

轴流压气机旋转失速建模与检测: I — 基于确定学习理论与高阶 Moore-Greitzer 模型的研究

王聪¹ 文彬鹤² 司文杰¹ 彭滔³
袁成志¹ 陈填锐⁴ 林文愉¹ 王勇⁵ 侯安平⁶

摘要 喘振和旋转失速是轴流压气机研究领域中的重要而困难的问题. 本文基于确定学习理论及动态模式识别方法提出一个旋转失速初始扰动近似准确建模和快速检测的方法. 首先, 基于高阶 Moore-Greitzer 模型 (Mansoux 模型), 利用确定学习理论提出一个对旋转失速初始扰动的内在系统动态的近似准确建模方法; 其次, 基于以上近似准确建模, 利用动态模式识别方法提出一个对旋转失速初始扰动的快速检测方法. 基于 MIT 的 Mansoux-C2 模型仿真研究验证了所提方法的有效性. 最后, 在北京航空航天大学航空发动机重点实验室的低速轴流压气机试验台上开展了试验研究. 通过对低速轴流压气机试验台参数进行测量, 得到基于北航低速轴流压气机试验台的 Mansoux 模型. 通过对基于北航试验台 Mansoux 模型进行仿真研究, 验证了所提方法的有效性.

关键词 涡扇发动机, 轴流压气机, 旋转失速, 喘振, 故障检测, 确定学习, 动态模式识别

引用格式 王聪, 文彬鹤, 司文杰, 彭滔, 袁成志, 陈填锐, 林文愉, 王勇, 侯安平. 轴流压气机旋转失速建模与检测: I — 基于确定学习理论与高阶 Moore-Greitzer 模型的研究. 自动化学报, 2014, 40(7): 1265–1277

DOI 10.3724/SP.J.1004.2014.01265

Modeling and Detection of Rotating Stall in Axial Flow Compressors: Part I — Investigation on High-order M-G Models via Deterministic Learning

WANG Cong¹ WEN Bin-He² SI Wen-Jie¹ PENG Tao³
YUAN Cheng-Zhi¹ CHEN Tian-Rui⁴ LIN Wen-Yu¹ WANG Yong⁵ HOU An-Ping⁶

Abstract Rotating stall and surge are important and challenging problems in the area of axial compressors. This paper presents an approach for approximately accurate modeling and rapid detection of stall precursors based on deterministic learning. Firstly, based on the high-order compressor model (Mansoux model), a method for modeling the system dynamics corresponding to stall precursors is presented by employing deterministic learning algorithm; Secondly, a scheme for rapid detection of stall precursors is proposed by using dynamical pattern recognition algorithm; Thirdly, experiments are conducted on a low-speed research compressor of Beihang University. By measuring relevant parameters of the compressor, the Mansoux-Beihang model is obtained. Simulation studies on the Mansoux-C2 model and the Mansoux-Beihang model are included to show the effectiveness of the approach.

Key words Turbofan engine, axial compressor, rotating stall, surge, fault detection, deterministic learning, dynamic pattern recognition

Citation Wang Cong, Wen Bin-He, Si Wen-Jie, Peng Tao, Yuan Cheng-Zhi, Chen Tian-Rui, Lin Wen-Yu, Wang Yong, Hou An-Ping. Modeling and detection of rotating stall in axial flow compressors: part I — investigation on high-order M-G models via deterministic learning. *Acta Automatica Sinica*, 2014, 40(7): 1265–1277

收稿日期 2013-06-19 录用日期 2014-01-27
Manuscript received June 19, 2013; accepted January 27, 2014
国家杰出青年科学基金 (61225014), 国家自然科学基金重点项目 (60934001), 国家自然科学基金 (61304084), 重庆理工大学科研启动基金 (2013ZD01) 资助
Supported by National Science Fund for Distinguished Young Scholars (61225014), State Key Program of National Natural Science Foundation of China (60934001), National Natural Science Foundation of China (61304084), and Startup Fund of Chongqing University of Technology (2013ZD01)
本文责任编辑 倪茂林
Recommended by Associate Editor NI Mao-Lin
1. 华南理工大学自动化科学与工程学院 广州 510640 2. 中航工业

航空动力控制系统研究所 无锡 214063 3. 重庆理工大学电子信息与自动化学院 重庆 400054 4. 广东工业大学自动化学院 广州 510006 5. 北京大学力学与工程科学系 北京 100871 6. 北京航空航天大学能源与动力工程学院 北京 100191
1. College of Automation Science and Engineering, South China University of Technology, Guangzhou 510640 2. AVIC Aviation Motor Control System Institute, Wuxi 214063 3. College of Electronic Information and Automation, Chongqing University of Technology, Chongqing 400054 4. School of Automation, Guangdong University of Technology, Guangzhou 510006 5. Department of Mechanics and Engineering Science, Peking University, Beijing 100871 6. School of Energy and Power Engineering, Beihang University, Beijing 100191

高性能航空发动机是一个国家工业综合水平的重要标志. 我国是世界上具有航空发动机自主研制能力的少数国家之一, 但与世界先进水平相比, 在可靠性、稳定性和效率等方面还有明显差距.

涡轮风扇 (涡扇) 发动机是目前世界上军民用飞机最常用的航空动力装置. 轴流压气机 (以下简称压气机) 是涡扇发动机的核心部件之一, 当代大型航空涡扇发动机的发展方向是追求更高的单级压比和更少的级数. 单级压比的提高和级数的减少, 必然要求压气机叶片负荷越来越高, 因而引起流动分离, 产生发动机内部不稳定流动问题, 例如旋转失速 (Rotating stall) 和喘振 (Surge) 等^[1]. 喘振是流体沿着压气机轴向的周期性振荡. 已有的实验表明, 在系统喘振发生的最初, 总是伴有压气机的旋转失速^[2], 所以, 旋转失速被认为是喘振先兆, 旋转失速是沿压气机周向的非均匀流动状态. 这些不稳定流动现象不但使发动机性能 (推力、经济性) 大为恶化, 限制发动机的工作范围, 而且更严重的是它们会引起发动机突然熄火, 或引起压气机叶片剧烈振动以致叶片断裂而造成整台发动机的损坏. 因此, 迫切需要对涡扇发动机压气机不稳定流动的建模, 检测与控制等问题进行深入研究, 以提高其可靠性和稳定性.

喘振和旋转失速是压气机研究领域中的重要而困难的问题. 关于喘振和旋转失速的建模, 上世纪 80 年代, Moore 和 Greitzer 从压气机转子和静子的整体性质出发, 在流体拟定常和压气机半激盘等假设下, 推导出一组描述压气机整体流场特性的偏微分方程 (Partial differential equations, PDE)^[3-4], 并在此基础上得到一个由三阶常微分方程组 (Ordinary differential equations, ODE) 描述的 Moore-Greitzer 模型. Moore-Greitzer 模型能够定性描述压气机喘振和旋转失速的动态特性^[3-4], 并验证了旋转失速是喘振先兆的实验结果^[1-2]. 由于该模型是个低阶 ODE 模型, 它被用于喘振主动控制器的设计^[5-8] 以及系统动力学分析^[9-12]. 但由于该模型假设流场是不可压缩的, 即忽略了可压缩性给压气机系统带来的影响, 且由于只采用了一阶 Galerkin 截断计算方法, 因此该模型只能反映压气机流场中的整体状态, 而无法刻画压气机流场的局部信息, 从而无法探究引发旋转失速和喘振的流动机理^[1]. 在 Moore 和 Greitzer 推导的偏微分方程组基础上, Paduano 和 Mansoux 等利用离散傅里叶变换及其逆变换推导出一个高阶 ODE 周向离散化 Moore-Greitzer 模型 (Mansoux 模型)^[13-15]. 该模型能够定量描述多种压气机旋转失速的发展过程^[13], 能够产生与压气机试验台失速初始扰动相似的仿真结果. 因此, 相对于三阶 ODE Moore-Greitzer 模型, 该模

型具有精度更高、能刻画压气机系统整个流场中局部信息等优点. 然而, 由于该模型的高阶性质, 利用该模型进行动力学特性分析以及旋转失速和喘振主动控制存在很多困难.

提前检测旋转失速对喘振的主动控制^[16] 具有重要意义. 在过去数十年中, 人们提出了许多旋转失速检测方法, 包括谐波傅立叶系数法^[17-19], 行波能量法^[20-21], 和小波分析法^[22-23] 等. 然而, 由于失速过程随着压气机的不同而呈现出多样性, 很难通过失速实验得到一个具有统计意义的先兆, 使得这些方法要随着测试压气机的改变而调整^[8,20,25]. 另外, 由于突尖波型旋转失速的物理机理没有得到很好解释, 人们仍然无法预估何时何地会发生突尖波型旋转失速^[24].

从系统与控制的角度看, 对旋转失速的建模是一个分布参数系统辨识问题. 由于分布参数系统具有无穷维性质, 分布参数系统辨识本身是一个极具挑战性的课题. 已有结果表明, 分布参数系统的辨识与持续激励条件 (Persistent excitation (PE) condition) 密切相关^[26-31]. 持续激励条件是系统辨识领域中的一个核心概念^[32-33], 在分布参数系统辨识和集中参数系统辨识中都起重要作用. 然而对于一般的非线性系统辨识, 持续激励条件通常难以刻画并得到预先验证^[34-35], 其中的许多基本问题有待于深入探究^[36]. 最近, 我们在对径向基函数神经网络 (Radial basis function (RBF) networks) 的持续激励特性研究的基础上^[26,34], 提出了确定学习理论^[37-41]. 确定学习运用自适应控制和动力学系统的概念与方法, 研究未知动态环境下的知识获取、表达、存储和利用等问题. 针对产生周期或回归轨迹的连续非线性动态系统, 确定学习可以对其未知系统动态进行局部准确建模, 其基本要素包括: 1) 使用径向基函数神经网络; 2) 对于周期 (或回归) 状态轨迹满足部分持续激励条件; 3) 在周期 (或回归) 轨迹的邻域内实现对非线性系统动态的局部准确神经网络逼近 (局部准确建模); 4) 所学的知识以时不变且空间分布的方式表达、以常值神经网络权值的方式存储, 并可在动态环境下用于动态模式的快速识别. 基于确定学习理论, 我们提出了一种对微小振动故障诊断的方法^[41]. 该方法首先对正常情况下和故障情况下系统内部动态进行准确建模, 并将建模结果存储在常值 RBF 神经网络中. 在诊断时, 构造一系列嵌入了常值 RBF 神经网络的动态估计器来监测系统, 最后根据最小残差原则进行诊断. 与基于模型的故障诊断方法相比 (如文献 [42]), 基于确定学习的故障诊断方法的主要优点在于能够对正常及故障模式的系统内部动态进行准确建模, 从而减小建模不确定项的影响, 并减小故障函数的幅值要求, 实现

对微小振动故障的快速检测^[41].

本文研究旋转失速初始扰动的建模和检测. 首先, 提出一个对旋转失速初始扰动的内在系统动态近似准确建模方法. 由于旋转失速是由偏微分方程 (PDE) 描述的无限维分布参数系统产生的复杂动态现象, 其无限维特性意味着任何基于有限状态测量的建模都是有限维近似建模. 文献 [13] 中推导出的高阶离散 Moore-Greitzer 模型 (Mansoux 模型) 是一个描述旋转失速过程的有限维 ODE 系统, 它可以在一定精度内产生与实验结果相吻合的仿真结果, 因此它可以被看作是无限维 PDE 系统在一定精度范围内的有限维近似, 其系统状态可以看作是在压气机周向均匀布置 $2N + 1$ (N 为 8 的倍数) 个流量传感器和在压气机入口和出口布置 2 个压力传感器所获取到的流量和压力信号.

对于每个测量点对应的 ODE 子系统, 在正常和失速先兆阶段其系统动态可表达为由这个测量点及其相邻 2 个测量点状态构成的动态加上由其它测量点状态构成的动态. 在上述分析的基础上, 我们利用三个相邻测量点信号, 采用确定学习算法, 对在正常和失速先兆阶段相应的 ODE 子系统的内部动态进行辨识, 获得对 ODE 子系统主要动态的神经网络近似, 并将之看作是对正常和失速初始扰动系统动态的近似建模. 这些近似建模均保存在经过确定学习算法训练的常值 RBF 神经网络中.

其次, 我们提出一种对旋转失速初始扰动进行快速检测的方法. 利用以上近似建模, 构建一组嵌入了常值 RBF 神经网络的动态估计器. 将这组动态估计器的状态与被测模式的状态比较, 得到一组残差信号. 根据动态模式识别方法, 两个失速初始扰动模式之间的状态差异近似正比于其内在的动态差异^[37, 40]. 由此提出一种基于最小残差原则判断压气机是否进入旋转失速初始扰动的方法, 即当对应于初始扰动模式的残差信号相比其它模式所对应的残差信号为最小时, 判定旋转失速即将发生.

最后, 我们对 Mansoux-C2 模型进行仿真研究, 并在北京航空航天大学航空发动机重点实验室的低速轴流压气机试验台上开展了部分试验研究. 1) 对 Mansoux-C2 模型失速前和失速初始扰动阶段对应的系统主要动态进行辨识, 基于仿真验证了对失速初始扰动的快速检测; 2) 测量北航低速轴流压气机试验台的特性曲线及与 Mansoux 模型相关的物理参数, 并将拟合所得到的压气机非线性特性和各测量参数代入到 Mansoux 模型, 得到基于北航低速轴流压气机试验台的 Mansoux 模型. 在该模型的基础上, 通过仿真研究验证了本文方法对旋转失速初始扰动建模及检测的有效性.

本文所提方法具有以下特点: 1) 该方法能实现

对失速初始扰动内在系统动态的近似准确建模, 与其他方法相比可提取出旋转失速更为全面的系统动态特征; 2) 该方法能迅速且比较准确地检测出旋转失速的发生, 能在压气机刚进入失速初始扰动时即给出预警.

本文的安排如下: 第 1 节为预备知识介绍; 第 2 节依据确定学习理论对旋转失速初始扰动进行近似准确建模; 第 3 节提出对旋转失速初始扰动的快速检测方法; 第 4 节通过仿真与实验研究验证本文所提出的方法的有效性; 第 5 节则给出本文结论.

1 预备知识

1.1 航空涡扇发动机及压气机不稳定性流动

航空涡扇发动机主要由风扇 (Fan)、压气机 (Compressor)、燃烧室 (Combustor)、涡轮 (Turbine) 和尾喷管 (Nozzle) 组成. 图 1 是航空涡扇发动机的基本结构示意图. 军用发动机在涡轮和喷管之间还有加力燃烧室 (Afterburner).

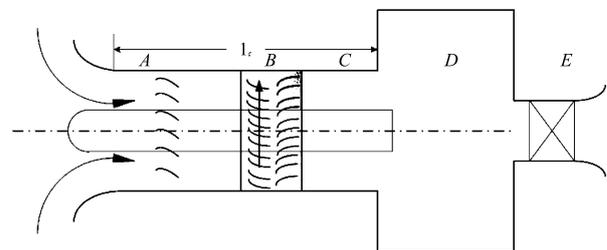


图 1 航空涡扇发动机示意图^[25]

Fig. 1 Schematic of turbofan engine^[25]

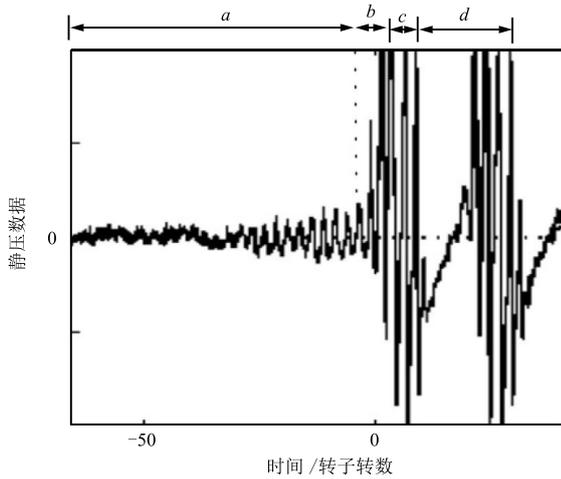
如图 2 中所示, 涡扇发动机压气机的旋转失速和喘振发生过程可以分为 4 个阶段^[25]: a 为失速前阶段; b 为旋转失速初始扰动阶段; c 为完全失速阶段; d 为喘振阶段. 各个过程的详细描述, 参见文献 [25], 在此不再赘述.

1.2 Mansoux 模型

对旋转失速和喘振的建模是一个复杂的问题. Paduano 和 Mansoux 等在 Moore-Greitzer 模型推导的基础上, 通过 3 步将原偏微分方程组 (即文献 [3] 中的式 (42) 和式 (43)) 转化为高阶离散化的 Moore-Greitzer 常微分方程 (ODE) 模型^[13-15] (Mansoux 模型^[43]):

$$\begin{cases} E\dot{\phi} = -A\phi + \Psi_c(\phi) - T\bar{\psi} \\ \dot{\bar{\psi}} = \frac{1}{4l_c B^2}(S\phi - \Phi_T(\bar{\psi})) \end{cases} \quad (1)$$

其中, 矩阵 E , A , T , S 参见文献 [13, 25].

图2 压气机旋转失速和喘振发生过程示意图^[25]Fig.2 Phenomenology of rotating stall and surge in compressor^[25]

相对于三阶 Moore-Greitzer 模型, Mansoux 模型 (1) 具有如下特点: 1) 通过截取 $\delta\Theta$ 和 $\delta\phi$ 的包含更高阶次谐波的解, Mansoux 模型充分考虑了非线性动态对整个系统的影响, 具有比 Moore-Greitzer 模型更高的精度; 2) Mansoux 模型可以比较充分地刻画压气机系统整个流场的特性, 能近似准确地描述多种压气机旋转失速初期的非线性发展过程^[13], 且其仿真结果与实验测量获得的流场数据比较吻合. Mansoux 模型的不足包括: 1) 其高阶特点使得对系统的动力学分岔分析难于进行; 2) 尽管推导该模型的初衷是为轴流压气机的主动控制提供依据, 而事实表明高阶 Mansoux 模型仍然很难用于主动控制器的设计.

1.3 确定学习理论

由于轴流压气系统内部流场具有周向对称特性和周期特性, 我们提出的确定学习理论^[37-38, 40] 能为轴流压气机系统不稳定流动的辨识或建模提供一个可行的方法.

下面通过一类非线性动态系统说明确定学习的基本方法. 考虑如下的非线性动态系统

$$\dot{\mathbf{x}} = F(\mathbf{x}; \mathbf{p}), \quad x(t_0) = x_0 \quad (2)$$

其中, $\mathbf{x} = [x_1, x_2, \dots, x_n]^T \in \mathbf{R}^n$ 是可测量的系统状态, \mathbf{p} 是系统的常值参数向量 (通常不同的 \mathbf{p} 产生不同的动态行为), $F(\mathbf{x}; \mathbf{p}) = [f_1(\mathbf{x}; \mathbf{p}), f_2(\mathbf{x}; \mathbf{p}), \dots, f_n(\mathbf{x}; \mathbf{p})]^T$ 表示系统 (2) 的未知系统动态, $f_i(\mathbf{x}; \mathbf{p})$ 是未知的连续非线性函数.

假设系统 (2) 状态 \mathbf{x} 保持一致有界 (如 $x(t) \in \Omega \subset \mathbf{R}^n, \forall t \geq t_0$), 其中 Ω 是一个紧集; 且始于初值 x_0 的系统轨迹 $\varphi_c(x_0)$ 是回归轨迹.

采用如下的动态 RBF 神经网络辨识系统 (2)

的未知系统动态

$$\dot{\hat{\mathbf{x}}} = -A(\hat{\mathbf{x}} - \mathbf{x}) + \widehat{\mathbf{W}}^T \mathbf{S}(\mathbf{x}) \quad (3)$$

其中, $\hat{\mathbf{x}} = [\hat{x}_1, \hat{x}_2, \dots, \hat{x}_n]^T$ 是动态 RBF 神经网络的状态向量, $A = \text{diag}\{a_1, a_2, \dots, a_n\}$ 是一个对角矩阵, $a_i > 0$ 是设计常数, RBF 神经网络 $\widehat{\mathbf{W}}^T \mathbf{S}(\mathbf{x}) = [\widehat{\mathbf{W}}_1^T \mathbf{S}_1(\mathbf{x}), \widehat{\mathbf{W}}_2^T \mathbf{S}_2(\mathbf{x}), \dots, \widehat{\mathbf{W}}_n^T \mathbf{S}_n(\mathbf{x})]^T$ 用于逼近紧集 Ω 中系统 (2) 的未知动态 $F(\mathbf{x}; \mathbf{p}) = [f_1(\mathbf{x}; \mathbf{p}), f_2(\mathbf{x}; \mathbf{p}), \dots, f_n(\mathbf{x}; \mathbf{p})]^T$.

神经网络权值估计通过如下的自适应学习律

$$\dot{\widehat{\mathbf{W}}}_i = -\Gamma_i \mathbf{S}_i(\mathbf{x}) \tilde{x}_i - \sigma_i \Gamma_i \widehat{\mathbf{W}}_i \quad (4)$$

其中, $\tilde{x}_i = \hat{x}_i - x_i$ 是状态估计误差, $\widehat{\mathbf{W}}_i$ 是最优权值 \mathbf{W}_i^* 的估计值, $\Gamma_i = \Gamma_i^T > 0, \sigma_i > 0$ 是很小的设计参数.

确定学习理论^[37, 40] 指出, 对于周期轨迹或者更一般的回归轨迹, RBF 神经网络中沿着回归轨迹的神经元函数构成的子向量可以满足部分 PE 条件. 即靠近轨迹 $\varphi_c(x_0)$ 的神经网络回归向量 \mathbf{S}_c 满足 PE 条件. 这个部分 PE 条件可以使得辨识误差系统满足指数稳定, 进而在沿周期或回归轨迹的局部区域实现对非线性系统动态的准确神经网络逼近:

$$f_i(\mathbf{x}; \mathbf{p}) = \bar{\mathbf{W}}_i^T \mathbf{S}_i(\mathbf{x}) + \xi_i(t), \quad \forall \mathbf{x} \in \Omega_c \quad (5)$$

其中, $\bar{\mathbf{W}}_i = \text{mean}_{t \in [t_a, t_b]} \widehat{\mathbf{W}}_i, t \in [t_a, t_b]$ 是权值收敛后的一段时间, Ω_c 是沿系统轨迹的一个局部区域, $|\xi_i(t)| < \xi^*, \xi^* > 0$ 是一个小常数, 这就实现了对非线性系统的未知动态进行局部准确建模.

基于确定学习机制, 文献 [37, 40] 提出了对由一类非线性动力学系统产生的时变模式 (动态模式) 的辨识、表达和快速识别的方法. 首先, 将由系统 (2) 产生的周期或回归轨迹 φ_c 定义为动态模式. 通过确定学习获得动态模式 φ_c 内在的局部准确系统动态建模, 并用此局部准确系统动态建模把随时间变化的动态模式以时不变且空间分布的方式有效地表达. 如式 (5) 所示, 这种表达方式是一种包含全部状态和动态信息的动态模式时不变空间分布全息表达方法, 区别于传统的从模式中提取部分特征的方法; 其次, 基于动态模式内在动力学上的拓扑相似, 给出了用来表征动态模式之间相似性的定义. 最后, 在对动态模式进行有效表达并刻画其相似性的基础上, 提出了一个对动态模式进行快速识别的方法^[37, 40]. 基于确定学习机制与动态模式识别方法, 文献 [41] 实现了对微小振动故障的准确建模和快速检测, 为振动故障诊断提供了一种新思路.

2 基于确定学习理论的失速初始扰动的建模

本节将基于确定学习理论, 提出对压气机旋转失速初始扰动和失速前的近似建模方法。

首先, 把 Mansoux 模型 (1) 重新表达为如下形式:

$$\begin{cases} \dot{\phi} = \mathcal{F}(\phi, \bar{\psi}, \mathbf{p}), & \phi(t_0) = \phi_0 \\ \dot{\bar{\psi}} = \mathcal{H}(\phi, \bar{\psi}, \mathbf{p}'), & \bar{\psi}(t_0) = \bar{\psi}_0 \end{cases} \quad (6)$$

其中, $\phi = [\phi_1, \phi_2, \dots, \phi_M]^T$ 是压气机周向上的 M 个测量点的流量, $\bar{\psi}$ 是压气机的平均压力增长, \mathbf{p} 和 \mathbf{p}' 是系统的参数向量, $[\mathcal{F}(\phi, \bar{\psi}, \mathbf{p}), \mathcal{H}(\phi, \bar{\psi}, \mathbf{p}')]^T = [\mathcal{F}_1(\phi, \bar{\psi}, \mathbf{p}), \dots, \mathcal{F}_M(\phi, \bar{\psi}, \mathbf{p}), \mathcal{H}(\phi, \bar{\psi}, \mathbf{p}')]^T$ 是旋转失速的内部动态. 记由系统状态 ϕ 和 $\bar{\psi}$ 构成的系统相空间轨迹为 $\varphi(t_0, \phi_0, \bar{\psi}_0, t)$, 简记为 φ . 流量 $\phi = [\phi_1, \phi_2, \dots, \phi_M]^T$ 可以通过沿周向均布在压气机转子前缘的 $2N + 1$ (N 为 8 的倍数) 个动态压力传感器测量得到, 平均压力增长 $\bar{\psi}$ 可以通过沿轴向布置的两个压力传感器获得。

Mansoux 等的研究结果^[13] 表明, 通过选取不同的系统参数和压气机特性函数, Mansoux 模型能够近似准确地模拟多种实际压气机系统旋转失速的发生过程, 其模型的仿真结果与实验测量获得的流场数据比较吻合. 因此, 有限维 ODE 系统 (6) 可被看作是在一定精度范围内对旋转失速的近似建模。

其次, 在以上近似建模的基础上, 本节利用确定学习理论, 对系统 (6) 各测量点系统内部动态 $\mathcal{F}_i(\phi, \bar{\psi}, \mathbf{p})$ 进行近似建模. 系统 (6) 的各测量点的系统动态 $\mathcal{F}_i(\phi, \bar{\psi}, \mathbf{p})$ 可表示如下:

$$\mathcal{F}_i(\phi, \bar{\psi}, \mathbf{p}) = f_i(\phi_{im}, \mathbf{p}_{im}) + g_i(\phi_{ir}, \bar{\psi}, \mathbf{p}_{ir}) \quad (7)$$

其中, ϕ_{im} 为测量点 i 本身状态和与其相邻 $2n$ 个测量点状态构成的状态向量 (此处取 $n = 1$); ϕ_{ir} 为除去 ϕ_{im} 之外其他系统状态构成的状态向量; $f_i(\phi_{im}, \mathbf{p}_{im})$ 表示由 ϕ_{im} 状态向量构成的系统动态; $g_i(\phi_{ir}, \bar{\psi}, \mathbf{p}_{ir})$ 表示由 ϕ_{ir} 和 $\bar{\psi}$ 构成的系统动态。

注 1. 本节余下部分将研究对由 $f_i(\phi_{im}, \mathbf{p}_{im})$ 表达的系统动态的近似准确建模, 其原因在于: 1) 旋转失速是轴流压气机系统周向局部范围内出现的流动不稳定现象, 其系统动态由某测量点及其相邻 $2n$ 个测量点状态构成的 $f_i(\phi_{im}, \mathbf{p}_{im})$ 来近似表达是合理的; 2) 利用确定学习对 $f_i(\phi_{im}, \mathbf{p}_{im})$ 进行建模时, 神经网络的输入状态为 ϕ_{im} , 其输入维数为 $2n + 1$, 远小于离散点数 M , 这样可以避免高输入维数导致的维数爆炸问题。

构造如下的动态 RBF 神经网络, 以辨识失速前和失速初始扰动阶段的主要系统动态 $f_i(\phi_{im}, \mathbf{p}_{im})$:

$$\dot{\hat{x}}_i = -a_i(\hat{x}_i - \phi_i) + \widehat{\mathbf{W}}_i^T \mathbf{S}_i(\phi_{im}) + g_i \quad (8)$$

其中, \hat{x}_i 是动态 RBF 神经网络的状态, $a_i > 0$ 是设计常数, RBF 神经网络 $\widehat{\mathbf{W}}_i^T \mathbf{S}_i(\phi_{im})$ 用来逼近由测量点 i 状态和与其相邻 $2n$ 个测量点状态表达的主要系统动态 $f_i(\phi_{im}, \mathbf{p}_{im})$ 。

注 2. 本节旨在通过对 Mansoux 模型的研究, 证明基于确定学习理论可以实现对由微小振动信号所表达的旋转失速初始扰动系统动态的近似准确建模. 这里由于在模型研究中所有系统状态可测, 且 $g_i(\phi_{ir}, \bar{\psi}, \mathbf{p}_{ir})$ 已知, 因此构造以上神经网络模型对 $f_i(\phi_{im}, \mathbf{p}_{im})$ 进行建模时, 可以采取直接抵消 $g_i(\phi_{ir}, \bar{\psi}, \mathbf{p}_{ir})$ 的方法以实现对其 $f_i(\phi_{im}, \mathbf{p}_{im})$ 的近似准确建模. 在实验研究中, $g_i(\phi_{ir}, \bar{\psi}, \mathbf{p}_{ir})$ 被看作作为系统未建模动态, 我们将采用其他方法消除 $g_i(\phi_{ir}, \bar{\psi}, \mathbf{p}_{ir})$ 对系统建模的影响。

在辨识 $f_i(\phi_{im}, \mathbf{p}_{im})$ 的过程中, 动态神经网络 (8) 中的神经网络估计权值 $\widehat{\mathbf{W}}_i$ 根据以下自适应学习律:

$$\dot{\widehat{\mathbf{W}}}_i = -\Gamma_i \mathbf{S}_i(\phi_{im}) \tilde{x}_i - \sigma_i \Gamma_i \widehat{\mathbf{W}}_i \quad (9)$$

其中, $\tilde{x}_i = \hat{x}_i - \phi_i$ 是状态估计误差, $\widehat{\mathbf{W}}_i$ 是最优权值 \mathbf{W}_i^* 的估计值, $\Gamma_i = \Gamma_i^T > 0$, $\sigma_i > 0$ 是小的设计参数。

根据确定学习理论^[37, 40], 可以得到:

$$f_i(\phi_{im}, \mathbf{p}_{im}) = \overline{\mathbf{W}}_i^T \mathbf{S}_i(\phi_{im}) + \epsilon_{i2}, \quad \forall (\phi_{im}) \in \Omega_\zeta \quad (10)$$

式 (10) 表明, 常值神经网络 $\overline{\mathbf{W}}_i^T \mathbf{S}_i(\phi_{im})$ 可以在失速前和旋转失速初始扰动阶段实现对其系统动态 $f_i(\phi_{im}, \mathbf{p}_{im})$ 的局部准确建模。

3 失速初始扰动的快速检测

本节将基于动态模式识别方法^[37, 40-41], 提出一种对旋转失速初始扰动进行快速检测的方法。

3.1 失速初始扰动模式库建立

本小节为压气机系统建立一个包含了失速前正常模式和失速初始扰动模式的动态模式库. 考虑压气机中 K 种失速前和失速初始扰动模式 χ^k ($k = 1, 2, \dots, K$), 它们由系统 (6) 产生, 我们将此 K 种动态模式定义为 K 种训练模式。

根据第 2 节的分析, 第 k 个动态模式的流量 ϕ_i^k 满足如下方程:

$$\dot{\phi}_i^k = \mathcal{F}_i^k(\phi^k, \bar{\psi}^k, \mathbf{p}^k), \quad i = 1, \dots, M \quad (11)$$

其中, $\mathcal{F}_i^k(\phi^k, \bar{\psi}^k, \mathbf{p}^k) = f_i^k(\phi_{im}^k, \bar{\psi}^k, \mathbf{p}_{im}^k) + g_i^k(\phi_{ir}^k, \bar{\psi}^k, \mathbf{p}_{ir}^k)$, $f_i^k(\phi_{im}^k, \bar{\psi}^k, \mathbf{p}_{im}^k)$ 是相应流量测量点的主要系统内部动态, $g_i^k(\phi_{ir}^k, \bar{\psi}^k, \mathbf{p}_{ir}^k)$ 为其他系统动态。

对系统 (11) 构造如第 2 节式 (8) 和式 (9) 所示的动态 RBF 神经网络和自适应学习律, 可以得到系

统在失速前和失速初始扰动模式下的主要系统动态的常值 RBF 神经网络表达:

$$f_i^k(\phi_{im}^k, \mathbf{p}_{im}^k) = \overline{\mathbf{W}}_i^{kT} \mathbf{S}_i(\phi_{im}^k) + \epsilon_{i2}^k, \quad \forall (\phi_{im}^k) \in \Omega_\zeta \quad (12)$$

其中, Ω_ζ 是沿系统轨迹 φ 的一个局部区域, $|\epsilon_{i2}^k| < \xi^*$, $\xi^* = O(\epsilon_{i2}^k) = O(|\epsilon_{i2}^k|)$ 是在 Ω_ζ 内神经网络对主要系统动态的逼近误差.

将以上得到的常数数值神经网络 $\overline{\mathbf{W}}_i^{kT} \mathbf{S}_i(\phi_{im}^k)$ 保存, 构建包含失速前正常模式和失速初始扰动模式的动态模式库. 由于神经网络的径向基函数 $\mathbf{S}_i(\phi_{im}^k)$ 的表达式对每个模式都是一样的, 我们只需将神经网络的常值数值保存作为对动态模式的特征表达, 因而把模式库中第 k 个模式记为 $\chi^k = \{\mathbf{W}_i^k | i = 1, \dots, M\}$, 整个模式库记为 $\chi_{\text{lib}} = \{\chi^k | k = 1, \dots, K\}$.

3.2 失速前正常模式和失速初始扰动模式的相似性

基于动态模式的相似性定义^[37, 40], 我们给出针对失速前正常模式和失速初始扰动模式的相似性定义.

考虑如下的被检测压气机系统:

$$\begin{cases} \dot{\phi}^d = \mathcal{F}^d(\phi^d, \bar{\psi}^d, \mathbf{p}^d), & \phi^d(t_0) = \phi_0^d \\ \dot{\bar{\psi}}^d = \mathcal{H}^d(\phi^d, \bar{\psi}^d, \mathbf{p}^d), & \bar{\psi}^d(t_0) = \bar{\psi}_0^d \end{cases} \quad (13)$$

其产生的失速前或失速初始扰动模式记为 χ^d , 其各个测量点的流量 ϕ_i^d ($i = 1, \dots, M$) 满足如下方程:

$$\dot{\phi}_i^d = \mathcal{F}_i^d(\phi^d, \bar{\psi}^d, \mathbf{p}^d), \quad i = 1, \dots, M \quad (14)$$

其中, $\mathcal{F}_i^d(\phi^d, \bar{\psi}^d, \mathbf{p}^d) = f_i^d(\phi_{im}^d, \mathbf{p}_{im}^d) + g_i^d(\phi_{ir}^d, \bar{\psi}^d, \mathbf{p}_{ir}^d)$, $f_i^d(\phi_{im}^d, \mathbf{p}_{im}^d)$ 是相应流量测量点所对应的主要系统内部动态, 而 $g_i^d(\phi_{ir}^d, \bar{\psi}^d, \mathbf{p}_{ir}^d)$ 是其他系统动态.

依据基于确定学习的动态模式相关理论^[38], 给出如下相似性定义:

定义 1. 对于由被测压气机系统 (14) 产生的失速前或失速初始扰动模式 χ^d 和压气机系统 (6) 产生的训练模式 χ^k , 若被测模式 χ^d 状态 $(\phi^d, \bar{\psi}^d)$ 处于训练模式 χ^k 状态 $(\phi^k, \bar{\psi}^k)$ 小邻域内, 同时两个动态模式的主要系统动态之间的差异很小, 即

$$\max_{\phi^k \in \varphi_\zeta^k} |\overline{\mathbf{W}}_i^{kT} \mathbf{S}_i(\phi_{im}^k) - f_i^d(\phi_{im}^d, \mathbf{p}_{im}^d)| \leq \epsilon^* + \xi^*$$

其中, $\epsilon^* > 0$ 是一个小的常数, ξ^* 是如式 (12) 所示的逼近误差. 则称被测失速前或失速初始扰动模式 χ^d 被识别为相似于训练模式 χ^k , 其中 $\epsilon^* + \xi^*$ 是相似性度量.

注 3. 上述相似性定义用系统的状态差异和动态差异共同度量, 并且是基于系统动态的时不变信

息. 因此以上定义为比较两个压气机失速前正常模式或失速初始扰动模式之间的相似性提供了合理的依据.

3.3 失速初始扰动的检测策略

根据动态模式识别方法^[37, 40], 以及失速初始扰动模式之间的相似性定义, 我们提出一种基于最小残差原则判断压气机是否进入旋转失速初始扰动的方法.

利用第 3.1 节建立的模式库中所保存的常值神经网络 $\overline{\mathbf{W}}_i^{kT} \mathbf{S}_i(\phi_{im}^k, \bar{\psi}^k)$, 我们为训练模式 χ^k 构造如下 K 个动态估计器:

$$\begin{aligned} \dot{\bar{\phi}}_i^k &= -b_i(\bar{\phi}_i^k - \phi_i^d) + \overline{\mathbf{W}}_i^{kT} \mathbf{S}_i(\phi_{im}^d) + g_i^k, \\ & k = 1, \dots, K \end{aligned} \quad (15)$$

其中, $\bar{\phi}_i^k$ 是第 k 个动态估计器在第 i 个测量点的状态, ϕ_i^d 是被检测压气机系统 (13) 的状态, $b_i > 0$ 是对所有的动态估计保持不变的设计参数.

由动态估计器 (15) 和方程 (14), 可以得到如下的残差系统:

$$\dot{\tilde{\phi}}_i^k = -b_i \tilde{\phi}_i^k + \overline{\mathbf{W}}_i^{kT} \mathbf{S}_i(\phi_{im}^d) - f_i^d + g_i^k - g_i^d \quad (16)$$

其中, $\tilde{\phi}_i^k = \bar{\phi}_i^k - \phi_i^d$ 是残差 (或状态估计误差).

根据动态模式识别方法, 两个失速初始扰动模式之间的状态差异近似正比于其内在的动态差异^[37, 40]. 利用文献 [41] 中关于微小振动故障诊断的最新结果, 我们采用如下的残差平均 l_1 范数 (17) 作为检测的决策范数:

$$\|\tilde{\phi}_i^k(t)\|_1 = \frac{1}{T} \int_{t-T}^t |\tilde{\phi}_i^k(\tau)| d\tau, \quad t \geq T \quad (17)$$

其中, $T > 0$ 为设计常数.

注 4. 压气机系统的对称性^[43] 表明在压气机周向任何一测量点的系统动态与其他测量点的系统动态都是相似的. 因此, 只需利用一个测量点对应的残差信号就可以检测旋转失速初始扰动的发生. 式 (15)~(17) 和以下检测策略所用到的下脚标 i 可以选取 $1, \dots, M$ 中的任一值.

根据微小振动故障诊断的最新成果^[41], 我们给出如下的旋转失速初始扰动检测策略:

失速初始扰动检测策略. 对所有的 $r \in \{1, \dots, K\} \setminus \{k\}$, 存在一个有限时间 t^k , 使得 $\|\tilde{\phi}_i^k(t^k)\|_1 < \|\tilde{\phi}_i^r(t^k)\|_1$ 在 $t \in [t^k, t^k + T]$ 的一段时间区域内成立:

1) 如果 k 对应的是训练模式中的正常模式, 我们就认定被检测压气机系统 (13) 处于正常运行状态;

2) 如果 k 对应的是训练模式中的旋转失速初始扰动模式, 我们就认定被检测压气机系统 (13) 进入旋转失速初始扰动。

根据以上检测策略, 当被检测压气机系统轨迹进入到旋转失速初始扰动, 对应于初始扰动模式的残差迅速变为最小, 因而该策略能准确判断被检测压气机系统中失速初始扰动的发生。

4 基于 Mansoux-C2 模型的失速建模与检测

为验证本文方法的有效性, 本节将选取文献 [13] 中的 C2 压气机模型 (记为 Mansoux-C2 模型) 开展仿真研究。

旋转失速发生过程是通过连续调整尾喷管特性参数 K_T 模拟得到的。图 3 为旋转失速初始扰动沿周向的传播图, 该图表明在失速初始扰动阶段流量存在渐长的过渡过程。

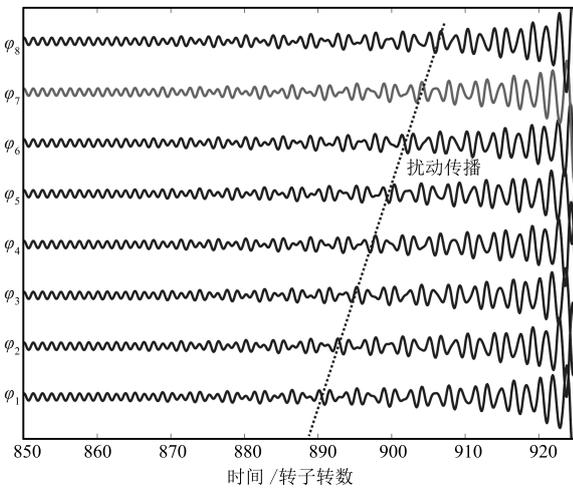


图 3 旋转失速发展过程中失速初始扰动传播图

Fig. 3 Time evolution of the first 8 flow states before rotating stall

依据第 2 节所介绍的建模方法, 将 Mansoux 模型中各流量系统动态写成如下形式:

$$\mathcal{F}_i(\phi, \bar{\psi}, \mathbf{p}) = f_i(\phi_{im}, \mathbf{p}_{im}) + g_i(\phi_{ir}, \bar{\psi}, \mathbf{p}_{ir}) \quad (18)$$

将系统参数代入其中, 可计算得到 f_i 和 g_i , 以第一个测量点为例:

$$f_1 = 0.8028\Psi_c(\phi_1) - 0.1874(\Psi_c(\phi_2) + \Psi_c(\phi_{17})) - 0.458(\phi_2 - \phi_{17})$$

$$g_1 =$$

$$\begin{aligned} & 0.3042(\phi_3 - \phi_{16}) - 0.0577(\Psi_c(\phi_3) + \Psi_c(\phi_{16})) - \\ & 0.1835(\phi_4 - \phi_{15}) + 0.0368(\Psi_c(\phi_4) + \Psi_c(\phi_{15})) + \\ & 0.1553(\phi_5 - \phi_{14}) + 0.0186(\Psi_c(\phi_5) + \Psi_c(\phi_{14})) - \\ & 0.1249(\phi_6 - \phi_{13}) + 0.0144(\Psi_c(\phi_6) + \Psi_c(\phi_{13})) + \\ & 0.1149(\phi_7 - \phi_{12}) + 0.0091(\Psi_c(\phi_7) + \Psi_c(\phi_{12})) - \\ & 0.1050(\phi_8 - \phi_{11}) + 0.0080(\Psi_c(\phi_8) + \Psi_c(\phi_{11})) + \\ & 0.1023(\phi_9 - \phi_{10}) + 0.0067(\Psi_c(\phi_9) + \Psi_c(\phi_{10})) - \\ & 0.1250\bar{\psi} \end{aligned}$$

仿真研究将验证基于确定学习理论可以实现对系统主要动态 f_1 (即 f_i) 的近似准确建模。这里由于在模型仿真中所有系统状态可测, 且 g_1 (即 g_i) 已知, 因此可构造如式 (8) 所示的神经网络模型, 直接抵消 g_i 以实现主要系统动态 f_i 的近似准确建模。

4.1 失速前和失速初始扰动模式的建模

本小节针对压气机 C2, 对压气机失速前和旋转失速初始扰动的系统动态 $f_i(\phi_{im}, \mathbf{p}_{im})$ 进行近似的建模, 并建立包含了失速前正常模式和失速初始扰动模式的动态模式库。

从图 3 可以看出, 失速前行程较长, 因此把失速前正常模式分成多个子模式 $\chi_7, \chi_{7-7.5}, \chi_{7.5-8}, \chi_{8-8.5}, \chi_{8.3-8.6}, \chi_{8.5-8.75}$ 和 $\chi_{8.75-9.41}$, 简记为 $\chi^1, \chi^2, \chi^3, \chi^4, \chi^5, \chi^6$ 和 χ^7 。失速初始扰动模式则记为 χ^8 。这些模式分别对应于参数 K_T 在不同值范围内的系统轨迹。

为辨识以上 8 个动态模式的系统动态, 可根据注 4 只辨识测量点 $i = 1$ 处的主要系统动态 $f_1(\phi_{1m}, \mathbf{p}_{1m})$ 。RBF 神经网络 $\widehat{\mathbf{W}}_1^T \mathbf{S}_1(\phi_{1m})$ 的中心点 μ_1 均匀地布置在 $[0.4 \ 0.8] \times [0.4 \ 0.8] \times [0.4 \ 0.8]$ 区域内, 两中心点的距离为 0.05, 神经元的宽度为 $\eta_1 = 0.07$; 动态 RBF 神经网络权值的初值是 $\widehat{\mathbf{W}}_1^T(0) = 0$, 并依据自适应学习率在线调整。设计相关参数分别选为 $a_1 = 0.5, \Gamma_1 = \text{diag}\{1.5, 1.5, 1.5\}$ 。

我们对如上所述 $K_T \in [7, 9.41]$ 的 8 个不同动态模式的第 1 个测量点的系统动态进行辨识, 并将学习得到的 8 个常值 RBF 神经网络权值 $\overline{\mathbf{W}}_1^k$ ($k = 1, 2, \dots, 8$) 作为这 8 个模式的特征表达, 从而建立模式库 $\chi_{\text{lib}} = \{\overline{\mathbf{W}}_1^k | k = 1, 2, \dots, 8\}$ 。

图 4 展示了利用上述方法对失速初始扰动模式 χ^8 的主要系统动态 $f_1 = 0.8028\Psi_c(\phi_1) - 0.1874(\Psi_c(\phi_2) + \Psi_c(\phi_{17})) - 0.458(\phi_2 - \phi_{17})$ 的辨识结果。结果表明所得常值 RBF 神经网络

$\bar{W}_1^{ST} S_1(\phi_{1m}^s)$ 能沿系统轨迹准确逼近 $f_1^s(\phi_{im}^s, p_{im}^s)$. 这验证了第 2 节所提建模方法能实现对由微小振动故障信号表达的旋转失速初始扰动主要系统动态的近似准确建模.

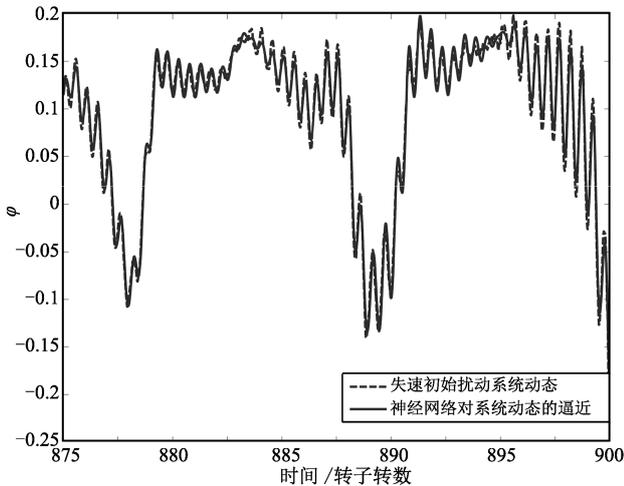


图 4 $\bar{W}_1^{ST} S_1(\phi_{1m}^s)$ 对动态模式 χ^s 的系统动态的逼近图: f_1^s (虚线), $\bar{W}_1^{ST} S_1(\phi_{1m}^s)$ (实线)

Fig. 4 Function approximation for main system dynamics of pattern χ^s by $\bar{W}_1^{ST} S_1(\phi_{1m}^s)$: f_1 (dotted line), $\bar{W}_1^{ST} S_1(\phi_{1m}^s)$ (solid line)

4.2 失速初始扰动的快速检测

在快速检测阶段, 利用系统 (1) 在初始条件 $\phi_i(0) = 0.624$ ($i = 1, \dots, 17$) 和 $\bar{\psi} = 0.7788$, K_T 的值从 5 逐渐变化至 9.41 产生的动态模式作为测试模式. 测试模式对应的状态变量变化与训练模式的相似但并不完全相同.

对上述测试模式, 利用辨识阶段得到的动态模式库 $\chi_{lib} = \{\bar{W}_1^k | k = 1, 2, \dots, 8\}$ 构造 8 个动态估计器 (15), 动态估计器中的 $b_1 = 0.5$, 神经网络 $\bar{W}_1^{kT} S_1(\phi_{1m}^d)$ ($k = 1, 2, \dots, 8$) 的所有参数与建模阶段的完全相同.

由这些动态估计器 (15) 与被检测压气机系统 (6) 得到检测残差系统 (16), 其中 $i = 1$, 表示只需利用残差信号 $\tilde{\phi}_1^k$ ($k = 1, 2, \dots, 8$) 作为检测依据. 图 5 显示旋转失速发生过程中的部分状态和检测系统运行过程中的残差 $\tilde{\phi}_1^k$ ($k = 1, 2, \dots, 8$), 该图表明本文提出的方法可以在刚进入失速初始扰动时即给出检测信号, 并能在完全失速发生 (即 925 转) 前 45 转检测出旋转失速即将发生. 相对于喘振发生时刻 (图 5 中第三根竖直线所标记的 930 转), 该方法提前了 50 转给出了检测信号. 按照文献 [13] 中的 C2 压气机的相关参数, 将转数换算成物理时间 45 转对应于 0.461 s, 50 转则对应于 0.512 s. 也就是说我们能在完全失速发生 (925 转) 之前 0.461 s 检测出系统

即将进入旋转失速, 而相对于喘振发生 (930 转) 前了 0.512 s 检测出系统即将发生喘振.

5 基于北航低速轴流压气机试验台的 Mansoux 模型的失速建模与检测

本节通过实验对北航低速轴流压气机试验台中存在的旋转失速现象进行研究. 首先, 通过现场测量得到与 Mansoux 压气机模型中对应的试验台参数: $l_c = 10$, $B = 0.1$, $m = 2$, $\mu = 0.5$, $\lambda = 0.6$, $N = 8$, $l = 1$. 其次, 通过稳态测量获取北航低速轴流压气机试验台的特性曲线, 稳态测量所得到的测量点分布图如图 6 所示, 对图中的稳态数据测量点进行非线性拟合得到如下压气机特性非线性方程:

$$\Psi_C = \begin{cases} -10.8743\phi^3 + 7.9459\phi^2 - 1.2630\phi + 0.1577, & \phi \leq 0.3871 \\ 6.7799\phi^3 - 13.2206\phi^2 + 7.1881\phi - 0.9660, & \phi > 0.3871 \end{cases} \quad (19)$$

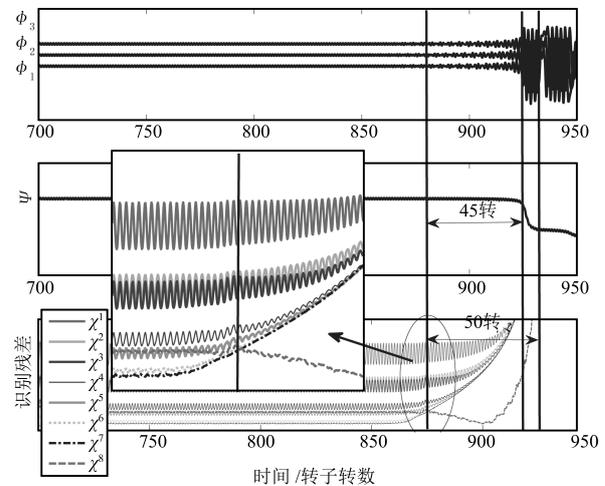


图 5 测试模式的状态和所有训练模式的残差的平均 l_1 范数
Fig. 5 The first flow state of test pattern χ^d and average l_1 norms of all training patterns

将该特性曲线和相应的试验台参数代入 Mansoux 模型便可得到基于北航低速轴流压气机试验台的 Mansoux 模型. 最后, 利用布置在 5 个相邻位置的 5 个传感器获取壁面静压数据, 并对这些数据进行转换, 得到与 Mansoux 模型中各个测量点相应的实验数据. 将这些数据与北航试验台 Mansoux 模型产生的数据进行对比, 如图 7 所示, 表明基于北航低速轴流压气机试验台的 Mansoux 模型能够得到更接近实验数据的仿真数据.

用于训练的样本数据是由基于北航试验台的 Mansoux 模型所产生. 本文之所以采用北航试验台

Mansoux 模型的样本数据, 是为了验证所提方法可以对失速初始扰动内在系统动态近似准确建模, 并提前检测出旋转失速的发生.

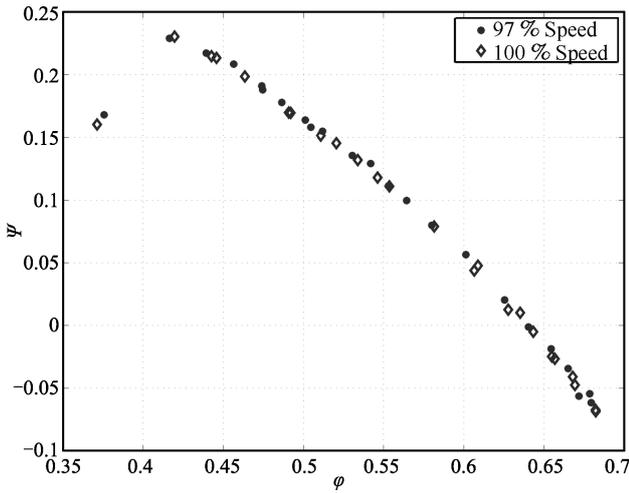


图 6 稳态测量数据点分布图

Fig. 6 The distribution map for experimental data by steady measurement

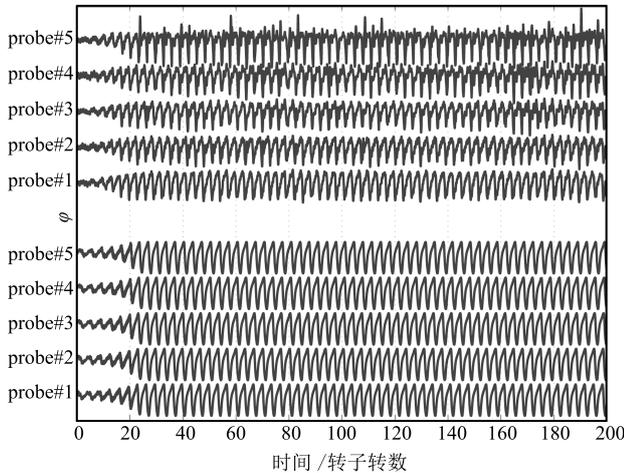


图 7 实验数据和仿真数据对比图 (上部 5 个信号为实验数据; 下部 5 个信号为模型仿真数据)

Fig. 7 Comparison chart for experimental data and simulated data (Five signals in the first half of the figure are experimental data; five signals in the lower part of the figure are simulated data.)

5.1 失速前和失速初始扰动动态模式建模

依照第 4 节中对 Mansoux-C2 模型的仿真研究, 从图中所示的五个测量点数据中选取某个传感器的测量信号和与其相邻的 2 个传感器的测量信号作为 RBF 神经网络输入. 并从中分段选取四段数据分别代表两个失速前模式 (*Prestall1* 和 *Prestall2*) 和两个失速初始扰动模式 (*Stall inception1* 和

Stall inception2). 由于篇幅关系, 省略相关仿真设计参数, 参照第 4 节基于 Mansoux-C2 模型的仿真.

通过对 RBF 神经网络的训练, 得到代表两个失速前模式和两个失速初始扰动模式的常值 RBF 神经网络, 将这些常值 RBF 神经网络保存为模式库. 图 8 显示针对失速初始扰动模式 *Stall inception1*, 所得常值 RBF 神经网络 $\bar{W}_1^T \mathbf{S}_1(\phi_{1m})$ 能沿系统轨迹近似准确逼近主要系统动态 $f_1(\phi_{1m}) = 0.515\Psi_c(\phi_1) - 0.0883(\Psi_c(\phi_2) + \Psi_c(\phi_{17})) - 1.0707(\phi_2 - \phi_{17})$. 这验证了第 2 节所提建模方法能实现对旋转失速初始扰动主要系统动态的近似准确建模.

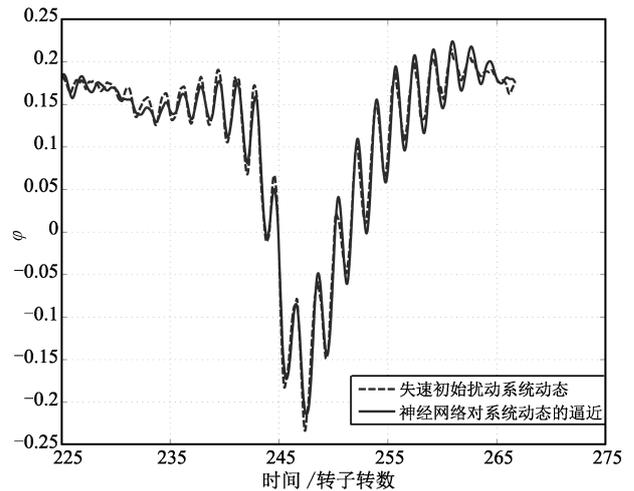


图 8 $\bar{W}_1^{4T} \mathbf{S}_1(\phi_{1m}^4)$ 对动态模式 *Stallinception1* 的系统动态的逼近图: f_1^4 (虚线), $\bar{W}_1^{4T} \mathbf{S}_1(\phi_{1m}^4)$ (实线)

Fig. 8 Function approximation for main system dynamics of pattern *Stallinception1* by $\bar{W}_1^{4T} \mathbf{S}_1(\phi_{1m}^4)$: f_1 (dotted line), $\bar{W}_1^{4T} \mathbf{S}_1(\phi_{1m}^4)$ (solid line)

5.2 失速初始扰动快速检测

在快速检测阶段, 通过改变 Mansoux 模型的初始条件产生与训练数据不同的被测数据. 对该测试模式, 利用以上保存的 4 个常值 RBF 神经网络构造 4 个动态估计器 (15), 动态估计器中的 $b_1 = 0.5$, 神经网络 $\bar{W}_1^{kT} \mathbf{S}_1(\phi_{1m}^d, \bar{\psi}^d)$ ($k = 1, 2, \dots, 4$) 的所有参数与建模阶段的完全相同.

由这些动态估计器 (15) 与被检测压气机系统 (6) 得到检测残差系统 (16). 图 9 为基于北航试验台 Mansoux 模型的旋转失速初始扰动的检测结果图. 图 9 中的上图表示被测数据, 中图为各个模式所对应的残差图, 实线为旋转 *Stall inception1* 所对应的残差线, 点划线表示 *Stall inception2* 所对应的残差线. 图 9 表明在旋转失速进入到旋转失速初始扰动阶段, 旋转失速初始扰动所对应的残差线降到

最低,表明旋转失速即将发生.

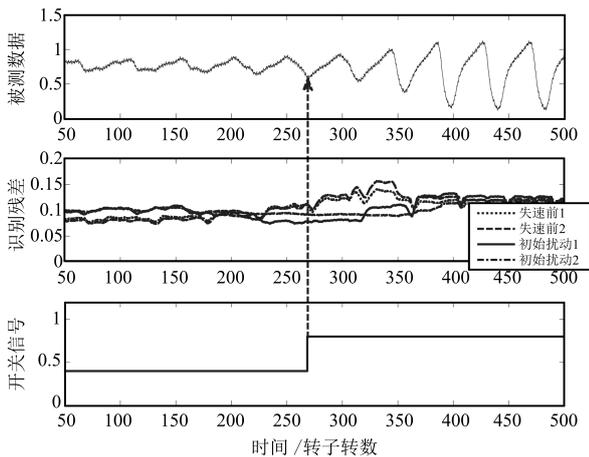


图9 基于北航试验台 Mansoux 模型的压气机旋转失速检测结果图

Fig.9 Detection results for test pattern generated by Mansoux model based on low-speed axial compressor of Beihang University

注 5. 本文采用基于北航试验台的 Mansoux 模型验证所提方法的有效性,即可以实现对失速初始扰动内在系统动态的近似准确建模,并能提前检测出旋转失速的发生.上述方法确实会导致较大的计算负荷,然而,随着计算机技术的飞速发展,特别是在高性能计算领域,并行计算已成为解决大规模计算问题的有效手段,其中众核处理器 GPU 因具有的大规模并行处理能力成为高性能计算的热点.我们利用 GPU 的强大计算能力来解决本文方法(即确定学习及动态模式识别算法)带来的较大计算负荷问题,大幅度缩短神经网络建模时间,增强了所提方法的实用性.

注 6. 第 4 节和第 5 节分别针对 Mansoux-C2 模型和基于北航试验台的 Mansoux 模型中的旋转失速主要系统动态进行了近似准确建模,在建模过程中,假设所有测量已知,并且 $g_i(\phi_{ir}, \psi, p_{ir})$ 都被准确抵消.在实验研究中,我们仅有某个传感器的测量信号和与其相邻的 2 个传感器的测量信号已知,此时 $g_i(\phi_{ir}, \psi, p_{ir})$ 被视为系统未建模动态.依照文献 [44] 中的结果,我们提出在任一测量点的系统动态可以近似由这个测量点及其相邻 2 个测量点状态构成的系统动态进行近似逼近.此方法的合理性可依据文献 [44] 中的结果进行解释,即任意耗散系统(包括许多由偏微分方程描述的无穷维分布参数系统)的系统动态可以由一个三阶常微分方程的解以任意精度来逼近.上述无穷维分布参数系统包括用于描述流体行为的 Navier-Stokes 系统,因此描述轴流压气机中流场旋转失速的系统动态可以由一个三维常

微分方程组的解来近似表达.在本文所提方法的基础上,我们利用北航试验台的实验数据开展了失速在线检测研究,在 2500 转/分、2700 转/分、2900 转/分、3000 转/分等四个典型转速下,实现了对旋转失速的在线实时提前检测.由于篇幅所限,具体试验研究结果将在另文中详细论述.

6 结论及展望

本文基于确定学习理论提出一个轴流压气机旋转失速建模与检测的新方法.首先,提出一个对旋转失速初始扰动的主要系统动态的近似准确建模方法.其次,在对主要系统动态近似准确建模的基础上,提出一种对旋转失速初始扰动进行快速检测的方法.并针对 MIT 的 Mansoux-C2 模型进行了仿真研究,验证了本文方法的有效性.最后,在北航的低速轴流压气机试验台上开展了试验研究,通过测量得到基于北航低速轴流压气机试验台的 Mansoux 模型,并针对北航试验台 Mansoux 模型进行了旋转失速的建模与检测,仿真研究结果验证了本文方法的有效性.

本文是基于北航低速轴流压气机试验台的 Mansoux 模型旋转进行失速建模与检测研究,在另一篇论文中,将会利用本文所提出的检测方法,详细介绍现场试验过程.

由于本文提出的近似准确建模和快速检测方法都是针对某一叶片通道的局部区域内的不稳定流动模式的建模和检测,因此也有可能应用于实现突尖波型旋转失速初始扰动的建模和检测.

致谢

感谢中国燃气涡轮研究院周拜豪副总工程师和哈尔滨工业大学于达仁教授等航空发动机研究领域专家与本文作者的有益讨论.感谢华南理工大学硕士研究生周龙沙、周勇、陈泓宇、许加庆、贺才梁、梁德战以及北京航空航天大学硕士研究生姚涓、北京大学博士研究生董万静和北京大学博士后张明明等为旋转失速检测系统的研制及大量的现场试验所付出的辛勤努力.

References

- 1 Wu Yan-Hui, Chu Wu-Li, Zhang Hao-Guang. A review of studies on stall precursors in axial-flow compressor. *Advances in Mechanics*, 2008, **38**(5): 571–584 (吴艳辉, 楚武利, 张皓光. 轴流压气机失速初始扰动的研究进展. *力学进展*, 2008, **38**(5): 571–584)
- 2 Greitzer E M. The stability of pumping systems — the 1980 freeman scholar lecture. *ASME Journal of Fluid Engineering*, 1981, **103**(2): 193–242

- 3 Moore F K, Greitzer E M. A theory of post-stall transients in axial compression systems, Part I: Development of equations. *Journal of Engines for Gas Turbines and Power*, 1986, **108**(1): 68–76
- 4 Moore F K, Greitzer E M. A theory of post-stall transients in axial compression systems, Part II: Application. *Journal of Engines for Gas Turbines and Power*, 1986, **108**(2): 231–239
- 5 Park H G. Unsteady Disturbance Structures in Axial Flow Compressor Stall Inception [Master dissertation], Massachusetts Institute of Technology, USA, 1994
- 6 Gong Y F. A Computational Model for Rotating Stall and Inlet Distortions in Multistage Compressors [Ph.D. dissertation], Massachusetts Institute of Technology, USA, 1999
- 7 Vo H D, Tan C S, Greitzer E M. Criteria for spike initiated rotating stall. *ASME Journal of Turbomachinery*, 2008, **130**(1): 1–9
- 8 Day I J, Breuer T, Escuret J, Cherrett M, Wilson A. Stall inception and the prospects for active control in four high-speed compressors. *Journal of Turbomachinery*, 1999, **121**(1): 18–27
- 9 McCaughan F E. Application of bifurcation theory to axial flow compressor instability. *Journal of Turbomachinery*, 1989, **111**(4): 426–433
- 10 McCaughan F E. Bifurcation analysis of axial flow compressor stability. *SIAM Journal on Applied Mathematics*, 1990, **50**(5): 1232–1253
- 11 Abed E H, Houpt P K, Hosny W M. Bifurcation analysis of surge and rotating stall in axial flow compressors. *AMSE Journal of Turbomachinery*, 1993, **115**(4): 817–824
- 12 Adomaitis R A, Abed E H. Bifurcation analysis of nonuniform flow patterns in axial-flow gas compressors. In: Proceedings of the 1st World Congress on Nonlinear Analysis. NJ, USA: Walter de Gruyter and Co. Hawthorne, 1992
- 13 Mansoux C A, Gysling D L, Setiawan J D, Paduano J D. Distributed nonlinear modeling and stability analysis of axial compressor stall and surge. In: Proceedings of the 1994 American Control Conference. Baltimore, MD, USA: IEEE, 1994. 2305–2316.
- 14 Paduano J D, Valavani L, Epstein A H. Parameter identification of compressor dynamics during closed-loop operation. In: Proceedings of the 1991 American Control Conference. Boston, MA, USA: IEEE, 1991. 2379–2385
- 15 Paduano J D, Valavani L, Epstein A H, Greitzer E M, Guenette G R. Modeling for control of rotating stall. *Automatic*, 1994, **30**(9): 1357–1373
- 16 Epstein A H. “Smart” engine components: a micro in every blade. *Aerospace America*, 1986, **24**(1): 1290–1315
- 17 Mcdougal N M, Cumpsty N A, Hynes T P. Stall inception in axial compressors. *ASME Journal of Turbomachinery*, 1990, **112**(1): 116–125
- 18 Garnier V H, Epstein A H, Greitzer E M. Rotating waves as a stall inception indication in axial compressors. *ASME Journal of Turbomachinery*, 1991, **113**(2): 290–301
- 19 Day I J. Stall inception in axial flow compressor. *ASME Journal of Turbomachinery*, 1993, **115**(1): 1–9
- 20 Tryfonidis M, Etchevers O, Paduano J D, Epstein A H, Hendricks G J. Prestall behavior of several high-speed compressors. *ASME Journal of Turbomachinery*, 1995, **117**(1): 62–80
- 21 Hoss B, Leinhos D, Fottner L. Stall inceptions in the compressor system of a turbofan engine. *ASME Journal of Turbomachinery*, 1998, **122**(1): 32–44
- 22 Liao S F, Chen J Y. Time-frequency analysis of compressor rotating stall by means of wavelet transform. In: Proceedings of the 1996 ASME, 1996. DOI: 96-GT-57
- 23 Xie Feng, Xie Shou-Sheng. Detection of rotating stall in aircraft engine based on wavelet analysis. *Journal of Aerospace Power*, 2006, **21**(4): 754–758
(谢峰, 谢寿生. 基于小波分析的航空发动机旋转失速检测方法. *航空动力学报*, 2006, **21**(4): 754–758)
- 24 Tan C S, Day I J, Morris S, Wadia A. Spike-type compressor stall inception, detection, and control. *Annual Review of Fluid Mechanics*, 2010, **42**(1): 275–300
- 25 Paduano J D. Analysis of Compression System Dynamics. *Von Karman Institute Invited Lecture in Active Control of Engine Dynamics*, Brussels. <http://web.mit.edu/jdpaduan/Public/Pubs/PaduanoVKI01.pdf>, 2001, 1–37
- 26 Deteriou M A, Rosen I G. On the persistence of excitation in the adaptive estimation of distributed parameter systems. *IEEE Transactions on Automatic Control*, 1994, **39**(5): 1117–1123
- 27 Deteriou M A, Rosen I G. Adaptive identification of second-order distributed parameter systems. *Inverse Problems*, 1994, **10**(2): 261–294
- 28 Hong K S, Bentsman J. Direct adaptive control of parabolic systems: Algorithm synthesis and convergence and stability analysis. *IEEE Transactions on Automatic Control*, 1994, **39**(10): 2018–2033

- 29 Orlov Y, Bentsman J. Adaptive distributed parameter systems identification with enforceable identifiability condition and reduced-order spatial differentiation. *IEEE Transactions on Automatic Control*, 2000, **45**(2): 203–216
- 30 Baumeister J, Scondo W, Demetriou M A, Rosen I G. On-line parameter estimation for infinite-dimensional dynamical systems. *SIAM Journal on Control and Optimization*, 1997, **35**(2): 678–713
- 31 Qu Shou-De, Li Song-Shi, Dai He-Ping. The application of Galerkin's method to parameter identification of one-dimensional parabolic partial differential equation and its boundary conditions. *Acta Automatica Sinica*, 1989, **15**(2): 156–160
(瞿寿德, 李松石, 戴和平. 应用 Galerkin 方法辨识一维抛物型偏微分方程及其边界条件中的参数. 自动化学报, 1989, **15**(2): 156–160)
- 32 Narendra K S, Annaswamy A M. *Stable Adaptive Systems*. Englewood Cliffs, NJ: Prentice-Hall, 1989
- 33 Sastry S S, Bodson M. *Adaptive Control: Stability, Convergence, and Robustness*. Englewood Cliffs, NJ: Prentice-Hall, 1989
- 34 Lu S, Basar T. Robust nonlinear system identification using neural-network models. *IEEE Transactions on Neural Networks*, 1998, **9**(3): 407–429
- 35 Gevers M. A personal view of the development of system identification. *IEEE Control Systems Magazine*, 2006, **26**(6): 93–105
- 36 Wang Le-Yi, Zhao Wen-Xiao. System identification: new paradigms, challenges, and opportunities. *Acta Automatica Sinica*, 2013, **39**(7): 933–942
(王乐一, 赵文斌. 系统辨识: 新的模式、挑战及机遇. 自动化学报, 2013, **39**(7): 933–942)
- 37 Wang C, Hill D J. Deterministic learning and rapid dynamical pattern recognition. *IEEE Transactions on Neural Networks*, 2007, **18**(3): 617–630
- 38 Wang C, Chen T R, Chen G R, Hill D J. Deterministic learning of nonlinear dynamical systems. *International Journal of Bifurcation and Chaos*, 2009, **19**(4): 1307–1328
- 39 Wang Cong, Chen Tian-Rui, Liu Teng-Fei. Deterministic learning and data-based modeling and control. *Acta Automatica Sinica*, 2009, **35**(6): 693–706
(王聪, 陈填锐, 刘腾飞. 确定学习与基于数据的建模及控制. 自动化学报, 2009, **35**(6): 693–706)
- 40 Wang C, Hill D J. *Deterministic Learning Theory for Identification, Recognition and Control*. Boca Raton, FL: CRC Press, 2009
- 41 Wang C, Chen T R. Rapid detection of small oscillation faults via deterministic learning. *IEEE Transactions on Neural Networks*, 2011, **22**(8): 1284–1296
- 42 Zhang X, Polycarpou M M, Parisini T. A robust detection and isolation scheme for abrupt and incipient faults in nonlinear systems. *IEEE Transactions on Automatic Control*, 2002, **47**(4): 576–593.
- 43 Wang Y, Murray R M. Bifurcation control of rotating stall with actuator magnitude and rate limits: Part I — model reduction and qualitative dynamics. *Automatica*, 2002, **38**(4): 597–610
- 44 Robinson J C. All possible chaotic dynamics can be approximated in three dimensions. *Nonlinearity*, 1998, **11**(3): 529–545



王聪 华南理工大学自动化学院教授。主要研究方向为非线性系统自适应神经网络控制与辨识, 确定学习理论, 动态模式识别, 基于模式的控制, 振动故障诊断及在航空航天, 生物医学工程及应用。本文通信作者。

E-mail: wangcong@scut.edu.cn

(**WANG Cong** Professor at the School of Automation, South China University of Technology. His research interest covers adaptive neural network control/identification, deterministic learning theory, dynamical pattern recognition, pattern-based intelligent control, oscillation fault diagnosis, and the application in aerospace and biomedical engineering. Corresponding author of this paper.)



文彬鹤 中航工业航空动力系统研究所系统工程师。主要研究方向为航空发动机全权限数字电子控制研究, 确定学习理论, 动态模式识别。

E-mail: bhwen5516521@126.com

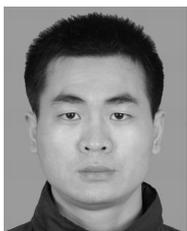
(**WEN Bin-He** Engineer at the AVIC Aviation Motor Control System Institute. His research interest covers full authority digital engine (or electronics) control, deterministic learning, and dynamic pattern recognition.)



司文杰 华南理工大学自动化学院控制与优化中心博士研究生, 主要研究方向为确定学习, 故障诊断。

E-mail: siwenjie@gmail.com

(**SI Wen-Jie** Ph. D. candidate at the Center for Control and Optimization, School of Automation, South China University of Technology. His research interest covers deterministic learning and fault diagnosis.)



彭滔 重庆理工大学电子信息与自动化学院讲师. 主要研究方向为神经网络控制, 确定学习理论, 分布参数系统, 机器人控制.

E-mail: pengtaoscut@163.com

(**PENG Tao** Lecturer at the College of Electronic Information and Automation, Chongqing University of Technology.

His research interest covers neural network control, deterministic learning theory, distributed parameter systems, and robot control.)



袁成志 华南理工大学自动化学院硕士研究生. 主要研究方向为混杂控制系统的稳定性分析与鲁棒控制器设计, 确定学习理论与应用.

E-mail: cyuan2@ncsu.edu

(**YUAN Cheng-Zhi** Master student at the School of Automation, South China University of Technology. His research interest covers stability analysis and robust controller design for hybrid control systems, deterministic learning theory and its applications.)



陈填锐 广东工业大学自动化学院讲师. 主要研究方向为确定学习, 故障诊断.

E-mail: trchen304@gmail.com

(**CHEN Tian-Rui** Lecturer at the School of Automation, Guangdong University of Technology. His research interest covers deterministic learning and fault diagnosis.)



林文愉 华南理工大学自动化学院硕士研究生. 主要研究方向为确定学习, 并行计算. E-mail: lwydeemail@163.com

(**LIN Wen-Yu** Master student at the School of Automation, South China University of Technology. His research interest covers deterministic learning and parallel computing.)



王勇 北京大学力学与工程科学系教授. 主要研究方向为非线性动力系统控制, 流体流动和飞行控制的应用.

E-mail: yongwang@mech.pku.edu.cn

(**WANG Yong** Professor in the Department of Mechanics and Engineering Science, Peking University. His research interest covers control of nonlinear dynamical systems with applications to fluid flows and flight control.)



侯安平 北京航空航天大学能源与动力工程学院副教授. 主要研究方向为叶轮机械气动弹性研究, 风扇、压气机气动设计, 气浮高速电机研究, 微型燃机、风光互补等分布式能源系统研究.

E-mail: houap@buaa.edu.cn

(**HOU An-Ping** Associate professor at the School of Energy and Power Engineering, Beihang University. His research interest covers turbomachinery aeroelastic research, fan and compressor aerodynamic design, air speed motor, and other distributed energy systems.)