

一种研究逆向卸荷膜片式减压器稳定性的 BP神经网络改进算法

刘文英¹, 王拥军¹, 王宝山¹, 陈阳², 陈经禄¹

(1. 北京航空航天大学 数学与系统科学学院, 北京 100191;

2. 北京航空航天大学 宇航学院, 北京 100191)

摘 要: 为更好地研究多结构参数耦合变化下减压器 PPR (pressure reducing regulator) 的稳定性, 使用 BFGS (Broyden-Fletcher-Goldfarb-Shanno) 拟牛顿法替换梯度下降法, 实现了基于 Wolfe 条件的一维线搜索变步长 BP (back propagation) 算法。结果表明: 改进的 BP 算法使迭代次数减少了 1~2 个数量级, 且易于收敛到最小点。该算法用于逆向卸荷膜片式减压器时, 能适应 2~3 个结构参数的耦合, 可预测大于 10^6 个数据点的数据集。多结构参数同时变化时, 更容易找到使得减压器稳定的结构参数组合。更重要的是这些结构参数同时变化时减压器的稳定性比仅其中一个参数变化时更好。

关键词: BP 神经网络; 拟牛顿法; 变步长; 减压器 (PPR); 稳定性; 结构参数

中图分类号: V434

文献标志码: A

An improved BP neural network algorithm for researching on stability of reverse unloading diaphragm pressure reducing regulator

LIU Wen-ying¹, WANG Yong-jun¹, WANG Bao-shan¹,
CHEN Yang², CHEN Jing-lu¹

(1. School of Mathematics and Systems Science,
Beijing University of Aeronautics and Astronautics, Beijing 100191, China;

2. School of Astronautics,
Beijing University of Aeronautics and Astronautics, Beijing 100191, China)

Abstract: To investigate the stability of PRR (pressure reducing regulator) with adjusting multiple structure parameters simultaneously, BFGS (Broyden-Fletcher-Goldfarb-Shanno) quasi-Newton method and line search with Wolfe conditions were applied to optimize the BP (back propagation) algorithm. Results showed that the improved BP algorithm reduced number of iterations by 1—2 orders of magnitude, making it easy to reach a global minimal point. When the improved BP algorithm was used for reverse unloading diaphragm PRR, it could adapt to coupling of 2—3 structure parameters and predict the data set with more than 10^6 data points. It was easy to find a combination of structure parameters to stabilize PRR

收稿日期: 2015-08-09

基金项目: 国家自然科学基金(11371044, 11101023)

作者简介: 刘文英(1991—), 女, 硕士生, 主要从事软计算, 机器学习和图像处理方面的研究。

引用格式: 刘文英, 王拥军, 王宝山, 等. 一种研究逆向卸荷膜片式减压器稳定性的 BP 神经网络改进算法[J]. 航空动力学报, 2017, 32(5): 1241-1249. LIU Wenying, WANG Yongjun, WANG Baoshan, et al. An improved BP neural network algorithm for researching on stability of reverse unloading diaphragm pressure reducing regulator[J]. Journal of Aerospace Power, 2017, 32(5): 1241-1249.

when multiple structure parameters change simultaneously. More importantly, when these parameters changed together, the stability of PRR was much better than the case with change of just one of the parameters.

Key words: back propagation (BP) neural network; quasi-Newton method; variable step size; pressure reducing regulator (PRR); stability; structural parameters

减压器是利用节流原理工作的部件,其作用是使进口高压气体的压力降至规定的值,并稳定在预设的压力范围内^[1-3]. 减压器的稳定性能是减压器稳定工作的重要影响因素,以往大多都是先采用数值算法进行数值仿真,再分析减压器的稳定性^[4-7]. 由于此类方法都无法完整地有效地给出减压器的结构参数和稳定性之间的关系,特别是对于多参数耦合变化的情形,且所需计算量和分析量巨大,难以适用.

在文献[8]中,使用标准的 BP 神经网络模型来预测结构参数与减压器稳定性之间的依赖关系,以此来分别研究单结构参数变化、多结构参数耦合变化下减压器的稳定性能,为各种减弱振荡措施的选取提供决策依据,增加逆向卸荷膜减压器的稳定性. 但标准的 BP 模型在实际运行中存在收敛速度缓慢,易陷入局部极小点的问题,从而导致数据集增大时,模型训练时间变长;耦合的结构参数增多时,预测结果精度下降.

对于文献[8]中的不足,本文采用数值优化理论来优化标准的 BP 算法:使用拟牛顿法替换梯度下降法,实现基于 Wolfe 条件的一维线搜索(line search)可变步长算法,增加附加冲量项. 优化的 BP 算法极大地减小了迭代次数,易于收敛于全局极小点,从而很好地减小了模型的训练时间且提升了预测结果的精度. 实验结果表明,改进的 BP 模型用于逆向卸荷膜片式减压器,能适应更多结构参数耦合、更大数据集的情形,并获得新结果:多结构参数(在单结构参数变化表现良好的结构参数,诸如阻尼孔直径、卸荷腔直径、膜片刚度等)同时变化时,稳

定性能显著提高. 更重要的是当这些参数同时变化时,稳定性比它们当中仅一个结构参数变化好得多.

1 逆向卸荷膜片式减压器

1.1 数值仿真模拟

本文研究的逆向卸荷膜片式减压器(以下简称减压器)示意图与文献[8]中相同.

图 1 为涡轮气封减压试验系统的数值仿真模型,图中标出了各管道的长度 L 、内径 ϕ ,各管道管壁厚度设为 2 mm,模块化建模时把此系统化为 1 个流体源(FS1)、6 段气体管道(GP1~GP6)、1 个气体容积(GVol1)、3 个气体阀门(GV1~GV3)、1 个减压器(GPRR1)、1 个缓开阀(BCV1),管道元件流场网格划分为每个网络 100 mm,FS1 设置为大气边界条件(压强出口), $p(t)$ 表示其压强. 电磁阀 GV1 和 GV2 在系统起动前处于关闭状态,系统起动时先打开 GV1,由高压气瓶 GVol1 流出的高压氦气冲击到缓开阀 BCV1 处,由于 BCV1 尚处于关闭状态,因此高压氦气只能通过缓开阀阀芯与阀座之间的缝隙流向下游,此时减压器 GPRR1 由于低压腔和阻尼腔压强很小处于完全打开状态,又由于 GV2 尚处于关闭状态,因此 GPRR1 低压腔和阻尼腔压强将会逐渐升高,相应地其阀芯会逐渐闭合直至完全关闭. GV2 打开后,高压气瓶流出的高压氦气经减压器降压后通过孔板 GV3 喷射出去,形成稳定流量的氦气射流吹到涡轮泵轴上产生气封的效果. 系统工作情况因此可分为两个过程:减压器低压腔建压(阀芯闭合)阶段和稳定射流阶段^[9].




图 1 涡轮气封减压试验系统的数值仿真模型

Fig. 1 Numerical simulation model of the turbine gas seal pressure reducing experiment systems

根据工程单位提供的数据,系统启动时刻初始状态为:高压氦气瓶-气体阀门 GV1 上游腔之间管路压强为 p_1 ,GV1 下游腔-气体阀门 GV2 上游腔之间管路压强为 p_2 ,GV2 下游腔之后管路压强为 p_3 ,管路温度为 278 K. 标准算例的参数设置见表 1,其中 d_{v3} , d_{v4} , c_m , l_1 , l_2 , m_{vc} 和 λ_s 分别为减压器阻尼孔直径、卸荷孔直径、膜片刚度、高压腔等效长度、低压腔等效长度、阀芯质量和弹性元件材料的阻尼系数, T_{GV2} 为气体阀门 GV2 打开的时刻. 氦气瓶体积 V_{He} 为 0.04 m^3 .

表 1 标准算例的初始状态和结构参数设置
Table 1 Initial state and structure parameter settings of the standard example

参数	数值	参数	数值
p_1/MPa	35	p_2/MPa	0.1
p_3/MPa	0.1	d_{v3}/m	0.001
d_{v4}/m	0.001	$c_m/10^5\text{ (N/m)}$	4.033
l_1/m	0.03306	l_2/m	0.02128
m_{vc}/kg	0.0822	λ_s/s	0.0004
T_{GV1}/s	1	T_{GV2}/s	5

1.2 减压器稳定性指标的选取

对于振荡现象,文献[8]中选取减压器 GPRR1 低压腔压强 p_2 在一定时间内的相对变化量作为衡量减压器稳定性的指标,在衡量稳定性时取得了良好的效果. 本文选取低压腔压强 p_2 和阀芯开度 h 在一定时间内的相对变化量作为衡量减压器稳定性的指标,即

$$S_{\text{GPRR1-}p_2} = \sqrt{\frac{1}{n} \sum_{i=1}^n \left[\frac{p_2(t_i) - p_2(t_{i-1})}{p_{\text{refer}}} \right]^2}$$
 (1)

$$S_{\text{GPRR1-}h} = \sqrt{\frac{1}{n} \sum_{i=1}^n \left[\frac{h(t_i) - h(t_{i-1})}{h_{\text{refer}}} \right]^2}$$
 (2)

式中 $p_{\text{refer}} = \frac{1}{n+1} \sum_{i=0}^n p_2(t_i)$, $h_{\text{refer}} = \frac{1}{n+1} \sum_{i=0}^n h(t_i)$.

如式(1)、式(2)所示,综合低压腔压强 p_2 和阀芯开度 h 作为稳定性指标,能够更准确地反映减压器的稳定性,稳定性指标的值越小,减压器越稳定.

2 改进的 BP 神经网络模型

神经网络是机器学习的重要分支,是数据挖掘中分类技术的重要方法,适合解决数据的分类和预测等问题[8]. BP 神经网络有很强的映射能力,能在不知道训练数据的映射关系的数学方程

的情况下,学习和存储大量训练数据的映射关系. BP 神经网络拥有良好的拟合能力和泛化能力. BP 神经网络模型具体介绍见文献[8].

2.1 拟牛顿法

拟牛顿法是一种基于牛顿法的方法,其基本思想是利用本次和上一次迭代的信息(梯度差和步长)来构造满足拟牛顿方程式(3)的 Hessian 矩阵的近似矩阵. 它是求解无约束优化问题中利用 1 阶导数信息的方法中收敛最快的方法[10]. BFGS 法是所有拟牛顿方法中最有效的方法之一.

$$\mathbf{B}_{k+1} \mathbf{s}_k = \mathbf{y}_k$$
 (3)

式(3)称作拟牛顿方程,也称作拟牛顿条件或者割线方程.

BFGS 拟牛顿法计算步骤如下:

- 1) 给出 $\mathbf{x}_0 \in \mathbf{R}^n$, $\mathbf{H}_0$, $0 \leq \epsilon \leq 1$.
- 2) 令 $k=0$.
- 3) 如果 $\|\mathbf{g}_k\| \leq \epsilon$, 则停止.
- 4) 计算搜索方向 $\mathbf{p}_k = -\mathbf{H}_k \mathbf{g}_k$.
- 5) 利用线搜索方法求 α_k .
- 6) 计算 $\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{p}_k$.
- 7) 利用式(5)求 $\mathbf{H}_{k+1}$.
- 8) 令 $k=k+1$, 转入 3).

在 BFGS 拟牛顿法中,下降方向设为

$$\mathbf{p}_k = -\mathbf{H}_k \mathbf{g}_k$$
 (4)

式中 $\mathbf{g}_k$ 为误差函数第 k 次迭代的梯度, $\mathbf{H}_k$ 为 Hessian 矩阵近似[11-13], 设

$$\mathbf{H}_{k+1} = \left(\mathbf{I} - \frac{\mathbf{s}_k \mathbf{y}_k^T}{\mathbf{y}_k^T \mathbf{s}_k} \right) \mathbf{H}_k \left(\mathbf{I} - \frac{\mathbf{y}_k \mathbf{s}_k^T}{\mathbf{y}_k^T \mathbf{s}_k} \right) + \frac{\mathbf{s}_k \mathbf{s}_k^T}{\mathbf{y}_k^T \mathbf{s}_k}$$
 (5)

标准 BP 算法在收敛过程中采用的是固定步长,容易出现问題,即如果步长设置过大时,网络权重每次的修改量会过大,导致收敛过程中出现震荡而无法收敛. 如果步长设置过小,权重每次修改量很小,导致算法收敛速度缓慢. 因此,一个合理的步长自适应算法对 BP 算法的优化很重要,一方面能提高收敛速度,减小训练时间,另一方面也有助于算法收敛于全局最小点[14-17]. 使用 Wolfe 条件的线搜索算法来选择步长 α .

2.2 改进的 BP 算法

改进的 BP 算法采用拟牛顿法计算下降方向来最小化网络输出值与期望值之间的误差,步长采用自适应步长 α_k , 因此

$$w_{k+1} = w_k + \Delta w_k$$
$$\Delta w_k = \alpha_k p_k = -\alpha_k H_k g_k \tag{6}$$

式中 Δw_k 为权值的修正值, α_k 为文中第 2.2 节求出的可变步长, H_k 为文中第 2.1 节中的 Hession 矩阵的近似.

BFGS_BP 算法计算步骤如下:

- 1) 令 $k=0$, 初始化网络权重 w_0 , 初始化 H_0 为单位矩阵.
- 2) 计算梯度初始值 g_0 .
- 3) 使用式(4)计算下降方向 p_k .
- 4) 使用线性搜索算法计算 α_k , 修正权值

表 2 算法比较(限定误差总和小于等于 0.1 为终止条件)

Table 2 Comparision of algorithm(error sum square is limited less than or equal to 0.1 for termination conditions)

算法	迭代次数	训练数据相对误差	测试数据相对误差	梯度范数平方
GDM_BP	50 701	0.007 033 97	0.007 043 17	0.000 034 52
BFGS_BP	195	0.007 015 38	0.006 735 25	0.000 447 16

表 3 算法比较(限定梯度范数平方小于等于 10^{-4} 为终止条件)

Table 3 Comparision of algorithm(gradient norm square is limited less than or equal to 10^{-4} for termination conditions)

算法	迭代次数	训练数据相对误差	测试数据相对误差	误差总和
GDM_BP	6 501	0.008 198 04	0.009 974 09	0.134 059 33
BFGS_BP	183	0.007 029 94	0.006 845 65	0.100 440 40

从表 2、表 3 可以看出在收敛速度上 BFGS_BP 算法要远优于标准的 BP 算法.

3 模型训练

为了度量 BP 模型的精度, 本文使用平均绝对误差和平均相对误差, 见式(7)、式(8).

$$E_{\text{abs}} = \frac{1}{n} \sum_{i=1}^n |R_i - P_i| \tag{7}$$

$$E_{\text{rel}} = \frac{1}{n} \sum_{i=1}^n \frac{|R_i - P_i|}{R_i} \tag{8}$$

式中 R_i, P_i 分别为第 i 个例子的期望值和输出值.

3.1 数据标准化

Min-max 标准化^[14]用于数据的标准化. 假定 $\min A$ 和 $\max A$ 是属性 A 的最小值和最大值. Min-max 标准化将 A 的一个值 v 通过计算式(9)映射到 $[0, 1]$ 上的 v' , 逆映射式(10)用于数据的逆标准化.

$$v' = \frac{v - \min A}{\max A - \min A} \tag{9}$$

$$v = v'(\max A - \min A) + \min A \tag{10}$$

由于文中所用的数据集稳定性指标的极大值

$$w_{k+1} = w_k + \alpha_k p_k .$$

5) 计算梯度 g_{k+1} .

6) 计算 $s_k = w_{k+1} - w_k$, $y_k = y_{k+1} - y_k$, 使用式(5)计算 H_{k+1} .

7) 如果 $\|g_{k+1}\| > \epsilon$, 转入 3), 否则算法终止.

2.3 算法比较

当收敛条件设置为误差总和小于等于 0.1 时, 算法的效果如表 2 所示. 当收敛条件为梯度范数平方小于等于 10^{-4} 时, 两个算法的效果如表 3 所示.

比极小值大很多, 因此标准化前对稳定性指标进行对数转换来缩小它们之间的差距, 式(9)、式(10)修改如下:

$$v' = \frac{\ln v - \min \ln A}{\max \ln A - \min \ln A} \tag{11}$$

$$v = e^{v'(\max \ln A - \min \ln A) + \min \ln A} \tag{12}$$

3.2 模型误差

使用改进的 3 层 BP 神经网络(2 个隐含层, 1 个输出层)训练表 1 中的数据集, 训练数据和测试数据的误差如表 4 所示. (对于单结构参数, 设置输入层 1 个节点, 第一隐含层 5 个节点, 第二隐含层 3 个节点, 输出层 2 个节点. 对于双结构参数, 设置输入层 2 个节点, 第一隐含层 8 个节点, 第二隐含层 6 个节点, 输出层 2 个节点. 对于三结构参数, 设置输入层 3 个节点, 第一隐含层 12 个节点, 第二隐含层 8 个节点, 输出层 2 个节点.)

从表 4 可以看出, 训练数据的平均绝对误差和平均相对误差都很小, 说明所构建的 BP 模型没有陷入局部极小点. 同时训练数据的误差与测试数据的误差比较接近, 所以模型不导致过拟合. 因此, 所构建的模型保证了生成的预测结果的准确性.

表 4 BP 神经网络预测模型的误差

Table 4 Error of BP neural network prediction model

稳定性指标(参数)	训练数据的平均 绝对误差	测试数据的平均 绝对误差	训练数据的平均 相对误差	测试数据的平均 相对误差
$S_{\text{GPRR1-}p_2}(m_{\text{vc}})$	0.00143720	0.00169651	0.00655022	0.00774874
$S_{\text{GPRR1-}h}(m_{\text{vc}})$	0.01142199	0.0125316	0.00800783	0.00887481
$S_{\text{GPRR1-}p_2}(\lambda_s)$	0.00229659	0.00280840	0.01959491	0.02399642
$S_{\text{GPRR1-}h}(\lambda_s)$	0.01591939	0.02041226	0.02170963	0.02717252
$S_{\text{GPRR1-}p_2}(d_{\text{v3}})$	0.00246704	0.00357239	0.03493886	0.04645235
$S_{\text{GPRR1-}h}(d_{\text{v3}})$	0.01799997	0.02734115	0.02564598	0.03651989
$S_{\text{GPRR1-}p_2}(d_{\text{v4}})$	0.00165102	0.00195459	0.02147685	0.02290355
$S_{\text{GPRR1-}h}(d_{\text{v4}})$	0.00895144	0.01014301	0.02055535	0.02212558
$S_{\text{GPRR1-}p_2}(l_1)$	0.00082710	0.00090792	0.00395622	0.00434065
$S_{\text{GPRR1-}h}(l_1)$	0.00391151	0.00436516	0.00366763	0.00407625
$S_{\text{GPRR1-}p_2}(l_2)$	0.00087423	0.00098042	0.00602669	0.00667472
$S_{\text{GPRR1-}h}(l_2)$	0.00305096	0.00355078	0.00300215	0.00347247
$S_{\text{GPRR1-}p_2}(c_{\text{m}})$	0.00229689	0.00307529	0.02713289	0.05926428
$S_{\text{GPRR1-}h}(c_{\text{m}})$	0.01015392	0.00942781	0.02621933	0.04003256
$S_{\text{GPRR1-}p_2}(m_{\text{vc}},\lambda_s)$	0.00177498	0.00246126	0.01406881	0.01918644
$S_{\text{GPRR1-}h}(m_{\text{vc}},\lambda_s)$	0.01602779	0.02519247	0.01942656	0.02874266
$S_{\text{GPRR1-}p_2}(l_2,m_{\text{vc}})$	0.00114002	0.00154251	0.00708332	0.00954317
$S_{\text{GPRR1-}h}(l_2,m_{\text{vc}})$	0.00863873	0.01229445	0.00651676	0.00930134
$S_{\text{GPRR1-}p_2}(d_{\text{v4}},l_2)$	0.00197511	0.00324568	0.06265237	0.10751977
$S_{\text{GPRR1-}h}(d_{\text{v4}},l_2)$	0.01247512	0.02038059	0.05727546	0.09731968
$S_{\text{GPRR1-}p_2}(d_{\text{v3}},\lambda_s)$	0.00414511	0.00793669	0.03964855	0.11116274
$S_{\text{GPRR1-}h}(d_{\text{v3}},\lambda_s)$	0.02285653	0.05078669	0.03259861	0.10698009
$S_{\text{GPRR1-}p_2}(d_{\text{v3}},l_2)$	0.00614194	0.00841479	0.08916594	0.19186800
$S_{\text{GPRR1-}h}(d_{\text{v3}},l_2)$	0.04316194	0.06726293	0.07367730	0.16166920
$S_{\text{GPRR1-}p_2}(d_{\text{v3}},c_{\text{m}})$	0.00282243	0.00540605	0.04810986	0.16505562
$S_{\text{GPRR1-}h}(d_{\text{v3}},c_{\text{m}})$	0.02889461	0.04358712	0.06040865	0.13435060
$S_{\text{GPRR1-}p_2}(l_1,m_{\text{vc}},\lambda_s)$	0.00199398	0.00256245	0.03185131	0.06179777
$S_{\text{GPRR1-}h}(l_1,m_{\text{vc}},\lambda_s)$	0.01874831	0.02425492	0.02260385	0.02832145
$S_{\text{GPRR1-}p_2}(d_{\text{v3}},m_{\text{vc}},\lambda_s)$	0.00711478	0.00996758	0.08513727	0.22209614
$S_{\text{GPRR1-}h}(d_{\text{v3}},m_{\text{vc}},\lambda_s)$	0.05049940	0.07803913	0.06949331	0.20876744
$S_{\text{GPRR1-}p_2}(d_{\text{v3}},c_{\text{m}},\lambda_s)$	0.00073007	0.00268048	0.05408972	0.23206847
$S_{\text{GPRR1-}h}(d_{\text{v3}},c_{\text{m}},\lambda_s)$	0.00712121	0.01920313	0.07254019	0.22897882

4 稳定性预测

实验采用 10 折交叉验证来评判模型的准确度,10 折交叉验证将训练出 10 个模型.在结果预测中,10 个模型预测出 10 个结果,最后的预测结果取它们的均值.

在预测结果时,单结构参数变化的情形,模型预测 10 000 个数据点并绘制二维曲线图.对于双结构参数变化的情形,模型预测 250 000 (500 × 500) 个数据点,并绘制二维颜色图(用颜色来表示

稳定性).对三结构参数变化的情形,模型预测 8 000 000 (200 × 200 × 200) 个数据点,并绘制三维颜色图(用颜色来表示稳定性).下面的 3 个小节分别是单参数变化,双参数变化,3 个参数变化下稳定性的变化情形(图片由软件 Matlab 和 Tecplot 绘制).

4.1 单结构参数

图 2 为部分结构参数在单参数变化时对减压器稳定性的影响,从图 2 中可以看出 d_{v3} 对减压器的稳定性有非常大的影响; l_2 对稳定性有明显的




图 2 在 BP 神经网络预测模型中,单结构参数(d_{v3} , l_2 , m_{vc} , l_1)变化下减压器稳定性的变化情况

Fig. 2 Correspondence between single-structure-parameter (d_{v3} , l_2 , m_{vc} , l_1) change and stability indexes generated by the BP neural network prediction models

影响; m_{vc} 能够在一定程度上影响稳定性; l_1 几乎对稳定性没有影响.实验结果表明,单结构参数变化的情形,与文献[8]中的单结构参数变化的情形类似.

4.2 双结构参数

图 3 为部分双结构参数耦合变化下减压器稳定性的变化情况.其中,蓝色区域为稳定值小的区域即稳定区域,红色区域是不稳定的.实验结果表明,在某些结构参数同时变化的情况下,稳定性指标值可以变得非常小,接近于零,如 d_{v3} 和 l_2 , d_{v3} 和 c_m 同时作用时.从图 3 可以看出,在双参数耦合变化的情况下,稳定性指标 $S_{GPPR1-p_2}$ 和 $S_{GPPR1-h}$ 的变化情形略有不同,图中 $S_{GPPR1-p_2}$ 的蓝色区域与 $S_{GPPR1-h}$ 蓝色区域的交集是所要寻找的参数变化范围.

从图 3(a)和图 3(b)可以看出,当 λ_s 和 m_{vc} 同时变化时, λ_s 对稳定性的影响要比 m_{vc} 对稳定性的影响大,且当 λ_s 取值在 0.0025 s 左右, m_{vc} 取较小范围值时,稳定性指标值会很小.从图 3(c)和

图 3(d)可以看出,当 d_{v3} 和 l_2 耦合变化时,稳定性指标值也可以变得非常小,但更值得注意的是,稳定性指标 $S_{GPPR1-p_2}$ 和 $S_{GPPR1-h}$ 的变化趋势在这里略有不同.图 3(e)和图 3(f)显示,在 d_{v3} 和 c_m 耦合变化下,当 d_{v3} 大于 0.002 m 且 c_m 大于 10^6 N/m 或者当 c_m 大于 2×10^6 N/m 时,稳定性指标变得非常小,接近于 0;在图 3(e)和图 3(f)中, $S_{GPPR1-p_2}$ 和 $S_{GPPR1-h}$ 的稳定区域(深蓝色区域)相似,而不稳定区域有所不同.

4.3 三结构参数

在 3 个结构参数耦合变化的预测图中,用空间的 3 个坐标系表示 3 个结构参数,用空间点的颜色来表示稳定性指标值.为了显示立方体内部情况,在图片生成时,设置了 40% 的透明度,因此 3 个结构参数变化的结果图中,颜色不如双结构参数情况结果图深.

图 4 中蓝色区域为稳定区域而红色区域为不稳定区域.从图 4(a)和图 4(b)可以看到,当 d_{v3} , m_{vc} , λ_s 同时变化时,大部分区域都是稳定区域,且 d_{v3} 对稳定性的影响要大于 λ_s , λ_s 对稳定性的影响要




图 3 在 BP 神经网络预测模型中,双结构参数耦合变化下减压器稳定性的部分变化情况
Fig. 3 Correspondence between dual-structure-parameter-combinations and the stability indexes generated by the BP neural network prediction models

大于 m_{vc} . 图 4(c)和图 4(d)显示,当 l_1 , m_{vc} , λ_s 同时变化时,并不能使稳定性指标变得特别小. 从图 4(e)和图 4(f)可以看到,当 d_{v3} , c_m , λ_s 同时变化时,大部分区域都是稳定区域.

从图 4 中,可以发现,当结构参数(在单参数情况下表现良好的参数)耦合变化时,大部分区域都会是稳定区域. 因此,很容易从这些参数中找到一组能让减压器稳定工作的参数组合. 当结构参




图 4 在 BP 神经网络预测模型中,三结构参数耦合变化下减压器稳定性的变化情况

Fig. 4 Correspondence between tri-structure-parameter-combinations and the stability indexes generated by the BP prediction models

数(在单参数情况下表现不好的参数)耦合变化时,稳定区域相对于不稳定区域来说范围很小,因

此,在这些参数设置中,不容易找到能使减压器稳定工作的参数组合。

5 结 论

本文使用数值优化理论方法建立改进的 BP 神经网络预测模型来研究结构参数和减压器稳定性之间的关系。实验结果表明,改进的 BP 神经网络预测模型极大地减少了迭代次数,改善了易陷入局部最优的问题,提升了预测结果的精确性。对提高减压器稳定性影响最大的结构参数和保证减压器稳定的结构参数范围都可以由改进的 BP 模型得到。改进的 BP 模型应用于逆向卸荷膜片式减压器,得到了以下结论:

- 1) 减压器阻尼孔直径(d_{v3}),卸荷孔直径(d_{v4})和隔膜刚度(c_m)对减压器稳定性的作用非常明显;阻尼系数(λ_s)和低压腔等效长度(l_2)对减压器稳定性作用明显;阀芯质量(m_{vc})能影响减压器稳定性,但效果不会太大。高压腔等效长度(l_1)对稳定性几乎没有作用。
- 2) 增大 d_{v3} , d_{v4} , c_m , l_2 , λ_s 取标准值的 6.5 倍左右,减小 m_{vc} 能够提高减压器的稳定性能。
- 3) 当在单参数变化情形下,表现良好的结构参数(d_{v3} , d_{v4} , c_m),与其他结构参数耦合变化时,稳定性指标值可以变得非常小即减压器可以变得非常稳定。更重要的是,当这些参数相互耦合变化时,对提高稳定性的效果要远远好于单个结构参数变化。当在单参数变化情形下,表现不好的结构参数(l_1 , m_{vc})与其他参数耦合时,不容易找到参数组合来构建十分稳定的减压器。
- 4) 稳定性指标 $S_{GPRRI-p_2}$ 和 $S_{GPRRI-A}$ 在单参数变化情形,变化趋势几乎一致;在多参数耦合变化情形,略有不同,特别是在不稳定区域,差异比较明显。

参考文献:

[1] Shahani A R, Esmaili H, Aryaei A, et al. Dynamic simulation of high pressure regulator[J]. Journal of Computational and Applied Research in Mechanical Engineering, 2011, 1(1): 17-28.

[2] Rami E G, Jean-Jacques B, Pascal G, et al. Stability study and modelling of a pressure regulating station[J]. International Journal of Pressure Vessels and Piping, 2005, 82(1): 51-60.

[3] Zafer N, Luecke G R. Stability of gas pressure regulators[J]. Applied Mathematical Modelling, 2008, 32(1): 61-82.

[4] 陈阳, 蔡国飙, 张振鹏, 等. 双组元统一推进系统减压器稳性仿真[J]. 北京航空航天大学学报, 2010, 36(10): 1135-1139.

CHEN Yang, CAI Guobiao, ZHANG Zhenpeng, et al. Nu-

merical simulation on dynamic stability of pressure reducing regulator in integral bipropellant propulsion system[J]. Journal of Beijing University of Aeronautics and Astronautics, 2010, 36(10): 1135-1139. (in Chinese)

[5] 陈阳, 高芳, 张黎辉, 等. 减压器动态仿真的有限体积模型[J]. 推进技术, 2006, 27(1): 9-14.

CHEN Yang, GAO Fang, ZHANG Lihui, et al. Finite volume model for numerical simulation on dynamic process of pressure reducing regulator[J]. Journal of Propulsion Technology, 2006, 27(1): 9-14. (in Chinese)

[6] Prescott S L, Ulanicki B. Dynamic modeling of pressure reducing valves[J]. Journal of Hydraulic Engineering, 2003, 129(10): 804-812.

[7] Afshari H H, Zanj A, Novinzadeh A B. Dynamic analysis of a nonlinear pressure regulator using bondgraph simulation technique[J]. Simulation Modelling Practice and Theory, 2010, 18(2): 240-252.

[8] 陈经禄, 王拥军, 陈阳. 使用 BP 神经网络模型研究逆向卸荷膜片式减压器的稳定性能[J]. 航空动力学报, 2013, 28(9): 2112-2120.

CHEN Jinglu, WANG Yongjun, CHEN Yang. Research on stability of reverse unloading diaphragm pressure reducing regulator using BP neural network model[J]. Journal of Aerospace Power, 2013, 28(9): 2112-2120. (in Chinese)

[9] 陈阳, 高芳, 张振鹏, 等. 气动薄膜调节阀控制系统工作过程的动态仿真[J]. 火箭推进, 2006, 32(6): 28-34.

CHEN Yang, GAO Fang, ZHANG Zhenpeng, et al. Dynamic simulation of working process for control system of a pneumatic diaphragm control valve[J]. Journal of Rocket Propulsion, 2006, 32(6): 28-34. (in Chinese)

[10] Bodén M. A guide to recurrent neural networks and back-propagation[J]. Electrical Engineering, 2001(2): 1-10.

[11] Kumars S. Neural networks[M]. Beijing: Tsinghua University Press, 2006.

[12] 袁亚湘. 非线性优化计算方法[M]. 北京: 科学出版社, 2010.

[13] 刘红英, 夏勇, 周水生. 数学规划基础[M]. 北京: 北京航空航天大学出版社, 2012.

[14] Han J, Kamber M, Pei J. Data mining: concepts and techniques[M]. 2nd ed. San Francisco: Morgan Kaufmann Publisher, 2006.

[15] Didandeh A, Mirbakhsh N, Amiri A, et al. A variable step size approach to speed-up the convergence of error back-propagation algorithm[J]. Neural Processing Letters, 2011, 33(2): 201-214.

[16] Silva F M, Almeida L B. Acceleration techniques for the backpropagation algorithm[M]. Berlin: Springer Berlin Heidelberg, 1990.

[17] Jacobs R A. Increased rates of convergence through learning rate adaptation[J]. Neural Networks, 1988, 1(4): 295-307.