

doi: 10.7690/bgzdh.2020.06.002

基于 BAS-BP 神经网络的多应力加速寿命试验预测方法

葛峰^{1,2}, 韩建立¹, 高松^{1,3}

(1. 海军航空大学, 山东 烟台 264001; 2. 中国人民解放军 92419 部队, 辽宁 兴城 125106;
3. 中国人民解放军 91115 部队, 浙江 舟山 316000)

摘要: 为解决多应力条件下加速寿命试验中建立复合加速模型困难、模型参数难以求解以及建模过程中通常忽略应力间耦合作用问题, 根据天牛须搜索建立改进的 BP 神经网络模型。使用多应力加速寿命试验中收集的 4 组应力水平的失效数据对 BAS-BP 神经网络模型进行训练, 对第 5 组应力水平下的可靠度与失效时间进行预测。利用平均相对误差、拟合优度 2 个参数对模型的预测结果进行评价, 并与 BP 神经网络的预测结果进行对比。结果表明, BAS-BP 神经网络具有更好的准确性及鲁棒性。

关键词: 天牛须算法; 多层感知神经网络; 多应力加速模型; 预测方法

中图分类号: TP393.02 **文献标志码:** A

Multi-stress Accelerated Life Test Prediction Method Based on BAS-BP Neural Network

Ge Feng^{1,2}, Han Jianli¹, Gao Song^{1,3}

(1. Navy Aviation University, Yantai 264001, China;
2. No. 92419 Unit of PLA, Xingcheng 125106, China;
3. No. 91115 Unit of PLA, Zhoushan 316000, China)

Abstract: In order to solve the problems of establishing complex acceleration model in accelerated life test under multi-stress conditions, the model parameters are difficult to solve and the stress coupling problem is usually neglected in the modeling process, an improved BP neural network model is established according to beetle antennae search (BAS). The BAS-BP neural network model was trained using the failure data of the 4 sets of stress levels collected in the multi-stress accelerated life test to predict the reliability and failure time of the 5th set of stress levels. The prediction results of the model were evaluated by using the average relative error and the goodness of fit, and compared with the prediction results of BP neural network. The results show that the BAS-BP neural network has better accuracy and robustness.

Keywords: BAS; multilayer perceptron neural networks (MLPNN); multi-stress acceleration model; prediction method

0 引言

加速模型是正确反映产品寿命与各环境应力之间数学关系的基础。在利用加速寿命试验数据预测产品寿命时, 通常采取利用加速模型来外推计算的方法, 从而得到正常应力作用下产品的寿命^[1]。对于多应力条件下加速模型的建立, 目前通常采取参考成熟的单应力加速模型进行复合的方法建模, 选择适用的单应力模型对于复合模型影响较大。实际中多应力作用于产品造成的失效形式多样、机理过程复杂, 各应力之间也存在着相互影响, 通常难以获得应用广泛、客观准确、表达直观的加速模型。此外, 基于此模式建立的多应力加速模型存在难以忽视的缺陷: 1) 研究人员在建模过程中普遍进行了各类假设, 最常见的假设是忽略各应力之间的耦合

作用, 认为各个应力间互相独立、互不作用, 人为地忽略各应力之间的综合影响, 基于该假设建立模型描述反映的客观性和正确性存在瑕疵; 2) 建立的多应力加速模型存在着许多待定参数, 而且随着加速模型考虑的应力数量的增多, 形式越来越复杂, 同时也造成模型难以求解, 降低了预测精度^[2-3]。

随着机器学习、数据挖掘算法及计算机科技的不断进步, 一些学者尝试将多层感知神经网络 (multi-layer perceptions, MLP)、支持向量机 (support vector machines, SVM)、深度信念网络 (deep belief network, DBN) 等机器学习算法引入产品寿命预测工作中, 建立基于机器学习的非参数模型, 通过加速寿命试验数据对模型进行训练, 利用机器学习模型强大的数据挖掘、处理能力, 通过样本训练总结试验数据规律, 准确地寻找出产品寿命

收稿日期: 2020-02-29; 修回日期: 2020-04-03

作者简介: 葛峰(1988—), 男, 山东人, 硕士, 助理工程师, 海军导弹装备综合保障研究。E-mail: 105375796@qq.com。

和多应力水平之间错综复杂的数学映射规律，并运用总结规律去预测不同应力水平下的产品寿命。WANG 等^[4]建立基于时间序列-BP 网络相结合的预测模型，利用模型开展了冷却风机剩余寿命的预测；MAIOR 等^[5]建立一种经验模态分解-SVM 预测模型，对电动机的寿命进行预测，结果较单纯 SVM 模型更加精确；张国辉^[6]建立了 DBN 寿命预测模型对轴承健康状态进行预测，并利用 DBN-RVM 融合模型对锂离子电池剩余寿命进行预测。基于机器学习的非参数预测方法主要由多应力加速寿命试验数据的收集、采用经验分布函数法确定可靠度与产品失效时间数据的关系、构造机器学习预测模型和采

用构造的模型进行预测 4 个步骤构成。

笔者探索利用天牛须搜索优化的 BP 神经网络模型预测多应力下产品寿命的方法，并与单纯的 BP 模型进行比较分析，检验模型实际效果，主要研究内容为：1) 基于 BAS-BP 神经网络预测模型的建立；2) 多应力加速寿命实验的数据处理；3) 利用 BAS-BP 神经网络模型进行预测；4) BAS-BP、BP 模型预测结果的比较检验。

1 模型的建立

基于机器学习的非参数预测模型评估步骤如图 1 所示。

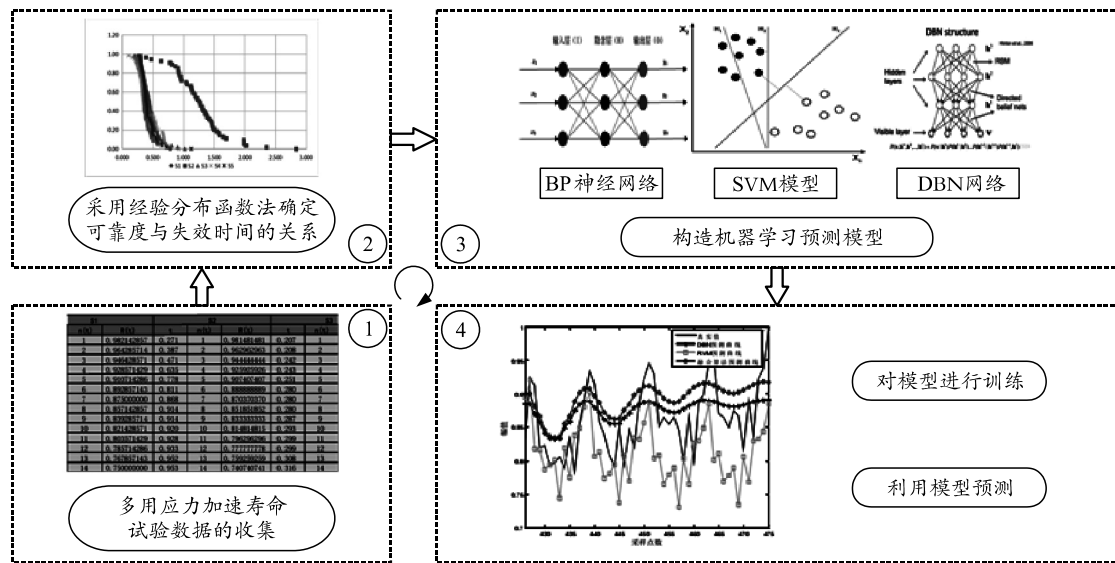


图 1 基于机器学习的非参数预测模型评估流程

1.1 BP 神经网络原理

1986 年，以 Rumelhart 和 McCelland 为首的科学家小组提出 BP (back-propagation) 神经网络，是一种在学习训练时采用反向传播算法对权值、阈值进行动态调整的多层前馈神经网络^[7]。根据 Kolmogorov 定理，存在一个 3 层神经网络，能精确实现任意连续映射，BP 神经网络具备拟合任意非线性函数的能力，广泛应用于图像识别、目标分类和数据压缩等领域，在寿命预测方面取得了突出效果。BP 神经网络的拓扑结构如图 2 所示，一般包括输入层、隐含层和输出层，可通过增加隐含层或隐含层单元数的方式柔性调节网络的结构，其基本算法包括信号的前向传播及误差的反向传播，采用梯度下降方式动态调整网络权值、阈值，使得网络输出值与期望输出值的误差均方差最小，经反复学习训练，直至达到预设的学习次数或者满足预定的训练输出误差。




图 2 BP 网络拓扑结构

1.2 BAS 天牛须搜索原理

天牛须搜索 (beetle antennae search, BAS) 算法由 Jiang 和 Li 等^[8-9]在 2017 年提出，是一种根据长须天牛检测和找寻食物的生物行为得出的仿生启发式算法，通过模仿自然界中天牛须的寻找功能和随机行走机制来实现检测和搜索功能，在解决多目标函数优化问题方面表现出了广泛的适用性和有效性，具备简单灵活、避免局部最优解、适合高维搜索的特点。基本原理：当天牛寻找食物或配偶时，

会摆动身体两侧的长触须，据此以随机方向探索附近空间的信息浓度，当一侧天牛须探测到的信息浓度高于另一侧时，天牛将向信息浓度高的一侧移动，而后再进行随机方向信息浓度探索比较，如此循环往复最终找到食物或配偶。天牛须搜索原理见图 3。




图 3 天牛须搜索原理

模型建立步骤如下：

1) 创建表示天牛须搜索行为的随机方向向量：

$$\mathbf{b} = \frac{\text{rands}(k,1)}{\|\text{rands}(k,1)\|} \quad (1)$$

式中：rands(•)为随机函数； k 为空间维度。

2) 创建模仿天牛左右须搜索行为的左右须空间坐标：

$$\left. \begin{aligned} x_{tr} &= x^t + d^t \mathbf{b} \\ x_{tl} &= x^t - d^t \mathbf{b} \end{aligned} \right\} \quad (2)$$

式中： x^t 为第 t 次寻找时天牛的空间位置； x_{tr} 为第 t 次寻找时天牛右须的空间位置； x_{tl} 为第 t 次寻找时天牛左须的空间位置； d^t 为第 t 次寻找时天牛须长。

3) 创建模仿天牛搜索行为的移动模型：

$$x^{t+1} = x^t - \delta^t \mathbf{b} \text{sign}[f(x_{tr}) - f(x_{tl})] \quad (3)$$

式中： x^{t+1} 为第 $t+1$ 次寻找时天牛的空间位置； x^t 为第 t 次寻找时天牛的空间位置； δ^t 为第 t 次天牛检测移动的步长；sign(•)为符号函数； $f(\bullet)$ 为适应度的函数。

1.3 BAS-BP 神经网络模型的建立

由于 BP 算法初始权值、阈值是采取随机初始化方式取得，学习过程中采用梯度下降方式动态调

整权值和阈值，搜索调整时容易陷于局部最优、速度慢等问题。笔者先建立天牛须搜索与 BP 神经网络相结合的模型，通过天牛须搜索对 BP 网络初始权值、阈值进行寻优，然后使 BP 网络在寻优的基础上开展后续的学习训练，从而加快收敛进程、避免陷入局部最优，最终提高预测模型的准确性^[10]。建模步骤如下：

1) 确定适应度函数。以模型输出值与期望输出值的均方误差 MSE 为适应度函数，适应度函数最小时对应的权值、阈值为最优解，适应度函数表示

$$F = \text{MSE} = \frac{1}{N} \sum_{i=1}^N (X_{\text{model},i} - X_{\text{ture},i})^2 \quad (4)$$

式中： N 为训练的样本数量； $X_{\text{model},i}$ 为第 i 个样本的模型输出值； $X_{\text{ture},i}$ 为第 i 个样本的实际值。

2) 创建表示天牛须搜索行为的随机方向向量。对于结构为 $n_{\text{sr}}-n_{\text{yhc}}-1$ 的 BP 网络，搜索空间维度就是需优化的权值与阈值数量之和， $k=n_{\text{sr}} \times n_{\text{yhc}} + n_{\text{yhc}} \times 1 + n_{\text{yhc}} + 1$ ，其中 n_{sr} 为输入层单元数， n_{yhc} 为隐含层单元数。

3) 确定天牛须长度 d^t 及搜索步长 δ^t ：

$$d^{t+1} = 0.95d^t + c; \quad (5)$$

$$\delta^{t+1} = 0.95\delta^t. \quad (6)$$

天牛须长度 d^t 对应天牛在搜索空间中的探索能力，其初始值应当足够大，使天牛在初始阶段可以跳出局部最优。 d^t 应随着搜索时间的延续而减小，以进行精确探索。天牛搜索步长 δ^t 关系着收敛速度，步长的初始值应当与搜索空间相适应，根据文献[8]天牛须长及步长衰减系数通常取 0.95， c 为常数。

4) 确定 BAS-BP 神经网络结构。

在 BAS-BP 模型中，输入层的 4 个单元为温度 T 、湿度 RH、电流 I 、可靠度 $R(t)$ 。输出层 1 个节点为失效时间 t 。对于隐含层单元数量的选取，可参考如下公式：

$$n_{\text{yhc}} = \sqrt{n_{\text{sr}} + n_{\text{sc}}} + c \quad (7)$$

其中： n_{sr} 为输入层单元数； n_{sc} 为输出层单元数； n_{yhc} 为隐含层单元数； c 为[1,10]间的常数。根据式(7)隐含层的取值范围为[4,12]，采用穷举法，计算每个隐含层取值对应的 MSE 值见表 1。

表 1 BAS-BP 模型隐含层取值与 MSE 关系

n_{yhc}	4	5	6	7	8	9	10	11	12
MSE	7.6×10^{-4}	7.7×10^{-4}	9.9×10^{-4}	5.1×10^{-4}	4.9×10^{-4}	9.1×10^{-4}	5.0×10^{-4}	8.2×10^{-4}	3.8×10^{-4}

可见，取值为 12，MSE 最小，则 BAS-BP 模型结构为 4-12-1，可以确定搜索空间维度

$$k = n_{\text{sr}} \times n_{\text{yhc}} + n_{\text{yhc}} \times 1 + n_{\text{yhc}} + 1 = 73。$$

初始化天牛在搜索空间中位置。各维度均随机

选取[-0.5,0.5]之间的随机数，确定天牛在搜索空间中的初始位置。

启动天牛进行搜索。根据式(2)–(6)计算天牛左右须的空间位置，比较天牛左右须所处适应度函数的大小，从而更新天牛的空间位置，以此启动天牛进行搜索，不断更新最优解及最优适应度。

确定最优解。若 MSE 小于预定精度或迭代次数达到要求，则停止天牛须搜索，此时最优适应度对应的解为最优解，利用其对 BP 网络的权值、阈值进行初始化。BAS-BP 预测模型具体流程如图 4 所示。

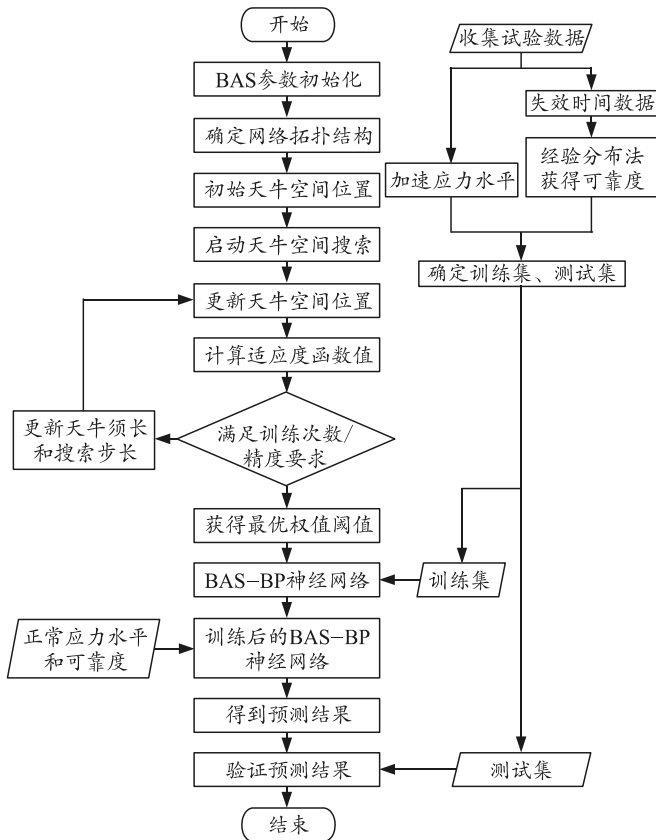


图 4 BAS-BP 预测模型具体流程

2 试验数据的处理

引用文献[11]中的各智能电表在温度、湿度、电应力不同水平作用下的试验数据进行分析，试验中 5 个应力水平见表 2 所示。

表 2 智能电表多应力加速寿命试验中应力施加情况

	<i>T</i> /°C	RH/%	<i>I</i> /A		
S ₁	80	80	60	56	0
S ₂	55	80	40	54	2
S ₃	55	95	20	56	0
S ₄	70	95	60	55	1
S ₅	70	95	40	56	0

根据表 2 中各应力水平作用下的试验结果，利

用经验分布函数的方法计算每个应力水平下的产品失效时间对应的可靠度：

$$R(t)=1-n(t)/N. \tag{8}$$

式中： $R(t)$ 为可靠度函数； $n(t)$ 为 t 时刻故障的试验样本个数； N 为试验样本数量。经计算，可得 5 个应力水平下对应的智能电表可靠度关系表，试验中 5 个应力水平下对应的智能电表可靠度与失效时间直线散点见图 5。




图 5 S₁–S₅ 应力水平对应下 $R(t)$ 、 t 的直线散点

选取 S₁、S₂、S₃、S₄ 应力水平作用下的 221 组数据作为后续 BAS-BP、BP 神经网络预测模型的训练集。将 S₅ 应力水平下 56 组数据设定为测试集来检验模型的预测效果。

3 模型验证

3.1 建立预测模型评价指标

为验证模型的预测结果，以平均相对误差 Are、拟合优度 Cod 2 个参数作为预测模型的评价指标^[12]。平均相对误差越小，说明模型的预测结果越好，拟合优度的值域为[0,1]，其计算值越接近 1，说明预测模型的效果越好，公式如下：

$$Are = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_{m,i} - y_{t,i}}{y_{t,i}} \right|; \tag{9}$$

$$Cod =$$

$$\frac{\left(n \sum_{i=1}^n y_{m,i} y_{t,i} - \sum_{i=1}^n y_{m,i} \sum_{i=1}^n y_{t,i} \right)^2}{\left[n \sum_{i=1}^n y_{m,i}^2 - \left(\sum_{i=1}^n y_{m,i} \right)^2 \right] \left[n \sum_{i=1}^n y_{t,i}^2 - \left(\sum_{i=1}^n y_{t,i} \right)^2 \right]}. \tag{10}$$

式中： n 为样本数量； $y_{m,i}(i=1,2,\dots,n)$ 为第 i 个样本的模型预测值； $y_{t,i}(i=1,2,\dots,n)$ 则为第 i 个样本的真实值。

3.2 BAS-BP、BP 神经网络模型的预测及比较

利用训练集中 221 组温度 T 、湿度 RH、电流 I 、可靠度 $R(t)$ 对预测模型进行训练，采用 BAS-BP 模型对 S₅ 应力水平下的 56 组数据进行预测，预测情况及相对误差见图 6。




图 6 BAS-BP 神经网络模型预测情况及相对误差

为验证 BAS-BP 模型预测的准确性与优越性，与 BP 模型预测结果进行对比，BP 模型预测情况及相对误差见图 7。




图 7 BP 神经网络模型预测情况及相对误差

从图 6、图 7 可知：BAS-BP 模型的预测精度较高，相对误差基本落在[-0.1,0.1]之间，预测值与实际值更加接近；BP 模型预测值在后段相对误差较大。根据式(9)、式(10)，从平均相对误差、拟合优度 2 个方面对模型预测效果进行对比，结果见表 3。

表 3 模型的预测效果对比

	/%	
BAS-BP	4.27	0.958 6
BP	9.17	0.748 1

对于工程中比较关心的中位寿命，即可靠度为 0.5 时对应的寿命，BAS-BP、BP 神经网络模型的预测情况见表 4。

表 4 BAS-BP、BP 模型中位寿命预测情况

	/%		
BAS-BP	0.391	0.396	1.28
BP	0.391	0.408	4.35

综上所述：相较于 BP 模型，BAS-BP 模型的预测效果优势明显，说明经过 BAS 算法优化的 BP 神经网络在预测性能上有较好的改善。

4 结束语

笔者探索了一种基于 BAS-BP 神经网络的多应力加速寿命试验预测方法，经训练、预测、检验和与 BP 模型的对比，说明 BAS-BP 神经网络模型具有较高的预测精度和良好的泛化性。

与传统的基于物理加速模型的寿命预测模型相比，以神经网络为代表的机器学习非参数预测模型具有的特点：1) 无需知晓具体的加速模型和产品寿命分布等信息，避免了建立多应力复合加速模型和求解最大似然方程组的困难^[13]；2) 建立和训练机器学习模型操作简单，泛化性、普适性较强^[14]；3) 随着机器学习算法、计算机技术的不断发展以及学者们不断研究、实践，将会不断提高机器学习算法的预测能力^[15]。

该模型也存在局限性，比如神经网络的训练需要大量的训练样本，在小样本情况下预测精度不高；神经网络模型能够学习试验数据中蕴含的规律信息，描述出试验数据与寿命之间的映射关系，但在表达形式上无直观的表达式，属于“黑箱”模型等。这些问题有待于进一步研究和完善。

参考文献：

[1] , . , 2007, 29(5): 828-831.
 [J]. , 2007, 29(5): 828-831.
 [2] , . , 2018-10-16.
 [P]. : CN108664690A, 2018-10-16.
 [3] , . , 2011-12-07.
 [P]. : CN102270302A, 2011-12-07.