

激波风洞测力信号的频域数据深度学习建模分析方法

聂少军^{1,2}, 汪运鹏^{1,2}, 王春^{1,2}, 姜宗林^{1,2}

(1. 中国科学院力学研究所 高温气体动力学国家重点实验室 北京 100190;
2. 中国科学院大学 工程科学学院 北京 100049)

摘要: 高精度气动力测量是激波风洞试验中的关键技术。在开展测力试验时,测力系统在风洞流场起动瞬间的冲击激励下产生振动,但振动信号无法在较短的有效试验时间内快速衰减,导致天平输出信号中耦合了惯性干扰。基于深度学习技术,对激波风洞天平信号在频域内开展数据处理,并针对动态信号的频域特征进行卷积神经网络建模分析,旨在消除测力信号中的惯性干扰。在频域模型训练样本和验证样本的结果分析中,天平信号的大幅惯性振动干扰被消除,达到预期的结果,验证频域建模分析方法的有效性和可靠性。此外,对处理结果进行误差分析,进一步验证该方法在激波风洞天平数据处理中具有较好的工程应用价值。

关键词: 激波风洞; 气动力测量; 惯性振动; 深度学习; 频域分析

中图分类号: V211.751

文献标志码: A

DOI: 10.13465/j.cnki.jvs.2023.13.035

Deep learning modeling analysis method of frequency-domain data of shock wind tunnel force measurement signals

NIE Shaojun^{1,2}, WANG Yunpeng^{1,2}, WANG Chun^{1,2}, JIANG Zonglin^{1,2}

(1. State Key Lab of High Temperature Gas Dynamics, Institute of Mechanics,
Chinese Academy of Sciences, Beijing 100190, China;

2. School of Engineering Sciences, University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: High accuracy aerodynamic measurement is key technology in shock wind tunnel tests. During force-measuring tests, a force-measuring system vibrates under impact excitation at the moment to start wind tunnel flow field, this vibration signal can't rapidly decay in shorter effective test time to cause coupling of inertial interference in output signal of shock wind tunnel balance. Here, based on deep learning technology, data processing was performed for shock wind tunnel balance signals in frequency domain, and the convolution neural network modeling analysis was performed for frequency domain characteristics of dynamic sample signals to eliminate inertial interference in force measurement signals. In results analysis of frequency domain model training samples and validation samples, large amplitude inertial vibration interference of balance signals was eliminated to obtain the expected results, and verify the effectiveness and reliability of frequency domain modeling analysis method. In addition, the error analysis for the processed results further verified that the proposed method has larger engineering application value in data processing of shock wind tunnel balance.

Key words: shock wind tunnel; aerodynamic force measurement; inertial vibration; deep learning; frequency-domain analysis

在新型高超声速飞行器的研制过程中,需要对飞行器模型进行高焓激波风洞试验检验其气动性能,降低研制的风险和成本^[1]。作为风洞试验中最基本、最重要的试验项目之一,测力试验是获取飞行器气动力数据的重要手段,其测量精准度将直接影响飞行器的

气动力特性评估,通常采用激波风洞天平测量模型的气动力^[2]。

目前,在毫秒级激波风洞中准确测量模型的气动力仍存在诸多关键性的技术问题,其中,测力系统(包括测力模型、风洞天平以及支撑结构)的惯性振动是主要问题来源^[3]。在激波风洞中开展测力试验时,风洞流场起动时的脉冲冲击作用引起测力系统产生惯性振动,天平信号中叠加了系统惯性振动信号,导致无法直接准确分辨出真实气动力信号的动态特征^[4-5]。随着

基金项目: 国家自然科学基金项目(11672357; 11727901)

收稿日期: 2022-04-27 修改稿收到日期: 2022-08-08

第一作者 聂少军 男, 博士生, 1999年生

通信作者 汪运鹏 男, 博士, 正高级工程师, 1978年生

工程部门对气动力测量结果的精准度要求逐渐提高,研究消除惯性振动干扰的方法,提供可靠的气动力数据,发展高精度的测力技术,对我国高超飞行器的研发具有十分重要的意义。

为消除天平输出信号中的惯性振动干扰,国内外许多测力和天平专家进行了相关研究,在改善天平结构和处理天平瞬态信号的基础上提出了多种天平技术。目前,主要有三类改善测力的技术:①通过增加天平的刚度或改善天平的结构提升测力系统的固有频率,天平在有效试验时间内出现更多完整的周期信号,如压电天平^[6-8]、应力波天平^[9-12]和脉冲型应变天平^[13-15]等技术;但上述技术因稳定性不高、结构复杂等仍无法摆脱系统惯性振动的干扰。②通过信号补偿消除惯性振动对气动力的影响,包括加速度计天平^[16-18]和惯性自补偿型技术^[19-22]等;当系统的振动频率和气动力频率较接近时,惯性自补偿技术无法准确识别出振动信号,可能带来更大的误差,导致测力结果无法使用。③从天平信号的处理角度出发,汪运鹏等^[23-24]将深度学习应用于脉冲型风洞测力系统中,提出了一种新的单矢量动态自校准技术(single-vector dynamic self-calibration, SVDC),针对时域内的样本信号,采用卷积神经网络(convolutional neural network, CNN)和循环神经网络(recurrent neural network, RNN)模型进行智能化处理,有效识别出惯性振动信号的动态特征,得到比较理想的气动力结果^[23-24]。综上所述,通过改善天平结构或信号补偿的方法提升测量精准度已非常困难,而人工智能技术在传统风洞测试领域的深度交叉应用成为趋势,将对风洞测试技术,尤其是激波风洞测力技术的性能大幅提升,具有重大工程意义。

由于天平输出信号中系统的惯性振动与气动力在频域中存在较大差别,其中惯性振动频率属于系统的固有属性,当测力系统的质量和结构等参数确定时,其惯性振动频率也随之确定,在风洞运行时间内保持稳定不变。而气动力信号会受到风洞流场参数等因素的影响,其频率随时间而变化。频率信号能够从本质上更准确的反映测力系统结构的惯性振动特征。

因此,本文针对复现高超声速飞行条件激波风洞(简称“JF-12 复现风洞”)的测力系统,采集天平阶跃载荷的时域信号样本,通过时频转换方法将其变换到频域信号,基于 CNN 开展样本振动特征训练,利用得到的频域模型对测力试验中天平输出信号智能处理,着重对天平信号在频域范围内开展深入分析,以期获得可靠的“准定常”气动力信号。

1 天平时域信号的采集与时频转换

JF-12 复现风洞可复现 25 ~ 50 km 高空马赫数 5 ~

9 的飞行条件,有效运行时间可以达到 130 ms^[25-26]。JF-12 复现风洞设备^[27],如图 1 所示。



图 1 JF-12 复现风洞(图片来源:参考文献[27])
Fig.1 JF-12 shock tunnel (Source: reference [27])

JF-12 复现风洞中针对尖锥标准测力模型开展的气动力测量试验,如图 2 所示。其中图 2(a)模型-天平-支撑测力系统,图 2(b)为对应的三分量杆式应变天平。本文将针对该测力系统,开展天平信号频域数据人工智能建模的研究。其中的一个关键步骤是针对原风洞测力系统开展施加阶跃载荷的天平输出样本数据采集,并进行时频转换分析。



(a) 模型-天平-支撑测力系统



(b) 三分量杆式应变天平

图 2 尖锥标准模型测力试验

Fig.2 Force measurement of cone model

1.1 天平时域信号样本的采集

由于激波风洞测力试验中天平的输出信号较复杂,考虑到激波风洞运行成本等因素,在风洞外搭建与风洞内测力试验时相同的测力系统。其中尖锥标准测力模型的半锥角为 10°,长度为 750 mm;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 ; 尾部采用弯刀支撑结构, 如图 3 所示。



图 3 天平信号样本采集装置

Fig. 3 Balance signal sample acquisition device

传统的标准动态信号发生的方法主要有脉冲响应法^[28-29]和阶跃响应法^[30-33]。脉冲响应法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。而汪运鹏等提出的 SVDC 法引入深度学习技术, 可针对天平测力动态数据进行建模处理, 以对耦合了惯性振动干扰的气动力进行精确辨识。

与传统的脉冲响应法和阶跃响应法不同, 新的 SVDC 法通过将钢丝与测力系统悬挂点连接以施加任意方向的单矢量载荷, 该单矢量载荷可以自动根据天平坐标系分解成多分量载荷, 其载荷大小可由测力天平直接读取并实时输出, 待天平输出信号稳定时, 瞬间剪断钢丝生成阶跃载荷。基于 SVDC 法的阶跃载荷采集装置设备较简单, 在一定程度上, 单矢量载荷的大小、方向和作用点不受限制, 仅需在测力系统迎风面尖端处悬挂钢丝, 待稳定后剪断钢丝, 从而生成阶跃载荷, 具有便捷性。同时, 由于测力系统的质量和结构直接影响其振动特性, 因此 SVDC 法不再针对单一天平进行动态校准, 而是针对整个测力系统进行动态校准, 基于 SVDC 后的测力系统更符合实际的风洞测力试验。本研究基于 SVDC 技术对整个测力系统进行动态校准。

在搭建完成天平信号样本采集装置后, 基于 SVDC 技术采集适量的时域信号样本, 包括法向力 Y 、俯仰力矩 M_z 和轴向力 X 三个分量的动态载荷样本。实际风洞试验时模型的轴向力较大, 且振动频率较高, 噪声干扰较小。为充分保证天平信号样本与风洞试验测力信号的一致性, 重点分析轴向力信号。采集的任意一个天平轴向力阶跃信号样本, 包括天平阶跃信号和理想阶跃信号两组数据, 在神经网络模型训练中分别对应输入和理想输出数据, 如图 4 所示。

图 4 中虚线为天平阶跃信号, 用于模拟风洞测力试验时测力系统受到流场冲击产生的响应信号, 实线

代表理想阶跃信号, 用于模拟简化后的“准定常”气动力信号。信号的总时间为 150 ms, 以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 55 ms 时, 信号产生跳变; 在后续时间内, 天平阶跃信号含有惯性振动, 理想阶跃信号不含惯性振动, 保持稳定不变。




图 4 天平时域信号样本(轴向力)

Fig. 4 Balance signal sample in time-domain (axial force)

1.2 天平信号样本的时频转换

测力试验中天平的输出信号为时域波形信号, 其直观反映出气动力随时间的变化趋势。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分辨出信号中的振动干扰分量。

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。其变换公式分别是

$$F(\omega) = [f(t)] = \int_{-\infty}^{+\infty} f(t) e^{-i\omega t} dt \quad (1)$$

$$f(t) = F^{-1}[F(\omega)] = \frac{1}{2\pi} \int_{-\infty}^{+\infty} F(\omega) e^{i\omega t} d\omega \quad (2)$$

式(1)和式(2)分别为傅里叶变换和傅里叶逆变换; $F(\omega)$ 为 $f(t)$ 的象函数; $f(t)$ 为 $F(\omega)$ 的象原函数。信号的分辨率在时域和频域之间有一种相反的关系, 时域内的脉宽与频域内的带宽乘积是常数, 即信号在时域脉冲越窄, 则其频谱主带越宽。

对图 4 中的时域信号进行快速傅里叶变换 (fast Fourier transform, FFT) 将其转换成频域内的频谱图, 如图 5 所示。从图 5 可知, 天平阶跃信号的主要频率约为 380 Hz, 而理想阶跃信号无该频率, 说明测力系统的惯性振动频率约为 380 Hz。

采用快速傅里叶逆变换 (inverse fast Fourier transform, IFFT) 将频域内的信号转换到时域内, 采用 FFT 和 IFFT 在一定程度上可能造成频谱损失, 将原始天平信号与经过 IFFT 处理后的信号进行对比, 如图 6 所示。从图 6 可知, 信号图显示了经过 FFT 和 IFFT 后的数据与原始数据基本完全重合, 说明两者之间的误差完全可以忽略不计, 为下一步频域内数据处理的可

行性和可靠性提供了理论基础支撑。




图 5 天平信号样本的频谱图

Fig. 5 Spectrum diagram of balance signal sample




图 6 样本经过 IFFT 处理后的效果验证

Fig. 6 Effect verification of sample with IFFT processing

2 CNN 频域模型的训练与结果处理

2.2 CNN 频域模型的构建

随着人工智能技术的快速发展,深度学习在提取特征和建模上逐渐展现出其独特的优势。相对于传统的机器学习,深度学习能从较少的原始样本数据中充分挖掘越来越抽象的特征表示,而且这些特征表示具有良好的泛化能力,有效克服了机器学习中特征提取等难以解决的问题。CNN 包含卷积计算且具有深度结构,是深度学习中一种经典的结构,因其局部连接、权值共享及池化操作等特性大大降低了网络的复杂度,减少了网络训练参数的数目,在图像识别、语音识别和数据拟合等领域获得广泛的应用^[34]。

CNN 频域模型包含输入层、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^[35]。在训练过程中,CNN 模型通过最小化损失函数达到收敛状态,其具体训练流程如图 7 所示。

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。在无量纲化处理中,首先确定样本实部和虚部中绝对值最大的数据,将该数据作为特征数据,然后根据式(3)将

所有数据映射到 $[-1, 1]$ 之间,式中 x 和 x^* 分别表示无量纲化前后的数据。

$$x^* = \frac{x}{\max(|x|)} \quad (3)$$

当训练结束时,再采用式(4)中的逆变换将标准数据还原到原始区间内。

$$x = \max(|x|) x^* \quad (4)$$

因此,本研究首先在频域内训练 CNN 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测力试验中,获得预期的气动力信号。

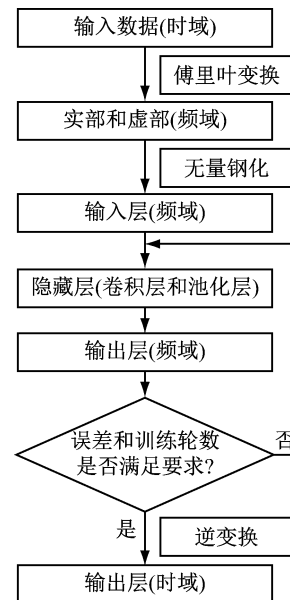


图 7 CNN 频域模型训练流程图

Fig. 7 CNN intelligent model training flow chart

2.3 CNN 频域模型的参数优化

在深度学习中,常用训练的精准度和训练时间来衡量网络模型的质量。目前,主要通过调节 CNN 模型的训练参数和结构参数提升模型质量。训练参数一般是训练过程的具体参数,包括训练轮数和学习率等参数;结构参数主要是网络结构隐藏层中的一些参数,如卷积层数、卷积核的数量和尺寸等。为了优化模型参数,首先确定训练参数,然后通过逐步改变结构参数优化模型,最后再进一步调整训练参数以优化训练模型^[36]。

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。考虑到与激波风洞测力试验相对应,对训练结果截取 70 ~ 110 ms 的时间段进行相对误差和相对标准偏差分析,以验证训练结果的精准度指标。以理想阶跃信号的平均值为真实值 \bar{F} ,CNN 模型处理后的输出信号的平均值为近似值 \bar{F}^* ,相对误差 δ (relative error) 和相对标准偏差 (relative standard deviation, RSD) 的定义式分

别为

$$\delta = \frac{\bar{F}^* - \bar{F}}{\bar{F}} \times 100\% \quad (5)$$

$$\text{RSD} = \frac{1}{\bar{F}^*} \sqrt{\frac{1}{n-1} \sum_{i=1}^n (F_i^* - \bar{F}^*)^2} \times 100\% \quad (6)$$

式中: n 为指定时间段内的数据采集点数; F_i^* 为指定时间内第 i 点时的输出近似值。

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。保证其余参数相同,计算不同卷积层数时训练结果的相对误差 δ 和 RSD,变层数误差量对比结果在表 1 中给出。

表 1 不同卷积层层数的 CNN 模型的结果对比

Tab. 1 Results of CNN model with different convolution layers

卷积层 层数	真实轴向力 \bar{F}/N	近似轴向力 \bar{F}^*/N	相对误差 $\delta/\%$	相对标准偏 差 RSD/ $\%$
24	2.549	2.547	-0.08	0.94
64	2.549	2.506	-1.69	0.39
96	2.549	2.495	-2.12	0.29

由表 1 可知,当卷积层数分别为 24、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、RSD 以及训练时间,选取卷积层数为 64。

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,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。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,如表 2 所示。表 2 呈现了训练轮数分别为 10 000、50 000 和 100 000 时的模型训练样本处理结果,当训练轮数增加时,其相对误差逐渐增加,而 RSD 逐渐降低。因此,综合考虑最终选取训练轮数为 100 000。

表 2 不同训练轮数的 CNN 模型的结果对比

Tab. 2 Results of CNN model with different epochsers


训练 轮数	真实轴向力 \bar{F}/N	近似轴向力 \bar{F}^*/N	相对误差 $\delta/\%$	相对标准偏 差 RSD/ $\%$
10 000	2.549	2.544	-0.20	2.19
50 000	2.549	2.516	-1.29	1.00
100 000	2.549	2.506	-1.69	0.39

经过上述对比分析,完成了对 CNN 智能模型参数的优化选择,最终选取的 CNN 模型卷积层层数为 64,训练轮数为 100 000。


2.4 天平阶跃信号的训练结果验证与误差分析

利用优化后的 CNN 模型对采集到的训练样本进行处理,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 8 所示。图 8 中,点划线为训练样本

的输入信号,虚线为理想阶跃信号,实线为经过 CNN 智能模型处理后的输出信号。由图 8 可知,经过 CNN 训练模型处理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,完全消除了输入信号中频率为 380 Hz 的惯性振动干扰。



(a) 频域信号



(b) 时域信号

图 8 训练样本与经过 CNN 模型处理后的信号对比

Fig. 8 Signal comparison of training samples by CNN model

从相对误差和相对标准偏差的分析数据可知,经过 CNN 频域数据模型处理后的信号平均值与理想阶跃载荷的平均值偏差很小,仅为 0.39%,验证了该 CNN 频域分析模型的数据处理可靠性。法向力和俯仰力矩的信号处理结果也比较类似,在此不再赘述。

3 天平频域信号 CNN 建模在激波风洞测力中的应用

在完成天平信号频域数据建模的样本验证之后,开展了在风洞测力中的应用。进一步为了验证该方法在激波风洞测力试验中应用的可靠性,本文在 JF-12 复现风洞中开展了标准模型测力试验,选取了半锥角为 10° 、长度为 750 mm 的尖锥标准测力模型。同时对该频域数据建模结果与时域信号建模结果进行了处理,与国际上风洞测量的参考数值对比分析。时域信号深度学习建模采用循环神经网络 RNN,即在数据处理过程中没有时频转换的步骤。RNN 是深度学习中常见的神经网络结构,网络同层神经元之间的节点是连接的,具有“记忆”功能,擅长挖掘数据中的时序信息,更适合处理解决时序问题。

CNN 模型在频域内的处理结果与 RNN 模型在时域内的处理结果的对比,如图 9 所示。图 9 中点划线为 JF-12 复现风洞测力试验中的天平输出信号,包括真实气动力信号与系统惯性振动信号;实线为 CNN 模型和 RNN 模型分别在频域和时域内对风洞测力信号的处理结果,可以发现频图中滤掉了主频为 380 Hz 的惯性振动信号。同时 相比时域信号处理,频域处理方法对振动干扰滤除的效果更好。




图 9 CNN 频域信号模型与 RNN 时域信号模型对风洞测试天平信号的数据处理对比

Fig. 9 Comparison of tunnel balance signal data between CNN frequency-domain model and RNN time-domain model

与训练样本信号数据处理方法类似,将经过 CNN 模型和 RNN 模型处理后得到的结果与参考文献 [23] 中测力系统的结果进行比较,对测试样本信号选取 70 ~ 110 ms 的时间段进行相对偏差 RD 和相对标准偏差 (relative deviation, RD) 和 RSD 分析。相对偏差的计算公式定义为

$$RD = \frac{\bar{A}^* - \bar{A}}{\bar{A}} \times 100\% \quad (7)$$

式中 \bar{A}^* 和 \bar{A} 分别为近似值和参考值,其计算对比结果如表 3 所示。

从表 3 可知,测力信号经过 CNN 和 RNN 智能模型处理后,频域数据 CNN 模型结果的相对误差更小,说明目前方法对激波风洞天平信号的处理结果具有较高

的准确性,能够有效识别出测力系统的惯性振动特征。基于频域数据的深度学习建模在处理激波风洞动态测力信号中具有较高的应用价值,作者也将针对深度学习技术在动态信号分析中的交叉应用,继续开展更加深入的研究。

表 3 CNN 模型与 RNN 模型处理测试样本的 RD 与 RSD
Tab. 3 RD and RSD comparison of test samples between CNN and RNN model

模型	参考系数 \bar{A}	近似系数 \bar{A}^*	相对偏差 RD/%	相对标准误差 RSD/%
RNN	0.102 6	0.103 1	0.49	16.49
CNN	0.102 6	0.101 2	-1.36	6.56

4 结 论

(1) 在激波风洞中开展气动力测量试验时,由于风洞有效运行时间较短,天平的输出信号受惯性干扰严重,有时无法直接通过 FFT 分析辨识出测力系统的惯性振动频率,因此在频域内对测力系统天平信号的振动特性进行深入数据分析、确认干扰分量具有技术研究的必要性。

(2) 针对激波风洞天平测力信号在频域内进行 CNN 模型训练,智能模型有效识别了系统的惯性振动频率特征,滤除了惯性振动主要干扰信号。将优化后的应用于频域内的 CNN 模型与应用于时域内的 RNN 模型进行了对比,验证了 CNN 智能模型在频域内的优势,输出的气动力信号稳定且符合理想阶跃信号的特征。

(3) 目前的将频域信号进行深度学习建模的方法验证了其在激波风洞测力试验中应用的可行性,具有较好的工程价值。探索激波风洞天平信号的不同人工智能数据处理方法,可以为高超声速飞行器气动力的真实气体效应研究提供更为可靠的数据,推动高焓流场气动力测量试验技术的进一步发展。

致谢

本研究在杨瑞鑫、陈正等人的协助下得以顺利完成,在此深表谢忱。

参 考 文 献

[1] 战培国. 国外风洞天平校准技术研究进展 [J]. 航空科学技术, 2012(2): 18-20.
ZHAN Peigu. Development of wind tunnel balance calibration techniques [J]. Aeronautical Science & Technology 2012(2): 18-20.

[2] 贺德馨. 风洞天平 [M]. 北京: 国防工业出版社, 2001.

[3] STORKMANN V, OLIVIER, GRONIG H. Force measurements in hypersonic impulse facilities [J]. AIAA Journal, 1998, 36(3): 342-348.

[4] NAUMANN K W, ENDE H, MATHIEU G. Technique for aerodynamic force measurement in shock tunnels [J]. Shock

- Waves, 1991, 1: 223–232.
- [5] 艾迪, 许晓斌, 王雄. 风洞天平动态特性多阶惯性补偿技术研究[J]. 实验流体力学, 2018, 32(4): 87–92.
AI Di, XU Xiaobin, WANG Xiong. Investigation of wind tunnel balance dynamic characteristics' multi-order inertial compensation [J]. Journal of Experiments in Fluid Mechanics, 2018, 32(4): 87–92.
- [6] DURYE A G R, MARTIN J F. An improved piezoelectric balance for aerodynamic force measurements [J]. IEEE Transaction on Aerospace & Electronic Systems, 1968, 4: 351–359.
- [7] 湛华海, 张旭, 吕治国, 等. 一种单矢量风洞天平校准系统设计[J]. 实验流体力学, 2014, 28(1): 70–74.
ZHAN Huahai, ZHANG Xu, LÜ Zhiguo, et al. Design of a single vector wind tunnel balance calibration system [J]. Journal of Experiments in Fluid Mechanics, 2014, 28(1): 70–74.
- [8] 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. Research progress on hypersonic wind tunnel aerodynamic testing techniques [J]. Acta Aeronautica et Astronautica Sinica, 2015, 36(1): 86–97.
- [9] SIMMONS J M, SANDERSON S R. Drag balance for hypervelocity impulse facilities [J]. AIAA Journal, 1991, 29(12): 2185–2191.
- [10] SMITH A L, MEE D J, DANIEL W J T, et al. Design, modelling and analysis of six component force balance for hypervelocity wind tunnel testing [J]. Computers & Structures, 2001, 79: 1077–1088.
- [11] ROBINSON M J, MEE D J, TSAI C Y, et al. Three-component force measurements on a large scramjet in a shock tunnel [J]. Journal of Spacecraft and Rockets, 2004, 41(3): 416–425.
- [12] MEE D J, DANIEL W, SIMMONS J M. Three-component force balance for flows of millisecond duration [J]. AIAA Journal, 2015, 34(3): 590–595.
- [13] WANG Y P, LIU Y F, LUO C T, et al. Force measurement using strain-gauge balance in a shock tunnel with long test duration [J]. Review of Scientific Instruments, 2016, 87: 005108.
- [14] WANG Y P, LIU Y F, JIANG Z L. Design of a pulse-type strain gauge balance for a long-test-duration hypersonic shock tunnel [J]. Shock Waves, 2016, 26: 835–844.
- [15] 汪运鹏, 刘云峰, 苑朝凯, 等. 长试验时间激波风洞测力技术研究[J]. 力学学报, 2016, 48(3): 545–556.
WANG Yunpeng, LIU Yunfeng, YUAN Chaokai, et al. Study on force measurement in long-test duration shock tunnel [J]. Chinese Journal of Theoretical and Applied Mechanics, 2016, 48(3): 545–556.
- [16] JOARDER R, JAGADEESH G. A new free floating accelerometer balance system for force measurements in shock tunnels [J]. Shock Waves, 2003, 13: 409–412.
- [17] TANNO H, KOMURO T, TAKAHASHI M, et al. Unsteady force measurement technique in shock tubes [J]. Review of Scientific Instruments, 2004, 75: 532–536.
- [18] SARAIVANAN S, JAGADEESH G, REDDY K. Aerodynamic force measurement using 3-component accelerometer force balance system in a hypersonic shock tunnel [J]. Shock Waves, 2009, 18: 425–435.
- [19] MARINEAU E C, MACLEAN M, MUNDY E P, et al. Force measurements in hypervelocity flows with an acceleration-compensated strain-gauge balance [J]. Journal of Spacecraft and Rockets, 2012, 49: 474–482.
- [20] 吕金洲, 张小庆, 陈光雄, 等. 基于惯性补偿的脉冲风洞测力天平瞬态研究[J]. 振动与冲击, 2018, 37(2): 216–222.
LÜ Jinzhou, ZHANG Xiaoqing, CHEN Guangxiong, et al. Transient simulation for dynamic output of force measuring balance in an impulse combustion wind tunnel based on inertia compensation [J]. Journal of Vibration and Shock, 2018, 37(2): 216–222.
- [21] 吕金洲, 陈光雄, 张小庆, 等. 基于惯性补偿的三分量测力天平瞬态特性的研究[J]. 推进技术, 2018, 39(6): 1396–1405.
LÜ Jinzhou, CHEN Guangxiong, ZHANG Xiaoqing, et al. Transient characteristics research of three-component force measurement balance based on inertia compensation [J]. Journal of Propulsion Technology, 2018, 39(6): 1396–1405.
- [22] LÜ J Z, ZHANG X Q, CHEN G X, et al. Transient dynamics research on the force-measurement system for hypersonic impulse combustion wind tunnel based on inertia compensation [J]. Journal of Aerospace Engineering, 2018, 31(6): 1–13.
- [23] 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. Deep-learning-based intelligent force measurement system using in a shock tunnel [J]. Chinese Journal of Theoretical and Applied Mechanics, 2020, 52(5): 1304–1313.
- [24] 聂少军, 王粤, 汪运鹏, 等. 循环神经网络在智能天平研究中的应用[J]. 力学学报, 2021, 53(8): 2336–2344.
NIE Shaojun, WANG Yue, WANG Yunpeng, et al. Application of recurrent neural network in research of intelligent wind tunnel balance [J]. Chinese Journal of Theoretical and Applied Mechanics, 2021, 53(8): 2336–2344.
- [25] 姜宗林, 李进平, 赵伟, 等. 长试验时间爆轰驱动激波风洞技术研究[J]. 力学学报, 2012, 44(5): 824–831.
JIANG Zonglin, LI Jinping, ZHAO Wei, et al. Investigating into techniques for extending the test-duration of detonation-driven shock tunnels [J]. Chinese Journal of Theoretical and Applied Mechanics, 2012, 44(5): 824–831.
- [26] WANG Y P, HU Z M, LIU Y F, et al. Starting process in a large-scale shock tunnel [J]. AIAA Journal, 2016, 54(4): 1–10.
- [27] 韩子健, 彭俊, 胡宗民, 等. JF-12 激波风洞在火星进入环境下的运行特性研究 [J]. 航空学报, 2021, 42(3): 124129.

(下转第315页)

- [8] 闵为, 杨珂, 李成, 等. 孔隙式黏滞阻尼器的力学特性研究[J]. 振动与冲击, 2021, 40(9): 125-132.
MIN Wei, YANG Ke, LI Cheng, et al. Mechanical characteristics of pore type viscous damper [J]. Journal of Vibration and Shock, 2021, 40(9): 125-132.
- [9] 孙靖雅, 焦素娟, 张磊, 等. 黏滞流体阻尼器冲击缓冲特性研究[J]. 振动与冲击, 2013, 32(14): 196-199.
SUN Jingya, JIAO Sujuan, ZHANG Lei, et al. Shock absorption characteristics of a viscous fluid damper [J]. Journal of Vibration and Shock, 2013, 32(14): 196-199.
- [10] 徐青华, 刘立平. 航天器展开机构阻尼器技术概述[J]. 航天器环境工程, 2007, 24(4): 239-243.
XU Qinghua, LIU Liping. Techniques of dampers for spacecraft deployment mechanism [J]. Spacecraft Environmental Engineering, 2007, 24(4): 239-243.
- [11] MITTER W, ZEMANN J, NITSCHKO T, et al. Adjustable large range rotary deployment damper [C]//Proceedings of 13th European Space Mechanism and Tribology Symposium. Vienna: European Space Agency, 2009.
- [12] KOLLER F, NITSCHKO T, LABRUYERE G. Viscous rotary damper [C]//Proceedings of 5th European Space Mechanisms and Tribology Symposium. Paris: 1993.
- [13] 濮海玲, 王晔, 杨巧龙. 黏滞型阻尼器对太阳翼展开性能的影响分析[J]. 航天器工程, 2013, 22(1): 54-59.
PU Hailing, WANG Xian, YANG Qiaolong. Analysis of viscous damper effect on solar array deployment [J]. Spacecraft Engineering, 2013, 22(1): 54-59.
- [14] 濮海玲, 刘志全, 王晔. 太阳翼黏滞阻尼器的可靠性评估方法[J]. 航天器工程, 2013, 22(5): 42-45.
PU Hailing, LIU Zhiquan, WANG Xian. Reliability assessment of rotary viscous damper for solar wing [J]. Spacecraft Engineering, 2013, 22(5): 42-45.
- ~~~~~
- (上接第302页)
- HAN Zijian, PENG Jun, HU Zongmin, et al. Investigating into operating characteristics for Mars entry tests of JF-12 shock tunnels [J]. Acta Aeronautica et Astronautica Sinica, 2021, 42(3): 124129.
- [28] 李斌. 6-SSR 六维加速度传感器性能试验研究[D]. 秦皇岛: 燕山大学, 2011.
- [29] GARLAND P P, ROGERS R J. Dynamic calibration of tri-axial piezoelectric force transducers [J]. Measurement Science and Technology, 2008, 19: 095202
- [30] 杨双龙. 风洞应变天平动态特性与动态校正方法研究[D]. 合肥: 合肥工业大学, 2014.
- [31] 徐科军, 朱志能, 李成, 等. 六维腕力传感器阶跃响应的实验建模[J]. 机器人, 2000, 22(4): 251-255.
XU Kejun, ZHU Zhineng, LI Cheng, et al. Experimental modeling of 6-axis wrist force sensor based on step responses [J]. Robot, 2000, 22(4): 251-255.
- [32] 郑红梅, 刘正士. 机器人六维腕力传感器动态性能标定系统的研究[J]. 电子测量与仪器学报, 2006, 20(3): 88-92.
ZHENG Hongmei, LIU Zhengshi. Research on the dynamic performance calibration system for robot's 6-axis wrist force sensor [J]. Journal of Electronic Measurement and Instrument, 2006, 20(3): 88-92.
- [33] 刘广孚, 张为公. 车轮力传感器的侧向力动态标定方法[J]. 仪表技术与传感器, 2010(3): 100-103.
LIU Guangfu, ZHANG Weigong. Research on dynamic calibration method of lateral force of wheel force transducer [J]. Instrument Technique and Sensor, 2010(3): 100-103.
- [34] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6): 1229-1251.
ZHOU Feiyan, JIN Linpeng, DONG Jun. Review of convolutional neural network [J]. Chinese Journal of Computers, 2017, 40(6): 1229-1251.
- [35] 郑泽宇, 梁博文, 顾思宇. TensorFlow: 实战 Google 深度学习框架[M]. 2版. 北京: 电子工业出版社, 2018.
- [36] 李俊. 基于二维 CNN 的车轴疲劳裂纹声发射信号实验数据分析[D]. 大连: 大连交通大学, 2020.