

基于 KPCA 与模糊积分的燃气轮机状态识别方法^{*}

崔建国¹, 刘 瑶¹, 于明月¹, 蒋丽英¹, 王景霖², 江秀红³

(1. 沈阳航空航天大学自动化学院 沈阳, 110136)

(2. 航空工业集团故障诊断与健康安全技术航空科技重点实验室 上海, 201601)

(3. 沈阳航空航天大学电子信息工程学院 沈阳, 110136)

摘要 针对舰用燃气轮机结构复杂、工作环境恶劣,难以对其状态进行有效识别问题,提出一种基于核主元分析(kernel principal component analysis,简称 KPCA)和模糊积分相结合的状态识别新方法。采用专用试验平台对舰用燃气轮机进行试验,获取其不同工况下的高压转子转速、低压转子转速、涡轮后排气温度及机匣振动等 9 个状态表征参数的原始信息,采用 KPCA 方法提取其状态表征参数的不同核主元,构建特征向量空间。并由提取的核主元特征向量分别创建 GRNN,Elman 神经网络状态识别模型,对燃气轮机状态进行识别。在此基础上,采用模糊积分方法对两种状态识别结果进行决策层融合,得到唯一的状态识别结果,提升了状态识别准确率。研究表明,采用核主元分析和模糊积分相结合的方法,能有效识别出舰用燃气轮机健康与故障状态,具有很好的实际应用价值。

关键词 舰用燃气轮机;核主元分析;神经网络;模糊积分;状态识别

中图分类号 TH136;TP206⁺.3

引 言

舰用燃气轮机作为新型的动力设备,具有结构紧凑、运行平稳、安全可靠、快速启动及较高的热效率等优点,日益受到人们的重视,应用范围也越来越广^[1]。但由于燃气轮机工作环境恶劣,结构复杂,故障发生频率高,因此对其进行状态识别技术研究具有重要的实际研究价值。

多年来,国内外诸多学者一直致力于对燃气轮机状态识别的技术研究,包括神经网络、专家系统、贝叶斯网、优化方法、数据挖掘等。赵元喜等^[2]提出了 BP 神经网络状态识别。刘辉等^[3]提出了广义回归神经网络(general regression neural network,简称 GRNN)状态识别等,但均难以达到实际应用效果。经典的主成分分析是一种线性算法,对非线性数据不能降维,为此,提出一种基于核主元分析和模糊积分组合的方法,对舰用燃气轮机状态进行识别技术研究,利用 KPCA 方法实现数据降维,排除信息重叠部分,构造特征向量^[4],通过模糊积分对 GRNN,Elman 神经网络的状态识别结果进行决策

层融合,实现对舰用燃气轮机状态识别效能。

1 KPCA 特征提取机理

核主元分析(kernel principal component analysis,简称 KPCA)利用事先选取的核函数,将原空间中的输入样本向量 \mathbf{X} 映射到多维特征空间 F 中,输入向量具有了更好的可分性。然后,对多维特征空间 F 中的映射数据做主元分析,进行特征提取。通过选取不同的核函数能够满足不同的非线性变化的要求^[5]。不同的核函数能满足不同的非线性变化,根据多次试验结果选取高斯函数为核函数。

设 x_1, x_2, \dots, x_M 为训练样本, $\{x_i\}$ 为输出空间, Φ 是将 x^d 映射到特征空间 F 中的映射,则协方差矩阵 \mathbf{C} 可以表示为

$$\mathbf{C} = \frac{1}{M} \sum_{\mu=1}^M \Phi(x_{\mu}) \Phi(x_{\mu})^T \quad (1)$$

相应的特征方程可以表示为

$$\mathbf{C}\nu = \lambda\nu \quad (2)$$

其中:特征值 $\lambda \geq 0$ 满足 $\nu \in F$ 或 $\{0\}$ 。

^{*} 国家自然科学基金资助项目(51605309);辽宁省自然科学基金资助项目(2014024003);航空科学基金资助项目(20153354005, 20163354004)

收稿日期:2016-11-27;修回日期:2017-03-17

即有

$$(\Phi(x_\nu)C\nu) = \lambda(\Phi(x_\nu)\nu) \quad (3)$$

$$\frac{1}{M} \sum_{\mu=1}^M \alpha_\mu \left(\sum_{\omega=1}^M (\Phi(x_\nu)\Phi(x_\omega)\Phi(x_\omega)\Phi(x_\mu)) \right) = \lambda \sum_{\mu=1}^M (\Phi(x_\nu)\Phi(x_\mu)) \quad (4)$$

定义 $M \times M$ 维矩阵 \mathbf{K} 为

$$\mathbf{K}_{\mu\nu} = (\Phi(x_\mu)\Phi(x_\nu)) \quad (5)$$

则式(5)可以简化为

$$M\lambda\alpha = \mathbf{K}\alpha \quad (6)$$

从式(6)可计算出特征值和与特征向量。

特征向量在特征空间上的投影为

$$(\nu^k\Phi(x)) = \sum_{i=1}^M (\alpha_i)^k (\Phi(x_i), \Phi(x)) \quad (7)$$

令 $\lambda_1 \geq \lambda_2 \cdots \geq \lambda_M$ 为矩阵的特征值,主元选取法则为

$$\left(\sum_{k=1}^p \lambda_k / \sum_{i=1}^M \lambda_i \right) > E \quad (8)$$

对某型舰用燃气轮机 3 个关键部件(主泵,喷口加力调节器,滑油压差传感器)的 9 个参数按以上 KPCA 方法进行特征提取,具体步骤如下:

- 1) 由式(1)的计算可以得到核矩阵;
- 2) 由式(4)求出特征值和特征向量;
- 3) 由式(7)计算特征向量在特征空间上的投影,可得到特征向量在高维特征空间中的各个主分量;
- 4) 由式(8)计算各主元分量对整体方差的贡献程度与累计贡献率 E ,选取并确定 E 值。根据 E 值确定主元,从而可建立新的样本数据集,即可作为燃气轮机 3 个关键部件状态的特征信息。

2 模糊积分基本理论

设 (X, Ω) 为一可测空间为 x 的所有子集组成的非空集, $g: \Omega \rightarrow [0, 1]$ 上的一个模糊测度, g 满足

- 1) 边界条件: $g(\Phi) = 0, g(X) = 1$;
- 2) 单调性: $\forall A, B \in \Omega$, 若 $A \subseteq B$ 则 $g(B) \geq g(A)$;

3) 连续性:若 $A_1 \subseteq A_2 \subseteq \cdots \subseteq A_n \subseteq \cdots \subseteq$, 则 $g(A_i) = g(\lim_{i \rightarrow \infty} A_i)$, 则称 g 为一个模糊测度。

对于一个有限集合 $\mathbf{X} = \{x_1, x_2, \dots, x_n\}$, 令 g 为模糊测度, 将单个元素的模糊测度记为 $g^i = g(\{x_i\})$, x_i 到 g^i 模糊测度的映射: $x_i \rightarrow g^i = g(\{x_i\}), i = 1, 2, \dots, n$ 称为模糊密度函数。假设 x_i 的识别率为 p_i

$$g^i = \omega_i \frac{p_i}{\sum_{i=1}^n p_i} \quad (9)$$

其中: $\omega_i \in [0, 1]$ 为主观值。

如果存在 $\lambda > -1, \forall A, B \subseteq X, A \cap B = \Phi$, 满足 $g(A \cup B) = g(A) + g(B) + \lambda g(A)g(B)$, 当 $\lambda = 0$ 则 x 的任意集 A 上的模糊测度即是 A 中所有元素的模糊密度之和, $g(X) = \sum_{i=1}^n g^i$; 反之, 若 $\lambda \neq 0$, 则 x 的任意子集 A 上的模糊测度为

$$g(A) = \frac{1}{\lambda} \left\{ \prod_{x_i \in A} (1 + \lambda g^i) - 1 \right\} (\lambda > 1, \lambda \neq 0) \quad (10)$$

其中: λ 的值可以通过求解 $g(X) = 1$ 即 $\lambda + 1 =$

$$\prod_{i=1}^n (1 + \lambda g^i)$$
 求得。

选择在 $[-1, \infty)$ 上的解为最终 λ 的值^[6-7]。

3 神经网络基本理论

3.1 GRNN 神经网络

GRNN 是径向基网络的一种变形形式,具有很强的非线性映射能力和非线性逼近性能,适于处理非线性问题。GRNN 神经网络由输入层模式层、求和层及输出层 4 层神经元构成。其神经网络结构如图 1 所示。




图 1 GRNN 神经网络结构

Fig.1 GRNN neural network structure

3.2 Elman 神经网络

Elman 神经网络是一种反馈网络,由输入层、隐含层、承接层及输出层 4 层神经元组成。Elman 神经网络结构如图 2 所示。

GRNN 和 Elman 神经网络都需要由系统的输入和输出进行建模。其中输入样本维数(经 KPCA 提取后的数据维数)为输入层神经元数目,输出样本维数(故障状态类别数目)为输出层神经元数目。




图 2 Elman 神经网络结构

Fig. 2 Elman neural network structure

4 燃气轮机状态识别技术方案

文中选用某型真实舰用燃气轮机的主泵、喷口加力调节器、滑油压差传感器 3 个关键部件的参数数据对其进行状态识别。状态识别总体方案如图 3 所示。




图 3 燃气轮机状态识别方案

Fig. 3 Gas turbine state recognition approach

首先,采用传感器采集相关参数的试验数据;其次,采用 KPCA 核主元分析的方法对采集到的参数数据进行核主元分析,提取主元并构造特征向量,并将其分为训练数据和测量数据^[8-10],提取主元后的训练数据送入到神经网络训练网络,再用测试数据送入 GRNN,Elman 神经网络进行状态分类;最后,利用模糊积分对 GRNN,Elman 两种神经网络的状态识别结果进行决策层融合,得到最终的状态识别结果。

5 燃气轮机状态识别技术试验

5.1 KPCA 主元模型的建立

采用专业试验平台对某型燃气轮机性能进行测试试验。获取可较好表征燃气轮机状态的高压转子转速、低压转子转速、涡轮后排气温度、机匣振动、低压压气机进口导流叶片转角位置、高压压气机进口导流叶片转角位置、油门杆位置、喷口位置、滑油压差等 9 个参数的不同状态的试验数据。试验数据每种状态选取 50 组数据,4 种状态共 200 组数据,每

种状态前 25 组数据为训练建模数据,后 25 组数据为测试数据。选取正常数据建立 KPCA 核主元分析模型,对其进行核主元分析,确定核主元个数,构造特征向量^[11]。某型燃气轮机 3 个部件 4 种运行状态可表示为集合 $\{A_1, A_2, A_3, A_4\}$, A_1 表示 3 个部件正常; A_2 表示主泵故障; A_3 表示喷口加力调节器故障; A_4 表示滑油压差传感器故障。选用累计贡献率 $E > 0.95$ 作为选取主元的依据,由于前 6 个核主元累计贡献率为 96.20%,故选取主元个数为 6。这样将原本的 9 维数据降为 6 维数据,并排除了信号中相互重叠的部分,且不丢失有用信息。如表 1、表 2 所示。

表 1 核主元贡献率及累计贡献率

Tab. 1 Kernel principal component contribution rate and the cumulative contribution rate %

| 主元 | 贡献率 | 累积贡献率 |
|----|-------|-------|
| 1 | 42.75 | 42.75 |
| 2 | 20.12 | 62.87 |
| 3 | 12.15 | 75.02 |
| 4 | 9.87 | 84.89 |
| 5 | 7.62 | 92.51 |
| 6 | 3.69 | 96.20 |

表 2 燃气轮机状态特征向量

Tab. 2 The state of gas turbine characteristic vector

| 状态样本 | 特征向量 | 状态模式 |
|------|-----------|-------|
| 1 | B_1 | A_1 |
| 2 | B_2 | A_1 |
| 3 | B_3 | A_1 |
| 4 | B_4 | A_1 |
| ⋮ | ⋮ | ⋮ |
| 200 | B_{200} | A_1 |

表 2 中: $B_1 = (-1.4027, -0.0288, 0.1557, 0.4613, -0.3291, 0.0664)$;

$B_2 = (-1.4318, -0.1465, 0.0060, 0.6364, 0.0003, 0.0257)$;

$B_3 = (-1.6542, -0.6971, 0.3234, -0.1509, 0.1438, 0.1890)$;

$B_4 = (-1.4647, -0.4257, 0.4246, 0.1904, 0.3429, 0.0765)$;

⋮

$B_{200} = (0.4764, 0.8438, -0.2527, -0.3533, 0.3052, -0.3721)$ 。

5.2 基于神经网络的状态识别试验验证

根据 KPCA 方法提取的主元个数和状态模式

数设置 GRNN 和 Elman 神经网络的输入层和输出层神经元个数分别为 6 和 4。将 KPCA 方法提取的 A_1, A_2, A_3, A_4 四种状态共 200 组数据分为训练数据集和测试数据集, A_1, A_2, A_3, A_4 的状态模式目标输出分别为: $(1,0,0,0)^T, (0,1,0,0)^T, (0,0,1,0)^T, (0,0,0,1)^T$, 将 100 组训练数据分别送入 GRNN, Elman 神经网络进行训练。再将另外 100 组测试数据送入训练好的 GRNN, Elman 神经网络模型中, 得到状态识别结果如表 3 所示。

表 3 神经网络的状态识别结果

Tab. 3 The state of the neural network recognition results

| 测试样本 | 识别方法 | 实际输出 | 识别结果 | 实际结果 |
|--------|-------|----------|-------|-------|
| 样本 1 | GRNN | C_1 | A_1 | A_1 |
| | Elman | C_2 | A_1 | A_1 |
| 样本 2 | GRNN | C_3 | A_1 | A_1 |
| | Elman | C_4 | A_1 | A_1 |
| 样本 3 | GRNN | C_5 | A_1 | A_1 |
| | Elman | C_6 | A_2 | A_1 |
| ⋮ | ⋮ | ⋮ | ⋮ | ⋮ |
| 样本 99 | GRNN | C_7 | A_4 | A_4 |
| | Elman | C_8 | A_4 | A_4 |
| 样本 100 | GRNN | C_9 | A_4 | A_4 |
| | Elman | C_{10} | A_4 | A_4 |

表 3 中: $C_1 = (1.000\ 0, 0.000\ 0, 0.000\ 0, 0.000\ 0)$;

$$C_2 = (0.997\ 9, 0.125\ 2, 0.000\ 2, 0.000\ 0);$$

$$C_3 = (1.000\ 0, 0.000\ 0, 0.000\ 0, 0.000\ 0);$$

$$C_4 = (0.992\ 7, 0.008\ 2, 0.022\ 1, 0.000\ 8);$$

$$C_5 = (1.000\ 0, 0.000\ 0, 0.000\ 0, 0.000\ 0);$$

$$C_6 = (0.003\ 7, 0.958\ 2, 0.022\ 1, 0.000\ 0);$$

$$C_7 = (0.000\ 0, 0.000\ 0, 0.000\ 0, 1.000\ 0);$$

$$C_8 = (0.018\ 6, 0.084\ 8, 0.000\ 0, 0.892\ 5);$$

$$C_9 = (0.000\ 0, 0.000\ 0, 0.000\ 0, 1.000\ 0);$$

$$C_{10} = (0.000\ 0, 0.002\ 2, 0.000\ 2, 0.996\ 9)。$$

试验结果表明, GRNN 神经网络和 Elman 神经网络的状态识别结果准确率分别为 89% 和 86%。

5.3 基于模糊积分的状态识别试验验证

由表 3 可知, 不同的神经网络对同一状态的数据识别结果出现不同的诊断结果, 为消除这种由不同网络自身特点所导致的差异, 现采用模糊积分的融合方法对 GRNN 和 Elman 神经网络的初步状态识别结果进行融合, 构建决策层融合模型, 提升识别准确率。

基于模糊积分的状态识别主要步骤如下:

- 1) 采用 GRNN 和 Elman 神经网络对处理后的测试数据进行识别, 得到初步识别结果(见表 3);
- 2) 通过 GRNN 和 Elman 神经网络的识别结果得到置信水平 h : 初步识别结果 $\rightarrow [0, 1]$;
- 3) 由测得的每个神经网络的诊断精度确定模糊密度 g^i ;
- 4) 根据确定的 g^i , 计算 λ 值, 求出模糊测度 $g(A)$;
- 5) 计算最终的模糊积分值。将融合结果作为最终的识别结果。

按照以上步骤可得到融合识别结果, 如表 4 所示。

表 4 模糊积分的融合结果

Tab. 4 The fuzzy integral fusion results

| 测试样本 | 融合结果 | 融合识别结果 | 实际结果 |
|--------|-----------|--------|-------|
| 样本 1 | D_1 | A_1 | A_1 |
| 样本 2 | D_2 | A_1 | A_1 |
| 样本 3 | D_3 | A_1 | A_1 |
| ⋮ | ⋮ | ⋮ | ⋮ |
| 样本 99 | D_{99} | A_3 | A_4 |
| 样本 100 | D_{100} | A_4 | A_4 |

表 4 中: $D_1 = (1.000\ 0, 0.191\ 4, 0.146\ 3, 0.651\ 7)$;

$$D_2 = (1.000\ 0, 0.454\ 9, 0.419\ 1, 0.090\ 9);$$

$$D_3 = (1.000\ 0, 0.273\ 3, 0.430\ 4, 0.281\ 9);$$

⋮

$$D_{99} = (0.001\ 1, 0.058\ 8, 1.000\ 0, 0.067\ 8);$$

$$D_{100} = (0.008\ 9, 0.353\ 9, 0.215\ 5, 1.000\ 0)。$$

按照表 4, 得出采用模糊积分对 GRNN 和 Elman 神经网络的初步状态识别结果, 进行决策层融合的准确率为 96%。各种识别方法准确率统计如表 5 所示。

表 5 各种状态识别方法的准确率统计

Tab. 5 Accurate statistics of various kinds of state recognition method

| 识别方法 | GRNN | Elman | 模糊积分 |
|-------|------|-------|------|
| 准确率/% | 89 | 86 | 96 |

由表 5 可知, 采用模糊积分对燃气轮机进行决策性融合得到的状态识别准确率远高于单一神经网络进行状态识别的准确率。表明采用模糊积分的方法可提高状态识别准确率。

6 结束语

研究表明, 采用 KPCA 方法提取舰用燃气轮机

关键部件状态参数的不同核主元,构建特征向量,由此特征向量分别创建 GRNN 和 Elman 神经网络状态识别模型,并进行状态识别,识别准确率分别是 89% 和 86%。在此基础之上,采用模糊积分对决策层信息进行融合,得到唯一的状态识别结果,融合后的准确率为 96%,识别准确率有了很大提升,从而验证了该方法的有效性,为燃气轮机状态识别提供了新思路,具有很好的实际应用价值。

参 考 文 献

- [1] 谢春玲,戴景民. 燃气轮机故障诊断技术研究综述与展望[J]. 汽轮机技术, 2010, 52(1): 1-3.
Xie Chunling, Dai Jingmin. Review and Prospect of gas turbine fault diagnosis technology [J]. Steam Turbine Technology, 2010, 52 (1): 1-3. (in Chinese)
- [2] 赵元喜,胥永刚,高立新,等. 基于谐波小波包和 BP 神经网络的滚动轴承声发射故障模式识别技术[J]. 振动与冲击, 2010, 29(10): 162-165.
Zhao Yuanxi, Xu Yonggang, Gao Lixin, et al. Acoustic emission fault pattern recognition of rolling bearing based on harmonic wavelet packet and BP neural network [J]. Journal of Vibration and Shock, 2010, 29 (10): 162-165. (in Chinese)
- [3] 钱征文,程礼,范家栋,等. 某型航空发动机振动值摆动故障诊断[J]. 振动、测试与诊断, 2012, 32(2): 208-213.
Qian Zhengwen, Cheng Li, Fan Jiadong, et al. Fault diagnosis of vibration amplitude swing for some kind of aeroengine[J]. Journal of Vibration, Measurement & Diagnosis, 2012, 32(2): 208-213. (in Chinese)
- [4] 孙闯,何正嘉,张周锁,等. 基于状态信息的航空发动机运行可靠性评估[J]. 机械工程学报, 2013, 49(6): 30-37.
Sun Chuang, He Zhengjia, Zhang Zhouso, et al. Operating reliability assessment for aero-engine based on condition monitoring information [J]. Journal of Mechanical Engineering, 2013, 49 (6): 30-37. (in Chinese)
- [5] 王逸萍,梅军,郑建勇,等. 基于 KPCA 的高压断路器故障诊断[J]. 电测与仪表, 2013, 50(8): 6-9.
Wang Yiping, Mei Jun, Zheng Jianyong, et al. Fault diagnosis of high voltage circuit breaker based on KPCA [J]. Electrical Measurement and Instrumentation, 2013, 50(8): 6-9. (in Chinese)
- [6] 李业波,李秋红,黄向华,等. 航空发动机气路部件故障融合诊断方法研究[J]. 航空学报, 2014, 35(6): 1612-1622.
Li Yebo, Li Qiu hong, Huang Xianghua, et al. Research on gas fault fusion diagnosis of Aero-engine component [J]. Chinese Journal of Aeronautics, 2014, 35(6): 1612-1622. (in Chinese)
- [7] Alireza R, Fariborz S. Intelligent modeling and identification of aircraft nonlinear flight [J]. Chinese Journal of Aeronautics, 2014, 27(4): 759-771.
- [8] Wang Ci, Jia Limin, Li Xiaofeng. Fault diagnosis method for the train axle box bearing based on KPCA and GA-SVM [J]. Applied Mechanics and Materials, 2014, 23(441): 376-379.
- [9] Li Kunlun, Zhang Yaxin, Liu Huanhuan, et al. Palmprint recognition based on modular PCA and LS-SVM [C]//2015 4th International Conference on Computer, Mechatronics, Control and Electronic Engineering. [S. l.]: Atlantis Press, 2015, 33(6): 556-571.
- [10] 李平,李学军,蒋玲莉,等. 基于 KPCA 和 PSOSVM 的异步电机故障诊断[J]. 振动、测试与诊断, 2014, 34(4): 617-620.
Li Ping, Li Xuejun, Jiang Lingli, et al. Fault diagnosis of induction motors based on KPCA and PSOSVM [J]. Journal of Vibration, Measurement & Diagnosis, 2014, 34(4): 617-620. (in Chinese)
- [11] 周绍磊,廖剑,史贤俊. 基于 FrFT-FD 和 KPCA 模拟电路故障特征提取方法[J]. 振动、测试与诊断, 2014, 34(2): 337-344.
Zhou Shaolei, Liao Jian, Shi Xianjun. Analog circuit fault feature extraction method based on FrFT-FD and KPCA [J]. Journal of Vibration, Measurement & Diagnosis, 2014, 34(2): 337-344. (in Chinese)



第一作者简介: 崔建国,男,1963年8月生,博士后、教授。主要研究方向为飞行器健康诊断、预测与综合健康管理等。曾发表《基于遗传算法和 ARMA 模型的航空发动机寿命预测》(《航空学报》2011年第32卷第8期)等论文。
E-mail: gordon_cjg@163.com