

基于 ANFIS 的涡轮发动机风车工况建模仿真*

武志文, 于达仁, 牛军, 郭钰锋

(哈尔滨工业大学 能源科学与工程学院, 黑龙江 哈尔滨 150001)

摘要: 小样本情况下神经网络模型泛化能力不足的缺陷限制了其在涡喷发动机风车工况建模中的应用。在十组风车工况实验数据的基础上建立了涡喷发动机风车工况的神经网络模型, 并且利用人们对涡喷发动机动静态、相似参数以及剩余功率与加速度的关系等先验知识不断对神经网络的输入变量进行变换, 逐次减少神经网络的训练样本数目, 最终只用一组训练样本就可以训练出泛化能力较强的神经网络模型, 大大提高了小样本情况下神经网络的泛化能力。仿真结果表明, 该方法简单有效。

关键词: 涡轮喷气发动机; 风车工况; 模糊神经网络; 先验知识

中图分类号: V231 文献标识码: A 文章编号: 1001-4055 (2005) 02-0162-05

Turbojet modeling and simulation in wind milling based on ANFIS

WU Zhiwen, YU Da-ren, NIU Jun, GUO Yu-feng

(School of Energy Science and Engineering, Harbin Inst. of Technology, Harbin 150001, China)

Abstract The deficiency of weak generalization ability in the case of small sample size has restricted neural network's application in modeling of wind milling. Based on ten samples experimental data of wind milling, a neural network's model of wind milling is built. By incorporating prior knowledge of dynamic and static state of rotor, similar parameters and the relationship between residual power and acceleration, the training samples numbers can be decreased step by step. Finally a neural network model of wind milling which has a good generalization ability can be set up in the case of just one training sample. The incorporation of prior knowledge greatly improves neural network's generalization ability. Results of the simulation prove that the method is simple and effective.

Key words Turbojet engine, Wind milling, Fuzzy neural network, Prior knowledge

1 引言

建立航空发动机风车起动工况的合理模型是确定可靠点火点的关键所在。但是由于风车工况是发动机一种存在强烈非线性的非设计工况, 因此长期以来该工况模型的建立都依赖于大量的吹风试验。目前, 虽然神经网络技术因其强大的非线性逼近能力为建模、控制、仿真等各领域非线性问题的解决提供了一种强有力手段, 在航空发动机风车工况的建模中也显示出了较好的效果^[1], 但是神经网络自身在小样本情况下泛化能力不足的缺陷却大大限制了它的实际应用。

近年来, 研究学者们提出了很多提高神经网络泛化能力的方法和途径, 总的来说, 这些方法可以归为

两种: 增加训练样本的容量和减少神经网络的自由度^[2-3]。前者意味着需要大量的实验数据, 这对于发动机行业来讲, 将会增加实验成本, 显然很不经济, 而且限于安全性的考虑对于某些特殊工况也难以取得大量实验数据。对于后者而言, 影响网络自由度的最主要因素就是神经网络输入变量的维数, 其影响是指数级的。因此在小样本情况下, 合理降低神经网络输入维数是增强神经网络模型泛化能力的最有效途径^[4-5]。PCA (Principal component analysis) 方法可以被用来提取神经网络输入变量的主成分, 从而减少输入变量的维数^[6]。但是 PCA 方法是输入变量的线性组合, 这对于本质非线性的问题是不合理的。在 PCA 方法基础上拓展得到的非线性 PCA 方法虽然考虑了变量之间的一些非线性关系, 但是对于具体的问题

* 收稿日期: 2004-04-09 修订日期: 2004-11-16

作者简介: 武志文 (1978—), 男, 博士生, 研究领域为航空航天推进器。E-mail wuzhiwen@hit.edu.cn

题仍然缺乏普遍适用的非线性变换关系^[7~8]。而且这些 PCA 方法单纯从数学的角度来提取变量的主成分, 不考虑变量的实际物理含义, 因此组合以后的变量也存在难于被人理解的缺陷。

在实际建模问题中, 除了传感器测得的数据样本以外, 人们往往还掌握了很多关于对象结构和变化规律的先验知识。合理有效的利用这些先验知识来减少神经网络自由度, 不仅简单方便, 而且也能克服 PCA 方法单纯从数学角度来降低神经网络自由度所带来的缺陷。本文在文献 [1] 的基础上, 利用专家对发动机所掌握的静动态、相似参数、剩余功率与加速度关系的先验知识来重新选择涡喷发动机风车工况神经网络模型的输入变量, 结果随着先验知识的加入, 达到同样泛化能力所需的训练样本数目也逐渐减少, 最终只需要一组训练样本就可以训练出泛化能力较高的风车工况神经网络模型, 大大提高了小样本情况下神经网络的泛化能力。

2 风车工况神经网络建模

2.1 风车工况的特点以及模型结构

图 1 为某涡喷发动机在风车工况中的一组典型实验数据, 实验数据进行了归一化处理。其中 p_1^* , p_2^* 和 n 分别为来流总压, 压气机后总压和转子转速。由图 1 可见, 转速 n 上升过程中 $p_2^* / p_1^* < 1$, 此时压气机处于做功状态, 这种非正常工况造成了建模的困难。

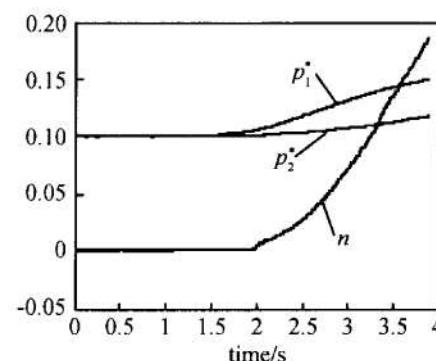


Fig 1 Curve of total pressure in wind m illing

如略去发动机热惯性, 只计及转子惯性, 那么发动机转子风车阶段的神经网络数学模型可以写作关系式

$$\frac{dn}{dt} = f(p_1^*, p_2^*, n) \quad (1)$$

现共有十组发动机实际试车数据, 每组数据样本都由以下实测变量构成: p_1^* , p_2^* , n 。为了消除变量量纲对于神经网络建模的影响, 所有变量均进行了归一

化处理。文献 [1] 先对转速做平滑微分处理求出转子加速度 a , 将风车工况的建模表示成了式 (2) 的形式, 这就相当于通过利用发动机静动态的先验知识将动态建模问题 (1) 转换成了静态建模问题 (2), 从而减少了一维时间变量。因此, 文献 [1] 在选择七组试车数据作为训练样本, 所有十组数据均作为检验样本的时候, 训练出来的神经网络具有足够的泛化能力。

$$a = f(p_1^*, p_2^*, n) \quad (2)$$

但是发动机行业中限于经济性的考虑, 实验样本数据是少量的, 而且对于某些特殊工况而言, 受安全性的限制, 实验样本的数目更少, 因此在小样本的前提下得到具有强的泛化能力的神经网络模型对于发动机行业来讲尤为重要。所以本文在文献 [1] 基础上继续运用先验知识不断重新组合式 (2) 中的四个变量, 最终只用一组训练样本就可以训练出有较好泛化能力的发动机风车工况神经网络模型。

2.2 相似参数的运用

相似理论是发动机行业中普遍采用的重要理论。根据相似原理, 可将影响发动机性能的全部物理量适当的组合成几个无量纲的相似参数, 从而将分散在许多物理变量上的信息集中到某几个相似参数上, 然后把这些相似参数都各自作为一个整体来研究各个物理量之间的函数关系, 这样不仅可以大大减少影响发动机性能的变量数目, 降低问题的复杂性, 而且采用相似参数绘制出的压气机特性曲线图适用于各种工况, 具有通用性。

主成分分析 (PCA) 是将分散在一组变量上的信息集中到某几个主成分上的统计分析方法, 利用该方法分析数据集的时候, 既便于利用主成分描述数据集内部的结构, 实际上也起着数据降维的作用。但是, 由于 PCA 方法只适用于线性变换, 这就限制了它在存在强烈非线性的风车工况中的应用。目前, 虽然已经有一些将线性 PCA 拓展到非线性领域的非线性 PCA 方法, 但是这些非线性 PCA 方法单纯从数学角度寻找普遍适用的非线性变换, 这通常都很难得到普遍适应的结论^[8]。

可见, 相似参数与非线性 PCA 方法在思路上有相同之处, 只不过相似参数是利用压气机的先验知识为变量找到了一种恰当的非线性变换, 从而既合理的降低了变量的维数, 又克服了非线性 PCA 单纯从数学角度寻找恰当非线性变换的难点。因此, 遵循这一思路, 在文献 [1] 的基础上, 通过相似原理重新选择了风车工况模型 (2) 的输入变量, 然后再用神经网络

对其建模。仿真结果表明用相似参数做输入参数表示的风车工况神经网络模型具有更强的泛化能力。

2.2.1 模型建立与仿真

相似原理中常用压比相似参数来表征压气机压力对发动机性能的影响,因此,本文引入压比相似参数来代替式(1)中的 p_1^* 和 p_2^* ,将风车工况模型表示成式(3)的形式,然后再对式(3)用神经网络进行建模

$$a = f(\pi, n) \quad (3)$$

式中 $\pi = p_2^*/p_1^*$,表征压气机的压比。

神经网络的训练是利用Matlab中Fuzzy工具箱中的ANFIS进行的。模糊神经网络融合了模糊逻辑易于表达语言信息和神经网络强大学习能力的优点,适于融合先验知识的非线性系统建模。为了表述方便,在以下的论述中均用网络A代表式(2)训练出的神经网络模型;用网络B代表式(3)训练出的神经网络模型。为了比较两个网络的泛化能力,只采用两组数据作为训练样本,用全部十组数据来做检验样本。其中网络A的输出结果如图2所示,网络B的输出结果如图3所示。图中实线表示传感器实测值,虚线表示神经网络输出值。

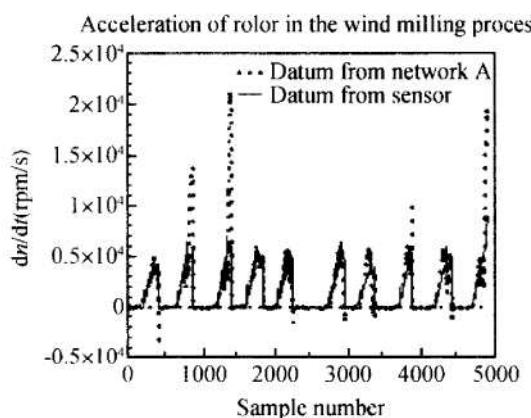


Fig 2 Comparison simulation result of network A with experimental datum

从图2和图3可以看出,当只用两组数据作为训练样本的时候,引入压比相似参数的网络B的泛化能力要明显好于网络A的泛化能力。值得说明的一点是,为了弱化训练样本自身的质量对于泛化能力的影响,重复做了若干组实验,每次实验选用的两组训练样本均是从十组数据中随机选取的,每次的结果都表明网络B要比网络A有强的泛化能力。

2.2.2 仿真结果分析

PCA方法是将原来的所有输入变量做线性组合作为新的输入变量,为了使新的输入变量尽可能多地

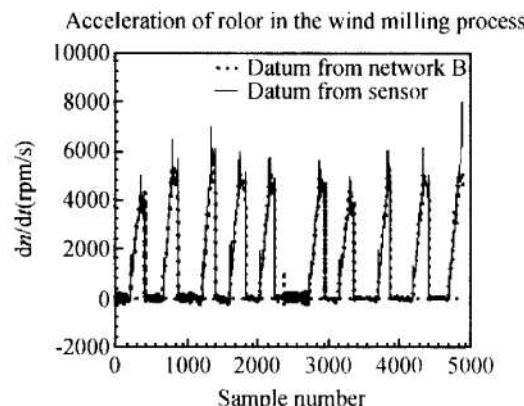


Fig 3 Comparison between simulation result of network B and experimental datum

反映原来变量的信息,就要使新变量的方差最大。因此,为了说明压比相似参数的非线性PCA效应,我们比较了 p_1^* 和 p_2^* 所有线性组合中的最大方差和组合成压比相似参数的方差,结果如表1所示。

Table 1 Comparison of variance

Recom bining mode	Linear combination	Ran pressure
Variance	5.1730×10^{-4}	2.4000×10^{-3}

从表1可以看出,组合成压比相似参数以后,数据的方差与 p_1^* 和 p_2^* 所有线性组合中可能达到的最大方差相比,前者将近是后者的10倍。所以从方差的角度表明压比相似参数是 p_1^* 和 p_2^* 的一种集合了较大信息量的非线性PCA变换。另外,组合成压比的形式,具有明确的物理含义,与单纯从数学角度进行变量组合更富有合理性。

2.3 转子加速度关系的运用

从建模的角度来讲,模型包含正确反映实际物理对象特性的信息量越多,所建立模型的准确度也越高。而在实际建模中,人们往往已经对因变量与自变量之间的关系有了一些定性、模糊的认识,只不过这些认识尚未达到建立机理模型的程度。如果将这些先验知识合理的融入神经网络建模中,也将提高神经网络模型的准确度,从而大大改善神经网络的泛化能力^[9]。因此,在式(3)的基础上,我们又将发动机转子的加速度与剩余功率的关系引入到风车工况建模中,仿真结果表明,随着这些先验知识的加入,神经网络的泛化能力得到了进一步的提高。

2.3.1 模型建立与仿真

发动机转子的加速度是由剩余功率产生的,即由先验知识可得风车工况的动态模型满足公式

$$Jn \cdot dn/dt = \Delta V \quad (4)$$

式中 J 为转子惯量, 是一个常数。 ΔV 为转子的剩余功率。

另外, 从压气机的特性可以得到, 压气机的比功率与 π 相关, 而与转速无关, 因此, 从式(4)可知转速只影响式(4)的左边。从而利用此先验知识将式(3)表示的风车工况神经网络模型重新组合成式(5)的形式, 然后再对式(5)进行神经网络建模。模型的输出是转速平方的导数 dn^2/dt , 对其积分再开方就得到转子的转速 n 。

$$dn^2/dt = f(\pi) \quad (5)$$

以下论述中用网络 C 来代表用式(5)训练出的网络。为了继续比较网络 B 与网络 C 的泛化能力, 只随机选取一组数据样本作为训练样本。弱化训练样本自身质量对于泛化能力影响的策略同上, 神经网络模型的输出结果如图 4 和图 5 所示。其中, 为了比较二者的泛化能力, 把网络 B 的输出加速度积分得到了转子转速。

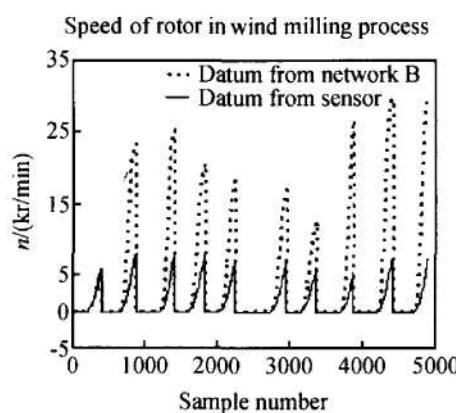


Fig 4 Comparison between simulation result of network B and experimental data

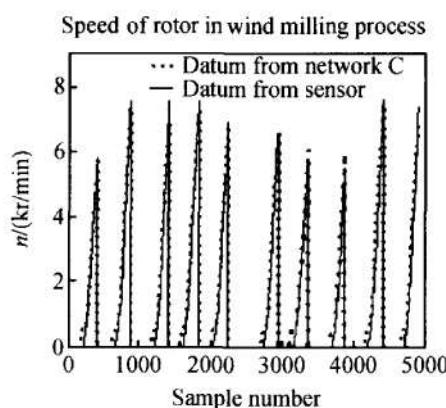


Fig 5 Comparison between simulation result of network C and experimental data

比较图 4 与图 5 可以看出, 由于发动机转子剩余功率与加速度关系的先验知识的加入, 网络 C 的泛化能力比网络 B 的更强。

2.3.2 仿真结果分析

作出式(3)的两个输入变量的关系曲线, 即压气机归一化后的压比与归一化的转速曲线如图 6 所示。从图中可以看出, 转速与压比存在很强的相关性, 而式(5)通过先验知识的加入, 不仅合理的解除了这种相关性, 而且减少了一维输入变量, 从而得到了更强的泛化能力。

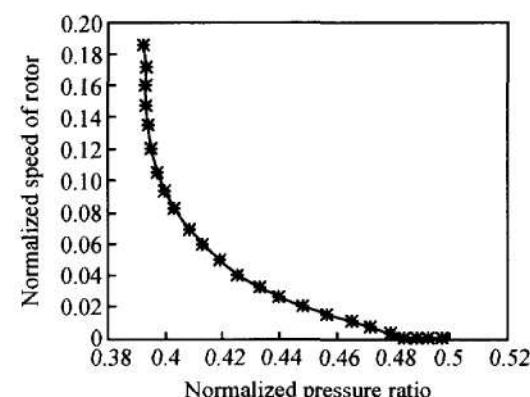


Fig 6 Relationship curve between speed of rotor and ram pressure

3 结果讨论

用检验样本的转速误差平方和表征所建神经网络模型的泛化能力, 即

$$\sum \delta^2 = \sum (n - \hat{n})^2 \quad (6)$$

式中 n 为实际转速测量值, \hat{n} 为神经网络模型输出值。

对于上述网络 A, B, C 所描述的模型分别用七, 四, 二, 一组样本作训练样本构建神经网络模型, 再用全部十组样本作检验样本得到 $\sum \delta^2$ 表征每个神经网络模型的泛化能力, 结果如表 2 所示。

Table 2 Comparison of generalization ability

Network	Seven samples	Four samples	Two samples	One samples
A	0.3757	0.3757	3.1133	203.9687
B	0.2186	0.2186	0.4971	1.0315×10^3
C	1.6210	2.2177	2.6641	2.6641

从表 2 可以看出, 随着训练样本数的减少, 网络 A, B, C 的 $\sum \delta^2$ 的增加速率是不同的。网络 A 在样

本数目减少时, $\sum \delta$ 的增加速率很大, 而网络 C 基本上处于平缓。因此, 在小样本情况下, 网络 C 仍然训练出了有较高泛化能力的网络模型。

另外, 对于相同数目训练样本而言, 由于神经网络 A, B, C 的输入变量维数逐渐减少, 训练样本对于样本集合总体的覆盖率就逐渐增加, 因此网络 C 在小样本情况下会有强的泛化能力。

本文的仿真结果都是在 ANFIS 模型下得到的, 与其它神经网络模型相比, 模糊神经网络虽然非常适合于融合语言信息描述的先验知识, 但是由于本文仅在选择神经网络的输入变量方面运用了先验知识, 所以其它神经网络模型也可以应用。为了弱化网络模型选取对于结果的影响, 本文又分别选用了 BP 网络和 RBF 网络进行了模型的建立与仿真, 仿真结果均表明利用先验知识重新选取神经网络模型的输入变量可以有效提高小样本情况下神经网络模型的泛化能力。

4 结 论

神经网络为涡喷发动机风车工况建模提供了一种强有力手段, 但神经网络自身却存在泛化能力不足的缺陷。本文在传统风车工况神经网络模型的基础上, 提出了利用发动机动静态、相似参数、剩余功率与转子加速度关系的先验知识重新组织神经网络的输入变量, 然后再对其进行神经网络建模的思路。仿真结果表明, 随着先验知识的不断加入, 风车工况神经网络模型的维数不断降低, 泛化能力随之逐渐提高, 最终只需要一组训练样本就可以训练出泛化能力较强的只有单一输入变量的风车工况神经网络模型。所以, 仿真结果表明, 利用先验知识提高神经网络泛化能力不仅切实有效, 而且简单易行, 易于工程应用。

参考文献:

- [1] 于达仁, 郭钰峰, 牛军, 等. 涡喷发动机风车启动工况的神经网络建模 [J]. 推进技术, 2001, 22(3) (YU Da-ren, GUO Yu-feng, NIU Jun, et al. Turbojet modeling in

windm illing based on radial basis function networks [J]. *Journal of Propulsion Technology*, 2001, 22(3).).

- [2] Wang Ying-Chun, Wu Hong-Xin, Geng Chang-Fu. Study and application of a class of neural networks model with better generalization ability [C]. *Intelligent Control and Automation*, 2002 Proceedings of the 4th World Congress on, 2002 3 2016~2020
- [3] Jian-Nan Lin, Shi-Min Song. Modeling gait transitions of quadrupeds and their generalization with CMAC neural networks[J]. *Systems Man and Cybernetics Part C, IEEE Transactions on*, 2002, 32: 177~189
- [4] Horvath G, Szabo T. CMAC neural network with improved generalization property for system modeling[C]. *Instrumentation and Measurement Technology Conference, 2002 MTC/2002 Proceedings of the 19th IEEE*, 2002, 2: 1603~1608
- [5] Ueda N, Nakano R. Estimating expected error rates of neural network classifiers in small sample size situations: a comparison of cross-validation and bootstrap[C]. *Neural Networks, 1995 Proceedings, IEEE International Conference on*, 1995, 1: 101~104
- [6] 殷春霞, 胡铁松, 郭元裕. 改善径向基函数网络泛化性能的主成分分析法及应用研究 [J]. 武汉水利电力大学学报, 2000, 33(2).
- [7] Hiden H G, Willis M J, Than M T, et al. Non-linear principal components analysis using genetic programming [C]. *Genetic Algorithms In Engineering Systems Innovations and Applications 1997 GALESIA 97 Second International Conference On (Conf. Publ. No. 446)*, 1997, 302~307.
- [8] Maltheuse E C. Limitations of nonlinear PCA as performed with generic neural networks [J]. *Neural Networks IEEE Transactions on*, 1998, 9(1): 165~173
- [9] Meng Jinli, Sun Zhiyi. Application of combined neural networks in nonlinear function approximation [C]. *Intelligent Control and Automation, 2000 Proceedings of the 3rd World Congress on*, 2000, 2: 839~841

(编辑: 朱立影)