

DOI: 10.19650/j.cnki.cjsi.J1904700

基于贝叶斯更新的机电作动器健康因子构建方法*

张玉杰, 冯伟童, 刘大同, 彭宇

(哈尔滨工业大学电子与信息工程学院 哈尔滨 150080)

摘要:机电作动器(EMA)由于重量轻、体积小、可靠性高等优势成为多电/全电飞机的核心部件,逐步广泛应用于各类多电/全电飞机中。然而,EMA动态变化的运行模式和载荷工况给其退化建模和健康因子(HI)估计带来较大挑战。因此,提出一种基于贝叶斯更新的EMA HI构建方法。首先基于历史监测数据构建HI先验模型,在此基础上,结合贝叶斯更新理论和实时监测数据对EMA HI先验模型参数分布进行迭代更新,最终实现不同运行模式和载荷工况下EMA退化状态的准确表征。为解决变工况条件下EMA HI构建模型失配问题提供了一种新颖的思路,并基于NASA公开数据集进行了实验验证。结果表明,与基于模型辨识的EMA HI构建方法相比,基于贝叶斯更新的EMA HI构建方法具有更强的工况适应能力,能够在变工况条件下有效地构建出EMA HI。

关键词:多电/全电飞机;机电作动器;变工况;健康因子;贝叶斯更新

中图分类号: TP206+3 TH165+3 **文献标识码:** A **国家标准学科分类代码:** 510.4030

Health indicator construction method based on Bayesian updating for electro-mechanical actuator

Zhang Yujie, Feng Weitong, Liu Datong, Peng Yu

(School of Electronics and Information Engineering, Harbin Institute of Technology, Harbin 150080, China)

Abstract: Electro-mechanical actuator (EMA) has become the core components of more/all electric aircraft due to its light weight, small size, high reliability and etc., which has gradually been widely utilized in various types of more/all electric aircrafts. However, the dynamic operation profiles and load conditions of EMA bring great challenges to its degradation modeling and health indicator (HI) estimation. Therefore, an EMA HI construction method based on Bayesian updating is proposed. Firstly, an HI prior model is built based on historical monitoring data. Secondly, the EMA HI prior model parameters are updated iteratively through utilizing Bayesian updating theory and real-time monitoring data. Finally, the EMA degradation state under various operation profiles and load conditions is accurately characterized. This study provides a novel idea for solving the mismatch issue of the EMA HI construction model under variable working conditions, and experiments with NASA benchmark data verify the effectiveness of the proposed method. The experiment results show that compared with the EMA HI construction method based on model identification, the proposed EMA HI construction method based on Bayesian updating has stronger adaptability to the working conditions and can effectively construct EMA HI under variable working conditions.

Keywords: more/all electric aircraft; electro-mechanical actuator; variable working condition; health indicator; Bayesian updating

0 引言

机电作动器(electro-mechanical actuator, EMA)是多电飞机核心部件之一,主要用于驱动舵面、起落架等机械

结构,以完成特定功能^[1]。与传统飞机液压作动系统相比,EMA能够实现节约飞机运行成本、减少飞机重量、增强可靠性和可维护性的目的^[2]。目前,EMA已应用于波音787、空客A380以及军用战斗机F-35等机型^[3]。但是,相对于传统液压作动系统,EMA属于新生事物,其性

收稿日期:2019-01-27 Received Date:2019-01-27

* 基金项目:国家自然科学基金(61571160,61803121,61701131)、中国博士后科学基金(2019M651277)项目资助

能退化是多电飞机的安全隐患,甚至可能导致坠机事故,造成巨大的经济损失。因此,EMA安全性和可靠性仍需进一步提高。

EMA健康管理系统是提高EMA安全性和可靠性的重要手段之一。健康因子(health indicator, HI)是指能够用于表征对象系统退化程度的直接或间接参量^[4-6]。作为EMA健康管理系统的重要组成部分,EMA HI构建成为EMA研究领域的热点问题之一^[7-9]。HI构建方法可分为直接构建方法和间接构建方法两类。直接构建方法即对系统的物理参量进行分析,从中直接选择某一个量作为HI。间接构建方法即通过对系统的退化过程进行分析,从性能相关参量中提取HI^[10-13]。目前,在HI构建领域存在很多研究。文献[7]基于EMA监测数据提出了5个EMA HI,包括温度偏差、位移、控制信号标准偏差、载荷和作用力。文献[14]在深入分析EMA模型的基础上,提出了4个HI,包括摩擦系数、齿轮局部刚度、力矩常数和电机温度。文献[15]研究了如何从信号频率变化、振型变化、应变模态中提取HI。文献[16]基于作动器的伺服电流频域的峰值特征构建了表征阀门性能退化的HI。这些研究揭示了EMA HI构建对于EMA健康管理系统技术发展的重要性。然而,复杂的EMA运行工况使得其监测数据极易受到工况变化的影响。文献[17]认为不同的故障模式具有不同的HI,且HI与运行工况密切相关。

在EMA HI构建研究中,许多研究者针对工况变化引起的问题做了大量的研究。文献[18]对飞机起落装置EMA不同工况模式下速度跟踪性能的退化特性进行了研究,并指出不同工况下EMA的模型参数的差异。文献[19]针对不同运行模式和载荷工况下的EMA监测数据进行了收集,以支撑EMA退化状态识别研究,并将真实工况状态下EMA监测数据的收集作为未来的研究重点之一。文献[3]指出运行模式、载荷类型、载荷大小会影响HI的退化基线,进而导致EMA故障诊断研究存在较高的误识别率。文献[20]针对时变EMA载荷和运行速度提出数据驱动的故障监测方法,通过提取故障信号与位置的相关关系,有效地从整体上减弱了工况变化对HI的影响。文献[21]在总结EMA状态监测功能的基础上指出EMA的退化状态与外部载荷具有一定的相关性,并讨论了在特定运行条件下的EMA寿命预测方法。文献[22]针对EMA寿命控制问题开展了相关研究,作者指出当存在时变载荷时,EMA轴承寿命预测模型的关键参数会发生变化,并提出利用试探法求解参数值。文献[23]分析了在EMA电机绕组故障检测和预测中运行工况的影响,并提出了通过施加特定控制命令和增加冗余作动器的方式消除工况影响的解决方法。上述研究从不同角度对EMA HI构建方法开展了研究,为EMA HI构建技术的发展奠定了基础。但是,这些EMA HI构建方

法仍为静态模型,当EMA运行工况发生变化时,此类HI构建方法的适用性受到限制。

由以上可知,现有EMA HI构建方法的静态性、复杂性致使其在实际变工况飞行场景中存在模型失配问题,难以满足复杂工况下EMA健康管理系统的需要。因此,为解决EMA HI模型中存在的由于运行工况变化而引起模型失配问题,本文提出一种基于贝叶斯更新的HI构建方法。在该方法中,从模型的自身角度出发,基于贝叶斯更新理论并结合EMA实时监测数据实现EMA HI构建模型参数的动态更新,最终解决了变工况条件下EMA HI模型失配问题,提高了EMA HI模型的准确性和适应性。

1 基于贝叶斯更新的HI构建方法

EMA HI构建方法主要分为2类:模型驱动方法和数据驱动方法。其中,模型驱动的HI构建方法主要是通过模型参数估计值与真实模型参数之间的偏差表征其退化程度,其优势表现为退化过程与模型参数有明显的对应关系。但该方法不能适应工况的变化,即当工况发生变化时,HI模型将出现失配问题,构建出的HI不能有效表征EMA的退化程度。另一方面,数据驱动的HI构建方法缺少先验知识的引导,当训练数据量过大时,容易出现过拟合问题。因此,本文针对工况变化引起的EMA HI构建模型失配问题,提出了基于贝叶斯更新的EMA HI构建方法。基于贝叶斯更新的EMA HI构建方法在引入EMA物理模型基础上,通过贝叶斯更新理论将先验模型知识和在线监测数据信息有机地结合在一起,有效地解决了工况变化引起的EMA HI构建模型失配问题,属于模型和数据驱动融合方法。

本文的创新之处在于:1)提出了基于多次最小二乘辨识方法的先验模型参数分布构建方法;2)提出了基于贝叶斯更新理论的先验模型参数更新方法。基于贝叶斯更新的EMA HI构建方法介绍可分为3个部分:EMA参数模型、贝叶斯更新理论和基于贝叶斯更新的EMA HI构建方法框架。

1.1 EMA参数模型

1) EMA结构组成和工作原理

EMA主要由控制电路、电机、机械传动机构、传感器4个部分组成,其组成结构如图1所示^[24]。

图1中, v_m 表示控制电路输出的电压信号,用于对电机进行控制; i_m 和 ω_m 分别为电机输出的电流信号和转速信号; T_{ex} 表示机械传动机构输出的载荷信号。工作过程中,电机用于驱动机械传动机构进行往复运动,以达到向外界提供机械推力或拉力的目的。同时,电机输出受到以传感器信息和控制信号为输入的控制电路的控制。

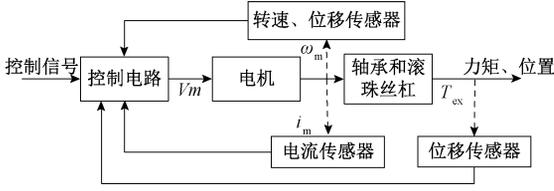


图1 EMA工作模块

Fig.1 The module diagram of EMA

2) EMA 参数模型构建

EMA 可以简化为一个带有负载的电路模型,如图2所示^[25]。

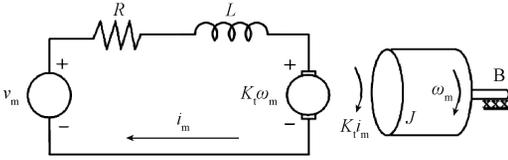


图2 EMA简化电路模型

Fig.2 Simplified circuit model of EMA

图2中, v_m 、 i_m 、 ω_m 、 R 和 L 分别为电机电枢电压、电枢电流、输出转速、电机内阻和电感;参量 J 和 B 分别表示系统转动惯量和系统摩擦系数;参量 K_e 和 K_t 分别表示反电动势常数和电磁转矩常数。反电动势常数即反电动势电压与电机输出转速之比,电磁转矩常数即电机输出转矩与电机电枢电流之比。

若令外部负载转矩为 T_{ex} ,根据基尔霍夫电压定律和输入输出转矩相等可得:

$$v_m = K_e \omega_m + i_m R + L \frac{di_m}{dt} \quad (1)$$

$$K_t i_m - T_{ex} = B \omega_m + J \frac{d\omega_m}{dt} \quad (2)$$

EMA 是由控制器电路、电机、机械结构和传感器系统组成的典型电机拖动系统,图2所示的电路简化模型是电机拖动系统的经典模型,且多次用于EMA相关领域的研究^[3,25]。因此,本文基于该电路简化模型开展EMA变工况HI构建研究,并通过参数辨识方法获得模型的参数。

由于传感器采集到的数据为离散数据,所以本文构建的模型为离散参数模型。当载荷 $T_{ex} = 0$ 时,将式(1)和(2)转换为 Z 域表示,并化简可得离散化参数模型,如式(3)所示。

$$\frac{I_m(z)}{V_m(z)} = \frac{(2JT + T^2B) + (T^2B + T^2)z^{-1} + (T^2 - 2JT)z^{-2}}{(4JL + 2TM + T^2N) + (2T^2N - 8JL)z^{-1} + (T^2N - 2TM + 4JL)z^{-2}} =$$

$$\frac{b_0 + b_1 z^{-1} + b_2 z^{-2}}{1 + a_0 z^{-1} + a_1 z^{-2}} \quad (3)$$

式中: $I_m(z)$ 和 $V_m(z)$ 分别为电流和电压的 Z 域表示; T 为采样周期。 $M = BL + JR$, $N = BR + K_e K_t$, a_0 、 a_1 、 b_0 、 b_1 和 b_2 分别表示如下。

$$a_0 = \frac{2T^2N - 8JL}{4JL + 2TM + T^2N} \quad (4)$$

$$a_1 = \frac{T^2N - 2TM + 4JL}{4JL + 2TM + T^2N} \quad (5)$$

$$b_0 = \frac{2JT + T^2B}{4JL + 2TM + T^2N} \quad (6)$$

$$b_1 = \frac{T^2B + T^2}{4JL + 2TM + T^2N} \quad (7)$$

$$b_2 = \frac{T^2 - 2JT}{4JL + 2TM + T^2N} \quad (8)$$

3) 参数辨识方法

通过参数辨识方法并基于电压和电流监测数据可以求得EMA模型参数,即得到 a_0 、 a_1 、 b_0 、 b_1 和 b_2 的值。本文使用最小二乘辨识方法估计EMA模型参数。最小二乘辨识方法的原理如下^[25-26]。

令 θ 表示模型参数向量,即:

$$\theta = [a_0 \ a_1 \ b_0 \ b_1 \ b_2] \quad (9)$$

定义在某一时刻 t ,电压和电流历史监测数据向量为回归向量 $\phi(t)$,表示如下。

$$\phi(t) = [-i(t-1) \ \dots \ -i(t-n_a) \ -v(t-1) \ \dots \ -v(t-n_b)]^T \quad (10)$$

式中: $v(t)$ 和 $i(t)$ 分别表示 t 时刻电压和电流监测数据; n_a 和 n_b 分别表示模型分母和分子中未知数的个数。在本文中, $n_a = 2$ 且 $n_b = 3$ 。根据最小二乘原理,定义判别函数 $D(\theta)$ 如下。

$$D(\theta) = \frac{1}{N} \sum_{t=1}^N \frac{1}{2} [i(t) - \phi^T(t)\theta]^2 \quad (11)$$

式中: N 表示监测数据的长度。当 $D(\theta)$ 的取值最小时, θ 值即为EMA模型参数的最优估计值 $\hat{\theta}$,即:

$$\hat{\theta} = \arg \min_{\theta} D(\theta) \quad (12)$$

1.2 贝叶斯更新理论

贝叶斯推理基于贝叶斯理论提供了理性结合先验知识的方法,以实现对其结果进行统计推理的目的,而进行贝叶斯推理的过程,称为贝叶斯更新^[27]。贝叶斯推理可以为故障诊断、寿命预测的结果提供判断。贝叶斯更新方法可以用于处理在时变运行工况下模型的更新问题^[28]。在本文中,该方法用于HI构建模型参数的更新。贝叶斯更新理论描述如下^[29]。

对于一个应用于EMA的贝叶斯模型类 M 应具有如下特点:

1) 在模型参数 θ 已知的情况下,电压监测数据 v 和电流监测数据 i 的概率可表示为 $p(i, v | \theta, M)$;

2) 根据先验知识可以得到参数的先验概率密度函数 (probability density function, PDF) $p(\theta | M)$ 。

假设历史电压监测数据 v 和电流监测数据 i 已知,贝叶斯更新的目的为基于实时监测数据更新模型参数 θ 的概率分布,即基于贝叶斯理论得到后验模型参数 $p(\theta | i, v, M)$, 如式(13)所示。

$$p(\theta | i, v, M) \propto p(i, v | \theta, M)p(\theta | M) \quad (13)$$

式中: $p(\theta | i, v, M)$ 是 θ 的函数,即似然函数;比例项常数即为 $p(i, v | M)$ 的倒数。

通过贝叶斯更新的方法可以实现通过模型参数更新引入实时监测数据信息的目的,同时可以对先验参数分布进行融合,使得模型参数更加合理。

1.3 基于贝叶斯更新的 EMA HI 构建方法框架

文献[25]在利用模型辨识方法构建特征之后,使用贝叶斯分类器对特征进行分类,以实现故障检测的目的。本文在文献[25]中 EMA 简化电路模型以及模型辨识方法的基础上,针对变工况引起的 HI 模型失配问题,引入了贝叶斯更新理论,提出了基于贝叶斯更新的 EMA 变工况 HI 构建方法,有效地将先验模型和在线监测数据结合在一起,使得 HI 构建模型具有了更新能力,进而实现 EMA 变工况 HI 的准确构建。基于贝叶斯更新的 EMA HI 构建方法如图 3 所示,主要步骤如下。

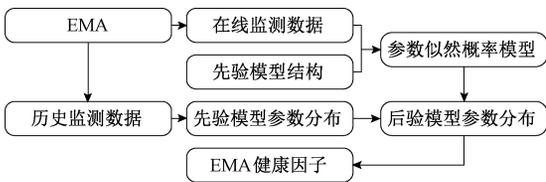


图 3 基于贝叶斯更新的 EMA HI 构建方法

Fig.3 EMA HI construction method based on Bayesian updating

1) EMA 参数模型构建

通过基于 EMA 各个参量之间的基本物理关系以及相应的数学推导,可以实现 EMA 参数模型的构建。本研究所使用的参数模型为 EMA 电机电压和电机电流参数模型,即模型的输入为电压,模型的输出为电流。模型的参数由实际监测的电压和电流数据辨识得到。

2) 先验参数分布获取

在步骤 1) 中建立的参数模型基础上,基于实际监测的电压和电流数据对参数模型的各个参数的先验分布进行辨识。由于每一次辨识均可获得一组确定的模型参数,因此,若要获得模型的先验参数分布,需要结合不同的电压和电流监测数据进行多次辨识,从而获得模型参数的先验分布,即获得各个模型参数的概率密度函数和

累积概率密度函数,进而得到 EMA 的先验参数模型。

3) 似然概率模型构建

在获得 EMA 先验参数模型之后,结合新的在线监测数据构建 EMA 似然概率模型。该似然概率模型含有未知的后验模型参数,当似然函数取得最大值时,后验模型参数的取值为最优取值。

4) 后验参数分布求解

基于极大似然估计方法对步骤 3) 中获得的似然概率模型中的后验参数分布进行估计。后验参数分布的求解过程包含参数模型结构、历史监测数据和在线监测数据等信息,即将先验知识和后验知识进行了结合,这种方式能够有效提升后验参数模型的准确性,降低运行工况变化带来的影响。

5) HI 估计

通过后验参数模型和 EMA 电压监测数据,能够有效地估计 EMA 电流监测数据。本文将电流监测数据作为表征 EMA 健康程度的 HI。

基于贝叶斯更新的 HI 构建方法核心过程可概括为 EMA 参数模型构建和模型参数的贝叶斯更新。其中,EMA 参数模型构建对应于步骤 1),模型参数的贝叶斯更新对应于步骤 2)~4)。

2 验证和评估

本研究在 EMA 参数模型构建的基础上使用贝叶斯更新方法对模型的参数进行了更新,并基于更新后的模型,完成 HI 的动态估计。为了验证提出的基于贝叶斯更新的 EMA HI 构建方法的有效性,使用来自于 NASA 的 EMA 公开数据集进行了实验验证。在实验中,将基于贝叶斯更新的 HI 构建方法与传统基于模型辨识的 HI 构建方法进行比较。在文献[25]的基础上,基于模型辨识的 HI 构建方法的主要包含步骤 1)、2) 和 5),其中步骤 5) 所用模型参数为步骤 2) 获取的先验参数。

2.1 EMA FLEA 实验平台介绍

由于实际场景中获得 EMA 真实失效数据具有周期长、成本高的特点,验证中使用的数据源自美国 NASA 的机载机电作动器 (flyable electro-mechanical actuator, FLEA) 试验台。FLEA 具有重量轻的特点,而且可以自动运行,仅需要与电源和飞机数据总线进行连接,即可进行正常工作。FLEA 有 2 路供电接口,分别为交流 110 V 和直流 28 V,其中交流 110 V 用于处理器和数据采集系统,直流 28 V 用于作动器和部分传感器,有 1 路载荷输入接口,用于飞行载荷接入,即 FLEA 可以直接连接到飞机数据总线上,使得应用于 FLEA 上的载荷和运动曲线可以从真实飞机控制舵面的数据中得到。FLEA 的模型和实物如图 4 所示。

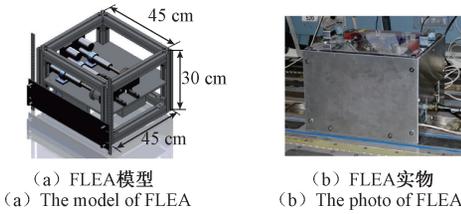


图4 FLEA模型和实物

Fig.4 The model and photo of FLEA

FLEA 数据采集系统使用 2 个 NI 6259 采集模块实现 2 个不同采样频率的数据采集通道,即低速通道和高速通道。低速通道采样频率为 1 kHz,用以实现低频信号数据采集,如温度、电压和电流等信号。高速通道采样频率为 20 kHz,用以实现高频信号数据采集,如振动信号。FLEA 与故障作动器 X 直接相关的监测数据曲线如图 5 所示。

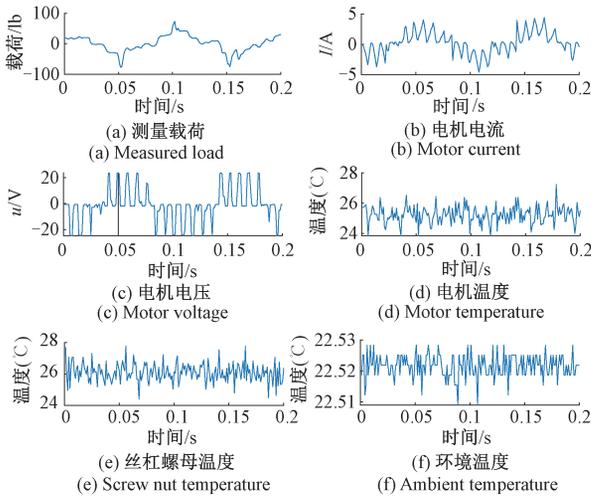


图5 FLEA 作动器 X 监测数据

Fig.5 The monitoring data of FLEA actuator X

为了验证本文方法的效果,使用了 NASA FLEA 试验台的运行条件不同的 2 组电压监测数据和电流监测数据进行变工况下电流估计验证,共进行了 2 个实验。2 组实验数据对应的运行条件如表 1 所示。

表 1 2 组监测数据集的 EMA 运行条件
Table 1 The EMA operation conditions for two monitoring datasets

组号	行程/mm	运动频率/Hz	载荷/lb	运动模式
①	40	1	10	正弦
②	80	0.25	-10	正弦

2.2 HI 构建方法验证

为了验证本文方法的有效性,在构建参数模型的基础上,2 个实验分别采用提出的基于贝叶斯更新的 EMA HI 构建模型和传统基于模型辨识的 EMA HI 构建模型对 EMA 电机电流进行估计。

在第 1 个实验中,基于第 1 组实验数据完成 EMA 参数模型构建和参数辨识,然后将第 2 组实验数据分为 2 部分,一部分用于更新参数模型,另一部分用于验证估计方法的性能。第 1 组数据包含 3 000 个点。本文从第 1 组数据中构建 100 个长度为 1 000 的随机训练数据集,通过多次训练可得模型参数的联合高斯分布。令 X 表示多维随机变量, $f(X)$ 表示多维随机变量的联合高斯分布 PDF, p 表示随机变量的维数, μ 为分布的均值, Σ 为该分布协方差,则该联合高斯分布的形式如式(14)所示。

$$f(X) = (2\pi)^{-\frac{p}{2}} |\Sigma|^{-\frac{1}{2}} \exp\left\{-\frac{1}{2} (X - \mu)^T \Sigma^{-1} (X - \mu)\right\} \quad (14)$$

其中, $p = 5$, μ 和 Σ 的值如式(15)和(16)所示。

$$\mu = [-1.2507 \ 0.1094 \ -0.0111 \ -0.0622 \ 0.0213] \quad (15)$$

$$\Sigma = \begin{bmatrix} 156.4674 & -13.7191 & 1.3891 & 7.7792 & -2.6694 \\ -13.7191 & 1.2408 & -0.1212 & -0.6793 & 0.2348 \\ 1.3891 & -0.1212 & 0.0133 & 0.0684 & -0.0235 \\ 7.7792 & -0.6793 & 0.0684 & 0.3875 & -0.1328 \\ -2.6694 & 0.2348 & -0.0235 & -0.1328 & 0.0456 \end{bmatrix} \quad (16)$$

第 2 组数据共包含 2 970 个点。本文选取第 2 组数据的前 100 个点作为贝叶斯更新模型的更新输入,选取剩余的 2 870 个点作为模型的测试数据集。更新后分布

模型的均值 μ_1 和方差 Σ_1 如式(17)和(18)所示。基于贝叶斯更新模型的电流估计值与真实值对比的结果如图 6 和 7 所示。

$$\mu_1 = [-1.8298 \ 0.5166 \ -0.0596 \ -0.0324 \ 0.0426] \quad (17)$$

$$\Sigma_1 = \begin{bmatrix} 21.2327 & -5.6964 & 0.8012 & 0.3367 & -0.5104 \\ -5.6964 & 1.9281 & -0.1625 & -0.0898 & 0.1359 \\ 0.8012 & -0.1625 & 0.0426 & 0.0092 & -0.0201 \\ 0.3367 & -0.0898 & 0.0092 & 0.0084 & -0.0082 \\ -0.5104 & 0.1359 & -0.0201 & -0.0082 & 0.0128 \end{bmatrix} \quad (18)$$

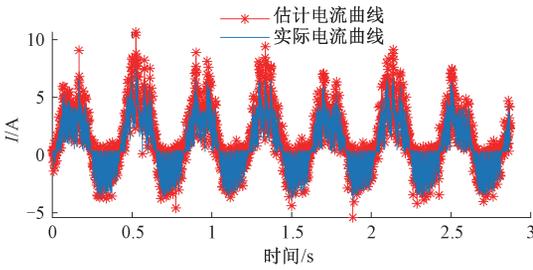


图 6 基于贝叶斯更新的电流估计数据和真实数据(2.87 s)
Fig.6 Current estimation data based on Bayesian updating method and real current data (2.87 s)

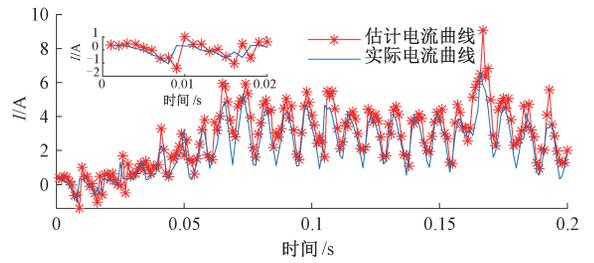


图 7 基于贝叶斯更新的电流估计数据和真实数据(0.2 s)
Fig.7 Current estimation data based on Bayesian updating method and real current data (0.2 s)

其中,图 6 为第 2 种工况下全部测试集,即 2.87 s, 电流估计值与实际电流值曲线对比,图 7 为第 2 种工况下测试集前 0.2 s 的电流估计值与实际电流值曲线对比。

在第 2 个实验中,使用第 2 组实验数据的前 100 个点作为训练数据集,并基于 Bootstrap 方法构建多个训练

数据集。通过多个训练数据集进行模型辨识构建参数分布,使用其参数分布均值作为模型的最终参数值,最终基于该模型对剩余的 2 870 个点的电流进行估计。在第 2 个实验中,模型参数分布的均值 μ_2 和方差 Σ_2 如式(19)和(20)所示。

$$\mu_2 = [-1.9456 \quad 0.5980 \quad -0.0694 \quad -0.0264 \quad 0.0469] \quad (19)$$

$$\Sigma_2 = \begin{bmatrix} 19.6684 & -5.5596 & 0.7873 & 0.2588 & -0.4837 \\ -5.5596 & 1.9162 & -0.1613 & -0.0830 & 0.1335 \\ 0.7873 & -0.1613 & 0.0424 & 0.0085 & -0.0199 \\ 0.2588 & -0.0830 & 0.0085 & 0.0046 & -0.0069 \\ -0.4837 & 0.1335 & -0.0199 & -0.0069 & 0.0124 \end{bmatrix} \quad (20)$$

基于传统模型辨识方法电流估计结果如图 8 和 9 所示。其中,图 8 为第 2 种工况下全部测试集,即 2.87 s, 电流估计值与实际电流值曲线对比,图 9 为第 2 种工况下测试集前 0.2 s 的电流估计值与实际电流值曲线对比。

使用 2 870 个点的 10 次实验 MAE 均值和 RMSE 均值评价 2 种方法的性能优劣,如表 2 所示。

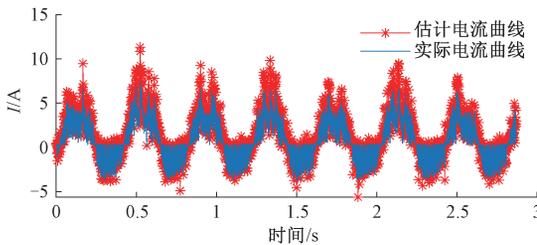


图 8 基于模型辨识方法的电流估计数据和真实数据(2.87 s)

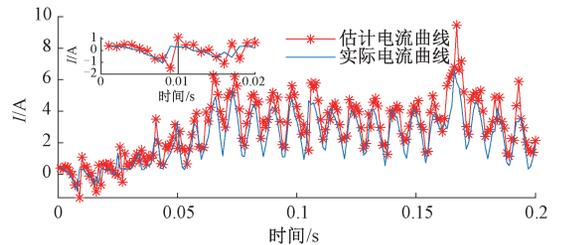


图 9 基于模型辨识方法的电流估计数据和真实数据(0.2 s)
Fig.9 Current estimation data based on model identification method and real current data (0.2 s)

Fig.8 Current estimation data based on model identification method and real current data (2.87 s)

表 2 EMA HI 构建实验 MAE 和 RMSE 均值
Table 2 The means of MAE and RMSE for EMA HI construction experiments

EMA HI 构建方法	MAE 均值	RMSE 均值
贝叶斯更新方法	0.584 1	0.791 3
模型辨识方法	0.650 1	0.884 9

从图 7 和 9 可以看出,2 种方法估计曲线与真实曲线都比较接近。因此,在本文中,使用平均绝对误差(mean absolute error, MAE)和均方根误差(root mean square error, RMSE)衡量 2 种方法的准确性和稳定性。RMSE 和 MAE 越小,表示方法的性能越好。基于贝叶斯更新方法和基于模型辨识方法的 HI 构建实验分别运行了 10 次。此外,由于在本文中 2 种方法估计的点数相同,所以

基于贝叶斯更新的 HI 构建方法 MAE 均值为 0.584 1,相比于传统基于模型辨识的 HI 构建方法减少了 10.1%。基于贝叶斯更新的 HI 构建方法 RMSE 均值为

0.791 3, 相比于传统基于模型辨识的 HI 构建方法减少了 10.6%。因此可以得出, 基于贝叶斯更新的 EMA HI 构建方法的性能优于传统基于模型辨识的 HI 构建方法。

3 结 论

本文研究了基于贝叶斯更新的 EMA HI 构建方法, 并采用 NASA 公开的 EMA 监测数据集对本文方法进行了实验验证。实验结果表明, 基于贝叶斯更新的 EMA HI 构建方法的 MAE 和 RMSE 指标均优于传统方法, 其 10 次实验的 MAE 均值和 RMSE 均值分别为 0.584 1 和 0.791 3, 相比于传统基于模型辨识的方法减少了 10.1% 和 10.6%。因此, 基于贝叶斯更新的 EMA HI 构建方法在变工况条件下对 EMA 的退化状态的表征性能优于传统基于模型辨识的方法。

但是, 本文没有充分考虑基于贝叶斯更新的 HI 构建方法在 EMA 健康管理系统中的实际应用, 而且仅研究了单退化模式下 EMA 的健康因子构建方法。在未来的研究中, 将重点关于基于贝叶斯更新的 HI 构建方法在 EMA 健康管理中的实际应用以及复合退化模式下的 EMA HI 构建方法研究。此外, 振动信号能够更直接地反映 EMA 工况变化情况, 基于振动信号的 EMA 变工况健康因子构建方法存在广泛的应用前景, 具有重要研究意义。因此, 基于振动信号的 EMA HI 构建是未来研究工作的重点之一。另一方面, 理论上更精确的 EMA 物理模型有助于提高本文提出方法的准确性和稳定性, 因此, 未来也将考虑研究基于精确物理模型的 EMA HI 构建方法。

参考文献

- [1] ROSERO J A, ORTEGA J A, ALDABAS E, et al. Moving towards a more electric aircraft [J]. IEEE Aerospace & Electronic Systems Magazine, 2007, 22(3): 3-9.
- [2] BALABAN E, SAXENA A, NARASIMHAN S, et al. Prognostic health-management system development for electromechanical actuators [J]. Journal of Aerospace Information Systems, 2015, 12(3): 329-344.
- [3] NARASIMHAN S, ROYCHOUDHURY I, BALABAN E, et al. Combining model-based and feature-driven diagnosis approaches-A case study on electromechanical actuators [C]. 21st International Workshop on Principles of Diagnosis, 2010: 1-8.
- [4] 彭宇, 刘大同. 数据驱动故障预测和健康管理综述 [J]. 仪器仪表学报, 2014, 35(3): 481-495.
PENG Y, LIU D T. Data-driven prognostics and health management: A review of recent advances [J]. Chinese Journal of Scientific Instrument, 2014, 35(3): 481-495.
- [5] PENG Y, ZHANG Y J, LIU D T, et al. Degradation estimation using feature increment stepwise linear regression for PWM inverter of electro-mechanical actuator [J]. Microelectronics Reliability, 2018, 88: 514-518.
- [6] ZHANG Y, LIU D, YU J, et al. EMA remaining useful life prediction with weighted bagging GPR algorithm [J]. Microelectronics Reliability, 2017, 75: 253-263.
- [7] BALABAN E, BANSAL P, STOELTING P, et al. A diagnostic approach for electro-mechanical actuators in aerospace systems [C]. 2009 IEEE Aerospace Conference, 2009: 3564-3576.
- [8] 谢文俊, 齐蓉, 肖蕾. 作动系统健康状况对飞行安全影响的评估方法 [J]. 计算机工程与应用, 2013, 49(15): 242-245.
XIE W J, QI R, XIAO L. Assessment methods of electromechanical actuation systems health situation impact on flight safety [J]. Computer Engineering and Applications, 2013, 49(15): 242-245.
- [9] 彭宇, 何永福, 王少军, 等. 飞行数据异常检测技术综述 [J]. 仪器仪表学报, 2019, 40(3): 1-13.
PENG Y, HE Y F, WANG SH J, et al. Flight data anomaly detection: A survey [J]. Chinese Journal of Scientific Instrument, 2019, 40(3): 1-13.
- [10] 刘大同, 郭凯, 王本宽, 等. 数字孪生技术综述与展望 [J]. 仪器仪表学报, 2018, 39(11): 1-10.
LIU D T, GUO K, WANG B K, et al. Summary and perspective survey on digital twin technology [J]. Chinese Journal of Scientific Instrument, 2018, 39(11): 1-10.
- [11] ZHANG H, MIAO Q, ZHANG X, et al. An improved unscented particle filter approach for lithium-ion battery remaining useful life prediction [J]. Microelectronics Reliability, 2018: 288-298.
- [12] SONG L Y, WANG H Q, CHEN P. Step-by-step fuzzy diagnosis method for equipment based on symptom extraction and trivalent logic fuzzy diagnosis theory [J]. IEEE Transactions on Fuzzy Systems, 2018, 26(6): 3467-3478.
- [13] NIU G, SINGH S, HOLLAND S W, et al. Health monitoring of electronic products based on Mahalanobis distance and Weibull decision metrics [J]. Microelectronics Reliability, 2011, 51(2): 279-284.
- [14] BYINGTON C S, WATSON M, EDWARDS D, et al. A model-based approach to prognostics and health management for flight control actuators [C]. Aerospace Conference, 2004 Proceedings, 2004: 3551-3562.

- [15] DOEBLING S W. Damage identification and health monitoring of structural and mechanical systems from changes in their vibration characteristics: A literature review[J]. Shock & Vibration Digest, 1996, 30(11): 2043-2049.
- [16] BYINGTON C S, WATSON M, EDWARDS D. Data-driven neural network methodology to remaining life predictions for aircraft actuator components [C]. Aerospace Conference, 2004 Proceedings, 2004: 3581-3589.
- [17] SIKORSKA J Z, HODKIEWICZ M, MA L. Prognostic modelling options for remaining useful life estimation by industry[J]. Mechanical Systems & Signal Processing, 2011, 25(5):1803-1836.
- [18] DI RITO G, GALATOLO R, SCHETTINI F. Experimental and simulation study of the dynamics of an electro-mechanical landing gear actuator [C]. 30th Congress of the International Council of the Aeronautical Sciences (ICAS). 2016: 1-10.
- [19] BALABAN E, SAXENA A, KAI G, et al. Experimental data collection and modeling for nominal and fault conditions on electro-mechanical actuators [C]. Annual Conference of the Prognostics and Health Management Society, 2009:1-15.
- [20] CHIRICO A J, KOLODZIEJ J R. A data-driven methodology for fault detection in electromechanical actuators[J]. Journal of Dynamic Systems Measurement & Control, 2014, 136(4): 041025.
- [21] TODESCHI M, BAXERRES L. Health monitoring for the flight control EMAs [J]. International Federation of Automatic Control, 2015, 48(21):186-193.
- [22] GOKDERE L U, CHIU S L, KELLER K J, et al. Lifetime control of electromechanical actuators [C]. IEEE Aerospace Conference, 2005: 3523-3531.
- [23] DE MARTIN A, JACAZIO G, VACHTSEVANOS G J. Windings fault detection and prognosis in electromechanical flight Control actuators operating in active-active configuration [J]. International Journal of Prognostics and Health Management, 2017, 8: 1-13.
- [24] 卢晓慧. 机电作动器中永磁容错电机设计与控制系统研究[D]. 长沙:国防科学技术大学, 2012.
LU X H. Research on Fault Tolerant Permanent Magnet Motor and its Control System in Electromechanical Actuator[D]. Changsha: National University of Defense Technology, 2012
- [25] SRIDHAR R, KOLODZIEJ J R, HALL L. Bearing fault detection in electromechanical actuators from empirically extracted features [C]. AIAA Atmospheric Flight Mechanics (AFM) Conference, 2013: 1-17.
- [26] ZHANG Y J, LIU L SH, PENG Y, et al. An electro-mechanical actuator motor voltage estimation method with a feature-aided Kalman filter [J]. Sensors, 2018, 18(12): 1-15.
- [27] ENRIGHT M P, DAN M F. Condition prediction of deteriorating concrete bridges using bayesian updating [J]. Journal of Structural Engineering, 1999, 127(5): 1118-1125.
- [28] LIAO H T, TIAN ZH G. A framework for predicting the remaining useful life of a single unit under time-varying operating conditions [J]. IIE Transactions, 2013, 45(9): 964-980.
- [29] BECK J L, MUTO M M. Bayesian updating and model class selection for hysteretic structural models using stochastic simulation[J]. Journal of Vibration & Control, 2008, 14(1/2): 7-34.

作者简介



张玉杰,2010年于哈尔滨工业大学(威海)获得学士学位,现为哈尔滨工业大学博士研究生,主要研究方向为故障预测与健康管理、状态监测、数据驱动的退化建模方法等。

E-mail: hnhzyj1h@hit.edu.cn

Zhang Yujie received his B.Sc degree in 2010 from Harbin Institute of Technology at Weihai. He is currently a Ph. D. candidate in Harbin Institute of Technology. His research interest includes prognostics and health management, condition monitoring, data-driven degradation modeling method and etc.



彭宇(通信作者),2004年于哈尔滨工业大学获得博士学位,现为哈尔滨工业大学教授、博士生导师,主要研究方向为虚拟仪器和自动测试、故障预测与健康管理和可重构计算等。

E-mail: pengyu@hit.edu.cn

Peng Yu (Corresponding author) received his Ph. D. from Harbin Institute of Technology in 2004. He is currently a professor and Ph. D. supervisor in Harbin Institute of Technology. His main research interest includes virtual instruments and automatic test technologies, prognostics and health management, reconfigurable computing and etc.