

DOI: 10.13382/j.jemi.B2104737

基于深度学习的机翼蒙皮载荷计算方法^{*}

刘佳玮¹ 于明鑫^{1,2} 祝连庆^{1,2,3} 夏嘉斌¹ 闫 光^{1,3} 梁生瑒¹

(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. 北京信息科技大学北京市
光电测试技术重点实验室 北京 100192; 3. 北京信息科技大学光纤传感与系统北京实验室 北京 100016)

摘 要:针对传统的载荷标定方程计算机翼蒙皮载荷精度低的问题,提出了一种基于深度学习的机翼蒙皮载荷计算新方法。考虑真实机翼蒙皮受力复杂,首先建立了机翼蒙皮试验件模型,使用 Ansys 仿真软件对试验件进行有限元分析,获得应变与载荷仿真数据,并对仿真数据进行数据清洗与预处理;其次,构建深度神经网络模型,将应变与载荷作为神经网络模型的输入与输出值,采用 Adam 算法优化提出的载荷计算模型;最后,在测试集上对载荷值进行预测,使用平均相对误差与绝对值差作为评价指标。实验结果显示,基于深度学习的载荷计算方法在小载荷数据上平均绝对误差为 0.081 N,在正常载荷数据上的平均相对误差为 0.063 8%;与传统载荷计算方法比较,本文提出的新方法计算的载荷精度明显优于传统方法。

关键词: 机翼蒙皮;载荷计算;深度学习;应变;载荷标定方程

中图分类号: TN606;V215.2⁺1 **文献标识码:** A **国家标准学科分类代码:** 590.99

Calculation method of wing skin load based on deep learning

Liu Jiawei¹ Yu Mingxin^{1,2} Zhu Lianqing^{1,2,3} Xia Jiabin¹ Yan Guang^{1,3} Liang Shengjun¹

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

Abstract: Aiming at the problem of low accuracy of the traditional load calibration equation for calculating wing skin load, a novel method of wing skin load calculation based on deep learning was proposed. Considering that the force of the real wing skin was complicated, this paper established a simplified wing structure model. Firstly, the finite element analysis on the wing was carried out by using Ansys software to obtain the strain and force simulation data, then the simulation data was cleaned and preprocessed. Secondly, a deep neural network model was constructed, its input and output were the strain and load values, respectively. The Adam optimization algorithm was used to optimize the model for load calculation. Finally, the test set was used to predict the load value, and the average relative error and absolute error were used as evaluation metrics. Experimental results show that the calculation method based on deep learning obtains the average absolute error of 0.081 N for small load data and average relative error of 0.063 8% for normal load data, respectively. The load accuracy of new method is obviously better than that of the traditional method comparing with traditional load calibration method.

Keywords: wing skin; load calculation; deep learning; strain; load calibration equation

0 引言

飞机载荷监测是飞机结构健康监测的重要组成部分,并且飞机载荷-时间历程也是飞机全尺寸疲劳试验的基础。机翼是飞机的重要组成部分,飞机引擎的驱动力是通过机翼形成向上的升力,与尾翼一起形成良好的稳定性与操纵性^[1]。机翼结构通常是由蒙皮、翼梁、纵梁、桁条、翼肋等构件组成。蒙皮用于构成和维持机翼外形,承受空气动力,并承受弯矩和扭矩^[2],如果机翼蒙皮因空气载荷出现损坏,很可能会导致飞机发生事故。因此,机翼蒙皮的载荷的监测与计算至关重要。载荷计算的通用方法是载荷标定方程,其原理来自美国的军用规范提出的计算飞行载荷的方法,在地面利用已知载荷和应变求出系数,然后在飞行中测量结构应变,即利用已知的系数推演飞机结构的载荷^[3]。为了提升载荷计算的精度,国内外专家在载荷方程的基础上提出了多种改进方法。侯乔乔等^[4]提出了一种改进的载荷标定实验数据回归算法,通过多元回归模型与多元二次回归模型对剪力和弯矩方程进行回归与数据对比,测试结果显示非线性模型的载荷方程比线性模型的载荷方程计算精度高。程凯等^[5]将载荷分解成多个相互垂直的分量,通过仿真指导标定,有效地提高了载荷测试的精度和效率。对于非对称结构,传统的载荷标定方法无法准确分离单向载荷引起的应变响应,从而引起测量误差。因此,吴波等^[6]建立的复合载荷方程可以通过通道响应分配因子识别出各向载荷引起的响应,进而获得较好的复合载荷校准结果。Wang 等^[7]提出了灰色关联度方法,用以找到传统载荷标定方程中的最优参数,进而构建载荷计算精度较高的应变-载荷方程。

基于以上的文献调研,目前载荷标定方程以及改进的方法均属于线性回归模型,即通过最小二乘法计算载荷方程的标定系数,然后,将采集的应变数据送入载荷方程估算出对应的载荷值。然而,线性载荷标定方程模型具有一定的局限性,包括:1)应变与载荷非线性关系表示能力弱,计算结构部件的载荷时,将结构件假设为弹性系统,是一种理想化处理方法,但是实际上,由于温度、结构复杂等多方面因素,载荷与应变之间的关系具有非线性。2)针对小载荷计算问题,线性载荷标定方程的载荷预测绝对误差较大^[4]。

针对以上问题,本文提出了一种基于深度学习的机翼蒙皮载荷计算新方法。考虑载荷方程建立与标定系数计算的复杂度,本文建立了机翼蒙皮等效模型,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机翼蒙皮载荷预测,用于提高蒙皮载荷计算精度,为机翼蒙皮载荷监测与计算提供新的理论方法支撑。

1 机翼蒙皮试验件建立与数据准备

1.1 机翼蒙皮试验件模型建立

在机翼蒙皮表面布置光纤光栅和施加载荷,可以得到准确且真实的数据。但是这种方式成本较高,可重复性较差,并且研究周期长,并且受到环境,温度等诸多客观因素影响。因此,利用试验件进行仿真模拟可以有效地克服这些障碍。机翼相邻桁条间的局部机翼蒙皮,曲度变化小,可以等效为一个无曲度的方形板^[2]。本文选择的机翼蒙皮试验件尺寸来源于歼-15 机翼相邻桁条间的局部机翼蒙皮。图1是歼-15 战斗机1:4 缩减样机的机翼图。




图1 歼-15 战斗机1:4 缩减样机的机翼图

Fig. 1 Wing diagram of 1:4 reduced prototype for J-15 fighter

图2为本文使用的试验件俯视图,该试验件的厚度为2 mm,材料选择航空铝。图3为机翼蒙皮试验件的三维结构图,其为对称结构。在做受力分析时,需固定结构件最左端的矩形部分,固定部分宽为50 mm、高为60 mm。机翼蒙皮一般承受弯矩和扭矩的作用。本文选择的载荷类型为弯矩,对比载荷方程与深度神经网络对弯矩的预测结果。




图2 机翼蒙皮试验件俯视图

Fig. 2 Top view of simplified wing skin test piece

1.2 数据采集与数据预处理

本文使用 Ansys 有限元仿真软件对结构件进行分析,Ansys 软件使用 19.0 版本。在有限元分析中,选择的




图3 机翼蒙皮试验件三维结构图

Fig. 3 Three-dimensional structure diagram of simplified wing skin test piece

材料为航空铝 7075-T6,弹性模量为 7.2×10^{10} Pa,泊松比为 0.33,有限元划分网格的大小为 $5 \text{ mm} \times 1 \text{ mm}$ 。在中轴线上的某一点施加载荷,载荷的范围为 $(0 \text{ N}, 90 \text{ N})$ 。在 Ansys 软件中最多可以施加 1 798 次载荷,每次加载的数据包含 3 个 dat 文件。3 个 dat 文件分别保存所有有限元块的 x, y, z 方向上的分应变值与总的相对应变值; x, y, z 方向上分力的大小和总应力值;施加载荷的大小和施加载荷的位置。

完成数据采集后,需要对采集的数据进行数据清洗。本实验是为实物载荷计算做前期准备,因此按照实物的光纤光栅粘贴位置筛选出 90 个光纤光栅布点测量的应变值。光纤光栅的布点位置如图 4 所示,试验件的上平面与下平面分别有 15 个光纤光栅区域,每一个光纤光栅区域取 3 个数据,共取出 90 个数据。



图4 光纤光栅布点示意图

Fig. 4 Schematic diagram of fiber Bragg grating distribution

对于清洗和筛选后的数据,通过观察数据的范围,发现数据中最大的应变值与最小的应变值差距较大。因此对应变数据进行标准化处理,使用 z-Score 标准化方法对数据进行标准化处理,标准化公式表示为:

$$z = \frac{x - \mu}{\sigma} \quad (1)$$

式中: μ 为均值; σ 为标准差;标准差的计算公式如式(2)所示。

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

载荷数据的范围为 $(0 \text{ N}, 90 \text{ N})$ 对载荷数据进行归一化处理,使所有的载荷值都处于 $[0, 1]$ 之间,归一化的公式为:

$$x_i^* = \frac{x_i - \min(x_1, \dots, x_n)}{\max(x_1, \dots, x_n) - \min(x_1, \dots, x_n)} \quad (3)$$

应变数据共有 1 798 组,每一组应变数据对应一个载荷。载荷分为小载荷与正常载荷,在实际的工程应用中,一般认为小于最大载荷的 10% 的载荷为小载荷。在本文中,小载荷的范围为 $0 \sim 10 \text{ N}$,正常载荷的范围为 $10 \sim 90 \text{ N}$ 。为了对比载荷方程与深度神经网络对载荷的测试效果,选择 30 组应变数据作为载荷方程与深度神经网络的共同测试集,剩余的 1 768 组数据作为神经网络的训练集。在测试集中,正常载荷数据共 20 组,小载荷数据共 10 组。使用 20 组正常载荷和 10 组小载荷测试神经网络模型的预测效果。

2 深度神经网络载荷计算模型

2.1 深度神经网络模型建立

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^[8-9],即任意两层网络结构之间的所有节点都有权值连接。图 5 为建立的基于深度神经网络的机翼蒙皮载荷计算模型,该网络分为 3 个部分,即输入层(input layer)、隐藏层(hidden layer)、输出层(output layer)^[10]。在本文中,深度神经网络的输入为每次施加载荷与其对应的应变值,输出为需要预测的载荷。因此输入层的神经元规模为 90,输出的神经元规模为 1。

图 5 中每一个节点表示一个独立的神经元,输入信息通过输入层传送至神经网络,经过隐藏层提取输入数据的特征信息,最后通过输出层输出特征信息对应的载荷值^[11]。




图5 深度神经网络载荷计算结构图

Fig. 5 Load calculation structure for deep neural network

在本文中,神经元的输入为经过预处理之后的应变数据 $[\varepsilon_1, \varepsilon_2, \dots, \varepsilon_{90}]$,每一组输入数据对应一个标签,标签值为应变对应的施加载荷。

输入层共 d 个神经元($d=90$),第 i 个神经元表示为 ε_i ,第 1 层隐藏层包含 q 个神经元,第 1 隐藏层第 h 个神经元表示为 a_h^1 ,第 1 隐藏层第 h 个神经元与输入层第 i 个神经元之间的权值为 w_{ih}^1 ,则隐藏层神经元 a_h^1 数学公式为:

$$a_h^1 = f\left(\sum_{i=1}^d w_{ih}^1 \varepsilon_i\right) \quad (4)$$

第 $m-1$ 层隐藏层共有 p 个神经元,第 $m-1$ 个隐藏层第 h 个神经元表示为 a_h^{m-1} ;第 m 层隐藏层共有 n 个神经元,则第 m 层第 k 个神经元 a_k^m 的数学公式为:

$$a_k^m = f(\sum_{i=1}^p w_{ih}^{m-1} a_h^{m-1}) \tag{5}$$

本文提出的深度神经网络模型中,输出层只有 1 个神经元(即载荷值),与第 m 层隐藏层第 k 个神经元之间连接的权值为 w_k^m ,则输出 F 的数学公式为:

$$F = f(\sum_{j=1}^n w_j^m a_j^m) \tag{6}$$

式中: F 表示神经网络输出的载荷值; a_j^m 为第 m 层隐藏层神经元的信息; f 为激活函数; w_j^m 为输出层与隐藏层之间的权重; n 为第 m 层对应隐藏层的神经元数量。

激活函数选择 sigmoid 函数,表达式为^[12]:

$$f(x) = \frac{1}{1 + e^{-x}} \tag{7}$$

2.2 模型训练与参数选择

在网络训练之前,需要确定损失函数,本文为载荷预测,即属于回归问题,因此损失函数采用均方误差损失函数^[13],可以表示为:

$$Loss = \frac{1}{2N} \sum_{i=0}^n (y - \hat{y})^2 \tag{8}$$

式中: N 表示样本的数目; y 表示真实的载荷值; $\hat{y}$ 表示载荷的预测值。均方误差可以理解为真实值与预测值之间的“距离”,损失函数的值越小,则说明模型的预测载荷越准确。当损失函数的值为 0 时,则说明模型预测的载荷值准确无误。

前向传播计算出预测值后,通过均方误差损失函数得到损失值,再通过链式法则计算出反向传播的梯度值 $\partial Loss/\partial w$,继而优化参数 w ,参数更新的表达式如下:

$$w <= w - \eta \frac{\partial Loss}{\partial w} \tag{9}$$

式中: $\partial Loss/\partial w$ 表示计算的梯度值,负号表示与梯度相反的方向, η 为学习率,用于控制参数优化的“步长”。如果学习率选取过大, y 值会发生振荡,甚至变大;如果学习率选取过小,虽然不会发生振荡,但是会导致收敛速度变慢,影响训练结果^[14-15]。

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,学习率为 0.000 1,优化方法为 Adam^[16-17],迭代次数为 1 000 次,激活函数选择 sigmoid 函数。使用网格搜索法选择 batch size 大小和网络深度,batch size 的大小选择 1~8,隐藏层层数选择 3~7。总训练时长约为 1.5 h,每个载荷推理时间小于 1 ms。通过网格搜索法,深度神经网络的超参数如表 1 所示。

表 1 深度神经网络超参数
Table 1 Super parameter of deep neural network

类别	超参数值
学习率	0.000 1
Batch size	1
优化方法	Adam
迭代次数	1 000
激活函数	sigmoid
隐藏层层数	4

设置好相关参数后,对深度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,以获得更准确的载荷预测值。

使用训练好的神经网络模型对 30 组应变数据的载荷进行预测,测试数据中,小载荷数据有 10 组,正常载荷数据有 20 组。

3 实验结果与分析

3.1 模型训练与参数选择

本文分别对小载荷数据(0 N,10 N)与正常载荷数据[10 N,90 N]进行评估,本文使用两种不同的评估方法评估载荷计算的精度。

载荷数据使用相对误差来评估载荷预测的精准度,使用平均相对误差来评判模型的整体效果。平均相对误差的表达式为:

$$real_error = \frac{1}{M} \sum_{i=1}^M \frac{|y_i - \hat{y}_i|}{y_i} \tag{10}$$

式中: y_i 表示真实载荷值; $\hat{y}_i$ 表示神经网络的预测值; M 代表测试集测试数据的数据数量。

在工程应用中,对小载荷的预测结果计算相对误差,很可能出现较大的相对误差结果。因此小载荷数据常使用绝对值差作为评价指标,绝对值差的表达式为:

$$abs_error = |y - \hat{y}| \tag{11}$$

式中: y 表示真实载荷值; $\hat{y}$ 表示神经网络的预测值。

3.2 载荷预测与结果分析

载荷预测分为小载荷(0 N,10 N)预测与正常载荷[10 N,90 N]预测。正常载荷[10 N,90 N]预测结果如表 2 所示,序号为不同载荷值的数据编号,共 20 组数据。

由表 2 可知,深度神经网络很好的预测了蒙皮试验件的载荷值[10 N,90 N],20 组真实数据与预测数据之间的相对误差均小于 0.3%,最大的相对误差为 0.047 72%,最小的相对误差为 0.000 06%,平均相对误差为 0.010 76%。

表 2 正常载荷预测结果

序号	真实值/N	深度神经网络	
		预测值/N	相对误差/%
1	46.4	46.30	0.002 91
2	34.9	34.95	0.002 32
3	53.7	53.64	0.003 65
4	40.8	40.76	0.015 8
5	49.0	48.93	0.000 06
6	73.7	73.68	0.011 5
7	71.7	71.66	0.010 8
8	33.8	33.77	0.002 78
9	71.9	71.94	0.011 0
10	50.7	50.68	0.001 52
11	61.6	61.63	0.007 38
12	36.8	36.77	0.000 05
13	76.8	76.79	0.012 3
14	53.6	53.56	0.003 45
15	43.7	43.71	0.047 7
16	27.9	27.89	0.008 89
17	42.1	42.08	0.024 8
18	41.5	41.52	0.021 0
19	24.7	24.66	0.013 2
20	86.8	86.76	0.014 4

小载荷(0 N,10 N)预测结果如图表 3 所示,小载荷测试数据共 10 组。

表 3 小载荷的预测结果

序号	真实值/N	深度神经网络	
		预测值/N	绝对值差/N
1	8.49	8.47	0.021 0
2	0.444	0.466	0.022 2
3	5.86	5.84	0.023 6
4	7.63	7.61	0.022 0
5	4.42	4.39	0.025 2
6	2.98	2.95	0.026 7
7	4.11	4.09	0.025 5
8	4.51	4.49	0.025 1
9	3.41	3.38	0.026 2
10	5.89	5.86	0.023 6

由表 3 可知,深度神经网络也较好的预测了蒙皮试验件的小载荷值,其中,最小的绝对误差只有 0.021 N,最大的绝对误差也只有 0.026 N,绝对值的差值均小于 0.03 N,平均的绝对误差为 0.024 12 N。

通过对正常载荷与小载荷的预测结果分析,深度神经网络的预测结果非常接近真实值。深度神经网络是通过多层非线性变换,对高复杂数据建模,得到预测结果。载荷与应变之间的关系会受到温度、结构复杂度等多方面因素的影响,线性关系较差。因此,非线性的深度神经

网络对载荷的预测结果更为精准。

3.3 与载荷方程计算结果比较与分析

为了与传统方法的计算结果做比较,在所有的应变数据中筛选出 90 组数据,用于计算载荷标定方程的标定系数。在选取数据时,保证相邻两个载荷值的差值相同,因此,本文选择[0 N,89 N]范围内的最靠近每个整数的载荷值,如最靠近 0 N 的载荷大小为 0.256 387 5 N,最靠近 1 N 的载荷大小为 1.001 642 4 N,共 90 组数据。根据美国军用规范提出的空测法,计算飞行载荷的公式为:

$$F=a\times\mu$$

(12)

式中: F 为标定的载荷值; a 为方程标定系数; μ 为标定载荷对应的应变值。在结构材料的可承受范围内,载荷与应变是线性关系。因此,通过地面标定,使用线性回归的方法,计算得到载荷方程的标定系数矩阵 a ,再根据计算的标定系数和应变计算出未知的载荷值^[18-19]。

表 4 为载荷标定方程与深度神经网络载荷对正常载荷[10 N,90 N)预测结果比较,从表中可以获悉,对大多数正常载荷,神经网络的预测结果均比载荷标定方程的预测结果更准确,相对误差更小。

表 4 正常载荷的相对误差对比

Table 4 Comparison of relative error for normal load			
序号	真实值/N	载荷标定方程的 相对误差/%	深度神经网络的 相对误差/%
1	46.4	0.038	0.002 91
2	34.9	0.080	0.002 32
3	53.7	0.852	0.003 65
4	40.8	0.230	0.015 8
5	49.0	0.280	0.000 06
6	73.7	0.229	0.011 5
7	71.7	0.022	0.010 8
8	33.7	0.120	0.002 78
9	71.9	0.012	0.011 0
10	50.7	0.119	0.001 52
11	61.6	0.199	0.007 38
12	36.8	0.214	0.000 05
13	76.8	0.022	0.012 3
14	53.6	0.166	0.003 45
15	43.7	0.017	0.047 7
16	27.9	0.106	0.008 89
17	42.1	0.224	0.024 8
18	41.5	0.104	0.021 1
19	24.7	0.111	0.013 2
20	86.8	0.084	0.014 4

为了更直观对比两种方法的预测结果,图 6 为载荷方程与深度神经网络预测正常载荷的相对误差对比图。表 5 为载荷标定方程和深度神经网络对小载荷(0 N,10 N)预测的绝对差值,图 7 为小载荷的绝对值差的对比图。




图 6 正常载荷的相对误差对比

Fig. 6 Relative error comparison for normal load

表 5 小载荷的绝对值差对比

Table 5 Comparison of absolute value difference for small load

序号	真实值/N	载荷标定方程的 绝对值差/N	深度神经网络的 绝对值差/N
1	8.49	0.677	0.021 0
2	0.444	0.396	0.022 2
3	5.86	0.568	0.023 6
4	7.63	0.679	0.022 0
5	4.42	0.338	0.025 2
6	2.98	0.344	0.026 7
7	4.11	0.339	0.025 5
8	4.51	0.456	0.025 1
9	3.41	0.341	0.026 2
10	5.89	0.569	0.023 6




图 7 小载荷的绝对值差的对比

Fig. 7 Comparison of absolute difference for small load

通过图 6 与 7 中的相对误差与绝对值差,以及平均相对误差与平均绝对值差,可以发现深度神经网络预测的载荷值更接近于真实值,且深度神经网络得到的预测值更具有普适性,对任意范围内的载荷都有着比载荷方

程更好的效果。特别对于小载荷预测时,深度神经网络的载荷预测效果极佳。在实际应用中,考虑飞机结构可能会因为环境温度等因素变化,造成应变和载荷关系具有非线性。相比于载荷方程,深度神经网络有很强的非线性表示能力,因此,深度神经网络模型能够较好的解决应变-载荷非线性预测问题。

4 结 论

本文提出了一种基于深度神经网络的机翼蒙皮载荷计算方法,将应变数据作为神经网络的输入,通过反向传播更新神经网络的参数,进而获得深度神经网络载荷计算模型。实现结果显示,基于深度学习的载荷预测平均相对误差与平均绝对值差分别为 0.011% 与 0.024 N,低于载荷方程的平均相对误差(0.16%)与平均绝对值差(0.47 N)。通过对比神经网络和载荷标定方程的预测结果可以得出,深度神经网络的预测结果更接近于真实值,对小载荷的预测效果尤为明显。通过分析,深度神经网络利用反向传播与随机梯度下降算法优化模型参数,即能够从大量参数中优化获得较优的参数建立模型。而载荷方程使用最小二乘法求解矩阵获得参数解,并没有优化参数过程,因此,模型预测精度较低。

尽管本文使用简单的机翼蒙皮结构件作为研究对象,但是本文成功的验证了基于深度神经网络方法在机翼载荷计算的适用性。后续将开展针对复杂机翼结构(如机翼骨架,整机机翼等)的载荷模型研究工作。通过分析,复杂机翼结构载荷预测,深度神经网络模型依然适用,即通过安装大量的传感器采集复杂结构载荷与应变数据,利用本文提出的深度神经网络建模方法,构建应用于复杂结构机翼载荷计算的神经网络模型,实现复杂机翼结构载荷预测。综上所述,本文提出的基于深度神经网络的载荷计算方法有效的提升了机翼载荷计算的准确度和推理速度,为飞机结构载荷监测与计算提供新的理论方法。

参考文献

[1] 段富海, 初雨田, 关文卿, 等. 变形机翼的发展现状综述[J]. 机电工程技术, 2021, 50(1): 12-18.
DUAN F H, CHU Y T, GUAN W Q, et al. Review of development status of morphing wing[J]. Mechanical & Electrical Engineering Technology, 2021, 50 (1): 12-18.
[2] 董秋阳. 机翼蒙皮在破片和冲击波作用下的损伤研究[D]. 南京: 南京航空航天大学, 2013.
DONG Q Y. Damage research of wing skins under projectile and shock wave [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2013.

- [3] 杨全伟, 舒成辉, 赵华. 飞机机翼载荷校准试验的有限元仿真方法[J]. 系统仿真学报, 2008, 20(23): 6569-6571.
YANG Q W, SHU CH H, ZHAO H. Finite element simulation method for aircraft wing load calibration test[J]. Journal of System Simulation, 2008(23): 6569-6571.
- [4] 侯乔乔, 张清勇. 一种改进的载荷标定试验数据回归算法[J]. 工程与试验, 2018, 58(4): 22-24.
HOU Q Q, ZHANG Q Y. An improved regression algorithm for load calibration test data[J]. Engineering & Test, 2018, 58(4): 22-24.
- [5] 程凯, 孟凡亮, 张关良, 等. 基于 CAE 仿真和矩阵标定的汽车零部件载荷测试方法[J]. 计算机辅助工程, 2016, 25(2): 43-47.
CHENG K, MENG F L, ZHANG G L, et al. Load test method for automobile components based on CAE simulation and matrix calibration[J]. Computer Aided Engineering, 2016, 25(2): 43-47.
- [6] 吴波, 孟敏. 复合受载的非对称结构载荷标定方法研究[J]. 航空科学技术, 2016, 27(8): 16-20.
WU B, MENG M. Research on calibration method of complex loaded asymmetrical structure[J]. Aeronautical Science & Technology, 2016, 27(8): 16-20.
- [7] WANG J R, JAU J S, LEE J H, et al. Apply grey relational grade in optimal airplane landing gear loads calibration[C]. International Conference on Intelligent & Advanced Systems. IEEE, 2008.
- [8] 尹宝才, 王文通, 王立春. 深度学习研究综述[J]. 北京工业大学学报, 2015, 41(1): 48-59.
YIN B C, WANG W T, WANG L CH. Review of deep learning[J]. Journal of Beijing University of Technology, 2015, 41(1): 48-59.
- [9] 刘斌, 李立欣, 李静. 一种改进的基于深度前馈神经网络的极化码 BP 译码算法[J]. 移动通信, 2019, 43(4): 8-14.
LIU B, LI X L, LI J. An improved polar BP decoding algorithm based on deep feedforward neural network[J]. Mobile Communications, 2019, 43(4): 8-14.
- [10] O'REILLY Japan, Inc. 深度学习入门-基于 Python 的理论与实现[M]. 陆宇杰, 译. 北京: 人民邮电出版社, 2018: 37-38.
O'REILLY Japan, Inc. Deep Learning from Scratch[M]. LU Y J, translated. Beijing: People's Posts and Telecommunications Press, 2018: 37-38.
- [11] 董珍一, 林莉, 孙旭, 等. 基于 BP 神经网络的超声表面波定量表征金属表层裂纹深度研究[J]. 仪器仪表学报, 2019, 40(8): 31-38.
DONG ZH Y, LIN L, SUN X, et al. Study on the quantitative characterization of metal surface crack depth through BP neural network combined with SAW technique[J]. Chinese Journal of Scientific Instrument, 2019, 40(8): 31-38.
- [12] 尤晓东, 苏崇宇, 汪毓铎. BP 神经网络算法改进综述[J]. 民营科技, 2018(4): 146-147.
YOU X D, SU CH Y, WANG Y D, Summary of BP neural network algorithm improvement [J]. Private Technology, 2018(4): 146-147.
- [13] 文洁. MSE 与 MAE 对机器学习性能优化的作用比较[J]. 信息与电脑(理论版), 2018(15): 42-43.
WEN J. Comparison of the effects of MSE and MAE on machine learning performance optimization [J]. China Computer & Communication, 2018(15): 42-43.
- [14] 周越. 基于深度神经网络的航空装配制孔毛刺预测与工艺优化[D]. 南京: 南京航空航天大学, 2019.
ZHOU Y. Burr prediction and process optimization of aeronautical assembly hole drilling based on deep neural network[D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2019.
- [15] 袁海英, 陈光, 谢永乐. 故障诊断中基于神经网络的特征提取方法研究[J]. 仪器仪表学报, 2007(1): 90-94.
YUAN H Y, CHEN G, XIE Y L. Feature extraction method in fault diagnosis based on neural network[J]. Chinese Journal of Scientific Instrument, 2007(1): 90-94.
- [16] KINGMA D P, BA J. Adam: A method for stochastic optimization [J]. arXiv preprint arXiv: 1412.6980, 2014.
- [17] NEWEY W K. Adaptive estimation of regression models via moment restrictions [J]. Journal of Econometrics, 1988, 38(3): 301-339.
- [18] 胡昌荣. 飞机飞行载荷测量载荷方程的优选[J]. 航空学报, 1994(1): 102-105.
HU CH R. The optimization of load equation during aircraft flight load measurement[J]. Acta Aeronautica Et Astronautica Sinica, 1994(1): 102-105.
- [19] 阎楚良, 张书明, 卓宁生, 等. 飞机机翼结构载荷测量试验力学模型与数据处理[J]. 航空学报, 2000, 21(1): 57-60.
YAN CH L, ZHANG SH M, ZHOU N SH, et al. Mechanical model and data processing of load measurement test for the airplane's wing structure[J]. Acta Aeronautica Et Astronautica Sinica, 2000, 21(1): 57-60.

作者简介



刘佳玮, 硕士研究生, 主要研究方向为智能检测与信息处理、机翼载荷计算。

E-mail: jwliuz@ sina. com

Liu Jiawei is a M. Sc. candidate in Beijing Information Science and Technology. His main research interest includes intelligent detection and information processing and wing load calculation.



于明鑫, 2015 年于北京理工大学获得博士学位, 现为北京信息科技大学的副教授, 主要研究方向为神经网络、图像识别、图像处理和人脑交互。

E-mail: 13810752119@ 163. com

Yu Mingxin received his Ph. D. degree in 2015. Now he is an associate professor in Beijing Information

Science and Technology University. His main research interests include neural networks, pattern recognitions, image processing and human-brain interaction.



祝连庆, 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 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 opto-electronic mechanical systems.