

文章编号:1000-8055(2012)12-2842-08

基于动态云 BP 网络的液体火箭发动机故障诊断方法

刘垠杰, 黄 强, 程玉强, 吴建军

(国防科技大学 航天与材料工程学院, 长沙 410073)

摘 要: 将云模型与 BP(back propagation)神经网络以串联方式有机结合, 首先利用云变换方法进行网络的结构辨识和云模型的特征提取, 同时通过在输入层引入单位延时环节描述发动机工作过程动态特性, 研究提出了基于动态云 BP 网络的液体火箭发动机故障诊断方法. 结合实际试车数据的验证结果表明, 该方法能够准确识别发动机已有的 3 种故障模式, 通过在试车数据中添加 0 期望、0.2 标准差的随机噪声的方法来模拟环境噪声和测试过程中产生的随机噪声, 根据持续性原则, 方法仍能够正确进行故障检测与分类. 方法单步运行时长为 1.124×10^{-4} s, 完全能够满足实时性要求.

关 键 词: 液体火箭发动机; 故障诊断; 云模型; 神经网络; 故障模式

中图分类号: V434.1

文献标志码: A

Fault diagnosis method for liquid-propellant rocket engines based on the dynamic cloud-BP neural network

LIU Yin-jie, HUANG Qiang, CHENG Yu-qiang, WU Jian-jun

(College of Aerospace and Material Engineering,

National University of Defense Technology, Changsha 410073, China)

Abstract: A fault diagnosis method for liquid-propellant rocket engines was proposed based on the dynamic cloud-BP (back propagation) neural network in the way of the integration of cloud model and BP neural network. The Cloud transform method was used to identify the network configuration and to extract the cloud features. And a unit time-delay was also introduced into the input layer to describe the dynamic characteristics of the engine. Results with test data show that the method can isolate the existed 3 fault modes precisely. A 0 expectation, 0.2 standard deviation noise was used to simulate the environmental noise and stochastic noise, and the method can still detect and classify the fault accurately account to lasting-rule. The method can run in real-time with the single processing time being 1.124×10^{-4} s.

Key words: liquid-propellant rocket engine; fault diagnosis; cloud model; neural network; fault mode

云理论是李德毅院士等在传统模糊集理论和概率统计的基础上提出的定性定量不确定性转换模型, 是对传统模糊集理论的进一步改进与完善, 有效解决了传统模糊集理论中模糊概念被精确化

的问题^[1]. 目前云理论在智能控制^[2-3]、复杂系统效能评估、数据挖掘^[4]等领域得到了成功应用.

将云理论和神经网络两者有机结合的云神经网络技术, 既具有有效处理不确定性信息的能力,

收稿日期: 2011-12-15

网络出版地址: http://www.cnki.net/kcms/detail/11.2297.V.20121218.0859.201212.2842_030.html

作者简介: 刘垠杰(1985—), 男, 甘肃庆阳人, 硕士生, 主要从事推进系统动力学、控制与健康监控研究.

又具有强大的学习、数据处理和容错性能,能有效提高故障诊断系统的性能。但目前该领域的研究成果尚不多见,尤其是针对液体火箭发动机这样复杂的非线性动态系统。徐宗本等^[5]将云理论与神经网络相结合,给出了一种空间推进系统的故障检测与诊断方法。黄强等^[6]采用类似方法实现了对某型号液体火箭发动机的故障检测功能。但上述方法构建的是一种故障检测诊断的静态网络,难以反映发动机工作过程中的动态特性。

本文通过将云模型与 BP 神经网络以串联方式有机结合,首先利用云变换的方法进行网络的结构辨识和云模型的特征提取,同时通过引入单位延时环节构建动态云神经网络,研究提出了基于动态云 BP 网络的液体火箭发动机故障诊断方法。结合实际发动机试车数据的验证结果表明:该方法不仅能准确识别发动机工作过程中发生的故障,而且能有效提高网络训练速度,以及具有良好的抗噪和实时能力。

1 云模型

云模型用期望值 E_x (expected value)、熵 S (entropy) 和超熵 S_h (hyper entropy) 3 个数字特征来表示。简单地讲,期望 E_x 是最能够代表定性概念的点;熵 S 是定性概念的不确定性度量,由概念的模糊性和随机性共同决定,反映了云滴的离散程度和取值范围;超熵 S_h 是熵的不确定性度量,由熵的模糊性和随机性共同决定。

生成云的软件或硬件称为云发生器。由云的数字特征 (E_x, S, S_h) 产生云滴,即实现定性到定量的转换,称为正向云发生器;给定符合某一分布规律的 1 组云滴作为样本 (x_i, μ_i) ,产生云所描述的定性概念的 3 个数字特征值,即实现定量到定性的转换,称为逆向云发生器。

云变换是指在一定的误差范围内,将任意函数(如直方图)、不规则的数据分布根据某种规律进行数学变换,分解为若干个大小不同的基云的叠加^[7],叠加的云越多,误差就越小。其定义如下^[7-9]:

设 U 是精确数值表示的定量数域, C 是 U 上的定性概念, $f(x)$ 为某个数据属性 x 的频率分布函数,自动生成若干个粒度不同的云 $C(E_{xi}, S_i, S_{hi})$ 的叠加。数据区间的连续数值 x 相应转化成离散的概念 C ,此过程称为云变换,其转换表达式为

$$f(x) = \sum_{i=1}^m [a_i \cdot C(E_{xi}, S_i, S_{hi})] + \varepsilon(x) \quad (1)$$

式中 a_i 为幅度系数, m 为变换后离散概念的个数,它随属性的差异取值不同, $\varepsilon(x)$ 为变换后的误差函数。

2 基于云神经网络的液体火箭发动机故障诊断方法

2.1 云神经网络的结构

文中提出的云神经网络的结构如图 1 所示,分为 5 层:输入层、正向云发生器层、标准化层(BP(back propagation)神经网络输入层)、隐含层和输出层。各层具体含义如下。

第 1 层:输入层,设 $k(k \geq 2)$ 时刻系统输入值为 $x(k) = [x(k)_1, x(k)_2, \dots, x(k)_m]^T$, 则

$$\begin{aligned} \text{输入} \quad & \begin{cases} x(k-1)_i^{(1)} = x(k-1)_i \\ x(k)_i^{(1)} = x(k)_i \end{cases} \\ \text{输出} \quad & \begin{cases} f(k-1)_i^{(1)} = g_i^{(1)} = x(k-1)_i^{(1)} \\ f(k)_i^{(1)} = g_i^{(1)} = x(k)_i^{(1)} \end{cases} \end{aligned}$$

式中 $i = 1, 2, \dots, m$ 。

第 2 层:正向云发生器层,执行模糊化操作,每个节点代表 1 个用云模型表示的语言变量,由 X 条件云发生器获得输入值对语言变量的隶属度 μ_{ij} (第 i 个输入变量的第 j 个语言变量),在图 1 中,用“CG”来表示 X 条件云发生器。

$E_{m_{ij}} = \phi(S_{n_{ij}}, S_h)$, ϕ 为生成正态分布随机数的函数

$$\text{输入} \quad x_{ij}^{(2)} = -\frac{(f_i^{(1)} - E_{x_{ij}})^2}{2E_{m_{ij}}^2}$$

$$\text{输出} \quad f_{ij}^{(2)} = g_{ij}^{(2)} = \mu_{ij} = e^{x_{ij}^{(2)}}$$

第 3 层:标准化层(BP 神经网络输入层),标准化隶属度,判断输入值的隶属概念

$$\text{输入} \quad x_{ij}^{(3)} = f_{ij}^{(2)}$$

$$\text{输出} \quad f_{ij}^{(3)} = g_{ij}^{(3)} = \begin{cases} 1 & x_{ij}^{(3)} = \max(x_{ij}^{(3)}) \\ 0 & x_{ij}^{(3)} \neq \max(x_{ij}^{(3)}) \end{cases}$$

将 $f_{ij}^{(3)}$ 按照一定的顺序表示为 $f_p^{(3)}$, $p = 1,$

$2, \dots, r$, 其中 $r = 2 \sum_{i=1}^m n_i$, n_i 为第 i 个输入参数经过云变换生成的原子概念的数量。

第 4 层:隐含层,设连接权值和阈值分别为 ω_{pq}^1 和 θ_q^1 ,使用正切 sigmoid 传递函数 $\tan \text{sig}$,该层单元数 s 根据公式 $s = \langle \log_2(r) \rangle$ 确定,其中, $\langle x \rangle$ 为不小于 x 的最小整数,则

$$\text{输入} \quad x_q^{(4)} = \sum_{p=1}^r \omega_{pq}^1 f_p^{(3)} - \theta_q^1$$

$$\text{输出} \quad f_q^{(4)} = \tan \text{sig} x_q^{(4)}, \quad q = 1, 2, \dots, s$$




图 1 云神经网络的结构

Fig. 1 Structure of cloud-BP neural network

第 5 层:输出层,神经元数量由训练数据包含的故障模式决定,每个节点代表 1 种故障模式,分别用 0 和 1 表示当前故障不属于或属于该节点所对应的故障模式,设连接权值和阈值分别为 ω_{qt}^2 和 θ_t^2 ,使用对数 sigmoid 传递函数 $\log \text{sig}$,该层单元数为 $n+1$ 个

$$\text{输入 } x_t^{(5)} = \sum_{q=1}^s \omega_{qt}^2 f_q^{(4)} - \theta_t^2$$

$$\text{输出 } f_t^{(5)} = \log \text{sig } x_t^{(5)}, t = 1, 2, \dots, n+1$$

2.2 基于云神经网络的液体火箭发动机故障诊断方法

基于云模型与神经网络进行液体火箭发动机故障诊断,主要分 3 步进行.首先将连续的训练数据离散化,通过云变换实现定量与定性之间的不确定转换,得到各个参数在其定义域上的由云模型表示的原子概念的数字特征,确定网络的输入、输出及各层神经元数量,完成系统的结构辨识;然后训练 BP 神经网络的权值和阈值,完成网络的参数辨识,系统的后半部分是 1 个单隐层的标准 BP 神经网络,其输入层即为系统的标准化层,输出层为系统的输出层,考虑到 Levenberg-Marquadt 反传算法具有良好的收敛性质,选择 trainlm 函数作为网络的训练函数^[10];最后以测试数据作为网络的输入,根据网络的输出向量判断发动机

的工作状态.

该方法主要具有以下特点:

1) 利用云变换的方法进行网络的结构辨识和云模型的特征提取,相比传统的人为划分或聚类分析的方法不但能够更好地反映参数的分布趋势,而且提高了训练速度.

2) 用云模型替代隶属函数,克服了边界划分过硬和将模糊概念精确化的缺点,能够较好的体现随机性、模糊性和 2 个样本之间的相关性.

3) 该网络输入层加入了 1 个单位延时环节,是 1 个动态网络,能够反映系统的动态特性.

4) 标准化层能够对云发生器输出的概念的隶属度进行标准化操作,不但增强了网络克服噪声和随机误差影响的能力而且也提高了数据压缩能力,使网络的训练需要更少的训练数据.

5) 模糊规则的获取、表示和存储由 BP 神经网络来完成,相比构造单独的“软与层”来计算,大大减少了计算量,并降低了网络的训练难度;同时,BP 神经网络还承担了模糊规则的判断和匹配工作,能够根据从训练数据中得到的知识,对测试数据进行模式识别,输出其对已知模式的隶属度.

2.3 诊断实例分析

针对某型号液体火箭发动机,将 1 次正常试车数据和 3 次故障试车数据分别作为训练数据,

选择燃气发生器压力 p_f 等 4 个试车参数作为检测参数.

2.3.1 网络结构和参数辨识

首先对正常试车数据进行云变换^[11], 结果如表 1 所示. 其中参数 $x_1 \sim x_4$ 在各自定义域上分别被划分为 5, 3, 5, 5 个用云模型表示的原子概念^[12]. 其中, x_1 为燃气发生器压力 p_f , x_2 为推力室压力 p_k , x_3 为氧泵出口压力 p_{ey} , x_4 为氢泵出口压力 p_{er} .

在网络结构的辨识中, 输入层的节点数量由选择的检测参数决定, 正向云发生器层和标准化层的节点个数需要根据云变换的结果确定, 隐含层的节点个数可以由 BP 神经网络隐含层节点的经验公式来设定, 输出层的节点个数由训练数据包含的正常模式和故障模式确定. 最终确定网络的结构为 4-36-36-6-4.

最后, 给定均方误差 (MSE) 为 0.01, 使用 Levenberg-Marquadt 反传算法训练网络的权值和阈值进行训练, 实现网络的参数辨识.

2.3.2 故障诊断

根据训练数据, 设定阈值为 0.6, 并引入持续性原则^[13], 即当某个节点的输出连续 3 次大于该

阈值时, 才认为系统处于该节点代表的故障模式.

以 5 次实际试车数据作为测试数据, 验证网络的故障识别能力, 网络的输出如图 2~图 6 所示, 其中对 test30_1 和 test30_2 正常试车数据,

表 1 云变换结果
Table 1 Results of cloud transform

参数	E_x
x_1	[0.0000, 0.2900, 0.5800, 0.7800, 0.9800]
x_2	[0.0200, 0.5000, 0.9800]
x_3	[0.0200, 0.2400, 0.4600, 0.7180, 0.9760]
x_4	[0.0200, 0.3000, 0.5800, 0.7787, 0.9775]
参数	S
x_1	[0.0371, 0.0596, 0.0371, 0.0380, 0.0202]
x_2	[0.0143, 0.1441, 0.0175]
x_3	[0.0183, 0.0461, 0.0361, 0.0515, 0.0328]
x_4	[0.0242, 0.0674, 0.0276, 0.0369, 0.0311]
参数	S_n
x_1	[0.0038, 0.0085, 0.0015, 0.0065, 0.0013]
x_2	[0.0014, 0.0198, 0.0012]
x_3	[0.0005, 0.0067, 0.0028, 0.0085, 0.0021]
x_4	[0.0020, 0.0110, 0.0018, 0.0060, 0.0021]




图 2 试车数据 test30_1 诊断结果
Fig. 2 Fault diagnosis result of data test30_1




图 3 试车数据 test30_2 诊断结果

Fig. 3 Fault diagnosis result of data test30_2




图 4 试车数据 test06_0 诊断结果

Fig. 4 Fault diagnosis result of data test06_0




图 5 试车数据 test18_8 诊断结果

Fig. 5 Fault diagnosis result of data test18_8




图 6 试车数据 test21_0 诊断结果

Fig. 6 Fault diagnosis result of data test21_0

均判断为正常,没有出现误诊,对故障试车数据 test06_0, test18_8 和 test21_0 分别在 1.51 s, 0.12 s 和 0.28 s 识别为故障模式 1、故障模式 2 和故障模式 3,没有出现漏诊或错诊.将该算法同包络线算法、神经网络算法和红线关机算法等的故障检测性能进行比较,表明该算法在及时性上有一定进步,如表 2 所示^[14-15].

表 2 检测结果对比

Table 2 Comparison of fault diagnosis result

算法名称	实际检测时间/s			
	test30_2	test06_0	test18_8	test21_0
包络线算法	2.40	0.6	0.9	
BP 神经网络算法	1.42	0.4	0.4	
RBF 神经网络算法	1.42	0.6	1.3	
红线关机	20.00	5.3	1.3	
本文方法	1.52	0.12	0.28	

2.3.3 算法性能分析

1) 对噪声的鲁棒性分析

为测试算法对噪声的鲁棒性,在试车数据

test30_2 中添加期望为 0, 标准差为 0.2 的随机噪声作为测试数据,模拟环境噪声和测试过程中产生的随机噪声,如所图 7 所示.然后将该数据作为系统输入,系统输出如图 8 所示,通过与图 3 进行对比,可以看出:该系统仍然能够正确进行故障检测与分类,虽然个别点被误判为故障模式 1,但是根据持续性原则,并不影响检测与诊断的结果.

2) 实时性分析

由于吸收了神经网络并行协同处理信息的优点,该系统具有非常强的实时性.在软件 Matlab 仿真计算环境下,单个数据点检测耗时 $1.124 \times$






图 7 有噪声和无噪声参数对比


Fig. 7 Comparison of parameters with/without noise




(a) 正常



(b) 故障模式 1



(c) 故障模式 2



(d) 故障模式 3

图 8 试车数据 test30_2(有噪声)诊断结果

Fig. 8 Fault diagnosis result of data test30_2 (with noise)

10^{-4} s, 仅为数据采样间隔(0.02 s)的 1/178, 完全能够满足实时性要求。

3 小 结

本文有机结合云模型与BP神经网络, 首先利用云变换的方法进行网络的结构辨识和云模型的特征提取, 同时通过引入单位延时环节构建动态云神经网络, 研究提出了基于动态云BP网络的液体火箭发动机故障诊断方法。诊断实例分析表明, 该方法能够有效识别发动机的故障模式, 没有出现漏报警和误报警, 并且具有优秀的噪声鲁棒性和实时性。同时模糊层具有压缩训练数据的能力, 所以与传统神经网络相比需要更少的训练数据。

参考文献:

- [1] 李德毅, 孟海军. 隶属云和隶属云发生器[J]. 计算机研究与发展, 1995, 32(6): 15-20.
LI Deyi, MENG Haijun. Membership cloud and membership cloud generators[J]. Computer Research & Development, 1995, 32(6): 15-20. (in Chinese)
- [2] 李德毅. 三级倒立摆的云控制方法及动平衡模式[J]. 中国工程科学, 1999, 1(2): 41-46.
LI Deyi. The cloud control method and balancing patterns of triple link inverted pendulum systems [J]. Engineering Science, 1999, 1(2): 41-46. (in Chinese)
- [3] 张飞舟, 范跃祖, 沈程智, 等. 利用云模型实现智能控制倒立摆[J]. 控制理论与应用, 2000, 17(4): 519-523.
ZHANG Feizhou, FAN Yuezhu, SHEN Chengzhi, et al. Intelligent control inverted pendulum with cloud models [J]. Control Theory and Applications, 2000, 17(4): 519-523. (in Chinese)
- [4] 李德毅, 邱凯昌. 用语言云模型发掘关联规则[J]. 软件学报, 2000, 11(2): 143-158.
LI Deyi, QIU Kaichang. Mining association rules with linguistic cloud models[J]. Journal of Software, 2000, 11(2): 143-158. (in Chinese)
- [5] 徐宗本, 樊忠泽. 基于云神经网络的空间推进系统故障检测与诊断[J]. 兵工学报, 2009, 30(6): 727-732.
XU Zongben, FAN Zhongze. Cloud neural network based fault detection and diagnosis of space propulsion system [J]. Acta Armamentarii, 2009, 30(6): 727-732. (in Chinese)
- [6] 黄强, 吴建军. 基于云-神经网络的液体火箭发动机故障检测方法[J]. 国防科技大学学报, 2010, 32(1): 11-15.
HUANG Qiang, WU Jianjun. Fault detection method based on cloud-neural network of liquid-propellant rocket engine[J]. Journal of National University of Technology, 2010, 32(1): 11-15. (in Chinese)
- [7] 田永清. 基于云模型的数据挖掘算法的研究与应用[D]. 上海: 上海交通大学, 2003.
TIAN Yongqing. Research and application of data mining based on cloud model [D]. Shanghai: Shanghai Jiaotong University, 2003. (in Chinese)
- [8] 柳炳祥, 李海林. 基于云理论与神经网络集成的模糊系统[J]. 计算机应用, 2008, 36(2): 305-306, 310.
LIU Bingxiang, LI Hailin. Induction of fuzzy system based on cloud theory and neural network[J]. Computer Applications, 2008, 36(2): 305-306, 310. (in Chinese)
- [9] 蒋嵘, 李德毅. 数值型数据的泛概念树的自动生成方法[J]. 计算机学报, 2000, 23(5): 470-476.
JIANG Rong, LI Deyi. Automatic generation of pan-concept-tree on numerical data [J]. Chinese J Computers, 2000, 23(5): 470-476. (in Chinese)
- [10] 葛哲学, 孙志强. 神经网络理论与 MATLAB2007 实现[M]. 北京: 电子工业出版社, 2007.
- [11] 秦昆, 王佩. 基于云变换的曲线拟合新方法[J]. 计算机工程与应用, 2008, 44(23): 56-74.
QIN Kun, WANG Pei. New method of curve fitting based on cloud transform[J]. Computer Engineering and Applications, 2008, 44(23): 56-74. (in Chinese)
- [12] 范大鹏, 王雪丹. 云模型方法在选煤厂跳汰系统中的故障检测与诊断[J]. 黑龙江科技学院学报, 2011, 21(4): 289-292.
FAN Dapeng, WANG Xuedan. Fault detection and diagnosis for coal preparation plant jigging system based on cloud model and information fusion[J]. Journal of Heilongjiang Institute of Science & Technology, 2011, 21(4): 289-292. (in Chinese)
- [13] 刘洪刚, 魏鹏飞, 谢廷峰, 等. 液体火箭发动机地面试车过程的实时故障检测方法研究[J]. 宇航学报, 2007, 28(6): 1660-1664.
LIU Honggang, WEI Pengfei, XIE Tingfeng, et al. Research of real-time fault detection method for liquid propellant rocket engines in ground test[J]. Journal of Astronautics, 2007, 28(6): 1660-1664. (in Chinese)
- [14] LIU Honggang, XIE Tingfeng, et al. A real-time fault detection and post-test diagnosis system for liquid-propellant rocket engines in ground tests[C]//58th International Astronautical Congress. Hyderabad, India; [s. n.], 2007: 24-28.
- [15] LIU Honggang, XIE Tingfeng, HUANG Qiang, et al. Real-time on-line fault detection algorithm for liquid-propellant rocket engines[R]. Beijing: 2007 International Symposium on Space Propulsion, 2007.