

## 专题——复杂载荷下的材料或结构疲劳损伤与寿命预测

神经网络技术在单机应变寿命监控  
中的应用研究

顾宇轩, 隋福成, 宋恩鹏

(沈阳飞机设计研究所, 沈阳 110035)

**摘要:** **目的** 解决单机应变监控载荷模型中非线性问题带来的误差。**方法** 基于人工神经网络技术, 结合某型飞机典型盒段试验件有限元模型, 建立用于单机应变寿命监控的神经网络载荷模型, 利用随机选取的测试数据对模型的精确性进行验证, 并与多元线性回归模型进行对比分析。**结果** BP 神经网络载荷模型的预测值比较贴近实测值, 同时要优于多元线性回归模型的预测结果。**结论** BP 神经网络载荷模型可以用于单机应变监控, 而且预测精度更高, 可以更加准确地把握平尾的损伤情况。

**关键词:** 应变监控; 神经网络; 载荷模型; 损伤

**DOI:** 10.7643/issn.1672-9242.2018.12.014

**中图分类号:** V215

**文献标识码:** A

**文章编号:** 1672-9242(2018)12-0074-04

## Application of Neural Network Technique in Individual Strain Life Monitoring

GU Yu-xuan, SUI Fu-cheng, SONG En-peng

(Shenyang Aircraft Design and Research Institute, Shenyang 110035, China)

**ABSTRACT:** **Objective** To solve the error caused by nonlinear problems in the single strain monitoring load model. **Methods** Based on the technique of artificial neural network and in combination with the finite element model of one airplane's typical box-section, a neural network load model used for ISM was established to validate its accuracy with random samples. **Results** The predictive value of BP neural network was close to the measured values of load model; and its prediction result was better than that of the multiple linear regression model. **Conclusion** The BP neural network load model is suitable for ISM. In addition, because of its high prediction accuracy, the damage of key parts could be monitored more accurately with the usage of neural network load model.

**KEY WORDS:** strain monitoring; neural networks; load model; damage

单机寿命监控作为一种先进的飞机寿命管理方法, 目前已经广泛应用于各类飞机。对于军用飞机而言, 飞机的平尾、垂尾等部件不同于机翼、机身, 其内部应力与飞机重心处过载不存在线性关系或其他能表达出的关系, 所以我国目前广泛使用的基于当量损伤的参数型监控方法并不适用。为了把握飞行过程中垂尾、平尾的损伤情况, 需要对其采用单机应变监

控<sup>[1]</sup>, 作为参数型单机寿命监控的补充。

单机应变监控的关键在于载荷模型的建立, 由于现代飞机结构复杂, 传力路径多, 传统的多元线性回归模型可能无法解决非线性问题带来的误差。因此文中提出利用 BP 神经网络建立某型飞机典型盒段试验件载荷模型, 与多元线性回归模型的预测结果进行对比, 验证神经网络载荷模型的精确性和优势。

## 1 人工神经网络模型原理

人工神经网络<sup>[2]</sup>是对生物神经系统高度简化后获得的一种神经网络模型，目前已经广泛应用于航空、航天、汽车、金融等领域。其中应用普及率最高的就是 BP（误差反向传播）神经网络。

BP 神经网络模型由输入层、隐含层、输出层构成，分为正向传播和反向传播两部分，输入信息经隐含层处理后传至输出层。

隐含层输出：

$$y_i = \Phi(\text{net}_i) = \Phi\left(\sum_{j=1}^M \omega_{ij}x_j + \theta_i\right) \quad (1)$$

输出层输出：

$$O_k = \Phi(\text{net}_k) = \Psi\left(\sum_{i=1}^q \omega_{ki}y_i + a_k\right) = dy$$

$$\Psi\left(\sum_{i=1}^q \omega_{ki}\Phi\left(\sum_{j=1}^M \omega_{ij}x_j + \theta_i\right) + a_k\right) \quad (2)$$

当输出层输出没有达到期望输出的时候，模型会把误差信号沿连接路径返回，修正各层之间的连接权值、阈值，如此循环直到输出层输出达到期望输出。算法流程如图 1 所示。




图 1 BP 神经网络算法流程

## 2 人工神经网络在应变监控中的应用

### 2.1 单机应变寿命监控方法

单机应变监控是通过在主要受力构件的合适位置加装应变片，构成测载应变计电桥，结合静力试验数据，找到测载应变计对于施加载荷的响应值，即载荷模型。利用飞机飞行过程中应变计记录的应变数据，再结合细节有限元分析获得关键部位的应力数据，根据基于名义应力算法推导出的当量损伤计算公

式<sup>[3]</sup>：

$$D_k = \sum [(S_{\max,i} - S_{\min,i})^{m/2} (S_{\max,i})^{m/2}] \quad (3)$$

计算出飞机某次飞行过程中监控部位的损伤值  $D_k$ 。根据飞机的典型飞行任务谱块，计算出谱块总损伤  $D_S$ ，结合单位谱块的飞行小时数  $T_S$ 、单机应变监控获得的损伤  $D_k$  及寿命要求规定的飞行小时  $T$  计算出某次飞行过程中的寿命消耗  $T_{\text{cost},k}$  和剩余寿命  $T_R$ ，合理安排飞机的飞行任务及维护、维修时间。

$$T_{\text{cost},k} = D_k \times \frac{T_S}{D_S} \quad (4)$$

$$T_R = T - \sum T_{\text{cost},k} \quad (5)$$

建立准确的载荷模型是单机应变监控的重要一环，传统的多元线性回归模型<sup>[4-5]</sup>无法解决飞机结构复杂，传力路径多等因素带来的非线性问题，造成预测误差较大，而 BP 神经网络模型却可以很好地解决这一问题，建立较为精确的载荷模型。

### 2.2 数据选取

某型飞机典型盒段试验件的监控部位如图 2 所示。监控部位-1 为下壁板口盖中心孔处（盒段中间），监控部位-2 为下壁板口盖中心孔处（盒段靠近端肋一侧）。由于中心孔周围存在凹陷，所以直接使用应力集中的相关公式对孔边的最大应力进行计算可能会造成一定的误差。文中采用神经网络模型建立考核部位的载荷模型，即应变数据与应力集中部位应力的转换关系。




图 2 某型飞机典型盒段监控部位

监控部位-1、监控部位-2 结构相似，所以二者的载荷模型具有通用性，结合结构的对称性以及应变片的粘贴位置（如图 3 所示），建立有限元简化模型如图 4 所示。

根据应变片的粘贴位置，在有限元模型上找到对应的节点。模拟不同的载荷工况，对有限元模型进行加载，获得应力集中处的应力值，再结合几何应力集中系数，即可得到用于疲劳寿命分析使用的名义应力及其对应的三个应变片节点的应变信息，见表 1。




图3 试验件贴片位置




图4 有限元简化模型

利用表1中的数据建立BP神经网络载荷模型。随机选取第3、6、12、18组数据作为预测数据,用于验证载荷模型预测结果的准确性,其余21组数据作为训练数据对建立的神经网络载荷模型进行训练。同时利用多元线性回归建立载荷模型,同样对四组测试样本的载荷情况进行预测,作为BP神经网络载荷模型的对比数据。

## 2.3 拓扑结构的确定

构建BP神经网络模型首先要确定网络的层数以及每层的节点数。本文的目的是建立载荷模型,所以输入为应变数据  $\varepsilon_1$ 、 $\varepsilon_2$ 、 $\varepsilon_3$ ,输出为加载载荷  $F$ 。由此可以确定输入层节点数为3,输出层节点数为1。

选取一个合适的隐含层单元数对于神经网络的成功构建具有很大的影响。隐含层节点数的确认目前并没有一个确切的解析式,往往是根据前人设计所得和自己进行试验来确定<sup>[6]</sup>:

$$n = \sqrt{n_i + n_o} + a \quad (4)$$

式中: $n$ 为隐含层节点数; $n_i$ 为输入层节点数; $n_o$ 为输出层节点数; $a$ 为取值在1~10之间的调整系数。

表1 BP神经网络模型原始数据

| 序号 | 应力 $\sigma/\text{MPa}$ | $\varepsilon_1$ | $\varepsilon_2$ | $\varepsilon_3$ |
|----|------------------------|-----------------|-----------------|-----------------|
| 1  | 198                    | 2.84            | 2.53            | -44.1           |
| 2  | 384                    | 5.5             | 4.91            | -85.4           |
| 3  | 577                    | 8.26            | 7.36            | -128            |
| 4  | 769                    | 11              | 9.81            | -171            |
| 5  | 961                    | 13.8            | 12.3            | -213            |
| 6  | 1150                   | 16.5            | 14.7            | -256            |
| 7  | 1350                   | 19.3            | 17.2            | -299            |
| 8  | 1540                   | 25.2            | 21.3            | -341            |
| 9  | 192                    | 2.75            | 2.45            | -42.7           |
| 10 | 369                    | 5.36            | 4.59            | -76.9           |
| 11 | 561                    | 8.11            | 7.04            | -120            |
| 12 | 754                    | 10.9            | 9.49            | -162            |
| 13 | 946                    | 13.6            | 11.9            | -205            |
| 14 | 1140                   | 16.4            | 14.4            | -248            |
| 15 | 1330                   | 18.8            | 16.2            | -290            |
| 16 | 1520                   | 24.1            | 20.9            | -333            |
| 17 | 162                    | 2.46            | 2.22            | -25.7           |
| 18 | 377                    | 5.43            | 4.75            | -81.1           |
| 19 | 546                    | 7.97            | 6.27            | -111            |
| 20 | 739                    | 10.7            | 9.17            | -154            |
| 21 | 931                    | 13.5            | 11.6            | -196            |
| 22 | 1120                   | 16.2            | 14.1            | -239            |
| 23 | 1320                   | 19              | 16.5            | -282            |
| 24 | 1510                   | 23.4            | 19              | -325            |
| 25 | 354                    | 4.27            | 5.21            | -68.4           |

通过式(4)确定隐含层节点数范围为2~12,再根据试验法最终确定隐含层节点数  $n=5$ ,神经网络的拓扑结构为3-5-1,如图5所示。




图5 神经网络模型拓扑结构

通过观察表1中的原始数据可以发现,原始数据的跨越性比较大<sup>[7]</sup>。虽然神经网络的容错率以及适应性较强,但是直接将数据用于训练,很可能会造成训练时间过长,同时也会影响最终的预测结果。因此需要对训练数据进行预处理,利用Matlab中的归一化函数mapminmax对原始数据进行处理,使得处理后的数据落在[-1,1]这个区间内,以便用于训练。

隐含层神经元的传递函数选择logsig函数,输出层神经元的传递函数则选择purelin函数,学习函数选择learngdm函数,性能函数选择mse函数。为了可以更快获得精度较高的预测结果,训练函数选择trainlm函数<sup>[8-9]</sup>。设置网络相关系数,包括最大迭代

次数为 500，学习率为 0.2，容许误差为  $10^{-4}$ 。

设置好相关参数后，对神经网络模型进行训练，由于网络的阈值及连接权值的初始值是随机选取的，需要在训练过程中不断地修正，所以需经过多次训练以获得更加理想的结果。经过训练，神经网络模型在第 49 步达到收敛，训练结束。

利用训练好的神经网络载荷模型对四组预测数据的孔边最大应力进行预测。

3 结果对比

为了获得对比数据，建立多元线性回归模型，对四组应变数据对应的应力集中处应力进行预测。

3.1 预测结果对比

神经网络载荷模型及多元线性回归模型的预测结果见表 2。

表 2 载荷预测结果对比

| 序号 | 实测值<br>/MPa | BP 神经网络<br>预测值/MPa | BP 神经网络<br>预测误差/% | 多元线性回归<br>预测值/MPa | 多元线性回归<br>预测误差/% |
|----|-------------|--------------------|-------------------|-------------------|------------------|
| 3  | 577         | 575.2              | 0.3               | 592.7             | -2.72            |
| 6  | 1150        | 1145.5             | 0.39              | 1138.5            | 1.01             |
| 12 | 754         | 755.8              | -0.23             | 752.9             | 0.14             |
| 18 | 377         | 376.3              | 0.3               | 399.2             | 5.90             |

3.2 结果分析

通过观察表 2 中的对比结果可以发现，BP 神经网络载荷模型的预测值比较贴近实测值，同时要优于多元线性回归模型的预测结果。这是因为飞机结构复杂等因素导致的非线性问题带来的误差，而神经网络模型却很好地解决了这一问题。

4 结语

文中提出了将神经网络技术用于单机应变监控，并通过建立某型飞机典型盒段神经网络载荷模型，对比预测结果加以验证。通过对比神经网络载荷模型与多元线性回归载荷模型的预测结果得出，神经网络载荷模型的预测精度更高，更适合用于单机应变监控。对于神经网络模型，训练数据越多，神经网络载荷模型拟合度越好，预测结果越精确，在工程使用中可以通过增加训练数据的方法来提高神经网络模型的预测精度。

参考文献：

[1] 刘文斑，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.

[2] 胡守仁，余少波. 神经网络导论[M]. 长沙：国防科技大学出版社，1993.

[3] 陈志伟，朱青云. 战斗机单机寿命监控中起飞重量的影响[J]. 航空学报，2009，30(4): 678-682.

[4] 尚琳，何发东. 基于神经网络的垂危飞行载荷模型研究[J]. 强度与环境，2011，38(5): 49-53.

[5] 张赐宝，滕申科. 基于 BP 神经网络的三角机翼飞行载荷模型研究[J]. 工程与试验，2014，54(3): 5-8.

[6] 李友坤. BP 神经网络的研究分析及改进应用[D]. 安徽：安徽理工大学，2012.

[7] 张佰清，潘启树. 提高 BP 网络训练速度的研究[J]. 哈尔滨工业大学学报，2001，33(4): 439-441.

[8] 周开利，康耀红. 神经网络模型及其 Matlab 仿真程序设计[M]. 北京：清华大学出版社，2005.

[9] 王小川，史峰. Matlab 神经网络 43 个案例分析[M]. 北京：北京航空航天大学出版社，2013.