

DOI: 10.19650/j.cnki.cjsi.J2209678

机电系统健康状态预测和维修决策的双向优化方法*

梁思远¹, 周金滢¹, 高占宝¹, 于劲松^{1,3}, 宋悦¹, 张健^{2,3}

(1. 北京航空航天大学自动化科学与电气工程学院 北京 100191; 2. 北京信息科技大学经济管理学院 北京 100192;
3. 绿色发展大数据决策北京市重点实验室 北京 100192)

摘要:在以机电系统为代表的复杂装备健康管理的应用场景中,健康状态预测与维修决策操作依赖于装备的健康状态演化进程,二者在所依赖的知识上具有明显的耦合性,对应的二元知识也因此具有双向融合的价值。本文从健康状态评估与维修排故二元知识的双向融合出发,提出一种面向机电系统的健康状态预测和维修决策双向优化方法,即定期利用该阶段积累的有限运行记录,在该阶段的健康状态预测和即时维修决策模型上做出优化。最后,本文基于实际机电系统中天线调平系统的仿真实验对本文所提的双向优化方法进行了验证,健康状态预测误差稳定降低到0.002%,维修决策收益稳定提升到93.57,验证了本文提出的健康状态预测与维修决策协同方法的有效性。

关键词: 复杂系统;健康管理;健康状态预测;维修决策;双向优化

中图分类号: TH707 **文献标识码:** A **国家标准学科分类代码:** 510.4

Bi-directional optimization method for health state prediction and maintenance decision-making of electromechanical systems

Liang Siyuan¹, Zhou Jinhan¹, Gao Zhanbao¹, Yu Jinsong^{1,3}, Song Yue¹, Zhang Jian^{2,3}

(1. School of Automation Science and Electrical Engineering, Beihang University, Beijing 100191, China;
2. School of Economics and Management, Beijing Information Science and Technology University, Beijing 100192, China;
3. Laboratory of Big Data Decision making for Green Development, Beijing 100192, China)

Abstract: In the application scenario of the actual health management for complex equipment health managements, represented by electromechanical systems, health perception and maintenance decision-making depend on the mined evolution mechanism of state of health. Both of them show an obvious coupling on their base knowledge whiling operating. The corresponding binary knowledge has the value of bi-directional fusion. Inspired by the bi-directional fusion of fault detection-maintenance binary knowledge, this article proposes a bi-directional optimization method of health perception and maintenance decision-making for electromechanical systems to regularly take advantage of the limited operation records accumulated in one period to optimize the previous health perception and maintenance decision-making model. Finally, the proposed bi-directional optimization method is evaluated by using the simulation experiment of the antenna leveling system in the actual electromechanical system, where the health prediction error is reduced to 0.002%. The maintenance decision-making benefit is increased to 93.57, which verifies the effectiveness of the proposed collaborative method of health state prediction and maintenance decision-making.

Keywords: complex system; health management; health state prediction; maintenance decision-making; bi-directional optimization

0 引言

随着系统功能需求复杂化、运行场景多元化,以机电

系统为代表的复杂系统运行机理分析越发困难,可能发生的故障类型越发丰富,系统健康状态与维修间的映射关系也越发复杂^[1],相同规模历史记录在健康状态演化与维修决策方面所能够表征的支撑知识也因此越发有

限,传统的检测、预测、维修决策机制已不再能有效实现对系统的可靠管理;同时,与采购费用和使用保障(operating and support, O&S)的固定成本相比,机电系统等复杂系统的维修保障费用则在技术上表现出更明显的可压缩性^[2]。因此,聚焦于健康状态预测和维修决策等可靠性核心问题的故障预测与健康管(health management, PHM)技术则逐渐成为了保障复杂系统运行可靠性与经济性的关键。

从20世纪70年代开始,故障预测与健康管(health management, PHM)技术^[3]的发展日益成熟,并在实际工程应用中逐渐成为诸多复杂系统正常运行的重要保障。以机电系统为例:在健康状态预测方面,文献[4]基于贝叶斯更新算法构建了能够描述机电作动器性能退化的健康因子指标;文献[5]结合模糊集理论改进实现了机电作动器故障溯源的动态故障树模型;文献[6]则通过改进的经验模态分解(empirical mode decomposition, EMD)功率谱分析提取了机电作动系统的早期故障特征。而在决策维修方面,文献[7]文献从可靠性为中心的维修(reliability centered maintenance, RCM)理论出发,在故障(失效)模式与效应分析(failure mode and effects analysis, FMEA)的基础上实现了通用的多元维修管理方法;文献[8]基于层次分析法(analytic hierarchy process, AHP)构建了支持智能维修决策的维修费效模型;文献[9]借助强化学习架构提出了基于自适应学习的自主维修决策代理机理。

然而,上述研究成果仍存在对完备专家经验的依赖性强、对于未知工作状况的迁移性弱等缺陷。而在实际工程应用中,为实现对于系统状态的分析,需要运用检测机制;进一步地,为实现对于系统状态的预测,需要运用基于检测机制的分析结果对于系统状态演化建立预测机制;在维修过程中,需要根据检测分析与预测结果选择必要维修操作的决策机制;最后,在执行维修操作后,系统状态也会根据选择的维修操作发生变化,从而在检测机制中体现出来。由于上述步骤间的高耦合性,检测、预测、维修决策中任意机制的变化,将会以输入的形式影响到其他的机制,最终影响到发生变化的机制自身,造成交叉的影响。专家经验难以有效感知变化带来的交叉影响、无法对现有机理进行有效的优化;传统数据驱动模式下的优化方法则一般仅基于检测、预测、维修决策等机制所直接相关的单类型知识,忽略了其他类型知识中能够反映交叉变化来源的相关信息,导致优化涉及的范围过大、使得推理机制难以维持对于部分已知场景的适应度。现有研究成果的缺陷因此在交叉变化的运行场景下得以显现,严重限制它们的实际应用效果。因此,如何更为有效地利用多来源知识、构建一种面向实际工作场景中交叉变

化的溯源性修正机制,是实现故障预测或维修决策等机制与实际工作场景同步优化、解决现有研究应用瓶颈的关键问题之一。

要解决该问题,必须充分研究健康管理技术内部检测、预测、维修决策等各具体机制之间知识的内在相关性,通过多元知识间的交叉实现不同具体机制间的多向优化。

健康状态预测与维修决策则是上述问题的两个典型对象。健康状态预测^[10]是指基于已知各检测器得到的各组件健康状态预测后续的故障演化趋势,维修决策^[11]则是指根据即时评估出的各组件健康状态、决定维修操作的实施与否及具体步骤,健康状态预测所提供的健康状态演化机理为维修操作提供了费效评估的依据,维修结果则为健康状态预测提供了各故障间发生的因果性。因此,健康状态预测与维修决策两者具有密切的关联性。与现有研究假设不同的是,实际应用中,提供给健康状态预测的样本往往聚焦于现有维修决策下所常见的运行场景,而维修决策的改变会为健康状态预测动态引入未知场景(即维修决策会使得部分故障的维修时机变化,导致系统在决策机制调整后进入新的状态,在参数层面出现新的表征),一定程度上导致健康状态预测机制的局部失效;而维修决策解决的也不局限于对于理想的单故障系统进行维修,即实际工程场景下很可能经常存在多个相关或无关故障同时发生的情况,更需要考虑多故障可能的实际运行场景下、各类型维修的时机,需要挖掘各故障在演化及传播上的关联关系,而该类关系也将是健康状态预测内部机理的重要部分。

事实上,健康状态预测和维修决策的知识在上述动态影响的过程中是紧密耦合的:关联故障往往具有并发性与维修耦合性等特征,可以通过维修操作记录进行挖掘;而健康状态预测则为维修操作明确了系统健康演化机理,为实时维修时机的权衡提供了重要依据。因此,在健康状态预测和维修决策各自的动态优化机理中融合彼此的知识,对于稳定提升两者的性能具有重要价值。

本文聚焦于健康状态预测与维修决策这两个健康管理的核心步骤,针对于故障检测记录和维修操作记录这两类历史记录,提出基于两类历史记录交叉的健康状态预测和维修决策双向优化方法,挖掘历史记录中蕴含的可交互信息,拓展优化所依赖的知识来源,进而针对实际工程特征,基于各交叉优化周期内有限运行场景下的历史运行记录,定期对健康状态预测和维修决策机理进行双向优化,从而提高故障趋势预测的准确性与维修决策的费效收益。

1 机电系统健康状态演化机理与维修过程的基本假设与应用

1.1 机电系统健康状态演化机理与维修过程的形式化表述

为了方便地描述机电系统的健康状态演化机理与维修过程,有必要首先将机电系统健康状态演化机理与维修过程所涉及的概念形式化。而考虑到部件的健康状态在实际工程中一般通过故障程度进行定义,本文因此也将直接采用故障程度指标来表述部件的健康状态。本文采用如下的形式化表述进行后续描述:

1) 单纯异常指征 $\hat{A}(i)$, 部件在健康状态演化过程中连续变化的故障程度指标。

单纯异常指征不考虑部件间的故障传播影响,是部件本身内秉的健康状态演化指标。单纯异常指征的取值范围在 0~1。其中,0 代表该部件本身完全健康,1 代表该部件本身彻底失效。

2) 复合异常指征 $A^{(i)}$, 部件在考虑部件间故障传播影响下的实际故障程度指标。

复合异常指征与单纯异常指征一样,取值范围也在 0~1 之间。其中,0 和 1 仍然分别代表该部件的实际运行状态完全健康和彻底失效。若某部件与其他部件的故障间不存在传播关系,则该部件的复合异常指征与单纯异常指征相等。

3) 观测异常指征 $A_d^{(i)}$, 实际健康状态评估模块衡量体系下部件表征出的故障程度。

观测异常指征仍然与单纯异常指征一样,取值范围仍然在 0~1 之间。其中,0 和 1 分别代表该部件被判别为完全健康和彻底失效状态。观测异常指征和复合异常指征间存在两个方面的主要差异:1) 观测异常指征存在误差,误差程度主要通过虚警率和漏检率两个指标衡量^[12-13],分别对应正向偏差和负向偏差;2) 观测异常指征的灵敏度有限,一般在故障初期对轻微故障的感知不灵敏,而在故障末期对于明显故障判别则又过快趋于彻底失效状态,相较于实际的复合异常指征而言演化趋势得更为陡峭。

观测异常指征可以直接与故障诊断模块中常用的异常分数相对应。以基于专家阈值门限的单参数故障诊断为例,单参数趋势波形距门限距离与门限宽度的比值则可视作该检测模型所得的观测异常指标。

所有观测异常指征组成的矢量 A_d , 即为当前系统各部件整体的观测异常指征指标。

4) 异常指征演化矩阵 P 与演化偏差 b , 预测健康演化趋势的参数。

部件故障在考虑部件故障间传播^[14]的情况下,基于当前各部件健康状态的观测异常指征矢量 A_d 预测的下一帧观测异常指征矢量 A_d^* :

$$A_d^*(t + \Delta t) = PA_d(t) + b \quad (1)$$

式中: Δt 为检测采样时间间隔, P 为待估计的观测异常指征演化矩阵, b 为待估计的演化偏差。式(1)描述了观测异常指征的演化过程,对应机电系统实际的健康状态演化过程,称为观测异常指征演化方程。

5) 维修质量指标 Q , 每次维修的净收益指标^[15]。

部件的维修操作在优化部件运行状态的同时,也会因为系统暂停运行与维修本身的人力物力费用直接或间接引入一定的额外成本。因此,维修质量指标需要统筹实际的费效比。

本文采用维修费效收益指标定义来实现对维修质量的评估:

$$Q = 1 - \alpha \left(\frac{C}{C_0} \right)^\beta - (1 - \alpha) \frac{1}{T_m} \int_0^{T_m} \frac{\sum_i (\max(0, \hat{A}_i - A_c))^\beta}{N_a (1 - A_c)^2} dt \quad (2)$$

式中: C 是综合系统暂停运行与维修本身的人力物力费用等方面而评估出的额外成本; C_0 是最大额外成本; T_m 是系统开启(即 0 时刻)至维修停机时间的系统运行时间; A_c 是部件异常衡量指标,用来人为划分部件正常状态; α 为成本偏好权重,取值范围在 0 ~ 1 之间, α 为 0 则只衡量系统整体的运行故障程度, α 为 1 则只衡量维修带来的额外成本; β 为指标对比程度, β 越大,指标对于成本和运行状态的优劣评判差异越明显。

6) 维修决策矢量 S , 各维修操作在当前情况下的净收益指标组成的矢量。

维修操作的净收益指标是维修决策的主要辅助标准,决策时可以先筛选出净收益大于维修净收益阈值 S_c 的操作,再按净收益从高到低进行贯序维修。

1.2 机电系统健康状态演化机理的基本假设

机电系统的故障机理虽然在理论上复杂多样,但在实际表征中可以归纳出一定的统计学表征。本文所采用的基本假设如下:

1) 单纯部件的健康状态演化过程属于 Gamma 过程。

单纯部件健康状态演化过程属于 Gamma 过程,即单纯异常指征随时间的增量满足 Gamma 分布^[16]:

$$\Delta \hat{A}(t) = \hat{A}(t + \Delta t) - \hat{A}(t) \sim \text{Ga}(\alpha, \beta) \quad (3)$$

式中: $\hat{A}(t)$ 为某部件在对应时刻下的单纯异常指征, $\text{Ga}(\alpha, \beta)$ 为满足形状参数为 α 、尺度参数为 β 的 Gamma 分布, 其概率密度函数为:

$$f_{\gamma}(x) = \frac{\beta^{\alpha}}{\int_0^{\infty} \omega^{\alpha-1} e^{-\omega} d\omega} x^{\alpha-1} e^{-\beta x} \quad (4)$$

在可靠性理论中, 指数分布、Gamma 分布、Weibull 分布、对数正态分布是最为常用的故障概率模型。与其他概率不同, Gamma 分布具有可加性, 即: 在某采样频率下满足 Gamma 过程的单纯部件健康状态演化过程在其他采样频率下仍然满足 Gamma 过程。这一特性则充分满足电气元件等组件的趋势性故障演化过程, 可作为反映故障演化连续且量化的单纯异常指征^[17]。

同时, 由 Gamma 分布特征^[18] 还可以推出健康状态演化过程速率均值为 $\mu = \frac{\alpha}{\beta}$ 、方差为 $\sigma^2 = \frac{\alpha}{\beta^2}$, 有助于结合实际系统特征实现对于各具体部件本身的健康演化模型进行形式化建模。

2) 部件间的故障传播关系在复合异常指征上满足乘性关系。

本文所研究的部件间故障传播关系在复合异常指征上满足乘性关系。若某一部件的健康状态(记异常指征为 \hat{A}_i) 由于与其他部件间存在故障传播关系而受到其他部件健康状态(记复合异常指征组成的集合为 $\{A_j\}_j$) 的影响, 复合后的实际影响效果按所涉及部件故障对该部件的影响程度(记为 $\{w_j\}_j$) 加权后满足加性关系, 则该部件的复合实际异常指征满足:

$$\frac{d}{dt} A_i(t + \Delta t) = \left(\sum_j w_j A_j(t) \right) \frac{d}{dt} \hat{A}_i(t) \quad (5)$$

近似离散化则有:

$$A_i(t + \Delta t) = \max\left(0, A_i(t) + \left(\sum_j w_j A_j(t) \right) \Delta \hat{A}_i(t) + \frac{1}{2} \left(\sum_j w_j \Delta A_j(t) \right) \Delta \hat{A}_i(t) \right) \quad (6)$$

式中: 对应部件内乘的单纯异常指征增量 $\Delta \hat{A}_i$ 与 ΔA_j 仍然满足独立的 Gamma 分布, 具有与时间无关的稳定均值。因此, 该部件的复合实际异常指征可以通过包含该部件在内的复合实际异常指征的仿射线性运算进行估计, 进而也可以间接验证部件观测异常指征演化方程的合理性。

1.3 机电系统维修过程的基本假设

机电系统的维修过程一般可以拆分为针对于具体故障的维修操作单元, 即每一维修操作单元是能够消除当前故障的最少操作集合。本文所述的维修过程则在维修操作单元的基础上, 提出以下假设:

1) 维修过程是维修操作单元的贯序实现过程^[19]。

维修过程中, 维修操作单元一般是按照一定顺序逐

个完成的。对于维修操作单元的选取与排序则是维修决策的两个重要研究对象。

2) 维修操作单元的目的是实现故障的稳定修复。

实际工程中, 维修操作单元并不是单纯以降低对应故障的异常指征为全部目的, 更多地是需要将对应故障部件调整到可以稳定正常运行的状态, 即部件在维修后短时间内的异常指征演化趋势也应该保持在一个期望值较平缓的水平。

3) 维修操作单元可能涉及传播相关故障的修复。

实际的机电系统故障间往往存在耦合性, 针对于某一故障的维修操作也同样会使得其他相关故障得到修复。具体而言, 由故障传播假设可知, 在不修复涉及关键性传播相关故障的情况下, 由于乘性关系, 当前故障修复仍然不稳定; 因此, 要真正实现稳定的故障修复, 也需要对于关键的传播相关故障有相对应的维修。当然, 就维修操作单元本身的目的而言, 对于部分相关故障所引入的维修操作单元, 其维修程度不一定需要到达完全修复的水平, 只需要达到不影响目标故障稳定修复的水平即可。维修操作单元与传播相关故障的具体映射关系一般较难准确获取。

例如, 作动器轴承严重磨损后应当更换新轴承, 此时如果原轴承还被健康状态预测到润滑不充分等故障, 则不需要再对于新更换的轴承再进行润滑操作。

2 机电系统健康状态预测与维修决策的双向优化方法

机电系统健康状态预测与维修决策的双向优化方法主要针对于故障预测与健康管理系统中健康状态预测与维修决策两个功能模块。如图 1 所示, 在机电系统运行阶段, 两个功能模块分别对应于故障演化预测与维修贯序决策的角色: 专家阈值门限等故障检测模型会将定量的故障异常指标分别提供给健康状态预测与维修决策模块, 由健康状态预测模块感知故障演化趋势、预测未来故障异常指征, 由维修决策模块决策当前维修与否, 并在有维修必要的情况下提供具体的维修顺序。

而在每运行一阶段时间后, 健康状态预测与维修决策则开始根据累积的记录进行双向优化: 健康状态预测机制根据维修操作记录挖掘到的因果关系来定性筛选出可能的故障间转移关系, 从而在由不同维修策略引入的新运行场景下缩小待优化范围, 并进一步通过运行记录定量优化健康状态预测机制; 而维修决策机理结合健康状态预测机制中对执行特定维修决策后对效果的预估和维修操作记录中的维修操作实际效果, 来支撑维修决策中对于维修顺序的决策, 从而打破常规停机检测维修的局限性背景, 补充维修决策的时机决策能力, 实现从连续运行的实际背景出发的长远维修决策机理。

率的差异性。该系数满足:

$$r_{ij} = \begin{cases} 0, & i = j \\ 1, & (i, j) \text{ 为直接维修相关性} \\ 1/\delta_r, & (i, j) \text{ 为间接维修相关性} \\ 1/\delta_r^2, & (i, j) \text{ 为潜在传播相关性} \end{cases} \quad (8)$$

式中: δ_r 为优化速率差异程度, δ_r 越大, 不同影响相关性的优化差异性就越大。

在梯度的有偏更新下, 健康演化感知机理会重点优化相关信息置信度高且维修层面重要性高的相关感知参数; 同时最大程度迟滞置信度低的信息对于当前健康状态预测机制更新的负面干扰, 从而使重要性较低的相关性信息随着更新的迭代只保留稳定的有效相关性信息。

同时, 有偏优化的健康状态预测机制融入了维修策略对于健康状态演化的感知需求, 也为维修策略的实时决策与动态优化更稳定地提供最宝贵的信息, 间接提高维修决策优化的稳定性和有效性。

2.2 基于健康状态预测机制的维修决策优化方法

故障维修决策方法一般转化为对于各维修操作收益的即时衡量问题。在得到可靠的衡量指标后, 维修决策再根据阈值筛选需要采取的维修操作, 并按照指标从高到低的顺序对于系统进行贯序维修。

传统的故障维修决策方法一般局限于对于维修即时费效比的优化上^[21]。然而, 实际系统的运行是一个长期的过程, 维修决策更应该对于维修后系统的运行状态和可能的额外费用做出一定的估计^[9]。而健康状态预测机制则使得维修决策能够通过观测异常指征演化方程评估后续的运行状态, 不再强制依赖于实际操作结果来衡量维修操作带来的长期收益; 并能够直接评估有无维修操作所带来的不同收益, 进而实现对于维修时机的权衡。

具体而言, 针对于具体部件故障 i , 在被维修的情况下, 根据贝尔曼方程 (Bellman equation)^[22], 其维修收益定义为:

$$S^{*(i)} = \gamma S^{(i)} + (1 - \gamma) \mathcal{M}^{(i)}(\mathbf{P}\mathbf{A}_d + \mathbf{b}) \quad (9)$$

式中: S^* 为综合维修收益, S 为实际维修净收益, γ 为后期效果偏好权重, \mathcal{M} 为维修净收益衡量函数, \mathbf{A}_d 为维修完成后的观测异常指征矢量。 γ 越大, 维修收益对于维修后系统运行效果的考虑就越多; γ 越小, 维修收益就越集中于对于维修操作本身费效比的评估。

而在未被维修的情况下, 其维修收益则为:

$$S^{*(i)} = \gamma(\mathcal{M}^{(i)}(\mathbf{A}_d) - \varepsilon) + (1 - \gamma)(1 - \mathcal{M}^{(i)}(\mathbf{P}\mathbf{A}_d + \mathbf{b})) \quad (10)$$

式中: \mathbf{A}_d 为未采取维修操作情况下的观测异常指征矢量, 其余定义与式(9)一致。由于 S^* 衡量的是维修操作带来的综合维修收益, 因此在未采取维修操作的后续收益则应与执行维修操作的后续收益互补, 而实际维修净

收益矢量则通过 \mathcal{M} 为维修净收益衡量函数进行估计, 并减去一定的收益 ε 以鼓励尽可能不采取维修行动。

通过健康状态预测机制, 故障后续的演化趋势可以逐步纳入到决策时维修费效比的评估中。纳入故障后续的演化趋势不仅可以在执行维修操作前得知该维修操作对系统状态造成的影响; 还可将原始满足 Gamma 过程的健康状态演化趋势改为鲁棒性好的演化期望预测, 更适合维修数据有限的实际工程情况。

与传统维修决策方法不同的是, 该策略不依赖于单故障假设、完美检测、固定成本等常见前提, 对于维修后续收益的感知也不强依赖于实际测试结果, 在实际工程中有更好的通用性。

此外, 维修净收益衡量函数 \mathcal{M} 的选择与该优化方案无依赖关系, 可以兼容常见的诸如贝叶斯网络、深度神经网络、Q-Learning 奖惩关系表等常见方法。本文则基于简单的双层网络结构, 将维修净收益衡量函数 \mathcal{M} 则定义为:

$$\mathcal{M}(\mathbf{A}) = \text{Sigmoid}(\mathbf{M}_2 \text{Relu}(\mathbf{M}_1 \mathbf{A} + \mathbf{b}_1) + \mathbf{b}_2) \quad (11)$$

式中: $\mathbf{M}_1 \in \mathbb{R}^{N \times M}$ 为初步的收益评估矩阵, $\mathbf{b}_1 \in \mathbb{R}^{1 \times M}$ 为初步的收益评估偏差, $\mathbf{M}_2 \in \mathbb{R}^{M \times M}$ 为收益调整矩阵, $\mathbf{b}_2 \in \mathbb{R}^{1 \times M}$ 为收益调整偏差。

对于维修净收益衡量函数 \mathcal{M} 的优化, 则通过上述基于贝尔曼方程的维修操作费效比为目标指标, 选取传统的梯度下降方法作为具体优化方法。

3 实验结果

3.1 实验设置

由于本文所提出的机电系统健康状态预测和维修决策的双向优化方法面向于实际工程中某步骤优化操作对健康状态感知、维修顺序决策等不同步骤后续工作场景的影响, 因此运行记录、维修记录等数据在优化后还由于工作场景的变化而不同。现有数据集并不能够体现上述的运行环境变化等动态因素, 因此只能结合第1节对健康状态预测与维修决策的相关假设, 通过对实际系统的故障-维修机理进行机理建模, 将该模型作为所需数据的仿真生成环境进行验证。

本文实验采用某机电驱动天线调平系统的故障-维修模型^[23]进行验证。以下对于实际实验中故障-维修模型的具体故障信息与维修信息进行具体说明。需要注意的是, 具体部件故障信息与维修信息只为天线调平系统故障传播-维修过程的仿真提供依据, 对于实际健康状态预测与维修决策方法则属于未知信息。

该系统的实际故障信息如表1所示。表中, 各部件故障对应的精确率和召回率反应了故障对应检测器的漏警情况和虚警情况, 精确率越高则漏检率越低, 召回率越高则虚警率越低; 故障概率反应部件本身发生故障的实

际概率,与检测器无关;故障原因则代表了导致该部件故障的故障来源,以部件故障的序号表示各部件的故障来源;传播权重则对应各部件故障来源对于该部件健康状

态演化趋势的具体影响程度。由于根故障在传播关系中不具有能作为来源的故障,因此不具有故障原因和传播权重,以“--”代表。

表 1 某天线调平系统的实际故障信息

Table 1 Real fault information of the chosen antenna levelling system

故障序号	故障名称	精确率	召回率	故障概率	故障原因	传播权重
1	天线座车无法架设	0.90	0.95	0.146	2,3	0.3,0.7
2	仿生臂伸展不到位	0.90	0.95	0.044	5,6	0.5,0.5
3	撑腿不能完全着地	0.90	0.95	0.102	4,6,7,8	0.3,0.3,0.2,0.2
4	撑腿电机故障	0.95	0.98	0.044	16	1.0
5	仿生臂电机故障	0.95	0.97	0.031	16,17,18	0.4,0.3,0.3
6	架设控制箱故障	1.00	1.00	0.150	11,12,13,14	0.3,0.2,0.2,0.3
7	减速机咬死	0.92	0.96	0.029	-	-
8	丝杆传统装置卡死	0.93	0.96	0.029	-	-
9	接近开关故障	0.92	0.97	0.009	-	-
10	接近开关监测偏差	0.93	0.97	0.007	9	1.0
11	机箱故障	1.00	1.00	0.049	-	-
12	机箱易受电磁干扰	0.93	0.96	0.012	19	1.0
13	机箱抗环境能力差	0.92	0.97	0.012	21	1.0
14	PLC 控制失效	1.00	1.00	0.037	10,11,15	0.4,0.3,0.3
15	低压电源故障	0.95	0.97	0.041	-	-
16	驱动器故障	0.93	0.98	0.023	20	1.0
17	接触器故障	0.95	0.97	0.007	-	-
18	继电器故障	0.95	0.97	0.007	-	-
19	整流器故障	0.95	0.98	0.018	22	1.0
20	开关电源故障	0.95	0.97	0.023	-	-
21	空气保护开关失效	0.95	0.97	0.023	-	-
22	滤波器故障	0.95	0.98	0.018	-	-

实际维修信息如表 2 所示。表中,维修最大费用体现部件在完全失效状态下的维修费用;修后异常故障异常指征体现部件在维修后对应测试项的残余故障程度;维修相关故障则代表该维修单元涉及的其他部件故障,修后相关故障异常指征则反映了涉及其他部件在该维修单元完成后的残余故障程度。

在机理建模方面,实验基于健康状态演化机理与维修过程假设,建立基于 Gamma 过程的多部件实际异常指征演化模型以及基于实时检测异常指征的即时维修决策模型,其中:Gamma 过程的各参数由部件的故障概率决定;检测误差则满足正态分布,参数由精确率和召回率联合决定。仿真共进行 10 轮,每轮仿真完毕,都根据故障检测记录和维修操作记录优化健康状态预测和维修决策机理,每轮优化 10 次。

健康状态预测方面,实验采用单位矩阵初始化部件间的故障传播有向图矩阵,用零矢量初始各部件的故障偏离值。基于梯度下降的优化过程中,优化速率差异程度 δ_i 取 1.5,学习率取 0.002。

维修决策方面,本实验取后期效果偏好权重 γ 为 0.9,成本偏好权重 α 为 0.45,部件异常衡量指标 A_c 为 0.25,指标对比程度 β 为 0.75,并采用单位矩阵初始化故障传播有向图矩阵,用零矢量初始各故障偏离值。基于梯度下降的优化过程中,学习率仍取 0.002。

3.2 验证策略

由于本文所提出的机电系统健康状态预测和维修决策的双向优化方法是面向的是实际工程中应用场景和优化操作交叉影响的动态场景,而不是传统研究中工作场景不随优化机制而变化的理想静态工作场景,因此当前

表2 某天线调平系统的实际维修信息

Table 2 Real maintenance information of the chosen antenna levelling system

名称	维修主要故障	维修最大费用	修后主要故障异常指征	维修相关故障	修后相关故障异常指征
天线座车重架设	1	810	0.01	2,3	0.05,0.02
仿生臂伸展功能修复	2	810	0.01	5,6	0.03,0.03
撑腿着地功能修复	3	360	0.04	6,7,8	0.21,0.24,0.25
撑腿电机修复	4	360	0.04	16	0.04
仿生臂电机修复	5	360	0.04	16,17,18	0.06,0.24,0.25
架设控制箱修复	6	250	0.05	11,12,13,14	0.32,0.32,0.3,0.3
减速机修复	7	250	0.05	-	-
丝杆传统装置修复	8	160	0.06	-	-
接近开关修复	9	160	0.06	-	-
接近开关监测校准	10	490	0.03	9	0.03
机箱修复	11	640	0.02	-	-
机箱抗电磁修复	12	640	0.02	19	0.02
机箱隔离层加固	13	810	0.01	21	0.02
PLC 更换	14	810	0.01	10,11,15	0.02,0.03,0.03
低压电源修复	15	810	0.01	-	-
驱动器修复	16	490	0.03	20	0.03
接触器修复	17	810	0.01	-	-
继电器修复	18	490	0.03	-	-
整流器修复	19	810	0.01	22	0.01
开关电源故障	20	810	0.01	-	-
空气保护开关失效	21	490	0.03	-	-
滤波器故障	22	640	0.02	-	-

研究对于该问题的研究较为空白,基本不具备与该场景相适应的对比方法,因此,本实验基于下述的两种衡量指标,量化验证该优化策略对预测精确度和维修费效比带来的提升,以证明该双向优化方法的有效性。

为了直观地评价健康状态感知与维修决策动态优化的效果。本文分别用健康状态预测误差与维修费效收益指标两项指标进行评估。健康状态预测误差定义为:

$$L = 0.2 \| Y_0 - (PX_0 + b) \|_2 + 0.8 \| Y_{act} - (PX_{act} + b) \|_2 \quad (12)$$

式中: (X_0, Y_0) 为第一轮优化的输入输出样本, (X_{act}, Y_{act}) 为当前训练轮的输入输出样本。考虑到后几轮的优质维修,第一轮仿真结果的异常指征跨度一般最为丰富,二者的加权平均即要求算法衡量即在满足异常指征全值域的普适性外,同时也要求对于新维修背景下的局部健康状态预测能力有更强的精确度。而维修决策效果的指标则通过式(2)定义的维修费效收益指标进行衡量。

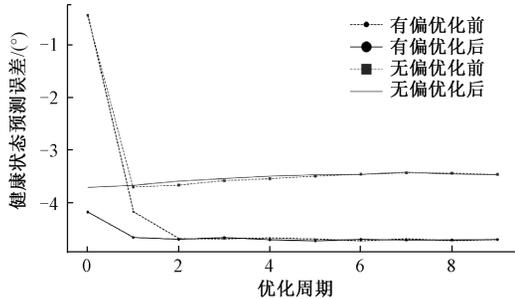
对于仿真实验得到的健康状态预测和维修决策优化结果,本文将选取式(12)中定义的健康状态预测误差与式(2)中动态的维修质量指标作为衡量指标,并对各指标的演化机理给出深入的分析。

3.3 结果分析

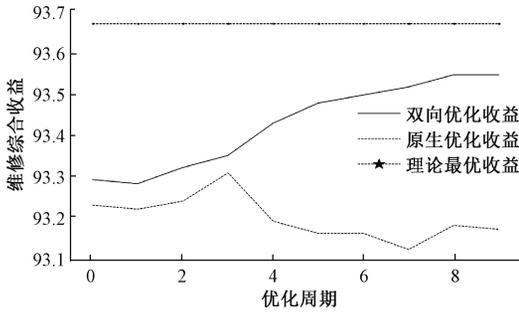
为了直观地体现双向优化方法的优势,实验分别为健康状态预测与维修决策设置了参照对象:针对于健康状态预测,实验载入了传统无偏梯度优化方法;针对于维修决策,实验在对照决策方法中注入了完整的部件间故障传播途径,并按维修的依赖性顺序对于部件故障采取贯序维修,该策略要求的条件虽然在实际中很难达到,但却为维修决策提供了理论最优的收益标准,因此将该策略多次实验下取得的平均收益记为参考收益。

健康状态预测与维修决策的双向优化方法的实验结果如图2所示。在本文提出的健康状态预测与维修决策的双向优化方法下,相较于不采取根据维修记录进行定性分析的无偏预测优化方法和不加入预测机理的原生维修优化方法而言,具有较好的有效性和收敛性。具体而言,本文提出的双向优化方法在健康状态预测方面更好适应了实际工程中由于维修决策调整而导致的运行场景变动,因此不仅能通过三轮优化周期到0.002% (较初始误差低3个数量级的误差水平),也能在后续优化周期中弱化维修机制调整引入的交叉影响,将健康状态预测误

差持续稳定在该水平;而该方法在维修顺序决策方面,则通过融入预测知识而更好对未来收益进行了衡量,因此随着预测机理的准确性上升和维修样本的逐渐丰富,优化后的收益也稳定地向输入完整故障演化机理后得到的理论最优收益趋近。



(a) 健康状态预测误差
(a) Health trend perception error



(b) 维修综合收益
(b) Comprehensive income from maintenance

图 2 健康状态预测与维修决策双向优化的实验结果

Fig. 2 Result of the experiment of the proposed bi-directional optimization method of health trend perception and maintenance decision-making

同时,在双向优化方法下,健康状态预测和维修决策在各自功能实现上仍有具体的个性优势。下面就健康状态预测和维修决策对于实验结果进行更深入地分析。

1) 健康状态预测优化结果分析

实际检测过程中,检测异常指征存在一定程度的噪声,使得梯度受到的扰动增大;尤其是当检测异常指征较小时,无关的部件故障噪声往往会对于梯度下降造成较大的干扰。本方法提出的差异化梯度下降方法则通过梯度加权无关较好地削弱了噪声对于传播模型增强训练的消极影响。

如图 3 所示,黑色折线代表各故障异常分数预测的平均预测偏差,灰色区域则代表基于正态分布得到的预测偏差基本分布范围(正负三倍标准差之内)。由此可知,利用优化后的部件间故障传播趋势感知机理预测 5 帧后的异常指征,并将预测结果与检测结果融合,则可以在检测噪声存在的背景下预测偏差基本稳定在 ± 0.1 间;考虑到原有观测异常指征本身包含的随机性观测噪

声,该偏差范围符合实际工程中健康状态预测准确性和鲁棒性的需求。

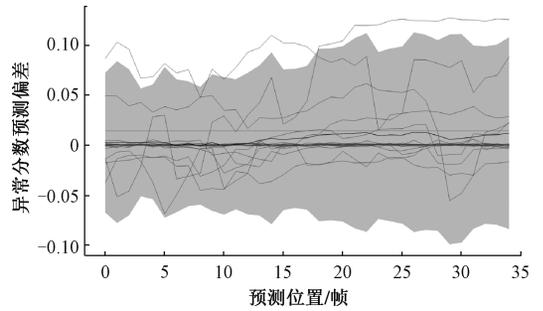


图 3 基于故障趋势感知的异常指征预测结果
Fig. 3 Result of anomaly score prediction based on fault trend perception

2) 维修决策优化结果分析

维修决策优化方法借助于健康状态预测机制将下一步的维修可能收益纳入到维修操作的综合收益评估中,更合理地提前维修操作,从而压缩维修费用。

具体而言,由于对于某一部件的维修单元会同样将根源故障对应的部件维修到不再需要维修的阶段;因此,为了达到最小维修成本,根源故障对应的部件维修应该排在其影响的部件维修之后。如图 4 所示,如果某时刻的检测异常指征矢量中,只根据维修阈值检测到故障序号为 3、6、7、8、11、14、15 的部件故障,则在滤除未超限的检测异常指征后,故障对应的部件维修按收益排序则可以形成最终的维修顺序,即 6、14、3、7、8、11、15。结合图 5 所示的实际故障传播关系,该维修顺序符合根源故障维修滞后的最大收益原则。

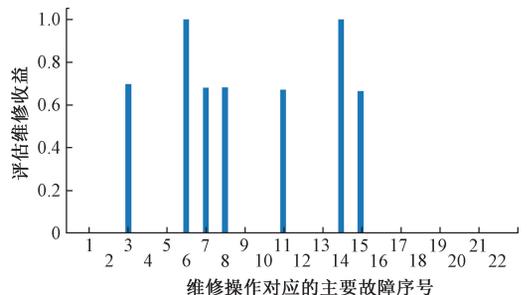


图 4 特定故障状态下的维修收益评估结果
Fig. 4 Evaluation of each maintenance' gain at the announced abnormal state

值得注意的是,由于双向优化方法本身的特征,维修的提前会使得实际数据的异常指征实际范围会逐渐缩小,在检测异常指征与实际异常程度映射非线性的条件下,不可避免会带来部分迭代的误差扰动。在该情况下,

维修收益可以稳定在较高水准,也说明了维修决策优化方法的优势。

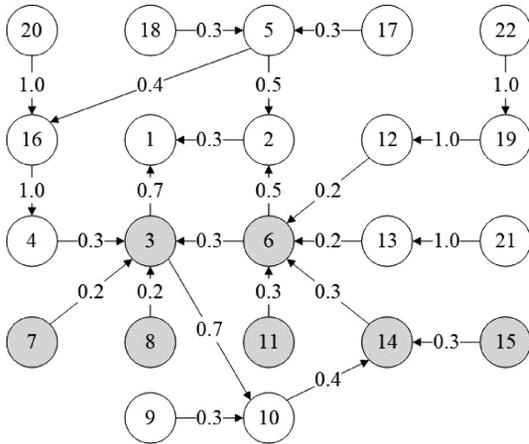


图5 实际故障传播关系图

Fig. 5 Graph of real fault propagation

4 结 论

本文面向机电系统提出了一种健康状态预测和维修决策的双向优化方法。一方面,该方法根据维修操作记录挖掘出的健康状态演化机理,在数据有限的情况下,提供了关于故障动态传播机理的相关性知识,针对健康状态预测进行了启发式优化;另一方面,该方法基于健康状态演化机理建立维修收益的贝尔曼方程,更鲁棒地将健康状态演化机理纳入到了维修的费效比分析中。该方法有效实现了健康状态预测与维修决策基于融合知识的双向优化,较传统独立优化方法而言,具有更强的鲁棒性和收敛性。

参考文献

[1] 孙晓哲,杨珍书,陈棒,等. 飞控机电作动系统典型故障模式影响分析[J]. 微特电机, 2019, 47(10): 25-30,35.
SUN X ZH, YANG ZH SH, CHEN B, et al. Typical fault modes and effect analysis of flight control electromechanical actuation system[J]. Small & Special Electrical Machines, 2019, 47(10):25-30,35.

[2] 曾声奎, PECHT M G, 吴际. 故障预测与健康管理的现状与发展[J]. 航空学报, 2005, 26(5):626-632.
ZENG SH K, PECHT M G, WU J. Status and perspectives of prognostics and health management technologies [J]. ACTA Aeronautica et Astronautica

Sinica, 2005, 26(5):626-632.

- [3] 吕琛,马剑,王自力. PHM 技术国内外发展情况综述[J]. 计算机测量与控制, 2016, 24(9):1-4.
LYU CH, MA J, WANG Z L. A state of the art review on PHM technology [J]. Computer Measurement & Control, 2016, 24(9):1-4.
- [4] 张玉杰,冯伟童,刘大同,等. 基于贝叶斯更新的机电作动器健康因子构建方法[J]. 仪器仪表学报, 2019, 40(5):124-131.
ZHANG Y J, FENG W T, LIU D T, et al. Health Indicator construction method based on bayesian updating for electro-mechanical actuator [J]. Chinese Journal of Scientific Instrument, 2019, 40(5):124-131.
- [5] 王剑,曹宇燕,李婷,等. 基于代数模型的机电作动器 Vague 动态故障树分析[J]. 西北工业大学学报, 2015(6):977-983.
WANG J, CAO Y Y, LI T, et al. A method for analyzing Vague dynamic fault tree of electro-mechanical actuator based on algebraic model [J]. Journal of North-western Poly-technical University, 2015(6):977-983.
- [6] 谢文俊,肖蕾. 基于 EMD 功率谱方法的机电作动系统早期故障特征提取[J]. 测控技术, 2012, 31(10): 29-32.
XIE W J, XIAO L. Electro-mechanical actuation system early fault feature extraction based on EMD power spectrum method [J]. Measurement & Control Technology, 2012, 31(10):29-32.
- [7] 张永强,马宪民,吴晓蕊. 基于 RCM 的煤矿机电设备维修管理系统的研究[J]. 煤炭工程, 2015, 47(9): 110-113.
ZHANG Y Q, MA X M, WU X R. Research on maintenance management system of coal mine electro-mechanical equipment based on RCM [J]. Coal Engineering, 2015, 47(9):110-113.
- [8] 韩中,程林,熊金泉,等. 大数据结构化与数据驱动的复杂系统维修决策[J]. 自动化学报, 2020, 46(2): 385-396.
HAN ZH, CHEN L, XIONG J Q, et al. Complex system maintenance decisions based on big data structuration and data-driven [J]. ACTA Automatica Sinica, 2020, 46(2):385-396.

- [9] 程俭达,刘炎,李天匀,等. 强化学习模式下舰船多状态退化系统的维修策略[J]. 中国舰船研究,2021,16(6):45-51.
CHEN J D, LIU Y, LI T Y, et al. Maintenance strategy of ship multi-state deterioration system under reinforcement learning mode[J]. Chinese Journal of Ship Research, 2021, 16(6):45-51.
- [10] 夏爽. 基于 M-DSSE 和 RVM 的航空机电设备健康状态预测[J]. 价值工程,2017(11):158-159.
XIA SH. Health prediction of aircraft electromechanical equipment based on M-DSSE and RVM [J]. Value Engineering, 2017(11):158-159.
- [11] 宋辉,李昌平,蔡忠春,等. 基于贝叶斯网络的故障诊断与维修决策研究[J]. 航空维修与工程,2011(1):32-34.
SONG H, LI CH P, CAI ZH CH, et al. Fault diagnosis and maintenance decision based on bayesian network[J]. Aviation Maintenance & Engineering,2011(1):32-34.
- [12] 李志栋,张涛. 非完美特性下的多状态系统检测与维修优化[J]. 北京航空航天大学学报,2017,43(5):951-960.
LI ZH D, ZHANG T. Optimization of inspection and repair of multi—state system under imperfect characteristics [J]. Journal of Beijing University of Aeronautics and Astronautics, 2017, 43(5):951-960.
- [13] 李志栋,张涛. 多状态串联维修系统的检测及维修优化[J]. 计算机仿真,2017,34(3):385-390,399.
LI ZH D, ZHANG T. Inspection and maintenance optimization of multi-state series repairable system[J]. Computer Simulation, 2017,34(3):385-390,399.
- [14] 朱琳,陈杰,陈文颖,等. 基于模糊概率符号有向图的复杂系统故障诊断[J]. 北京理工大学学报,2007,27(11):969-973.
ZHU L, CHEN J, CHEN W J, et al. Fault diagnosis based on fuzzy probability signed directed graph in complex system [J]. Transaction of Beijing Institute of Technology, 2007, 27(11):969-973.
- [15] 胡道生,常健永. 基于模糊综合评判的军事装备维修费绩效管理评估[J]. 兵工自动化,2012,31(3):35-37.
HU D SH, CHANG J Y. Evaluation in performance management of maintenance costs of military equipment based on fuzzy comprehensive evaluation [J]. Ordnance Industry Automation, 2012, 31(3):35-37.
- [16] 郭驰名,郭波,王文彬,等. 非周期不完全检测下的维修优化[J]. 国防科技大学学报,2013,35(4):176-181.
GUO CH M, GUO B, WANG W B, et al. Maintenance optimization under non-periodic imperfect inspections [J]. Journal of National University of Defense Technology, 2013, 35(4):176-181.
- [17] MOHRI H, TAKESHITA J I. Catastrophic failure and cumulative damage models involving two types of extended exponential distributions [J]. International Journal of Reliability, Quality and Safety Engineering, 2021, DOI: 10.48550/arXiv.2109.08546.
- [18] YUAN X. Stochastic modeling of deterioration in nuclear power plant components [D]. Waterloo: University of Waterloo, 2007.
- [19] 陈阳隆,马彦恒,刘骐玮,等. 贯序任务下考虑不完全维修的装备选择性维修决策研究[J]. 航空兵器,2019,26(6):93-98.
CHEN Y L, MA Y H, LIU Q W, et al. Research on selective maintenance decision-making of equipment considering imperfect maintenance under sequential mission [J]. Aero Weaponry, 2019, 26(6):93-98.
- [20] 王岱青,丁建国,白英彩. 网络故障管理的贝叶斯模型参数学习[J]. 计算机应用与软件,2008,25(4):158-159.
WANG D Q, DING J G, BAI Y C. Parameter learning of bayesian network in fault management system [J]. Computer Applications and Software, 2008, 25(4):158-159.
- [21] 程志君,郭波. 基于半 Markov 决策过程的劣化系统检测与维修优化模型[J]. 自动化学报,2007,33(10):1101-1104.
CHENG ZH J, GUO B. Optimization of inspection and maintenance policy for deteriorating system with semi-markov decision process [J]. ACTA Automatica Sinica, 2007, 33(10):1101-1104.
- [22] 张欣,薄迎春,崔黎黎. 离散非线性零和博弈的事件驱动最优控制方案[J]. 控制理论与应用,2018,35(5):

619-626.

ZHANG X, BO Y CH, CUI L L. Event-triggered optimal control scheme for discrete-time nonlinear zero-sum games [J]. Control Theory & Applications, 2018, 35(5):619-626.

- [23] 张红旗,邵晓东,苏春,等. 改进 FMEA 与故障传播模型混合故障诊断方法[J]. 机械科学与技术, 2017, 36(1):23-28.

ZHANG H Q, SHAO X D, SU CH, et al. Analysis on an opportunistic maintenance and adaptability for generating units[J]. Mechanical Science and Technology for Aerospace Engineering, 2017, 36(1):23-28.

作者简介



梁思远, 2020 年于北京航空航天大学获得学士学位, 现为北京航空航天大学研究生, 主要研究方向为自动化测试和故障预测与健康管理技术。

E-mail: SiyuanLiang2020@buaa.edu.cn

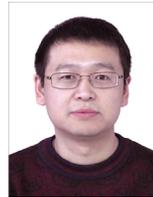
Liang Siyuan received his B. Sc. degree in 2020 from Beihang University. Now he is postgraduate student in Beihang University. His main research interests include automatic testing and prognostic and health management.



周金滄, 2020 年于北京航空航天大学获得学士学位, 现为北京航空航天大学研究生, 主要研究方向为自动化测试和故障预测与健康管理技术。

E-mail: jinhan_zhou@buaa.edu.cn

Zhou Jinhan received his B. Sc. degree in 2020 from Beihang University. Now he is postgraduate student in Beihang University. His main research interests include automatic testing and prognostic and health management.



高占宝 (通信作者), 分别在 1996 年、2002 年和 2006 年于北京航空航天大学获得学士学位、硕士学位和博士学位, 现为北京航空航天大学讲师, 主要研究方向为故障诊断与健康管理, 数据挖掘。

E-mail: gaozhanbao@buaa.edu.cn

Gao Zhanbao (Corresponding author) received his B. Sc., M. Sc. and Ph. D. degrees all from Beihang University respectively in 1996, 2002 and 2006. Now he is a lecturer in Beihang University. His main research interests include fault diagnosis and health management, datamining.