

基于深度神经网络的航炮炮振载荷识别



黄虎¹, 刘脩然², 王用岩¹, 杨建², 杨智春²

1. 航空工业成都飞机设计研究所 飞行器数字敏捷设计全国重点实验室, 四川 成都 610091

2. 西北工业大学 强度与结构完整性全国重点实验室, 陕西 西安 710072

摘 要:飞机在进行结构设计时, 需要考虑飞机结构抗炮振设计问题, 因此, 确定航炮发射时的动载荷大小及时间历程尤为重要。相对于传统的动载荷识别方法, 以深度学习技术为支撑的深度学习神经网络具有强大的拟合能力, 对于动载荷的识别具有广阔的应用前景。本文从深度学习应用的角度出发, 建立航炮炮振载荷识别方法, 以与某型炮舱结构动力学相似的简化炮舱模型为研究对象, 对复杂波形冲击载荷的动载荷环境进行模拟并对简化炮舱试验模型进行激励; 从信号处理的角度将有阻尼动力学系统与有限长脉冲响应系统等效, 提取对应的特征信号, 应用长短期记忆(LSTM)神经网络对简化炮舱模型试验的冲击动载荷进行识别, 并从鲁棒性角度对方法的应用性能进行测试。最终, 利用本文所建立的方法对实际的某型炮舱在真实炮振载荷环境下受到的冲击波脉动压力载荷进行了识别, 验证了该方法在实际应用场景中的适用性, 为炮振动载荷这类复杂冲击载荷的识别提供了新的思路和技术途径。

关键词:深度学习; 载荷识别; 振动分析; 特征提取; 鲁棒性

中图分类号: V21S.1

文献标识码: A

DOI: 10.19452/j.issn1007-5453.2025.01.001

由航炮射击而产生的剧烈振动称为炮击振动。严重的炮击振动将引起结构破裂、设备失灵, 因此在飞机结构设计时, 必须考虑飞机结构抗炮振设计问题。而进行飞机结构抗炮振设计, 首先要确定航炮发射时的动载荷。航炮连发时, 炮弹受到高膛压的推动, 连续地从炮口高速射出, 随着炮弹连续离开炮口, 连续冲出的高压气体的脉冲压力波以空气和结构为传递介质作用在飞机结构上。此外, 在膛压载荷作用下, 航炮会进一步产生前冲载荷和后座载荷, 并通过支持结构和航炮的连接点传递给航炮的支持结构, 这种载荷通过支持结构和航炮的连接点传递给航炮的支持结构, 这些载荷是航炮支持结构进行动力学设计的主要动载荷^[1]。然而, 由于在航炮射击的工况下不便在关键测点安装力传感器来直接测量这些动载荷, 于是, 只能利用容易测得的结构动响应, 通过动载荷识别的手段, 来间接地获取作用于结构的动载荷信息^[2]。

传统的动载荷识别方法是基于数学推理所建立的, 具

有原理性强、物理意义明确的特点, 已经尝试应用于建筑桥梁^[3-4]、机械制造^[5]、航空航天^[6-7]等各工程领域, 但也由于其必须基于受载结构的精确数学模型, 且不可避免的矩阵求逆运算往往容易导致计算困难^[8]、不适定^[9]等一系列问题, 造成了方法具有先天的局限性, 无法得到进一步的突破性提升。21 世纪, 以深度学习技术为支撑的深度学习神经网络作为人工智能技术领域最为活跃且拥有众多实际应用的研究领域, 已经在航空工程领域展现出巨大潜力^[10]; 利用深度神经网络的优势是, 对于动载荷识别问题进行代理模型的建立^[11-13], 以及充分发挥深度学习神经网络对于相关关系强大的拟合能力, 可以不必像传统数学方法那样建立振动响应与动载荷之间的理论表达式, 从而避免如高精度数学理论建模、正模型求逆不适定等难题^[14-16]。

因此, 本文针对炮振载荷识别的难点问题, 从深度学习神经网络应用的角度出发, 依据结构动力学原理, 将动载荷时域识别问题归类于时间序列回归预测与处理问题, 选取深度

收稿日期: 2024-06-25; 退修日期: 2024-09-25; 录用日期: 2024-11-25

基金项目: 航空科学基金(20220015053002)

引用格式: Huang Hu, Liu Xiaoran, Wang Yongyan, et al. Dynamic load identification of gun bay based on deep neural network[J]. Aeronautical Science & Technology, 2025, 36(01): 1-10. 黄虎, 刘脩然, 王用岩, 等. 基于深度神经网络的航炮炮振载荷识别[J]. 航空科学技术, 2025, 36(01): 1-10.

循环神经网络作为动载荷识别模型,建立本文的炮振载荷识别方法,并基于简化炮舱结构试验模型和简化的动载荷工况进行冲击动载荷的时域识别,考察方法的鲁棒性,论证了本文所提方法的适用性;最后以某型航炮真实炮舱模拟舱段的地面炮击试验实测数据为样本,完成本文所提出的炮振载荷识别方法验证。

1 基于深度循环神经网络的炮振载荷识别方法

1.1 线性时不变结构动力学特性

常见的工程结构大多属于线性时不变结构,利用结构有限元思想,可将其离散为线性多自由度系统。对于线性时不变的离散振动系统,假设系统共受到 p 个点的随机载荷与冲击载荷的激励,随机载荷的信号样本具有各态历经特性,冲击载荷为单次或连续冲击载荷,本文的动载荷及动响应均是针对上述载荷的时域样本。根据线性叠加原理,测点 i 的结构动响应 $\ddot{x}_i(t)$ 与其所受动态载荷 $f_j(t)$ 的卷积关系为

$$\ddot{x}_i(t) = \sum_{j=1}^p \int_0^t h_{ij}(t-\tau) f_j(\tau) d\tau \quad (1)$$

将式(1)离散化,展开之后得

$$\ddot{x}_i(t) = \sum_{j=1}^p h_{ij}(0) f_j(t) + h_{ij}(\Delta t) f_j(t-\Delta t) + \dots + h_{ij}(n\Delta t) f_j(t-n\Delta t) \quad (2)$$

式中, Δt 为采样时间的时间间隔; $\ddot{x}_i(t)$ 为 t 时刻振动系统在 i 点的加速度响应幅值; $f_j(t)$ 为 t 时刻作用于振动系统 j 点的动载荷幅值; $h_{ij}(n\Delta t)$ 为 $t=n\Delta t$ 时刻结构 i 响应点与 j 加载点之间的跨点脉冲响应函数。

可以看出,任意时刻的结构动态响应 $\ddot{x}_i(t)$,不仅由该时刻的动态载荷 $f_j(t)$ 决定,还会受到该时刻之前所有的动态载荷 $f_j(t-\Delta t), f_j(t-2\Delta t), \dots, f_j(t-n\Delta t)$ 的影响。由此,依据式(2),可以进一步推导振动响应 $\ddot{x}_i(t)$ 与动载荷 $f_j(t)$ 的关系

$$\ddot{x}_i(t) = \sum_{j=1}^p F_j \left(f_j(t), f_j(t-\Delta t), f_j(t-2\Delta t), \dots, f_j(t-n\Delta t) \right) \quad (3)$$

将式(3)改写成如下形式

$$\ddot{x}_i(t+d\Delta t) = \sum_{j=1}^p F_j \left(f_j(t+d\Delta t), f_j(t+(d-1)\Delta t), \dots, f_j(t), \dots, f_j(t+(d-n)\Delta t) \right) \quad (4)$$

观察式(2)~式(4), t 时刻的外激励 $f_j(t)$ 会影响 $t, t+\Delta t, t+2\Delta t, \dots, t+d\Delta t$ 时刻的振动响应,因此振动响应 $\ddot{x}_i(t), \ddot{x}_i(t+\Delta t), \ddot{x}_i(t+2\Delta t), \dots, \ddot{x}_i(t+d\Delta t)$ 中包含激励 $f_j(t)$ 的信息。结构

的振动载荷识别问题可以表示成以下形式

$$f_j(t) = \sum_{i=1}^N G_i \left(\ddot{x}_i(t), \ddot{x}_i(t+\Delta t), \ddot{x}_i(t+2\Delta t), \dots, \ddot{x}_i(t+d\Delta t) \right) \quad (5)$$

综上所述,对于线性时不变结构的动载荷识别问题,其本质可归纳为“序列数据-序列数据”的回归问题,所以深度神经网络模型可用于搭建响应序列数据到载荷序列数据之间的关系,而选取深度神经网络模型时,应选择可以处理序列数据与回归问题的循环神经网络。

1.2 长短期记忆神经网络

长短期记忆(LSTM)神经网络^[7]是传统神经网络的一个变种。LSTM神经网络在保留了传统神经网络框架结构的基础上,通过改变神经网络内部的神经元结构,来克服传统循环神经网络的“梯度爆炸”与“梯度消失”问题,使得LSTM神经网络可以实现长序列输入数据的训练与预测。

在LSTM神经网络构建中,最为关键的就是其神经元内部的结构设计。如图1所示,相较于传统循环神经网络的神经元,LSTM网络的神经元内部增加了输入门、遗忘门及输出门,其中门函数为Sigmoid函数。Sigmoid函数常被用作各个神经网络模型的激活函数 σ ,其表达式如下

$$\sigma = \frac{1}{1 + e^{-x}} \quad (6)$$

由函数定义的公式可看出,Sigmoid函数会将输入数据 x 映射在 $[0,1]$ 的范围内,这样的特性可以使其有选择性地对一些数据进行“遗忘”,即归零;同时也会有效保留前序有用的数据,并且在循环计算中合理分配数据占比,从而避免出现“梯度爆炸”与“梯度消失”的问题。

LSTM神经网络的神经元之间的连接关系与传统循环神经网络相同,每一个神经元同时接收与它相连接的神经元的状态信息与输出信息,以及从输入层输入的外部输入信息。

在 t 时刻状态下,LSTM神经网络隐含层中第 i 个神经元的遗忘门 $f_i^{(t)}$ 的运算方式为

$$f_i^{(t)} = \sigma(b_i^f + \sum_j U_{ij}^f x_j^{(t)} + \sum_j W_{ij}^f h_j^{(t-1)}) \quad (7)$$

式中, $x_j^{(t)}$ 为LSTM神经网络输入层传递至隐含层的外界输入信息矢量; $h_j^{(t-1)}$ 为隐含层所有神经元输出信息组成的输出矢量; $b_i^f, U_{ij}^f, W_{ij}^f$ 分别为遗忘门运算中的偏置参数、输入权值参数和遗忘门的循环运算权值参数矢量。

输入门 $g_i^{(t)}$ 也以类似遗忘门的运算方式进行运算




图1 LSTM网络神经元结构示意图

Fig.1 Schematic diagram of the neuron structure of the LSTM network

$$g_i^{(t)} = \sigma(b_i^g + \sum_j U_{ij}^g x_j^{(t)} + \sum_j W_{ij}^g h_j^{(t-1)}) \quad (8)$$

式中, b_i^g 、 U_{ij}^g 、 W_{ij}^g 分别为输入门运算中的偏置参数、输入权值参数和输入门的循环运算权值矢量参数。同时, LSTM 神经元状态的运算方式为

$$c_i^{(t)} = f_i^{(t)} c_i^{(t-1)} + g_i^{(t)} \sigma(b_i + \sum_j U_{ij} x_j^{(t)} + \sum_j W_{ij} h_j^{(t-1)}) \quad (9)$$

式中, b_i 、 U_{ij} 、 W_{ij} 分别为运算状态中的偏置参数、输入权值参数和状态循环运算权值矢量参数, $c_i^{(t)}$ 为神经元的状态变量。 $f_i^{(t)}$ 、 $g_i^{(t)}$ 与 $h_j^{(t-1)}$ 的变量含义仍与前式相同。

最后, 输出门的运算方式如下

$$h_i^{(t)} = \tanh(c_i^{(t)}) q_i^{(t)} \quad (10)$$

$$q_i^{(t)} = \sigma(b_i^o + \sum_j U_{ij}^o x_j^{(t)} + \sum_j W_{ij}^o h_j^{(t-1)}) \quad (11)$$

式中, b_i^o 、 U_{ij}^o 、 W_{ij}^o 分别为输出门运算中的偏置参数、输入权值参数和输入门的循环运算权值矢量参数。

由算法可见, LSTM 神经网络具有“自主选择记忆”的能力, 能够比传统循环架构的神经网络更易于学习和处理长序列问题, 也具有更强的非线性拟合能力。

1.3 线性时不变结构与因果有限长脉冲响应系统的等效

由于在工程实际中, 对于时域内的自然信号都只能以离散信号的形式进行采集, 因此, 本节基于动载荷与动响应的离散信号进行推导。在数字信号处理领域, 通常将“输入-输出”之间的对应关系不会随时间变化的系统, 定义为线性时不变系统。同时, 因果系统是指对于一个线性时不变系统, 如果它在 t 时刻的输出 $y(t)$ 仅与系统当前和前序的输入有关, 而与系统后序的输入无关, 则该系统被称为因果系统。同时, 依据系统对于外界脉冲激励输入导致的系统所产生响

应的时影响来判断, 还将因果系统进一步划分为有限长脉冲响应系统和无限长脉冲响应系统。对于无限长脉冲响应系统, 当系统在 t 时刻受到外界的脉冲激励后, 系统会因为该激励的影响, 在之后无限长的时间范围内都持续产生响应, 在结构动力学领域, 无阻尼振动系统符合此特性; 相对的, 有限长脉冲响应系统则只会 t 时刻之后有限的时间范围内受到 t 时刻输入激励的影响, 结构动力学领域的有阻尼振动系统则符合此特性。因此, 对于一个具有 d 步有限长脉冲响应 $h(n)$ 的因果有限长脉冲响应系统, 有

$$h(n) = 0, \quad 0 > n \geq d \quad (12)$$

因此, 系统的卷积公式就简化为

$$y(n) = \sum_{k=0}^{d-1} h(k)x(n-k) \quad (13)$$

结合式(4)、式(5)与式(13)可以得到, 由于有阻尼线性振动系统中阻尼特性的影响, 可认为 t 时刻的动态载荷 $f_j(t)$ 对于经过 $d\Delta t$ 时间后的结构动响应不再造成影响, 因此, 对于任意的有阻尼线性时不变振动系统, 都可等效为因果有限长脉冲响应系统 H 。在此基础上, 假设一个系统 H^{-1} , 其内部运行机制恰好是 H 的逆向运算, 则当系统 H^{-1} 的输入信号是前后时序颠倒的动响应 $\ddot{x}_i\{t\}$, 而输出信号则也是前后时序颠倒的动态载荷 $f_j\{t\}$, 此时, 也可以将“倒时序动响应-倒时序动载荷”系统等效为 d 阶的因果有限长脉冲响应系统。

1.4 利用 LSTM 神经网络的动载荷倒序识别

结合式(5)、式(11)及 1.3 节的公式推导, 可以得到“动响应-动载荷”关系如式(14)所示

$$Y(t) = R(X(t), X(t+1), \dots, X(t+d)) \quad (14)$$

式中, $X(t), X(t+1), \dots, X(t+d)$ 为结构从 t 时刻到 $t+d$ 时刻的动响应; $Y(t)$ 为 t 时刻作用于结构的动载荷; R 为 $Y(t)$ 与 $X(t), X(t+1), \dots, X(t+d)$ 之间的映射关系。

由此可以利用 LSTM 神经网络进行映射关系 R 的拟合和搭建, 从而提出利用 LSTM 神经网络的动载荷倒序识别方法。

1.5 基于小波变换的炮振载荷信号基线漂移的处理

1.5.1 小波基函数选取

在结构动力学领域, 通常都借助傅里叶变换来观察与描述振动时域信号的频率特性, 因此, 本节选取了具有紧支撑傅里叶变换特性的 Meyer 小波作为小波基函数。

Meyer 小波的基函数是在频域内利用 $\sin$ 函数作为基础函数进行定义的, 其公式为

$$w = \begin{cases} \frac{1}{\sqrt{2\pi}} \sin \left[\frac{\pi}{2} v \left(\frac{3\pi}{2} |\omega| - 1 \right) \right] e^{\frac{i\omega}{2}}, & \frac{2\pi}{3} \leq |\omega| \leq \frac{4\pi}{3} \\ \frac{1}{\sqrt{2\pi}} \sin \left[\frac{\pi}{2} v \left(\frac{3\pi}{2} |\omega| - 1 \right) \right] e^{\frac{i\omega}{2}}, & \frac{4\pi}{3} \leq |\omega| \leq \frac{8\pi}{3} \\ 0, & |\omega| \leq \frac{2\pi}{3}, |\omega| \geq \frac{8\pi}{3} \end{cases} \quad (15)$$

式中, w 表示小波基函数, $v(x)$ 为辅助函数

$$v(x) = x^4 (35 - 84x + 70x^2 - 20x^3), x \in (0, 1) \quad (16)$$

1.5.2 信号样本的特征信息提取

基于 Meyer 小波基函数, 可以利用离散小波变换对任意的冲击载荷样本信号进行多频率分辨率分解。本节所采用的办法是利用带通滤波器进行多阶的离散小波分解, 分解过程如式 (17)、式 (18) 所示

$$a_{j-1} = \sum_{i=1}^M H(N-2I) a_j(N) \quad (17)$$

$$d_{j-1} = \sum_{i=1}^M G(N-2I) d_j(N) \quad (18)$$

式中, H 为低通滤波器; G 为高通滤波器; $a_j(N)$ 为信号的低频部分, 也称为离散近似信号; $d_j(N)$ 为信号的高频部分, 也称为离散细节信号; N 为滤波器组中滤波器系数的个数; I 为小波分解的尺度, $I=2^j$; j 为分解层数; M 为滤波器阶数。

不同的小波基对应不同的高、低通滤波器。因此, 对于任意一段频率成分复杂的冲击载荷都可以依据预先设定好的小波基函数及带通滤波器进行分解, 本节采用 Meyer 小波基函数属于具有紧支撑性、正交性的小波基, 即 Meyer 小波仅在有限范围内具有非零值, 且特征信号样本提取过程不存在信号泄漏、冗余的情况, 可以对响应信号样本实现正交分解。

2 简化炮舱模型的动载荷识别试验

航炮炮舱结构主要承受的动载荷, 是在航炮实弹射击工况下产生的炮振载荷; 同时, 考虑到炮舱结构还有可能受到其他随机动载荷的作用, 因此本节从冲击载荷对简化炮舱模型的动载荷识别进行研究, 归纳动载荷识别主要可分为 4 步, 主要为: (1) 选定动载荷加载点与动响应观测点, 采集实测数据; (2) 利用小波变换信号处理技术对实测数据进行去噪与预处理; (3) 基于处理得到的实测数据样本, 对 LSTM 神经网络进行训练与测试, 保证其正确收敛; (4) 将训练获得的 LSTM 神经网络应用于炮振载荷识别。识别流程如图 2 所示。

2.1 简化炮舱模型与试验布置

为验证本文所建立的动载荷识别方法在炮振载荷识别




图2 简化炮舱结构动载荷识别流程

Fig.2 Dynamic load identification process of the simplified gun bay model

应用中的有效性, 首先建立一个简化炮舱结构模型, 来进行动载荷识别的试验研究。基于某型航炮的炮舱结构, 按动力学相似原则设计了简化炮舱结构模型如图 3 所示。简化炮舱模型结构的材料选用 304 型号钢材; 舱体整体框架结构采用 L 形角钢; 直接承受炮振动载荷作用的壁板厚度为 3mm, 采用加筋壁板结构设计以保证舱体壁板的整体刚度。

采用底部固支边界条件将简化炮舱模型安装于固支基础上; 由于在航炮射击时炮舱壁板结构受到的冲击波载荷在时间维度和空间维度均具有迅速衰减的特性, 因此试验时采用冲击载荷模拟冲击波载荷。采用电磁激振器对简化炮舱模型进行动载荷加载, 以模拟炮振载荷环境。施加于




图3 简化炮舱模型结构

Fig.3 Simplified structural model of the gun bay

简化炮舱试验模型的动载荷为复杂、不规则波形的连续冲击载荷。

试验时,采用半实物仿真系统中的白噪声信号生成模块与带通滤波器共同搭建信号生成系统。信号生成模块所产生的冲击载荷信号通过功率放大器进行放大后,驱动电磁激振器,对结构进行冲击载荷加载,模拟结构在动载荷环境中所受到的冲击载荷激励;采用力传感器安装于激振器顶杆加载端,并采用强力胶黏结于试验件的壁板上。同样,信号生成模块所产生的冲击信号通过功率放大器进行放大后驱动激振器,对结构进行冲击载荷加载,模拟结构所受到的环境激励;采用力传感器安装于激振器顶杆加载端,直接冲击壁板(无黏结)。采用加速度传感器测量位移动响应信号样本。最后,采集记录“动载荷-动响应”信号样本。简化炮舱模型的“动载荷-动响应”加载测量试验现场布置如图4所示,简化炮舱模型的动载荷测点与动响应测点试验布置示意如图5所示。




图4 简化炮舱模型加载试验布置

Fig.4 Loading test set-up of the simplified gun bay model

如图5所示,简化炮舱结构中红色圆点标注处为结构加速度测点位置;黄色菱形点标注处为冲击载荷加载点位置。针对炮舱结构所处的动载荷类型,冲击载荷模拟炮舱结构所受到的炮击载荷。

2.2 简化炮舱模型的模态分析与测试

首先进行简化炮舱模型模态分析与试验测试。进行简化炮舱模型的动力学有限元建模和模态分析,获取模型的一阶模态振型与固有频率,其中炮舱的一阶固有频率为46.12Hz,一阶模态振型如图6(a)所示;根据用有限元模型仿真计算所得的前壁板结构的振动模态,对其进行区域划分与加速度测点布置,对待测壁板共布置9个加速度传感器,测点分布如图6(b)所示,试验测点布置如图6(c)所示,加速度计的灵敏度系数为100mV/g。试验采用锤击法对壁板结




图5 简化炮舱模型测点试验布置示意图

Fig.5 Schematic diagram of the measurement points of the simplified gun bay model




图6 简化炮舱模型模态试验

Fig.6 Modal test of simplified gun compartment model

构进行模态测试。模态测试试验的一阶固有频率为47.17Hz,试验模态振型如图6(d)所示。

2.3 简化炮舱模型的动载荷识别

以50Hz为基础冲击频率对简化炮舱模型进行动载荷加载,采集所得的部分“动载荷-动响应”试验数据样本,共采集获得时长30s的“动载荷-动响应”样本数据。将加速度响应时域数据作为深度神经网络模型的输入数据,随机动载荷时域数据作为深度神经网络模型的输出数据;按照“不重叠、不连续”的数据划分选取原则,将加载过程中5~15s的“动载荷-动响应”样本数据作为深度神经网络模型训练集数据;加载过程中20~22.5s的“动载荷-动响应”样本数据作为验证集数据;加载过程中25~27.5s的“动载荷-动响应”样本数据作为测试集数据。

经3000次训练迭代后,成功构建了一个LSTM深度神经网络模型,用于简化炮舱模型的动载荷识别。利用测试集数据对完成训练的深度神经网络模型进行测试,测试结果如图7所示。可以看到,深度神经网络模型对于复杂、不规则的连续冲击载荷实现了很好的识别效果,经计算统计得到动载荷样本识别结果与真实载荷样本曲线的最大峰值相对误差为11.21%,平均峰值相对误差为3.57%。

2.3.1 动载荷识别方法的鲁棒性

动载荷识别方法鲁棒性测试试验的基础是对简化炮舱模型的动力学特性进行摄动,而摄动量以其固有频率改变量为评判依据。为了测试动载荷识别深度神经网络模型的鲁棒性,在简化炮舱模型受载壁板中心粘贴400g的质量块,使其一阶固有频率降低5.33%(使模型参数发生变化),作为针对简化炮舱结构所建立的动载荷识别深度神经网络模型的鲁棒性衡量指标。

按照动载荷试验加载方案,对简化炮舱模型进行以50Hz为基础冲击频率进行复杂波形连续冲击载荷加载,采集得到“动载荷-动响应”试验数据样本作为测试集数据,进行动载荷识别深度神经网络模型的鲁棒性测试试验,结果如图8所示。

经计算统计得到动载荷样本识别结果与真实载荷样本曲线的最大峰值相对误差为16.52%,平均峰值相对误差为6.53%。可见,针对简化炮舱结构所建立的动载荷识别深度神经网络模型,对冲击载荷识别具有较好的鲁棒性。

2.3.2 动载荷识别结果分析

由2.2节和2.3节的研究结果对比可以发现,本文所提出的动载荷识别方法对于冲击载荷取得了良好的识别结果,具有较好的工程实际适用性。同时对比发现,在简化炮




图7 冲击载荷识别结果

Fig.7 Impact load identification results

舱模型识别方法鲁棒性研究中,在结构挂载质量增加400g后,动载荷的识别精度出现了相对明显下降,分析其主要原因:深度神经网络依据训练集样本数据进行学习,从而精确拟合动载荷与动响应之间的确定性的相关关系。在结构挂载400g集中质量后,结构的动力学特性发生明显的变化,此时结构测点处的动响应与加载点处动载荷之间的相关关系也出现了变化,使得原有深度神经网络模型所映射的相关关系不再足够准确,这是导致动载荷识别效果下降的主要原因。

3 真实炮舱模拟舱段实弹射击的冲击波脉动压力载荷识别

在实验室内完成简化炮舱模型的动载荷的识别应用验证以及动载荷识别鲁棒性验证后,进一步地利用某型航炮炮舱模拟舱段结构在实弹射击工况下,测试所得的冲击波脉动压力载荷样本与冲击波载荷作用下结构部分测点处的加速度响应样本,进行动载荷识别方法的应用验证(下文所有脉动压强的数据均做了归一化处理,即归一化压强 p/p_0 ,其中 p_0 为参考压强)。




图8 一阶模态频率下降5.33%后的冲击载荷识别结果
Fig.8 Identification results of impact load after a 5.33% decrease in the first-order modal frequency

在模拟舱段结构壁板表面共布置了10个脉动压力传感器测点,分别编号为P11、P21、P31、P41、P42、P33、P43、P14、P24、P34;由于真实的脉动冲击波压力是无法直接测量获取的,要借助压强来进行估算;因此脉动压力传感器实际测量的物理量是动载荷测点处在受到脉动冲击波载荷作用时的内外压强差值。共布置三个加速度响应测点,分别编号为A71、A73和A74。完成三次15连发射击,测试获取各测点处在三次连发工况下的“动载荷-动响应”样本数据,分别记作试验1、试验2和试验3。由于强冲击波对脉动压力传感器测试的影响与舱体内外压强差值不平衡,导致所测量获取的脉动压力载荷基本存在明显的“零漂”现象,且在部分测点处采集到的动载荷样本信号也受到了明显的噪声污染,信噪比较低。

首先利用小波变换技术为各动载荷测点的样本数据进行数据处理。剔除每个测点处所测到的动载荷样本中明显的高频噪声、零漂曲线以及非动载荷激励时间段的冗余信号(对信号样本进行两端裁剪,保留关键信息段),并对动响应信号作相同的处理。本节利用12阶的Meyer小波完成数

据处理,以试验1测试工况中P14测点处的动载荷样本数据为例,动载荷信号数据样本的处理过程如图9所示。




图9 测点P14动载荷样本信号预处理过程与结果

Fig.9 The signal preprocessing process and results of dynamic load sample at point P14

完成所有的数据前处理工作后,分别利用处理后的试验1样本数据集构建总训练集,试验2样本数据集构建总验证集,试验3样本数据集作为总测试集;为保证方法的泛化能力,采用“单点动载荷-单深度神经网络识别”的策略,即针对P11~P14测点中每一个动载荷测点,分别构建并训练一个深度神经网络模型,专门用于识别该测点处的冲击波脉动压力载荷。

由此,从试验1样本数据集、试验2样本数据集和试验3样本数据集中,分别提取P11~P14测点的动载荷样本数据和与之对应的动响应样本数据,构建出分别用于识别P11~P14各动载荷测点处冲击波脉动压力载荷的样本数据集,作为各个深度神经网络训练与测试所需的数据集。

利用测试集数据对完成训练的各个深度神经网络模型进行测试,以P14测点的识别结果为例,经训练后,用P14测

点脉动压力载荷识别的深度神经网络模型,对P14测点脉动压力载荷进行识别,识别得到的脉动压力载荷时间历程如图10所示。




图10 P14测点动载荷识别归一化结果

Fig.10 Identification normalization results of P14 measurement point load

以平均峰值误差为衡量标准,最终对P11~P43共10个测点的动载荷识别结果进行计算与统计,得到结果见表1。

对P11~P43共10个动载荷测点处的冲击波脉动压力载荷识别应用的试验测试结果进行统计,其中识别效果相对最差的测点P34平均峰值相对误差为21.39%,识别效果最好的测点P14平均峰值相对误差为8.80%。虽然相较之前的实验室识别效果有所下降,但总体上仍然较为准确地实现了冲击波脉动压力载荷的识别,且研究过程中发现,影响动载荷识别效果的主要因素是样本数据量与样本质量,包括能够供深度神经网络学习的训练样本数据只有0.6s,并且大多数测点的样本信号的信噪比过低、数据特征过于稀疏,造成深度神经网络模型无法得到有效、充分地训练,而并不是本文所提方法本身的局限性。

表1 各测点动载荷平均峰值误差

Table 1 The averaged peak value error of the dynamic load at each measurement point

测点	P11	P14	P21	P24	P31
相对误差/%	21.12	8.80	12.22	16.44	14.12
测点	P33	P34	P41	P42	P43
相对误差/%	16.67	21.39	18.02	13.08	15.89

综合本节研究工作所取得的载荷识别应用测试结果,验证了本文所建立的方法对于实际航空工程领域以及其他结构动力学工程领域进行动载荷识别问题的解决与应用都

具有很好的潜力。

4 结束语

本文提出了一种基于深度神经网络的航炮炮振载荷识别方法,并通过实验室简化炮舱模型的模拟试验和实际炮舱模拟舱段的实弹射击试验,验证了该方法的有效性。研究表明,利用LSTM神经网络对复杂的冲击载荷进行识别,不仅能够精确地拟合动载荷与动响应之间的相关关系,还具有良好的鲁棒性,能够应对结构动力学特性发生变化时的载荷识别问题。

在实验室环境下,简化炮舱模型的动载荷识别结果与真实载荷的峰值相对误差较小,验证了该方法的精确性。在实际炮舱模拟舱段的实弹射击试验中,尽管存在样本数据量不足和信噪比低的问题,动载荷识别结果的峰值相对误差仍在可接受范围内。这表明本文提出的方法不仅在理论上具备较强的适用性,在工程实践中也具有良好的应用前景,特别是在复杂冲击载荷的识别领域中提供了一条新的思路和技术途径。

未来的研究工作可以在进一步提高样本数据质量和丰富样本数据量的基础上,探索更多类型的深度神经网络模型和优化算法,以提升载荷识别的精度和鲁棒性。同时,本文的方法也可以推广应用于其他复杂动载荷识别场景,为工程结构的动态分析与设计提供较为有效的工具和技术支持。

AST

参考文献

- [1] 杨智春,谷迎松,李斌,等.航空结构动强度分析与设计[M].西安:西北工业大学出版社,2021.
Yang Zhichun, Gu Yingsong, Li Bin, et al. Dynamic strength analysis and design of aircraft structures[M]. Xi'an: Northwestern Polytechnical University Press, 2021. (in Chinese)
- [2] 杨智春,贾有.动载荷的识别方法[J].力学进展,2015,45(1): 29-54.
Yang Zhichun, Jia You. The identification of dynamic load[J]. Progress in Mechanics, 2015, 45(1): 29-54. (in Chinese)
- [3] Law S S, Chan T H T, Zeng Q H. Moving force identification: a time domain method[J]. Journal of Sound and Vibration, 1997 (1): 1-22.
- [4] 黄坤.基于高层建筑动力响应的动荷载反演研究[D].武汉:武汉理工大学,2019.
Huang Kun. Research on dynamic load inversion based on

- dynamic response of high-rise buildings[D]. Wuhan: Wuhan University of Technology, 2019. (in Chinese)
- [5] Okubo N, Tanabe S, Tatsuno T. Identification of forces generated by a machine under operating condition [C]//Proceedings of the 3rd International Modal Analysis Conference (IMAC), 1985: 920-927.
- [6] 孟光, 周徐斌, 苗军. 航天重大工程中的力学问题[J]. 力学进展, 2016, 46(1): 267-322.
- Meng Guang, Zhou Xubin, Miao Jun. Mechanical problems in momentous projects of aerospace engineering[J]. Progress in Mechanics, 2016, 46(1): 267-322. (in Chinese)
- [7] 王洪波, 赵长见, 廖选平, 等. 基于飞行工作模态分析的飞行器动载荷识别研究[J]. 动力学与控制学报, 2017, 15(2): 178-183.
- Wang Hongbo, Zhao Changjian, Liao Xuanping, et al. Research on dynamic load identification of aircraft based on flight work mode analysis[J]. Journal of Dynamics and Control, 2017, 15(2): 178-183. (in Chinese)
- [8] 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, Shuai Zhijun, et al. Review of research and development status of dynamic load identification in time domain[J]. Noise and Vibration Control, 2014, 34(1): 6-11. (in Chinese)
- [9] 杨智春, 贾有. 动载荷识别方法的研究进展[J]. 力学学报, 2015, 47(2): 384.
- Yang Zhichun, Jia You. Research progress in dynamic load identification methods[J]. Chinese Journal of Theoretical and Applied Mechanics, 2015, 47(2): 384. (in Chinese)
- [10] 韩仁坤, 杜焦喜, 刘子扬, 等. 基于深度神经网络的含运动边界非定常流场预测方法研究[J]. 航空科学技术, 2023, 34(12): 37-42.
- Han Renkun, Du Jiaoxi, Liu Ziyang, et al. Research on the prediction method of unsteady flow field with moving boundary based on deep neural network[J]. Aeronautical Science & Technology, 2023, 34(12): 37-42. (in Chinese)
- [11] Ren Shaofei, Li Tiange, Chen Guorong, et al. A deep learning-based computational algorithm for identifying damage load condition: An artificial intelligence inverse problem solution for failure analysis[J]. Computer Modeling in Engineering & Sciences, 2018, 117(3): 287-307.
- [12] Chen Guorong, Li Tiange. Application of deep learning neural network to identify collision load conditions based on permanent plastic deformation of shell structures[J]. Computational Mechanics: Solids, Fluids, Fracture Transport Phenomena and Variational Methods, 2019, 64(2): 435-449.
- [13] 黄大伟, 陈立昆, 高亚东. 基于LSTM和响应分解的冲击载荷识别方法研究[J]. 振动与冲击, 2024, 43(3): 69-76+119.
- Huang Dawei, Chen Likun, Gao Yadong. Research on impact load identification method based on LSTM and response decomposition[J]. Journal of Vibration and Impact, 2024, 43(3): 69-76+119. (in Chinese)
- [14] 张璐, 冯东明, 吴刚. 基于LSTM网络的车辆动态荷载识别方法[J]. 东南大学学报(自然科学版), 2023, 53(2): 187-192.
- Zhang Lu, Feng Dongming, Wu Gang. Vehicle dynamic load identification method based on LSTM network[J]. Journal of Southeast University (Natural Science Edition), 2023, 53(2): 187-192. (in Chinese)
- [15] Gao Chenyu, Jiang Liangliang, Yang Fan, et al. Impact load identification and localization method on thin-walled cylinders using machine learning[J]. Smart Materials and Structures, 2023, 32(6): 065018.
- [16] Qiu Binbin, Zhang Meng, Xie Yaoguo, et al. Localisation of unknown impact loads on a steel plate using a pattern recognition method combined with the similarity metric via structural stress responses in the time domain[J]. Mechanical Systems and Signal Processing, 2019, 128: 429-445.
- [17] 何昆鹏, 赵瑾玥, 周琪, 等. 基于LSTM神经网络的机载光纤陀螺温度冲击误差补偿技术[J]. 航空科学技术, 2024, 35(2): 31-38.
- He Kunpeng, Zhao Jinyue, Zhou Qi, et al. Temperature shock error compensation technology for airborne fiber optic gyroscopes based on LSTM neural networks[J]. Aeronautical Science & Technology, 2024, 35(2): 31-38. (in Chinese)

Dynamic Load Identification of Gun Bay Based on Deep Neural Network

Huang Hu¹, Liu Xiaoran², Wang Yongyan¹, Yang Jian², Yang Zhichun²

1. *National Key Laboratory of Digital and Agile Aircraft Design, AVIC Chengdu Aircraft Design & Research Institute, Chengdu 610091, China*

2. *National Key Laboratory of Strength and Structural Integrity, Northwestern Polytechnical University, Xi'an 710072, China*

Abstract: In the design of aircraft structures, it is necessary to consider the anti-gun vibration design of aircraft structures and to determine the dynamic load when the aircraft machine gun is firing. In comparison with the traditional dynamic load recognition method, deep neural networks supported by deep learning technology have a strong fitting ability and a broad application prospect in dynamic load recognition. This paper presents a vibration load identification method for artillery hands, established from the perspective of deep neural network application. A simplified artillery bay model with similar structural dynamics of a certain type of gun bay was taken as the research object to simulate the dynamic load environment of the complex waveform impact load and the simplified gun bay experimental model. From the perspective of signal processing, the damped dynamic system is equivalent to a finite-length impulse response system. The corresponding feature signals are extracted, and impact dynamic load recognition experiments are carried out on the simplified gun bay model by means of the LSTM neural network. The application performance of the method is examining in terms of robustness. Finally, the method established in this article was used to identify the shock wave load experienced by a certain type of gun compartment in a real gun vibration load environment, verifying the applicability of the method in practical application scenarios and providing new ideas and technical approaches for the identification of complex impact loads such as gun vibration loads.

Key Words: deep learning; load identification; vibration analysis; feature extraction; robustness

Received: 2024-06-25, **Revised:** 2024-09-25, **Accepted:** 2024-11-25

Foundation item: Aeronautical Science Foundation of China(20220015053002)