DOI: 10. 13382/j. jemi. B2205503

基于神经网络的星敏支架指向倾角监测方法*

宋健峰¹ 祝连庆^{1,2,3} 于明鑫^{1,3} 宋言明¹ 张 旭^{1,2}

(1.北京信息科技大学光电测试技术及仪器教育部重点实验室 北京 100016;2.北京信息科技大学光纤传感与 系统北京实验室 北京 100016;3.北京信息科技大学北京市光电测试技术重点实验室 北京 100192)

摘 要:针对星敏支架热致变形导致其指向精度降低的问题,提出了一种基于神经网络的指向倾角监测方法。首先,分析星敏 支架结构特征,搭建星敏支架指向倾角预测系统,采集星敏支架结构形变和倾角变化数据,并对实验数据进行预处理;其次,构 建深度神经网络模型,将星敏支架模型各测量点的应变信息作为输入变量,并使用 Adam 优化算法更新网络参数,经训练迭代 后得到指向倾角预测模型;然后针对传统深度神经网络收敛速度慢、容易产生局部最小值等局限性,使用遗传算法对深度神经 网络的超参数进行优化,以提升神经网络的训练速度;最后使用测试集数据对星敏支架指向倾角变化进行预测,分析该模型在 不同温度条件下对星敏支架指向倾角监测的准确率。实验结果表明,优化后深度神经网络模型的指向倾角预测方法的平均误 差为 0. 20",且倾角预测精度明显优于传统算法,证明利用深度学习方法实现星敏支架指向倾角监测具有可行性。 关键词:星敏支架;形变监测;深度学习;倾角预测

中图分类号: TH712 文献标识码: A 国家标准学科分类代码: 460.4

Star tracker bracket pointing inclination monitoring method based on neural network

Song Jianfeng¹ Zhu Lianqing^{1,2,3} Yu Mingxin^{1,3} Song Yanming¹ Zhang Xu^{1,2}

(1. Key Laboratory of the Ministry of Education for Optoelectronic Measurement Technology and Instrument, Beijing Information Science & Technology University, Beijing 100016, China; 2. Beijing Laboratory of Optical Fiber Sensing and System, Beijing Information Science & Technology University, Beijing 100016, China; 3. Beijing Key Laboratory of Optoelectronic Measurement Technology, Beijing Information Science & Technology University, Beijing 100192, China)

Abstract: Aiming at the problem that the pointing accuracy of star tracker bracket is reduced due to thermal deformation, a pointing inclination monitoring method based on neural network is proposed. Firstly, the structural characteristics of the star tracker bracket are analyzed, the pointing inclination prediction system of the star tracker bracket is built, the structural deformation and inclination change data of the star tracker bracket are collected, and the experimental data are preprocessed. Secondly, the depth neural network model is constructed, the strain information of each measurement point of the star tracker bracket model is taken as the input variable, and the network parameters are updated by Adam optimization algorithm. After training iteration, the pointing inclination prediction model is obtained. Then, aiming at the limitation of slow convergence and easy to produce local minimum value of traditional deep neural network, genetic algorithm is used to optimize the hyperparameters of deep neural network to improve the training efficiency. Finally, the test set data is used to predict the change of the pointing angle of the star tracker bracket, and the accuracy of the model in monitoring the pointing angle of the star tracker bracket under different temperature conditions is analyzed. The experimental results show that the average error of the directional inclination prediction method of the optimized depth neural network model is 0.20", and the accuracy of inclination prediction is significantly better than the traditional algorithm, which proves that the deep learning method is feasible to realize the directional inclination monitoring of star tracker bracket.

Keywords: star tracker bracket; deformation monitoring; deep learning; inclination prediction

收稿日期: 2022-05-18 Received Date: 2022-05-18

^{*}基金项目:北京市自然科学基金(4202027)、国家自然科学基金(61801030,62003346)项目资助

0 引 言

航天器在轨运行过程中,面临着空间辐照、高低温、 气动热、空间碎片等复杂环境^[1-2]。环境损伤与动态载荷 相互作用,可能会导致航天器上的星敏支架结构产生机 械变形,从而对其结构的可靠性与服役寿命造成威 胁^[34]。高轨高分辨率成像卫星中热变形对图像定位与 配准系统有较大的影响,为提高卫星定姿精度,通常将多 台星敏感器按照特定角度安装在星敏支架上,以控制星 敏感器由于在轨温度变化引起的热变形。星敏支架通常 安装在有效载荷的安装基板上,当有效载荷工作时,其产 生的热量将通过安装基板传递至星敏支架,导致星敏支 架产生变形。因此,对星敏支架结构形态变化的有效监 控,以提高载荷的指向精度,具有十分重要的工程应用背 景及理论研究价值。

为了对物体变形进行有效控制,国内外学者提出了 多种结构变形预测方法。Haas 等^[5]利用多元线性回归 等多变量方法来创建载荷预测模型,准确地对低速和悬 停夜间以及低发动机扭矩等条件下直升机地部件载荷进 行了预测。严大卫^[6]采用高斯过程回归模型建立结构优 化模型,对变形翼导弹的弯度、扭转等变形进行有效控 制。蔡炜等^[7]建立了自回归滑动平均求和(autoregressive integrated moving average model,ARIMA)模型对连续的变 形监测数据进行预测分析,验证了利用 ARIMA 模型对变 形监测数据进行预测的可行性。Klotz 等^[8]提出了一种 使用光纤布拉格光栅和神经网络的飞机机翼变形预测方 法,该方法预测的相对误差在-1.9%~2.0%之间,表明 可以利用神经网络对机翼变形进行预测。

基于以上文献调研,目前的形变监测方法主要有多 元线性回归分析法、高斯过程回归模型、ARIMA 模型等。 然而,由于星敏支架自身结构和工作环境较为复杂,上述 方法在此情境下均具有一定的局限性:1)多元线性回归 方法无法较好地拟合较为复杂的非线性数据;2)高斯过 程回归方法在特征数量较多的高维空间下,其拟合能力 会下降,从而失去其预测的有效性;3)ARIMA 模型要求 数据是线性稳定的,主要用来对时序数据进行预测,并不 适用于对非时序数据进行拟合的场景。而深度神经网络 具有较强的学习能力,并且适应性好,预测精度较高,因 此能够解决较为复杂的高维非线性预测问题。

针对以上问题,考虑星敏支架模型热致变形的复杂 度,本文提出了一种基于深度学习的星敏支架指向倾角 预测方法,建立了星敏支架热致变形指向倾角监测模型, 利用深度神经网络非线性表示能力,构建多层深度神经 网络,实现星敏支架热致变形预测。并针对其局限性,对 网络结构进行了改进,以提高变形监测精度,为航天器在 轨运行中产生的结构热致变形监测提供了理论依据,为 进一步实现航天器结构热致变形在轨实时监测提供了 参考。

1 星敏支架试验件建立与数据准备

1.1 星敏支架试验件模型建立

星敏支架结构如图 1 所示,实验模型主要由 3 根碳 纤维复合杆、星敏感器平台以及支架底座组成,支撑杆的 长度为 346 mm,底面直径为 15 mm。其中,碳纤维复合材 料的弹性模量 E=120 GPa,泊松比 v=0.31,材料密度 $\rho=$ 1.62 g/cm³。

星敏支架底部为殷钢平台,其平均膨胀系数为 1.5× 10⁻⁶/℃,导热系数为 0.026~0.032 cal·(cm·sec·℃)⁻¹, 具有塑性高、韧性高、膨胀系数小、导热系数低等特点,在 -80 ℃~+100 ℃时均不发生变化,因此在进行温度变化 实验时,星敏支架底部固定,倾角变化主要体现在星敏支 架 3 根杆受热形变导致顶部平台发生倾斜。

星敏支架在轨运行过程中,各部位受热不均匀,因此 会导致星敏支架顶部平台倾角发生变化。在星敏支架各 杆件上布置光纤光栅测点,并对支架结构进行加热,使得 星敏支架各杆发生热致变形,即可得到星敏支架各光纤 测量点所产生的应变。将采集到的应变信息输入神经网 络模型,即可求解得到星敏支架倾角变化信息。



图 1 星敏支架结构图 Fig. 1 Structure diagram of star tracker bracket

1.2 实验系统构建

实验系统主要由星敏支架结构、光纤光栅传感器、光 纤传感解调仪、激光倾角测量仪、平面反射镜、电源、高低 温试验箱、计算机以及星敏支架结构变形可视化监测软 件等共同组成。星敏支架指向倾角预测实验系统如图 2 所示。



图 2 星敏支架指向倾角预测系统

Fig. 2 Star tracker bracket pointing angle prediction system

光纤光栅传感器布置方式如图 3 所示,在星敏支架 支撑杆长度为 346 mm,在其上下表面距离底部 86.5、173 以及 259.5 mm 处各选取 3 个测点安装光纤光栅应变传 感器,为了监测星敏支架各部位的变形,采用波分复用的 方式将 18 个光纤光栅传感器依次串接于光纤光栅解 调仪^[9-11]。





为了提取星敏支架在不同温度下的倾角变化,用于 神经网络模型的训练和测试,并验证神经网络预测的准 确性,本文利用激光位移传感器和平面反射镜的组合来 测量星敏支架的倾角变化,图2中展示了激光倾角测量 系统的工作原理。激光位移传感器发出一束激光,经过 4个平面镜反射,随后位于星敏感器平台的平面镜将光 线反射,使其沿原光路返回激光倾角测量装置的光电探 测器靶面。根据反射光投射到光电探测器靶面的位置, 计算得到星敏感器平台的倾角变化。

1.3 数据采集与数据预处理

将星敏支架置于高低温试验箱内,按照图 2 的方式 搭建实验系统。星敏支架正常工作温度范围在-30 ℃~ 40 ℃之间,因此在该范围内提取不同温度条件下,星敏 支架的倾角变化量以及各测量点所发生的应变,共计采 集了 1 000 组数据用于神经网络训练。

星敏支架指向倾角预测系统实验环境如图 4 所示, 高低温试验箱型号为精宏 GDH-2010B,其控温范围为 -40 ℃~130 ℃,温度分辨率为 0.1 ℃。实验过程中,光 纤光栅传感解调系统解调出各传感器的中心波长,利用 其中心波长变化信息,可以计算出当前部位产生的应变。 其中,实验所采用的光纤光栅传感器中心波长的变化范 围为1530~1562 nm,应变灵敏度系数为0.83 με/pm。

激光倾角测量仪的重量为1000g,其体积大小为120mm×80mm×50mm,采用12V直流电源供电,测量精度为1"。电源选用Keithley 2231A-30-3三通道直流电源,输出电压范围为0~30V,输出电流范围为0~3A,最大功率为195W。



图 4 星敏支架指向倾角预测系统实验环境图 Fig. 4 Experimental environment diagram of star tracker bracket pointing angle prediction system

根据系统采集到的数据, 星敏支架各部位所产生的 应变在 17~518 με 之间, 并且星敏支架倾角变化范围在 0.16~122"之间。表1 中展示了部分温度条件下监测到 的星敏支架应变信息和指向倾角变化信息。分析采集到 的数据,发现由于高低温实验过程中还存在振动、循环气 流等环境影响, 星敏支架倾角变化情况比较复杂, 并没有 与温度、应变等自变量展现出较为明显的数学规律, 因此 使用传统的数学模型对星敏支架指向倾角变化进行预测 难度较高。

完成数据采集后,需要对采集的数据进行数据清洗 和筛选。剔除应变或倾角变化范围过大的异常点,并重 新采集该异常点所处温度条件下的应变数据和倾角变化 数据,再次进行数据清洗,直至所有数据都处于正常范 围内^[12-13]。

观察采集到的光纤光栅应变数据,发现数据中最大的应变值与最小的应变值差距较大。因此需要对星敏支 架各部位应变数据进行标准化处理,标准化公式为:

z

$$=\frac{x-\mu}{\sigma} \tag{1}$$

表 1	不同温度条件下星敏支架应变和倾角变化表

Table	1	Variation	of strain	and	inclination	of star	tracker
bracket under different temperature conditions						15	

	温度/℃				
	5	10	15	20	25
应变 1/με	127.15	119.56	82.47	54.51	39.21
应变 2/με	124.82	107.40	78.02	57.24	41.54
应变 3/με	191.59	165.25	118.44	79.53	47.92
应变 4/με	179.84	149.95	108.51	73.25	46.20
应变 5/με	179.13	145.59	103.34	71.02	47.01
应变 6/με	256.74	88.15	65.25	54.00	41.44
应变 7/με	138.20	122. 29	91.39	59.17	41.74
应变 8/με	181.16	155.93	109.42	55.12	40.83
应变 9/με	139.31	117.12	83.59	53.19	41.54
应变 10/με	150.46	128.27	90.58	60.59	43.87
应变 11/με	172.65	147.72	107.50	72.24	46.51
应变 12/με	118.54	109.63	80.04	58.26	41.84
应变 13/με	163.63	143.16	104.36	68.69	44.68
应变 14/με	129.38	110.23	79.94	55.52	41.74
应变 15/με	128.47	109.63	78.83	52.89	37.08
应变 16/με	188.45	163.93	113.68	64.84	35.26
应变 17/με	188.25	164.34	113.88	66.87	37.49
应变 18/με	124.75	125.73	114. 19	82.37	58.87
倾角变化/"	35.75	58.44	53.38	87.62	91.10

式中:µ为均值,σ为标准差。其中,标准差的计算公式 如式(2)所示。

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^{N} (x_i - \mu)^2}$$
(2)

观察采集到的数据,发现光纤光栅传感器所产生的 应变在 17~518 με 的范围内,星敏支架倾角变化变化范 围在 0.16~122"。分析实验数据,发现由于星敏支架各 部位受热产生的变形不均匀,导致神经网络输入参量的 取值范围变化较大,训练过程中变化较大的参量会对网 络产生较大影响,使得变化较小的输入参量所携带的信 息被掩盖,训练很难达到收敛,得不到具备相应功能的网 络。因此需要在训练前对神经网络的输入输出参量进行 归一化调整,调整公式为:

$$X_{i} = \frac{x_{i} - x_{\min}}{x_{\max} - x_{\min}}$$
(3)

数据归一化后按照设计的网络结构对预测模型进行 训练,将经过清洗和筛选后的训练数据按照8:1:1的 比例划分为训练集、验证集和测试集,即选择800组形变 数据作为神经网络的训练集,并且各选择100组应变数 据分别作为神经网络的验证集和测试集。将星敏支架模 型各部分应变数据及对应的指向倾角变化数据输入指向 倾角监测模型对神经网络进行训练和测试,直至网络性 能达到监测要求。

2 星敏支架指向倾角预测模型

2.1 模型结构确定

本文采用的深度学习模型为深度前馈神经网络模型,也称为深度神经网络。深度神经网络是一种按误差反向传播的多层前馈网络,它能学习和存贮大量的输入一输出模式映射关系,而无需事前揭示描述这种映射关系的数学方程^[1415]。深度学习算法主要把学习过程分为两个阶段:第1阶段为正向传播过程,给出输入信息通过输入层经各隐含层逐层处理并计算每个单元的实际输出值,第2阶段为反向传播过程,通过比较实际输出和期望输出得到误差信号,把误差信号从输出层逐层向前传播得到各层的误差信号,再通过调整各层的连接权重以减小误差^[16]。

深度神经网络模型主要包括输出层、隐含层和输出 层,其中输入层和输出层的节点数是由待解决问题的本 身决定的,本文的输入层节点数为星敏支架模型形变测 量点的个数,输出为星敏支架指向倾角的变化量,因此输 入层节点数为18,输出层节点数为1。

针对星敏支架指向倾角变化预测问题,考虑到模型 所使用的数据量,使用单隐含层即可对结构倾角变化进 行拟合。如表2所示,为确定隐含层节点数,本文对含有 不同隐含层节点数的神经网络模型经过10000次训练 产生的预测误差进行了对比。由表2可以看出,经过 10000次训练,隐藏层节点数为60的神经网络模型预测 误差最小,收敛最快,所以该模型的隐含层节点数确定 为60。

表 2 具有不同隐藏层节点数神经网络的预测误差 Table 2 MSE of neural networks with different number of hidden layer nodes

节点数	40	50	60	70
MSE	0.00017	0.000 35	0.000 08	0.000 11

综上所述,星敏支架指向倾角预测模型最终确定为 输入层、隐含层、输出层节点数分别为18、60、1的3层神 经网络结构,其模型结构如图5所示。

2.2 模型训练与参数选择

基于神经网络的星敏支架指向倾角预测模型输入数 据为星敏支架各杆件上下表面的对应测点的形变量,即 x_1, x_2, \dots, x_{18} ,输出数据为星敏支架受热变形所导致的角 度偏转值,即 $y_1 \otimes w_{ij}$ 和 w_{ji} 是各层网络之间的连接权值。 模型训练基本流程如下:

1)根据训练样本初始化网络模型基本参数,例如,神经网络各层节点数、各层之间的权值参数等。



图 5 建敏文朱宙阿倾用顶侧狭空图 Fig. 5 Model diagram of star tracker bracket pointing angle prediction

2) 计算隐含层输出。输入层和隐含层之间的连接权值为 w_i, 隐含层偏置值为 a, 根据式(4) 计算隐含层的输出 H。

$$H_j = f\Big(\sum_{i=1}^n w_{ij} x_i - a_j\Big) \tag{4}$$

3) 计算输出层输出。隐含层输出为 H,连接权值为 w_μ, 输出层偏置值为 b,根据式(5) 计算深度神经网络预测输 出 O。

$$O_{k} = \sum_{i=1}^{l} H_{j} w_{jk} - b_{k} \quad k = 1, 2, \cdots, m$$
(5)

4) 计算模型预测误差。此时, 神经网络预测输出为 0, 期 望输出为 Y, 代入式(6) 计算网络预测误差 e。

$$e_k = Y_k - O_k \quad k = 1, 2, \cdots, m$$
 (6)

5) 根据网络预测误差 e 更新神经网络模型连接权值 w_{ij} , w_{ik} 。权值更新公式如式(7)和(8)所示。

$$w_{ij} = w_{ij} + \eta H_j (1 - H_j) x(i) \sum_{k=1}^{m} w_{jk} e_k$$
(7)

$$w_{jk} = w_{jk} + \eta H_j e_k \tag{8}$$

6)根据网络预测误差 e 更新网络偏置参数 a 和 b。偏置 参数更新公式如式(9)和(10)所示。

$$a_{j} = a_{j} + \eta H_{j} (1 - H_{j}) \sum_{k=1}^{m} w_{jk} e_{k}$$

$$b_{k} = b_{k} + e_{k}$$
(9)
(10)

$$b_k = b_k + e_k \tag{1}$$

通过重复步骤 2)~6),直到达到最大训练次数,即 可完成对星敏支架指向倾角预测模型的训练。

模型的激活函数选择 Leaky ReLU 函数,其表达式为:

$$\phi(x) = \begin{cases} x, x \ge 0\\ ax, x < 0 \end{cases}$$
(11)

Leaky ReLU 函数在输入 x<0 时,将保持一个很小的 梯度 α,一般为 0.01。对于反向传播过程中小于 0 的输 入,Leaky ReLU 函数也会产生一个非 0 的梯度进行参数 更新,避免当前神经元永远不能被激活,从而解决了 Sigmoid 函数和 ReLU 函数中常见的梯度消失问题。

本文提出的神经网络的超参数包括学习率、批次大

小(batch size)、优化方法、迭代次数,激活函数等。其中, 神经网络模型的隐含层数为1,激活函数为 Leaky ReLU 函数,学习率为0.0001,batch size 的大小选择为100,优 化算法选择 Adam 函数,迭代次数为10000次。总训练 时长约为1h。深度神经网络的超参数如表3所示。

表 3 深度神经网络超参数 Table 3 Hyperparameters of deep neural network

类别	超参数值
学习率	0.000 1
Batch size	100
优化方法	Adam
迭代次数	10 000
激活函数	Leaky ReLU
隐含层层数	1

设置好相关参数后,对该神经网络模型进行训练。 由于神经网络中权重的初始值都是随机生成,因此需要 多次迭代,不断地修正权值,以获得更准确的倾角变化预 测值。

2.3 遗传算法优化的深度神经网络

虽然具有3个隐含层的深度神经网络可以完成任意的n维输入空间到m维输出空间的非线性映射,但是由于深度神经网络的初始参数时随机生成的,导致神经网络收敛速度慢,而且容易产生局部最小值^[17]。

因此针对上述问题,本文采取了一种利用遗传算法 (genetic algorithm,GA)优化神经网络的方法,在神经网 络训练之前对深度神经网络每层权值和阈值的进行优 化,以降低神经网络的训练成本,提升神经网络训练 效率。

遗传算法优化深度神经网络的实现分为网络结构的 确定、遗传算法优化和神经网络模型预测 3 个部分。首 先深度神经网络结构根据拟合函数输入输出参数个数确 定,进而确定遗传算法个体长度;其次使用遗传算法优化 深度神经网络的权值和阈值,种群中的每个个体都包含 了一个网络所有权值和阈值,个体通过适应度函数计算 个体适应度值,遗传算法通过选择、交叉和变异操作来找 到最优个体,得到遗传算法适应度值最优个体,即基于遗 传算法优化后的模型权重和偏置初始值;最后,利用经遗 传算法优化后的网络参数,在深度神经网络模型中对神 经网络进行参数训练,最终得到具有星敏支架指向倾角 预测模型权重和偏置的最优解^[18-19]。算法流程如图 6 所示。

3 模型效果分析

将测试集数据输入训练好的神经网络对指向倾角监



Fig. 6 Flow chart of depth neural network algorithm based on genetic algorithm optimization

测算法模型进行验证,根据各项评价指标对算法模型进 行性能验证。

3.1 倾角预测与结果分析

将 100 组测试集数据输入神经网络模型,得到相应 的星敏支架热致变形预测数据,并与真实数据进行对比, 表 4 记录了其中 20 组不同温度条件下的星敏支架变形 的真实值与预测值,并计算了绝对误差。

由表 5 可得,深度神经网络较好地预测了星敏支架 热致变形的倾角变化值,所选取的 20 组数据,预测值与 真实值之间的平均绝对误差为 0. 20"。通过对星敏支架 热致变形的预测结果的分析,可以看出基于遗传算法的 深度神经网络通过对初始化参数进行优化,并进行多层 非线性变换,对高维复杂数据建模,其预测结果非常接近 于真实值。

3.2 多种倾角预测方法对比分析

为了能体现基于遗传算法优化的深度神经网络的 优越性,图7展示了使用遗传算法优化的神经网络和 传统深度神经网络训练过程中均方误差的变化曲线。 通过分析对比,可以看出使用遗传算法进行优化的神 经网络模型,其收敛速度要明显优于传统神经网络预 测模型。 表 4 星敏支架倾角预测结果 Table 4 Inclination prediction results

of star tracker bracket

它旦	真实值/(") -	遗传算法优化深度神经网络			
71, 2		预测值/(")	绝对误差/(")		
1	10. 50	10.64	0.14		
2	10. 52	10.44	0.09		
3	10. 21	10.17	0.04		
4	5.28	4.98	0.31		
5	5.37	5.33	0.05		
6	6.25	5.79	0.46		
7	8.89	9.17	0. 28		
8	8.23	8.11	0.12		
9	8.12	8.04	0.08		
10	8.57	8.07	0.50		
11	11.74	11.84	0.10		
12	7.59	7.85	0.27		
13	7.45	7.21	0.24		
14	20. 32	20.33	0.01		
15	17.90	17.83	0.07		
16	18.63	18.39	0.24		
17	22.61	22.86	0.25		
18	23.56	23.79	0.23		
19	98.83	98.43	0.40		
20	26.75	26.88	0.13		

表 5 多种倾角预测方法相对误差对比

Table 5 Comparison of results of various

inclination prediction methods

序号	真实值/(")	MLR/%	GPR/%	DNN/%	GA-DNN/%
1	10. 50	0.65	3. 81	1.80	1.36
2	10. 52	14.10	2.74	1.28	0.82
3	10.21	53.81	5.59	0.84	0.39
4	5.28	42.20	17.94	6.35	5.78
5	5.37	53.63	4.02	0.77	0.84
6	6.25	104.84	15.97	8.05	7.37
7	8.89	39.86	3.14	4.02	3.14
8	8.23	15.13	5.24	2.23	1.42
9	8.12	15.13	3.22	0.74	1.00
10	8.57	12.81	6.23	5.58	5.86
11	11.74	13.82	8.70	1.27	0.89
12	7.59	8.61	4.31	4.52	3.52
13	7.45	35.23	4.07	4.21	3.23
14	20.32	14.23	0.56	0.17	0.05
15	17.90	8.10	4.92	0.66	0.37
16	18.63	3.44	2.13	1.57	1.29
17	22.61	2.66	1.54	1.45	1.10
18	23.56	22.73	1.12	1.24	0.96
19	98.83	7.55	0.82	0.48	0.40
20	26.75	35.14	1.18	0.42	0.49

为了进一步体现出该方法的优势,需要与传统方法 的计算结果进行比较,利用高低温实验采集的数据分别





使用多元线性回归(multiple linear regression, MLR)、高斯 过程回归(Gaussian process regression, GPR)以及传统深 度神经网络等方法实现对星敏支架指向倾角变化的反 演,并将4种方法进行对比分析。

表5为使用多元线性回归模型、高斯过程回归模型、 深度神经网络模型以及遗传算法优化深度神经网络4种 方法对星敏支架指向倾角变化预测的结果比较,从表5 中可以看到,基于遗传算法的优化深度神经网络模型对 星敏支架指向倾角变化进行预测的精度高于多元线性回 归算法和高斯过程回归算法。相较于未使用遗传算法的 深度神经网络,其预测误差都处于较低水平,基本保持一 致,模型收敛速度有明显提升,因此基于遗传算法的优化 神经网络模型有效地提升了神经网络的训练效率。

为了更直观对比4种方法的预测结果,图8为使用4 种方法预测的绝对误差对比图。通过使用各种方法对星 敏支架热致变形的指向倾角变化进行预测,可以发现基 于遗传算法优化的深度神经网络预测模型对于复杂结构 的形变预测具有良好的适应性。

综上所述,考虑到星敏支架可能受到环境温度、振动 等因素的影响,造成形变与倾角变化具有非线性关系,基 于遗传算法优化的深度神经网络有较好的非线性拟合能 力,该模型提高了对星敏支架指向倾角变化的预测精度, 因而能够较好地解决星敏支架热致变形指向倾角预测 问题。

4 结 论

本文针对星敏支架热致变形指向倾角监测需求,提 出了一种基于深度神经网络的指向倾角监测算法。通过 前向传播计算神经网络输出及误差反向传播优化参数, 建立了星敏支架指向倾角监测模型,并针对传统神经网 络收敛速度慢、容易陷入局部最优等缺点,结合遗传算法



的对网络模型进行改进。

实验结果表明,算法预测数据与实验数据拟合程度 较高。通过对比几种预测方法所产生的误差,得出深度 神经网络模型相较于多元回归模型和高斯过程回归模型 具有较高的计算精度,对于非线性预测问题具有较好的 拟合能力。而通过对深度神经网络模型的改进,融合遗 传算法的深度神经网络模型在训练效率上有了很大 提升。

本文所提方法成功验证了基于深度神经网络模型 方法在星敏支架指向倾角变化预测的适用性问题,该 方法具有非视觉测量、可扩展性强以及多功能复用等 特点,为复杂航天器结构形变监测与计算提供了新的 理论方法。

参考文献

- [1] 黄居坤. 空间结构热变形与应变场分布式光纤监测 方法研究[D]. 南京:南京航空航天大学,2019.
 HUANG J K. Monitoring method of spatial structure thermal deformation and strain field based on distributed optical fiber [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2019.
- [2] 任友良,王志国,胡炳亭.一种星敏感器支架热变形 控制方法[J]. 航天器工程,2017,26(2):77-83.
 REN Y L, WANG ZH G, HU B T. A method for controlling thermal deformation of star sensor bracket[J]. Spacecraft Engineering, 2017, 26(2):77-83.
- [3] 刘鹏,曾捷,李翔宇,等. 空间桁架横梁分布式光纤变形监测与误差修正[J]. 压电与声光, 2019, 41(5):715-720,724.

LIU P, ZENG J, LI X Y, et al. Distributed optical fiber deformation monitoring and error correction for space truss beams [J]. Piezoelectrics & Acoustooptics, 2019, 41(5):715-720,724.

 [4] 何凯,曾捷,林秋红,等. 空间伸展结构变形与振动 分布式光纤监测研究[J]. 仪器仪表学报, 2018, 39(2):56-65.

HE K, ZENG J, LIN Q H, et al. Research on spatial deployable structure deformation and vibration monitoring with distributed optical fiber [J]. Chinese Journal of Scientific Instrument, 2018, 39(2):56-65.

- [5] HAAS D J, FLITTER L, MILANO J. Helicopter flight data feature extraction or component load monitoring[J]. Journal of Aircraft, 2015, 33(1):37-45.
- [6] 严大卫. 变形翼导弹弹性飞行动力学分析与控制方法研究[D]. 南京:南京理工大学, 2017.
 YAN D W. Elastic dynamics analysis and control design for morphing-wing missiles [D]. Nanjing: Nanjing University of Science and Technology, 2017.
- [7] 蔡炜, 岳东杰. ARIMA 模型在桥梁变形监测预测分析中的应用[J]. 甘肃科学学报, 2021, 33(6):16-21.
 CAI W, YUE D J. Application of ARIMA model in bridge deformation monitoring and prediction analysis[J]. Journal of Gansu Sciences, 2021,33(6):16-21.
- [8] KLOTZ T, POTHIER R, WALCH D, et al. Prediction of the business jet global 7500 wing deformed shape using fiber Bragg gratings and neural network [J]. Results in Engineering, 2021, 9: 100190.
- [9] GOOSSENS S, DE PAUW B, GEERNAERT T, et al. Aerospace-grade surface mounted optical fiber strain sensor for structural health monitoring on composite structures evaluated against in-flight conditions [J]. Smart Materials and Structures, 2019, 28(6): 065008.
- [10] GALANOPOULOS G, MILANOSKI D, BROER A, et al. Health monitoring of aerospace structures utilizing novel health indicators extracted from complex strain and acoustic emission data [J]. Sensors, 2021, 21(17): 5701.
- [11] IKIADES A A. Strain measurement on cracks using fiber Bragg gratings for use in aircraft composite skin repairs[J]. Aerospace, 2020, 7(9): 138.
- [12] YU M, TANG X, LIN Y, et al. Diesel engine modeling based on recurrent neural networks for a hardware-in-theloop simulation system of diesel generator sets [J]. Neurocomputing, 2018, 283(29):9-19.
- [13] YU M, TANG X, LIN Y, et al. An eye detection method based on convolutional neural networks and support vector machines[J]. Intelligent Data Analysis, 2018, 22(2): 345-362.
- [14] SUN Y, DONG M, YU M, et al. Modeling and simulation of all-optical diffractive neural network based

on nonlinear optical materials[J]. Optics Letters, 2022, 47(1): 126-129.

- [15] 刘浩然,赵翠香,李轩,等.一种基于改进遗传算法的神经网络优化算法研究[J]. 仪器仪表学报,2016, 37(7):1573-1580.
 LIU H R, ZHAO C X, LI X, et al. Study on a neural network optimization algorithm based on improved genetic algorithm[J]. Chinese Journal of Scientific Instrument,
- [16] JIA Z, REN L, LI H, et al. Pipeline leak localization based on FBG hoop strain sensors combined with BP neural network [J]. Applied Sciences, 2018, 8(2): 146.

2016, 37(7):1573-1580.

- [17] ZHOU H, DING W F, LI Z, et al. Predicting the grinding force of titanium matrix composites using the genetic algorithm optimizing back-propagation neural network model [J]. Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture, 2019, 233(4): 1157-1167.
- [18] SUN Y, XUE B, ZHANG M, et al. Automatically designing CNN architectures using the genetic algorithm for image classification [J]. IEEE Transactions on Cybernetics, 2020,50(9): 3840-3854.
- [19] WANG Z Z, SOBEY A. A comparative review between genetic algorithm use in composite optimisation and the state-of-the-art in evolutionary computation [J]. Composite Structures, 2020, 233: 111739.
- 作者简介



宋健峰,北京信息科技大学硕士研究 生,主要研究方向为光纤传感与光电器件。 E-mail: songjianfeng@bistu.edu.cn

Song Jianfeng is a M. Sc. candidate in Beijing Information Science and Technology University. His main research interest includes

optical fiber sensing and optoelectronic devices.



祝连庆(通信作者),北京信息科技大 学仪器与光电工程学院教授,博士生导师。 主要研究方向为光纤传感与光电器件、生物 医学检测技术与仪器、精密测量与光机电 系统。

E-mail: lqzhu_bistu@ sina. com

Zhu Lianqing (Corresponding author) is a professor and Ph. D. supervisor in the School of Instrument and Optoelectronic Engineering, Beijing Information Science and Technology University. His main research interests include optical fiber sensing and opto-electronic devices, biomedical detection technology and instruments, precision measurement and optoelectronic mechanical systems.