

DOI: 10.19650/j.cnki.cjsi.J2310964

一种新的工业过程振荡数据去噪技术*

郎煜民¹, 郎 恂¹, 吴建德^{1,2}, 刘 燕³, 李 鹏¹

(1. 云南大学信息学院 昆明 650000; 2. 云南大学云南省智能系统与计算重点实验室 昆明 650000;
3. 东北林业大学计算机与控制学院 哈尔滨 150006)

摘 要: 振荡现象是工业过程控制回路性能恶化的重要表现, 因此有效的振荡监控机制对于保证过程的安全稳定运行至关重要。然而, 过程振荡数据中普遍存在随机噪声和外部扰动等因素, 导致信噪比较低, 严重影响振荡检测与诊断的准确性。为此, 提出一种新的工业过程数据去噪技术, 结合自适应噪声完备集合经验模态分解 (CEEMDAN)、去趋势波动分析 (DFA) 与典型相关分析 (CCA)。首先, 利用 CEEMDAN 对信号进行分解, 得到一系列固有模态函数 (IMFs); 接着, 通过 DFA 将 IMF 分量划分为信息主导和噪声主导两类; 然后, 对噪声主导的 IMF 分量应用 CCA 以去除噪声; 最后, 将 CCA 输出的结果与信息主导的 IMF 分量叠加, 得到去噪后的振荡信号。仿真和实际工业振荡数据的实验结果表明, 与现有的去噪技术相比, 方法在去噪后的信号相对均方根误差最低, 相关性最高, 展示出卓越的去噪精度和鲁棒性。

关键词: 自适应噪声完备集合经验模态分解; 去趋势波动分析; 典型相关分析; 工业振荡; 去噪

中图分类号: TH86 TP274+.2 **文献标识码:** A **国家标准学科分类代码:** 510.4

Novel method for oscillation data denoising in process industry

Lang Yumin¹, Lang Xun¹, Wu Jiande^{1,2}, Liu Yan³, Li Peng¹

(1. School of Information Science & Engineering, Yunnan University, Kunming 650000, China; 2. Yunnan
Key Laboratory of Intelligent Systems and Computing, Yunnan University, Kunming 650000, China;
3. School of Computer and Control Engineering, Northeast Forestry University, Harbin 150006, China)

Abstract: Oscillation is a significant indicator of performance degradation in industrial process control loops. Therefore, an effective oscillation monitoring mechanism is essential for ensuring the safe and stable operation of these processes. However, random noise and external disturbances are prevalent in process oscillation data, leading to a low signal-to-noise ratio (SNR), which severely affects the accuracy of oscillation detection and diagnosis. To address this, this paper proposes a novel denoising technique for industrial process data, combining complete ensemble empirical mode decomposition with adaptive noise (CEEMDAN), detrended fluctuation analysis (DFA), and canonical correlation analysis (CCA). First, CEEMDAN is used to decompose the signal into a series of intrinsic mode functions (IMFs). Next, DFA is employed to classify the IMF components into information-dominated and noise-dominated categories. Then, CCA is applied to the noise-dominated IMF components to remove noise. Finally, the outputs of CCA are combined with the information-dominated IMF components to reconstruct the denoised oscillation signal. Simulation and experimental results using actual industrial oscillation data show that, compared to existing denoising techniques, this method achieves the lowest root mean squared relative error (RMSE) and the highest correlation in the denoised signals, demonstrating excellent denoising accuracy and robustness.

Keywords: complete ensemble empirical mode decomposition with adaptive noise; detrended fluctuation analysis; canonical correlation analysis; industrial oscillation; denoising

0 引言

日趋规模化与集成化的流程工业为生产过程控制系统带来了越来越多的挑战,底层控制回路的维护任务也变得愈发艰巨^[1]。Dambros 等^[2]通过大量调查指出振荡仍是过程控制中最常见的问题之一。工业振荡数据周期长、伪迹多、易受测量设备干扰,加之生产工艺的原料波动、操作条件变化及机械磨损等固有因素,使得相应过程呈现出低信噪比、多尺度、非线性及非平稳等综合特征^[3],严重影响后续的振荡检测与诊断准确性,进而阻碍流程工业的安全稳定运行。如何净化过程振荡数据,消除干扰振荡监控技术适用性的复杂伪迹,成为一项亟待研究的新问题。

传统去噪技术为工业数据预处理奠定了良好的算法基础。为净化噪声数据,Wang 等^[4]利用小波去噪技术丢弃噪声成分。但由于小波基函数的自适应性差,导致信号重构精度低。为改善小波分解的缺陷,Dong 等^[5]提出经验模态分解(empirical mode decomposition, EMD)与迭代间隔阈值相结合的去噪技术(EMD-IIT)。该方法在分解过程中易出现模态混叠现象(产生虚假分量),降低重构质量。受 EMD 阈值去噪技术的启发,文献[6]研究了变分模态分解(variational mode decomposition, VMD)与去趋势波动分析(detrended fluctuation analysis, DFA)相结合的间隙阈值去噪方法,并采用蒙特卡罗实验与实测雷达数据验证了方法的有效性。另一方面,Zhong 等^[7]基于小波变换和窄带信号分析理论提出经验小波变化(empirical wavelet transform, EWT)用于隔离噪声分量。上述两种去噪方案对于表征非线性程度高的真实数据具有边界局限性,去噪效果差。

在工业振荡监测领域,文献[8-9]在提出振荡监测算法的同时匹配了相应的数据去噪或预处理步骤,然而所涉及的去噪手段多局限于特定数据或过程,不具备通用性。工业过程振荡数据去噪研究于 2017 年才被首次讨论,国内外研究动态及基础尚处于起步阶段。针对这一主题,Zhou 等^[10]提出启发式的方法来检测和消除振荡信号中的瞬态变化;Chen 等^[11]建议利用排列熵及相应阈值丢弃噪声分量。然而上述方法可移植性差,无法作为通用的振荡数据去噪手段。鉴于此,Lang 等^[12-13]针对振荡信号通常具有高度自相关性的特点提出了将集合经验模态分解(ensemble empirical mode decomposition, EEMD)与典型相关分析(canonical correlation analysis, CCA)相结合的去噪技术,并在仿真与典型工业案例中成功恢复了振荡成分特征和波形,表现出良好的去噪性能。同时,针对 EEMD 中存在的模态混叠现象,文献[14-15]提出了中值互补集合经验模态分解(median complementary

ensemble EMD, MCEEMD)抑制了模态混叠现象,提升了分解完备性。此外,类似的信号分解与去噪结合的思路,已被成功应用于多个领域的去噪问题^[16-17]。

然而,EEMD-CCA 方法在重构过程中常表现出鲁棒性差、振荡信息丢失等问题,不利于对原始振荡特征的准确估计。为此,本文提出一种新的工业过程振荡数据去噪技术,该技术融合了完备自适应噪声集合经验模态分解(complete EEMD with adaptive noise, CEEMDAN),去趋势波动分析和典型相关分析。首先利用 CEEMDAN 将原始信号分解为一系列固有模态函数集(intrinsic mode functions, IMFs)。然后,采用 DFA 对 IMFs 进行筛选,区分噪声主导和信息主导的 IMFs,以保留完整的振荡信息,并提升噪声识别的精确度。最后,对噪声主导的 IMFs 应用 CCA 算法,将处理后的结果与信息主导的 IMFs 进行累加,从而得到去噪处理后的振荡信号。仿真案例与真实工业案例的去噪结果验证了所提方法的有效性。

本文采用 CEEMDAN 算法取代了传统的 EEMD 算法。通过引入自适应噪声集合替代原始单一噪声,实现筛分过程的精确重构,进而有效解决 EEMD 方法中普遍存在的噪声残留以及模态数目差异等问题。引入 DFA 量化信号在较长时间尺度的相关性。通过揭示信号中是否存在周期性行为,即振荡成分,将分解所得 IMFs 划分为噪声主导和振荡信息主导两类。该划分策略不仅保留了更为本质的振荡特征,而且有效解决了 EEMD-CCA 方法中可能出现的振荡信息丢失问题。

1 EEMD-CCA 方法回顾

工业过程数据中,振荡成分通常表征出高度自相关性,而噪声、扰动等其他成分因其频谱分布宽泛导致自相关性较低^[18]。鉴于此,文献[12-13]提出 EEMD-CCA 方法,该方法旨在振荡振荡数据进行去噪处理。该方法首先使用 EEMD 将原始信号不同尺度成分分配到不同通道中,形成一组多通道 IMFs 信号(注意,筛选后残余信号将作为趋势成分被剔除)。然后,使用 CCA 算法根据振荡成分与噪声的自相关性差异,设定阈值筛分过程数据中的振荡成分和噪声伪迹成分,以达到抑制各通道中的噪声的目的。最后,将去除噪声后的 IMFs 信号叠加,还原潜在振荡成分。经过典型仿真模型和真实工业案例的验证,该方法展现出较好的应用有效性。

然而,EEMD-CCA 方法存在重构结果不稳定、振荡信息丢失等问题。为验证这一说法,使用时变振荡加高斯白噪声的数值模型进行实验,其数学表达式为:

$$x(t) = [1 + 0.5\sin(0.5\pi ft)] \{ \sin[100\pi t + 2\sin(\pi ft)] \} + \beta\omega(t) \quad (1)$$

式中: $\omega(t)$ 为服从 $\mathcal{N}(0,1)$ 分布的高斯白噪声。

设置如下参数:频率 f 在 2 ~ 7 (间隔为 1), 噪声幅值 $\beta = 0.25$, 采样频率 $f_s = 1\,000$, 数据长度 $T = 1\,024$ 。

1.1 不稳定性问题溯源

首先,采用 EEMD 分解振荡信号得到 M 个 IMF 函数;随后将 IMF 函数应用 CCA 算法求解源矩阵的自相关系数,并将自相关值小于设定阈值 $\rho = 0.9$ 的源分量置为 0;最后执行逆 CCA 算法获得重构信号,计算原振荡 $[1 + 0.5\sin(0.5\pi ft)] \{ \sin[100\pi t + 2\sin(\pi ft)] \}$ 与重构信号之间的重构误差。为了量化该误差,本文引入相对均方根误差^[19] (root mean squared relative error, RMSRE),其数学表达式如下:

$$RMSRE = \frac{1}{\sqrt{T}} \sqrt{\frac{\sum_{i=1}^T (x_i - y_i)^2}{\sum_{i=1}^T x_i^2}} \quad (2)$$

式中: T 是信号长度; x_i 为数值模型中的振荡分量; y_i 为重构信号。该统计值反映重构信号与原始信号的相对误差,其值越小证明重构效果越好,反之亦然。各频率 f 配置下,独立重复实验 500 次,得到相应的 RMSRE 波动情况如图 1 所示, RMSRE 的标准差均较大,且波动较大,这表明了每次实验中重构信号差异大,重构结果不稳定。




图 1 重构性能波动情况

Fig. 1 Reconstruction performance fluctuations

考虑到该现象可能由 EEMD 分解或 CCA 算法引起,本文进一步设计数值实验探索 EEMD-CCA 算法的不稳定性来源。本文针对同一仿真信号进行了 500 组数值实验。

1) 固定 EEMD 分解结果测试 CCA 稳定性。保存单次 IMF 重复输入 CCA 计算重构信号 $\hat{x}(t)$, 观察原振荡成分 $x(t)$ 与重构信号的 RMSE 数值变化情况。其结果表明该指标保持不变。

2) 测试 EEMD 稳定性。每组实验独立执行 EEMD-CCA 算法,观察 RMSE 的变化情况。结果表明,每次实验结果的 RMSE 都有明显差异。

上述实验表明, EEMD 分解的不确定性是导致 EEMD-CCA 去噪所得重构信号不稳定的根本原因。

1.2 振荡特征信息损失问题溯源

保存 EEMD 分解所得 IMF 分量,在不同 CCA 自相关阈值 ρ 配置下 (ρ 为 0.75 ~ 0.9, 间隔为 0.05) 对 $x(t)$ 执行 CCA 算法得到相应的去噪波形如图 2 所示。可以看到,对于不同阈值 ρ 配置下的 EEMD-CCA 算法,最终的去噪结果均呈现出一定程度的差异。若阈值取值较小,则存在较多噪声残余;若阈值取值较大,则损失一定振荡信息。这意味阈值参数会对该算法的振荡特征提取能力以及最终的去噪效果产生影响。




图 2 不同阈值配置下的重构信号

Fig. 2 Reconstructed signals with different threshold configurations

为保证去噪效果,文献[12]建议的阈值为 $\rho = 0.9$,这可能导致部分振荡信息损失的问题。如能在执行 CCA 算法之前预先保留振荡主导 IMF 分量,就可以在保证较好的去噪效果的同时,避免振荡信息丢失的问题。

综上所述, EEMD-CCA 算法在去噪应用中表现的问题主要由 EEMD 方法的分解不确定性^[20] (分解不同噪声辅助信号所对应的 IMF 存在显著差异) 及 CCA 的经验阈值所致。

2 振荡数据去噪技术

第 1 节通过实验演示了 EEMD-CCA 算法所存在的稳定性差及振荡信息丢失问题。鉴于此,提出一种新的工业过程振荡数据去噪技术,即 CEEMDAN-DFA-CCA。该算法首先采用更加稳定的 CEEMDAN 算法将原始信号分解为不同时间尺度的 IMF 分量。CEEMDAN 比 EEMD 具有更好的分解完备性与鲁棒性,因此能够更全面地描述信号的特征。其次,利用 DFA 方法将噪声 IMF 分量预隔离,以保留振荡信息主导的 IMF 分量。该步骤旨在解决单一使用

CCA 所导致的振荡信息缺失问题,从而进一步提高算法的去噪精度。然后,采用 CCA 方法消除噪声主导 IMF 中的噪声成分。最后,将 CCA 输出与信息主导 IMF 相加重构,即可得到纯净的振荡信号。

2.1 CEEMDAN-DFA-CCA 算法

本文提出的 CEEMDAN-DFA-CCA 具体执行步骤如下。

1) 对工业振荡数据 $x(t)$ 执行 CEEMDAN 算法分解为多通道信号 $X(t)$ 。为减小非平稳趋势项对去噪性能的影响,去除残差信号 $R(t)$ 。因此,最终 $X(t)$ 包含 M 个 IMF 集合,可表示为:

$$X(t) = [c_1(t); c_2(t); \cdots; c_M(t)] \quad (3)$$

2) 将多通道信号 $X(t)$ 输入 DFA,分离出前 N 个噪声主导 IMF (处于波动阈值 θ 范围内的 IMF 序列) 与 $M - N$ 个信息主导 IMF,简记为 IMF_{n-d} 与 IMF_{s-d} ,可表示为:

$$IMF_{n-d} = [c_1(t); c_2(t); \cdots; c_N(t)] \quad (4)$$

$$IMF_{s-d} = [c_{N+1}(t); c_{N+2}(t); \cdots; c_M(t)] \quad (5)$$

3) 将 IMF_{n-d} 输入 CCA 然后对所得源矢量按自相关系数从低至高排序,得到 N 维源矩阵 $S(t)$ 及对应的解混矩阵 W ,指定阈值 ρ_0 隔离 $S(t)$ 对应的前 $H (H < N)$ 个噪声分量,记为:

$$S_{\text{noise}}(t) = [s^1(t); s^2(t); \cdots; s^H(t)] \quad (6)$$

$$S(t) = [S_{\text{noise}}(t); s^{H+1}(t); \cdots; s^N(t)] \quad (7)$$

4) 将 $S(t)$ 中前 H 个源矢量 $S_{\text{noise}}(t)$ 置为 0,得到净化后的源矩阵 $\tilde{S}(t)$ 。最终,混合矩阵 $A(W^{-1})$ 乘以 $\tilde{S}(t)$ 获得 N 维重构信号 $\tilde{X}(t)$ 。其表达式为:

$$\tilde{S}(t) = [0; s^{H+1}(t); \cdots; s^N(t)] \quad (8)$$

$$\tilde{X}(t) = A\tilde{S}(t) = [\tilde{c}_1(t); \tilde{c}_2(t); \cdots; \tilde{c}_N(t)] \quad (9)$$

5) 去噪后的振荡数据 $\tilde{x}(t)$ 通过 $\tilde{X}(t)$ 中的 N 维行矢量与 $M - N$ 维信息主导 IMF 矢量 IMF_{s-d} 求和计算,表示为:

$$\tilde{x}(t) = \sum_{i=1}^N \tilde{c}_i(t) + \sum_{i=N+1}^M c_i(t) \quad (10)$$

2.2 CEEMDAN 算法

CEEMDAN 在分解的每个阶段添加特定的噪声(噪声幅度 ε_i 和集合尺寸 Z),计算唯一的残差以获得每个 IMF^[21],其算法的步骤如下。

1) 对给定时间序列 $x(t), t = 1, 2, \cdots, T$, 添加特定的白噪声构造噪声辅助信号,如下所示:

$$y^i(t) = x(t) + \varepsilon_0 \omega^i(t) \quad (11)$$

式中: $y^i(t)$ 是添加噪声后的分解信号, i 是加入噪声的次序 ($i = 1, 2, \cdots, Z$); ε_0 是噪声幅度; $\omega^i(t)$ 为服从 $\mathcal{N}(0, 1)$ 分布的随机白噪声序列。

2) 使用 EMD 方法对 Z 个信号进行分解,并进行平均

计算,得到第 1 组 IMF 函数。

$$\widetilde{IMF}_1(t) = \frac{1}{Z} \sum_{i=1}^Z IMF_1^i(t) \quad (12)$$

式中: $\widetilde{IMF}_1(t)$ 即为第 1 阶 IMF 函数,计算第 1 阶段 ($k=1$) 相对应的残差值。

$$r_1(t) = x(t) - \widetilde{IMF}_1(t) \quad (13)$$

3) 构造新的噪声辅助信号集合 $r_1(t) + \varepsilon_1 E_1(\omega^i(t)), i = 1, 2, \cdots, Z$, 本文定义了符号 $E_j(\cdot)$, 给定信号经过 EMD 分解后得到的第 j 个 IMF 函数;通过 EMD 依次分解该集合得到第 2 阶 IMF 函数。

$$\widetilde{IMF}_2(t) = \frac{1}{Z} \sum_{i=1}^Z E_1(r_1(t) + \varepsilon_1 E_1(\omega^i(t))) \quad (14)$$

4) 遵循上述准则,对每个阶段 $k = 3, \cdots, M$ (假定第 M 阶段后不再满足 EMD 分解条件,无法继续分解),计算其 $j-1$ 阶残差项 $r_{j-1}(t) = r_{j-2}(t) - \widetilde{IMF}_{k-1}(t)$ 和第 j 个模态结果。

$$\widetilde{IMF}_k(t) = \frac{1}{Z} \sum_{i=1}^Z E_1(r_{k-1}(t) + \varepsilon_{k-1} E_{k-1}(\omega^i(t))) \quad (15)$$

5) 当到达第 M 阶段后,计算最后残差项为:

$$R(t) = x(t) - \sum_{k=1}^M \widetilde{IMF}_k(t) \quad (16)$$

最终得到 M 个 IMF 函数。因此,给定信号 $x(t)$ 可表示为:

$$x(t) = \sum_{k=1}^M \widetilde{IMF}_k(t) + R(t) \quad (17)$$

CEEMDAN 算法可有效消除添加白噪声所引起的误差,提升分解完备性,同时克服 EEMD 筛分过程中分解独立噪声信号而产生不同模态数目的问题。此外,它还降低了分解迭代次数,对于不同频率成分的信号具有更高的分辨率。

2.3 去趋势波动分析

DFA 作为非平稳特性下赫斯特指数的扩展版本,是一种衡量非平稳序列长程相关性的方法^[22]。该方法旨在消除时间序列的局部趋势从而避免非平稳性造成的虚假相关性,其具体步骤如下。

1) 对时间序列 $x(t), t = 1, 2, \cdots, T$, 计算离差时间序列:

$$y(t) = \sum_{i=1}^T (x(i) - \bar{x}) \quad (18)$$

式中: T 为数据长度; $\bar{x} = \frac{1}{T} \sum_{i=1}^T x(t)$ 为序列 $x(t)$ 的均值。

2) 将新序列 $y(t)$ 划分为 U 个长度为 n 的不重叠子区间,即 $U = \lfloor T/n \rfloor$, 其中 $\lfloor \cdot \rfloor$ 为向下取整函数。据此可知, $N_u = [(u-1)n + 1, un]$ 代表第 u 个子区间 ($u = 1, 2, \cdots, U$)。

3) 对每个子区间 N_u , 通过多项式最小二乘法拟合确定局部趋势。例如阶数 $l = 2$, 则可得到拟合项 $\hat{y}_u(t)$ 为:

$$\hat{y}_u(t) = a_u t^2 + b_u t + c_u, t \in N_u \quad (19)$$

式中: a_u, b_u, c_u 表示多项式系数。接下来, 计算每个子区间的消除趋势序列:

$$\varepsilon_u(t) = y_u(t) - \hat{y}_u(t), t \in N_u \quad (20)$$

4) 计算第 $u (u = 1, 2, \dots, U)$ 个子区间的去趋势波动函数 $F(u, n)$, 如式 (21) 所示。最后对所有分段 $\{F(u, n)\}_{u=1}^U$ 进行平均运算得到总体均方根波动 $F(n)$, 即式 (22) 所示。

$$F(n, u) = \frac{1}{n} \sum_{(u-1)n+1}^{un} (\varepsilon_u(t))^2 \quad (21)$$

$$F(n) = \frac{1}{U} \sum_{u=1}^U (F(n, u))^{1/2} \quad (22)$$

5) 改变子区间长度 n , 重复 1) ~ 4), 可得到总体均方根波动 $F(n)$ 随子区间长度 n 变化的双对数曲线。拟合曲线求取每一个长度 n 下的斜率即为标度指数, 最终均方根波动与斜率呈现如下对数函数关系:

$$F(n) \propto n^\alpha \quad (23)$$

其中, 标度指数 $\alpha = 0.5$ 对应白噪声。它的另一个含义是粗糙度, 即标度指数 α 越大, 序列越平滑, 对应噪声分量越少。

2.4 典型相关分析

CCA 的核心思想是迫使源之间的最大程度自相关和互不相关来解决分离问题^[23]。

假设 $X_1(t)$ 具有 M 个通道, T 个观测值, $X_2 = X_1(t - 1)$ 为它的延时版本。CCA 的目标在于, 找到两个基向量 $\mathbf{w}_1, \mathbf{w}_2$, 分别用于投影 $X_1(t), X_2(t)$, 使投影后的两向量相关性最大, 公式如式 (24) 所示。

$$\arg\max_{\mathbf{w}_1, \mathbf{w}_2} \rho_0(s_1(t), s_2(t)) = \frac{\mathbf{w}_1^T C_{12} \mathbf{w}_2}{\sqrt{\mathbf{w}_1^T C_{11} \mathbf{w}_1} \sqrt{\mathbf{w}_2^T C_{22} \mathbf{w}_2}} \quad (24)$$

式中: $s_1(t) = \mathbf{w}_1^T X_1(t)$ 和 $s_2(t) = \mathbf{w}_2^T X_2(t)$ 为第 1 对正则源; C_{11}, C_{22}, C_{12} 分别代表 $X_1(t)$ 的自协方差、 $X_2(t)$ 的自协方差以及 $X_1(t)$ 与 $X_2(t)$ 的互协方差。对式 (24) 分别求 $\mathbf{w}_1, \mathbf{w}_2$ 的导数并置为 0, 转换为特征分解问题:

$$\begin{cases} C_{12} \mathbf{w}_2 = \rho_0 \lambda_1 C_{11} \mathbf{w}_1 \\ C_{21} \mathbf{w}_1 = \rho_0 \lambda_2 C_{22} \mathbf{w}_2 \end{cases} \quad (25)$$

式中: $\lambda_1 = \lambda_2^{-1} = \frac{\sqrt{\mathbf{w}_2^T C_{22} \mathbf{w}_2}}{\sqrt{\mathbf{w}_1^T C_{11} \mathbf{w}_1}}$ 。由于基向量 $\mathbf{w}_1, \mathbf{w}_2$ 的系数不会影响相关系数 ρ_0 , 可取范数 $\|\mathbf{w}_1\|_2 = \|\mathbf{w}_2\|_2 = 1$, 得到:

$$\begin{cases} C_{11}^{-1} C_{12} C_{22}^{-1} C_{21} \mathbf{w}_1 = \rho_0^2 \mathbf{w}_1 \\ C_{22}^{-1} C_{21} C_{11}^{-1} C_{12} \mathbf{w}_2 = \rho_0^2 \mathbf{w}_2 \end{cases} \quad (26)$$

式中: ρ_0^2 为特征值; $\mathbf{w}_1, \mathbf{w}_2$ 为相应的特征向量。遵循同样的思想可以解决相同的特征分解问题, 但求解第

$M (M \geq 2)$ 对正则源时需与前 $M - 1$ 对正则源均互不相关。依此类推, 重复上述步骤可得到源矢量矩阵 $\mathbf{S}(t)$ 及解混矩阵 $\mathbf{W}$:

$$\begin{cases} \mathbf{S}_1(t) = [s_1^1(t); s_1^2(t); \dots; s_1^M(t)] \\ \mathbf{S}_2(t) = [s_2^1(t); s_2^2(t); \dots; s_2^M(t)] \end{cases} \quad (27)$$

$$\begin{cases} \mathbf{W}_1 = [(\mathbf{w}_1^1)^T; (\mathbf{w}_1^2)^T; \dots; (\mathbf{w}_1^M)^T] \\ \mathbf{W}_2 = [(\mathbf{w}_2^1)^T; (\mathbf{w}_2^2)^T; \dots; (\mathbf{w}_2^M)^T] \end{cases} \quad (28)$$

其中, 根据定义可知 $\mathbf{S}_1(t) = \mathbf{W}_1^T \mathbf{X}_1(t), \mathbf{S}_2(t) = \mathbf{W}_2^T \mathbf{X}_2(t)$, $\mathbf{S}_1(t)$ 与 $\mathbf{S}_2(t)$ 对应的源矢量对 $(\mathbf{S}_1^i(t) \text{ 与 } \mathbf{S}_2^i(t), i = 1, 2, \dots, M)$ 是高度相关的。然后, 将 $\mathbf{S}_1(t)$ 中自相关系数值 < 设定阈值 ρ_0 的源矢量置为零, 得到净化后的源矩阵 $\tilde{\mathbf{S}}_1(t)$ 。最后对 $\tilde{\mathbf{S}}_1(t)$ 与混合矩阵 $\mathbf{A} = \mathbf{W}_1^{-1}$ 执行逆 CCA 算法获得重构信号 $\tilde{\mathbf{X}}_1(t)$ 。

2.5 方法参数整定

1) CEEMDAN 集合尺寸与噪声幅度, 文献[24]认为 CEEMDAN 分解所涉及参数噪声幅度 ε_i 和集合尺寸 Z 在不同应用场合可能会影响分解方法效果。因此, 本文参考文献[24]默认参数 $\varepsilon_i = 0.2, Z = 200$ 。

2) DFA 子区间长度, Mert 等^[22]建议子区间长度 n 应符合 $l + 2 \leq n \leq T/4$ 条件 (l 为阶数, T 为数据长度), 同时应遵循可靠的线性区域 $4 \leq n \leq 16$ 与 $16 \leq n \leq 200$ 。文献[22]还指出在实际应用中取 $n = 4$ 通常可以取得良好的结果。因此, 本文综合考虑可靠性和计算复杂度后, 选用子区间长度 $n = 4$ 。

3) DFA 阈值, 为克服分解算法的局限性, 文献[22]通过丢弃 DFA 处在阈值 θ 范围内 ($\theta = \alpha \pm 0.25$) 的 IMFs 来实现噪声分离 ($\theta = 0.5 \pm 0.25$ 对应白噪声)。该阈值区间通过标度指数 α 确定, 阈值 θ 范围决定噪声 IMFs 的数量。由于工业过程振荡数据所含噪声通常为频谱宽泛的白噪声行为^[20], 本文方法的阈值选取规则同文献[22]保持一致, 即设定 DFA 阈值为 $\theta = 0.5 \pm 0.25$ 。

4) CCA 阈值参数, Lang 等^[12]根据实际经验指出 ρ_0 阈值选为 0.75 ~ 0.9 时, 在多数情况下可以取得良好的去噪效果。因此, 本文与文献[12]一致, 使用自相关阈值 $\rho_0 = 0.9$ 用以区分噪声和振荡成分。

3 仿真案例

实际生产过程复杂性高, 使对应过程输出呈现出非线性、非平稳以及噪声等特性^[25]。为了更贴近实际工业场景, 并有效展示所提方法的去噪性能, 参考已有仿真模型构建了 3 种数值振荡模型, 即多成分振荡^[11]、时变振荡^[25]和间歇振荡^[26-27]。此外, 为了全面评估本文所提方法的优越性, 还将额外引入 3 种典型的去噪技术作为对比方法。

3.1 数值实现定性分析

选用3个典型振荡案例(多成分振荡、时变振荡、间歇振荡)进行仿真实验。所涉及实验使用的频率、噪声幅值、采样频率、采样点等参数均与第2节保持一致。

1) 多重振荡模型

案例1为多重振荡模型,其表达式为:

$$x_2(t) = \frac{4}{\pi} [\sin(2\pi ft)] + \frac{1}{2} [\sin(6\pi ft) + \sin(10\pi ft)] + \beta\omega(t) \quad (29)$$

该模型参考了Chen等^[11]提出的非线性振荡模型,由一个周期性信号、两个谐波分量和噪声组成。多重振荡是流程工业常见的振荡行为。在磷化工、锡化工等行业,由于反应过程的复杂性,以及生产工况的恶劣性,生产过程极易产生非线性退化特征,从而引发多重振荡。此外,当控制回路中同时存在两种及以上振荡诱因时,也会表现多重振荡行为。

不失一般性,本文选取 $f=4$ 、 $\beta=0.25$ 作为典型案例进行去噪效果对比,图3所示为相应的原始信号波形以及基于EEMD-CCA与CEEMDAN-DFA-CCA去噪后的重构信号波形对比。可以看到,两种方法均消除了趋势与噪声的干扰,但本文方法的重构效果更好,振荡细节保留更完整。相比之下,EEMD-CCA方法损失了部分振荡信息,如局部放大示意图所示。




图3 多成分振荡案例波形对比

Fig. 3 Multi-component oscillation case and waveform comparison

为进一步量化本文方法效果,采用皮尔逊相关系数(Pearson correlation coefficient, PCC)衡量原始信号与重构信号之间的相关程度,PCC值越大则说明两者相关性越高,重构效果越好。

本文将结合原振荡成分与重构信号之间的RMSRE、PCC指标进行去噪效果数值研究。独立重复500组实验后的去噪性能对比结果如图4所示。可以看到,所提方法在所有频率下均表现出更好的去噪能力。具体而言,在RMSRE相关统计量上,可观察到本文方法具有更低的平均值和标准差;在PCC相关统计量上,本文方法具有

更高的平均值与更低的标准差。上述结果表明,本文方法可有效用于对多成分振荡信号的去噪。




图4 多成分振荡定量分析

Fig. 4 Quantitative comparison with varying frequency of multi-component oscillation

2) 时变振荡模型

案例2为时变振荡模型,该模型的详细表达式如式(3)。该模型源自文献[25],由调幅调频振荡信号、噪声组成。工业过程的慢变性、长周期波动及干扰是导致时变振荡行为的主要因素。慢变特性在工业领域非常常见,例如化学反应中,反应速率并非恒定,而随着反应的推进不断变化。该过程所采集的振荡信号通常具有时变的频率、振幅和相位。

与前文相同,选取 $f=4$ 、 $\beta=0.25$ 后两种方法所得去噪结果如图5所示。可以看到,本文所提方法较为完整地保留了有效振荡信息,而EEMD-CCA方法则丢失了部分有效信息。




图5 时变振荡案例及波形对比

Fig. 5 Time-varying oscillation case and waveform comparison

在定量分析环节,同样进行500次独立实验,横向对比两种方法的去噪指标,如图6所示。可以看到两种方法的去噪效果与案例1类似,EEMD-CCA表现出分解鲁棒性差、重构精度低的问题。相比而言,运用本文方法去

噪后的信号 RMSRE 数值较低,而且重构信号的标准差更小,去噪性能更好。




图 6 时变振荡定量分析

Fig. 6 Quantitative comparison with varying frequency of time-varying oscillation

3) 间歇振荡模型

该案例为参考文献[26]构建的间歇振荡模型,其表达式为:

$$\begin{aligned}x_4(t) &= x_{41}(t) + x_{42}(t) + \beta\omega(t) \\ x_{41}(t) &= 2\sin(18\pi t) \\ x_{42}(t) &= \begin{cases} \sin(21\pi ft), & t = 0.2 : 0.4, 0.6 : 0.8 \\ 0, & \text{其他} \end{cases}\end{aligned}\tag{30}$$

该模型由 $x_{41}(t)$, $x_{42}(t)$ 和 $\beta\omega(t)$ 组成,其中 β 为噪声幅度, $\omega(t)$ 为服从 $\mathcal{N}(0,1)$ 分布的随机白噪声序列,其中 t 取值范围为 $(0.8 \sim 1.024)$ 。实际过程中,间歇振荡出现概率较低,但依然不可忽略。例如为响应生产需求及系统维护需求,过程需间歇对生产参数进行调节。当控制器性能处于临界状态,或控制回路中存在滞后及过大延迟时,可能会引发间歇振荡^[27]。

该间歇振荡去噪前后的波形对比($f=4$)如图 7 所示。与前文仿真案例类似,EEMD-CCA 方法的分解不稳定问题,导致了有效信息的损失,如局部放大示意图所示。




图 7 间歇振荡案例波形对比

Fig. 7 Intermittent oscillation case and waveform comparison

同时,两种方法在不同频率下的去噪性能对比如图 8 所示,可以看到应用本文方法后的重构误差更小、相关性更高,证明该方法对间歇振荡的去噪效果更好。




图 8 间歇振荡定量分析

Fig. 8 Quantitative comparison with varying frequency of intermittent oscillation case

4) 实验结果定量分析

为了进一步说明所提方法与 EEMD-CCA 去噪性能差异,两种方法 RMSRE 指标及性能差异百分比如表 1 所示。

表 1 EEMD-CCA 与所提方法性能指标对比 (RMSRE)
Table 1 Comparison of performance indicators of EEMD-CCA and our purposed method (RMSRE)

信号	f	EEMD-CCA	本文方法	性能提升/%	平均提升/%
多成分振荡	2	0.004 0±0.001 0	0.002 2±0.000 1	45.00	30.52
	3	0.003 4±0.000 4	0.002 5±0.000 2	26.47	
	4	0.003 5±0.000 3	0.002 2±0.000 1	37.14	
	5	0.003 2±0.000 2	0.002 8±0.000 1	12.50	
	6	0.003 5±0.000 3	0.002 7±0.000 1	22.86	
	7	0.004 6±0.000 3	0.002 8±0.000 1	39.13	
时变振荡	2	0.003 9±0.000 1	0.003 0±0.000 1	23.08	16.00
	3	0.004 4±0.000 2	0.003 6±0.000 1	18.18	
	4	0.004 8±0.000 2	0.004 0±0.000 1	16.67	
	5	0.004 6±0.000 2	0.004 2±0.000 1	8.70	
	6	0.004 4±0.000 2	0.003 9±0.000 1	11.36	
	7	0.005 0±0.000 3	0.004 1±0.000 1	18.00	
间歇振荡	2	0.002 5±0.000 2	0.002 3±0.000 03	7.43	9.86
	3	0.002 5±0.000 1	0.002 3±0.000 02	8.32	
	4	0.002 8±0.000 1	0.002 2±0.000 03	20.25	
	5	0.002 3±0.000 1	0.002 0±0.000 02	8.63	
	6	0.002 4±0.000 1	0.002 3±0.000 03	5.93	
	7	0.002 6±0.000 1	0.002 4±0.000 02	8.62	

由表 1 可见,本文方法相较 EEMD-CCA 方法在 RMSRE 指标上的显著提升。平均来看,在单成分振荡、多成分振荡、时变振荡和间歇振荡的情境中,本文方法 RMSRE 指标平均提升百分比分别为 32.85%、30.52%、16.00% 和 9.86%。本文强调两种方法在 PCC 指标上的差异与 RMSRE 结果高度一致,即所提方法对应 PCC 指标始终优于 EEMD-CCA。但受限于篇幅,此处不再单独列出详细表格。

3.2 先进去噪技术对比

延用 3.1 节中的 3 种代表性振荡案例作为测试对象,定量对比分析几种先进去噪技术 (EMD-IIT^[6], VMD-DFA^[7], EWT^[8], EEMD-CCA^[12]) 与本文方法的性能差异。执行 500 组独立实验后,上述方法所对应的 RMSRE 结果如表 2 所示 (与第 3.1 节类似,PCC 对应结果因与 RMSRE 结果高度一致,此处进一步省略)。

表 2 先进去噪算法性能指标对比 (RMSRE)
Table 2 Comparison of performance indicators of advanced denoising algorithms (RMSRE)

信号	方法	$\beta=0.25$	$\beta=0.5$
多成分振荡	EMD-IIT	0.006 4±0.000 1	0.002 9±0.000 1
	VMD-DFA	0.003 5±0.000 1	0.002 8±0.000 1
	EWT	0.010 6±0.000 1	0.010 8±0.000 1
	EEMD-CCA	0.004 3±0.000 8	0.004 3±0.001 7
	本文方法	0.002 4±0.000 1	0.002 3±0.000 1
时变振荡	EMD-IIT	0.025 2±0.000 6	0.0091±0.0005
	VMD-DFA	0.004 4±0.000 1	0.0076±0.0001
	EWT	0.005 5±0.000 1	0.008 3±0.000 1
	EEMD-CCA	0.008 1±0.000 4	0.008 4±0.000 2
	本文方法	0.003 0±0.000 1	0.006 9±0.000 1
间歇振荡	EMD-IIT	0.053 5±0.000 2	0.008 6±0.000 1
	VMD-DFA	0.002 4±0.000 1	0.003 5±0.000 1
	EWT	0.021 6±0.000 1	0.008 5±0.000 4
	EEMD-CCA	0.002 8±0.000 2	0.005 1±0.000 4
	本文方法	0.002 2±0.000 1	0.002 4±0.000 1

由表 2 可见,本文提出的方法相比于 3 种先进的去噪算法,在多种振荡场景和不同噪声幅度条件下,RMSRE 指标的平均值和标准差均表现为最低。这一结果表明,所提方法不仅具备更高的鲁棒性和适应性,而且能够更加精确地处理不同振荡情境下的复杂信号特征。

综上所述,本文提出的 CEEMDAN-DFA-CCA 方法具有如下优越性。

1) 能将信号、噪声有效分离。原始信号中噪声大部分被滤除,信号细节保留更多,重构精度更高。

2) 对比多个仿真案例,本文所提方法均得到最好的去噪结果 (即最低的 RMSRE 值)。特别地,在间歇振荡情况下 ($\beta=0.5$),应用本文方法后的 RMSRE 指标较 EWT、VMD-DFA、EMD-IIT、EEMD-CCA 分别降低了 71.76%、31.43%、72.09%、52.94%。

3) 本文方法在不同噪声等级下仍能保持最佳的去噪性能,证明其去噪广泛性好,不局限于特定含噪信号,能为后续的振荡检测与诊断工作提供良好的技术支撑。

4 真实案例

针对仿真案例环节提出的 3 种仿真模型,即多成分振荡、时变振荡和间歇振荡,在本领域一个具有广泛代表性的公开数据集中筛选了与之相符的 3 条工业控制回路进行对照分析。该数据集由 Jelali 等^[28]提供,常被用作评估振荡检测与诊断方法的基准。为验证本文所提去噪技术的工业应用有效性,所提方法还与 3 种典型的工业数据去噪技术 (VMD-DFA^[6]、EWT^[7]、EEMD-CCA^[12]) 进行了对比。

4.1 多成分振荡模型对应工业案例分析

针对多成分振荡的特征,从数据集中选取了包含多个振荡组分的工业数据进行了实验。该数据采集自流量控制回路 (chemicals. loop23. pv), 采样间隔为 10 s。由于控制器整定不当及外部干扰等因素,该数据包含了多个振荡成分和噪声,与本文所使用的多成分振荡模型相一致。

工业振荡数据 (loop23) 长噪效果对比如图 9 所示,根据振荡的定义^[29],可以确定该数据中包含多个振荡分量,其余部分为噪声伪迹。从局部放大示意图可以看到,本文所提方法成功地还原了多重振荡成分。相比之下,EEMD-CCA 方法错误地将低幅值高频振荡成分视为噪声并予以去除。而 VMD-DFA 方法的去噪结果中存在显著




图 9 工业振荡数据 (loop23) 去噪效果对比
Fig. 9 Comparison of denoising effects of industrial oscillation data (loop23)

的噪声残留,严重影响了重构信号的质量;而 EWT 方法则在去噪的同时消除了部分有效信息。

就真实信号而言,由于噪声分布和能量等级未知,无法使用定量的性能指标衡量去噪效果。鉴于此,本节采用功率谱密度(power spectral density, PSD)以定性评价相应方法的去噪性能。在缺乏对真实信号认知的应用场景,PSD 是比较合适用于定性性能评估的工具。类似的性能评价方式在脑电、心电去噪领域^[30-31]已有广泛运用。

该振荡数据的 PSD 分布如图 10 所示。可以看出,所提方法表现出了较好的去噪效果。局部放大图 A 中,所提方法更好地保留了原始信号中的振荡分量,而其他 3 种方法均不同程度丢失了部分有效信息,其中 EEMD-CCA 方法额外产生了虚假的振荡分量。局部放大图 B 主要反映各种方法的噪声抑制能力。可以看到,除了 EWT 和所提方法外,其余方法均未能完全去除噪声成分。




图 10 工业振荡数据(loop23)功率谱密度对比
Fig. 10 Power spectral density comparison of industrial oscillation data (loop23)

综上,所提出的方法在有效抑制噪声的同时,避免了振荡成分的丢失,整体表现出最佳的去噪性能。

4.2 时变振荡模型对应工业案例分析

该案例所使用的样本采集自液位控制回路(chemicals. loop37. pv),采样间隔为 12 s。由于过程慢变特性,数据中包含时变振荡和噪声成分,与本文所使用的时变振荡模型相符合。

上述数据的去噪波形如图 11 所示。可以看到,所提方法不仅有效地消除了噪声伪迹,还较好地保留了振荡成分。相比之下,VMD-DFA 方法保留了部分噪声成分,其余两种方法则丢失部分振荡信息。

工业振荡数据(loop37)功率谱密度对比如图 12 所示,本文方法是唯一一个保留了振荡特征的同时将噪声伪迹抑制在最小的幅度范围内的方法,同时呈现出的去噪效果显著优于所有对比方法。




图 11 工业振荡数据(loop37)去噪效果对比
Fig. 11 Comparison of denoising effects of industrial oscillation data (loop37)




图 12 工业振荡数据(loop37)功率谱密度对比
Fig. 12 Power spectral density comparison of industrial oscillation data (loop37)

4.3 间歇振荡模型对应工业案例分析

最后一个样本采集自流量控制回路(chemicals. loop56. pv),采样间隔为 60 s。该数据主要包含间歇振荡,与本文所使用的间歇振荡模型相一致。

该回路的去噪波形如图 13 所示,可以看到,所提方法较好地重构了原始信号中的振荡分量,重建后的波形




图 13 工业振荡数据(loop56)去噪效果对比
Fig. 13 Comparison of denoising effects of industrial oscillation data (loop56)

轮廓更加平稳,如局部放大图所示。相比之下,VMD-DFA方法虽然还原了振荡分量波形,但是存在残余噪声,其余两种方法无法有效提取振荡分量,且产生了虚假分量。

这一结论在图14所示的PSD分析中亦得到充分验证。由该方法处理后的结果显示,其在完整保留原始信号振荡与谐波特征的基础上,有效消除了噪声干扰,从而实现了整体最优的频域去噪性能。




图14 工业振荡数据(loop56)功率谱密度对比

Fig. 14 Power spectral density comparison of industrial oscillation data (loop56)

综上所述,通过在不同振荡特征的真实工业数据上进行测试,本文所提方法表现出了优于其他方法的去噪性能。这充分证明了本文方法确实是一种高效的工业振荡数据预处理工具。

5 结 论

针对工业控制过程中的振荡信号周期长、伪迹多、信噪比低等特点,本文提出了一种基于CEEMDAN-DFA-CCA的高质量去噪技术,以促进振荡检测与诊断工作。首先使用CEEMDAN对过程数据进行分解,然后通过DFA进行预处理(隔离噪声主导的IMFs,保留信息主导的IMFs)。接着,结合CCA去噪技术,从噪声主导的IMFs中提取振荡信息,并与信息主导的IMFs累加得到重构信号。最后,通过仿真实验和实际工业案例验证了方法的可行性。分析结果显示,本文提出的方法在去噪性能上明显优于其他方法。

本文旨在探索适用于工业领域的先进去噪技术,以提升过程数据质量,进而提高振荡检测精度与诊断可靠性,为工业控制回路的监测与维护提供新方案。然而,本文方法的参数问题仍需进一步讨论,例如需要更多统计研究来确定CEEMDAN的最佳集合次数与噪声幅度,以及DFA的最佳窗长自适应选择。这些问题将作为后续研究的重点。

参考文献

- [1] 高学金, 马东阳, 韩华云, 等. 基于DAE和TCN的复杂工业过程故障预测[J]. 仪器仪表学报, 2021, 42(6): 140-151.
GAO X J, MA D Y, HAN H Y, et al. Fault prediction of complex industrial process based on DAE and TCN[J]. Chinese Journal of Scientific Instrument, 2021, 42(6): 140-151.
- [2] DAMBROS J W, TRIERWEILER J O, FARENZENA M. Oscillation detection in process industries-part I: Review of the detection methods[J]. Journal of Process Control, 2019, 78: 108-123.
- [3] CHEN Q M, WEN Q S, WU X L, et al. Detection and time-frequency analysis of multiple plant-wide oscillations using adaptive multivariate intrinsic chirp component decomposition[J]. Control Engineering Practice, 2023, 141: 105715.
- [4] WANG Z Y, ZHU J, YAN T, et al. A new modified wavelet-based ECG denoising[J]. Computer Assisted Surgery, 2019, 24(S1): 174-183.
- [5] DONG X, LI G L, JIA Y CH, et al. Non-iterative denoising algorithm for mechanical vibration signal using spectral graph wavelet transform and detrended fluctuation analysis[J]. Mechanical Systems Signal Processing, 2021, 149: 107202.
- [6] 吴龙文, 聂雨亭, 张宇鹏, 等. 基于变分模态分解的自适应滤波降噪方法[J]. 电子学报, 2021, 49(8): 1457-1465.
WU L W, NIE Y T, ZHANG Y P, et al. An adaptive filtering denoising method based on variational mode decomposition[J]. Acta Electronica Sinica, 2021, 49(8): 1457-1465.
- [7] ZHONG J, BI X W, SHU Q, et al. Partial discharge signal denoising based on singular value decomposition and empirical wavelet transform[J]. IEEE Transactions on Instrumentation and Measurement, 2020, 69(11): 8866-8873.
- [8] DAMBROS J W, TRIERWEILER J O, FARENZENA M, et al. Oscillation detection in process industries by a machine learning-based approach[J]. Industrial Engineering Chemistry Research, 2019, 58(31): 14180-14192.
- [9] LANG X, ZHANG Y F, XIE L, et al. Use of fast multivariate empirical mode decomposition for oscillation monitoring in noisy process plant[J]. Industrial &

- Engineering Chemistry Research, 2020, 59(25): 11537-11551.
- [10] ZHOU B F, CHIOUA M, BAUER M, et al. Improving root cause analysis by detecting and removing transient changes in oscillatory time series with application to a 1, 3-butadiene process[J]. Industrial Engineering Chemistry Research, 2019, 58(26): 11234-11250.
- [11] CHEN Q M, LANG X, XIE L, et al. Detecting nonlinear oscillations in process control loop based on an improved VMD [J]. IEEE Access, 2019, 7: 91446-91462.
- [12] LANG X, LIU Y, ZHANG Y F, et al. Denoising of industrial oscillation data using EEMD with CCA [J]. IFAC-World Congress 2020, 2021, 53 (2): 11662-11668.
- [13] LANG X, ZHANG Y F, XIE L, et al. Detrending and denoising of industrial oscillation data[J]. IEEE Transactions on Industrial Informatics, 2022, 19 (4): 5809-5820.
- [14] LIU S H, LANG X, ZHANG Y F, et al. An automated diagnostic framework for multiple oscillations with median complementary EEMD[J]. IEEE Transactions on Control Systems Technology, 2024, 32(3): 919-933.
- [15] 刘淞华, 何冰冰, 郎恂, 等. 中值互补集合经验模态分解[J]. 自动化学报, 2023, 49(12): 2544-2556.
- LIU S H, HE B B, LANG X, et al. Median complementary ensemble empirical mode decomposition[J]. Acta Automatica Sinica, 2023, 49(12): 2544-2556.
- [16] 余慧敏, 朱姣姿. 基于新模态-小波包分解的超宽带雷达生命体征信号去噪算法[J]. 电子测量与仪器学报, 2024, 38(3): 143-151.
- YU H M, ZHU J Z. Ultra-wideband radar vital signs signal denoising algorithm based on new mode-wavelet packet analysis[J]. Journal of Electronic Measurement and Instrument, 2024, 38(3): 143-151.
- [17] 夏焰坤, 寇坚强, 李欣洋. 基于 IWOA-VMD 的永磁同步电机匝间短路故障振动信号去噪方法[J]. 电子测量与仪器学报, 2024, 38(4): 202-216.
- XIA Y K, KOU J Q, LI X Y. Denoising method for vibration signal of inter-turn short circuit[J]. Journal of Electronic Measurement and Instrument, 2024, 38(4): 202-216.
- [18] CHEN Q M, LANG X, LU S H, et al. Detection and root cause analysis of multiple plant-wide oscillations using multivariate nonlinear chirp mode decomposition and multivariate Granger causality [J]. Computers Chemical Engineering, 2021, 147: 107231.
- [19] KUMAR A, TOMAR H, MEHLA V K, et al. Stationary wavelet transform based ECG signal denoising method[J]. ISA Transactions, 2021, 114: 251-262.
- [20] LANG X, UR REHMAN N, ZHANG Y F, et al. Median ensemble empirical mode decomposition[J]. Signal Processing, 2020, 176: 107686.
- [21] 耿读艳, 王晨旭, 赵杰, 等. 基于 CEEMDAN-PE 的心冲击信号降噪方法研究[J]. 仪器仪表学报, 2019, 40(6): 155-161.
- GENG D Y, WANG CH X, ZHAO J, et al. Research on BCG signal de-noising method based on CEEMDAN and PE[J]. Chinese Journal of Scientific Instrument, 2019, 40(6): 155-161.
- [22] MERT A, AKAN A. Detrended fluctuation thresholding for empirical mode decomposition based denoising [J]. Digital Signal Processing, 2014, 32: 48-56.
- [23] LIU Y, ZHOU Y, LANG X, et al. An efficient and robust muscle artifact removal method for few-channel EEG[J]. IEEE Access, 2019, 7: 176036-176050.
- [24] TORRES M E, COLOMINAS M A, SCHLOTTHAUER G, et al. A complete ensemble empirical mode decomposition with adaptive noise[C]. 2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). IEEE, 2011: 4144-4147.
- [25] LANG X, CHEN Q M, LU S, et al. On demodulation of time-varying oscillations in process plant [J]. Journal of Process Control, 2022, 120: 28-43.
- [26] XIE L, LANG X, HORCH A, et al. Online oscillation detection in the presence of signal intermittency [J]. Control Engineering Practice, 2016, 55: 91-100.
- [27] BOUNOUA W, AFTAB M F, OMLIN C W P. Online detrended fluctuation analysis and improved empirical wavelet transform for real-time oscillations detection in industrial control loops[J]. Computers & Chemical Engineering, 2023, 172: 108173.
- [28] JELALI M, HUANG B, CHOUDHURY S M A A, et al. Detection and diagnosis of stiction in control loops state of the art and advanced methods[J]. Chemical Engineering Progress, 2010, 106(6): 46-47.
- [29] WANG T, CHEN Q M, LANG X, et al. Detection of oscillations in process control loops from visual image space using deep convolutional networks[J]. IEEE/CAA

Journal of Automatica Sinica, 2024, 11(4): 982-995.

[30] 陈妮,覃玉荣,熊艳婷,等. 基于变分模态分解的脑电锁相刺激方法[J]. 仪器仪表学报, 2020, 41(5): 205-213.

CHEN N, QIN Y R, XIONG Y T, et al. Phase locked stimulus method of EEG based on variational mode decomposition[J]. Chinese Journal of Scientific Instrument, 2020, 41(5): 205-213.

[31] 冯宝亮,史斌君,左国坤,等. 基于图案化柔性织物电极的非接触式多体位睡眠心电监测系统[J]. 仪器仪表学报, 2021, 42(7): 126-134.

FENG B L, SHI B J, ZUO G K, et al. A non-contact multi-positional sleeping ECG monitoring system based on patterned flexible fabric electrodes[J]. Chinese Journal of Scientific Instrument, 2021, 42(7): 126-134.

作者简介



郎煜民, 2019 年于中国石油大学(华东)获得学士学位, 主要研究方向为工业过程振荡数据治理, 工业过程数据分析。

E-mail: lym_ynu@163.com

Lang Yumin received his B.Sc. degree from China University of Petroleum (East China) in 2019. His main research interests include the governance of oscillatory data in industrial processes and the analysis of industrial process data.



郎恂(通信作者), 2014 年于浙江大学获得学士学位, 2019 年于浙江大学获得博士学位, 现为云南大学副教授, 主要研究方向为控制系统性能评估, 过程监测, 工业设备健康保障。

E-mail: langxun@ynu.edu.cn

Lang Xun (Corresponding author) received his B.Sc. degree from Zhejiang University in 2014, and Ph.D. degree from Zhejiang University in 2019. Now he is an associate professor at Yunnan university. His main research interests include control system performance evaluation, process monitoring, industrial equipment health assurance.



吴建德, 2001 年于西北工业大学获得学士学位, 2004 年于西北工业大学获得硕士学位, 2007 年于浙江大学获得博士学位, 现为云南大学教授, 主要研究方向为复杂工业过程建模、控制与优化。

E-mail: jdwu@ynu.edu.cn

Wu Jiande received his B.Sc. degree from Northwestern Polytechnical University in 2001, M.Sc. degree from Northwestern Polytechnical University in 2004 and Ph.D. degree from Zhejiang University in 2007. Now he is a professor at Yunnan University. His main research interests include complex industrial process modeling, control and optimization.



刘燕, 2013 年于哈尔滨工业大学获得博士学位, 现为东北林业大学教授, 主要研究方向为脑电/磁成像处理分析, 癫痫发作预测和病灶定位。

E-mail: yan.liu@enfu.edu.cn

Liu Yan received her Ph.D. degree from the Harbin Institute of Technology in 2013. Now she is a professor at Northeast Forestry University. Her main research interests include EEG/MEG processing, and epilepsy seizure prediction and foci localization.