞测力系统传力特性研究[J]. 振动与冲击, 2018, 37(21): 117-125, 142.
- LI Shichao, GAO Hongli, LIU Bokai, et al. Force transmission characteristics of force-measuring system in impulse combustion wind tunnel[J]. Journal of Vibration and Shock, 2018, 37(21): 117-125, 142. (in Chinese)
- [5] 吕金洲, 张小庆, 赵晓男, 等. 脉冲风洞测力系统结构动力学特性[J]. 西南交通大学学报, 2019, 54(6): 1305-1313.
- LÜ Jinzhou, ZHANG Xiaoqing, ZHAO Xiaonan, et al. Structural dynamic characteristics of force measurement system in pulse wind tunnel[J]. Journal of Southwest Jiaotong University, 2019, 54(6): 1305-1313. (in Chinese)
- [6] 张小庆, 乐嘉陵. 脉冲式燃烧风洞起动特性数值研究[J]. 航空动力学报, 2008, 23(9): 1568-1572.
- ZHANG Xiaoqing, LE Jialing. Numerical study on starting characteristics of pulse combustion wind tunnel[J]. Journal of Aerospace Power, 2008, 23(9): 1568-1572. (in Chinese)
- [7] 张小庆, 吕金洲, 刘伟雄, 等. 脉冲风洞一体化飞行器测力精度分析[J]. 航空动力学报, 2018, 33(12): 115-120.
- ZHANG Xiaoqing, LU Jinzhou, LIU Weixiong, et al. Force measurement accuracy analysis of pulse wind tunnel integrated aircraft[J]. Journal of Aerospace Power, 2018, 33(12): 115-120. (in Chinese)
- [8] 刘勃锴, 高宏力, 吴颖川, 等. 脉冲燃烧风洞新型悬挂式测力系统[J]. 浙江大学学报(自然科学版), 2018, 52(4): 619-627.
- LIU Bokai, GAO Hongli, WU Yingchuan, et al. A new type of suspended force measurement system for pulse combustion wind tunnel[J]. Journal of Zhejiang University (Natural Science Edition), 2018, 52(4): 619-627. (in Chinese)
- [9] 吕成涛. 基于频响函数拟合的机械结构动载荷识别[D]. 沈阳: 东北大学, 2019.
- LÜ Chengtao. Dynamic load identification of mechanical structure based on frequency response function fitting[D]. Shenyang: Northeastern University, 2019. (in Chinese)
- [10] 唐秀近. 动态力识别的时域方法[J]. 大连工学院学报, 1987(4): 21-28.
- TANG Xiujin. Time-domain method for dynamic force recognition[J]. Journal of Dalian Institute of Technology, 1987(4): 21-28. (in Chinese)
- [11] 周盼, 张权, 率志君, 等. 动载荷识别时域方法的研究现状与发展趋势[J]. 噪声与振动控制, 2014, 34(1): 6-11.
- ZHOU Pan, ZHANG Quan, LI Zhijun, et al. Research status and development trend of time-domain methods for dynamic load identification[J]. Noise and Vibration Control, 2014, 34(1): 6-11. (in Chinese)
- [12] 徐志英, 廖旭晖. 动态载荷识别及其进展[J]. 常州工学院学报, 2006, 19(4): 13-18.
- XU Zhiying, LIAO Xuhui. Dynamic load identification and its progress[J]. Journal of Changzhou Institute of Technology, 2006, 19(4): 13-18. (in Chinese)
- [13] ZHOU J M, DONG L, GUAN W, et al. Impact load identification of nonlinear structures using deep recurrent neural network[J]. Mechanical Systems and Signal Processing, 2019, 133: 106292.1-106292.14.
- [14] 王琿玮. 基于神经网络的飞行器力载荷识别算法研究[D]. 杭州: 浙江大学, 2018.
- WANG Hunwei. Research on recognition algorithm of aircraft force and load based on neural network[D]. Hangzhou: Zhejiang University, 2018. (in Chinese)
- [15] 张方, 朱德懋. 基于神经网络模型的动载荷识别[J]. 振动工程学报, 1997, 10(2): 156-162.
- ZHANG Fang, ZHU Demao. Dynamic load identification based on neural network model[J]. Journal of Vibration Engineering, 1997, 10(2): 156-162. (in Chinese)
- [16] 汪运鹏, 杨瑞鑫, 聂少军, 等. 基于深度学习技术的激波风洞智能测力系统研究[J]. 力学学报, 2020, 52(5): 1304-1313.
- WANG Yunpeng, YANG Ruixin, NIE Shaojun, et al. Research on shock wave wind tunnel intelligent force measurement system based on deep learning technology[J]. Chinese Journal of Theoretical and Applied Mechanics, 2020, 52(5): 1304-1313. (in Chinese)
- [17] LUO C, WANG Y, WANG C, et al. Wave system fitting: a new method for force measurements in shock tunnels with long test duration[J]. Mechanical Systems and Signal Processing, 2015, 62/63: 296-304.
- [18] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[R]. Las Vegas, NV, US: IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016.
- [19] JIE H, LI S, GANG S, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(8): 2011-2023.
- [20] DONOHO D L. De-noising by soft-thresholding[J]. IEEE Transactions on Information Theory, 2002, 41(3): 613-627.

(编辑: 王碧琚)