

基于长短期记忆网络与小波变换的直升机飞参-载荷预测



谢克诚,周轩,董雷霆

北京航空航天大学,北京 100191

摘要:结构疲劳对直升机的飞行安全构成严重威胁。基于数字孪生的直升机单机寿命监控旨在考虑每架直升机结构损伤和健康状态的差异,从而合理地安排检查维护,其中获取可靠的直升机载荷数据是实现数字孪生的重要步骤。本文提出一种基于长短期记忆网络(LSTM)的直升机飞行载荷预测方法,可以考虑飞行与应变数据的非线性时变关系,以直升机飞行参数为输入,预测桨盘中心件飞行载荷;针对实际使用过程中载荷采样频率高于飞参的情况,通过小波变换对高采样载荷降维,实现了升采样载荷预测。最后,使用从某型直升机获取的实测试飞数据对上述方法进行了验证。该方法为可靠获取直升机结构数字孪生的载荷数据提供了重要参考,未来也可进一步扩展至其他航空结构。

关键词:载荷预测;数字孪生;直升机;长短期记忆网络;小波变换

中图分类号:V215

文献标识码:A

DOI: 10.19452/j.issn1007-5453.2024.11.007

结构疲劳问题严重威胁直升机的飞行安全。直升机动部件大多数采用单通道传力设计,由于其结构特殊且载荷复杂多变,一旦发生疲劳损坏,往往会导致严重的事故风险。传统直升机疲劳寿命管理采用机队统一管理思想,即以型号直升机的机队所包含的全部直升机作为整体按统一的准则和方法进行管理,未考虑到机队每架直升机结构损伤和健康状态的差异。基于数字孪生的直升机单机寿命监控考虑了任务组合、机动严重程度不同所造成的每架直升机结构疲劳寿命差异,根据数字孪生体预测每架直升机健康状态和剩余寿命的差异,并有针对性地调整结构检查间隔^[1]。

进行单机寿命监控首先要获取直升机的载荷数据。目前常用的方法包括基于传感器的直接测量^[2-4]、基于多学科仿真的载荷预测^[4-5]以及基于飞行参数的数据挖掘方法等^[6-7]。相比于其他方法,基于飞行参数的数据挖掘方法能够发现输入和输出之间的非线性关系,不需要额外加装测量设备,且避免了仿真模型与实际结构的保真度差异和使用传感器计算载荷数据的误差^[8],因此已被广泛用于载荷和疲劳预测。刘文珽等^[9]基于试飞实测数据和气动仿真数据建立了多种由数据驱动的结构载荷识别方法,并在国内多个型号的监控与延寿中得到了应用。曹善成等^[10]提出了一种支持

向量机回归飞行载荷识别模型,使用飞行参数识别某一部位弯矩;张夏阳等^[11]提出一种结合遗传算法(GA)和极限学习机(ELM)的GA-ELM模型,相比传统神经网络有更高的识别精度;唐宁等^[12]建立了基于改进支持向量机回归方法的模型,用于预测飞机跨声速俯仰机动时的机翼载荷。

直升机在实际飞行过程中承受非定常气动载荷,每一时刻的气动载荷既依赖于当时的流场状况,又依赖于前一段时间内流场运动的时间历程。因此在载荷预测中,考虑飞参和载荷的时间依赖信息是很有必要的,而目前基于多元线性回归和人工神经网络的方法没有考虑这一问题。Sisson等^[13]基于前馈神经网络构建模型,使用直升机前两个时间步的状态与操纵输入预测下一时刻状态。长短时记忆网络(LSTM)方法是循环神经网络的一种变种,该方法借鉴了人的记忆机制,可以有效处理长时间序列的预测问题。Candon等^[14]构建了基于双向LSTM的模型,使用飞机上的多点传感器应变数据预测飞机跨声速机动状态下的机翼载荷;Zhang Ruiyang等^[15]利用深度LSTM方法进行了建筑结构的非线性地震响应的预测,其中输入为地震波信号,输出为结构响应。然而,由于直升机结构复杂,飞行环境多变,考虑时变特性的飞参-载荷预测问题仍没有得到较好的

收稿日期: 2024-04-07; 退修日期: 2024-07-05; 录用日期: 2024-08-29

基金项目: 航空科学基金(201909051001)

引用格式: Xie Kecheng, Zhou Xuan, Dong Leiting. Flight-parameter-based load prediction of helicopter using lstm network and wavelet transform[J]. Aeronautical Science & Technology, 2024, 35(11): 51-57. 谢克诚, 周轩, 董雷霆. 基于长短期记忆网络与小波变换的直升机飞参-载荷预测[J]. 航空科学技术, 2024, 35(11): 51-57.

解决。此外,在实际的使用过程中,飞行参数与载荷数据的采样频率往往不一致;或是出现所需的计算对采样频率要求较高,飞行参数记录不能满足的情况。目前还没有得到有效解决。

综上所述,本文针对直升机考虑时变特性的飞参-载荷预测问题,使用某型直升机的实测试飞数据,构建了基于LSTM的载荷预测模型,以试飞过程中的飞行参数作为输入,桨盘中心件结构载荷作为输出,取得了良好的预测效果。为解决载荷数据采样率高于飞参的问题,本文采用小波变换的方法对飞行载荷进行分解,使用神经网络预测小波系数,从而实现了升采样载荷预测。

1 飞行试验数据与预处理

本文使用的数据集来自某型直升机的试飞实测,共进行4284s试飞,以25Hz的采样频率采集到106200组飞行参数;使用的载荷来自试飞过程中以1000Hz采样频率采集的,粘贴在直升机桨盘中央件上的应变片测量值。

1.1 数据筛选

为了保证模型所需输入可获取,消除冗余和异常值,需要对飞参数据进行一定的筛选。主要有两步流程:(1)通过查阅GJB 6346—2008军用直升机飞行参数采集要求^[16],将其中不做要求的侧滑角、迎角两组数据排除在模型输入之外,同时以其给定的测量范围为依据对其他飞参数据进行异常值诊断,确认剩余飞参数据均在正常测量范围内;(2)通过数据绘图以及简单的线性分析,发现同一飞行参数的不同方式测量的数据存在高度的一致性,故同一飞参仅保留一组数据作为输入。

进行上述处理,最终得到15组正常测量范围内的飞参数据作为模型输入,包括指示速度、高度、俯仰角、偏航角、横滚角、法向过载、纵向过载、侧向过载、X轴角速度、Y轴角速度、Z轴角速度、总距、横向操纵、纵向操纵、航向操纵。所有输入量采样频率均为25Hz。

1.2 数据分段

由于试飞过程数据复杂,不同机动状态间飞行参数与载荷关系较为复杂,需要首先对试飞数据进行分段,将不同机动状态分离开来。

飞行参数记录如图1所示,本文通过机动变换的临界点来分段。当飞行器法向载荷为1g,俯仰角、横滚角为0°时,可以认为飞行器未进行任何机动。以此作为分段依据,将原始飞行参数数据分为由不同类型的机动构成5个阶段,本文取其中的第4、5段(图中阴影部分,共1500s),使用其飞行参数预测结构载荷。

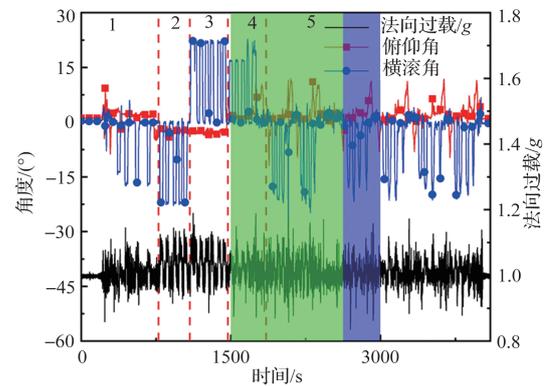


图1 机动状态分段

Fig.1 Segmentation of flight maneuvers

2 基于LSTM神经网络的载荷预测

由于所测量的飞行参数与载荷均为时间序列数据,每一步的载荷均由此前的状态与当前步的飞行参数决定。本文使用LSTM神经网络,以飞行参数为输入,对时间序列载荷进行预测。

2.1 LSTM神经网络模型

在使用神经网络处理时间序列问题时,循环神经网络(RNN)是最常用的模型之一,这种模型会使用 $t-1$ 时间步节点值作为 t 时间步的输入,即

$$h_t = \sigma(x_t \times w_x + h_{t-1} \times w_h + b) \quad (1)$$

式中, h_t 为 t 时间步节点值, x_t 为 t 时间步输入, w_x 和 w_h 分别为 x_t 和 h_{t-1} 的神经网络权重, b 为神经网络偏差, $\sigma(\cdot)$ 为sigmoid激活函数。

由于RNN的权值矩阵循环相乘导致的相同函数的多次组合会造成极端的非线性行为,又因为RNN的权重在各个时间步共享,导致RNN模型训练中的梯度消失和梯度爆炸问题,令RNN模型不能很好地预测长期趋势。

为解决上述问题,使用LSTM模型代替RNN模型。LSTM模型单元结构如图2所示,由输入门、遗忘门和输出门组成。相比于RNN神经网络,LSTM神经网络能够解决“长期依赖”问题,更好地处理“遗忘”与“记忆”之间的关系,并且具有较高的可行性。

对于每个时间步 t ,LSTM单元使用 $t-1$ 时间步的结果和该时间步的输入 x_t 计算 t 时间步节点值 h_t 和单元状态 c_t 。

单元结构中,遗忘门表示 c_{t-1} 的哪些特征被用于计算 c_t ,通常使用sigmoid作为激活函数

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

式中, f_t 为遗忘门值, W_f 为遗忘门权重, b_f 为遗忘门偏差。

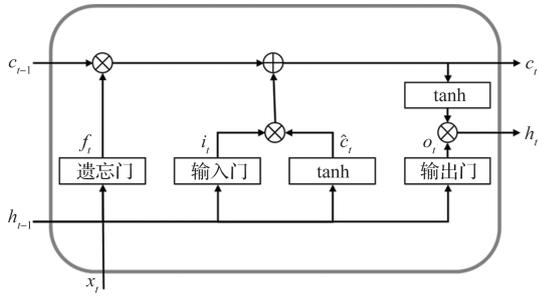


图2 LSTM模型单元结构

Fig.2 LSTM model unit structure

\hat{c}_t 为单元状态更新值,由输入数据 x_t 和上一节点值 h_{t-1} 经由一个神经网络层得到,单元状态更新值的激活函数通常使用tanh

$$\hat{c}_t = \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (3)$$

式中, W_c 为更新值权重, b_c 为更新值偏差。

输入门 i_t 表示 \hat{c}_t 的哪些特征用于更新 c_t ,通常使用sigmoid作为激活函数

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (4)$$

$$c_t = f_t \times c_{t-1} + i_t \times \hat{c}_t \quad (5)$$

式中, W_i 为输入门权重, b_i 为输入门偏差。

使用输出门 o_t 和 c_t 计算节点值 h_t

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (6)$$

$$h_t = o_t \times \tanh(c_t) \quad (7)$$

式中, W_o 为输出门权重, b_o 为输出门偏差。

在进行数值预测时,不仅需要考虑到前向后的时间序列,还需要结合下一状态值进行预测,即考虑从后向前的时间序列。因此可以构建双向LSTM神经网络。对于每个时刻 t 都会同时提供给两个方向相反的LSTM单元,输出由这两个单向LSTM单元共同决定。

2.2 基于LSTM神经网络进行载荷预测

基于TensorFlow框架,使用LSTM单元构建神经网络,结构见表1。其中网络1共有4个隐藏层,由LSTM层与三个全连接层组成;考虑到更高层次的非线性关系,构建了基于双层LSTM单元的网络2,即在网络1前再加入一层单元;将网络2中的第一层单元替换为双向LSTM单元,构成网络3。使用Adam优化器,设定学习率为0.001。以15组25Hz采样频率的飞行参数为输入,取飞行参数对应时刻的直升机桨盘中央件应变为输出,即将输出数据采样频率降低至25Hz。取时间步长为1,按照不同的窗口长度,生成时间序列切片,从而构建飞参与应变的时间序列数据集。将此数据集按照前后0.75:0.25的比例连续划分为训练集(图1中绿色阴影)和测试集(图1中蓝色阴影)。以均方误差

(MSE)作为损失(Loss)函数,每批使用100组数据,进行500轮训练。使用网络3测试了不同序列长度的MSE误差,见表2。随着窗口长度的增加,训练集和测试集的MSE误差并没有出现明显减少,计算用时却大量增加,因此本文选择窗口长度为5的数据集进行训练和测试。

表1 神经网络结构

Table 1 Structure of neural network

隐藏层类型			单元数量	激活函数
网络1	网络2	网络3		
—	LSTM	双向LSTM	100	sigmoid/tanh
LSTM	LSTM	LSTM	100	sigmoid/tanh
全连接层	全连接层	全连接层	100	Leaky ReLU
全连接层	全连接层	全连接层	50	Leaky ReLU
全连接层	全连接层	全连接层	25	Leaky ReLU

表2 不同窗口长度的误差

Table 2 Comparison between errors for different window lengths

窗口长度	训练集MSE	测试集MSE	每批训练用时/s
5	1.21×10^{-4}	1.05×10^{-4}	6
25	1.53×10^{-4}	1.36×10^{-4}	9
50	1.04×10^{-4}	9.43×10^{-5}	14
100	1.24×10^{-4}	1.07×10^{-4}	20
200	1.40×10^{-4}	1.05×10^{-4}	39

最终训练集误差见表3。从表3中可以看出,网络3对载荷预测的准确性为三者中最好,说明双向LSTM可以更有效地捕捉飞行参数与应变数据之间的非线性时变关系。训练过程中训练集与测试集损失函数如图3所示。

表3 不同载荷预测模型的误差对比

Table 3 Comparison between errors in load prediction models

模型	训练集MSE	测试集MSE
网络1	1.05×10^{-3}	8.85×10^{-4}
网络2	2.38×10^{-4}	1.95×10^{-4}
网络3	1.21×10^{-4}	1.05×10^{-4}

网络3对测试集(共有9370组数据)的预测结果如图4所示,图中蓝线为实测载荷,红线为神经网络预测载荷;图4(a)~图4(c)分别是测试集前、中、后三部分中取出长度为200的片段进行观察,图4(d)计算了测试集的功率谱密度。图中各部分载荷预测值与实测值波形相似,幅值平均误差4.6%,功率谱密度一致,说明网络3对载荷数据具有良好的预测作用。

3 基于小波变换的升采样载荷预测

在实际试验过程中,飞行参数与载荷采样数据往往不

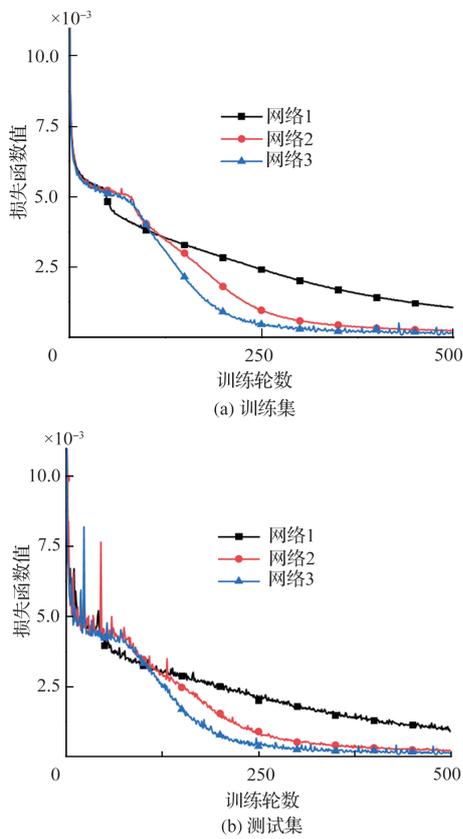


图3 训练过程损失函数值

Fig.3 Loss value in training process

是一一对应的,本文数据集的原始数据中,飞行参数采样频率为25Hz,而载荷的采样频率为1000Hz。使用低采样率的输入数据预测高采样率的输出,对于通常的神经网络较为困难,本文通过小波变换将高采样率信号分解,使用神经网络预测小波参数,实现升采样载荷预测。

3.1 小波变换

对于函数 $f(x)$ 进行小波变换,得到 $f(x)$ 的小波函数 W_f

$$W_f(a,b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} \psi\left(\frac{x-b}{a}\right) f(x) dx \quad (8)$$

式中, a 和 b 分别为尺度系数和时间系数,下标 f 表示对函数 $f(x)$ 进行小波变换。小波基函数 ψ 使用Meyer小波

$$\psi(\omega) = \begin{cases} \frac{1}{\sqrt{2\pi}} \sin\left[\frac{\pi}{2}v(x)\left(\frac{3}{2\pi}|\omega|-1\right)\right] e^{\frac{i\omega}{2}}, & \frac{2\pi}{3} \leq |\omega| < \frac{4\pi}{3} \\ \frac{1}{\sqrt{2\pi}} \cos\left[\frac{\pi}{2}v(x)\left(\frac{3}{4\pi}|\omega|-1\right)\right] e^{\frac{i\omega}{2}}, & \frac{4\pi}{3} \leq |\omega| < \frac{8\pi}{3} \\ 0, & |\omega| \notin \left[\frac{2\pi}{3}, \frac{8\pi}{3}\right] \end{cases} \quad (9)$$

其中辅助函数

$$v(x) = x^4(35 - 84x + 70x^2 - 20x^3), x \in (0, 1) \quad (10)$$

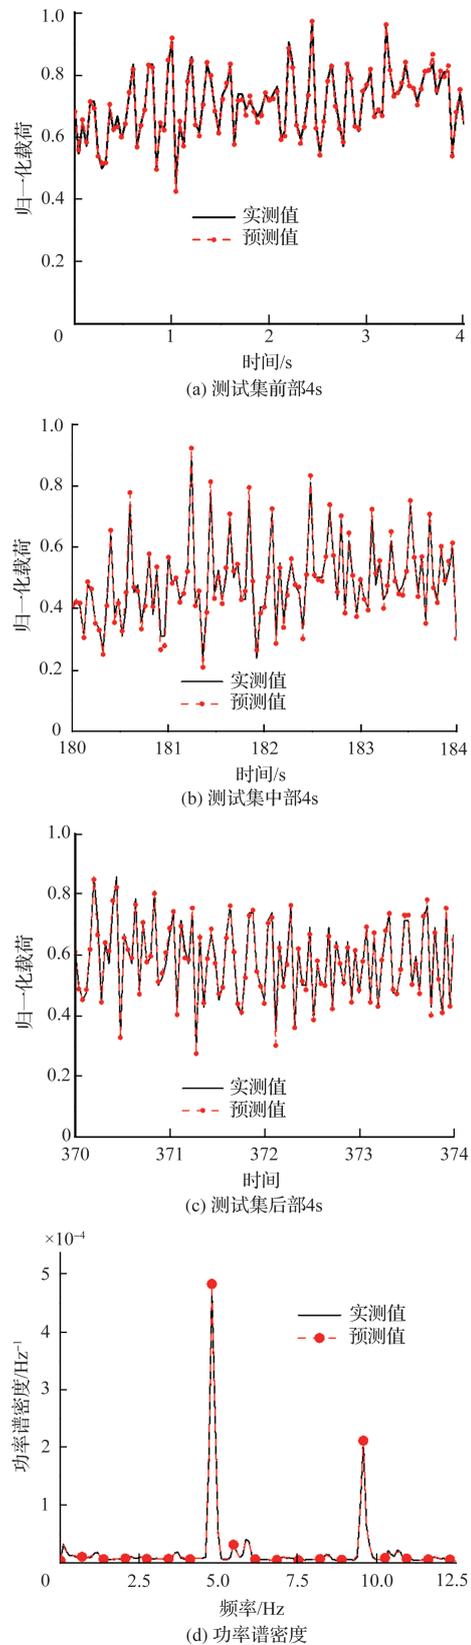


图4 神经网络预测结果与实测值对比

Fig.4 Comparison between the prediction and measurement

求得小波变换系数

$$\begin{cases} a_{j-1}(k) = \sum_n h(n-2k)a_j(n) \\ d_{j-1}(k) = \sum_n g(n-2k)a_j(n) \end{cases} \quad (11)$$

3.2 升采样模型

基于LSTM单元构建神经网络,结构见表4。以*t*时刻15组25Hz采样频率的飞行参数为输入,将1000Hz采样频率的载荷数据使用Meyer小波,对每两组输入之间(*t-t*+0.04s时刻)的40个载荷数据进行5阶小波分解,每个时刻共342个小波系数,以此作为*t*时刻的输出。以5个时间步的窗口长度构建数据集,将此数据集按照前后3:1的比例连续划分为训练集(图1中绿色阴影)和测试集(图1中蓝色阴影)。以均方差(MSE)作为损失(Loss)函数,每批使用100组数据,进行500轮训练。

表4 神经网络结构

Table 4 Structure of neural network

隐藏层类型			单元数量	激活函数
网络1	网络2	网络3		
—	LSTM	双向LSTM	500	sigmoid/tanh
LSTM	LSTM	LSTM	500	sigmoid/tanh
全连接层	全连接层	全连接层	500	Leaky ReLU
全连接层	全连接层	全连接层	500	Leaky ReLU
全连接层	全连接层	全连接层	500	Leaky ReLU

训练集与测试集损失函数如图5所示。最终训练集均方差见表5。从中可以看出,模型训练已趋于稳定,其中网络3对载荷预测的准确性为三者中最好。

网络3对高采样率测试集(共有374800组数据)的预测结果如图6所示,图中蓝线为实测载荷,红线为神经网络预测载荷;图6(a)~图6(c)分别是测试集前、中、后三部分中取出时间长度为0.2s的片段进行观察,图6(d)计算了测试集的功率谱密度。图中各部分载荷预测值与实测值波形相似,幅值近似相同,功率谱密度一致,说明网络3对高采样率载荷数据具有良好的预测作用。

4 结束语

本文提出了一种基于LSTM的直升机飞行载荷预测方法。该方法可考虑直升机飞参与载荷数据的非线性时变关系,并通过小波变换处理输入输出采样率不一致的问题。构建了含不同LSTM单元的神经网络,以直升机飞行参数为输入,预测桨盘中心件飞行载荷。对比发现含双向单元的双层LSTM神经网络对载荷的预测效果最好。对于载荷采样频率高于飞行参数的情况,进一步采用小波变换对载

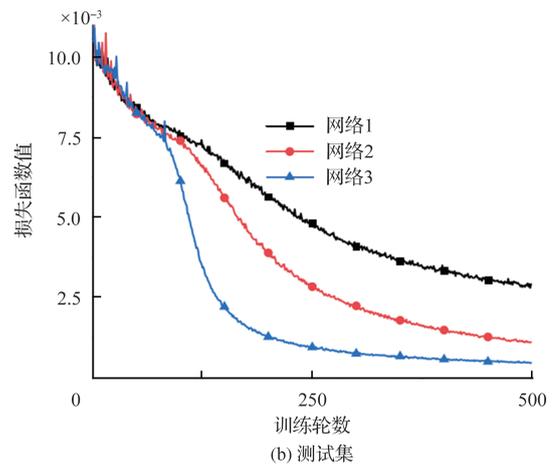
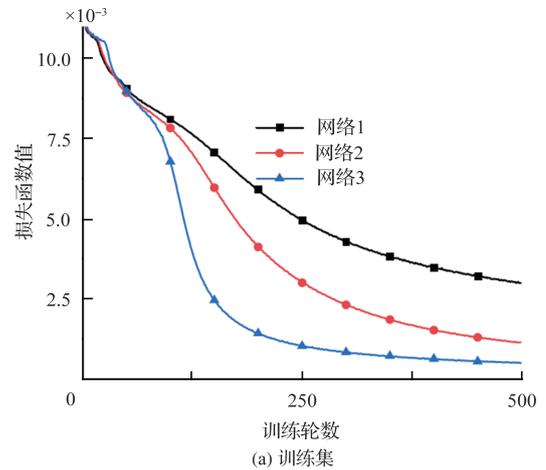


图5 训练过程损失函数值

Fig.5 Loss value in training process

表5 不同高采样率载荷预测模型的误差

Table 5 Comparison between errors in highly sampled load prediction models

模型	训练集MSE	测试集MSE
网络1	2.99×10^{-3}	2.91×10^{-4}
网络2	1.13×10^{-3}	1.10×10^{-3}
网络3	4.85×10^{-4}	4.57×10^{-4}

荷数据进行分解,并使用LSTM网络预测小波系数,实现升采样载荷预测,在实测飞行数据上取得了良好的预测效果。在后续研究中,将进一步探索使用多次飞行试验数据,或多架直升机的飞行试验数据对方法的泛化性进行更详细的分析与验证。

AST

参考文献

[1] 顾宇轩, 隋福成, 宋恩鹏. 神经网络技术在单机应变寿命监控中的应用研究[J]. 装备环境工程, 2018, 15(12): 74-77.

Gu Yuxuan, Sui Fucheng, Song Enpeng. Application of neural

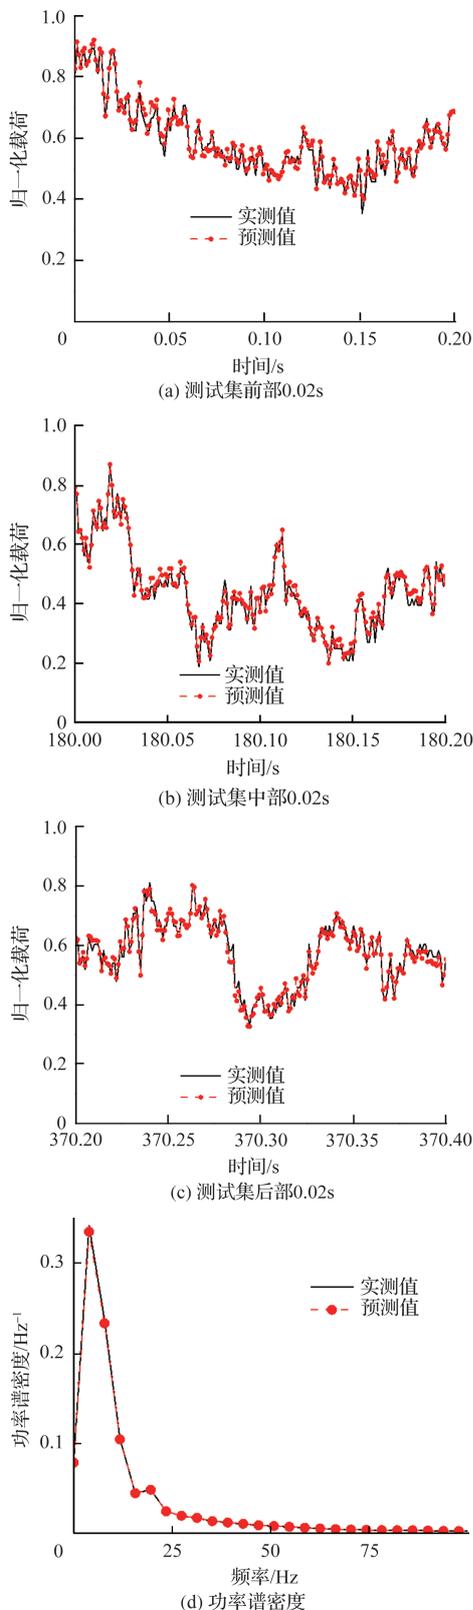


图6 高采样率数据集预测结果与实测值对比

Fig.6 Comparison between the prediction and measurement for highly sampled datasets

- network technique in individual strain life monitoring[J]. Equipment Environmental Engineering, 2018, 15(12): 74-77. (in Chinese)
- [2] Staszewski W J, Tomlinson G, Boller C, et al. Health monitoring of aerospace structures[M]. Chichester: Wiley, 2004.
- [3] 吴承根, 张吉超, 王永青, 等. 用于飞行器结构监控的柔性无线曲率传感器[J]. 航空科学技术, 2022, 33(9): 127-134. Wu Chenggen, Zhang Jichao, Wang Yongqing, et al. Flexible wireless curvature sensor for aircraft structure monitoring [J]. Aeronautical Science & Technology, 2022, 33(9): 127-134. (in Chinese)
- [4] 张彦军, 王斌团, 宁宇, 等. 飞机结构应变监控技术研究进展[J]. 航空科学技术, 2020, 31(7): 109-114. Zhang Yanjun, Wang Bintuan, Ning Yu, et al. Research progress on strain monitoring technology for aircraft structures [J]. Aeronautical Science & Technology, 2020, 31(7): 109-114. (in Chinese)
- [5] Kendra M. AFOSR spring review 2013: test and evaluation[R]. ADA579010, 2013.
- [6] 朱亮, 雷晓欣, 李小鹏, 等. 加改装飞机局部结构载荷谱实测与数据处理方法研究[J]. 航空科学技术, 2022, 33(6): 46-52. Zhu Liang, Lei Xiaoxin, Li Xiaopeng, et al. Research on load measurement and data processing method of local structure of modified aircraft[J]. Aeronautical Science & Technology, 2022, 33(6): 46-52. (in Chinese)
- [7] 兑红娜, 王勇军, 董江, 等. 基于飞行参数的飞机结构载荷最优回归模型[J]. 航空学报, 2018, 39(11): 80-89. Dui Hongna, Wang Yongjun, Dong Jiang, et al. Optimal regression model for aircraft structural load based on flight data [J]. Acta Aeronautica et Astronautica Sinica, 2018, 39(11): 80-89. (in Chinese)
- [8] 董雷霆, 周轩, 赵福斌, 等. 飞机结构数字孪生关键建模仿真技术[J]. 航空学报, 2021, 42(3): 107-135. Dong Leiting, Zhou Xuan, Zhao Fubin, et al. Key technologies for modeling and simulation of airframe digital twin [J]. Acta Aeronautica et Astronautica Sinica, 2021, 42(3): 107-135. (in Chinese)
- [9] 刘文琰, 王智, 隋福成. 单机寿命监控技术指南[M]. 北京: 国防工业出版社, 2010. Liu Wenting, Wang Zhi, Sui Fucheng. Technical guide for individual aircraft life monitoring[M]. Beijing: National

- Defense Industry Press, 2010. (in Chinese)
- [10] 曹善成, 宋笔锋, 殷之平, 等. 基于支持向量机回归的飞行载荷参数识别研究[J]. 西北工业大学学报, 2013(4): 535-539.
Cao Shancheng, Song Bifeng, Yin Zhiping, et al. Establishing a flight load parameter identification model with support vector machine regression[J]. Journal of Northwestern Polytechnical University, 2013(4):535-539. (in Chinese)
- [11] 张夏阳, 黄其青, 殷之平, 等. 基于 GA-ELM 的飞行载荷参数识别[J]. 航空工程进展, 2014, 5(4):497-501.
Zhang Xiayang, Huang Qiqing, Yin Zhiping, et al. Establishing a parametric flight loads identification method with GA-ELM model[J]. Advances in Aeronautical Science and Engineering, 2014, 5(4):497-501. (in Chinese)
- [12] 唐宁, 白雪. 基于改进支持向量机回归的非线性飞机结构载荷模型建模[J]. 航空工程进展, 2020, 11(5):694-700.
Tang Ning, Bai Xue. Nonlinear aircraft structure load model based on improved support vector machine regression[J]. Advances in Aeronautical Science and Engineering, 2020, 11(5):694-700. (in Chinese)
- [13] Sisson W, Karve P, Mahadevan S. Digital twin for component health and stress-aware rotorcraft flight control[J]. Structural and Multidisciplinary Optimization, 2022, 65(11): 1-12.
- [14] Candon M, Esposito M, Fayek H, et al. Advanced multi-input system identification for next generation aircraft loads monitoring using linear regression, neural networks and deep learning[J]. Mechanical Systems and Signal Processing, 2022 (171): 108809-108834.
- [15] Zhang Ruiyang, Chen Zhao, Chen Su, et al. Deep long short-term memory networks for nonlinear structural seismic response prediction[J]. Computers & Structures, 2019, 220: 55-68.
- [16] 中国人民解放军陆军航空兵学院. GJB 6346—2008 军用直升机飞行参数采集要求[S]. 总装备部, 2008.
Chinese People's Liberation Army Aviation School. GJB 6346—2008 requirements for flight data acquisition of military helicopter [S]. General Armament Department, 2008. (in Chinese).

Flight-parameter-based Load Prediction of Helicopter Using LSTM Network and Wavelet Transform

Xie Kecheng, Zhou Xuan, Dong Leiting

Beihang University, Beijing 100191, China

Abstract: Structural fatigue presents a significant threat to helicopter flight safety, necessitating the development of innovative digital-twin-based individual helicopter life monitoring, which considers the difference in structural damage and health condition of each helicopter, thereby enabling a rational schedule for inspection and maintenance. Obtaining reliable helicopter load data is an important step in realizing a digital twin. In this paper, an approach for helicopter flight load prediction based on a long short-term memory(LSTM) network is proposed, which considers the nonlinear and unsteady relationship between flight and load data. The proposed approach employs helicopter flight parameters as input to accurately forecast the flight load. Notably, to tackle scenarios where the sampling rate of the load data exceeds that of the flight parameters in practical applications, the wavelet transform is incorporated to achieve upsampling load prediction. Finally, the effectiveness of the proposed approach is verified using realistic test flight data acquired from an actual helicopter. The proposed method serves as a crucial reference for obtaining reliable load data for digital twins of helicopter structures. Furthermore, its applicability can be extended to encompass a broader range of aeronautical structures in future.

Key Words: load prediction; digital twin; helicopter; LSTM network; wavelet transform

Received: 2024-04-07; Revised: 2024-07-05; Accepted: 2024-08-29

Foundation item: Aeronautical Science Foundation of China(201909051001)