



面向大规模工业生产数据驱动故障诊断方法综述

于骞翔 李擎 李琳琳 王义轩

A survey of data-driven fault-diagnosis methods for large-scale industrial production processes

YU Qianxiang, LI Qing, LI Linlin, WANG Yixuan

引用本文:

于骞翔, 李擎, 李琳琳, 王义轩. 面向大规模工业生产数据驱动故障诊断方法综述[J]. 北科大: 工程科学学报, 2025, 47(4): 780–793. doi: 10.13374/j.issn2095–9389.2024.05.24.002

YU Qianxiang, LI Qing, LI Linlin, WANG Yixuan. A survey of data-driven fault-diagnosis methods for large-scale industrial production processes[J]. *Chinese Journal of Engineering*, 2025, 47(4): 780–793. doi: 10.13374/j.issn2095–9389.2024.05.24.002

在线阅读 View online: <https://doi.org/10.13374/j.issn2095–9389.2024.05.24.002>

您可能感兴趣的其他文章

Articles you may be interested in

基于柔性残差神经网络的滚动轴承智能故障诊断方法

Intelligent fault diagnosis method for rolling bearings based on flexible residual neural network
工程科学学报. 2025, 47(3): 480 <https://doi.org/10.13374/j.issn2095–9389.2024.06.24.006>

基于KPCA–MTCN的锂离子电池故障诊断方法

Lithium-ion battery fault diagnosis method based on KPCA–MTCN
工程科学学报. 2024, 46(12): 2297 <https://doi.org/10.13374/j.issn2095–9389.2024.01.30.001>

一种改进的 I_p -RWMKE-ELM故障诊断模型

Research on an improved I_p -RWMKE-ELM fault diagnosis model
工程科学学报. 2022, 44(1): 82 <https://doi.org/10.13374/j.issn2095–9389.2020.07.09.001>

基于WOA–VMD与PSO–SVM的锂离子电池内短路故障诊断方法

Research on internal short-circuit fault diagnosis methods for lithium-ion batteries based on WOA–VMD and PSO–SVM
工程科学学报. 2023, 45(12): 2162 <https://doi.org/10.13374/j.issn2095–9389.2022.10.04.004>

一种基于轻量级神经网络的高铁轮对轴承故障诊断方法

Fault diagnosis of high-speed train wheelset bearing based on a lightweight neural network
工程科学学报. 2021, 43(11): 1482 <https://doi.org/10.13374/j.issn2095–9389.2020.12.09.001>

基于深度学习的高超声速飞行器执行器零样本故障辨识

Deep learning based actuator fault identification for hypersonic vehicles: A zero-shot case
工程科学学报. 2024, 46(9): 1613 <https://doi.org/10.13374/j.issn2095–9389.2023.09.27.001>

面向大规模工业生产过程中的数据驱动故障诊断方法综述

于骞翔¹⁾, 李 擎^{1,2)✉}, 李琳琳^{1,2)}, 王义轩¹⁾

1) 北京科技大学自动化学院, 北京 100083 2) 工业过程知识自动化教育部重点实验室, 北京 100083

✉通信作者, E-mail: liqing@ies.ustb.edu.cn

摘 要 聚焦于大规模工业生产过程智能化、精准化和多源化的需求, 故障诊断对保障工业生产过程的安全可靠运行与实时有效维护具有重要意义. 数据驱动方法作为一种创新范式, 通过融合历史数据、实时数据以及多源信息, 避免了对精确模型的依赖, 能够有效提升故障检测与识别的准确率和效率. 首先, 本文梳理了数据驱动框架下的故障诊断方法, 着重探讨了信号处理、统计模式识别、多元统计等系统稳态特性分析方法, 并针对系统的动态、非线性和非高斯分布等复杂特性, 进一步综述了动态多元统计、子空间辨识、深度学习和核空间投影等故障诊断方法. 其次, 介绍了大规模工业生产过程的分布式故障诊断方法. 从系统的分布式结构和分布式传感器网络出发, 分别阐述了该方法在系统分解和数据融合、相关性分析以及一致性方法等三个方面的最新进展. 分布式故障诊断方法将监测职能分散到各子单元, 使各子单元可根据自身及相邻子单元的运行状态自行做出安全性能判断, 在大规模工业生产过程的监测和故障诊断中具有优势. 最后, 总结了数据驱动的分布式故障诊断方法的实际应用, 并指出其在定性定量混合分析、鲁棒性诊断和数据安全等方面的发展趋势.

关键词 大规模系统; 故障诊断; 数据驱动; 动态特性; 分布式

分类号 TP277

A survey of data-driven fault-diagnosis methods for large-scale industrial production processes

YU Qianxiang¹⁾, LI Qing^{1,2)✉}, LI Linlin^{1,2)}, WANG Yixuan¹⁾

1) School of Automation and Electrical Engineering, University of Science and Technology Beijing, Beijing 100083, China

2) Key Laboratory of Knowledge Automation for Industrial Processes (Ministry of Education), Beijing 100083, China

✉Corresponding author, E-mail: liqing@ies.ustb.edu.cn

ABSTRACT Fault diagnosis for large-scale industrial production systems has attracted considerable research interest in response to the complex, multisource, and precision requirements of these processes. Fault diagnosis is crucial for the safe, reliable, and real-time maintenance of industrial production processes. This work presents a comprehensive survey of fault-diagnosis methods and emphasizes two cornerstone strategies: data-driven paradigms and distributed methods. Traditional fault-diagnosis methods based on mechanism have limited applications because precise modeling of the systems considered is required. Data-driven approaches avoid the dependence on precise modeling; thus, the research focus on fault diagnosis for industrial production processes has gradually shifted from mechanism-based to data-driven methods that integrate historical data, real-time data, and multisource information to enhance the accuracy and efficiency of the fault detection and identification approaches. A comprehensive overview of data-driven fault-diagnosis methods is given in the first part of this work. Specifically, smooth data from industrial processes is collected and used for fault diagnosis. The internal state variables may continuously change, and accompanied with time correlation among the process measurements. Integrating data-driven and dynamic analyses, necessitated by the dynamic nature of the process variables, offers a more

收稿日期: 2024-05-24

基金项目: 国家优秀青年科学基金资助项目(62322303); 国家自然科学基金资助面上项目(62073029, 62273033)

accurate representation of system behavior. This can be achieved through the introduction of time-series modeling in basic multivariate statistics and the capture of dynamic properties by subspace identification. Furthermore, deep learning and kernel methods address nonlinearity, and non-Gaussian traits are tackled by independent component analysis (ICA) and other methods. Second, distributed fault-diagnosis methods for large-scale industrial production processes are reviewed. The usual fault-diagnosis methods for large-scale systems rely on centralized sensor network monitoring. Centralization necessitates consolidated data processing, which can create immense computational stress. Applying distributed fault-diagnosis methods spreads the monitoring capacities among all the subsystems, enabling each subsystem to independently assess its safety and performance based on its own data and interactions with neighboring subsystems. The latest advances in system decomposition and data fusion, correlation analysis, and consensus mechanisms are elaborated on subsystems based on the distributed structure and sensor networks in large-scale systems. System decomposition focuses on the local features of each subsystem although adopting a purely subsystem-centric approach to data processing often leans toward decentralization, in contrast to the essence of distribution. Thus, the effective integration of data is critical for achieving comprehensive information about large-scale systems. Correlation analysis examines the intricate relationships among subsystems or nodes. It elucidates mutual interactions and uncovers dependencies and influences. Meanwhile, consensus analysis focuses on the communication topology of the nodes, ensuring that all nodes converge to a unified data state at any instant. Finally, the practical applications for evaluating the performance of distributed data-driven fault-diagnosis methods are summarized. The potential trends are also highlighted, including qualitative and quantitative methods integration, improved diagnosis robustness, and data security assurance.

KEY WORDS large-scale systems; fault diagnosis; data-driven; dynamic properties; distributed approach

大规模工业过程结构庞大、机理复杂,一旦某一环节发生故障且不能被及时诊断出来,就有可能发生连锁反应,进而威胁系统的稳定性与安全性。因此,如何设计高效的故障诊断单元,以确保生产过程的稳定、安全、可靠、高效运行,已经成为工程应用和理论研究的热点方向之一。因实际工业过程不确定因素多且过程复杂,致使其难以构建精确的机理模型,这限制了传统的基于机理模型的故障诊断方法的应用。数据驱动方法避免了对精确模型的依赖,故工业生产过程的故障诊断逐渐从基于机理模型的方法转向数据驱动的方法。总体来看,数据驱动的故障诊断已经取得了丰富的研究成果,包括面向具有稳态特性系统的信号处理、模式识别、多元统计等方法,针对系统动态特性的动态多元统计和子空间辨识等方法,以及针对具有非线性、非高斯特性的系统的核方法、ICA 和高斯混合建模等方法。

现有的数据驱动故障诊断方法大多为集中式结构,即所有过程测量变量都集中到一个中心故障诊断单元执行计算。由于大规模系统多具有层次式与分布式结构,单元间的过程变量存在错综复杂的耦合关系,并通过通讯拓扑互联,这种复杂性使得集中式方法在处理大规模数据时面临巨大的计算压力,并且难以捕捉到各个子系统或单元之间的细微差异和相互作用。在这种情况下,分布式方法通过将监测职能分散到局部子系统,利用与相邻节点的信息交互进行故障诊断。分布式方

法不仅能够一定程度上分散集中式的安全风险,还具有交互数据少、灵活性高、易于拓展和调整等优点,在电网、冶金、钢铁、化工等领域被广泛应用,形成了系统分解和数据融合、相关性和一致性分析等多样化的方法。因此,有必要针对大规模工业生产过程的分布式故障诊断开展研究和综述。

综上所述,针对大规模工业系统的机理复杂、工序众多、数据分散等特点,研究数据驱动的分布式故障诊断方法,是保证大规模工业系统的安全可靠运行与实时有效维护的关键,具有重要的科学意义和应用前景。本文首先介绍了面向系统稳态和动态特性的数据驱动故障诊断方法,并综述了针对非线性等复杂系统特性的诊断方法;其次阐述了面向大规模系统的数据驱动分布式故障诊断的研究现状和应用案例;最后依据相关研究成果进行总结与展望。

1 数据驱动故障诊断方法的研究现状

数据驱动的故障诊断方法起源于质量控制和统计过程控制,在 20 世纪 90 年代前后得到了广泛地关注和应用。在初始阶段,工程师获得的大多是关乎产品质量的关键指标的离线测量数据,这些数据大部分属于平稳随机过程。随着科技的进步,特别是在线测量仪表种类的丰富和性能的提升,大量具有非平稳、非线性的生产过程实时数据得以采集,直接推动了数据驱动的工业生产过程实时监测的发展。数据驱动的故障诊断涉及信号处

理、统计模式识别等数据分析方法和子空间辨识、核空间投影等方法的交叉,其核心任务是基于过程数据的系统建模和分析,通过信号之间的相关关系来提取有用的知识和特征,从而揭示故障发生时系统的异常模式与动态变化^[1]。本文从这一核心任务出发,对面向系统稳态、动态、非线性和非高斯特性的数据驱动故障诊断方法进行了详细阐述。

1.1 面向系统稳态特性的故障诊断方法

稳态特性是指系统处于平衡状态,不再对外部扰动或输入产生明显的动态响应,系统内部性质如温度、压力等不随时间发生变化。针对系统稳态特性的故障诊断方法可以分为基于统计信号处理的方法、基于统计模式识别的方法和基于多元统计的方法等。

1.1.1 基于统计信号处理的方法

统计信号处理方法主要针对过程的局部变量进行监测,其研究涉及频谱分析、小波变换等传感器信号处理技术。基于频谱分析的故障诊断方法通过将复杂信号分解来识别与故障相关的特定频率,从而判断故障类型和位置。这种方法最早在 1983 年提出^[2],其考虑了故障与给定频率幅值调制之间的关联性,通过分析信号中是否存在特定的频率峰值来进行故障诊断。小波变换则通过基函数来实现信号的多尺度细化分析,因其时频局部化的特性而在故障诊断中得到了广泛应用。近年来,人们提出了多种改进的小波变换方法,如文献^[3]采用优化 Morlet 小波的一维信号瞬态特征提取技术,根据信号滤波结果来构建幅值和相位组合信息,并将其作为轴承的运行状态评价指标。文献^[4]结合了可变波形分量分解和小波变换的方法,通过可变波形分量分解将复杂的波形信号分解为多个简单的分量,然后通过小波重构进一步处理波形分量,进而提取设备运行状态的特征参数来进行故障诊断。总体上,基于信号处理的各种方法对输入信号质量要求低且计算量小,但其仅利用可测信息与故障源之间的直接关系来判断故障,并没有考虑多元测量值,限制了其在大规模工业系统的应用。

1.1.2 基于统计模式识别的方法

基于统计模式识别的故障诊断方法的核心在于数据分类。具体来说,这种方法通过对多维特征空间分析来将信号空间划分为不同的区域,当系统产生新的数据点时,该方法会将其映射到相应的特征空间,并根据特征区域来识别其所属的故

障模式或类别。基于深度学习和基于支持向量机的故障诊断是两种代表性的统计模式识别方法。

在数据驱动的框架下,基于深度学习的故障诊断方法的核心在于充分利用深度学习模型如循环神经网络及其变体长短期记忆网络等的学习优势,旨在通过深度神经网络对工业场景中的传感器网络及其捕捉的复杂动态数据进行深度挖掘与分析,学习并建立输入与输出之间的复杂映射关系,自动提取故障特征并构建故障分类模型^[5]。然而,深度学习模型是典型的黑盒模型,其决策机制尚不明确,限制了其在高可靠性要求的故障诊断场景中的应用,这一问题促使了近年来人们对于具有可解释性的深度学习模型的广泛关注。文献^[6]提出了一种基于时频网络的可解释神经网络结构,将物理上的时频变换方法嵌入到传统的卷积层中,以提取与故障相关的时频信息,从频域角度解释了卷积神经网络预测的逻辑。文献^[7]通过展开用于稀疏编码模型的嵌套迭代软阈值算法来生成可解释的网络结构,并采用了可视化方法来检查网络是否学习了有效的轴承和齿轮的故障特征。虽然上述文献针对故障诊断领域的深度学习模型可解释性方面给出了有效的优化策略,但仍存在诸多亟待解决的问题,如:(1)大规模系统数据模型的复杂度极高,构建完整的深度学习可解释性模型几乎不可能;(2)局部与全局解释方法的权衡问题尚未解决。因此,进一步提高神经网络的可解释性将是基于深度学习的故障诊断方法的重要研究方向。

另一方面,支持向量机作为一种强大的机器学习算法,通过在数据的高维特征空间中构建最优超平面来实现分类。该超平面旨在有效地分隔不同类别的样本,并同时确保它们之间距离的最大化。在文献^[8]中,关于在线故障检测的描述指出,当新的系统数据被映射至高维特征空间时,支持向量机能够基于在训练阶段学习得到的最优超平面规则,对新映射的数据进行快速而准确的分类。

从上述两种方法的基本原理可以看出,虽然统计模式识别方法具有强大的分类能力,但在进行故障检测时,往往需要大量带有准确标签的训练数据来指导特征空间的分类。因此,如何在有限的训练数据下提高分类器的性能,是当前研究的难点。

1.1.3 基于多元统计的方法

多元统计方法是在数据驱动的过程监测与故障诊断领域研究最多的方法,其依托的主要理论

是以主成分分析(PCA)、独立成分分析(ICA)和偏最小二乘法(PLS)等为核心的数据投影降维方法。

PCA是一种在数据降维中广泛应用的代表性方法,其对数据的降维示意图如图1(a)所示。基于PCA的故障诊断通过识别数据中的关键变量作为主成分,并在正交子空间中构建主元子空间和残差子空间。随后,通过监测这两个子空间的检验统计量是否超出控制限来实现故障的诊断和识别,通常选择卡方检验统计量(χ^2)或 Hotelling's T^2 检验统计量(T^2)作为统计指标, χ^2 和 T^2 能够提供综合度量,以评估观察值与理论值之间的偏离程度。与PCA的去相关特性不同,ICA旨在分离可观察信号中的非高斯信号源,通过确定统计独立的非高斯成分来提取数据中的关键信息。在基于ICA的故障诊断中,平方预测误差(SPE)和 T^2 等图形化工具被广泛应用于检测过程数据的变化情况^[9]。图1(b)展示了基于ICA降维的田纳西-伊斯曼过程故障诊断仿真结果。

PCA和ICA方法通常被视为典型的非因果数据降维方法,它们主要关注于数据特征的提取,而不直接考虑变量间的因果关系。PLS方法通过构建潜变量来反映自变量和因变量之间的主要因果关系,因此PLS被视为一种因果分析方法。具体来说,PLS同时考虑预测变量 X 和响应变量 Y 的潜在结构,通过在 X 中提取与 Y 最相关的成分来解释 X 和 Y 的方差,同时保持 X 和 Y 之间的最大协方差,从而建立两者的线性回归关系^[10]。传统PLS在故障检测领域展现出其局限性,这主要源于它可能对数据执行不必要地分解,导致有价值的信息残留在残差子空间中^[11]。为了克服这一局限,文献[12]提出了一种后处理策略全PLS技术,通过机器学习技术来进一步挖掘残差中的信息,并将

这些信息重新整合到故障检测模型中,细化了数据空间的划分。然而,文献[13]研究表明,在面对故障幅度增大的情况时,这种后处理策略在降低与质量无关的故障误报率方面仍显不足。为此,文献[14]引入了基于正交信号校正的改进PLS方法,旨在提升PLS在识别质量相关故障方面的能力。该方法通过计算不同过程变量与产品质量变量之间的互信息来得到权重因子,滤除了PLS倾斜分解产生的质量无关部分,有效地减少了因不相关信息干扰而导致的误报。这一方法的提出,是对PLS技术在故障检测领域应用的一次重要拓展,提升了PLS在复杂工业过程中的故障检测精度和效率。

典型相关分析(CCA)是另一种用于探索两组多元变量之间关系的多元统计方法。基于CCA的故障诊断的基本原理是构建两组变量之间的线性组合,并通过最大化这些组合之间的相关性来构建残差信号,从而用于故障诊断。文献[15]通过CCA来最小化残差信号的协方差,显著提高了系统故障的可检测性。文献[16]深入剖析了系统中各部件和环节的因果关系,通过CCA最大化综合变量间的相关性来识别故障模式,构建二次方统计量 Q_{cca} 作为检验统计量来进行故障检测,并将其应用于氧化铝蒸发过程,仿真结果如图2所示。CCA在揭示变量组之间的关联关系方面具有显著优势,然而,由于其具有计算复杂度高、对数据的质量要求高等缺点,在实际应用中,CCA通常与其他技术相结合来增强其在故障诊断应用方面的鲁棒性和抗噪性。

通过以上方法看出,基于多元统计的故障诊断方法将原始数据投影到低维空间来提取数据的主要特征,是一类利用数据降维和数据统计特性

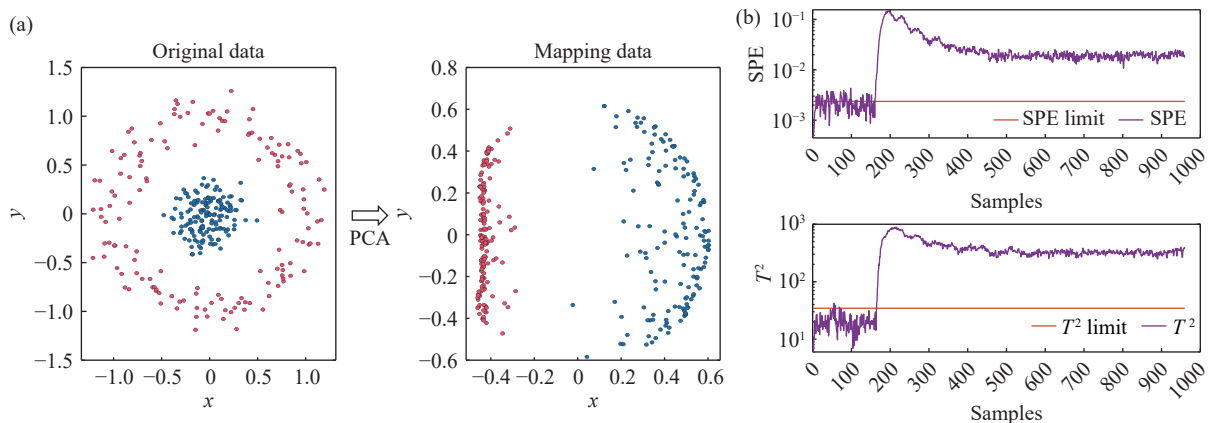


图1 数据降维及检验统计量。(a) circle型数据降维; (b) 田纳西-伊斯曼数据的ICA降维和其检验统计量的SPE、 T^2 曲线

Fig.1 Data dimensionality reduction and test statistics: (a) circle-type data downscaling; (b) ICA downscaling of TE data and its test statistic SPE, T^2 curves

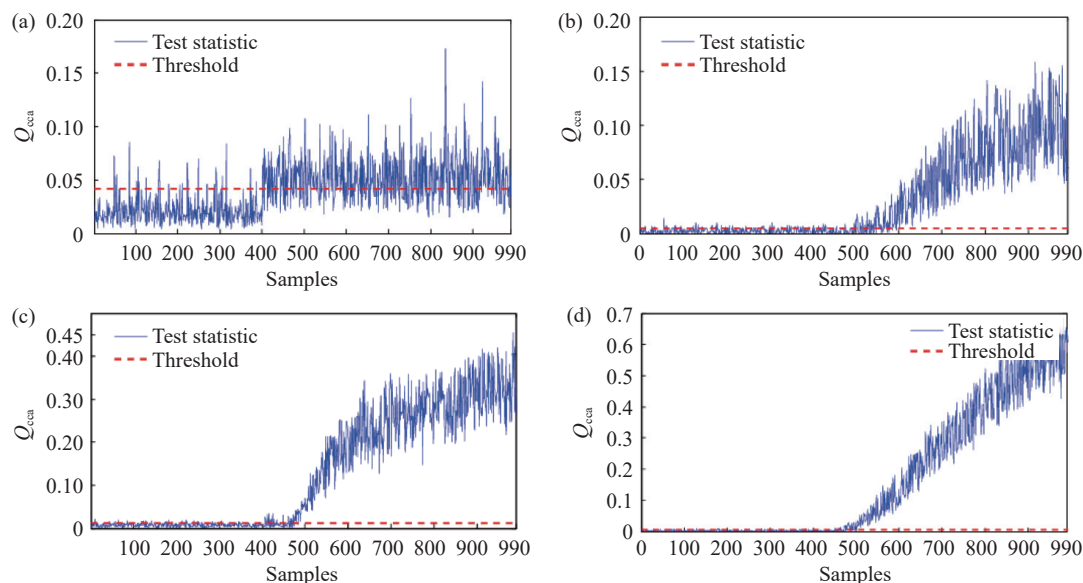


图2 基于 CCA 的氧化铝蒸发过程故障诊断的 Q 检验统计量曲线. (a) 第一蒸发器液体出口流量传感器故障; (b) 第四台蒸发器结垢; (c) 第四个蒸发器进气阀卡住; (d) 蒸汽阀泄漏

Fig.2 Q -test statistical curves for CCA-based fault diagnosis of the alumina evaporation process (a case): (a) faulty liquid outlet flow sensor in the first evaporator; (b) fouling in the fourth evaporator; (c) stuck inlet valve in the fourth evaporator; (d) leaking vapor valve

进行故障诊断的方法,但在面向工业过程的复杂数据时仍存在降维导致信息损失、计算量过大导致实时性差等问题.鉴于机器学习在分析复杂数据特性方面的卓越能力,把机器学习和多元统计方法结合起来,是复杂工业过程故障诊断方法的发展趋势.

1.2 面向系统动态特性的故障诊断方法

流程工业过程并不都处于稳态,其内部状态变量可能随时间不断发生变化,这导致过程测量值具有时序相关性.因此,面向系统动态特性的数据驱动故障诊断方法逐渐成为研究热点.

1.2.1 基于动态多元统计的方法

近年来,动态多元统计成为研究动态系统数据驱动故障诊断的主要手段,并取得了一系列的研究成果.其基本思想是利用时序信息将系统数据扩充成数据矩阵,并通过分析历史数据与当前数据之间的相关性来刻画系统的动态特性,从而将时间动态建模问题转化为更直观的空间稳态建模问题^[17].文献[18]首先提出了基于扩展数据矩阵的动态 PCA 方法,构建了一个包含历史数据和当前数据的扩展矩阵,通过 PCA 从该矩阵中提取数据主成分,并基于此建立精确的故障判据.这种方法不仅利用了历史数据中的信息,还考虑了基于最新数据的扩展矩阵动态更新,因此广泛应用于连续工业过程的动态监测领域^[19].之后,文献[20]针对传统动态 PCA 在面对非平稳时间序列时可能

出现问题,给出了具有自适应参数调节的动态 PCA 算法,这类算法能够根据数据的实时变化自动调整模型参数,从而提高故障诊断的鲁棒性.然而,由于上述扩充数据矩阵的方法存在缺乏动态关系的明确表达和计算量随历史数据增加而增大的问题,限制了其在动态建模时的应用.

1.2.2 基于子空间辨识的方法

子空间辨识方法(SIM)作为传统线性系统辨识方法的一个有益补充,是动态系统故障诊断的研究热点.SIM的基本思想可以追溯到20世纪60年代所提出的状态空间理论.基于该理论,系统的状态空间模型可以通过脉冲响应系数组成的 Hankel 矩阵来得到.然而,由于难以获取可靠的脉冲响应估计,近年来采用系统的输入输出数据构造 Hankel 矩阵的研究备受关注.基于 SIM 的系统模型^[21]可以描述为:

$$Y = H_x X + H_u U + V \quad (1)$$

$$H_x = \begin{bmatrix} C \\ CA \\ \vdots \\ CA^s \end{bmatrix}, H_u = \begin{bmatrix} D & 0 & \cdots & 0 \\ CB & D & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ CA^{s-1}B & \cdots & CB & D \end{bmatrix} \quad (2)$$

其中, s 表示矩阵的长度, X 表示系统状态构成的矩阵, U 、 Y 分别表示由输入、输出数据堆叠得到的 Hankel 矩阵, A 、 B 、 C 、 D 表示系统状态空间方程的系数矩阵, H_x 表示状态 x 的扩展的可观测矩阵, H_u 表示由输入 u 到输出的 Toeplitz 矩阵, V 表

示噪声. 基于该模型, 文献 [22] 从线性系统的几何性质角度出发, 详细阐述了确定性、随机性以及确定性与随机性混合的三种 SIM 具体实现方法. 文献 [23] 系统性地归纳了开环系统的 SIM 方法, 并指出了存在反馈控制的情况下输入信号和噪声不相关的假设可能不成立, 这限制了 SIM 在闭环中的应用. 文献 [24] 进一步研究了闭环条件下的系统可识别性和 SIM 方法, 并优化了闭环系统辨识带来的偏差. 文献 [25] 通过引入与控制输入和噪声不相关的变量, 利用矩阵分解实现了与闭环结构兼容的 SIM 方法, 保证了分解后的数据矩阵仍然保持数据的原有特征. 文献 [26] 研究了基于核空间投影的 SIM 故障诊断方法, 在此基础上文献 [27] 提出了稳定核表征的 SIM 辨识方法, 并由文献 [28] 进一步拓展至非线性系统. 近年来, SIM 与卡尔曼滤波器融合的方法广泛应用于动态系统状态估计和滤波. SIM 可以为卡尔曼滤波器提供一个初始的、较为准确的系统模型, 在此基础上卡尔曼滤波器利用观测的数据对系统模型进行实时修正, 进而实现动态系统的最优状态估计. 文献 [29] 提出了基于投影的闭环 SIM 方法, 利用输入输出数据估计非稳态卡尔曼滤波器的状态向量和系统矩阵. 文献 [30] 针对误差变量模型的结构, 提出了基于正交子空间投影和辅助变量闭环 SIM 算法, 该方法通过扩展可观测性矩阵、下三角 Toeplitz 矩阵和卡尔曼滤波状态向量矩阵的投影矩阵来构造系统动态模型.

SIM 首次应用于工业过程识别领域可见于文献 [31], 随后文献 [32] 明确指出 SIM 特别适用于具有动态特性和随机干扰的工业过程的故障诊断. 但在实际应用中, SIM 方法对系统状态空间模型精确辨识往往产生误差. 因此, Ding 在文献 [33] 中融合了数据驱动和解析模型的优势, 提出了基于数据驱动核表征辨识的故障诊断方法. 该方法直接通过 SIM 从数据中辨识动态系统的核表征, 避免了传统的 SIM 方法先辨识状态空间模型再进行故障诊断系统设计带来的累积误差. 后续文献 [34] 进一步完善了对系统核表征和像表征的数据驱动辨识.

综上所述, 子空间辨识方法侧重于采用系统的输入输出数据构造 Hankel 矩阵, 进而辨识反映系统动态特性的模型. 若能将传统信号处理方法与子空间辨识方法相结合, 通过信号处理方法从原始数据中提取时频信息, 通过子空间辨识方法构建系统动态模型, 并将这两类信息有效融合以

在不同模型层次上进行故障诊断, 可以实现对系统的多维度、多层次监测, 从而更全面地捕捉故障特征.

1.3 面向系统非线性的故障诊断方法

由于工业生产过程物质流动、能量转换和化学反应的复杂性, 变量间往往呈现非线性特性, 这使得直接利用线性系统的故障诊断方法难以取得理想效果. 对此, 最为直观的解决方法是对非线性模型进行线性化处理进而设计线性的故障诊断单元. 然而该方法仅适用于局部分析、弱非线性以及系统参数和结构明确的情况. 对于高度非线性的系统, 传统的线性化方法显然不适用. 针对这一问题, 本节重点从深度学习、核方法两方面对非线性系统故障诊断方法进行阐述.

深度学习通过模拟原始数据特征与权重参数间的复杂关联, 实现了对高度非线性系统特性的有效逼近. 在故障诊断领域, 神经网络通过其多层结构和非线性激活函数, 能够很好地逼近系统的非线性映射, 从而准确刻画系统的故障特征. 文献 [35] 设计了一种基于特征对齐堆叠自编码器的半监督深度学习模型, 通过逐层堆叠多个自编码器来学习数据的非线性特征, 以实现工业过程故障分类. 文献 [36] 提出了一种基于强化迭代学习框架的最优化故障诊断策略, 设计了一类迭代学习故障观测器, 并将最优化故障诊断问题重新表述为强化学习任务以逼近非线性. 因此, 强化学习的引入为实现非线性故障诊断的智能化提供了新的思路.

核方法的基本思想是将原始数据通过非线性映射函数(核函数)投影到高维特征空间(图 3), 然后在该特征空间中执行线性算法. 这种方法避免了显式非线性运算, 有效地解决了原始数据非线性不可分类问题. 文献 [37] 针对系统的非线性输入, 提出了核 PCA 方法, 通过积分算子和非线性核函数将原始数据映射到高维的再生核希尔伯特空间, 使非线性数据在高维特征空间中呈线性关系. 类似地, 文献 [38] 提出了非线性核 PLS, 利用核函数建立非线性 PLS 模型, 并证明了该模型具有与线性 PLS 相当的复杂度. 虽然核方法在处理系统复杂数据映射时面临可解释性的挑战, 但其强大的非线性处理能力使其具有广泛的应用前景和深远的研究价值.

1.4 面向系统非高斯特性的故障诊断方法

非高斯过程指不满足多元高斯分布的随机过程. 具体而言, 如果一个随机过程的任意有限维联合分布不符合多元高斯分布的特性, 呈现出偏态、

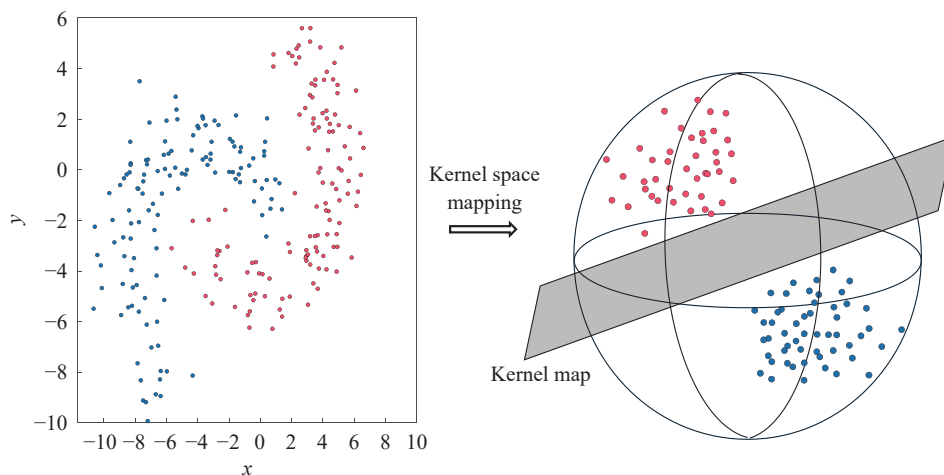



图3 原始输入数据及核空间映射

Fig.3 Original data and kernel space mapping

多峰或其他复杂的非高斯分布形式,那么这个过程就被归类为非高斯过程.针对系统非高斯特性的故障诊断方法集中在三个方面,分别为基于独立主元、基于概率密度估计和基于混合建模的方法.

ICA 因假设信号服从非高斯分布且在统计上彼此独立,已被证明是一种分析非高斯特性的有效方法^[39].文献[40]通过 ICA 方法对数据进行统计分析并计算出非高斯统计量,之后采用 PCA 对非高斯建模后剩余的残差进行统计建模并得到高斯统计量,并对这两个统计量进行加权获取新的统计指标,从而实现对实际工业过程的在线监控.文献[41]指出概率密度估计作为一种非参数估计方法,可以通过核密度估计来获取随机变量的概率密度函数,进而实现对非高斯分布数据的建模和分析(图4).针对非高斯潜在子空间和剩余子空间内批处理数据的故障检测问题,文献[42]提出了非线性批处理的多向核 PLS 方法,通过引入多向核 PLS 模型来提取非高斯数据中的异常信息,并成功应用于青霉素发酵生产过程的故障诊断.事实上,该方法是上述一维核概率密度估计方法

图4 非高斯系统输出概率密度函数. (a) 无故障时概率密度函数; (b) 全过程概率密度函数(引入故障)^[44]Fig.4 Non-Gaussian system output probability density function: (a) probability density function in the absence of faults; (b) full-process probability density function (introduction of faults)^[44]

的多维扩展.在系统混合建模方法中,高斯混合建模采用期望最大化算法来精确估计模型参数,是专门针对数据非高斯分布特性的一种建模方法.文献[43]针对热工过程的异常数据,通过构建非高斯混合模型来拟合数据的复杂分布,进而捕捉数据的非高斯特性.相比于概率密度估计,该方法的模型简单,是分析系统非高斯特性的有效工具.

总而言之,独立主元分析作为一种统计技术,其核心在于从复杂数据中提炼出一组相互独立且呈现非高斯特性的成分,从而为深入理解非高斯特性提供新视角;概率密度估计则通过非参数化途径,精准地刻画了实际数据的概率分布形态;高斯混合模型将多个高斯分布融合以逼近更为复杂的非高斯概率分布,极大地拓宽了处理非高斯数据的能力边界.在系统普遍存在的非高斯特性背景下,以深入剖析数据分布特性为核心的诊断方法正日益成为研究热点.

2 分布式故障诊断方法的研究现状

分布式方法的基础思想是将复杂工业过程分解为多个独立的局部子系统或节点,每个子系统或节点都具备数据获取与处理功能,且配备了独立的计算单元和通讯接口,以实现与其他节点间的信息交换,如图5所示是一类分布式传感器网络的拓扑结构, y_i 为第*i*个节点的信息.针对这一网络拓扑结构,分布式故障诊断方法能够利用节点自身数据和与相邻节点的交换数据,在各个节点内部进行安全监测^[45].

分布式故障诊断主要关注两类系统:一类是由多个子系统互联耦合的大规模系统,二是配备分布式传感器网络的大规模系统.对于第一类系




图5 具有 M 个节点的分布式传感器网络
Fig.5 Distributed sensor network with M nodes

统,故障诊断主要基于系统分解和数据融合、节点间的相关性分析来实现;对于第二类系统,故障诊断主要基于一致性分析来实现,包括分析节点间的相互作用和依赖关系,以及处理数据同步和一致性等。

2.1 基于系统分解的分布式故障诊断方法

基于系统分解的分布式诊断方法多通过将大规模系统分解为多个子块/子层,再融合每个子块/子层的局部信息来实现系统的全局诊断。本节重点从系统分解和数据融合两方面对基于系统分解的分布式故障诊断方法进行介绍。

2.1.1 系统分解的方法

传统的系统分解方法主要基于流程工艺的物理特性进行子块划分,而近年来,数据驱动的分块方法因其高效性和准确性而受到广泛关注。数据驱动的分块方法通过深入分析过程数据的结构特性和过程机理知识,将变量或样本数划分为不同的功能块或组件,从而提取全流程数据的局部变量信息^[46]。文献[47]针对系统的拓扑结构和内在机理知识可得的情况,提出了基于多块核主成分分析的过程监测与故障诊断方法。这一方法利用了系统内部不同部分的机理关联性进行分块,并通过核 PCA 技术对各个子块数据进行多元统计分析。文献[48]进一步拓展了此领域的研究,引入了多级 PCA 的故障诊断技术。该方法不仅考虑了子块数据在单一层级上的统计特性,还将传统的 PCA 扩展为多级形式,实现了同时对同一条生产线的共同特性和不同等级中特定特性的提取和分析。

从上述成果可看出,基于系统分解的故障诊断方法主要针对每个子块的局部特征,对于子系统或通信网络节点之间的数据传输及其对故障检测性能的影响研究尚显不足。文献[49]指出,仅仅在各个子块上建立独立的监测模型,而没有充分考虑到子块之间可能存在的相关性和耦合特征的监测方法,被称为“伪”分布式监测。这种局限性可能导致在实际应用中陷入分散式。

2.1.2 数据融合的方法

为了实现大规模系统的全局诊断,数据的有效融合显得尤为重要。研究者们致力于发展一种“分解-融合”的方法论,首先将复杂的系统或传感器网络分解为多个局部子系统或节点,然后通过融合所有局部信息,形成对系统状态的全局监测^[50]。

数据融合技术中应用较多的是基于分布式卡尔曼滤波器的方法。该方法采用递归方式,根据新的观测数据和前一时刻数据的估计值来更新状态估计误差向量的协方差矩阵,并通过“预测-更新”两个步骤来对系统的状态进行最优估计。文献[51]对分布式卡尔曼滤波器的基本结构和设计方案进行了深入研究。后续研究在此结构的基础上进行了扩展和优化,文献[52]研究了基于集成卡尔曼滤波、融合无迹卡尔曼滤波和融合扩展卡尔曼滤波三种滤波器的分布式故障诊断方法,采用基于分布式数据融合的架构,实现了故障的有效检测和隔离。文献[53]提出了基于共识卡尔曼滤波器的分布式故障检测方案,通过引入动态过程的优化模型来对所有传感器节点的残差向量进行最优融合。贝叶斯推理是另一种数据融合方法,其能够有效地将各个子系统的监测结果融合成一个综合评价指标,实现对子块数据融合,典型流程如图6所示。文献[54]采用子块的并行数据建立了局部监测器来表征局部过程,然后通过贝叶斯推理的技术实现数据的有效融合,从而准确识别过程的故障状态。文献[55]提出了基于贝叶斯推理的系统状态评估方法,该方法首先为每个子系统分配了初始的概率分布并进行动态地调整和优化,这些分布代表了子系统处于不同状态(如正常或故障)的可能性,进而通过融合各子系统的信息得到一个综合评价指标来评估整个系统的状态。




图6 分块 PCA-贝叶斯推理监测流程图
Fig.6 Schematic of multiblock PCA-Bayesian inference monitoring method

综上所述,当前基于系统分解的分布式故障诊断方法的思路为:数据获取、系统分解、局部诊断、全局融合,从数据驱动的角度,通过对大规模系统各节点的分块分析与系统整体的监测,从定

性、定量维度综合评估系统状态. 具体实现步骤概括为: 利用传感器网络的通信拓扑结构, 实现对系统运行状态的数据采集和传输; 采用系统分解技术, 将复杂网络划分为若干子系统; 引进多元统计、动态系统分析等多种手段进行子系统局部故障诊断; 通过卡尔曼滤波、贝叶斯推理等融合局部信息得到综合评价指标, 形成对系统状态的全局监测.

2.2 基于相关性的分布式故障诊断方法

基于系统分解的方法主要对子系统进行独立的信号处理, 未能有效地利用子系统间的相关性信息进行故障诊断. 为了解决该问题, 基于相关性分析的分布式故障诊断方法成为研究热点. 这类方法通过深入探索多个耦合子系统之间的相关性来揭示它们之间的耦合关系, 再根据相关性分析的结果提取出与故障发生相关的特征变量.

考虑到基于系统分解的故障诊断方法多陷入分散式, 基于子块间相关性分析的分布式故障诊断方法得到了广泛的关注. 该方法通过对过程数据的分析、处理和挖掘, 直接从数据中提取能够揭示节点间强相互作用和依赖关系的相关性信息. 文献 [56] 按主成分方向将系统划分为多个耦合的子块, 并在此基础上提出了基于相关性分析的数据驱动分布式故障诊断方法. 文献 [57] 结合变量间的耦合关系和高阶统计信息, 在传感器数量有限的情况下借助相关性分析实现了性能驱动的分布式过程监测. 文献 [58] 针对非线性系统的分布式故障诊断, 利用节点本身和互连节点的信息, 设计了局部故障诊断单元, 并采用自适应算法来逼近相邻子系统的耦合项. 文献 [59] 将概率分布相似的变量归为统一子块, 利用 Hellinger Distance 和贝叶斯概率统计来对非高斯子系统进行诊断.

此外, 互信息是一种常用的变量(特征)选择技术, 其数值可作为两个随机变量相关程度的度量指标. 当两个随机变量之间的互信息量较大时, 表示两者间的关联性较强, 可能存在故障传播的风险. 在基于互信息的分布式故障诊断研究方面, 文献 [60] 首次提出了数据驱动的子块自动分割的方法, 通过互相关信息构建了系统非线性多模块模型. 文献 [61] 利用互信息来获取与每个变量相关的测量值, 这种分块方式可以充分地获取与子块相对应的自相关性与交叉相关性信息. 文献 [62] 指出互信息方法中的一些选定变量可能存在较大的冗余, 这将降低分布式监测的效率, 因此提出了基于最小冗余最大相关性和贝叶斯推理的 PCA 分

布式过程监测方法, 通过最大相关性规则来确定先前所选变量的最大相关性和最小冗余, 从而提高过程的分布式监测效率, 具体实现如图 7 所示, X_t 为 t 时刻系统所具有的信息组成的矩阵, 包含 m 个子系统的信息矩阵 x_t , 通过定义系数 F 来描述每一块与第 i 块间的相关性来实现对系统的自动分块.

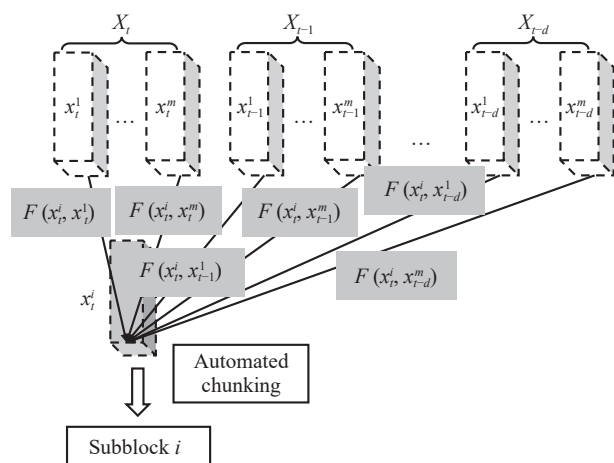


图 7 基于最小冗余最大相关性算法的变量选择与分块
Fig.7 Variable selection and division based on mRMR

分布式 CCA 是另一类典型的基于变量相关性分析的故障诊断方法, 这源于 CCA 本身是一种经典的多变量分析方法, 主要用于探索两组变量之间的线性关系. 针对大规模耦合系统, 文献 [63] 强调了网络拓扑配置和通信链路优化是分布式 CCA 方法的关键问题, 并介绍了一种通过从相邻节点传输压缩的数据来提高传感器通信网络效率的方法. 文献 [64] 利用相邻节点的相关信息来减少局部测量数据的不确定性, 提出了数据驱动的分布式 CCA 故障诊断的实现形式, 并优化了节点间的数据传输成本. 文献 [65] 进一步详细介绍了基于分布式 CCA 的数据驱动故障检测方法, 并用于解决热串联轧钢生产过程监控问题, 这种方法通过使用其他操作节点数据的相关性来检测局部故障, 同时通过通信网络仅传输节点相关性的测量投影, 因此降低了传输成本. 文献 [66] 开发了一种基于遗传算法和 CCA 的分布式局部故障检测方法. 该方法为每个子系统建立了基于遗传算法规范化的 CCA 故障检测器, 旨在以最小的通信成本保持数据的最大相关性的同时, 实现子系统的最优故障检测.

总体来看, 分布式系统的子系统具有“相关性”特点, “相关”在故障诊断中的内涵包括: (1) 节点间具有相互连接的通信拓扑结构, 分布式故障诊断必须全面考虑网络的连通性、冗余度等信息;

(2) 节点间的相互耦合是相关性的重要原因, 互信息等相关性参数作为耦合关系的量化表达, 深刻揭示了各个子系统之间错综复杂的依赖关系和强相互作用. 总之, 通过传感器网络结构、分布式的相关性参数计算和全局优化的策略, 有效地揭示了子系统数据之间的故障模式, 这才符合分布式系统故障诊断中对全局分析的高要求.

2.3 基于一致性的分布式故障诊断方法

一致性问题作为分布式故障诊断领域的基础问题, 对大规模工业生产过程有极其重要的理论意义和实际应用价值. 一致性研究可追溯至 20 世纪 60 年代的管理科学和统计学领域, Benediktsson 和 Swain^[67] 在 1992 年首次将统计一致性理论应用于系统分析领域. 之后, 文献[68]提出了解决动态网络各个节点一致性问题的理论框架, 给出了完善的鲁棒一致性算法. 文献[69]提出达成一致性是多智能体的编队控制方法之一, 即控制系统内所有成员最终收敛至一个相同的状态. 在一致性研究领域, 平均一致性是用于处理分布式优化问题的常用算法之一. 基于平均一致性的故障诊断通过节点间的信息交换与迭代更新, 使各节点的测量值收敛至所有节点的平均值, 这样, 每个节点可以获取所有节点的信息. 具体实现包括: 在迭代过程中, 每个节点除了维护自身的信息外, 还通过通信网络与其他节点交换信息, 并根据邻居节点的状态信息及预设的更新规则来更新自身的值; 在迭代过程之后, 每个节点的在线计算故障检验统计量和阈值通过迭代计算得到的全局信息来执行. 对于含 N 个节点的传感器网络, 每个节点具有 n 个传感器, 每个传感器的测量值构成了第 i 个节点的测量值向量 $\varphi_i \in \mathbf{R}^{1 \times n}$. 平均一致性算法是向量 φ_i 在第 i 个节点的迭代计算:

$$\varphi_{i,k+1} = w_{ii}\varphi_{i,k} + \sum_{j \in \Pi_i} w_{ij}\varphi_{j,k}, i = 1, \dots, N; k = 0, \dots, S \quad (3)$$

其中, 迭代从初始值 $\varphi_{i,0}$ 开始. 向量 $\varphi_{i,k}$ 表示第 i 个节点第 k 次迭代的值, $\varphi_{j,k}$ 表示在第 k 次迭代时从第 j 个节点接收到的值. 在更新每个节点 i 的信息时, 该节点会赋予自身当前值一个特定的权重, 表示为 w_{ii} . 同时, 从它的邻接节点集合 Π_i 中的每一个节点 j 接收信息时, 节点 i 会根据接收到的信息给予不同的权重, 这些权重表示为 w_{ij} . 整个过程在不超过预定义的迭代次数上限 S 的条件下进行, 该上限依据当前迭代所得值与初始值之间的差异来决定, 以确保收敛到预设的精确度. 将每个节点的

第 k 次迭代数据 $\varphi_{i,k}$ 和权重堆叠得到:

$$\Theta_k = \begin{bmatrix} \varphi_{1,k} \\ \vdots \\ \varphi_{N,k} \end{bmatrix} \in \mathbf{R}^{N \times n}, \mathbf{W} = \begin{bmatrix} w_{11} & \cdots & w_{1N} \\ \vdots & \ddots & \vdots \\ w_{N1} & \cdots & w_{NN} \end{bmatrix} \in \mathbf{R}^{N \times N} \quad (4)$$

那么上述算法的迭代终点可以描述为:

$$\lim_{k \rightarrow \infty} \Theta_k = \lim_{k \rightarrow \infty} \mathbf{W}^k \Theta_0 = \frac{\mathbf{1}\mathbf{1}^T}{N} \Theta_0 \quad (5)$$

其中

$$\Theta_0 = \begin{bmatrix} \varphi_{1,0} \\ \vdots \\ \varphi_{N,0} \end{bmatrix} \in \mathbf{R}^{N \times n}, \mathbf{1} = \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix} \in \mathbf{R}^{N \times 1} \quad (6)$$

针对分布式平均一致性算法的收敛性问题, 文献[70]阐述了权重的选择可以加速收敛, 并证明了最快收敛问题可以转化为凸优化问题来解决. 文献[71]针对带有约束的分布式一致性的最优化问题, 系统性地提出了一种基于李雅普诺夫函数的收敛分析范式, 将收敛性的凸优化分析简化为构造李雅普诺夫函数并验证收敛条件.

在分布式故障诊断方面, 文献[72]提出了基于故障检测的平均一致性算法的直观实现, 证明了各个传感器节点上测量平均值的可用性, 算法流程示意图如图 8 所示, 其中, t 为采样时刻, y 为采样数据, k 为采样点. 文献[73]面向具有通信链路故障的互联系统分布式故障诊断问题, 创新地设计了一种针对局部观测器进行优化的分布式算法, 通过动态平均一致性算法在相邻节点之间交换信息, 使每个计算节点都经过迭代收敛到所有子系统残差的平均值. 基于此, 文献[74]提出了完整的分布式故障诊断架构, 此设计架构的核心在于通过平均一致性的迭代计算使得每个节点可以

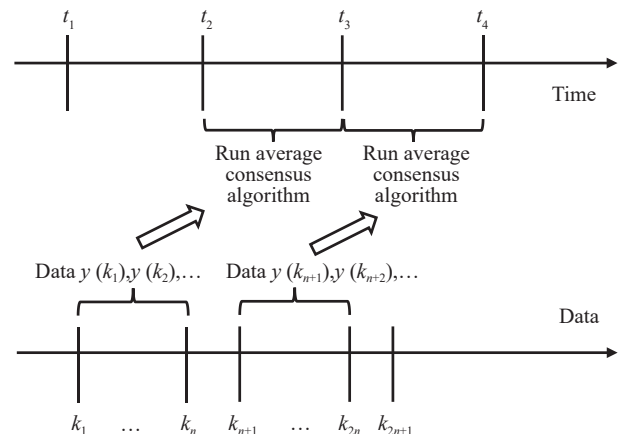


图 8 数据采集和异步渐近一致算法

Fig.8 Data acquisition and asynchronous asymptotic consistency algorithms

获取所有节点信息, 每个子监控系统仅需依赖系统内的局部信息以及其邻近子系统的交互信息即可完成对整体系统的监控与诊断. 这种去中心化的分布式设计模式降低了对单一信息源的依赖, 显著简化了信息处理的复杂度.

在面向实际应用场景时, 一致性的节点异步性问题和迭代的时延问题比较突出. 一致性算法的前提是所有信息都是同步可用的, 但在实际工业生产过程中, 由于传感器位置的不同和采样频率的差异, 获取的数据往往是异步的. 此外, 迭代计算容易导致故障检测的延迟. 针对分布式系统和并行计算的异步渐近一致问题, 文献 [75] 提出了在传感器节点的每次迭代过程进行故障诊断的方法, 从而减少由迭代引起的检测延迟问题. 文献 [76] 提出了一类最优化分布式故障检测方案, 在一致性迭代过程中对随机变量的协方差矩阵进行迭代估计, 并用于计算分布式检验统计量, 从而有效解决了平均一致性方法在线监测阶段的迭代延迟问题.

无论大规模系统的拓扑结构与特性如何错综复杂, 基于一致性故障诊断技术的核心在于促使各节点检验统计量参数通过迭代计算逐步收敛至全局最优. 得益于节点间的高度连通性, 通过逐步的迭代和信息的交互, 每个节点能够获取所有节点的信息, 而这些数据经过迭代处理所达成的一致性结果, 成为了判定系统故障与否的可靠依据. 这样为每个节点都提供了基于系统全局视角的故障诊断依据, 而非仅限于自身测量范围内的局部信息. 采用一致性方法的分布式故障诊断技术, 其未来发展方向聚焦于提高迭代计算的收敛速度、优化通信网络中的数据传输效率, 以及有效处理因迭代计算过程而引发的检测延时问题等.

3 分布式数据驱动故障诊断方法的实际应用

分布式数据驱动故障诊断方法实际过程多应用于复杂流程或大规模监测节点. 表 1 总结了常规案例和实际工业过程信息及其在故障诊断中的应用.

表 1 评估大规模系统故障诊断方法的标准案例和实际过程

Table 1 Standard cases and practical processes for evaluating fault-diagnosis methods for large-scale systems

Form	Name	Number of modes	Number of variables	Number of faults	Refs.
Benchmarks	Tennessee Eastman process	5	53	20	[64–66,76]
	Continuous stirred tank reactor	2	9	6	[45]
	Fluidized catalytic cracking unit	2	335	10	[16]
	Continuous stirred tank heater	5	3	2	[63]
Practical processes	Industrial polyethylene process	3	15	3	[47]
	Annealing furnace system	3	23	1	[40,43]
	Wind energy conversion system	2	10	2	[77]

(1) 田纳西伊斯曼过程 (TE) 数据是基于 TE 化学公司化工生产过程提出的仿真系统. 整个过程主要包含五个操作单元: 反应器、冷凝器、循环压缩机、分离器和汽提塔, 连续过程变量包括 12 个操纵变量和 41 个测量变量, 分为 1 种正常工况以及 21 种故障工况. 在系统工程领域, TE 过程具有多变量、非线性、强耦合等特性, 是验证分布式故障诊断方法的有效数据集.

(2) 百万千瓦级超临界火电发电机组 (Large-scale thermal power unit) 热力系统包括锅炉、汽轮机等主机及辅助设备. 针对我国某座超临界火电厂的 26 个关键变量的故障诊断研究表明, 设备耦合性、系统复杂性及特殊工作环境导致故障率高且表征复杂, 使得难以应用集中式故障诊断方法. 因此, 分布式故障诊断方法在此过程研究中具有

巨大潜力.

(3) 风电机组系统的研究工作主要基于其数据源开展. 风电机组是一种拥有多个子发电机节点的大规模系统, 其运行监测单元通过监测控制系统组成的分布式传感器网络进行监测, 提供了风电机的风速、转速和温度等数据 [77]. 分布式故障诊断系统能够融合多个传感器节点的数据, 进行综合分析, 提高全局故障诊断的准确性和可靠性.

4 结论及展望

分布式数据驱动的故障诊断方法是现代故障诊断技术中的重要组成部分, 它通过集成来自不同数据源的信息, 实现了对大规模工业生产过程实时、准确的故障检测与诊断. 随着工业物联网和大数据技术的快速发展, 分布式数据驱动的故障

诊断方法已成为提高系统可靠性、降低维护成本的关键技术, 受到了工业界和学术界的广泛关注. 本文首先介绍了数据驱动的故障诊断方法的基础理论和研究现状, 包括面向系统稳态和动态特性、面向非线性和非高斯特性等方面的指导性文章和研究成果. 其次, 重点探讨了基于系统分解和数据融合、基于相关性和基于一致性的故障诊断方法, 以及这些方法在准确性、实时性和适用性方面的优势. 在详细探讨中, 注意到以下几个关键点:

(1) 数据驱动方法的适用性: 大规模工业过程往往具有复杂特性, 而数据驱动的方法能够灵活应对这些特性对故障诊断方法带来的挑战, 特别是在系统表现出非线性和非高斯分布特性时.

(2) 分布式方法的潜力: 对于具有相互连接子过程和分布式传感器网络的大规模系统, 分布式方法提供了过程监测和故障诊断的客观条件. 系统分解和数据融合、相关性和一致性分析等技术使得分布式数据驱动方法在大规模工业过程监测和故障诊断中发挥了重要作用.

然而, 尽管这些基于数据驱动的分布式方法在大规模工业生产过程的监测和故障诊断中取得了丰富的成果, 但仍存在一些值得进一步探讨的问题:

(1) 定性定量融合: 单一的数据驱动检测方法直接应用在大规模系统上还存在一些缺陷. 据此, 柴天佑院士提出将定性和定量分析相融合进行诊断的必要性. 如何适当地融合传统过程机理以及专家知识作为数据驱动实施过程中的约束条件, 是一个值得关注的研究方向.

(2) 分布式方法的鲁棒性: 分布式方法在面對系统状态变化、数据噪声、异常值或模型假设偏差时, 其稳定性和可靠性可能受到影响. 因此, 鲁棒性算法、冗余设计以及模型评估与优化等研究, 对于提高分布式方法的鲁棒性和可靠性至关重要.

(3) 数据质量和数据安全问题: 如何确保数据的质量和安全性, 以及在数据传输过程的抗噪性, 是数据驱动的分布式故障诊断方法面临的重要挑战.

综上所述, 尽管分布式数据驱动故障诊断方法在大规模工业过程中展现出巨大潜力, 但仍需进一步研究和探索以克服现有挑战, 并提升故障诊断的准确性和可靠性.

参 考 文 献

- [1] Venkatasubramanian V, Rengaswamy R, Kavuri S N, et al. A review of process fault detection and diagnosis Part III: Process

history based methods. *Comput Chem Eng*, 2003, 27(3): 327

- [2] Timperley J E. Incipient fault identification through neural RF monitoring of large rotating machines. *IEEE Trans Power Appar Sys*, 1983, 102(3): 693
- [3] Ma L, Kang J S, Zhao C Y, et al. Morlet wavelet transform-based signal de-noising and its application in bearing condition monitoring. *Mech Sci Technol Aerosp Eng*, 2014, 33(9): 1345 (马伦, 康建设, 赵春宇, 等. 基于 Morlet 小波变换的信号去噪及在轴承状态监测中的应用. *机械科学与技术*, 2014, 33(9): 1345)
- [4] Chatterjee S, Haque N. Fault analysis in three phase long transmission lines using wavelet transform // *Proceedings of International Conference on Advancements in Power, Communication and Intelligent Systems*. Kannur, 2024: 1
- [5] Kramer M A. Nonlinear principal component analysis using autoassociative neural networks. *AIChE J*, 1991, 37(2): 233
- [6] Chen Q, Dong X J, Tu G W, et al. TFN: An interpretable neural network with time-frequency transform embedded for intelligent fault diagnosis. *Mech Syst Signal Process*, 2024, 207: 110952
- [7] An B T, Wang S B, Zhao Z B, et al. Interpretable neural network via algorithm unrolling for mechanical fault diagnosis. *IEEE Trans Instrum Meas*, 2022, 71: 3517011
- [8] Wang J, Zhang J J, Qu B, et al. Unified architecture of active fault detection and partial active fault-tolerant control for incipient faults. *IEEE Trans Syst Man Cybern*, 2017, 47(7): 1688
- [9] Ge Q B, Cheng H R, Zhang M C, et al. Non-Gaussian feature detection and recognition based on PCA and ICA pattern fusion. *Acta Automa Sin*, 2024, 50(1): 169 (葛泉波, 程惠茹, 张明川, 等. 基于 PCA 和 ICA 模式融合的非高斯特征检测识别. *自动化学报*, 2024, 50(1): 169)
- [10] Muradore R, Fiorini P. A PLS-based statistical approach for fault detection and isolation of robotic manipulators. *IEEE Trans Ind Electron*, 2012, 59(8): 3167
- [11] Yin S, Ding S X, Zhang P, et al. Study on modifications of PLS approach for process monitoring. *IFAC Proc Vol*, 2011, 44(1): 12389
- [12] Zhao C H, Sun Y X. Multispace total projection to latent structures and its application to online process monitoring. *IEEE Trans Control Syst Technol*, 2014, 22(3): 868
- [13] Ma H, Wang Y, Ji Z C, et al. A novel three-stage quality oriented data-driven nonlinear industrial process monitoring strategy. *IEEE Trans Instrum Meas*, 2022, 71: 3524711
- [14] Chen R R, Dong J, Peng K X. Quality-related plant-wide process monitoring based on mutual information-neighborhood preserving embedding-partial least squares for hot strip mill process // *Proceedings of Chinese Control and Decision Conference (CCDC)*. Hefei, 2022: 1466
- [15] Jiang B B, Huang D X, Zhu X X, et al. Canonical variate analysis-based contributions for fault identification. *J Process Control*, 2015, 26: 17
- [16] Chen Z W, Ding S X, Zhang K, et al. Canonical correlation

- analysis-based fault detection methods with application to alumina evaporation process. *Control Eng Pract*, 2016, 46: 51
- [17] Zeng Y Q, Lou Z J. The new PCA for dynamic and non-Gaussian processes // *Proceedings of Chinese Automation Congress*. Shanghai, 2020: 935
- [18] Wang Y, Jiang Q C, Fu J Q. Data-driven optimized distributed dynamic PCA efficient monitoring of large-scale dynamic processes. *IEEE Access*, 2017, 5: 18325
- [19] Zhang J X, Zhou D H, Chen M Y. Monitoring multimode processes: A modified PCA algorithm with continual learning ability. *J Process Control*, 2021, 103: 76
- [20] Bakdi A, Kouadri A. Improved process monitoring using PCA methods and adaptive threshold scheme // *2017 5th International Conference on Electrical Engineering*. Boumerdes, 2017: 1
- [21] Ding X X, Li Q, Cui J R. Subspace method aided fault detection for distributed identical systems // *Proceedings of Chinese Automation Congress (CAC)*. Hangzhou, 2019: 2054
- [22] Van O P, De M B. *Subspace Identification for Linear Systems: Theory Implementation Applications*. Dordrecht: Kluwer Academic Publishers, 1996
- [23] Van Overschee P, De Moor B. *Subspace Identification for Linear Systems*. Boston, MASpringer US, 1996
- [24] Wang J, Qin S J. A new subspace identification approach based on principal component analysis. *J Process Control*, 2002, 12(8): 841
- [25] Li K, Luo H, Yang C M, et al. Subspace-aided closed-loop system identification with application to DC motor system. *IEEE Trans Ind Electron*, 2020, 67(3): 2304
- [26] Ding S X, Zhang P, Naik A, et al. Subspace method aided data-driven design of fault detection and isolation systems. *J Process Control*, 2009, 19(9): 1496
- [27] Ding S X, Yang Y, Zhang Y, et al. Data-driven realizations of kernel and image representations and their application to fault detection and control system design. *Automatica*, 2014, 50(10): 2615
- [28] Li L L, Ding S X, Yang Y, et al. A fault detection approach for nonlinear systems based on data-driven realizations of fuzzy kernel representations. *IEEE Trans Fuzzy Syst*, 2018, 26(4): 1800
- [29] Van Overschee P, De Moor B. Closed-loop subspace system identification // *Proceedings of IEEE Conference on Decision and Control*. San Diego, 1997: 1848
- [30] Huang B, Ding S X, Qin S J. Closed-loop subspace identification: An orthogonal projection approach. *J Process Control*, 2005, 15(1): 53
- [31] Qin S J, Li W H. Detection and identification of faulty sensors in dynamic processes. *AIChE J*, 2001, 47(7): 1581
- [32] Yin S, Ding S X, Haghani A, et al. A comparison study of basic data-driven fault diagnosis and process monitoring methods on the benchmark Tennessee Eastman process. *J Process Control*, 2012, 22(9): 1567
- [33] Ding S X, Zhang P, Huang B, et al. Subspace method aided data-driven design of observer-based fault detection systems. *IFAC Proc Vol*, 2005, 38(1): 167
- [34] Wang Y L, Ma G F, Ding S X, et al. Subspace aided data-driven design of robust fault detection and isolation systems. *Automatica*, 2011, 47(11): 2474
- [35] Tang X C, Zhang Y, Zhang X M, et al. Nonlinear dynamic system based on SAE-LDS model for fault diagnosis // *Proceedings of IEEE Data Driven Control and Learning Systems Conference*. Kaifeng, 2024: 1958
- [36] Chen Z Q, Huang R R, Zhang Z H, et al. Fault estimation for nonlinear systems with disturbance based on reinforcement iterative learning strategy // *Proceedings of IEEE Data Driven Control and Learning Systems Conference*. Kaifeng, 2024: 678
- [37] Schölkopf B, Smola A, Muller K R. Nonlinear component analysis as a kernel eigenvalue problem. *Neural Comput*, 1998, 10(5): 1299
- [38] Rosipal R, Trejo L J. Kernel partial least squares regression in reproducing kernel Hilbert space. *J Mach Learn Res*, 2001, 2(12): 97
- [39] Du W, Li H L, Li X L, et al. ICA of fMRI data: Performance of three ICA algorithms and the importance of taking correlation information into account // *Proceedings of IEEE International Symposium on Biomedical Imaging: From Nano to Macro*. Chicago, 2011: 1573
- [40] Kong X Y, Ge Z Q. Deep learning of latent variable models for industrial process monitoring. *IEEE Trans Ind Inform*, 2022, 18(10): 6778
- [41] Hu W M, Gao J, Li B, et al. Anomaly detection using local kernel density estimation and context-based regression. *IEEE Trans Knowl Data Eng*, 2020, 32(2): 218
- [42] Mori J, Yu J. Quality relevant nonlinear batch process performance monitoring using a kernel based multiway non-Gaussian latent subspace projection approach. *J Process Control*, 2014, 24(1): 57
- [43] Wu Z, Zhang Y, Dong Z. Outlier detection during thermal processes based on improved Gaussian mixture model. *J Syst Simul*, 2023, 35(5): 1020
(吴铮, 张悦, 董泽. 基于改进高斯混合模型的热工过程异常值检测. 系统仿真学报, 2023, 35(5): 1020)
- [44] Yao L N, Yin Z Y, Qin J F. Integrated fault diagnosis and fault tolerant control algorithm for non-Gaussian stochastic distribution systems. *Trans Beijing Inst Technol*, 2014, 34(1): 96
(姚利娜, 阴自阳, 秦记峰. 非高斯随机分布系统的集成故障诊断与容错控制. 北京理工大学学报, 2014, 34(1): 96)
- [45] Yang X, Gao J J, Huang B. Data-driven design of fault detection and isolation method for distributed homogeneous systems. *J Frankl Inst*, 2021, 358(9): 4929
- [46] Li C, Li G, Chen X, et al. A multiblock kernel dynamic latent variable model for large-scale industrial process monitoring. *IEEE Trans Instrum Meas*, 2022, 71: 3529910
- [47] Zhang L F, Xie L B. Fault detection and identification based on kernel principal component analysis with multi-block information extraction // *Proceedings of Chinese Control Conference*. Hefei,

- 2022: 5560
- [48] Zhou L, Chen J, Hou B P, et al. Multi-grade principal component analysis for fault detection with multiple production grades. *Chemom Intell Lab Syst*, 2018, 175: 20
- [49] Wan X C, Tong C D, Shi X H. Decentralized non-Gaussian process monitoring scheme based on multi-block modified ICA algorithm. *Inf Control*, 2020, 49(4): 464
(万新春, 童楚东, 史旭华. 基于多块修正 ICA 算法的分散式非高斯过程监测方法. 信息与控制, 2020, 49(4): 464)
- [50] Khatib S, Daoutidis P. Generating optimal overlapping subsystems for distributed statistical fault detection subject to constraints. *J Process Control*, 2019, 80: 143
- [51] Olfati-Saber R. Distributed Kalman filter with embedded consensus filters // *Proceedings of IEEE Conference on Decision and Control*. Seville, 2005: 8179
- [52] Shaheen K, Chawla A, Uilhoorn F E, et al. Sensor-fault detection, isolation and accommodation for natural-gas pipelines under transient flow. *IEEE Trans Signal Inf Process Netw*, 2024, 10: 264
- [53] Xin D J, Shi L F, Yu X K. Distributed Kalman filter with faulty/reliable sensors based on Wasserstein average consensus. *IEEE Trans Circuits Syst II Express Briefs*, 2022, 69(4): 2371
- [54] Jiang Q C, Huang B. Distributed monitoring for large-scale processes based on multivariate statistical analysis and Bayesian method. *J Process Control*, 2016, 46: 75
- [55] Zhu J, Ge Z Q, Song Z H. Distributed Gaussian mixture model for monitoring multimode plant-wide process // *Proceedings of Chinese Control and Decision Conference*. Yinchuan, 2016: 5826
- [56] Ge Z Q, Song Z H. Distributed PCA model for plant-wide process monitoring. *Ind Eng Chem Res*, 2013, 52(5): 1947
- [57] Jiang Q C, Yan X F, Huang B. Performance-driven distributed PCA process monitoring based on fault-relevant variable selection and Bayesian inference. *IEEE Trans Ind Electron*, 2016, 63(1): 377
- [58] Ferrari R M G, Parisini T, Polycarpou M M. Distributed fault diagnosis with overlapping decompositions: An adaptive approximation approach. *IEEE Trans Autom Control*, 2009, 54(4): 794
- [59] Jiang Q C, Wang B, Yan X F. Multiblock independent component analysis integrated with hellinger distance and Bayesian inference for non-Gaussian plant-wide process monitoring. *Ind Eng Chem Res*, 2015, 54(9): 2497
- [60] Jiang Q C, Yan X F. Plant-wide process monitoring based on mutual information-multiblock principal component analysis. *ISA Trans*, 2014, 53(5): 1516
- [61] Tong C D, Lan T, Shi X H. Fault detection by decentralized dynamic PCA algorithm on mutual information. *CIESC J*, 2016, 67(10): 4317
(童楚东, 蓝艇, 史旭华. 基于互信息的分散式动态 PCA 故障检测方法. 化工学报, 2016, 67(10): 4317)
- [62] Xu C, Zhao S Y, Liu F. Distributed plant-wide process monitoring based on PCA with minimal redundancy maximal relevance. *Chemom Intell Lab Syst*, 2017, 169: 53
- [63] Jiang Q C, Gao F R, Yan X F, et al. Multiobjective two-dimensional CCA-based monitoring for successive batch processes with industrial injection molding application. *IEEE Trans Ind Electron*, 2019, 66(5): 3825
- [64] Chen Z W, Cao Y, Ding S X, et al. A distributed canonical correlation analysis-based fault detection method for plant-wide process monitoring. *IEEE Trans Ind Inf*, 2019, 15(5): 2710
- [65] Zhang K, Peng K X, Ding S X, et al. A correlation-based distributed fault detection method and its application to a hot tandem rolling mill process. *IEEE Trans Ind Electron*, 2020, 67(3): 2380
- [66] Jiang Q C, Ding S X, Wang Y, et al. Data-driven distributed local fault detection for large-scale processes based on the GA-regularized canonical correlation analysis. *IEEE Trans Ind Electron*, 2017, 64(10): 8148
- [67] Benediktsson J A, Swain P H. Consensus theoretic classification methods. *IEEE Trans Syst Man Cybern*, 1992, 22(4): 688
- [68] Olfati-Saber R, Murray R M. Consensus problems in networks of agents with switching topology and time-delays. *IEEE Trans Autom Control*, 2004, 49(9): 1520
- [69] Jia Y N, Li Q. Research development of multi-robot formation control. *Chin J Eng*, 2018, 40(8): 893
(贾永楠, 李擎. 多机器人编队控制研究进展. 工程科学学报, 2018, 40(8): 893)
- [70] Xiao L, Boyd S, Kim S J. Distributed average consensus with least-mean-square deviation. *J Parallel Distrib Comput*, 2007, 67(1): 33
- [71] Liang S, Peng K X. Distributed gradient-based consensus optimization algorithm and convergence analysis. *Chin J Eng*, 2020, 42(4): 434
(梁舒, 彭开香. 分布式一致性最优化的梯度算法与收敛分析. 工程科学学报, 2020, 42(4): 434)
- [72] Ding S X. *Advanced Methods for Fault Diagnosis and Fault-tolerant Control*. Berlin: Springer, 2021
- [73] Wang H, Luo H, Jiang Y C, et al. Distributed fault diagnosis approach for large-scale interconnected systems with communication link failures // *Proceedings of IEEE International Conference on Industrial Cyber-Physical Systems*. Wuhan, 2023: 1
- [74] Wang H, Luo H, Ren L, et al. Data-driven design of distributed monitoring and optimization system for manufacturing systems. *IEEE Trans Ind Inform*, 2024, 20(7): 9455
- [75] Tsitsiklis J, Bertsekas D, Athans M. Distributed asynchronous deterministic and stochastic gradient optimization algorithms. *IEEE Trans Autom Control*, 1986, 31(9): 803
- [76] Li L L, Ding S X, Peng X. Distributed data-driven optimal fault detection for large-scale systems. *J Process Control*, 2020, 96: 94
- [77] Fenton W G, McGinnity T M, Maguire L P. Fault diagnosis of electronic systems using intelligent techniques: A review. *IEEE Trans Syst Man Cybern Part C (Appl Rev)*, 2001, 31: 269