

基于神经网络的机翼结构载荷模型建立方法

唐宁

(中国飞行试验研究院, 西安, 710089)

摘要 建立以飞行参数为变量的机翼结构载荷模型是飞行安全监控及飞机疲劳寿命估算的重要技术基础。首先将机翼燃油质量对其结构载荷的影响分离,在此基础上依据飞机结构载荷与飞行参数间的相关性,通过相关分析结合主成分分析的方法确定了低维数且互不相关的建模参数,并采用高斯-伯努利受限玻尔兹曼机预训练的BP神经网络方法实现了模型建立。以飞机跨音速俯仰机动为例,建立了机翼某测载剖面剪力模型,模型验证结果表明,预训练可有效降低模型初始误差,提升建模效率及精度。

关键词 机翼结构载荷;机翼燃油;神经网络;主成分分析;受限玻尔兹曼机

DOI 10.3969/j.issn.1009-3516.2021.04.007

中图分类号 V217+.1 **文献标志码** A **文章编号** 1009-3516(2021)04-0041-06

A Method of Establishing Wing Structural Load Model Based on Neural Network

TANG Ning

(Chinese Flight Test Establishment, Xi'an 710089, China)

Abstract The establishment of a wing structural load model with flight parameters as variables is an important technical basis for flight safety monitoring and aircraft fatigue life estimation. Firstly, the influence of wing fuel quality on its structural load is separated. On the basis of this and in accordance with the correlation between aircraft structural load and flight parameters, and the low-dimensional and the uncorrelated modeling parameters determined through correlation analysis combined with principal component analysis, a model is established by the BP neural network method pre-trained by Gauss-Bernoulli restricted Boltzmann machine. Taking the aircraft's transonic pitch maneuver for example, a shear force model of a certain measured load profile of the wing is established. The model verification results show that the pre-training can effectively reduce the initial error of model, and improve the modeling efficiency and accuracy.

Key words wing structure load; wing fuel neural networks; principal component analysis; restricted Boltzmann machine

飞机飞行过程中,机翼作为主要承载结构,受到气动力、重力、发动机推力及惯性力等载荷共同影响,在相应剖面上产生结构载荷,通过结构载荷实测,可在飞机服役及使用过程中对机翼结构实施载荷安全监控,并为结构疲劳寿命评估积累相关数据。

目前,一般采用应变法^[1]对机翼结构载荷进行测量,该方法通过载荷地面校准试验建立表征结构应变响应与结构所受载荷之间对应关系的载荷方程,在飞行实测过程中,通过实测应变与载荷方程确定结构载荷。但该方法存在地面试验成本较高且应变电桥

收稿日期: 2020-12-16

作者简介: 唐宁(1989—),男,四川广元人,工程师,研究方向:飞机飞行载荷测量。E-mail:158334240@qq.com

引用格式: 唐宁. 基于神经网络的机翼结构载荷模型建立方法[J]. 空军工程大学学报(自然科学版), 2021, 22(4): 41-46. TANG Ning. Establishing Method of Wing Structural Load Model Based on Neural Network[J]. Journal of Air Force Engineering University (Natural Science Edition), 2021, 22(4): 41-46.

受环境及人为因素影响难以长期可靠测量等问题,因此有必要在机翼结构载荷与飞行参数相关性的基础上建立一种以飞行参数为变量的机翼结构载荷模型。

应变法飞行实测数据能够真实反映机翼结构受载及其对应的飞行状态,因此可基于飞行实测数据建立模型,对此国内外已有相关研究开展^[2-5],采用了包含多元线性回归、BP神经网络(BPNN)及支持向量机回归(SVR)等方法,其中线性回归方法仅适用于线性模型,SVR方法建模效率受样本规模影响,BPNN方法拟合能力较强且建模效率受样本影响小,但该方法对网络初始权值敏感,可能因初值选取不当导致训练陷入局部最优而影响模型精度,考虑到真实飞行中机翼结构受载的复杂性,需要对建模方法进行合理选取。此外为保证所建立模型在不同机翼油量下的适用性,需将燃油对机翼结构载荷的影响予以分离。

针对上述问题,首先对机翼结构载荷中燃油受影响部分进行分离,其次采用高斯-伯努利受限玻尔兹曼机预训练的BP神经网络算法建立了机翼结构载荷模型,并通过跨音速俯仰机动条件下机翼剖面剪力对该方法的准确性及效率进行验证。

1 机翼燃油影响分离方法

对于机翼燃油影响分离的思路是根据燃油设计质量分布,将机翼测载剖面外的燃油简化为分布质量单元,不计机翼变形及飞机机动过程中的燃油晃动,分别计算不同油量下剖面外各质量单元惯性力及重力对剖面载荷的影响,对其进行累计得到总的燃油影响。对于质量为 m_i ,质心位于机体坐标系中点 $M(x_i, y_i, z_i)$ 的燃油质量单元,首先对其质心加速度进行计算以得到其所受惯性力,见图1。




图1 机翼燃油质量分布示意图

机体坐标系各坐标轴方向依照文献[6]中的规定,依据文献[7]中的飞机任意处机动过载修正方法,可得机动瞬时点 M 处在机体坐标系中的三向加速度为:

$$a_x = (n_x - 1)g + [-z_i \dot{q} + y_i \dot{r} + x_i (r^2 + q^2) - y_i p q - z_i p r] \quad (1)$$

$$a_y = n_y g + [-x_i \dot{r} + z_i \dot{p} + y_i (p^2 + r^2) - z_i q r - z_i q p] \quad (2)$$

$$a_z = n_z g + [y_i \dot{p} - x_i \dot{q} - z_i (p^2 + q^2) + x_i p r + y_i q r] \quad (3)$$

式中: p 、 q 及 r 分别为飞机的俯仰、滚转及偏航角速度; n_x 、 n_y 及 n_z 分别为飞机重心在机体坐标系各轴方向过载分量,在此基础上可确定质量单元惯性力。

对于质量单元的重力,利用机体坐标系与地面坐标系间转换矩阵 L_{bg} 将其投影到机体坐标系如下^[8],其中 F_{xbg} 、 F_{ybg} 及 F_{zbg} 分别为重力在机体坐标系各坐标轴的方向分量:

$$\begin{bmatrix} F_{xbg} \\ F_{ybg} \\ F_{zbg} \end{bmatrix} = L_{bg} \begin{bmatrix} 0 \\ 0 \\ m_i g \end{bmatrix} \quad (4)$$

垂直于机翼方向的燃油惯性力及重力分量为:

$$F_{M_i} = (F_{zbg} + m_i a_z) \cos \gamma + (F_{ybg} + m_i a_y) \sin \gamma \quad (5)$$

式中: γ 为机翼上反角。将各质量单元的惯性力及重力对剖面载荷的影响累加,即可确定其影响,在实测载荷结果中减去该影响量,可建立与机翼燃油质量无关的模型,该模型仅考虑气动力、机翼结构重力及惯性力的影响。对于不同油量下的模型预测结果,采用相同方法计算燃油质量影响,并将其叠加在模型计算结果上即可得到真实的机翼结构载荷。图2为采用了除以飞机重力的方式归一化处理对某型机翼根剖面结构剪力在俯仰机动过程中的燃油影响分离结果。为验证该分离结果的正确性,将剖面外机翼结构重力及惯性力的影响叠加在分离结果上以得到机翼根剖面外的气动力,因为飞机飞行过程中气动力主要由机翼产生,并因此产生过载,而俯仰机动中可用法向过载代表总过载。因此,根据机翼气动力计算所得过载应与实测法向过载基本一致,计算结果与此相符,从而间接表明了燃油影响分离结果的正确性。




图2 机翼燃油影响分离结果

2 建模参数选取方法

2.1 飞行参数与载荷相关性分析

建模参数的合理选取对建模精度及效率均有较大影响, 建立机翼结构载荷模型过程中, 首先应选取与机翼结构载荷相关性较高的飞行参数, 以避免引入无关参数对模型预测能力造成的不利影响。

飞机在空间中的机动可分为纵向、横向及航向 3 类, 每种机动的主要影响参数是不同的, 为避免引入过多无关参数, 应针对不同机动类型分别建立机翼结构载荷模型。

在初步选取参数的基础上, 基于飞行实测数据可通过相关系数对飞行过程中机翼结构载荷与飞行参数间的相关性进行量化分析, 计算方法如下^[9]:

$$r = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (X_i - \bar{X})^2} \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (6)$$

式中: X 和 Y 为包含 n 个样本点的变量; r 的取值范围为 $[-1, 1]$, $|r|$ 越接近 1, 两变量间的相关性越强, $|r|$ 为 0 时, 则两变量间无相关性, 依据工程经验, 在 $|r| < 0.3$ 时则认为该飞行参数与载荷相关性过低, 不作为建模参数。

2.2 主成分分析方法确定建模变量

通过上述相关性分析方法所确定的建模飞行参数仅能保证飞行参数与机翼结构载荷间的相关性, 但无法保证各参数间的互不相关性, 并且参数个数可能较多, 这些均会给建模效率及模型精度带来不利影响, 因此采用主成分分析方法^[10]对在初步确定的飞行参数基础上构建低维互不相关变量。

因主成分分析结果受量纲影响, 首先对各飞行参数进行归一化如下:

$$X_{\text{norm}} = \frac{X - X_{\min}}{X_{\max} - X_{\min}} \quad (7)$$

式中: X_{\max} 和 X_{\min} 为飞行参数的测试范围上下限, 一般在飞行前测试参数准备阶段均已确定。

主成分分析的目的是通过所不同实测飞行参数 X_1, X_2, \dots, X_p 的线性组合得到分散且彼此正交的主成分变量 Z_1, Z_2, \dots, Z_p 。

在主成分变量求解中, 对飞行参数 X_1, X_2, \dots, X_p 的协方差矩阵特征值及特征向量求解, 所得到的特征向量即为各主成分变量, 其对应的特征值 λ_i 既为各变量的重要程度, 将 λ_i 由大到小进行排序, 选取累计贡献率 $\sum_{j=1}^d \lambda_j$ 达到一定阈值的前 d 个特征向量

作为主成分变量进行建模, 一般取该阈值为 0.9。

3 机翼结构载荷模型建立方法

3.1 BPNN 算法原理

相关研究表明, 单隐层 BP 神经网络具有良好的非线性回归能力, 因此本文基于单隐含层 BP 神经网络进行机翼结构载荷模型建立, 其网络结构如图 3 所示, W_i 为相邻层间节点连接权值。




图 3 单隐含层 BP 神经网络结构

BP 神经网络训练算法分为信号前向传播和误差反向传播两部分, 其训练目标是通过相关优化方法迭代调整节点间的连接权值向量 ω , 从而最小化网络输出值 h 与训练目标 y 之间的差异函数 $e(\omega)$, 其表达式如下:

$$e(\omega) = \frac{1}{2} \sum_{i=1}^{d^{(L)}} (h(x_i) - y_i)^2 \quad (8)$$

本文采用列文伯格-马尔奎特(L-M)算法^[11]进行各连接权值更新, 该方法是一种改进的高斯-牛顿法, 具有二阶收敛速度且克服了牛顿法中 Hesse 矩阵计算量大且难以收敛的缺点。

3.2 BP 神经网络预训练方法

神经网络权值的初始化方法对求解效率及模型精度有较大影响, 不合理的初始权值会导致模型训练陷入局部最优, 从而无法得到全局最优解。一般 BP 神经网络初始权值采用随机赋值的方式初始化, 但实践表明, 该方法会导致不同初值条件下建模效率及精度的较大差异, 因此有必要对网络进行预训练, 以优化初始权值。

本文基于深度信念网络(DBN)训练方法, 采用 DBN 的组成单元受限玻尔兹曼机(RBM)^[12]对单隐藏层 BP 神经网络进行预训练, 再通过 BP 算法对网络进行精调。RBM 结构见图 4。




图 4 受限玻尔兹曼机网络结构

RBM网络结构分为可见层 \mathbf{v} 及隐层 \mathbf{h} , \mathbf{W} 为两层间的连接权重,因机翼结构载荷模型的输入为连续变量,故选择高斯-伯努利受限玻尔兹曼机^[13](GBRBM),其输入层单元节点为带独立高斯噪声的线性变量节点,隐层单元为二值的伯努利节点,其系统能量函数如下:

$$E(\mathbf{v}, \mathbf{h} | \boldsymbol{\theta}) = - \sum_{i=1}^n \frac{(v_i - b_i)^2}{2\sigma_i^2} - \sum_{j=1}^m c_j h_j - \sum_{i=1}^n \sum_{j=1}^m \frac{v_i}{\sigma_i} W_{ij} h_j \quad (9)$$

式中: σ_i 为可见层单元 i 的高斯噪声标准差,一般取值为1; $\boldsymbol{\theta} = \{\mathbf{W}, \mathbf{b}, \mathbf{c}\}$ 为RBM参数; b_i 和 c_j 分别为可见层及隐藏层偏置,由此可得RBM所定义的关于观测数据 \mathbf{v} 的分布 $P(\mathbf{v} | \boldsymbol{\theta})$,可表示为:

$$P(\mathbf{v} | \boldsymbol{\theta}) = \frac{\sum_{\mathbf{h}} e^{-E(\mathbf{v}, \mathbf{h} | \boldsymbol{\theta})}}{\sum_{\mathbf{v}, \mathbf{h}} e^{-E(\mathbf{v}, \mathbf{h} | \boldsymbol{\theta})}} \quad (10)$$

GBRBM训练的目标是最大化其在训练集上的对数似然函数 $L(\boldsymbol{\theta})$,其表达式为:

$$L(\boldsymbol{\theta}) = \sum_{l=1}^T \log P(\mathbf{v}^{(l)} | \boldsymbol{\theta}) \quad (11)$$

采用对比散度^[12](CD)方法对GBRBM进行迭代训练,实际训练过程中,由于飞行实测数据量较大,采用小批量分组方法^[14]将所有数据分为 Q 组,每组包含 K 个样本,则以最大化 $L(\boldsymbol{\theta})$ 为目标,基于随机梯度上升法更新参数组合 $\boldsymbol{\theta}$,对于每组数据,更新规则为:

$$\Delta \omega_{ij} = \varepsilon \left(\frac{1}{K} \sum_{k=1}^K (\langle v_{i,k} h_{j,k} \rangle - \langle v'_{i,k} h'_{j,k} \rangle) \right) \quad (12)$$

$$\Delta b_i = \varepsilon \left(\frac{1}{K} \left(\sum_{k=1}^K \langle v_{i,k} \rangle - \langle v'_{i,k} \rangle \right) \right) \quad (13)$$

$$\Delta c_j = \varepsilon \left(\frac{1}{K} \left(\sum_{k=1}^K \langle h_{j,k} \rangle - \langle h'_{j,k} \rangle \right) \right) \quad (14)$$

式中: ε 为学习率。重复上述过程直至达到最大训练迭代数 T_{\max} 。训练过程中可见层及隐藏层开启概率分别为式(15)及(16):

$$p(v_i = \mathbf{v} | \mathbf{h}) = N(\mathbf{v} | b_i + \sum_j h_j W_{ij}, \sigma_i^2) \quad (15)$$

$$p(h_j = 1 | \mathbf{v}) = s(c_j + \sum_i W_{ij} \frac{v_i}{\sigma_i}) \quad (16)$$

式中: $N(\cdot | \mu, \sigma^2)$ 为均值0,方差1的高斯概率密度函数; $s(x)$ 为sigmoid函数 $1/(1+e^{-x})$ 。

3.3 机翼结构载荷模型训练流程

通过GBRBM可对BPNN预训练并在此基础上实现机翼结构载荷模型建立,建模流程如图5所示。为保证建模效率,BPNN的迭代终止条件包含

3点:①训练误差低于指定值;②达到最大迭代次数;③在指定的迭代次数内训练误差未减小,满足其中之一即终止迭代。

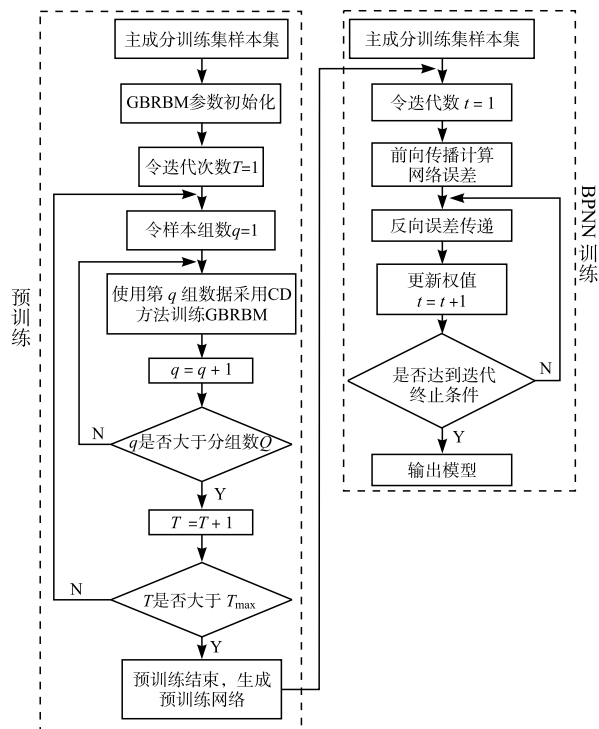


图5 机翼结构载荷模型训练流程

4 方法应用及分析

4.1 建模数据及变量确定

采用上述方法建立某机跨音速对称俯仰机动条件下机翼某载荷测量剖面剪力模型。在建模及验模数据集选取过程中,选择机动段数据进行建模及验模,为保证所建立的模型外推计算能力,选择了80%限制法向过载以下的机动数据进行建模,模型验证数据中包含了80%限制法向过载以上的机动数据,此外在选择建模及验模数据时,应保证一定的分散性,避免数据过于集中而降低所建立模型泛化能力。

在俯仰机动主要影响参数理论分析的基础上,进行相关系数计算及主成分分析,结果见表1,前3个主成分 P_1 、 P_2 及 P_3 累计方差贡献率为0.915,将其作为建模变量。

虽然俯仰机动过程中前缘襟翼发生偏转以改变机翼气动力,但相关性分析表明其与剖面剪力相关性不强,故不参与建模,剩余参数均与剖面剪力相关性较高,验证了依据俯仰机动理论分析所确定关键飞行参数的正确性,通过主成分分析,将建模变量数量由9个缩减至3个,且各变量相互正交,协方差为0,保证了各变量间互不相关。

表 1 飞行参数相关性及主成分分析结果

飞行参数	r	P_1	P_2	P_3
动压	0.775	0.288	0.161	-0.076
迎角	0.886	0.156	-0.351	0.062
左平尾偏度	-0.876	-0.209	0.014	0.038
右平尾偏度	-0.798	-0.178	0.025	0.045
左前缘襟翼偏度	-0.102	—	—	—
右前缘襟翼偏度	-0.065	—	—	—
俯仰角速度	0.695	0.157	-0.335	0.868
俯仰角加速度	0.579	0.024	0.145	0.003
机翼重心法向过载	0.942	0.514	0.030	0.164
发动机油门杆角度 1	-0.433	0.016	-0.084	0.115
发动机油门杆角度 2	-0.395	0.009	-0.095	0.126

4.2 BPNN 结构确定

隐藏层节点数量一般不小于 $(m+n)^{0.5}$, 其中 m 和 n 分别为输入层及输出层节点数量^[15]。选取不同隐藏层节点数量网络模型进行建模, 通过式(17)及(18)对模型预测结果进行评估。

$$e_{\text{residual}} = \frac{\max |L_i - \hat{L}_i|}{L_{\text{limit}}} \times 100\% \quad (17)$$

$$e_{\text{mean}} = \sqrt{\frac{\sum_{i=1}^n (L_i - \hat{L}_i)^2}{\sum_{i=1}^n L_i^2}} \times 100\% \quad (18)$$

式中: L_i 和 \hat{L}_i 分别为实测载荷及模型预测载荷; L_{limit} 为剖面限制载荷。通过这两个指标, 可分别从局部及整体精度两方面对模型精度进行评估, 结果见表 2。

表 2 不同结构网络模型预测结果

节点数	最大残差/%	平均误差/%
2	10.265	5.448
4	7.442	4.356
6	6.945	4.221
8	6.522	4.026
10	7.856	3.929
12	8.021	4.032

对比预测结果可以看出, 隐藏层节点数对于模型预测的平均误差影响不大, 但对于最大残差, 在节点数为 8 时达到最优, 对于隐藏层节点数应选取合理数值, 以避免 BP 神经网络模型中常见的过拟合现象发生。

4.3 结果分析

为检验预训练对 BP 神经网络初始误差的影响, 在其他网络参数相同的情况下, 对网络连接权值均随机初始化, 采用式(8)分别对有无预训练的网络模型初始误差进行多次计算, 结果见图 6。




图 6 有无预训练网络模型初始误差对比

可以看到, 虽然有无预训练 BP 神经网络的连接权值均采用随机初始化, 但经过预训练后, 其初始误差较未经预训练的分散性明显降低且量值较低, 避免了不同初值条件下模型训练收敛过程的较大不确定性导致迭代训练过程较长或过早陷入局部最优的问题。

在预训练确定的初始权值基础上, 通过 BP 神经网络算法对网络权值进行精调并完成机翼结构载荷模型建立, 使用验模数据集对所建立模型精度进行检验, 为进行对比, 使用相同数据集训练该 BP 神经网络模型, 其网络权值随机初始化, 训练过程收敛迭代数及验证精度对比见表 3。

表 3 模型收敛及验证精度对比

方法	收敛迭代数	最大残差/%	平均误差/%
GBRBM-BPNN	102	6.522	4.026
原始 BPNN	765	10.326	4.942

与原始 BPNN 模型相比, GBRBM-BPNN 模型迭代收敛数由 765 次下降到 102 次, 效率明显提升, 且模型预测最大残差由 10.326% 降低至 6.522%, 精度同样得以提高。

在达到限制过载时, 飞机迎角较大, 此时机翼表面可能出现气流分离从而导致其受载情况较为复杂, 而此时的载荷是结构受载严重情况评估的依据, 对模型的准确预测能力要求较高, 因此选取 90% 及 100% 正负限制过载状态下两种方法的预测结果进行对比, 结果见图 7(所有结果均采用除以该剖面限制载荷的方式归一化处理)。

在整个机动过程中, 飞机从稳定平飞状态开始, 逐渐改变俯仰姿态, 飞机迎角发生改变, 从而引起飞机过载及机翼载荷的同步变化, 直至飞机达到最大姿态。从两种模型预测结果对比可以看出, 在机动初始阶段, 飞机姿态改变较小, 机翼表面气流变化不大, 两种模型均能够准确预测机翼载荷, 而在飞机姿态改变接近并达到最大, 机翼载荷到达极值时, GBRBM-BPNN 模型较原始 BPNN 模型能够更准确的对载荷进行预测, 这表明了预处理对 BPNN 模型改进的有效性。

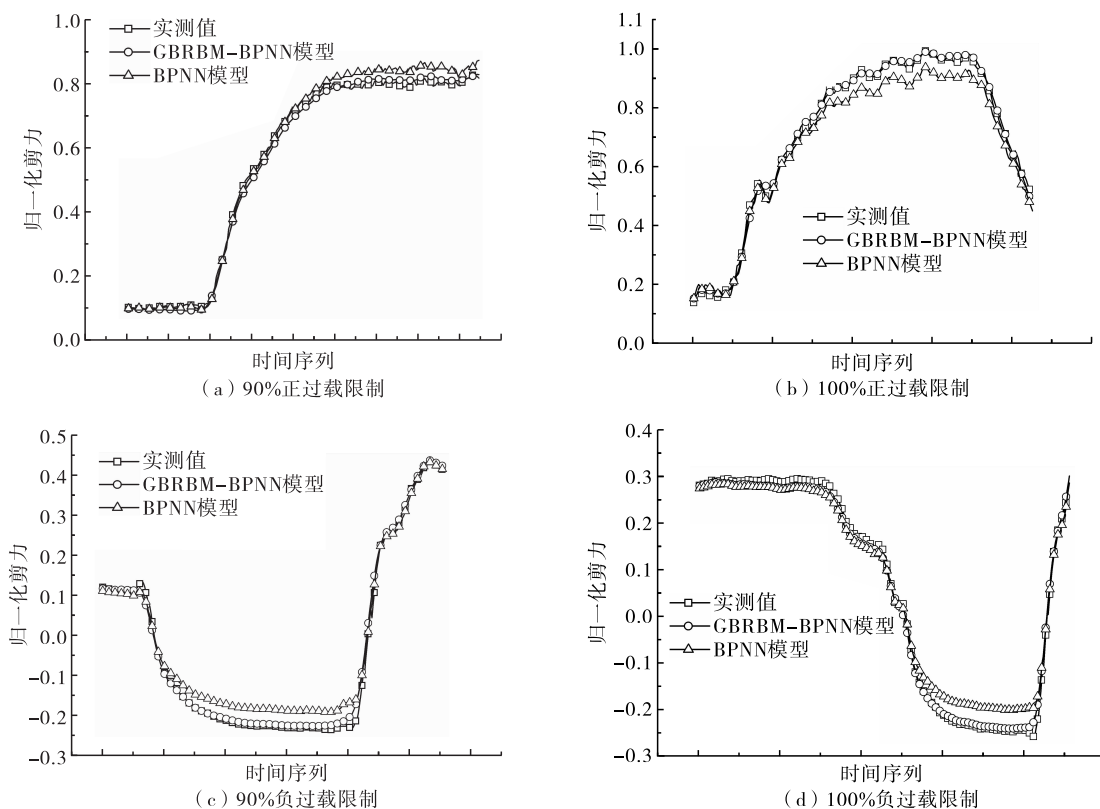


图7 机翼剖面剪力载荷模型检验结果

5 结论

1)通过机翼燃油对结构载荷的影响分离,可在飞机构型不变的条件下,令所建立模型适用于不同燃油质量;

2)通过相关性分析结合主成分分析的方法可有效对机翼结构载荷模型建模参数进行选取,达到降低建模参数维数和消除其相关性的目的;

3)通过使用GBRBM预训练的BP神经网络建模方法可实现对机翼结构载荷模型参数的高效识别,所建立模型精度较好,避免了随机网络初始权值引起的建模精度及效率问题。

参考文献

- [1] 蒋祖国,田丁栓.飞机结构载荷/环境谱[M].北京:电子工业出版社,2012:260-267.
- [2] MICHAEL J, RYAN P. Modeling Aircraft Wing Loads from Flight Data Using Neural Networks, NASA /TM-2003-212032[Z]. Edwards, California, 2003.
- [3] 曹善成,殷之平,黄其青,等.基于遗传神经网络的飞行载荷参数识别[J].航空计算技术,2013,43(1):61-64.
- [4] 赵燕,宋江涛,唐宁.某机翼的安全预测载荷模型建立[J].航空学报,2020,41(10):259-266.
- [5] 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.

- [6] 中华人民共和国国家质量监督检验检疫总局,中国国家标准化管理委员会.飞行力学概念、量和符号 第1部分 坐标轴系和运动状态变量:GB/T 14410.1—2008[S].北京:中国国家标准出版社,2008.
- [7] 《飞机设计手册》总编委会.飞机设计手册 第9册:载荷、强度与刚度[M].北京:航空工业出版社,2001:19-20.
- [8] 方振平,陈万春,张曙光.航空飞行器飞行动力学[M].北京:北京航空航天大学出版社,2010:20-22.
- [9] 何春雄,龙卫江,朱锋峰.概率论与数理统计[M].北京:高等教育出版社,2012.
- [10] 周志华.机器学习[M].北京:清华大学出版社,2016:105-106.
- [11] 马昌凤.最优化计算方法及其MATLAB程序实现[M].北京:国防工业出版社,2017:107-116.
- [12] 张春霞,姬楠楠,王冠伟.受限波尔兹曼机[J].工程数学学报,2015,32(2):159-173.
- [13] HINTON G E, SALAKHUTDINOV R R. Reducing the Dimensionality of Data with Neural Networks[J]. Science, 2006, 313(5786):504-507.
- [14] HINTON G E. A Practical Guide to Training Restricted Boltzman Machines[J]. Momentum, 2012, 9(1): 599-619.
- [15] 陈明. MATLAB神经网络原理与实例精解[M].北京:清华大学出版社,2017:165-166.

(编辑:姚树峰)