

文章编号: 1000-8055(2006)01-0207-06

粗糙集与神经网络在航空发动机 气路故障诊断中的应用

陈 恬, 孙健国

(南京航空航天大学 能源与动力学院, 江苏 南京 210016)

摘要: 提出了一种基于粗糙集理论和神经网络集成的发动机智能故障诊断方法, 首先对测量数据进行离散处理, 并运用粗糙集理论建立故障决策表, 进而约简属性和提取规则, 对航空发动机气路部件的几种典型故障进行隔离。然后建立神经网络故障诊断子系统, 使用粗糙集处理后的数据计算出发动机气路相关部件的故障程度。最后, 还验证了粗糙集神经网络故障诊断系统的抗噪性能。研究表明, 该系统能够正确而且高效地诊断出发动机故障的严重程度, 并具备良好的抑制噪声的能力。

关键词: 航空、航天推进系统; 粗糙集; 神经网络; 故障诊断; 航空发动机; 气路

中图分类号: V 233. 7;

文献标识码: A

Aeroengine Gas Path Fault Diagnosis Using Rough Sets and Neural Networks

CHEN Tian, SUN Jian-guo

(College of Energy and Power Engineering,

Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China)

Abstract: Aeroengine is a very complex nonlinear object. Traditional methods for its fault diagnosis were proved time-consuming and low efficient. A new system based on rough sets and neural networks for the fault diagnosis of aeroengine gas path component faults was presented in this paper. At first, the rough set theory was used to detect qualitatively faults and to isolate the fault. It consists of three steps: performing the discretion of sensed data, establishing the decision table and generating rules. After that, feed-forward neural networks are added into the system to construct several sub-systems, which take the engine sensible data pretreated by rough sets as inputs and compute damage degrees of the aeroengine fault. Finally, the noise rejection abilities of the engine fault diagnosis system were analyzed. The test results show that the system can quantitatively diagnose the faults of aeroengine gas path components precisely and efficiently, while it is robust for noise rejection.

Key words: aerospace propulsion system; rough sets; neural networks; fault diagnosis; aeroengine; gas path

收稿日期: 2005- 03- 28; **修订日期:** 2005- 08- 09

基金项目: 国家自然科学基金资助(50576033);

作者简介: 陈恬(1978-), 男, 江苏南京人, 南京航空航天大学能源与动力学院博士生, 主要从事航空发动机控制及故障诊断的研究

粗糙集(Rough Set, RS)理论是波兰华沙理工大学计算机科学研究所的数学家 Zdzislaw Pawlak^[1]于1982年提出的一种用于处理不完整不精确知识的数学方法。该理论不需要任何预备的或额外的先验知识,能有效分析和处理不精确、不一致、不完整等各种不完备数据,并从中发现隐含的知识,揭示潜在的规律。该理论具有很强的实用性,近年来日益受到重视,方法日趋成熟,在很多领域^[2~6]产生了一些令人关注的应用。

神经网络的研究已经持续了40多年。神经网络本身所具有的强大的非线性映射能力使其在许多领域成为一种强有力的工具。但神经网络自身的复杂结构常常会致使训练神经网络耗费很长时间。

航空发动机是一个非常复杂的非线性对象,其故障诊断的难度较大。近年来,一些智能化的发动机状态监视和故障诊断技术得到了发展和应用^[7]。这一技术的一个重要关键是发展一个准确、快速的诊断方法。然而,航空发动机在实际使用中常常发生多特征、多过程和突发性故障,另外由于使用环境的限制,不可能测量很多参数,而且得到的测量数据也并不完全,如何从有限的监视信息中正确诊断出发动机的故障便成了一个技术难点。针对这种情况,本文以某型涡扇发动机为对象,提出了基于粗糙集理论和神经网络的智能故障诊断方案,对航空发动机的气路部件故障进行诊断。文献[5]中讨论了在模式识别中将粗糙集作为神经网络数据预处理的方法,文献[6]分析了这一方法的步骤。但在这两篇文献中神经网络是作为分类器,粗糙集的用途是减少神经网络分类器的输入维数。另外,这两篇文献中的方法并没有用于故障诊断。如果用于故障诊断,则其只能实现故障的定性隔离而不能实现定量的诊断。本文中BP神经网络作为一个非线性映射工具,可以定量的诊断出发动机的故障,而粗糙集作为分类器,将对故障进行隔离和分类。

1 粗糙集理论

定义信息系统 $S = \{U, A, V_a, f_a\}_{a \in A}$, 其中 $U = \{u_1, u_2, \dots, u_p\}$ 为非空集合,称为论域; $A = \{a_1, a_2, \dots, a_h\}$ 也是一个有限非空集合,称为属性集。如果 $A = C \cup D$ 且 $C \cap D = \emptyset$, 则信息系统 $\{U, A\}$ 被称作决策表,其中 C 和 D 为 A 的子集,分别称作 A 的条件属性和决策属性。故该信息系统可以写作 $S = \{U, C, D, V_a\}_{a \in C \cup D}$ 。

决策表约简后可以得到规则,但每一条规则的可信任度是不同的,这里引入了支持数(Support)和正确率(accuracy)两个概念来表征规则的可信任程度。

对于一个规则 $\varphi \rightarrow d$ 来说(φ : 条件属性, d : 决策属性),支持数(Support)定义为所有具有属性 φ 和决策 d 的规则总数,描述的是在属性的基础上,能得到决策的正确性:

$$\text{accuracy}(\varphi \rightarrow d) = \frac{\text{Support}(\varphi, d)}{\text{Support}(\varphi)} \quad (1)$$

因此正确性越高说明由的可能性越大, $\text{accuracy}(\varphi \rightarrow d) = 1$, 则 $(\varphi \rightarrow d)$ 肯定成立。

2 粗糙集和神经网络故障诊断系统

首先建立的诊断系统的结构如图1所示,其中有2个基本部分:粗糙集和神经网络诊断子系统。




图1 初步设计的诊断系统结构图

Fig 1 Structure of the system designed in the first step

2.1 系统的输入

系统的输入为发动机测量参数。由于客观条件的限制,无法获得发动机试车数据,所以本文以某型发动机部件级数学模型为研究对象,所有采集的数据均来自于该模型。为模拟发动机气路部件的故障,研究中采取了在发动机气路部件模型的性能量(效率和流通能力)计算公式上乘以一个故障系数的方法,将模型拉偏,此时采集的数据即为该部件出现故障时的测量数据。

2.2 粗糙集数据预处理

2.2.1 离散化

粗糙集拥有很强的处理离散数据的能力,但

其处理连续数据的能力较弱。所以对于连续数据, 必须先将其离散化。常用的离散化方法有等距离算法、等频率算法、Naive Scaler 算法、SemiNaive Scaler 算法、Boolean Reasoning 算法等。等频率算法将每个条件属性单独考虑, 而且离散过程中没有使用决策属性。对于Naive Scaler 算法和SemiNaive Scaler 算法, 离散过程中在一个时刻只考虑了一个条件属性, 但同时使用了决策属性。在 Boolean Reasoning 算法中, 所有的条件属性都被同时考虑了, 而且结合使用了决策属性。本文在研究中, 分别使用了以上 4 种离散化方法, 并比较了诊断的正确性。结果显示使用 Boolean Reasoning 算法离散化后的诊断效果最好, 故而最终本文使用了该算法对数据进行离散化处理。

2.2.2 决策表的形成和约简, 规则的支持数和正确率

(1) 理论中知识的表示方法是采用决策表的形式。由离散化后的数据组成决策表, 包括条件属性(离散化后的测量参数)和决策属性(测量参数所对应的故障种类)。本文针对航空发动机气路故障所建立的决策表 $S = (U, A)$, U 为不同的发动机故障(包括无故障), $A = C \cup D$, 其中条件属性 $C = (c_1, c_2, \dots, c_{12})$ 为 12 个可测量参数集合, 决策属性 $D = (d_1, d_2, \dots, d_6)$ 对应于 6 个故障种类。 C 和 D 的详细定义请分别见表 1 和表 2。

表 1 条件属性说明
Table 1 Condition attribute C

序号	条件属性内容
C1	PN C: 高压转子转速
C2	PN F: 低压转子转速
C3	T ₂₂ : 风扇出口温度
C4	P ₂₂ : 风扇出口压力
C5	T ₃ : 压气机出口温度
C6	P ₃ : 压气机出口压力
C7	PS ₁₆ : 外涵出口压力
C8	TS ₁₆ : 外涵出口温度
C9	T ₄₂ : 高压涡轮出口温度
C10	P ₄₂ : 高压涡轮出口压力
C11	P ₆ : 低压涡轮出口压力
C12	T ₆ : 低压涡轮出口温度

表 2 决策属性说明
Table 2 Decision attribute D

序号	决策属性内容
d ₁	无故障
d ₂	风扇故障
d ₃	压气机故障
d ₄	燃烧室故障
d ₅	高压涡轮故障
d ₆	低压涡轮故障

(2) 当决策表规模比较小的时候, 可以用手工进行约简。但当测量参数多和样本数多导致决策表规模较大时, 需要使用计算机根据算法编程实现约简。对决策表化简可供选择的算法有遗传算法^[8]、Johnson 算法等, 本文通过比较约简结果, 采用了以遗传算法编程约简决策表的属性和属性值, 得到诊断规则。

(3) 编程计算每条诊断规则的支持数和正确率。如果某条规则的正确率不为 1 时, 本文采用正确性最大的规则作为决策规则, 这样可以排除奇异数据的干扰, 从而提取出最终的决策规则。

2.3 神经网络故障诊断子系统

本文使用 BP 神经网络来构建故障诊断子系统计算出航空发动机的故障程度, 从而达到定量诊断故障的目的。神经网络的输入为经过粗糙集预处理过的测量数据, 输出为相应的发动机性能量。设有 m 类决策属性 $D_0, D_1, \dots, D_{m-1}$, 其中 D_0 代表“无故障”, $D_1, \dots, D_{m-1}$ 代表其他各类故障, 则有 $m-1$ 个神经网络子系统需要训练。若 $X_i (i=1, 2, \dots, m-1)$ 是对象的集合, D_i 为决策属性, 则 X_i 中的测量数据构成了第 i 个神经网络子系统的输入, 故障程度构成了第 i 个神经网络子系统的输出。在本文的研究中, 故障程度由发动机气路部件的性能量(效率和流通能力)的变化值来表示。第 i 个神经网络子系统可以描述为:

$$Output_i = f_{net_i}(Input_i)$$
$$i = 1, 2, \dots, m - 1 \tag{2}$$

3 仿真和结果分析

3.1 诊断系统仿真

首先在 4 个发动机典型工作点开启发动机模型: 设计点 ($H = 0, Ma = 0$)、亚声速巡航点 ($H =$

表3 部分决策规则
Table 3 A part of decision rules

序号	规 则
1	$c_1=1 \text{ AND } c_2=1 \text{ AND } c_6=0 \text{ AND } c_7=1 \Rightarrow \text{Non-fault}$
2	$c_1=1 \text{ AND } c_6=1 \Rightarrow \text{Fan fault}$
3	$c_2=0 \text{ AND } c_6=1 \Rightarrow \text{High compressor fault}$
4	$c_6=0 \text{ AND } c_8=1 \Rightarrow \text{Combustor fault}$
5	$c_6=0 \text{ AND } c_7=0 \text{ AND } c_8=0 \Rightarrow \text{HPTurbine fault}$
6	$c_1=0 \text{ AND } c_2=1 \text{ AND } c_7=1 \Rightarrow \text{LPTurbine fault}$

5 km, $M_a=0.85$)、亚声速巡航点2 ($H=9$ km, $M_a=0.9$)、超声速突防点 ($H=12$ km, $M_a=1.5$), 共记录 848 组样本。每组样本中包括发动机可测量参数(转子转速、温度和压力)和性能量(效率和流通能力)。在样本空间中, 70% 的样本为训练样本, 30% 的样本为检测样本。

系统从输入样本中提取出 17 条诊断规则, 由于篇幅限制, 无法将得到的全部 17 条诊断规则列出, 表 3 只中列出了 6 条典型的规则。

研究中, 所得到的诊断规则基本可以与专家经验相一致。以表 3 中第一条规则“ $c_1=1 \text{ AND } c_2=1 \text{ AND } c_6=0 \text{ AND } c_7=1$ ”为例, 在离散过程中, c_1, c_2, c_6 和 c_7 的离散化区间分别为:

$$\begin{aligned} c_1: [-\infty, 0.994\ 548\ 98, +\infty] &\Rightarrow 1, \\ [0.994\ 548\ 98, +\infty] &\Rightarrow 0 \\ c_2: [0.998\ 248\ 93, +\infty] &\Rightarrow 1, \\ [-\infty, 0.998\ 248\ 93] &\Rightarrow 0 \\ c_6: [1.001\ 620\ 05, +\infty] &\Rightarrow 1, \\ [-\infty, 1.001\ 620\ 05] &\Rightarrow 0 \\ c_7: [0.979\ 849\ 99, +\infty] &\Rightarrow 1, \\ [0.979\ 849\ 99, +\infty] &\Rightarrow 0 \end{aligned}$$

所以, “ $c_1=1 \text{ AND } c_2=1 \text{ AND } c_6=0 \text{ AND } c_7=1$ ”即表示“ $PNC \geq 0.994\ 548\ 98 \text{ AND } PNF \geq 0.998\ 248\ 93 \text{ AND } P_3 \leq 1.001\ 620\ 05 \text{ AND } PS_{16} \geq 0.979\ 849\ 99$ ”。由于条件属性中的可测量参数都已经进行了标准化处理(将测量参数除以发动机设计点时相同工作状态的该测量参数), 则无故障样本的 PNC, PNF, P_3 和 PS_{16} 都应该等于 1。所以第一条规则的结论和专家经验是一致的, 并且由粗糙集所得到的规则比专家经验可以更准确地隔

离故障。
然后针对 5 种故障类型构建 5 个神经网络子系统。根据实验效果, 确立每个子系统的网络结构为 12- 26- 2。输入为 12 个发动机可测量参数, 输出为 2 个部件性能量。以对应于风扇故障的神经网络子系统为例, 其输出为风扇效率 (ETA_F) 和流量系数 (WA_{22C}) 的变化量。神经网络的训练函数为 *trainbr*, 训练误差目标为 0.000 01。

3.2 对比研究

接下来, 为分析所设计故障诊断系统(系统 A)的优越性, 我们构建了一个只有神经网络的故障诊断系统(系统 B)进行对比研究。图 1 中已经给出了系统 A 的结构, 而系统 B 为常规的神经网络, 其结构为 12- 26- 10, 输入与系统 A 相同, 输出为发动机 5 个部件的 10 性能量的变化值。对比研究中系统 B 的训练样本和测试样本与系统 A 相同, 仿真结果如表 4 所示。

表 4 254 个检测样本的诊断结果
Table 4 Diagnosis results for 254 testing samples

决策属性	系统 A	系统 B
$\Sigma Ed1/\%$	0	0.026 8
$\Sigma Ed2/\%$	0.938 6	2.715 2
$\Sigma Ed3/\%$	0.163 7	1.563 3
$\Sigma Ed4/\%$	1.451 7	2.476 1
$\Sigma Ed5/\%$	0.275 1	1.073 2
$\Sigma Ed6/\%$	1.391 2	1.986 3
$\Sigma Ed/\%$	4.245 5	9.840 9

表 4 中系统 A 的 $\Sigma Ed1$ 为故障隔离错误率。由于粗糙集将此类样本归类入“无故障”, 故系统 A 无需计算出效率和流通能力的变化, 所以对于系

统A, Σ_{Ed1} 指标代表被错误归入“无故障”类别的故障样本数目的比例。

系统A 的 Σ_{Ed2} - Σ_{Ed6} 指标表示相应发动机气路故障部件性能量的诊断误差, 即各个神经网络子系统的诊断误差。以子系统1 为例:

$$\Sigma_{Ed2} = \sum_{i=1}^n \left(\left| \frac{\Delta E T A F_{NNout}^i - \Delta E T A F^i}{\Delta E T A F^i} \right| + \left| \frac{\Delta W A 22C_{NNout}^i - \Delta W A 22C^i}{\Delta W A 22C^i} \right| \right) \times 100\%$$

式中: n 为风扇故障的样本数目, $\Delta E T A F_{NNout}$ 为神经网络子系统1 输出的 $E T A F$ 的变化值, $\Delta E T A F$ 为相应测试样本中 $E T A F$ 的原始变化值, $\Delta W A 22C_{NNout}$ 为神经网络子系统1 输出的 $W A 22C$ 的变化值, $\Delta W A 22C$ 为相应测试样本中 $W A 22C$ 的原始变化值。

系统B 的 Σ_{Ed1} 为神经网络输出层中输出值最大的神经元的诊断误差之和。因为对于无故障的测试样本, 神经网络输出层每个神经元的输出都应该为零, 所以本文将输出误差最大的神经元的输出作为“无故障”样本的诊断误差。

系统B 的 Σ_{Ed2} - Σ_{Ed6} 分别对应于5 种故障的诊断误差, 即相对应的输出层神经元的输出。例如, Σ_{Ed2} 和式3 的形式相同, 但其中 $\Delta E T A F_{NNout}$ 和 $\Delta W A 22C_{NNout}$ 分别为系统B 神经网络输出层的第1 个和第2 个神经元的输出, 而 $\Delta E T A F$ 和 $\Delta W A 22C$ 分别为相应的测试样本中 $E T A F$ 和 $W A 22C$ 的原始变化量。




图2 最终的诊断系统的机构图

Fig 2 Final diagnosis system structure

从表4 中可以看出, 系统A 的诊断误差要小于系统B。另外, 系统B 中神经网络的训练步数为6 864, 而系统A 中5 个神经网络子系统训练步数

的总和为373。

表5 噪声数据和无噪声数据的诊断比较

Table 5 Comparison between data with and without noise

误差统计	无噪声样本	有噪声样本
Max (e) /%	0.068 3	0.114 7
Mean (e) /%	0.013 8	0.053 5
Med (e) /%	0.006 7	0.021 9
2σ(e) /%	0.015 4	0.076 0

3 3 提高系统的抗噪声能力

最后, 由于测量数据中往往含有噪声干扰, 所以设计的故障诊断系统对于噪声的抵抗能力至关重要。为此, 本文在所设计的诊断系统中集成入自联想神经网络滤波器。诊断系统的最终结构如图2 所示。我们在测试样本中加入随机白噪声, 噪声由MATLAB 软件中的Randn 函数产生, 噪声的均值为0, 方差为1, 标准偏差为1。根据发动机实际使用中的情况, 噪声的信噪比被设置为1 : 0.02。使用254 组测试样本进行仿真验证, 仿真结果如表5 所示, 其中 σ 为诊断误差的标准偏差。从表中可以看出, 噪声对于诊断效果的影响不大, 基于粗糙集和神经网络的故障诊断系统的抗噪能力是令人满意的。

4 结 论

(1) 如果在决策表出现了条件属性相同而决策属性不同的情况, 则选择正确率accuracy 最大的规则作为最终的决策规则。

(2) 粗糙集可以隔离发动机故障, 这使得作为诊断子系统的神经网络的结构得到简化, 神经网络的训练步数得到减少。

(3) 粗糙集可以定性的隔离发动机故障, 神经网络可以定量的诊断出故障程度, 将这两者结合使用可以得到比单一使用这两种方法更好的诊断结果。

参考文献

[1] Pawlak Z Rough Sets[J]. International Journal of Information and Computer Sciences, 1982, 11: 341~ 356

[2] Nguyen, Tuan Trunq Rough set approach to domain knowledge approximation[R]. Fundamenta Informaticae, 2004, 59(2~ 3): 261~ 270

- [3] Nowicki Robert Rough Sets in the Neuro-Fuzzy Architectures Based on Non-Monotonic Fuzzy Implications [R]. *Lecture Notes in Artificial Intelligence (Subseries of Lecture Notes in Computer Science)*, v 3070, *Artificial Intelligent and Soft Computing- ICA ISC 2004*: 518~525
- [4] James F, Zbigniew S, Shan S, Sheela R, Witold P, Pizzi N. Classification of Meteorological Volumetric Radar Data Using Rough Set Methods [R]. *Pattern Recognition Letters*, 2003, 24(6): 911~920
- [5] Roman W Swiniarski, Andrzej Skowron. Rough Set Methods in Feature Selection and Recognition [R]. *Pattern Recognition Letters*, 2003, 24(6): 833~849
- [6] Szczuka M. Rough Sets and Artificial Neural Networks [R]. *In: Rough Sets in Knowledge Discovery 2: Applications, Case Studies and Software Systems, Physica-Verlag, Heidelberg*, 1998: 449~470
- [7] 陈恬, 孙健国, 杨蔚华, 等. 自组织神经网络航空发动机气路故障诊断[J]. *航空学报*, 2003, 24(1): 46~48
- Chen Tian, Sun Jianguo, Yang Weihua, et al. Self-Organizing Neural Network Based Fault Diagnosis for Aeroengine Gas Path [J]. *ACTA AERONAUTICA ET ASTRONAUTICA SINICA*, 2003, 24(1): 46~48
- [8] Wroblewski, Jakub. Finding Minimal Reducts Using Genetic Algorithm (Extended Version) [R]. *Warsaw University of Technology, Institute of Computer Science, Reports- 16/95*