



中国科技期刊卓越行动计划项目入选期刊

控制与决策

CONTROL AND DECISION

从分解视角出发:基于多元统计方法的工业时序建模与过程监测综述

赵春晖, 陈旭

引用本文:

赵春晖,陈旭. 从分解视角出发:基于多元统计方法的工业时序建模与过程监测综述[J]. *控制与决策*, 2024, 39(11): 3521–3546.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2024.0698>

您可能感兴趣的其他文章

Articles you may be interested in

基于自适应混合核典型变量分析的工业过程质量相关故障检测

Quality-related fault detection for industrial processes based on adaptive mixed kernel canonical variable analysis

控制与决策. 2021, 36(4): 801–807 <https://doi.org/10.13195/j.kzyjc.2020.0690>

基于核典型相关性-熵成分分析的工业过程质量监测方法

A quality monitoring method for industrial process based on kernel canonical correlation-entropy component analysis

控制与决策. 2021, 36(12): 2999–3006 <https://doi.org/10.13195/j.kzyjc.2020.0548>

基于马尔可夫过程的多部件系统劣化状态空间划分模型

Multi-component system state space partition model based on Markov process

控制与决策. 2021, 36(2): 418–428 <https://doi.org/10.13195/j.kzyjc.2019.0480>

面向工业软测量应用的定制化生成对抗数据填补模型

Customized generative adversarial data imputation model for industrial soft sensing

控制与决策. 2021, 36(12): 2929–2936 <https://doi.org/10.13195/j.kzyjc.2020.0974>

基于广义主成分分析的重构故障子空间建模方法

Reconstructed fault subspace modelling method based on generalized principal component analysis

控制与决策. 2021, 36(4): 808–814 <https://doi.org/10.13195/j.kzyjc.2019.0818>

从分解视角出发：基于多元统计方法的工业时序建模与过程监测综述

赵春晖[†], 陈旭

(浙江大学 控制科学与工程学院, 杭州 310027)

摘要: 数据驱动的过程监测是确保工业过程安全运行的重要手段。工业数据大多以时间序列的形式存在。由于工艺复杂性、噪声干扰等影响,工业时间序列往往呈现出低质量、强动态和非平稳等特性,给监测模型的建立带来了困难。尽管研究学者针对不同特性分别提出了相关方法,但这些方法之间的内在关联几乎没有被挖掘。鉴于此,揭示这些方法所蕴含的共性出发点:在工业过程中,仅知晓故障存在与否往往难以满足实际需求,需要对复杂时间序列特性进行深度分解,以实现过程状态多方面的精细感知;从一种分解的视角出发,综述现有多元统计方法如何针对时间序列各类复杂特性进行建模,通过将复杂的时间序列分解成多个具有实际物理意义的成分,提供可解释的监测结果;总结提炼不同建模方法的核心分解思想并进行对比,并针对各类方法梳理监测统计量的构造与含义;最后,对工业时间序列分解建模工作进行总结和展望,提出未来研究方向。

关键词: 工业时间序列; 分解建模; 过程监测; 低质量特性; 动态特性; 非平稳特性; 研究综述

中图分类号: TP277

文献标志码: A

DOI: 10.13195/j.kzyjc.2024.0698

引用格式: 赵春晖,陈旭. 从分解视角出发: 基于多元统计方法的工业时序建模与过程监测综述[J]. 控制与决策, 2024, 39(11): 3521-3546.

From the decomposition perspective: A survey of industrial time series modeling and process monitoring based on multivariate statistical methods

ZHAO Chun-hui[†], CHEN Xu

(College of Control Science and Engineering, Zhejiang University, Hangzhou 310027, China)

Abstract: Data-driven process monitoring is a crucial means to ensure the safe operation of industrial processes. Most industrial data exists in the form of time series. Due to the complexity of mechanism, noise interference, and other factors, industrial time series often exhibit characteristics such as low quality, strong dynamics, and nonstationary characteristics, which pose challenges to the establishment of monitoring models. Although researchers have proposed relevant methods addressing different characteristics, the intrinsic connections between these methods have hardly been explored. This paper reveals, for the first time, the common motivation underlying these methods: in industrial processes, merely knowing the presence or absence of a fault often fails to meet actual needs. It is necessary to deeply decompose the complex characteristics of time series to achieve a comprehensive perception of the process state. Innovatively adopting a decomposition perspective, this paper reviews existing multivariate statistical methods for modeling various complex characteristics of time series. By decomposing complex time series into multiple components with practical physical significance, the paper provides interpretable monitoring results. It summarizes and compares the core decomposition ideas of different modeling methods. Subsequently, the paper elucidates the construction and implications of monitoring statistics for various methods. Finally, this paper summarizes and forecasts the work on decomposing and modeling industrial time series, proposing future research directions.

Keywords: industrial time series; decomposition modeling; process monitoring; low quality characteristic; dynamic characteristic; nonstationary characteristic; survey

收稿日期: 2024-06-12; 录用日期: 2024-08-14.

基金项目: 国家自然科学基金杰出青年基金项目(62125306); 浙江省“尖兵”“领雁”研发攻关计划项目(2024C01163).

[†]通讯作者. E-mail: chhzhao@zju.edu.cn.

0 引言

工业是国民经济的主体,对国家发展有着重要意义.随着生产需求不断增长且呈现多样化趋势,现代工业正朝着规模化、复杂化、一体化的方向发展.然而,这种发展也为工业过程的安全稳定运行带来了严峻挑战.现代工业的多个系统、设备紧密相连,形成了一个复杂的网络,牵一发而动全身.一旦发生故障,它往往不仅仅局限于单个设备或系统,而是会迅速蔓延至相邻的设备,甚至整个系统.这种故障传播特性可能导致级联效应,造成更严重的故障或系统崩溃.因此,对工业过程进行实时监测,及时发现故障并给出警报,确保生产过程安全至关重要^[1-6].

随着人工智能、物联网和数据库技术的发展,基于数据驱动的过程监测方法为工业过程的安全可靠运行提供了保障,在工业界和学术界都获得了广泛关注^[7-18].首先,通过传感器等设备收集过程中的海量变量,包括温度、压力、流量、浓度等多个参数;然后基于所收集的数据,使用多元统计分析方法,包括主成分分析(principal component analysis, PCA)^[11-12]、偏最小二乘(partial least squares, PLS)^[14-16]和典型相关分析(canonical correlation analysis, CCA)^[17-18]等,建立监测模型.通过分析变量的复杂特性,探寻各个设备系统间的潜在关联,挖掘出工业过程运行模式,从而实时监测和评估工业过程的运行状态.通过监测关键指标、识别异常行为和潜在故障,过程监测可以提供及时的警报和反馈,指导操作人员对异常部件进行检修,从而保证工业过程的安全性和可靠性^[9-10].

所采集的工业过程数据通常以时间序列的形式呈现^[19-21].时间序列是指按照时间顺序记录的一系列数据点,每个数据点表示在特定时间点上观测到的某个变量的取值,反映了工业过程的动态变化和演化趋势.工业时间序列数据具有多种特性,给过程监测模型的建立带来了挑战^[22-25].首先,受外部干扰或信号传输故障等因素影响,工业过程中采集的时间序列可能存在噪声和异常值,呈现低质量特性,这会导致模型参数估计不准确,从而影响模型鲁棒性^[26-29];其次,工业时间序列存在动态特性,也称作时序相关性,即当前时刻的数据与之前时刻的数据相关^[30-37].对动态性的忽略会使模型无法利用过去观测值对未来观测值进行预测或解释,从而导致故障误报和漏报.另外,随着时间的推移,工业时间序列的统计特性和分布可能发生变化,呈现典型的非平稳特性.受非平稳特性影响,先前建立的监测模型不再适用于新的过程数据,导致模型失配难题^[38-41].

如何考虑工业时间序列数据复杂特性的影响来建立可靠的过程监测模型,已经受到大量学者的关注,并得到了一定的发展^[42-43].然而,领域内近期的研究综述往往针对时间序列某一特性进行阐述.比如,文献[34, 42]针对工业数据的动态特性对现有方法进行综述;文献[40]围绕工业过程数据的非平稳时变特性梳理现有研究.但上述综述研究缺乏从工业时间序列多种复杂特性的统一视角进行全面系统地梳理,难以揭示不同特性处理方法之间的关联关系.尽管处理不同时序特性所采用的方法各不相同,但它们都存在一种化繁为简、分而治之的共性思想.依据所分析的复杂特性,将工业时间序列分解成具有不同物理意义的成分并建立监测模型,从而提供细粒度、可解释的过程运行状态识别结果.

本文从统一的分解视角出发,按照时间尺度由小到大的顺序,系统综述针对不同类型时序特性的多元统计分析方法.文章整体架构如图1所示.第1节介绍工业过程时间序列的表示方法以及时序数据的各类复杂特性.第2节梳理针对低质量特性的时序分解建模方法,该类方法可以将时间序列样本分解为干净数据和异常值.第3节梳理针对动态特性的时序分解建模方法,该类方法考虑一段时序样本中存在的时序相关性,将其分解为时序相关特征和时序无关特征.第4节着眼于更长时间尺度的数据,梳理针对非平稳特性的时序分解建模方法,该类方法可以将时间序列分解为时不变特征与时变特征.第5节梳理各类方法分解视角下的统计量构建与监测策略.第6节讨论不同方法之间的内在关联.第7节探讨工业时间序列分解建模的研究展望.本文主要贡献点总结如下:

1) 以工业时间序列为分析对象,从分解的统一视角对时序数据中针对低质量特性、动态特性和非平稳特性的过程监测方法进行全面综述.依据不同的分解角度,将各类多元统计方法进行系统地梳理分类,并总结出这些方法化繁为简的共性理念.

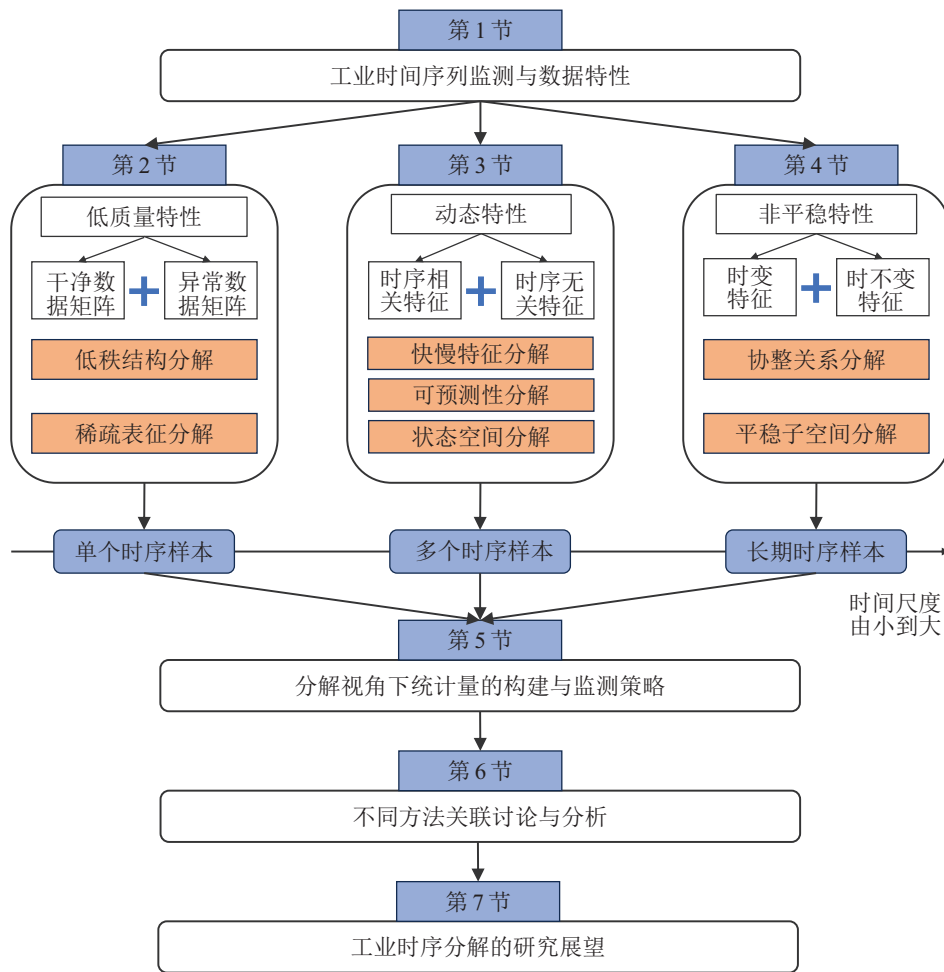
2) 通过对工业时间序列建模与监测研究现状的梳理,展望复杂时序分解建模领域未来的发展,包括混合异构与知识数据融合的建模挑战以及时序分解建模的拓展应用,为后续研究提供基础和参考.

1 工业时间序列监测与数据特性

本节先介绍工业时间序列数据的表示形式与监测模型的建立,再介绍时序数据的各类复杂特性.

1.1 工业时序数据表示与监测

在工业过程中,温度、压力、流速等变量可以反映生产参数和工艺状态的重要信息.基于这些变量,可



以评估过程的运行状态,对于确保生产过程的安全性、稳定性和高效性发挥着关键作用^[43].借助工业物联网和数据库存储等先进技术手段,这些观测值能够以时间序列的形式被准确记录.具体而言,在同一时刻,对各个变量的观测值进行记录,从而构建一个完整样本,记作 $\mathbf{x}_t = [x_{t,1}, x_{t,2}, \dots, x_{t,m}]^T$. 其中: \mathbf{x}_t 为第 t 个时刻所记录的样本, $x_{t,i}$ ($1 \leq i \leq m$) 为该样本第 i 个变量的观测值, m 为变量个数. 进行一段时间的记录后可获得二维时间序列矩阵,记作 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N] \in \mathbb{R}^{m \times N}$, 其中 N 为样本个数. 在一些研究方法中,也可将 \mathbf{X} 进行转置来表示,即 $\mathbf{X}^T \in \mathbb{R}^{N \times m}$, 每一行表示一个样本.

对于工业时序过程监测,PCA是最常用的模型之一^[11-12],下面以PCA为例介绍建立监测模型的一般步骤.给定标准化后的时间序列矩阵 $\mathbf{X} \in \mathbb{R}^{m \times N}$,PCA的目标是寻找投影方向 \mathbf{p} ,使得特征的方差最大化,可以表示为如下优化问题:

$$\begin{aligned} & \max_{\mathbf{p}} \mathbf{p}^T \mathbf{X} \mathbf{X}^T \mathbf{p}; \\ & \text{s.t. } \mathbf{p}^T \mathbf{p} = 1. \end{aligned} \quad (1)$$

通过拉格朗日乘法,可将上述问题转化为特征值求解问题,即通过对 $\mathbf{X} \mathbf{X}^T$ 做特征值分解求得一系列的投影方向 \mathbf{p}_i ($1 \leq i \leq m$),使得所提取的特征 $\mathbf{t}_i = \mathbf{p}_i^T \mathbf{X}$ 按照方差大小降序排列.记 $\mathbf{P} = [\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_A]^T$,其中 A 为主成分个数,对于每个样本 \mathbf{x} ,其主成分特征和残差量表示为

$$\mathbf{t} = \mathbf{P} \mathbf{x}, \quad (2)$$

$$\mathbf{e} = (\mathbf{I} - \mathbf{P}^T \mathbf{P}) \mathbf{x}, \quad (3)$$

其中 \mathbf{I} 表示单位矩阵.

构建 T^2 和 SPE 统计量如下:

$$T^2 = \mathbf{t}^T \mathbf{S}^{-1} \mathbf{t}, \quad (4)$$

$$\text{SPE} = \mathbf{e}^T \mathbf{e}, \quad (5)$$

其中 $\mathbf{S} = \text{diag}\{\lambda_1, \lambda_2, \dots, \lambda_A\}$ 为对角矩阵,由 $\mathbf{X} \mathbf{X}^T$ 的前 A 个特征值构成.

通过检验假设或核密度估计(kernel density estimation, KDE)^[13]可以获得这些统计量的控制限.如果样本的统计量超过对应的控制限,则认为可能发生了故障.

尽管基于PCA的过程监测方法在实践中得到了

广泛应用,但该方法存在较强的前提假设.具体而言,基于PCA的过程监测方法通常假设工业过程是静态的和平稳的,即过程变量不存在显著的时序相关性,且过程在某一工作点稳定运行.此外,该方法还假设时序数据中不存在异常值干扰的情况.然而,实际工业过程往往较为复杂,工业时序数据具有多种特性,包括低质量特性、动态特性和非平稳特性.在这些复杂特性的影响下,基于PCA的监测模型容易失效,造成大量的误报和漏报.下面将对这些特性进行详细介绍.

1.2 时序数据的低质量特性

由于测量设备的误差、信号干扰以及传输失误等原因,在工业过程中采集的时间序列数据往往会受到噪声和异常值的污染,呈现低质量特性,这给建立鲁棒的过程监测模型带来了挑战^[27-29].如图2所示,工业时序数据存在多种污染情况,其中黑色和灰色方块表示受污染数据点,白色方块表示未受影响的数据点.图2(a)展示了随机异常值的影响,即二维时间序列矩阵中的每个元素都可能被污染而明显偏离正常范围,但总体上异常值数量较少,且分布具有稀疏性和随机性.图2(b)展示了样本损坏的情况,即在某个时刻所有变量都偏离正常范围,异常值分布呈现出典型的列相关.与之相似的是,当特定传感器或测量设备出现故障时,将导致某一变量的数据在一段时间内持续异常,异常值的分布呈现典型的行相关.图2(c)展示了噪声污染的情况,矩阵中几乎每个数据元素都会受到不同程度的影响.然而,与异常值不同,这些影响并不会导致数据呈现明显偏离.对于不同的低质量情况,需要使用对应方法对时序数据进行建模.




图2 工业时间序列数据污染情况

1.3 时序数据的动态特性

受系统耦合和复杂闭环反馈系统的影响,工业时间序列数据往往表现出明显的动态特性,也称作时序相关性^[34,42].这种时序相关性与过程的内在运行

机制密切相关.比如,在工业过程中,当输出值与设定值之间存在误差时,控制系统会调节操作指令和过程输入形成闭环回路,闭环回路之间的变量相互耦合会在时间上表现出滞后,这将导致工业时序数据呈现显著动态特性.如图3所示,对于具有动态特性的时间序列,每个时刻的样本 x_t 都与之前若干时刻的样本 $x_{t-1} \sim x_{t-d}$ 相关,而不是孤立的样本点.动态特性指示了工业数据的时序相关关系,体现了可预测部分的信息.与之相对的,时序无关的特性称为静态特性,指示了同时刻内变量的互相关关系.动态信息和静态信息对应着工业时间序列不同的物理含义,对于动态时序数据监测,需要充分利用这两种信息来全面指示过程运行状态变化.




图3 工业时间序列的动态特性

1.4 时序数据的非平稳特性

鉴于生产条件的变化、外界未知干扰以及设备开关等因素的影响,工业过程无法始终保持在一个稳定的工作点,而是在多个工作点之间进行切换,从而导致时间序列呈现出典型的非平稳特性^[40].在分析非平稳特性之前,需要先了解时间序列中关于平稳性的定义.严格来说,平稳过程要求随机过程的统计性质不随时间改变^[44],但这在实际工业过程中几乎无法达到.因此,工业过程中常使用宽平稳的定义,只要求其一阶和二阶统计特性不随时间变化^[45].具体而言,对于 m 维度时序样本 x_t ,宽平稳要求其满足

$$E(x_t) = \mu, \text{Var}(x_t) = \sigma^2,$$

$$\text{Cov}(x_t, x_{t+k}) = \text{Cov}(x_{t+h}, x_{t+h+k}) = \rho. \quad (6)$$

其中: μ 和 σ^2 分别表示均值和方差,且不随时间变化;自协方差 ρ 仅与时间差有关.

在实际工业过程中,当工况在多个工作点切换时,时序数据的均值、方差等都随时间发生了改变,可认为是非平稳时间序列.一方面,非平稳特性导致先前建立的过程监测模型无法捕获变化后数据的特性,引发模型失配问题.另一方面,大范围变化的非平稳时间序列可能会掩盖故障早期的微弱迹象,导致故障漏报现象^[40].因此,如何针对非平稳特性对时间序列进行建模和分析是一个极具挑战的问题.

对于时间序列中存在的低质量特性、动态特性和非平稳特性,目前已有学者分别设计了针对性的时

序建模方法.虽然这些方法对于不同特性的处理方式也有所不同,但均存在化繁为简的分解思想.这些方法通过将时序数据分解成具有多个可解释因子的成分,揭示了复杂时序特性中所蕴含的物理意义,并提供了精细化的监测结果.在下面的章节中,本文将从统一的分解视角出发,对现有针对低质量特性、动态特性和非平稳特性的时间序列分解建模与监测方法进行梳理和对比.

2 低质量时序数据建模方法

如前文所述,受环境干扰、信号传输失误等因素影响,工业时间序列数据中可能存在异常值和噪声,给过程监测模型的建立带来诸多挑战.一方面,它们

会导致模型参数估计的不准确性,影响模型的精度;另一方面,异常值和噪声也会干扰监测统计量控制限的确定,进而影响到过程监测的有效性^[27].为克服时序数据低质量特性影响,建立鲁棒的过程监测模型,已有大量学者提出了相关方法.本节先对现有的几类方法进行对比和梳理,再详细介绍基于分解视角的低质量时序数据建模方法.

2.1 低质量时序数据建模方法综述

本节将低质量时序数据建模方法梳理总结为4大类,包括基于样本处理的方法、基于优化项调节的方法、基于概率建模以及分解建模方法.总体类别框架以及代表性方法如图4所示.

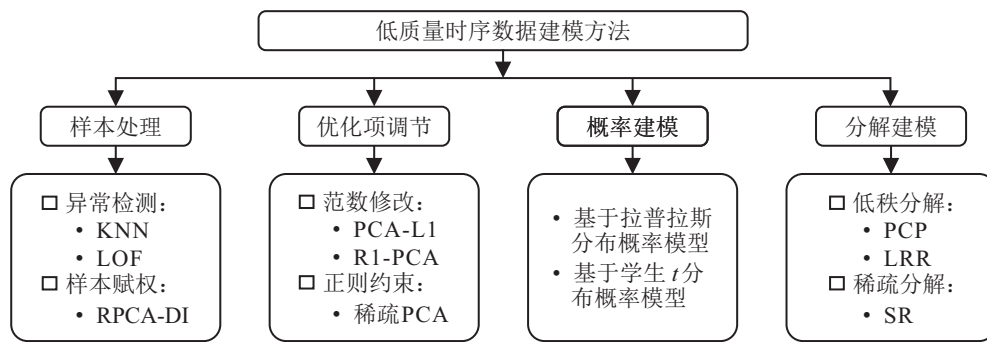


图4 低质量时序数据建模方法类别与代表性方法

基于样本处理的方法可进一步分为异常检测和样本赋权两种类别.通过 K 近邻(K -nearest neighbor, KNN)^[46]或者局部离群因子(local outlier factor, LOF)^[47]等异常检测方法,可筛选出包含异常值的样本并进行剔除,只保留干净样本用于建立过程监测模型.但是,直接删除带有异常值的样本可能会导致信息损失.相比于异常检测,样本赋权采用一种软处理手段,对受到较大影响的样本赋予更小的权重,该类方法的关键在于如何评价样本的受影响程度.比如,Gao等^[48]设计了一种判别信息提取方法,提出一种基于判别信息的鲁棒主成分分析法(robust principal component analysis based on discriminant information, RPCA-DI),对样本赋予不同的权重以实现鲁棒建模.这种方法虽然可以在一定程度上缓解异常值对模型的影响,但模型本身并未具备足够的鲁棒性.

基于优化项调节的方法通过直接调节模型的优化目标,将异常值处理嵌入到模型训练过程中,确保模型在面对异常值时仍能保持较高的稳定性.该方法可进一步分为范数修改和正则化约束两种类别.范数修改的方法主要涉及对优化目标中的范数进行调整.例如,将传统PCA优化目标中的2-范数替换为1-范数(PCA-L1)^[49]或2,1-范数(R1-PCA)^[50].在

优化问题中2-范数由于其平方项的特性,对异常值具有放大作用,从而导致模型对异常值极为敏感.相比之下,1-范数对异常值的反应更加平缓.范数修改方法的核心在于,通过改变误差度量方式使模型在面对异常值时表现出更高的鲁棒性,避免被极端值所主导.正则化约束的方法通过引入额外的正则化项来约束模型参数,从而避免模型过拟合^[51-52].比如,1-范数正则化通过在优化目标中额外加入参数的绝对值总和,促使模型产生稀疏解,即多数参数趋于零,从而提升模型的简洁性和泛化能力.

基于概率建模的方法通过引入潜变量和显式的概率分布来表述数据生成过程,并通过最大似然估计等技术对模型参数进行优化.通过在概率框架中使用拉普拉斯分布^[53]或学生 t 分布^[54]可增强模型的鲁棒性,实现对低质量时间序列的建模.这些分布的共同特点是具有较重的尾部,相较于高斯分布对异常值更为宽容.这意味着在处理异常值时,给予的惩罚较小,不会过度放大异常值的影响.

然而,上述方法并未从根本上将异常值和噪声从数据中分离出来,它们在一定程度上仍然会受到二者的干扰.相比之下,分解建模的方法可以将数据中的有用信息与外部干扰进行有效解耦.通过这种方法,

模型不仅能够准确捕捉数据的主要结构和特征,还能显著降低异常值和噪声对分析结果的负面影响,从而实现鲁棒的时序数据建模. 本文依据分解准则的不同,将现有的基于分解建模方法分为两类:基于低秩分解和稀疏分解的方法,下面将对这两类方法进行详细介绍与分析.

2.2 低秩结构分解方法

基于低秩分解方法的核心思想是,通常情况下收集到的变量是冗余且高度相关的,因此干净的数据矩阵具有低秩结构^[27]. 对于受到污染的原始数据矩阵,只需要分解出具有低秩结构的矩阵,剩余的即为异常值矩阵. 主成分追踪(principal component pursuit, PCP)和低秩表示方法(low-rank representation, LRR)是这类方法的典型代表^[26-29,55-59],围绕PCP和LRR,现有工作展开了一系列关于鲁棒过程监测的研究和改进. 下面详细介绍PCP和LRR算法,并介绍两者的关联.

2.2.1 主成分追踪方法

给定矩阵 $\mathbf{X} \in \mathbb{R}^{m \times N}$. 其中: m 为变量个数, N 为样本个数, \mathbf{X} 中的每一列都表示一个样本. 如图5所示,PCP的目标是将 \mathbf{X} 分解为一个低秩矩阵 \mathbf{L} 和一个异常值矩阵 \mathbf{S} ,要求 \mathbf{L} 的秩尽可能小,且异常值矩阵 \mathbf{S} 尽可能稀疏,表示为

$$\begin{aligned} \min_{\mathbf{L}, \mathbf{S}} \quad & \text{rank}(\mathbf{L}) + \lambda \|\mathbf{S}\|_0; \\ \text{s.t.} \quad & \mathbf{X} = \mathbf{L} + \mathbf{S}. \end{aligned} \quad (7)$$

其中: $\lambda > 0$ 为一个可调节权重参数, $\|\cdot\|_0$ 表示0-范数,即非零元素的个数. PCP假设异常值个数较少,所以在异常值矩阵 \mathbf{S} 上加了稀疏化约束. 如图5所示,橙色单元格表示异常值,分布较为稀疏. 由于上式难以求解,通常情况下,PCP使用核范数和1-范数代替上式中秩和0-范数的最小化目标,将非凸优化问题转化为一个凸优化问题,表达如下:

$$\begin{aligned} \min_{\mathbf{L}, \mathbf{S}} \quad & \|\mathbf{L}\|_* + \lambda \|\mathbf{S}\|_1; \\ \text{s.t.} \quad & \mathbf{X} = \mathbf{L} + \mathbf{S}. \end{aligned} \quad (8)$$

其中: $\|\cdot\|_*$ 表示核范数,用于衡量矩阵奇异值的求和; $\|\cdot\|_1$ 表示1-范数.

原始的PCP算法假设工业时间序列受稀疏的随机异常值的影响,因此使用1-范数描述异常值矩阵的稀疏性. 然而,如图2所示,工业时序数据也可能受到样本损坏和噪声的影响. 当样本损坏时,异常值的分布呈现明显的列相关性. 而在噪声污染的情况下,矩阵中的大部分元素都会受到影响. 此时,仍使用1-范

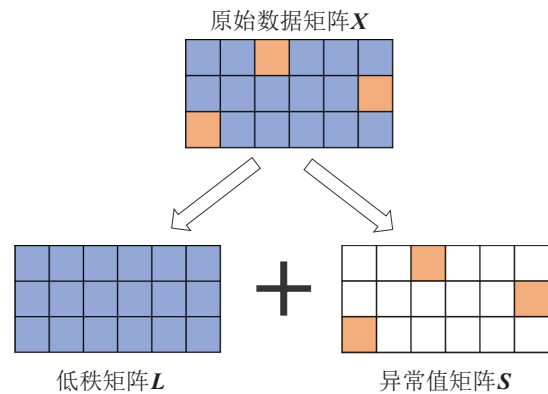


图5 基于PCP的分解思路

数来约束异常值矩阵的稀疏性是不合理的,并且分解结果也不准确. 为了应对不同的异常值情况,可以调整PCP算法中对异常值矩阵的约束范数,以适应不同的场景. 对于图2(b)中展示的样本损坏情况,可以使用2,0-范数或2,1-范数来约束列的稀疏性^[60-61]. 对于图2(c)所示的噪声影响情况,可使用 F -范数来约束噪声矩阵(原本PCP算法中的异常值矩阵)所有元素平方和的平方根,即要求噪声的总和要尽可能小^[62]. 上述时间序列分解方法都假设仅存在一种数据污染情况. 在实际工业过程中,异常值和噪声可能会同时出现,原始时间序列可以被分解为3部分,即干净数据矩阵、异常值矩阵以及噪声矩阵. 为了同时考虑异常值和噪声的影响,Zhou等^[63]对PCP进行改进,提出稳定主成分追踪(stable PCP, SPCP),实现了多种污染影响下的数据复原. SPCP将原始时间序列分解为3部分,其优化目标如下:

$$\min_{\mathbf{L}, \mathbf{S}} \|\mathbf{L}\|_* + \lambda_1 \|\mathbf{S}\|_1 + \frac{\lambda_2}{2} \|\mathbf{X} - \mathbf{L} - \mathbf{S}\|_F^2. \quad (9)$$

其中: λ_1 和 λ_2 为权重参数, $\|\cdot\|_F$ 为 F -范数, $\mathbf{X} - \mathbf{L} - \mathbf{S}$ 表示原始时间序列分解出干净数据矩阵和异常值矩阵后剩余的噪声部分.

在获得干净时间序列矩阵后,可以基于此建立各类过程监测模型^[56-57,64-68]. 后文(第5节)将对各类监测统计量的构建和对应含义进行具体介绍. Isom等^[56]将PCP用于过程监测和变量隔离任务中,克服了传统PCA方法容易受异常值影响的问题. Yu等^[29]基于PCP分解获得干净数据矩阵,提出了一种鲁棒典型变量差异分析方法(canonical variate dissimilarity analysis, CVDA),进一步考虑了变量的时序特性. Yan等^[67]使用SPCP分离出过程数据中的异常值,通过田纳西伊斯曼过程(Tennessee Eastman process, TEP)中的多个案例验证了方法的有效性. Li等^[68]提出一种鲁棒有监督子空间学习方法,将SPCP与偏最小二乘(partial least squares, PLS)结合,考虑质量相关的建模.

2.2.2 低秩表示方法

上述PCP方法都隐含地假设时间序列数据的底层结构来自单个低秩子空间.当数据来自多个子空间 $\{\mathcal{S}_1, \mathcal{S}_2, \dots, \mathcal{S}_k\}$ 的并集 $\bigcup_i^k \mathcal{S}_i$ 时,这些方法便会将数据视为是从单个子空间 $\mathcal{S} = \sum_i^k \mathcal{S}_i$ 采样得到的.在这种情况下,所恢复的数据矩阵可能是不准确的.为了解决该问题,Liu等^[26]提出了LRR方法,将传统PCP的秩最小化问题转变成一个更为泛化的版本,具体表示如下:

$$\begin{aligned} \min_{\mathbf{Z}, \mathbf{S}} \text{rank}(\mathbf{Z}) + \lambda \|\mathbf{S}\|_l; \\ \text{s.t. } \mathbf{X} = \mathbf{AZ} + \mathbf{S}. \end{aligned} \quad (10)$$

其中: \mathbf{A} 表示“字典”,用于表征原始序列 \mathbf{X} , \mathbf{Z} 为对应的表征系数; $\|\cdot\|_l$ 表示 l -范数,可按照实际需求设置为1-范数、2,1-范数或者 F -范数等.当字典 \mathbf{A} 设置为单位矩阵 \mathbf{I} 时,可以发现LRR将退化回PCP算法.通常可用 \mathbf{X} 本身来表示字典,即

$$\begin{aligned} \min_{\mathbf{Z}, \mathbf{S}} \text{rank}(\mathbf{Z}) + \lambda \|\mathbf{S}\|_l; \\ \text{s.t. } \mathbf{X} = \mathbf{XZ} + \mathbf{S}. \end{aligned} \quad (11)$$

与PCP类似,对于秩最小化的求解,可转为核范数优化问题.在求解出表征系数矩阵 \mathbf{Z} 后,通过 \mathbf{XZ} 来表示干净数据矩阵,而 \mathbf{S} 表示异常值矩阵或噪声矩阵,从而实现了对时间序列的分解.

研究学者们结合工业过程的特性已经对LRR进行了一系列的改进和拓展^[69-74].Fu等^[72]指出,现有的LRR存在两个缺点,一是LRR无法在原始空间与低维空间之间产生显式的投影,另一个问题是LRR只考虑数据的全局结构,忽略了数据中隐藏的局部几何结构.为克服上述问题,提出一种低秩联合嵌入(low-rank joint embedding, LRJE)方法,通过引入流形正则化来保持数据的局部几何结构.进一步地,Fu等^[73]考虑多模态特性影响,设计了一种低秩多流形嵌入(low-rank multimanifold embedding, LRME)方法,在克服离群点影响的同时捕获多模态之间的关联.Miao等^[74]借鉴SPCP算法的场景,考虑异常值和噪声同时存在的情况,提出了一种结构化低秩表示(structured low-rank representation, SLRR)方法,使用2,0-范数和 F -范数分别约束异常值列稀疏性和噪声强度,从而分解出干净数据矩阵建立鲁棒监测模型.

低秩分解方法是基于变量冗余和高度相关的假设,从变量的角度出发,分解出具有低秩结构的矩阵作为干净数据.然而,在变量数量较少或相关性较低

的情况下,即使没有噪声和异常值的干扰,时间序列矩阵仍然具有满秩性.在这种情况下,基于低秩分解的方法不再适用.

2.3 稀疏表征分解方法

基于稀疏分解方法的核心思想是,时间序列中的每个正常样本都可以由少量其他样本来表示,或者由“字典”里的若干个基本原型表示^[75-80].通过这种方式,可以将原始时间序列分解为可稀疏表征部分和不可表征部分,分别表示干净数据矩阵和异常值矩阵.本文将基于稀疏分解的方法分为两类:稀疏表示方法(sparse representation, SR)和字典学习(dictionary learning, DL)方法.下面详细介绍两种方法,并介绍其关联.

2.3.1 稀疏表示方法

SR理论最初源于信号压缩和表示^[77].给定矩阵 $\mathbf{X} \in \mathbb{R}^{m \times N}$,每一列都表示一个样本.对于第 i 个样本 \mathbf{x}_i ,SR的目标是找一个系数向量 \mathbf{c}_i ,对其他样本进行组合来表示 \mathbf{x}_i ^[78-82].对于所有的样本 \mathbf{X} ,SR的优化目标表达如下:

$$\begin{aligned} \min_{\mathbf{C}, \mathbf{E}} \|\mathbf{C}\|_0 + \lambda \|\mathbf{E}\|_0; \\ \text{s.t. } \mathbf{X} = \mathbf{XC} + \mathbf{E}, \\ \text{diag}(\mathbf{C}) = 0, \mathbf{C}^T \mathbf{1} = \mathbf{1}. \end{aligned} \quad (12)$$

其中: \mathbf{C} 为系数矩阵, \mathbf{E} 为异常值矩阵.

SR的第1个优化项 $\|\mathbf{C}\|_0$ 要求系数矩阵中非零个数尽可能少,即要求系数矩阵尽可能稀疏.如果样本没有受到噪声或异常值的影响,则通过少数其他样本即可进行表征.SR的第2个优化项 $\|\mathbf{E}\|_0$ 表示异常值矩阵应该是稀疏的.SR的第1个约束项指出,原始数据矩阵 \mathbf{X} 能被分解为可表征部分 \mathbf{XC} (干净时序矩阵)和不可表征部分 \mathbf{E} (异常值矩阵).第2个约束项避免了平凡解 $\mathbf{C} = \mathbf{I}$ 的情况,即避免样本自身表征的问题.第3个约束项对表征系数进行了归一化.与低秩分解类似,在处理上述优化问题时,会使用1-范数代替原先的0-范数方便求解.考虑到噪声和异常值同时存在的问题,与SPCP类似,原始数据矩阵也可分解为干净时序矩阵、异常值矩阵和噪声矩阵3项.

通过SR,可将工业时间序列中的噪声和异常值进行分解,从而避免其对模型参数估计的影响.Xiao等^[78]基于SR从工业数据中分解出干净时序矩阵,并建立PCA模型以实现鲁棒过程监测.进一步地,Xiao等^[79]还考虑了过程动态特性,提出一种稀疏表征保持嵌入(sparse representation preserving embedding, SRPE)方法,在干净数据空间线性投影中保持稀疏权

值,并对异常值具有很强的鲁棒性. Guo等^[80]也指出工业数据具有较强的时序相关性,通过设计一种时间约束稀疏表示(time-constrained sparse representation, TCSR)方法来确保每个样本点由近邻时间上的其他样本点表示,以实现鲁棒分解.

2.3.2 字典学习方法

上一小节介绍的SR直接将所有输入数据作为基准,并通过稀疏组合表示每个样本点. 鉴于样本之间的相似性,基准中出现的样本存在冗余,因此无法确保每个样本都具有代表性. 为了进一步提高表征的效率和准确性,挑选出具有代表性的样本作为基准,DL成为一种重要的技术. 顾名思义,字典学习是一种从数据中提取出原型来构建更高效的字典的技术,也是SR方法的一个分支. 其目标是通过优化字典的结构和字典中原型的选择,从而能够更好地捕捉到数据的内在结构和特征,提供更紧凑和更具判别性的表示形式^[81-88].

与SR类似,字典学习也将原始数据矩阵 \mathbf{X} 分解为可表征部分和不可表征部分,不同的是将作为基准的 \mathbf{X} 替换为表征更紧凑的字典 \mathbf{D} ,表示如下:

$$\begin{aligned} \min_{\mathbf{D}, \mathbf{C}} \|\mathbf{X} - \mathbf{DC}\|_F^2; \\ \text{s.t. } \|\mathbf{c}_i\|_1 \leq T. \end{aligned} \quad (13)$$

其中: \mathbf{C} 为系数矩阵; \mathbf{DC} 为数据 \mathbf{X} 中的干净时序矩阵; T 为所设定的阈值, T 越小,表示对 \mathbf{C} 的稀疏性要求越高.

稀疏表征后剩余的噪声残差部分记作

$$\mathbf{E} = \mathbf{X} - \mathbf{DC}. \quad (14)$$

字典学习的优化目标表示不可表征的噪声部分需要尽可能小,而约束项表示每个系数向量需要尽可能稀疏,即用少量的字典原型来对样本进行表征. 相比于直接使用输入数据 \mathbf{X} 作为基准,字典学习的任务更加困难,不仅要提取出一个适应于输入数据的字典 \mathbf{D} ,还要求解出基于该字典的稀疏系数矩阵 \mathbf{C} ,可通过 K 奇异值分解(K -singular value decomposition, K -SVD)^[83]或最优方向法(method of optimal directions, MOD)^[84]等进行求解. 这些方法通过迭代更新的方式逐步优化字典 \mathbf{D} 和表征系数矩阵 \mathbf{C} ,直到满足一定的条件.

此外,还有学者对字典学习进行了改进^[85-88]. Yang等^[86]进一步考虑时序数据中异常值的影响,使用字典学习将时序数据分解为3部分. Huang等^[88]通过核函数将字典学习拓展为非线性版本,适用于具有较强非线性特性的工业过程.

一般情况下,可以获取到足够充分的样本. 因此,相较于低秩分解方法,基于稀疏分解的方法具有更广泛的适用范围. 然而,该类方法也存在缺点,即其对异常值的容忍程度较有限^[77-80]. 基于稀疏分解的方法使用其他样本对特定样本进行表示. 但是,如果其他样本中存在大量异常值,则对于时序数据的表示能力也会较差,难以从中提取出干净的数据矩阵. 此外,考虑到可能涉及到的对于字典的学习,其计算复杂度也更高.

3 动态时序数据建模方法

工业时间序列中的动态特性指示了工业数据的时序相关关系. 由于时序相关的样本不满足独立同分布的假设,忽略动态性使用静态方法建模可能会导致故障的误报和漏报^[89]. 为捕获时序数据中的动态时序关系,提高监测模型的准确性,已经有学者提出了大量相关方法. 本节先对现有的几类动态性建模方法进行梳理,再介绍动静分解建模方法的核心思想和具体应用.

3.1 动态时序数据建模方法综述

本节将动态时序数据建模方法梳理总结为5大类,包括基于回归的方法、时序拓展方法、快慢特征分解方法、可预测性分解方法以及状态空间分解方法. 各类方法的原理与对比如表1所示.

动态时序建模的核心问题是如何捕捉变量间的时序关系,基于回归的方法提供了一种直观的解决方案. 通过建立回归模型,如自回归积分滑动平均模型(ARIMA)^[21]和长短期记忆网络(long short-term memory network, LSTM)^[90],利用历史数据预测未来时刻的数据. 比较预测值和真实值的残差,如果残差较大,则表明时序关系发生了变化,不再符合原先的模式,可能意味着故障的发生. 基于回归的方法没有分解变量的动态关系和静态关系,而是对两者进行混合建模. 当预测残差较大时,也可能是变量的互相关关系发生了变化.

静态建模方法(如PCA, PLS等)基于样本独立同分布的假设,无法直接应用于动态时序数据建模. 为了解决这一问题,一种简单的技巧是使用时序拓展将多个时刻的样本拼接成扩增后的数据,再直接使用传统静态监测方法进行建模^[91-92],通过这种方式可以捕获不同时刻间的变量关系. 然而,时序拓展方法存在诸多缺点. 首先,时序拓展会大大增加变量的维度,导致较高的计算复杂度;其次,这类方法依旧无法避免动静混合建模的问题,难以提供具有可解释性的过程状态辨识结果.

表 1 动态特性时间序列建模方法对比

类别	代表方法	体现分解思想	提取显式高阶动态	迭代计算	方法原理
基于回归的方法	ARIMA	×	✓	×	建立回归模型, 使用历史数据预测未来时刻数据, 通过比较预测误差判别故障是否发生
	LSTM	×	✓	✓	
时序拓展方法	DPCA	×	✓	×	对数据进行时序拓展, 在拓展后的数据矩阵上建立多元统计模型
	DPLS	×	✓	×	
快慢特征分解方法	SFA	✓	×	×	分解为慢特征和快特性, 其中慢特征体现了时序相关部分的动态信息, 快特征表示无规律时变的白噪声静态信息
	KSFA	✓	×	×	
可预测性分解方法	DiPCA	✓	✓	✓	分解为可预测特征和不可预测的残差, 可预测特征表示具有时序关系, 可从过去时刻预测未来时刻, 不可预测残差体现了时序无关的静态特性
	DiCCA	✓	✓	✓	
状态空间分解方法	CVA	✓	✓	×	分解为状态方程和观测方程, 前者描述了系统状态的时序变化规律, 体现了动态特性, 后者反映了同时刻系统状态到观测值的关系, 体现了静态特性
	ECVAS	✓	✓	×	

在过程监测中, 动态信息和静态信息对应着工业时间序列不同的物理含义. 动态信息指示了工业过程中不同时刻间的时序关系, 而静态信息指示了同一时刻变量所遵循的互相关关系, 是一种时序无关的体现. 与上述两类方法不同, 快慢特征分解方法、可预测性分解方法以及状态空间分解方法实现了动静态的分解, 从动态和静态两个角度实现时序建模. 尽管这些方法都能分离出动态性, 但他们对动态性的描述角度各不相同, 以下进行具体介绍.

3.2 快慢特征分解方法

慢特征通常被认为是原始时序数据的一种高级表示, 在一定程度上可以反映出工业过程固有的属性和重要结构信息^[93-99], 其本质上也是一种时序相关的表现. 由于特征是缓慢变化的, 具有较强的可预测性和时序相关性, 即通过之前时刻的样本可预测未来时刻的样本. 而对应的快特征表示不可预测、无规律变化的部分, 反映了白噪声信息或静态信息. 分解快慢特征的代表性方法是慢特征分析 (slow feature analysis, SFA), 该方法于 2002 年由 Wiskott 等^[95] 提出, 用于提取时间序列中变化最慢的特征. SFA 通过将原始时间序列分解为慢特征和快特征, 从而实现动静态分解.

给定 m 维时序 $\mathbf{x}(t) = [x_1(t), x_2(t), \dots, x_m(t)]^T$, SFA 的目标是找到一组映射函数 g_1, g_2, \dots, g_m , 将原始时间序列 $\mathbf{x}(t)$ 转变为一组由慢到快变化的特征 $\mathbf{y}(t) = [y_1(t), y_2(t), \dots, y_m(t)]^T$, 其中 $y_j(t) = g_j(\mathbf{x}(t))$. SFA 的优化目标可以表示如下:

$$\min \Delta(y_j) = \langle \dot{y}_j^2 \rangle_t, \quad (15)$$

其中 $\langle \cdot \rangle_t$ 和 \dot{y} 分别为时序平均和时序求导操作. 对于离散时间序列, 求导可用一阶差分. 对于线性 SFA, 所提取的特征表示为

$$\mathbf{y}(t) = \mathbf{W}\mathbf{x}(t), \quad (16)$$

其中 $\mathbf{W} = [\mathbf{w}_1 \ \dots \ \mathbf{w}_m]^T$ 为系数矩阵.

通过拉格朗日乘子法可将 \mathbf{W} 的求解转换为广义特征值分解问题, 慢特征 $\mathbf{y}_s(t)$ 和快特征 $\mathbf{y}_f(t)$ 可通过如下公式提取:

$$\mathbf{y}_s(t) = \mathbf{W}_s\mathbf{x}(t), \quad (17)$$

$$\mathbf{y}_f(t) = \mathbf{W}_f\mathbf{x}(t), \quad (18)$$

其中 $\mathbf{W}_s = [\mathbf{w}_1 \ \dots \ \mathbf{w}_A]^T$ 和 $\mathbf{W}_f = [\mathbf{w}_{A+1} \ \dots \ \mathbf{w}_m]^T$ 分别为最小 A 个特征值所对应的特征向量和剩余特征向量.

慢特征的概念与时序相关的概念在本质上是一致的. 将 SFA 的优化目标修改表达如下:

$$\begin{aligned} \langle \dot{\mathbf{y}}^2 \rangle_t &= \langle [\mathbf{y}(t) - \mathbf{y}(t-1)]^T [\mathbf{y}(t) - \mathbf{y}(t-1)] \rangle_t = \\ &= \langle \mathbf{y}(t)^T \mathbf{y}(t) - \mathbf{y}(t)^T \mathbf{y}(t-1) - \\ &= \mathbf{y}(t-1)^T \mathbf{y}(t) + \mathbf{y}(t-1)^T \mathbf{y}(t-1) \rangle_t. \end{aligned} \quad (19)$$

由于单位方差约束, $\langle \mathbf{y}(t)^T \mathbf{y}(t) \rangle_t$ 和 $\langle \mathbf{y}(t-1)^T \mathbf{y}(t-1) \rangle_t$ 近似为 1, 有

$$\begin{aligned} \min \langle \dot{\mathbf{y}}^2 \rangle_t &= \\ \min \langle 2 - \mathbf{y}(t)^T \mathbf{y}(t-1) - \mathbf{y}(t-1)^T \mathbf{y}(t) \rangle_t &= \\ \max \langle \mathbf{y}(t)^T \mathbf{y}(t-1) + \mathbf{y}(t-1)^T \mathbf{y}(t) \rangle_t. \end{aligned} \quad (20)$$

由式 (20) 可以看出, SFA 提取慢特征的本质是要求特征一阶时序相关性最大. 因此 SFA 对快慢特征分解的过程本质上可归结到对时序相关和时序无关特征的分解, 即对动态和静态的分解.

鉴于 SFA 在动静态分解的有效性, 该方法受到广泛关注, 并已被改进和扩展为多个版本, 以适应不同特性的工业过程^[100-104]. Zhang 等^[100] 通过核函数将 SFA 拓展为非线性版本提出了核 SFA (kernel SFA, KSFA), 用于捕获过程变量的非线性关系. Yu 等^[101] 考虑到变量关系可能随时间发生变化, 设计了一种递归指数 SFA (recursive exponential SFA, RESFA) 方法, 使用最新获得的样本更新 SFA 模

型. Zhang等^[33]将SFA用于间歇过程,从全局和局部两个角度实现工况运行偏差和动态故障的识别.此外,考虑到缺失数据的影响,Guo等^[102]将SFA拓展为概率版本. Zheng等^[93]在缺失数据的基础上进一步考虑非等间隔采样的问题,提出了一种间隔感知的概率SFA (interval-aware probabilistic SFA, IA-PSFA)方法.

SFA通过提取快慢特征的形式实现了对时序相关和时序无关信息的分解,具有较好的可解释性,但该方法仅限于提取一阶动态性,无法提出高阶时序关系.虽然有研究学者通过时序拓展的形式扩展了时间维度,但简单地将不同时刻的变量拼接在一起可能会导致动静混叠问题^[22].下面介绍的动态内部潜变量模型可以解决上述问题,分解出显式的高阶动态时序关系.

3.3 可预测性分解方法

动静分解的另一类方法从预测性角度来实现.如果特征存在较强的时序关系,则该特征未来时刻的取值是可以预测的,具有动态特性.而随机变化的特征,未来时刻的取值与过去时刻没有相关性,是不可预测的.通过动态内部潜变量模型可分解出可预测和不可预测特征,实现工业过程运行状态识别.由于该类方法主要任务是提取可预测的潜变量,也可称为动态内部潜变量模型,动态内部主成分分析 (dynamic-inner PCA, DiPCA)^[32]是该类方法的典型代表,其主要思想是,从原始时间序列中提取出动态特征,要求该特征具有可预测性.对于 $\mathbf{x}(t)$,DiPCA的目标是找到投影向量 \mathbf{w} ,使得所提取的潜变量 $d(t) = \mathbf{w}^T \mathbf{x}(t)$ 可以被之前时刻所预测,表示为

$$\hat{d}(t) = \beta_1 d(t-1) + \beta_2 d(t-2) + \dots + \beta_s d(t-s), \quad (21)$$

其中 $\boldsymbol{\beta} = [\beta_1, \beta_2, \dots, \beta_s]^T$ 为权重系数向量.

DiPCA的整体目标可表示为最大化潜变量的多阶自相关关系,表示为

$$\begin{aligned} \max_{\mathbf{w}, \boldsymbol{\beta}} \mathbf{w}^T \mathbf{X}_{s+1}^T \mathbf{Z}_s (\boldsymbol{\beta} \otimes \mathbf{w}); \\ \text{s.t. } \|\mathbf{w}\| = 1, \|\boldsymbol{\beta}\| = 1. \end{aligned} \quad (22)$$

其中: $\boldsymbol{\beta} \otimes \mathbf{w}$ 表示Kronecker积, $\mathbf{Z}_s = [\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_s]$, $\mathbf{X}_i = [\mathbf{x}(i), \mathbf{x}(i+1), \dots, \mathbf{x}(N+i-1)]^T$.

提取动态潜变量特征 $\mathbf{d} = \mathbf{X}\mathbf{w}$ 后,更新 \mathbf{X} 如下:

$$\mathbf{X} := \mathbf{X} - \mathbf{d}\mathbf{p}^T, \quad (23)$$

其中 $\mathbf{p} = \mathbf{X}^T \mathbf{d} / (\mathbf{d}^T \mathbf{d})$ 为负载向量.

通过上述方式可提取多个动态潜变量,并获得对应负载矩阵 \mathbf{P} 和特征提取矩阵 \mathbf{W} .对于新样本 $\mathbf{x}(t)$,

提取动态潜变量 $\mathbf{d}(t)$ 如下:

$$\mathbf{d}(t) = \mathbf{R}^T \mathbf{x}(t), \quad (24)$$

其中 $\mathbf{R} = \mathbf{W}(\mathbf{P}^T \mathbf{W})^{-1}$.

基于所提取的动态潜变量 $\mathbf{d}(t)$,构建自回归模型进行预测,表示为

$$\mathbf{v}(t) = \mathbf{d}(t) - \hat{\mathbf{d}}(t), \quad \hat{\mathbf{d}}(t) = \sum_{i=1}^s \boldsymbol{\Theta}_i^T \hat{\mathbf{d}}(t-i). \quad (25)$$

其中: $\mathbf{v}(t)$ 为预测残差,自回归参数 $\boldsymbol{\Theta}_i$ 可通过最小二乘进行估计.静态成分 $\mathbf{e}(t)$ 表示为

$$\mathbf{e}(t) = \mathbf{x}(t) - \mathbf{P}\hat{\mathbf{d}}(t). \quad (26)$$

对静态成分 $\mathbf{e}(t)$ 建立PCA模型,可以获得静态主成分和静态残差,表示为

$$\mathbf{d}_r(t) = \mathbf{P}_r^T \mathbf{e}(t), \quad (27)$$

$$\mathbf{e}_r(t) = (\mathbf{I} - \mathbf{P}_r \mathbf{P}_r^T) \mathbf{e}(t), \quad (28)$$

其中 \mathbf{P}_r 为主成分投影矩阵.

这里的动态潜变量 $\mathbf{d}(t)$ 表示与时序相关的信息,而不可预测的静态残差表示与时序无关的信息.与SFA类似,DiPCA表面是从可预测性的角度进行分析,其本质还是归结到对时序相关和时序无关特征的分解,即动静特性的分解.

在DiPCA方法的基础上,研究学者对其优化目标和约束项进行修改,衍生了其他动态内部潜变量模型.可以发现,DiPCA方法的目标是最大化 $\mathbf{d}(t)$ 和 $\hat{\mathbf{d}}(t)$ 的协方差.而动态内部典型相关分析 (dynamic inner CCA, DiCCA)^[105-106]要求最大化两者的相关关系,更直接地描述了两者的相关性.动态内部偏最小二乘 (dynamic inner PLS, DiPLS)^[107]则考虑了过程变量 $\mathbf{x}(t)$ 与质量变量 $\mathbf{y}(t)$ 间的关系. Zhu等^[108]提出了一种动态正则化隐变量回归 (dynamic regularized latent variable regression, DrLVR)算法,最大化质量变量 $\mathbf{y}(t)$ 在过程变量 $\mathbf{x}(t)$ 动态潜空间上的投影,保留了质量变量 $\mathbf{y}(t)$ 的解释能力.上述动态内部潜变量模型都是基于自回归结构提取可预测的动态潜变量,实现了动态特征与静态特征的分解.

相较于SFA方法,动态内部潜变量模型不再受限于一阶动态关系,能够提取出更高阶的动态时序关系.然而,由于动态潜变量需要通过迭代的方式逐个提取,其计算复杂度也相应增加.

3.4 状态空间分解方法

工业过程数据可以分解为状态方程和观测方程进行描述^[109-112],其中状态方程描述系统状态如何随时间变化,体现了时序相关信息,而观测方程描述如何从当前时刻的系统状态中获取当前时刻的

观测值,体现了时序无关信息.通过这种方式,状态空间模型可以根据时序相关性将时间序列进行分解,分别进行监测.典型变量分析(canonical variate analysis, CVA)^[76-77,113-116]是最常用的状态空间分解方法之一.线性状态空间方程表示为

$$\begin{aligned} \mathbf{h}(t) &= \mathbf{A}\mathbf{h}(t-1) + \mathbf{w}(t), \\ \mathbf{x}(t) &= \mathbf{B}\mathbf{h}(t) + \mathbf{v}(t). \end{aligned} \quad (29)$$

其中: $\mathbf{x}(t)$ 为工业时间序列的观测样本, $\mathbf{h}(t)$ 为 $\mathbf{x}(t)$ 状态描述, \mathbf{A} 为状态转移矩阵, \mathbf{B} 为观测矩阵, $\mathbf{w}(t)$ 和 $\mathbf{v}(t)$ 为过程噪声和观测噪声.上述两个方程分别称为状态方程和观测方程.

CVA的目标是找到两组投影方向,使得“过去”的时间序列和“未来”的时间序列投影后具有最大的相关性,即提取出具有最大时序相关性的潜变量,而剩余部分被认为是时序无关的特征.对于包含 m 个变量的观测样本 $\mathbf{x}(t)$,分别利用 s 个过去时刻和未来时刻的样本进行时序拓展,可得到过去观测向量和未来观测向量,表示如下:

$$\begin{aligned} \mathbf{x}_p(t) &= [\mathbf{x}(t-1)^T, \mathbf{x}(t-2)^T, \dots, \mathbf{x}(t-s)^T]^T, \\ \mathbf{x}_f(t) &= [\mathbf{x}(t)^T, \mathbf{x}(t+1)^T, \dots, \mathbf{x}(t+s-1)^T]^T. \end{aligned} \quad (30)$$

将多个样本组合构建过去数据矩阵和未来数据矩阵 \mathbf{X}_p 和 \mathbf{X}_f ,CVA的目标是分别找两个投影方向 \mathbf{a} 和 \mathbf{b} ,使得投影后的特征具有最大的相关性,其优化目标为

$$\begin{aligned} \max_{\mathbf{a}, \mathbf{b}} \mathbf{a}^T \Sigma_{pf} \mathbf{b}; \\ \text{s.t. } \mathbf{a}^T \Sigma_{pp} \mathbf{a} = 1, \mathbf{b}^T \Sigma_{ff} \mathbf{b} = 1. \end{aligned} \quad (31)$$

其中

$$\Sigma_{pf} = \frac{\mathbf{X}_p \mathbf{X}_f^T}{N-1}, \Sigma_{pp} = \frac{\mathbf{X}_p \mathbf{X}_p^T}{N-1}, \Sigma_{ff} = \frac{\mathbf{X}_f \mathbf{X}_f^T}{N-1}.$$

优化问题(31)可通过对Hankel矩阵进行奇异值分解来求解,有

$$\Sigma_{pp}^{-1/2} \Sigma_{pf} \Sigma_{ff}^{-1/2} = \mathbf{U} \mathbf{\Lambda} \mathbf{V}^T. \quad (32)$$

提取出 \mathbf{X}_p 中与时序相关的特征,记作

$$\mathbf{Z} = \mathbf{A}_l \mathbf{X}_p, \quad (33)$$

其中 $\mathbf{A}_l = \mathbf{U}_l^T \Sigma_{pp}^{-1/2} = [\mathbf{a}_1^T, \mathbf{a}_2^T, \dots, \mathbf{a}_l^T]^T$ 为前 l 个投影向量.剩余的残差被认为是时序无关的部分,记作

$$\mathbf{E} = \mathbf{P}_l \mathbf{X}_p, \quad (34)$$

其中 $\mathbf{P}_l = (\mathbf{I} - \mathbf{U}_l \mathbf{U}_l^T) \Sigma_{pp}^{-1/2}$.通过上述方式,CVA将工业时间序列划分为时序相关与时序无关特征.

由CVA分解得到的特征 \mathbf{Z} 反映了状态变量的波动情况,从动态角度指示了过程时序信息是否发生异常.而特征 \mathbf{E} 描述了过程的静态信息,即残差的波动范围.只要任意一个统计量超过预定的控制限,就认为发生了故障^[48].在此基础上,研究学者对CVA进行了改进^[113-116].Odiowei等^[13]为了突破传统CVA仅能提取线性关系的局限,借助核函数和核密度估计设计了非线性版本CVA,用于提取复杂的非线性时序关系.Zhang等^[77]将CVA与SFA相结合,把过程数据分解为时序相关的子空间和残差子空间,并进一步提取反映过程变化速度的慢特征,有效地从时序数据中抽取过程内在动态变化规律,提供了具有明确物理含义的过程监测结果.Zheng等^[76]提出了一种基于慢特征的增强型规范变量分析(enhanced canonical variate analysis with slow feature, ECVAS)算法,要求所提取的特征具有较强时序相关性的同时还要要求缓慢变化,并与静态信息和快速变化的噪声分离. ECVAS实现了对闭环控制下过程动力学深入解析,对静态信息和动态信息分别进行监测,有助于精细识别工艺变化.在文献^[115]中,考虑到工业过程存在多种操作模式,CVA被拓展成多模态版本,一种通用CVA模型(common CVA, CCVA)被设计用于提取出多个模态间的共通信息,揭示了不随操作模式发生变化的进程信息.

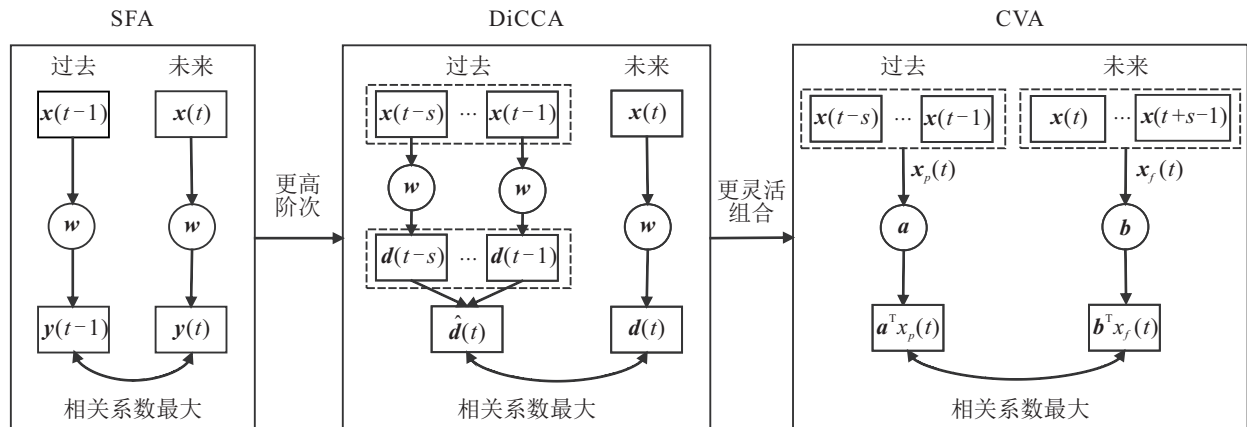


图6 基于动态特性分解的方法

虽然状态空间模型 CVA 与上文所提的 SFA 以及动态内部潜变量模型的表述不同,但本质都可归结到对时序相关特征的提取上,从而实现动态特性与静态特性的分解.图 6 展示了 SFA、DiCCA 以及 CVA 三种方法的图示,从而直观地对比这些方法的联系与区别. SFA 要求所提取的特征变化尽可能慢,本质上是寻找一个投影方向使得一阶时序相关性最大;DiCCA 将 SFA 拓展成一个高阶版本,即不再仅局限于一阶时序相关,而是要综合考虑多阶的时序关系;相比于 DiCCA, CVA 模型对于特征提取的形式更加灵活.该方法不仅对过去时刻和未来时刻都进行了高阶拓展,而且不再施加两者投影向量必须相同的限制来提取强时序相关的特征.

4 非平稳时序数据建模方法

工业过程中,由于生产条件的变化或设备老化等因素的影响,系统可能在多个工作点之间切换,导致各种关键参数的统计特性(如均值、方差等)随着时间发生改变.这种变化使时间序列表现出典型的非

平稳特性^[40,117-123].如前文所述,非平稳特性的存在会导致模型失配问题,并可能会掩盖故障早期的微弱迹象,导致故障漏报.为应对这些挑战,已经提出了大量针对非平稳特性的时序数据建模方法^[124-131].本文将首先对现有方法进行梳理,然后详细介绍基于分解理念的非平稳时序建模方法.

4.1 非平稳时序数据建模方法综述

本节将非平稳时序数据建模方法总结为 3 大类:自适应方法、多模态方法和基于分解的方法.各类方法的原理和对比如表 2 所示.

非平稳时间序列的均值和方差随着时间变化,导致原始模型不再适用.然而,通过不断自适应调整和更新模型,可使其适应非平稳特性的影响,这便是自适应方法的核心思想.一种直观的方法是将传统方法修改为递归版本,如递归 PCA (recursive PCA, RPCA)^[132]、递归 PLS (recursive PLS, RPLS)^[133]等.递归方法使用在线收集的新样本对旧模型进行更新,使其适应新的工况.即时学习是自适应方法的

表 2 非平稳特性时间序列建模方法对比

类别	代表方法	方法原理	相关案例	建模难点
自适应方法	递归方法	使用新收集的样本,对原先建立的监测模型进行调整和更新,使其适应新的工况	1. 递归 PCA 对工业过程进行在线模型更新与故障检测 ^[132] 2. 基于递归 PLS 自适应更新阈值,降低误报率,提高故障检测率 ^[133]	难以区分缓变故障和新工况数据,容易错误地将故障数据用于模型更新
	即时学习	从历史数据中找出和当前样本最相似的样本集合,建立全新模型	1. 通过即时学习自适应建立局部 CCA 模型用于过程监测 ^[134] 2. 采用局部模型结构和即时学习克服过程扰动的影响 ^[135]	
多模态方法	时间驱动模型	在时间轴方向上将非平稳时序数据划分为不同的模态,针对每个模态建立模型	1. 在时间轴将间歇过程划分为多模态,并考虑软过渡问题 ^[120] 2. 采用高斯混合模型,使用多个高斯元描述不同模态 ^[136] 3. 通过模糊聚类将时序数据分为多个模态 ^[137]	时间驱动建模方法存在模态在线识别困难的问题;此外,模型准确度依赖于模态划分结果,模态个数较难选择
	条件驱动模型	将非平稳时序数据按照条件指示变量重新排序,按照条件轴方向划分成多个模态	1. 创新性地从条件轴角度进行模态划分,相似操作条件下的过程特性也相似 ^[121] 2. 考虑了条件轴上的软过渡问题 ^[8] 3. 考虑了存在多个条件指示变量的情况 ^[123]	
分解方法	协整关系分解方法	对非平稳变量进行组合后获得平稳特征,寻找长期均衡关系	1. 使用协整分析提取出平稳特征,对平稳特征进行监测 ^[38] 2. 考虑协整关系随时间发生改变的情况 ^[138]	协整分析需要基于同阶协整假设,平稳子空间分析对时间序列片段划分有较高要求
	平稳子空间分解方法	将时间序列切分为多个时间片段,通过描述时间片段的统计差异来优化映射矩阵,将非平稳时间序列分解为平稳特征和非平稳特征	1. 通过 SSA 将时间序列分解为平稳特征和非平稳特征 ^[39,124] 2. 将原始 SSA 拓展为概率版本 SSA ^[139]	

另一个分支,该类方法完全抛弃原先模型,根据新样本在数据库中搜索相似样本,动态构建全新的模型^[134-135]。然而,自适应方法难以区分新工况变化和故障症状不明显的缓变故障,可能会将错误的样本信息纳入模型,导致建模精度下降。

处理非平稳特性的另一类方法是多模态方法。由于非平稳时序数据中变量之间的相关性随时间变化,可以将这些样本划分为不同的模态,并针对每个模态建立相应的模型。因此,多模态方法的关键在于模态的划分和识别。按照模态划分角度的不同,多模态方法可进一步分为时间驱动和条件驱动模型^[40]。前者按照时间轴方向,根据样本距离或者变量特性相似程度将时序数据聚类成不同的模态^[120,136-137]。但在在线应用中,时间驱动方法难以确定当前样本属于哪一种模态。一般而言,需要多次尝试以找出最能适应当前样本的模态。这不仅不方便,而且可能导致错误的模式识别结果。为了克服时间驱动方法的缺点,Zhao等^[121]提出了条件驱动的多模态分析理论。该理论基于以下认知:1)尽管过程特性随着时间的演变而变化是无限的,但实际上过程仅在一定有限的操作条件范围内变化;2)尽管操作条件随时间变化,但在相同条件模式下,变量的潜在关联性大致相似,而在不同条件下则不同;3)一个过程可以根据其内在过程相关性随条件变化被划分为若干条件模式。不同于时间驱动,条件驱动方法在条件轴上对时序数据进行多模态划分,充分考虑了过程特性的变化,并以条件变量作为指示,克服了在线模态难以识别的问题^[8,123]。

然而,上述方法无法实现平稳特征与非平稳特征的分解。实际上,非平稳时间序列可以看作是平稳特征和非平稳特征的叠加,其中平稳特征反映了工业过程中不随时间发生变化内在物理或化学机理,而非平稳特征反映了外在操作条件的变化。协整分析(cointegration analysis, CA)和平稳子空间分析(stationary subspace analysis, SSA)从分解的视角出发,从非平稳时间序列中提取出平稳特征,从不同的视角描述工业过程状态,提供了可解释的监测结果。下面对这两类方法进行具体介绍。

4.2 协整关系分解方法

Engle等^[38]于1987年首次在经济领域提出了CA理论,该理论认为非平稳变量同阶单整并且具有共同的趋势,那么通过对这些变量进行线性组合则可获得平稳特征,这称为协整关系,也反应了变量间的长期均衡关系(long-term equilibrium relationship)。通

过这种方式,可以从非平稳时间序列中分解出平稳特征。如果一个非平稳变量 x_j 经过 d 阶差分后变得平稳,则称变量 x_j 是 d 阶单整的,记作 $x_j \sim I(d)$ 。对于时序 $\mathbf{X} \in \mathbb{R}^{m \times N}$ (m 表示变量数, N 表示样本数),CA的目标是找到一个协整向量 $\mathbf{b} = [b_1, b_2, \dots, b_m]^T \in \mathbb{R}^m$,对非平稳变量进行线性组合后得到特征满足 $\boldsymbol{\gamma} = \mathbf{b}^T \mathbf{X} \sim I(d-k)$, $k > 0$ 。简单起见,本文仅讨论所有变量都是一阶单整的情况,所分析的结果也可推广到高阶单整变量的处理。此时,所提取的特征 $\boldsymbol{\gamma}$ 代表了时序数据中的平稳特征。为求解协整向量 \mathbf{b} ,使用向量自回归模型(vector autoregressive, VAR)对时序数据进行描述,表示为

$$\mathbf{x}(t) = \boldsymbol{\Pi}_1 \mathbf{x}(t-1) + \dots + \boldsymbol{\Pi}_p \mathbf{x}(t-p) + \mathbf{c} + \boldsymbol{\mu}(t). \quad (35)$$

其中: $\mathbf{x}(t)$ 为第 t 个时刻的样本, $\boldsymbol{\Pi}_i \in \mathbb{R}^{m \times m}$ 为VAR模型中的系数矩阵, \mathbf{c} 和 $\boldsymbol{\mu}(t)$ 为常数向量和噪声向量, p 为VAR模型的阶数。在上式两边同时减去 $\mathbf{x}(t-1)$,可获得

$$\Delta \mathbf{x}(t) = \sum_{i=1}^{p-1} \boldsymbol{\Omega}_i \Delta \mathbf{x}(t-i) + \boldsymbol{\Gamma} \mathbf{x}(t-1) + \boldsymbol{\mu}(t). \quad (36)$$

其中: $\Delta \mathbf{x}(t)$ 为 $\mathbf{x}(t)$ 的一阶差分, $\boldsymbol{\Gamma} = -\mathbf{I} + \sum_{i=1}^p \boldsymbol{\Pi}_i$,

$$\boldsymbol{\Omega}_i = - \sum_{j=i+1}^p \boldsymbol{\Pi}_j.$$

将 $\boldsymbol{\Gamma}$ 分解为两个秩满列矩阵 $\boldsymbol{\Gamma} = \mathbf{A} \mathbf{B}_f^T$ 并代入式(36),移项后可得

$$\mathbf{B}_f^T \mathbf{x}(t-1) = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \left(\Delta \mathbf{x}(t) - \sum_{i=1}^{p-1} \boldsymbol{\Omega}_i \Delta \mathbf{x}(t-i) - \boldsymbol{\mu}(t) \right). \quad (37)$$

由于这些变量都是一阶单整, $\Delta \mathbf{x}(t)$ 和 $\Delta \mathbf{x}(t-i)$ 都是平稳的,式(37)右边表示平稳成分,左边 $\mathbf{B}_f^T \mathbf{x}(t-1)$ 表示对非平稳变量的线性组合,也是平稳的, \mathbf{B}_f 便是所求的协整向量。进一步地,Johansen等^[140]证明可以利用最大似然估计把对 \mathbf{B}_f 的求解转化为一个特征值问题,从而实现更高效的协整向量求解,这里不再详细展开。

CA可以将每个样本 $\mathbf{x}(t)$ 分解为平稳特征和非平稳特性,表示如下:

$$\boldsymbol{\gamma}(t) = \mathbf{B}_f^T \mathbf{x}(t), \quad (38)$$

$$\boldsymbol{\tau}(t) = \mathbf{B}_f^{\perp T} \mathbf{x}(t), \quad (39)$$

其中 $\mathbf{B}_f^{\perp T}$ 为与 \mathbf{B}_f^T 正交的列满秩矩阵。平稳特征 $\boldsymbol{\gamma}(t)$

表示非平稳变量的均衡残差,反映了非平稳变量间的长期均衡关系. 对于非平稳特性 $\tau(t)$, 如果变量满足一阶单整, 则其差分 $\Delta\tau(t) \sim I(0)$ 是平稳的, 可用于监测非平稳特征的变化是否出现异常.

此外, 不少研究学者基于 CA 提出多种改进版本, 以适应具有不同特性的工业过程^[138,141-143]. Huang 等^[142] 利用 CA 将工业时序数据分解为平稳特征和非平稳特征, 避免非平稳变化趋势对微小故障信号的掩盖. Zhao 等^[117] 结合 CA 和 SFA, 提取非平稳时间序列中长期协整关系和动静态的波动变化情况, 对工业过程进行了细粒度描述. Yu 等^[138] 考虑到协整关系也可能随时间发生变化, 设计了一种递归 CA (recursive CA, RCA) 方法用于更新 CA 模型. Zhang 等^[141] 在 RCA 的基础上设计一种弹性权重策略来巩固先前学习的知识, 增强了 CA 模型的抗遗忘能力. 针对大范围非平稳工业过程, Zhao 等^[41] 提出一种稀疏协整分析 (sparse CA, SCA) 方法, 将具有不同协整关系的变量划分成多个子组, 自底向上建立分布式层级模型, 不仅描述了每个变量子组内的非平稳关系, 还建立了多个非平稳变量子组之间的联系.

4.3 平稳子空间分解方法

CA 要求所有变量是同阶单整的, 这在实际工业过程中往往难以满足. 相比之下, SSA^[39,124] 提供了一种更灵活的平稳与非平稳特征分解的方法. SSA 将所采集的时间序列数据 $\mathbf{x}(t) \in \mathbb{R}^m$ 看作是平稳特征 $\mathbf{s}_S(t) \in \mathbb{R}^q$ 和非平稳特征 $\mathbf{s}_N(t) \in \mathbb{R}^{m-q}$ 的叠加, 表示为

$$\mathbf{x}(t) = \mathbf{A}\mathbf{s}(t) = [\mathbf{A}_S, \mathbf{A}_N] \begin{bmatrix} \mathbf{s}_S(t) \\ \mathbf{s}_N(t) \end{bmatrix}. \quad (40)$$

其中: \mathbf{A} 为可逆的线性变化矩阵, m 为变量个数, q 为平稳特征的个数. 通过计算线性变化的逆矩阵 \mathbf{A}^{-1} , 可将时间序列分解为平稳特征和非平稳特征. 根据宽平稳的定义, 如果一个时间序列的均值和协方差不随时间改变, 则可认为该时间序列是平稳的. 在实际应用中, 对于具有 N 个观测样本的时间序列 $\mathbf{X} = [\mathbf{x}(1), \mathbf{x}(2), \dots, \mathbf{x}(N)] \in \mathbb{R}^{m \times N}$, 将其均匀划分为 P 个不重叠的时序片段. 计算第 i 个时序片段的均值向量和协方差矩阵, 分别记作 $\boldsymbol{\mu}_i$ 和 $\boldsymbol{\Sigma}_i$. 如果 $\boldsymbol{\mu}_i$ 和 $\boldsymbol{\Sigma}_i$ 满足下式, 则认为时间序列 \mathbf{X} 是平稳的:

$$\begin{aligned} \boldsymbol{\mu}_i &= \bar{\boldsymbol{\mu}}; \\ \boldsymbol{\Sigma}_i &= \bar{\boldsymbol{\Sigma}}, i = 1, 2, \dots, P. \end{aligned} \quad (41)$$

其中: $\bar{\boldsymbol{\mu}} = \frac{1}{P} \sum_{i=1}^P \boldsymbol{\mu}_i$, $\bar{\boldsymbol{\Sigma}} = \frac{1}{P} \sum_{i=1}^P \boldsymbol{\Sigma}_i$. SSA 的目标是找到一个线性变换 \mathbf{B}_S , 使得所提取的特征是宽平稳

的, 表示为

$$\mathbf{s}_S(t) = \mathbf{B}_S \mathbf{x}(t). \quad (42)$$

SSA 采用 Kullback-Leibler (KL) 散度^[141] 描述每个时序片段与时序片段均值之间的差异性并使其最小化, 具体可参见文献 [39]. 由于该优化目标是通过 KL 散度表达的, 此方法也称为 KL-SSA. 为了解决 KL-SSA 存在计算复杂度较高的问题, Hara 等^[124] 提出了解析 SSA (analytic SSA, ASSA) 方法, 将 KL-SSA 问题转变成一个广义特征值问题, 从而快速实现线性变换矩阵的求解, 用于提取平稳特征, 剩余的部分是非平稳特征.

通过 SSA, 可以将时间序列分解为平稳特征和非平稳特征, 其中平稳特征反映了系统中的不变性, 即过程变量间存在的长期恒定关系. 如果这种关系发生了改变, 则表明可能出现了故障. SSA 算法也被改进为各类版本^[139,144-147]. Yu 等^[144] 将使用 SSA 所提取的非平稳特性划分为多个模态并分别建立局部 SSA 模型, 通过全局模型和局部模型联合的方式提高了故障检测的灵敏度. 考虑到实际工业过程中存在各种不确定性因素, 如随机噪声、未知干扰等, Wu 等^[139] 提出了一种概率版本的 SSA 算法 (probabilistic SSA, PSSA), 对非平稳过程中不确定性进行建模, 提高了模型的鲁棒性. 在非平稳工业过程中, 变量间的长期恒定关系也可能随时间缓慢变化. 因此, Chen 等^[145] 提出了一种自适应版本的 SSA 算法, 使用在线采集的样本对 SSA 模型进行更新以适应变量关系的改变. Lou 等^[146] 提出一种时间约束的全局和局部非线性解析平稳子空间分析方法, 在考虑工业过程中存在的非线性和动态性的基础上实现了平稳和非平稳分解.

5 分解视角下的统计量构建与监测策略

前文梳理了针对各种复杂特性的时间序列分解建模方法, 本节将在同一监测框架下, 总结每种方法监测统计量的构建. 分解建模的本质是提取出时间序列中具有不同物理意义的特征, 如何对这些特征构建统计量, 量化地描述分布偏差, 是实现工业过程监测的重要一环. 下面针对 3 类分解方法进行详细介绍.

5.1 低质量时序数据监测统计量构建

通过分解建模, 可以从低质量时序数据提取出干净数据矩阵, 避免异常值和噪声的干扰. 通常而言, 可以针对干净数据矩阵直接建立传统监测模型. 以 PCP 为例, 在获得具有低秩结构的干净时间序列矩

阵 L 后,可以直接建立1.1节所述的PCA模型,并构建 T^2 和SPE统计量,如式(4)和(5)所示^[27]. 其中 T^2 统计量描述了数据的主要波动范围,可用于监测主成分空间的异常,而SPE统计量体现了变量的互相关关系,可用于监测残差空间中的异常. 正常样本的 T^2 和SPE统计量会遵循一定的分布,一般可通过检验假设或KDE来确定控制限. 当样本的统计量超过该控制限时,则认为有较大可能是发生了故障. 在DL方法中,可稀疏表征的干净数据矩阵记作 DC ,也可针对此直接建立PCA模型. 此外,也有学者针对表征的残差(由式(14)计算)建立监测统计量SPE,表示如下:

$$SPE = \|\mathbf{x} - D\mathbf{c}\|_2^2. \quad (43)$$

该统计量表示,如果过程处于正常运行状态,则该样本基本可以由字典 D 表征,表征残差处于较小的范围^[87].

5.2 动态时序数据监测统计量构建

在动态时序数据建模过程中,会将时间序列分解为动态特征和静态特征. 前者指示了工业过程中的时序关系,后者指示了与时序无关的变量间互相关性. 从动静协同角度分别设计监测统计量,能够更全面、准确地反映实际运行状态,提高故障检测精度,并提供可解释的监测结果. 下面将以SFA、DiPCA和CVA为典型代表,介绍动静监测统计量的构建方法.

SFA可以将工业时间序列分解为慢特征 $\mathbf{y}_s(t)$ 和快特征 $\mathbf{y}_f(t)$,并基于此分别构建动态和静态监测统计量,表示如下:

$$T_s^2 = \mathbf{y}_s(t)^T \mathbf{y}_s(t), \quad (44)$$

$$T_f^2 = \mathbf{y}_f(t)^T \mathbf{y}_f(t). \quad (45)$$

不同于PCA等传统监测模型,SFA还针对快慢特征的差分设计了统计量,用于区分正常工况切换与真实故障^[99-100],表示如下:

$$S_s^2 = \dot{\mathbf{y}}_s(t)^T \Omega_s^{-1} \dot{\mathbf{y}}_s(t), \quad (46)$$

$$S_f^2 = \dot{\mathbf{y}}_f(t)^T \Omega_f^{-1} \dot{\mathbf{y}}_f(t). \quad (47)$$

其中: $\dot{\mathbf{y}}_s(t)$ 和 $\dot{\mathbf{y}}_f(t)$ 分别为慢特征和快特征的一阶差分, Ω_s 和 Ω_f 分别为 $\dot{\mathbf{y}}_s(t)$ 和 $\dot{\mathbf{y}}_f(t)$ 的经验协方差矩阵.

Shang等^[99]利用“位置”和“速度”这两个物理概念类比原始特征及其差分信息. 基于快慢特征构建的监测统计量指示了过程的操作条件,而基于差分特征构建的监测统计量指示了过程的动态行为. 当过程切换到新的工作点时,稳态运行条件随之发生变化. 然而,在反馈控制的影响下,过程的动态行为保持不变. 通过SFA,可将过程的稳态运行条件与动态行

为分开,能够有效区分运行条件变化与实际故障,从而避免故障误报.

DiPCA方法可基于分解得到的动态潜变量 $\mathbf{d}(t)$ 和静态成分 $\mathbf{e}(t)$ 构建动态和静态监测统计量. 对于动态统计量,Dong等^[32]指出,由于潜变量 $\mathbf{d}(t)$ 具有动态特性,在较大的范围内波动,直接监测 $\mathbf{d}(t)$ 可能导致较高的故障误报. 由于DiPCA提取了变量间的时序关系,可以通过预测误差 $\mathbf{v}(t)$ 来监测过程的动态行为. 如果发生了故障,则过程变量不再遵循先前的时序变化规律,可反映在预测误差 $\mathbf{v}(t)$ 上. 对预测误差建立PCA模型,可获得联合监测统计量表示如下:

$$\varphi_v = \mathbf{v}(t)^T \Phi_v \mathbf{v}(t), \quad (48)$$

$$\Phi_v = \frac{\mathbf{P}_v \Lambda_v^{-1} \mathbf{P}_v^T}{\chi_v^2} + \frac{\mathbf{I} - \mathbf{P}_v \mathbf{P}_v^T}{\delta_v^2}. \quad (49)$$

其中: \mathbf{P}_v 为针对预测误差所建立的PCA模型的映射矩阵, Λ_v 为预测误差协方差矩阵, χ_v^2 和 δ_v^2 为对应 T^2 和SPE的控制限.

对于静态成分 $\mathbf{e}(t)$,可直接使用PCA进行建模以提取静态主成分和静态残差,如式(27)和(28)所示,并基于此构建 T^2 和SPE统计量,可参见式(2)和(3).

CVA将工业时间序列分解为时序相关特征 \mathbf{Z} 和时序无关特征 \mathbf{E} . 与PCA类似,CVA也可基于分解得到的 \mathbf{Z} 和 \mathbf{E} 构建 T^2 和SPE统计量,表示如下:

$$T^2 = \mathbf{z}(t)^T \mathbf{z}(t), \quad (50)$$

$$SPE = \mathbf{e}(t)^T \mathbf{e}(t), \quad (51)$$

其中 $\mathbf{z}(t)$ 和 $\mathbf{e}(t)$ 为 \mathbf{Z} 和 \mathbf{E} 中的一个样本. 统计量 T^2 反映状态变量的波动情况,从动态角度指示了过程时序信息是否发生异常. 统计量SPE描述过程的静态信息,即残差的波动范围^[48],通过这种方式,CVA从动静分解的角度实现过程状态的全面评估与监测.

5.3 非平稳时序数据监测统计量构建

在非平稳时序数据建模过程中,会将时间序列分解为平稳特征和非平稳特征. 前者反映系统不随时间变化的内在物理或化学机制,体现了变量之间长期存在的关系^[124-131,138-140]. 后者指示工业过程随着不同工作条件下的状态切换. 由于非平稳特征在不断变化,难以预先定义一个波动范围. 因此,一般而言,常针对平稳特征构建统计量进行监测. 下面以CA和SSA为典型代表介绍监测统计量的构建方法.

CA可以将每个样本 $\mathbf{x}(t)$ 分解为平稳特征 $\boldsymbol{\gamma}(t) = \mathbf{B}_f^T \mathbf{x}(t)$ 和非平稳特性 $\boldsymbol{\tau}(t) = \mathbf{B}_f^{\perp T} \mathbf{x}(t)$. 平稳特征 $\boldsymbol{\gamma}(t)$ 表示非平稳变量的均衡残差,反映了非平稳变量间的长期均衡关系. 在CA中,如果变量满足一阶

单整,则非平稳特性 $\tau(t)$ 不再是无规律可循,其差分 $\Delta\tau(t) \sim I(0)$ 是平稳的,也可用于监测非平稳特征的变化是否出现异常.对 $\gamma(t)$ 和 $\Delta\tau(t)$ 可构建监测统计量如下:

$$T_\gamma^2 = \gamma(t)^T \Lambda_\gamma^{-1} \gamma(t), \quad (52)$$

$$T_\tau^2 = \Delta\tau(t)^T \Lambda_\tau^{-1} \Delta\tau(t), \quad (53)$$

其中 Λ_γ 和 Λ_τ 分别为 $\gamma(t)$ 和 $\Delta\tau(t)$ 的协方差矩阵.

SSA 与 CA 类似,也可以提取出平稳特征 $s_S(t) = B_S x(t)$. 但是 SSA 并没有对变量作同阶单整的假设,其非平稳特征在进行差分后仍可能是非平稳的,没有固定的变化范围.因此,SSA 仅对平稳特征 $s_S(t)$ 构建

T^2 统计量,表示如下:

$$T^2 = s_s(t)^T \Lambda_s^{-1} s_s(t), \quad (54)$$

其中 Λ_s 为 $s_S(t)$ 的协方差矩阵.

各类方法的监测统计量构建与描述总结如表 3 所示. 总体而言,监测统计量就是基于所分解的特征,在度量空间中使用欧氏距离或马氏距离等衡量方式来量化描述过程特性与正常状态的偏离程度.而在变量独立同分布的场景中,协方差矩阵将转变为单位矩阵,马氏距离与欧氏距离呈现相同的表达.通过对具有不同物理意义的特征构建对应统计量,可提供对工业时间序列细粒度、可解释的监测结果.

表 3 分解视角下各类方法统计量构建与描述

代表方法	干净数据矩阵			异常值/噪声矩阵		
	特征公式	统计量构建	统计量描述	特征公式	统计量构建	统计量描述
低质量特性	PCP	式(2)	$T^2 = t^T S^{-1} t$			数据的主成分波动范围
		式(3)	$SPE = e^T e$			变量的互相关关系,监测残差空间
	DL	式(2)	$T^2 = t^T S^{-1} t$			数据的主成分波动范围
		式(3)	$SPE = e^T e$	式(14)	$SPE = \ x - Dc\ _2^2$	变量的互相关关系,监测残差空间 描述了样本的表征残差
动态特性	SFA	式(17)	$T_s^2 = y_s(t)^T y_s(t)$	式(18)	$T_f^2 = y_f(t)^T y_f(t)$	描述了慢特征稳态分布 描述了快特征稳态分布
		式(17)	$s_s^2 = \dot{y}_s(t)^T \Omega_s^{-1} \dot{y}_s(t)$	式(18)	$S_f^2 = \dot{y}_f(t)^T \Omega_f^{-1} \dot{y}_f(t)$	描述了慢特征动态行为 描述了快特征动态行为
	DiPCA	式(25)	$\varphi_v = v(t)^T \Phi_v v(t)$	式(27)	$T^2 = d_r(t)^T S^{-1} d_r(t)$	动态潜在变量的预测残差,体现了时序相关性 时序无关静态成分的主成分波动范围
				式(28)	$SPE = e_r(t)^T e_r(t)$	时序无关静态成分的残差空间
	CVA	式(33)	$T^2 = z(t)^T z(t)$	式(34)	$SPE = e(t)^T e(t)$	状态变量的波动情况 时序无关的残差信息波动范围
	非平稳特性	CA	式(38)	$T_\gamma^2 = \gamma(t)^T \Lambda_\gamma^{-1} \gamma(t)$	式(39)	$T_z^2 = \Delta\tau(t)^T \Lambda_\tau^{-1} \Delta\tau(t)$
SSA						

6 不同类别方法的关联讨论与分析

前文从分解的角度出发,以低质量特性、动态特性和非平稳特性为切入点,综述了各类时间序列建模和监测方法,总结如表4所示. 尽管这些方法所处理的特性不同,但仍存在着内在关联,包括以下3个方面.

1)从方法理念来看,这些方法都包含化繁为简的共性思想. 在实际工业过程中,由于内部机理的复杂性,变量之间多种关系交织耦合,异常的触发可能是多种关系共同作用的结果. 而时间序列分解建模方

法可以将复杂特性分解成多个具有实际物理意义的组成部分. 比如,针对低质量特性的分解方法将时序数据分解为干净数据矩阵和异常值矩阵,从而避免异常值的干扰. 针对动态特性的分解方法将时序数据分解为时序相关特征与时序无关特征,反映了变量间的时序相关关系与互相关关系. 非平稳特性的分解方法将时序数据分解为时不变特征与时变特征,体现了变量长期均衡关系以及随工况发生变化的时变关系. 这些方法都是基于化繁为简的思想,提供了可解释的分解结果.

表4 分解视角下的各类时间序列建模方法对比

类别	分解形式	分解方法	分解理念	优势	不足	相关工作案例
低质量数据分解	把时序数据分解为干净数据矩阵和异常值矩阵	低秩分解	变量具有高相关性,干净数据矩阵具有低秩结构	1. 计算相对简单 2. 对异常值的鲁棒性较强	1. 需要基于低秩结构的假设 2. 难以处理非线性	1. PCP分离干净数据矩阵和异常值矩阵 ^[27-29] 2. SPCP追踪进一步分离噪声矩阵 ^[63] 3. LRR将PCP拓展为更泛化版本 ^[26]
		稀疏分解	干净样本可以由其他少量样本表征,不能表征部分为异常	无需假设数据结构,可以自适应学习稀疏表征	1. 对异常值容忍度有限,过多异常值影响稀疏分解效果 2. 需要设计合适的字典,计算复杂度高	1. SR使用原始数据作为基础进行表征 ^[77-82] 2. DL通过构造字典进一步提高表征的效率和准确性 ^[85-88]
动态特性分解	把时序数据分解为时序相关特征与时序无关特征	慢特征分析	分解为慢特征和快特征	计算复杂度低,通过原始特征及其差分全面监测动态过程,可解释性强	局限于分析一阶动态性	1. SFA通过快慢特征及其差分构造统计量 ^[95-98] 2. 拓展为非线性版本SFA ^[100] 3. 拓展为时变版本SFA ^[101]
		动态内部模型	分解为可预测特征和不可预测特征	1. 可拓展至高阶动态性 2. 提供了动静态的显式分离	计算复杂,需要通过迭代的形式逐个分离动态特征	1. DiPCA显式分离出动态和静态特征 ^[32] 2. DiCCA将SFA拓展为高阶版本 ^[105,106]
		状态空间模型	分解为状态方程和观测方程进行描述	1. 可拓展至高阶动态性 2. 计算复杂度低,无需迭代计算	容易受到变量共线性的影响	1. CVA提取出具有最大时序相关性的潜变量 ^[113,114] 2. 拓展为多模态版本CVA ^[115]
非平稳特征分解	把时序数据分解为时不变特征与时变特征	协整分析	分解出具有长期均衡关系的平稳特征和时变非平稳特征	1. 计算简单 2. 原始特征和差分特征都可以用于过程监测	需要基于变量同阶单整的假设,难以在实际中满足	1. CA分离出具有长期均衡关系的特征 ^[38] 2. 拓展为稀疏版本CA ^[41] 3. 拓展为时变版本CA ^[138]
		平稳子空间分析	通过描述时间片段的均值和协方差与整体的差异性分解平稳源与非平稳源	不需要基于变量同阶单整的假设,形式更加灵活	1. 数值求解不稳定,计算复杂度高 2. 对时间片段的划分有特定要求	1. SSA分离出平稳源和非平稳源 ^[39,124] 2. 拓展为概率版本SSA ^[139] 3. 拓展为自适应更新版本SSA ^[145]

2) 从分解手段来看, 这些方法都是将所分析的特性描述成一定的数学形式并归结为一个优化问题以分解对应成分。比如, 在针对低质量特性的分解方法中, 可以通过低秩来描述矩阵的干净程度, 并以此为目标进行优化分解出干净数据矩阵。而动态特性具有多种描述形式, 优化目标也略有不同。SFA 将动态特性表示为最小化差分的形式, 动态内部模型从可预测性的角度要求预测残差最小化, 而状态空间模型目标是提取最大时序相关性的潜变量。在提取出动态成分后, 剩余的残差就表示静态信息。对于平稳特性, 可通过 SSA 将其描述为每个时序片段与时序片段均值之间的差异性并使其最小化, 从而实现平稳源与非平稳源的分离。

3) 从监测分析来看, 这些方法都基于所分解的成分分别设计多个监测统计量, 全面描述了工业过程运行状态, 提供了细粒度的监测结果。对于低质量特性分解, 可基于干净数据矩阵建立监测模型并设计统计量, 捕获正常数据的波动范围。同时, 也可基于分解出的噪声设计监测统计量对残差进行描述。对于动态特性分解, 可基于时序预测残差和提取出的动态特征, 设计动态统计量描述时序关系是否发生改变以及系统动态特征的波动范围。基于静态特征, 可设计静态统计量描述时序无关的变量互相关关系。对于非平稳特性分解, 可基于所提取的平稳特征设计监测统计量, 描述非平稳变量长期均衡关系是否发生改变。此外, 如果变量满足一阶单整, 非平稳特征的差分信息也是平稳的, 则可基于此设计监测统计量描述非平稳特征的变化是否出现异常。

7 工业时序分解与应用的未来展望

从场景看, 目前时序分解研究在面对变量混合异构及知识与数据融合的建模挑战时, 尚存在较大的发展空间。在建模方法方面, 现有工业时序分解建模的研究主要基于多元统计分析方法, 而采用深度学习技术的相关研究较为缺乏。此外, 在应用方面, 当前的研究主要集中在监测环节, 而对于时序数据分解建模在后续根因溯源等应用中的潜力探索仍然不足。本文将进一步展望工业时序分解方法的未来研究方向。

7.1 混合异构时序分解建模

在实际工业过程中, 除了温度、压强等连续变量, 还存在大量离散变量, 如阀门开闭状态、功率等级等。离散变量和连续变量的信息粒度和分布类型不一致。建模过程中常用的欧氏距离和马氏距离等衡量方式并不适用于离散变量。此外, 传统时序建模方法通常用高斯分布描述连续变量, 而离散变量一般遵循伯努

利分布或者类别分布。传统方法往往基于连续变量的假设, 难以准确描述混合异构数据, 这给工业时序分解建模带来巨大挑战^[148]。

将连续变量和混合变量用统一框架描述, 挖掘出离散变量背后所蕴含的连续信息, 从而对混合异构时序数据进行精细化建模, 获得了学者们的广泛关注^[149-151]。Wang 等^[149]提出了一种无监督描述框架, 对连续变量和离散变量同时进行描述, 实现对混合变量的过程监测。在此基础上, Wang 等^[150]进一步考虑了非平稳特性, 将上述框架改进为迭代版本实现自适应故障检测。Chen 等^[151]考虑到过程监测任务中故障的可不知问题, 提出了一种更加泛化的描述框架, 实现对连续变量与离散变量的联合监测。

7.2 知识数据融合时序分解建模

现有的时序分解方法往往是基于通用先验认知, 更多地是从数据本身所蕴含的特性进行分解。比如, 一些异常值分解算法往往是基于“干净数据矩阵具有低秩特性”这样一种先验认知。这种认知具有通用性, 在化工过程、火电过程等多个领域均适用, 但忽略了每个具体过程所独有的专家知识。实际上, 现有大量的过程专家知识, 包括对过程机理的描述、测点分布及其连接关系、故障排查修复记录、故障发生原理等, 其应用能够显著提高分解模型的可解释性, 使分解监测结果不仅符合数据统计特性, 更贴合实际过程运行机理。

专家知识形式多样, 来源各异, 往往没有统一的规范形式。将多源异构的专家知识规整为统一结构的语义向量和知识图谱, 并嵌入数据驱动模型为其提供可靠指导^[152-160]。比如, Feng 等^[152]提出工业零样本学习范式, 从对故障的自然语言描述中抽取出现统一形式的语义属性向量, 并嵌入故障诊断模型, 实现了专家知识与数据的融合。Chen 等^[155]针对属性信息粒度不同的问题, 进一步利用专家知识对属性进行由粗到细的分层设计一种模糊分层故障诊断策略, 加强了模型的可解释性。Li 等^[156]针对火力发电过程构建故障知识库, 设计了一种知识嵌入的工业联邦学习方法。Zhou 等^[158]利用自然语言处理技术, 将工业过程中积累的技术文档转换为结构化的工业知识图谱, 将知识图谱中所描述的动态语义信息融入时序数据中。这些方法均可作为知识与数据融合的可解释时序分解建模带来启发与参考。

7.3 基于深度学习的时序分解建模

本文所述时序分解方法主要为多元统计学习方法。近年来, 深度学习技术在多个领域取得了突破性

进展,凭借其强大的表征能力和拟合能力,已经成为时序建模与分析的主流方法之一。然而,深度学习模型通常被视为黑箱模型,其内部隐藏层的工作机制难以解释。

通过对神经网络模型施加特定归纳偏好约束,可使网络表征时序数据中的不同成分,从而实现时序数据的分解建模^[161]。比如, Song 等^[125]设计一种级联深度信息分离(cascaded deep information separation, CDIS)架构,对工业时间序列中多模态耦合的平稳和非平稳特征进行了解耦。Liu 等^[162]提出了一种时频解耦框架,将时序数据中的时域和频域特征进行分解,提取出趋势性信息和季节性波动信息。在文献^[163]中,一种时空解耦显式表征方法被提出,对时间和空间依赖性分别进行描述,并从两个视角分别设计监测统计量,提供了全面的过程监测策略。结合深度学习的强表征能力,并将时序数据分解为多个具有不同含义的成分以提供可解释分析结果,为工业生产提供更加智能化的决策支持,具有重要意义。

7.4 时序分解建模拓展应用

尽管基于时序分解的监测方法可以对过程状态进行识别,但这些工作更多聚焦于感知层面,仅能判断是否发生故障,未能深入探究故障发生的根源。在检测到故障后,如何进一步确定故障传播路径并追踪根源故障变量,是保障工业过程安全的重要一环。通过对时序数据的分解,可以获知过程哪方面出现异常,进而结合根因溯源技术,辨识导致该异常的根因变量,协助操作人员快速定位故障的关键设备和部件,加快故障修理进程^[164-165]。

近年来,基于数据驱动的根本溯源方法获得了广泛关注。除了格兰杰因果(Granger causality, GC)分析^[166]、转移熵(transfer entropy, TE)模型^[167]、收敛交叉映射(convergent cross mapping, CCM)^[168]等基本根本溯源方法外,研究者针对复杂工业过程的特性也提出了一系列改进^[169-179]。比如,针对非线性特性, Chen 等^[170]使用高斯过程回归(Gaussian process regression, GPR)代替 GC 中的线性自回归模型,从而有效提取非线性因果关系。对于非平稳特性导致的虚假因果回归问题, Zhang 等^[171]利用向量误差纠正(vector error correction, VEC)模型,基于原始数据和差分数据综合考虑长期和短期因果关系,实现了根本变量的溯源。结合时序分解方法,从多角度、多方面溯源不同故障类型的根本变量,是一个值得研究的方向。

8 结论

工业时间序列的建模与监测是工业过程安全高效运行的保障,也是提升其智能化水平的关键。鉴于工艺复杂性、变量间深度耦合等因素,仅知晓工业过程中存在异常与否往往无法满足实际应用需求,还需要确定出现问题的具体方面。本文从分解的角度出发,以低质量特性、动态特性和非平稳特性为切入点,全面综述了各类时间序列建模和监测方法,探讨了这些方法如何对复杂时序特性化繁为简,将其分解成多个具有实际物理意义的组成部分。基于所分解的特征,梳理了对应监测统计量的构造以提供精细的监测结果。根据对现有研究的总结和讨论,对复杂时序分解建模领域未来的发展进行了展望,其中包括混合异构与知识数据融合的时序建模挑战以及时序建模的拓展应用,为后续研究提供了有价值的参考。

参考文献(References)

- [1] Raveendran R, Kodamana H, Huang B. Process monitoring using a generalized probabilistic linear latent variable model[J]. *Automatica*, 2018, 96: 73-83.
- [2] 赵春晖. 运行工况监测与故障溯源推理: 机器学习方法[M]. 北京: 化学工业出版社, 2022: 1-9. (Zhao C H. Operating condition monitoring and fault tracing reasoning[M]. Beijing: Chemical Industry Press, 2022: 1-9.)
- [3] Joe Qin S. Statistical process monitoring: Basics and beyond[J]. *Journal of Chemometrics*, 2003, 17(8/9): 480-502.
- [4] Lee J M, Yoo C, Lee I B. Statistical process monitoring with independent component analysis[J]. *Journal of Process Control*, 2004, 14(5): 467-485.
- [5] Severson K, Chaiwatanodom P, Braatz R D. Perspectives on process monitoring of industrial systems[J]. *Annual Reviews in Control*, 2016, 42: 190-200.
- [6] 孔祥玉, 杨治艳, 刘佑民, 等. 基于独立成分分析及其扩展模型的工业过程监测方法综述[J]. *控制与决策*, 2022, 37(4): 799-814. (Kong X Y, Yang Z Y, Liu Y M, et al. Overview of industrial process monitoring methods based on independent component analysis and its extended model[J]. *Control and Decision*, 2022, 37(4): 799-814.)
- [7] Wise B M, Gallagher N B. The process chemometrics approach to process monitoring and fault detection[J]. *Journal of Process Control*, 1996, 6(6): 329-348.
- [8] Chen X, Zhao C H. Conditional discriminative autoencoder and condition-driven immediate representation of soft transition for monitoring complex nonstationary processes[J]. *Control Engineering Practice*, 2022, 122: 105090.
- [9] Raghappriya M, Kanthalakshmi S. Sliding mode

- observer-based fault detection for helicopter system[J]. *Journal of Control and Decision*, 2023, 10(4): 465-475.
- [10] 周平, 刘记平, 梁梦圆, 等. 基于KPLS鲁棒重构误差的高炉燃料比监测与异常识别[J]. *自动化学报*, 2021, 47(7): 1661-1671.
(Zhou P, Liu J P, Liang M Y, et al. KPLS robust reconstruction error based monitoring and anomaly identification of fuel ratio in blast furnace ironmaking[J]. *Acta Automatica Sinica*, 2021, 47(7): 1661-1671.)
- [11] Wold S, Esbensen K, Geladi P. Principal component analysis[J]. *Chemometrics and Intelligent Laboratory Systems*, 1987, 2(1/2/3): 37-52.
- [12] Kano M, Hasebe S, Hashimoto I, et al. A new multivariate statistical process monitoring method using principal component analysis[J]. *Computers & Chemical Engineering*, 2001, 25(7/8): 1103-1113.
- [13] Odiweei P E P, Cao Y. Nonlinear dynamic process monitoring using canonical variate analysis and kernel density estimations[J]. *IEEE Transactions on Industrial Informatics*, 2010, 6(1): 36-45.
- [14] Geladi P, Kowalski B R. Partial least-squares regression: A tutorial[J]. *Analytica Chimica Acta*, 1986, 185: 1-17.
- [15] Li G, Qin S J, Zhou D H. Geometric properties of partial least squares for process monitoring[J]. *Automatica*, 2010, 46(1): 204-210.
- [16] Zhong B, Wang J, Zhou J L, et al. Quality-related statistical process monitoring method based on global and local partial least-squares projection[J]. *Industrial & Engineering Chemistry Research*, 2016, 55(6): 1609-1622.
- [17] Lindquist A, Picci G. Canonical correlation analysis, approximate covariance extension, and identification of stationary time series[J]. *Automatica*, 1996, 32(5): 709-733.
- [18] Wang H M, Wang J K, Xu S Q, et al. Dynamic inner independent component analysis-based incipient fault detection for electric drive systems of high-speed trains[J]. *Journal of Control and Decision*, 2023: 1-11.
- [19] 赵春晖, 胡赞昀, 郑嘉乐, 等. 数据驱动的燃煤发电装备运行工况监控——现状与展望[J]. *自动化学报*, 2022, 48(11): 2611-2633.
(Zhao C H, Hu Y Y, Zheng J L, et al. Data-driven operating monitoring for coal-fired power generation equipment: The state of the art and challenge[J]. *Acta Automatica Sinica*, 2022, 48(11): 2611-2633.)
- [20] 郭小萍, 陆宁云, 高福荣, 等. 间歇过程滑动窗口子时段PCA建模和在线监测[J]. *控制与决策*, 2005, 20(9): 1034-1037.
(Guo X P, Lu N Y, Gao F R, et al. Sub-stage PCA modeling and on-line monitoring with moving windows for batch processes[J]. *Control and Decision*, 2005, 20(9): 1034-1037.)
- [21] Box G E P, Jenkins G M, Reinsel G C. Time series analysis[M]. John Wiley & Sons, 2015: 47-82.
- [22] Chen X, Zheng J L, Zhao C H, et al. Full decoupling high-order dynamic mode decomposition for advanced static and dynamic synergetic fault detection and isolation[J]. *IEEE Transactions on Automation Science and Engineering*, 2024, 21(1): 226-240.
- [23] Liu Y Q, Liu B, Zhao X J, et al. A mixture of variational canonical correlation analysis for nonlinear and quality-relevant process monitoring[J]. *IEEE Transactions on Industrial Electronics*, 2018, 65(8): 6478-6486.
- [24] Dong J, Zhang K, Huang Y, et al. Adaptive total PLS based quality-relevant process monitoring with application to the Tennessee Eastman process[J]. *Neurocomputing*, 2015, 154: 77-85.
- [25] Zhang S M, Zhao C H. Hybrid independent component analysis(H-ICA) with simultaneous analysis of high-order and second-order statistics for industrial process monitoring[J]. *Chemometrics and Intelligent Laboratory Systems*, 2019, 185: 47-58.
- [26] Liu G C, Lin Z C, Yan S C, et al. Robust recovery of subspace structures by low-rank representation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35(1): 171-184.
- [27] Candès E J, Li X D, Ma Y, et al. Robust principal component analysis?[J]. *Journal of the ACM*, 2011, 58(3): 1-37.
- [28] Pan Y J, Yang C J, An R Q, et al. Robust principal component pursuit for fault detection in a blast furnace process[J]. *Industrial & Engineering Chemistry Research*, 2018, 57(1): 283-291.
- [29] Yu W K, Zhao C H. Low-rank characteristic and temporal correlation analytics for incipient industrial fault detection with missing data[J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(9): 6337-6346.
- [30] Jaffel I, Taouali O, Harkat M F, et al. Moving window KPCA with reduced complexity for nonlinear dynamic process monitoring[J]. *ISA Transactions*, 2016, 64: 184-192.
- [31] Chen X, Zhao C H. Linear and nonlinear hierarchical multivariate time delay analytics for dynamic modeling and process monitoring[J]. *Journal of Process Control*, 2021, 107: 83-93.
- [32] Dong Y N, Qin S J. A novel dynamic PCA algorithm for dynamic data modeling and process monitoring[J]. *Journal of Process Control*, 2018, 67: 1-11.
- [33] Zhang S M, Zhao C H. Slow-feature-analysis-based batch process monitoring with comprehensive interpretation of operation condition deviation and dynamic anomaly[J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(5): 3773-3783.
- [34] Zheng J L, Zhao C H, Gao F R. Retrospective comparison of several typical linear dynamic latent

- variable models for industrial process monitoring[J]. *Computers & Chemical Engineering*, 2022, 157: 107587.
- [35] Misra M, Yue H H, Qin S J, et al. Multivariate process monitoring and fault diagnosis by multi-scale PCA[J]. *Computers & Chemical Engineering*, 2002, 26(9): 1281-1293.
- [36] Lee H W, Lee M W, Park J M. Multi-scale extension of PLS algorithm for advanced on-line process monitoring[J]. *Chemometrics and Intelligent Laboratory Systems*, 2009, 98(2): 201-212.
- [37] Du Y C, Du D P. Fault detection and diagnosis using empirical mode decomposition based principal component analysis[J]. *Computers & Chemical Engineering*, 2018, 115: 1-21.
- [38] Engle R F, Granger C W J. Co-integration and error correction: Representation, estimation, and testing[J]. *Econometrica*, 1987, 55: 251-276.
- [39] von Bünau P, Meinecke F C, Király F C, et al. Finding stationary subspaces in multivariate time series[J]. *Physical Review Letters*, 2009, 103(21): 214101.
- [40] Zhao C H. Perspectives on nonstationary process monitoring in the era of industrial artificial intelligence[J]. *Journal of Process Control*, 2022, 116: 255-272.
- [41] Zhao C H, Sun H, Tian F. Total variable decomposition based on sparse cointegration analysis for distributed monitoring of nonstationary industrial processes[J]. *IEEE Transactions on Control Systems Technology*, 2020, 28(4): 1542-1549.
- [42] Qin S J, Dong Y N, Zhu Q Q, et al. Bridging systems theory and data science: A unifying review of dynamic latent variable analytics and process monitoring[J]. *Annual Reviews in Control*, 2020, 50: 29-48.
- [43] Yin S, Ding S X, Xie X C, et al. A review on basic data-driven approaches for industrial process monitoring[J]. *IEEE Transactions on Industrial Electronics*, 2014, 61(11): 6418-6428.
- [44] Mandelbrot B B, van Ness J W. Fractional Brownian motions, fractional noises and applications[J]. *SIAM Review*, 1968, 10(4): 422-437.
- [45] Brockwell P J, Davis R A. *Time series: Theory and methods*[M]. New York: Springer Science & Business Media, 1991: 1-41.
- [46] Zhang M L, Zhou Z H. ML-KNN: A lazy learning approach to multi-label learning[J]. *Pattern Recognition*, 2007, 40(7): 2038-2048.
- [47] Breunig M M, Kriegel H P, Ng R T, et al. LOF: Identifying density-based local outliers[C]. *Proceedings of the 2000 ACM SIGMOD International Conference on Management of Data*. Texas, 2000: 93-104.
- [48] Gao Y L, Lin T T, Zhang Y S, et al. Robust principal component analysis based on discriminant information[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2023, 35(2): 1991-2003.
- [49] Kwak N. Principal component analysis based on L1-norm maximization[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2008, 30(9): 1672-1680.
- [50] Ding C, Zhou D, He X F, et al. R_1 -PCA: Rotational invariant L_1 -norm principal component analysis for robust subspace factorization[C]. *Proceedings of the 23rd International Conference on Machine Learning*. Pittsburgh, 2006: 281-288.
- [51] Yi S Y, Lai Z H, He Z Y, et al. Joint sparse principal component analysis[J]. *Pattern Recognition*, 2017, 61: 524-536.
- [52] Yu W K, Zhao C H, Huang B, et al. A robust with Laplace distribution for incipient fault detection[J]. *IEEE Transactions on Dissimilarity Distribution Analytics Industrial Electronics*, 2023, 70(12): 12752-12761.
- [53] Zou H, Hastie T, Tibshirani R. Sparse principal component analysis[J]. *Journal of Computational and Graphical Statistics*, 2006, 15(2): 265-286.
- [54] Dai Q Y, Zhao C H, Zhao S Y. Variational Bayesian student's-t mixture model with closed-form missing value imputation for robust process monitoring of low-quality data[J]. *IEEE Transactions on Cybernetics*, 2024, 54(1): 373-386.
- [55] Tsakiris M C, Vidal R. Dual principal component pursuit[C]. *IEEE International Conference on Computer Vision Workshop*. Santiago, 2015: 850-858.
- [56] Isom J D, LaBarre R E. Process fault detection, isolation, and reconstruction by principal component pursuit[C]. *Proceedings of the 2011 American Control Conference*. San Francisco, 2011: 238-243.
- [57] Cheng Y, Chen T W. Application of principal component pursuit to process fault detection and diagnosis[C]. *American Control Conference*. Washington, 2013: 3535-3540.
- [58] Cen J, Chen H H, Wu Y B, et al. Robust fault detection for chemical processes based on dynamic low-rank matrix and optimized LSTM[J]. *Process Safety and Environmental Protection*, 2023, 178: 18-33.
- [59] Wang Y, Wan Y M, Zhang H, et al. Robust decomposition of kernel function-based nonlinear robust multimode process monitoring[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 3511711.
- [60] Xu H, Caramanis C, Sanghavi S. Robust PCA via outlier pursuit[J]. *IEEE Transactions on Information Theory*, 2012, 58(5): 3047-3064.
- [61] Liu G C, Lin Z C, Yu Y. Robust subspace segmentation by low-rank representation[C]. *Proceedings of the 27th International Conference on Machine Learning*. Haifa: ACM, 2010: 663-670.
- [62] Candès E, Plan Y. Matrix completion with noise[J]. *Proceedings of the IEEE*, 2009, 98: 925-936.
- [63] Zhou Z H, Li X D, Wright J, et al. Stable principal

- component pursuit[C]. IEEE International Symposium on Information Theory. Austin, 2010: 1518-1522.
- [64] Yan Z B, Yao Y, Zhang Z J. Robust fault isolation using stable principal component pursuit[M]. Computer Aided Chemical Engineering. Amsterdam: Elsevier, 2016: 769-774.
- [65] Yan Z B, Chen C Y, Luo L K, et al. Stable principal component pursuit-based thermographic data analysis for defect detection in polymer composites[J]. Journal of Process Control, 2017, 49: 36-44.
- [66] Chen C Y, Yao Y. Robust process monitoring via stable principal component pursuit[J]. IFAC-PapersOnLine, 2015, 48(8): 617-622.
- [67] Yan Z B, Chen C Y, Yao Y, et al. Robust multivariate statistical process monitoring via stable principal component pursuit[J]. Industrial & Engineering Chemistry Research, 2016, 55(14): 4011-4021.
- [68] Li W Q, Wang Y. A robust supervised subspace learning approach for output-relevant prediction and detection against outliers[J]. Journal of Process Control, 2021, 106: 184-194.
- [69] Hu Z W, Zhao H T, Peng J C. Low-rank reconstruction-based autoencoder for robust fault detection[J]. Control Engineering Practice, 2022, 123: 105156.
- [70] Zhang M Q, Zhang W, Chiu M S, et al. Scalable active subspace low-rank graph representation for continuous system online security evaluation with input corruption[J]. Process Safety and Environmental Protection, 2022, 158: 242-256.
- [71] Pan Y J, Yang C J, An R Q, et al. Fault detection with improved principal component pursuit method[J]. Chemometrics and Intelligent Laboratory Systems, 2016, 157: 111-119.
- [72] Fu Y J, Luo C M, Bi Z M. Low-rank joint embedding and its application for robust process monitoring[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 3515313.
- [73] Fu Y J, Ding J L, Xu X. Low-rank multimanifold embedding learning for multimode process monitoring[J]. IEEE Transactions on Industrial Informatics, 2024, 20(3): 3468-3477.
- [74] Miao Z H, Xiu X C. Efficient and robust process monitoring using structured low-rank representation[J]. IEEE Transactions on Circuits and Systems II: Express Briefs, 2022, 69(8): 3530-3534.
- [75] Olshausen B A, Field D J. Emergence of simple-cell receptive field properties by learning a sparse code for natural images[J]. Nature, 1996, 381(6583): 607-609.
- [76] Zheng J L, Zhao C H. Enhanced canonical variate analysis with slow feature for dynamic process status analytics[J]. Journal of Process Control, 2020, 95: 10-31.
- [77] Zhang S M, Zhao C H, Huang B. Simultaneous static and dynamic analysis for fine-scale identification of process operation statuses[J]. IEEE Transactions on Industrial Informatics, 2019, 15(9): 5320-5329.
- [78] Xiao Z B, Wang H G. Sparse representation residual space analysis and its application to multimode batch process monitoring[J]. Industrial & Engineering Chemistry Research, 2016, 55(1): 187-196.
- [79] Xiao Z B, Wang H G, Zhou J W. Robust dynamic process monitoring based on sparse representation preserving embedding[J]. Journal of Process Control, 2016, 40: 119-133.
- [80] Guo T X, Zhou D H, Zhang J F, et al. Fault detection based on robust characteristic dimensionality reduction[J]. Control Engineering Practice, 2019, 84: 125-138.
- [81] Tang H F, Chen J, Dong G M. Sparse representation based latent components analysis for machinery weak fault detection[J]. Mechanical Systems and Signal Processing, 2014, 46(2): 373-388.
- [82] Ren L K, Lv W M, Jiang S W, et al. Fault diagnosis using a joint model based on sparse representation and SVM[J]. IEEE Transactions on Instrumentation and Measurement, 2016, 65(10): 2313-2320.
- [83] Aharon M, Elad M, Bruckstein A. K-SVD: An algorithm for designing overcomplete dictionaries for sparse representation[J]. IEEE Transactions on Signal Processing, 2006, 54(11): 4311-4322.
- [84] Rubinstein R, Bruckstein A M, Elad M. Dictionaries for sparse representation modeling[J]. Proceedings of the IEEE, 2010, 98(6): 1045-1057.
- [85] Ren L K, Lv W M. Fault detection via sparse representation for semiconductor manufacturing processes[J]. IEEE Transactions on Semiconductor Manufacturing, 2014, 27(2): 252-259.
- [86] Yang C H, Zhou L F, Huang K K, et al. Multimode process monitoring based on robust dictionary learning with application to aluminium electrolysis process[J]. Neurocomputing, 2019, 332: 305-319.
- [87] Wang Y, Zheng Y, Wang Z J, et al. Time-weighted kernel-sparse-representation-based real-time nonlinear multimode process monitoring[J]. IEEE Transactions on Industrial Informatics, 2022, 18(4): 2411-2421.
- [88] Huang K K, Wen H F, Ji H Q, et al. Nonlinear process monitoring using kernel dictionary learning with application to aluminum electrolysis process[J]. Control Engineering Practice, 2019, 89: 94-102.
- [89] Chen X, Zhao C H, Ding J L, et al. Input-output directed dependency: Driving-disentangled dynamic mode decomposition for control system representation learning and monitoring[J]. IEEE Transactions on Industrial Electronics, 2024, 71(10): 13428-13438.
- [90] Wang K, He D J, Chen G C, et al. Reordered short-term autocorrelation-driven long-range discriminative

- convolutional autoencoder for dynamic process monitoring[J]. *Journal of Process Control*, 2024, 135: 103176.
- [91] Ku W F, Storer R H, Georgakis C. Disturbance detection and isolation by dynamic principal component analysis[J]. *Chemometrics and Intelligent Laboratory Systems*, 1995, 30(1): 179-196.
- [92] Sánchez-Fernández A, Baldán F J, Sainz-Palmero G I, et al. Fault detection based on time series modeling and multivariate statistical process control[J]. *Chemometrics and Intelligent Laboratory Systems*, 2018, 182: 57-69.
- [93] Zheng J L, Chen X, Zhao C H. Interval-aware probabilistic slow feature analysis for irregular dynamic process monitoring with missing data[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2023, 53(10): 6553-6564.
- [94] Li G, Qin S J, Zhou D H. A new method of dynamic latent-variable modeling for process monitoring[J]. *IEEE Transactions on Industrial Electronics*, 2014, 61(11): 6438-6445.
- [95] Wiskott L, Sejnowski T J. Slow feature analysis: Unsupervised learning of invariances[J]. *Neural Computation*, 2002, 14(4): 715-770.
- [96] Qin Y, Zhao C H. Comprehensive process decomposition for closed-loop process monitoring with quality-relevant slow feature analysis[J]. *Journal of Process Control*, 2019, 77: 141-154.
- [97] 狄克松, 王宇红, 尚超, 等. 基于非线性慢特征回归的动态软测量建模[J]. *计算机与应用化学*, 2016, 33(11): 1160-1164.
(Di K S, Wang Y H, Shang C, et al. Dynamic soft sensor modeling based on nonlinear slow feature analysis[J]. *Computers and Applied Chemistry*, 2016, 33(11): 1160-1164.)
- [98] Song P Y, Zhao C H. Slow down to go better: A survey on slow feature analysis[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2024, 35(3): 3416-3436.
- [99] Shang C, Yang F, Gao X Q, et al. Concurrent monitoring of operating condition deviations and process dynamics anomalies with slow feature analysis[J]. *AIChE Journal*, 2015, 61(11): 3666-3682.
- [100] Zhang N, Tian X M, Cai L F, et al. Process fault detection based on dynamic kernel slow feature analysis[J]. *Computers & Electrical Engineering*, 2015, 41: 9-17.
- [101] Yu W K, Zhao C H. Recursive exponential slow feature analysis for fine-scale adaptive processes monitoring with comprehensive operation status identification[J]. *IEEE Transactions on Industrial Informatics*, 2019, 15(6): 3311-3323.
- [102] Guo F H, Shang C, Huang B, et al. Monitoring of operating point and process dynamics via probabilistic slow feature analysis[J]. *Chemometrics and Intelligent Laboratory Systems*, 2016, 151: 115-125.
- [103] Zheng J L, Zhao C H. Online monitoring of performance variations and process dynamic anomalies with performance-relevant full decomposition of slow feature analysis[J]. *Journal of Process Control*, 2019, 80: 89-102.
- [104] Song P Y, Zhao C H, Huang B. SFNet: A slow feature extraction network for parallel linear and nonlinear dynamic process monitoring[J]. *Neurocomputing*, 2022, 488: 359-380.
- [105] Dong Y N, Liu Y X, Joe Qin S. Efficient dynamic latent variable analysis for high-dimensional time series data[J]. *IEEE Transactions on Industrial Informatics*, 2020, 16(6): 4068-4076.
- [106] Dong Y N, Qin S J. New dynamic predictive monitoring schemes based on dynamic latent variable models[J]. *Industrial & Engineering Chemistry Research*, 2020, 59(6): 2353-2365.
- [107] Dong Y N, Qin S J. Regression on dynamic PLS structures for supervised learning of dynamic data[J]. *Journal of Process Control*, 2018, 68: 64-72.
- [108] Zhu Q Q, Joe Qin S, Dong Y N. Dynamic latent variable regression for inferential sensor modeling and monitoring[J]. *Computers & Chemical Engineering*, 2020, 137: 106809.
- [109] Akaike H. Markovian representation of stochastic processes by canonical variables[J]. *SIAM Journal on Control*, 1975, 13(1): 162-173.
- [110] Zhao C H, Wang W, Tian C, et al. Fine-scale modeling and monitoring of wide-range nonstationary batch processes with dynamic analytics[J]. *IEEE Transactions on Industrial Electronics*, 2021, 68(9): 8808-8818.
- [111] Chai Z, Zhao C H. Enhanced random forest with concurrent analysis of static and dynamic nodes for industrial fault classification[J]. *IEEE Transactions on Industrial Informatics*, 2020, 16(1): 54-66.
- [112] Negiz A, Çınar A. Statistical monitoring of multivariable dynamic processes with state-space models[J]. *AIChE Journal*, 1997, 43(8): 2002-2020.
- [113] Natarajan B K. Sparse approximate solutions to linear systems[J]. *SIAM Journal on Computing*, 1995, 24(2): 227-234.
- [114] Donoho D L. Compressed sensing[J]. *IEEE Transactions on Information Theory*, 2006, 52(4): 1289-1306.
- [115] Zhang S M, Bao X L, Wang S J. Common canonical variate analysis (CCVA) based modeling and monitoring for multimode processes[J]. *Chemical Engineering Science*, 2023, 271: 118581.
- [116] Zou X Y, Zhao C H. Concurrent assessment of process operating performance with joint static and dynamic analysis[J]. *IEEE Transactions on Industrial Informatics*, 2020, 16(4): 2776-2786.
- [117] Zhao C H, Huang B. A full-condition monitoring

- method for nonstationary dynamic chemical processes with cointegration and slow feature analysis[J]. *AIChE Journal*, 2018, 64(5): 1662-1681.
- [118] 赵春晖, 余万科, 高福荣. 非平稳间歇过程数据解析与状态监控——回顾与展望[J]. *自动化学报*, 2020, 46(10): 2072-2091.
(Zhao C H, Yu W K, Gao F R. Data analytics and condition monitoring methods for nonstationary batch processes—Current status and future[J]. *Acta Automatica Sinica*, 2020, 46(10): 2072-2091.)
- [119] Scott D, Shang C, Huang B, et al. A holistic probabilistic framework for monitoring nonstationary dynamic industrial processes[J]. *IEEE Transactions on Control Systems Technology*, 2021, 29(5): 2239-2246.
- [120] Zhao C H, Wang F L, Lu N Y, et al. Stage-based soft-transition multiple PCA modeling and on-line monitoring strategy for batch processes[J]. *Journal of Process Control*, 2007, 17(9): 728-741.
- [121] Zhao C H, Chen J H, Jing H. Condition-driven data analytics and monitoring for wide-range nonstationary and transient continuous processes[J]. *IEEE Transactions on Automation Science and Engineering*, 2021, 18(4): 1563-1574.
- [122] Wu D H, Sheng L, Zhou D H, et al. Dynamic stationary subspace analysis for monitoring nonstationary dynamic processes[J]. *Industrial & Engineering Chemistry Research*, 2020, 59(47): 20787-20797.
- [123] Chen X, Hu Y Y, Zhao C H. Multiple condition indicator decoupling and hierarchical monitoring for large-scale nonstationary processes[J]. *Industrial & Engineering Chemistry Research*, 2022, 61(14): 4896-4909.
- [124] Hara S, Kawahara Y, Washio T, et al. Separation of stationary and non-stationary sources with a generalized eigenvalue problem[J]. *Neural Networks*, 2012, 33: 7-20.
- [125] Song P Y, Zhao C H, Ding J L, et al. Multimodal decoupled representation with compatibility learning for explicit nonstationary process monitoring[J]. *IEEE Transactions on Industrial Electronics*, 2024, 71(7): 8121-8131.
- [126] Lin Y L, Kruger U, Chen Q. Monitoring nonstationary dynamic systems using cointegration and common-trends analysis[J]. *Industrial & Engineering Chemistry Research*, 2017, 56(31): 8895-8905.
- [127] Zheng J L, Chen X, Zhao C H. Coarse-to-fine condition identification for wide-range non-stationary processes driven by coupled condition indicators[J]. *Control Engineering Practice*, 2022, 128: 105328.
- [128] Zhao C H, Sun H. Dynamic distributed monitoring strategy for large-scale nonstationary processes subject to frequently varying conditions under closed-loop control[J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(6): 4749-4758.
- [129] Li G, Qin S J, Yuan T. Nonstationarity and cointegration tests for fault detection of dynamic processes[J]. *IFAC Proceedings Volumes*, 2014, 47(3): 10616-10621.
- [130] Hu Y Y, Zhao C H. Fault diagnosis with dual cointegration analysis of common and specific nonstationary fault variations[J]. *IEEE Transactions on Automation Science and Engineering*, 2020, 17(1): 237-247.
- [131] Lee S, Kim S B. Time-adaptive support vector data description for nonstationary process monitoring[J]. *Engineering Applications of Artificial Intelligence*, 2018, 68: 18-31.
- [132] 刘金平, 王杰, 刘先锋, 等. 基于递归稀疏主成分分析的工业过程在线故障监测和诊断[J]. *控制与决策*, 2020, 35(8): 2006-2012.
(Liu J P, Wang J, Liu X F, et al. Online fault monitoring and diagnosis using recursive sparse principal component analysis[J]. *Control and Decision*, 2020, 35(8): 2006-2012.)
- [133] Feng X W, Kong X Y, Du B Y, et al. Adaptive LII-RMPLS based data-driven process monitoring scheme for quality-relevant fault detection[J]. *Journal of Control and Decision*, 2022, 9(4): 477-488.
- [134] Chen Z W, Liu C, Ding S X, et al. A just-in-time-learning-aided canonical correlation analysis method for multimode process monitoring and fault detection[J]. *IEEE Transactions on Industrial Electronics*, 2021, 68(6): 5259-5270.
- [135] Yin S, Gao H J, Qiu J B, et al. Fault detection for nonlinear process with deterministic disturbances: A just-in-time learning based data driven method[J]. *IEEE Transactions on Cybernetics*, 2017, 47(11): 3649-3657.
- [136] 谭帅, 常玉清, 王福利, 等. 基于GMM的多模态过程模态识别与过程监测[J]. *控制与决策*, 2015, 30(1): 53-58.
(Tan S, Chang Y Q, Wang F L, et al. Mode identification and process monitoring for multiple mode processes based on GMM[J]. *Control and Decision*, 2015, 30(1): 53-58.)
- [137] 张瑞垚, 周平. 基于鲁棒加权模糊聚类的污水处理过程监测方法[J]. *自动化学报*, 2022, 48(9): 2198-2211.
(Zhang R Y, Zhou P. Robust weighted fuzzy clustering for sewage treatment process monitoring[J]. *Acta Automatica Sinica*, 2022, 48(9): 2198-2211.)
- [138] Yu W K, Zhao C H, Huang B. Recursive cointegration analytics for adaptive monitoring of nonstationary industrial processes with both static and dynamic variations[J]. *Journal of Process Control*, 2020, 92: 319-332.
- [139] Wu D H, Zhou D H, Chen M Y. Probabilistic stationary subspace analysis for monitoring nonstationary industrial processes with uncertainty[J]. *IEEE Transactions on Industrial Informatics*, 2022, 18(5): 3114-3125.
- [140] Johansen S, Juselius K. Maximum likelihood estimation

- and inference on cointegration— With applications to the demand for money[J]. *Oxford Bulletin of Economics and Statistics*, 1990, 52(2): 169-210.
- [141] Zhang J X, Zhou D H, Chen M Y. Adaptive cointegration analysis and modified RPCA with continual learning ability for monitoring multimode nonstationary processes[J]. *IEEE Transactions on Cybernetics*, 2023, 53(8): 4841-4854.
- [142] Huang K K, Zhang L, Yang C H, et al. Unified stationary and nonstationary data representation for process monitoring in IIoT[J]. *IEEE Transactions on Instrumentation and Measurement*, 2022, 71: 3512812.
- [143] Kullback S, Leibler R A. On information and sufficiency[J]. *The Annals of Mathematical Statistics*, 1951, 22(1): 79-86.
- [144] Yu W K, Zhao C H, Huang B. Stationary subspace analysis-based hierarchical model for batch processes monitoring[J]. *IEEE Transactions on Control Systems Technology*, 2021, 29(1): 444-453.
- [145] Chen J H, Zhao C H. Exponential stationary subspace analysis for stationary feature analytics and adaptive nonstationary process monitoring[J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(12): 8345-8356.
- [146] Lou S W, Yang C J, Zhang X J, et al. Blast furnace ironmaking process monitoring with time-constrained global and local nonlinear analytic stationary subspace analysis[J]. *IEEE Transactions on Industrial Informatics*, 2024, 20(3): 3163-3176.
- [147] Lin Y L, Kruger U, Gu F S, et al. Monitoring nonstationary processes using stationary subspace analysis and fractional integration order estimation[J]. *Industrial & Engineering Chemistry Research*, 2019, 58(16): 6486-6504.
- [148] Wang M, Sheng L, Zhou D H, et al. A feature weighted mixed naive Bayes model for monitoring anomalies in the fan system of a thermal power plant[J]. *IEEE/CAA Journal of Automatica Sinica*, 2022, 9(4): 719-727.
- [149] Wang M, Zhou D H, Chen M Y. Hybrid variable monitoring: An unsupervised process monitoring framework with binary and continuous variables[J]. *Automatica*, 2023, 147: 110670.
- [150] Wang M, Zhou D H, Chen M Y. Anomaly monitoring of nonstationary processes with continuous and two-valued variables[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2023, 53(1): 49-58.
- [151] Chen J H, Zhao C H, Ding J L. A flexible probabilistic framework with concurrent analysis of continuous and categorical data for industrial fault detection and diagnosis[J]. *IEEE Transactions on Industrial Informatics*, 2023, 19(10): 10578-10590.
- [152] Feng L J, Zhao C H. Fault description based attribute transfer for zero-sample industrial fault diagnosis[J]. *IEEE Transactions on Industrial Informatics*, 2021, 17(3): 1852-1862.
- [153] Feng L J, Zhao C H. Transfer increment for generalized zero-shot learning[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 32(6): 2506-2520.
- [154] Mou M, Zhao X Q, Liu K, et al. Variational autoencoder based on distributional semantic embedding and cross-modal reconstruction for generalized zero-shot fault diagnosis of industrial processes[J]. *Process Safety and Environmental Protection*, 2023, 177: 1154-1167.
- [155] Chen X, Zhang B L, Zhao C H, et al. From coarse to fine: Hierarchical zero-shot fault diagnosis with multigrained attributes[J]. *IEEE Transactions on Fuzzy Systems*, 2024, 32(5): 2837-2849.
- [156] Li B X, Zhao C H. Federated zero-shot industrial fault diagnosis with cloud-shared semantic knowledge base[J]. *IEEE Internet of Things Journal*, 2023, 10(13): 11619-11630.
- [157] Xu J, Zhou L, Zhao W H, et al. Zero-shot learning for compound fault diagnosis of bearings[J]. *Expert Systems with Applications*, 2022, 190: 116197.
- [158] Zhou B, Shen X W, Lu Y Q, et al. Semantic-aware event link reasoning over industrial knowledge graph embedding time series data[J]. *International Journal of Production Research*, 2023, 61(12): 4117-4134.
- [159] Chen X, Zhao C H, Ding J L. Pyramid-type zero-shot learning model with multi-granularity hierarchical attributes for industrial fault diagnosis[J]. *Reliability Engineering & System Safety*, 2023, 240: 109591.
- [160] Yue J Q, Zhao J C, Zhao C H. Similarity makes difference: SSHTN for generalized zero-shot industrial fault diagnosis by leveraging auxiliary set[J]. *IEEE Transactions on Industrial Informatics*, 2024, 20(5): 7598-7607.
- [161] 文载道, 王佳蕊, 王小旭, 等. 解耦表征学习综述[J]. *自动化学报*, 2022, 48(2): 351-374.
(Wen Z D, Wang J R, Wang X X, et al. A review of disentangled representation learning[J]. *Acta Automatica Sinica*, 2022, 48(2): 351-374.)
- [162] Liu X, Hu Q P, Li J S, et al. Decoupling representation contrastive learning for carbon emission prediction and analysis based on time series[J]. *Applied Energy*, 2024, 367: 123368.
- [163] Song P Y, Zhao C H, Huang B, et al. Explicit representation and customized fault isolation framework for learning temporal and spatial dependencies in industrial processes[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2024, 35(3): 2997-3011.
- [164] Jiang B, Zhang K, Liu C, et al. Fault diagnosis and accommodation with flight control applications[J]. *Journal of Control and Decision*, 2020, 7(1): 24-43.
- [165] Abbasi Nozari H, Sadati Rostami S J, Castaldi P,

- et al. Hybrid robust fault detection and isolation of satellite reaction wheel actuators[J]. *Journal of Control and Decision*, 2024, 11(1): 117-131.
- [166] Granger C W J. Investigating causal relations by econometric models and cross-spectral methods[J]. *Econometrica*, 1969, 37(3): 424-438.
- [167] Schreiber T. Measuring information transfer[J]. *Physical Review Letters*, 2000, 85(2): 461-464.
- [168] Sugihara G, May R, Ye H, et al. Detecting causality in complex ecosystems[J]. *Science*, 2012, 338(6106): 496-500.
- [169] 赵春晖, 宋鹏宇. 从结构推断到根因识别——工业过程故障根因诊断研究综述[J]. *控制与决策*, 2023, 38(8): 2130-2157.
(Zhao C H, Song P Y. From structure inference to root cause identification: A survey on root cause diagnosis of industrial process faults[J]. *Control and Decision*, 2023, 38(8): 2130-2157.)
- [170] Chen H S, Yan Z B, Yao Y, et al. Systematic procedure for granger-causality-based root cause diagnosis of chemical process faults[J]. *Industrial & Engineering Chemistry Research*, 2018, 57(29): 9500-9512.
- [171] Zhang H J, Peng K X, Ma L. A systematic nonstationary causality analysis framework for root cause diagnosis of faults in manufacturing processes[J]. *Control Engineering Practice*, 2023, 131: 105404.
- [172] Song P Y, Zhao C H, Huang B, et al. Sparse and time-varying predictive relation extraction for root cause quantification of nonstationary process faults[J]. *IEEE Transactions on Instrumentation and Measurement*, 2022, 71: 3525013.
- [173] Yuan T, Qin S J. Root cause diagnosis of plant-wide oscillations using Granger causality[J]. *Journal of Process Control*, 2014, 24(2): 450-459.
- [174] Yu J, Rashid M M. A novel dynamic Bayesian network-based networked process monitoring approach for fault detection, propagation identification, and root cause diagnosis[J]. *AIChE Journal*, 2013, 59(7): 2348-2365.
- [175] Song P Y, Zhao C H, Huang B. MPGE and RootRank: A sufficient root cause characterization and quantification framework for industrial process faults[J]. *Neural Networks*, 2023, 161: 397-417.
- [176] Zhang Z D, Dong F L. Fault detection and diagnosis for missing data systems with a three time-slice dynamic Bayesian network approach[J]. *Chemometrics and Intelligent Laboratory Systems*, 2014, 138: 30-40.
- [177] Senol Y E, Aydogdu Y V, Sahin B, et al. Fault tree analysis of chemical cargo contamination by using fuzzy approach[J]. *Expert Systems with Applications*, 2015, 42(12): 5232-5244.
- [178] Chen J W, Zhao C H. Multi-lag and multi-type temporal causality inference and analysis for industrial process fault diagnosis[J]. *Control Engineering Practice*, 2022, 124: 105174.
- [179] Yazdi M, Korhan O, Daneshvar S. Application of fuzzy fault tree analysis based on modified fuzzy AHP and fuzzy TOPSIS for fire and explosion in the process industry[J]. *International Journal of Occupational Safety and Ergonomics*, 2020, 26(2): 319-335.

作者简介

赵春晖(1979-),女,教授,博士,博士生导师,从事工业大数据分析与应用、状态监测、故障诊断、软测量等研究, E-mail: chhzhaoc@zju.edu.cn;

陈旭(1997-),男,博士生,从事工业大数据分析、工业过程监测、故障诊断等研究, E-mail: 3160102260@zju.edu.cn.

科研团队简介

课题组负责人赵春晖教授是国家杰出青年基金获得者,中国青年女科学家奖获得者,CAA Fellow. 主要研究方向为人工智能理论、状态监控与故障诊断、质量分析与工艺优化等,涉及能源发电、化工生产等不同领域. 近年主持10余项科研项目,包括国家自科杰青、优青、联合基金、国家重点研发课题以及省重点研发项目、重大企业合作课题等,与多家企业开展合作. 围绕机器学习、数据知识融合等研究,发表国际SCI/EI论文300余篇. 一作出版数据分析相关专著3本,授权发明专利60余项. 10余篇论文入选ESI高被引论文,2篇为热点论文. 担任6家权威期刊编委,包括 *Journal of Process Control*, *Control Engineering Practice*, *Neurocomputing* 等. 担任多家重要学术机构委员,包括两家国际自控联技术委员会委员、IEEE Senior Member、自动化学会女科技工作者专委会秘书长以及过控专委会常务委员等. 曾获国家杰出青年基金、优秀青年基金、中国青年女科学家奖、教育部新世纪优秀人才、浙江省首届青年科技英才奖、浙江省杰出青年基金、中国自动化学会会士、首届中国自动化学会青年女科学家等荣誉奖励. 连续两年入选斯坦福大学全球前2%顶尖科学家. 过程监测与故障诊断相关成果曾获教育部自然科学一等奖、自动化学会自然科学一等奖等重要奖励十多项,近20次获得权威学术会议的最佳论文奖或提名奖.