

基于 DBO 与遗忘因子 AEKF 的有色噪声协同优化算法

徐刘胜, 程竹明, 杜振龙, 赵传荣

(安徽工业大学 电气与信息工程学院, 安徽 马鞍山 243032)

摘要: 针对自适应扩展卡尔曼滤波(AEKF)算法在处理有色噪声时历史数据依赖性强、估计精度受限等问题, 提出一种基于蜣螂优化(DBO)与遗忘因子AEKF的协同优化算法。该算法基于有色噪声特性构建AEKF预测模型, 通过引入遗忘因子动态调整历史数据权重分配, 从而降低其对当前估计的干扰, 并在此基础上改进AEKF的更新校正模型。进一步利用DBO算法的强大全局优化能力, 以信噪比(SNR)作为目标函数评估指标, 构建遗忘因子的动态优选机制, 最终形成具备参数自适应能力的FFAEKF-DBO协同优化算法。选取4类典型有色噪声信号数据集和凯斯西储大学提供的滚动轴承振动数据集进行实验, 多维度评估本文算法的性能。结果表明: 在有色噪声测试中, 与EKF, AEKF和FFAEKF相比, 本文算法展现出全面优势, 从粉红噪声来看, 相较于基准EKF算法, 本文算法的MAE与RMSE分别降低了约16.93%和17.99%, SNR增益获得了0.93 dB的显著提升, 且归一化互相关系数(NCC)始终保持最优。在滚动轴承振动信号分析中, 该算法在保持信号均值稳定的同时显著降低均方差, 且NCC值持续优于对比算法。所提算法通过遗忘因子动态优化机制有效解决了AEKF算法对历史数据的依赖, 显著提升了有色噪声抑制精度, 为工业信号处理及故障诊断提供了可靠技术支撑。

关键词: 自适应扩展卡尔曼滤波; 蜣螂算法; 协同优化; 遗忘因子; 动态优选机制; 故障诊断; 有色噪声

中图分类号: TN 911.4 **文献标志码:** A **doi:** 10.12415/j.issn.1671-7872.24201



A Collaborative Optimization Algorithm for Colored Noise Based on DBO and Forgetting Factor AEKF

XU Liusheng, CHENG Zhuming, DU Zhenlong, ZHAO Chuanrong

(School of Electrical & Information Engineering, Anhui University of Technology, Maanshan243032, China)

Abstract: To address the issues of strong historical data dependency and limited estimation accuracy in the adaptive extended Kalman filter (AEKF) algorithm when processing colored noise, a collaborative optimization algorithm based on dung beetle optimization (DBO) and forgetting factor AEKF was proposed, where a forgetting factor was introduced to dynamically adjust the weight allocation of historical data, thereby reducing its interference with current estimations and improving the AEKF update-correction model. Furthermore, utilizing the strong global optimization capability of the DBO algorithm and employing the signal-to-noise ratio (SNR) as the objective function evaluation metric, a dynamic optimization mechanism for the forgetting factor was established. This ultimately led to the development of an adaptive FFAEKF-DBO collaborative optimization algorithm.

收稿日期: 2024-12-21

基金项目: 安徽省高校自然科学研究项目(KJ2021A0371)

作者简介: 徐刘胜(1999—), 男, 安徽池州人, 硕士生, 主要研究方向为信号处理及故障诊断技术。

通信作者: 程竹明(1975—), 男, 安徽怀宁人, 博士, 副教授, 主要研究方向为信号处理与自动检测技术。

引文格式: 徐刘胜, 程竹明, 杜振龙, 等. 基于 DBO 与遗忘因子 AEKF 的有色噪声协同优化算法[J]. 安徽工业大学学报(自然科学版), 2025, 42(6):643-651.

Experiments were conducted using four types of typical colored noise signal datasets and the rolling bearing vibration dataset provided by Case Western Reserve University (CWRU) to evaluate the performance of the proposed algorithm across multiple dimensions. The results demonstrate that in the colored noise tests, the proposed algorithm exhibits significant advantages over traditional EKF, AEKF and FFAEKF methods. Specifically, it achieves average reductions of 11.50% in mean absolute error (MAE) and 11.36% in root mean square error (RMSE), along with an average SNR improvement of 1.11 dB, while consistently maintaining the best normalized cross-correlation (NCC) values. In the analysis of rolling bearing vibration signals, the proposed algorithm significantly reduces the mean square error while preserving signal stability and consistently outperforms comparative algorithms in NCC. By introducing a dynamically optimized forgetting factor mechanism, the proposed algorithm effectively mitigates the historical data dependency issue in AEKF and significantly enhances colored noise suppression accuracy. This provides a reliable technical solution for industrial signal processing and fault diagnosis applications.

Keywords: adaptive extended Kalman filter; dung beetle optimizer; collaborative optimization; forgetting factor; dynamic optimization mechanism; fault diagnosis; colored noise

噪声预处理是信号分析的关键环节,而实际工程系统中的过程噪声与测量噪声多为有色噪声。与高斯噪声相比,有色噪声因具有时域相关性及非均匀频谱特性而易导致信号失真、信噪比下降,从而影响系统的灵敏度与鲁棒性^[1-4]。随着智能电网、航空航天等重大工程对高精度传感与噪声抑制技术提出了更严苛的要求,噪声预处理技术的研究显得尤为重要。在工业设备振动监测领域,噪声干扰会直接影响设备状态评估的准确性,进而制约预测性维护策略的有效实施。因此,以工业设备振动监测中受齿轮箱低频共振干扰的声发射信号为研究对象,探索如何改进智能优化算法以克服传统降噪方法在处理有色噪声和非平稳信号时的局限性,同时提升算法的自适应能力和状态估计精度,具有重要的理论价值和工程应用意义。

滤波法是有色噪声处理的基础算法,虽然操作简便,但在处理具有强不确定性、时变性的有色噪声时效果有限。为此,学者们尝试结合模型辨识技术对有色噪声进行白化处理以改进滤波性能。如Luo等^[5]通过自回归(auto-regressive, AR)参数模型估计有色噪声特性;赵辰乾等^[6]则通过对噪声协方差矩阵的特征值进行一致化处理来优化滤波。然而,这类白化处理方法需在不同噪声背景下将有色噪声转换为高斯噪声,而精确的映射关系往往难以建立,且在转换过程中可能导致有用信息丢失,从而制约了其实际应用效果。针对上述问题,研究者们相继提出了多种改进策略:陈明建等^[7]提出了基于迭代最小二乘与空间差分平滑的混合信号波达方向(direction of arrival, DOA)估计算法,通过联合优化

抑制有色噪声干扰;Wang等^[8]通过将有色噪声建模为自回归过程,提出基于多信息理论的无限脉冲响应(infinite impulse response, IIR)滤波器参数估计算法,该算法显著提升了系统的稳态精度,但在处理动态突变噪声场景时适应性仍显不足。

尽管上述算法通过模型辨识技术提升了噪声处理能力,但在应对复杂非线性系统时仍存在适应性不足的缺陷,且参数调节高度依赖经验知识,普遍存在模型泛化能力弱、参数设置主观性强等局限^[9]。这些问题限制了这些算法在实际工程中的应用效果,在此背景下,基于状态估计的滤波算法因其计算高效、实时性强等特点逐渐成为研究的焦点。其中卡尔曼滤波(Kalman filter, KF)算法在导航定位等领域应用广泛,但其仅适用于线性系统的局限促使学者转向扩展卡尔曼滤波(extended Kalman filter, EKF)算法以处理信号中的有色噪声问题,如在电池荷电状态测量^[10]与运动目标定位^[11]中有效缓解了噪声干扰。然而,由于EKF模型自身缺乏自适应性,当面对强非线性系统时会造成滤波发散或结果失真^[12]。为此发展的自适应扩展卡尔曼滤波(adaptive extended Kalman filtering, AEKF)算法虽然显著提升了估计精度和鲁棒性,但其对历史数据的过度依赖问题仍未有效解决^[13]。学者们通过引入遗忘因子来削弱历史数据影响,如Elmenshawy等^[14]将遗忘因子AEKF用于配电网负荷预测,有效提升了复杂环境下的噪声处理精度,但固定值的遗忘因子难以适应系统非线性突变或噪声时变特性,导致全局最优性无法保障。值得注意的是,遗忘因子优化本质上属于复杂非线性规划问题,传统梯度算法易陷入

局部最优, 而蛻螂优化 (dung beetle optimization, DBO) 凭借种群多样性高、全局探索能力强等优势, 在动态参数寻优中展现出突出潜力^[15], 这为突破固定遗忘因子的局限性提供了新思路。鉴于此, 本文提出一种基于 DBO 与遗忘因子自适应扩展卡尔曼滤波 (forgetting factor adaptive extended Kalman filter, FFAEKF) 的有色噪声协同优化算法, 通过针对有色噪声特性改进 FFAEKF 的更新校正模型以增强对时变噪声的敏感性, 利用 DBO 的全局寻优能力动态调整最优遗忘因子以降低噪声突变的影响, 最后通过仿真与实测实验验证该算法在非线性信号滤波精度与鲁棒性方面的优越性, 以期为复杂噪声环境下的高精度信号处理提供理论支撑与技术参考。

1 FFAEKF 算法的改进

卡尔曼滤波 (KF) 是一种基于线性系统状态方程和观测数据的最优估计算法, 这种估计既可用于当前和过去状态的滤波平滑, 也可用于对未来状态的预测^[16-17]。遗忘因子自适应扩展卡尔曼滤波 (FFAEKF) 算法继承并发展了 EKF 和 AEKF 算法的优势, 通过动态调整噪声协方差矩阵显著提升了非线性系统的状态估计精度。然而, 传统 FFAEKF 算法采用固定遗忘因子的策略, 难以适应系统的非线性突变和噪声时变特性, 影响算法的全局最优性。为此, 本文结合有色噪声的统计特性, 对 FFAEKF 算法进行针对性改进。

1.1 有色噪声更新校正模型的改进

有色噪声因其时域相关性和非均匀频谱特性, 使其协方差矩阵呈现显著的非对角特性, 反映出噪声在不同时间点之间存在强相关性。传统 FFAEKF 算法基于白噪声假设 (即协方差矩阵对角) 设计, 在有色噪声环境下会出现明显的估计性能退化。为解决这一问题, 本文通过建立精确的过程噪声和测量噪声模型, 提出改进的 FFAEKF 算法, 以显著提升算法在有色噪声环境下的状态估计能力。图 1 为改进后 FFAEKF 算法的工作原理框架。

在非线性系统建模中, 利用泰勒级数展开进行线性化处理, 省略高阶无穷小项。展开式如下:

$$f(x) = f(x_0) + [\nabla f(x_0)]^T(x - x_0) + o^n \quad (1)$$

式中: $[\nabla f(x_0)]^T = \mathbf{J}(x_0)$, 表示雅可比矩阵; o^n 表示高阶无穷小量。

系统状态转移方程表示状态变量的演化, 其中噪声项满足有色噪声特性。

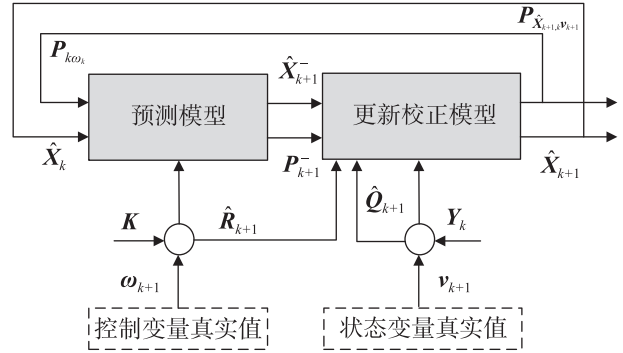


图1 改进后 FFAEKF 算法的原理框架

Fig. 1 Framework of the improved FFAEKF algorithm

$$\begin{cases} \mathbf{X}_{k+1} = f(\mathbf{X}_k) + \mathbf{\Gamma}_k \boldsymbol{\omega}_k \\ \mathbf{Y}_k = h(\mathbf{X}_k) + \mathbf{v}_k \end{cases} \quad (2)$$

式中: f 为状态转移函数, 表示前后时刻状态向量的映射关系; h 为测量函数, 表示状态向量和测量值间的映射关系; \mathbf{X}_k 表示 k 时刻的真实状态向量; $\mathbf{\Gamma}_k$ 为系统噪声矩阵; $\boldsymbol{\omega}_k$ 为 k 时刻的系统噪声。

当系统噪声为有色噪声, 且系统状态噪声仅与相邻元素有关而与不相邻元素无关, 即状态噪声序列中相邻元素 $\boldsymbol{\omega}_k$ 与 $\boldsymbol{\omega}_j$ 间存在协方差 $\text{cov}(\boldsymbol{\omega}_k, \boldsymbol{\omega}_j) \neq 0 (k \neq j)$ 相关性。假设已知 k 时刻状态估计值 $\hat{\mathbf{X}}_{k|k}$ 及其后验估计误差协方差 $\mathbf{P}_{k|k}$, 将 $f(\mathbf{X}_k)$ 在 $\hat{\mathbf{X}}_{k|k}$ 处泰勒级数展开并忽略高阶项, 可得状态方程:

$$\mathbf{X}_{k+1} = f(\hat{\mathbf{X}}_{k|k}) + \mathbf{F}_k(\mathbf{X}_k - \hat{\mathbf{X}}_{k|k}) + \mathbf{\Gamma}_k \boldsymbol{\omega}_k \quad (3)$$

式中 $\mathbf{F}_k = \frac{\partial f}{\partial \mathbf{X}_k} |_{\mathbf{X}_k = \hat{\mathbf{X}}_{k|k}}$, 表示 $f(\mathbf{X}_k)$ 在 $\hat{\mathbf{X}}_{k|k}$ 处的雅可比矩阵。

进而可得出 $k+1$ 时刻的预测 (先验估计) 结果:

$$\hat{\mathbf{X}}_{k+1|k} = E[f(\hat{\mathbf{X}}_{k|k}) + \mathbf{F}_k(\mathbf{X}_k - \hat{\mathbf{X}}_{k|k}) + \mathbf{\Gamma}_k \boldsymbol{\omega}_k] = f(\hat{\mathbf{X}}_{k|k}) \quad (4)$$

将式 (4) 两边同时减去 \mathbf{X}_{k+1} :

$$\hat{\mathbf{X}}_{k+1|k} - \mathbf{X}_{k+1} = \mathbf{F}_{k+1,k}(\hat{\mathbf{X}}_k - \mathbf{X}_k) - \mathbf{\Gamma}_k \boldsymbol{\omega}_k \quad (5)$$

假设

$$\begin{cases} \hat{\mathbf{x}}_{k+1|k} = \hat{\mathbf{X}}_{k+1|k} - \mathbf{X}_{k+1} \\ \hat{\mathbf{e}}_k = \hat{\mathbf{X}}_{k|k} - \mathbf{X}_k \end{cases} \quad (6)$$

式中 $\hat{\mathbf{e}}_k$ 表示 k 时刻最优估计值与理论值的差值。将式 (5) 代入式 (6), 由协方差传播规律可得出:

$$\begin{aligned} \mathbf{P}_{\hat{\mathbf{x}}_{k+1|k}} &= (\mathbf{F}_{k+1,k} - \mathbf{\Gamma}_k) \begin{pmatrix} \mathbf{P}_k & \mathbf{P}_{k\omega_k} \\ \mathbf{P}_{\omega_k k} & \mathbf{P}_{\omega_k} \end{pmatrix} (\mathbf{F}_{k+1,k} - \mathbf{\Gamma}_k)^T = \\ & \mathbf{F}_{k+1,k} \mathbf{P}_k \mathbf{F}_{k+1,k}^T + \mathbf{\Gamma}_{k+1,k} \mathbf{P}_{\omega_k} \mathbf{\Gamma}_{k+1,k}^T - \\ & \mathbf{\Gamma}_{k+1,k} \mathbf{P}_{\omega_k k} \mathbf{\Gamma}_{k+1,k}^T - \mathbf{F}_{k+1,k} \mathbf{P}_{k\omega_k} \mathbf{F}_{k+1,k}^T \end{aligned} \quad (7)$$

k 时刻的最优估计值如下:

$$\hat{\mathbf{X}}_k = (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k)(\hat{\mathbf{X}}_k - \mathbf{\Gamma}_{k-1} \boldsymbol{\omega}_{k-1})(\mathbf{F}_{k-1})^{-1} + \mathbf{K}_k \mathbf{Y}_k \quad (8)$$

同样, 由协方差传播规律可得到 k 时刻的最优估计误差协方差:

$$\mathbf{P}_{k\omega_k} = \begin{pmatrix} \mathbf{I} + \mathbf{K}_k \mathbf{H}_k \mathbf{\Gamma}_k & \mathbf{0} \end{pmatrix} \begin{pmatrix} \mathbf{P}_{\omega_{k-1}} & \mathbf{P}_{\omega_{k-1},k} \\ \mathbf{P}_{\omega_k,k-1} & \mathbf{P}_{\omega_k} \end{pmatrix} \begin{pmatrix} \mathbf{0} \\ \mathbf{I} \end{pmatrix} = \begin{pmatrix} \mathbf{I} + \mathbf{K}_k \mathbf{H}_k \mathbf{\Gamma}_k & \mathbf{0} \end{pmatrix} \mathbf{P}_{\omega_k,k-1} = \mathbf{P}_{\omega_k, \hat{\mathbf{x}}_k}^T \quad (9)$$

式中 $\mathbf{P}_{\omega_k, \hat{\mathbf{x}}_k}^T$ 表示 k 时刻下系统状态与动态噪声之间的方差。

将式(7)代入式(8),即可求得 $\hat{\mathbf{P}}_{\hat{\mathbf{x}}_{k+1|k}}$ 。当测量噪声为有色噪声时(其处理方式与系统噪声为有色噪声的情况类似),式(2)中 $\mathbf{v}_k = \mathbf{A}_{k,k-1} \mathbf{v}_{k-1} + \mathbf{\Phi}_{k-1}$, $\mathbf{\Phi}_{k-1}$ 应满足互不相关且均值为零的白噪声特性。基于此,通过前文算法推导,可得到适用于有色噪声环境的测量更新校正方程:

$$\begin{cases} \mathbf{K}_{k+1} = (\mathbf{P}_{\hat{\mathbf{x}}_{k+1|k}} \mathbf{H}_{k+1}^T - \mathbf{P}_{\hat{\mathbf{x}}_{k+1|k} \mathbf{v}_{k+1}})(\mathbf{H}_{k+1} \mathbf{P}_{\hat{\mathbf{x}}_{k+1|k}} \mathbf{H}_{k+1}^T + \mathbf{H}_k \mathbf{P}_{\hat{\mathbf{x}}_{k+1|k} \mathbf{v}_{k+1}} - \mathbf{P}_{\mathbf{v}_{k+1} \hat{\mathbf{x}}_{k+1|k}} \mathbf{H}_{k+1}^T)^{-1} \\ \hat{\mathbf{x}}_{k+1|k+1} = \hat{\mathbf{x}}_{k+1|k} + \mathbf{K}_{k+1} [\mathbf{Y}_{k+1} - \mathbf{H}_{k+1} \mathbf{X}_{k|k-1}] \\ \mathbf{P}_{k+1|k+1} = (\mathbf{I} - \mathbf{K}_{k+1} \mathbf{H}_{k+1})(\mathbf{P}_{k+1|k} - \mathbf{P}_{\hat{\mathbf{x}}_{k+1|k} \mathbf{v}_{k+1}}^T) \end{cases} \quad (10)$$

1.2 遗忘因子的引入

受文献[14]启发,针对AEKF算法在噪声协方差矩阵自适应更新过程中存在的估计误差发散和结果偏差问题,本文在构建有色噪声的AEKF更新校正模型基础上,进一步引入遗忘因子机制,通过动态调整历史数据的权重分配,有效提升了算法在有色噪声环境下的状态估计精度。

首先,初始化 $k=0$ 时的均值和协方差矩阵:

$$\begin{cases} \hat{\mathbf{x}}_k = \mathbf{E}(\mathbf{X}_k) \\ \mathbf{P}_{\hat{\mathbf{x}}_k} = \mathbf{E}[(\mathbf{X}_k - \hat{\mathbf{x}}_k)(\mathbf{X}_k - \hat{\mathbf{x}}_k)^T] \end{cases} \quad (11)$$

式中 $\hat{\mathbf{x}}_0$ 和 $\mathbf{P}_{\hat{\mathbf{x}}_0}$ 分别表示系统估计的初始状态和误差协方差矩阵。由第 k 步到第 $k+1$ 步的投影得到先验状态及其协方差矩阵,分别如式(4)与式(9)。

随后,基于预测模型得到的状态预测值与实际观测值,计算两者之间的残差:

$$\mathbf{r}_{k+1} = \mathbf{Y}_{k+1} - \hat{\mathbf{C}}_{k+1}^X \mathbf{P}_{\hat{\mathbf{x}}_{k+1|k}} - \mathbf{D}_{k+1}^X \mathbf{u}_{k+1} \quad (12)$$

式中 \mathbf{r}_k 为观测值与先验估计值之间的残差。后验估计结果与实际观测值之差可由式(6)中的第2个公式进一步推导得到:

$$\mathbf{e}_{k+1} = \mathbf{Y}_{k+1} - \hat{\mathbf{C}}_{k+1}^X \mathbf{P}_X - \mathbf{D}_{k+1}^X \mathbf{u}_{k+1} \quad (13)$$

最后,引入遗忘因子 α 用于自适应更新噪声协方差矩阵,推导出更新协方差矩阵:

$$\begin{cases} \mathbf{P}_{\hat{\mathbf{x}}_k \omega_k} = \alpha [(\mathbf{I} + \mathbf{K}_{k+1} \mathbf{H}_{k+1} \mathbf{\Gamma}_k) \mathbf{P}_{\hat{\mathbf{x}}_k \omega_{k-1}}] + (1 - \alpha) (\mathbf{K}_{k+1} \mathbf{r}_{k+1} \mathbf{r}_{k+1}^T \mathbf{K}_{k+1}^T) \\ \mathbf{P}_{\hat{\mathbf{x}}_{k+1|k} \mathbf{v}_{k+1}} = \alpha (\mathbf{F}_{k+1,k} \mathbf{K}_{k+1} \mathbf{P}_{\mathbf{v}_{k,k+1}}) + (1 - \alpha) [\mathbf{e}_{k+1} \mathbf{e}_{k+1}^T + \hat{\mathbf{C}}_{k+1}^X \mathbf{P}_{\hat{\mathbf{x}}_{k+1|k}} (\hat{\mathbf{C}}_{k+1}^X)^T] \end{cases} \quad (14)$$

式(14)中两式分别定义了 k 时系统噪声协方差和 $k+1$ 时预测值(先验估计)的观测噪声协方差。

2 基于DBO的遗忘因子动态调整机制

针对传统FFAEKF因固定遗忘因子导致的动态噪声适应能力不足问题,本文引入DBO算法的全局寻优特性,构建遗忘因子的动态调整机制,以提升算法在有色噪声环境下的状态估计精度。

2.1 DBO算法原理

DBO是一种新型仿生智能优化算法,其通过模拟蜣螂的滚球、产卵、觅食和偷窃等自然行为实现全局最优解搜索。该算法的核心思想在于利用种群个体在多维解空间中进行协同搜索,并借助动态位置更新策略寻找最优参数^[18]。DBO的搜索框架^[19]主要包括4种行为模型,其中滚球行为的位置更新方式可表示为:

$$\begin{aligned} \mathbf{x}_i(t+1) &= \mathbf{x}_i(t) + \eta l \mathbf{x}_i(t-1) + \xi \Delta \mathbf{x} \\ \Delta \mathbf{x} &= |\mathbf{x}_i(t) - \mathbf{X}^w| \end{aligned} \quad (15)$$

式中: i 为蜣螂个体序号; η 为自然系数, $\eta=1$ 表示没有偏离, $\eta=-1$ 表示偏离原来方向; \mathbf{X}^w 表示全局最差位置; $\Delta \mathbf{x}$ 表示模拟光强的变化,数值越大表示光照越弱; $l \in (0,0.2)$, 表示偏转系数; $\xi \in (0,1)$ 表示常数。

在滚球行为模拟过程中,当遇到障碍物(局部最优)时,算法通过引入跳舞行为实现路径重定向,其位置更新方式可表示为:

$$\mathbf{x}_i(t+1) = \mathbf{x}_i(t) + \tan(\theta) |\mathbf{x}_i(t) - \mathbf{x}_i(t-1)| \quad (16)$$

式中: $\theta \in [0, \pi]$; $|\mathbf{x}_i(t) - \mathbf{x}_i(t-1)|$ 表示第 i 只蜣螂在第 t 次与第 $t-1$ 次迭代时的位置差。因此,滚球个体的位置更新具有动态记忆特性,其运动轨迹由当前环境信息与历史最优位置共同决定。特别地,为模拟雌性蜣螂为后代优化栖息地的生物特性,当种群进入产卵阶段时,算法通过以下更新方程实现安全区域的定位:

$$\begin{aligned} L^* &= \max(\mathbf{A}(1-R), L) \\ U^* &= \min(\mathbf{A}(1+R), U) \end{aligned} \quad (17)$$

式中: L, U 分别表示产卵区域的下界和上界; \mathbf{A} 表示当前局部最优解; $R = 1 - t/t_{\max}$; t_{\max} 表示最大迭代次数。产卵区域也会随迭代次数动态调整,可表示为:

$$\mathbf{B}_i(t+1) = \mathbf{A} + b_1(\mathbf{B}_i(t) - L^*) + b_2(\mathbf{B}_i(t) - U^*) \quad (18)$$

其中: $\mathbf{B}_i(t)$ 表示第 t 次迭代时第 i 个卵球的位置; b_1 和 b_2 表示2个大小为 $1 \times N$ 的独立随机向量; N 表示优化问题的维度。当算法模拟成熟蜣螂的觅食行为时,位置更新遵循与产卵阶段相同的优化准则。此时个体通过以下更新方程确定最佳觅食区域:

$$x_i(t+1) = x_i(t) + M_1(x_i(t) - L^b) + M_2(x_i(t) - U^b) \quad (19)$$

式中: M_1 表示遵循正态分布的随机向量; $M_2 \in (0, 1)$, 表示随机向量。

在 DBO 的最终阶段, 算法模拟部分蛭螂窃取其他个体粪球的生物竞争行为, 该行为通过以下位置更新方程实现种群多样性的增强。

$$x_i(t+1) = X^d + sg \{ |x_i(t) - X^*| + |x_i(t) - X^d| \} \quad (20)$$

式中: g 表示大小为 $1 \times G$ 且服从正态分布的随机向量; X^d 表示食物竞争的最佳位置; s 为常量。

DBO 算法通过模拟蛭螂的滚球、产卵、觅食和偷窃等系列自然行为, 实现对搜索空间的多维度探索, 有效避免陷入局部最优, 并在局部开发和全局搜索之间保持良好平衡^[20]。

2.2 遗忘因子优选机制

以信噪比 (signal-to-noise ratio, SNR) 作为优化目标函数, 利用 DBO 算法动态调整 FFAEKF 中的遗忘因子 α , 具体实现步骤如下:

1) 初始化算法参数, 设定最大迭代次数 t_{max} 及蛭螂种群规模。

2) 设置滤波器参数, 初始化状态向量及其误差协方差矩阵, 并给定过程噪声与观测噪声的协方差矩阵。

3) 迭代优化, 若当前迭代次数未达到预设最大值, 则通过评估蛭螂个体局部与全局最优位置的适应度来判断是否满足收敛条件。在每轮迭代中, 个体根据 DBO 行为规则, 结合当前全局最优位置信息更新自身状态, 其位置更新公式可表示为:

$$\alpha_i(t+1) = \alpha_i(t) + c_1 m_1 (\alpha_b - \alpha_i(t)) + c_2 m_2 (\alpha_g - \alpha_i(t)) \quad (21)$$

式中: $\alpha_i(t)$ 为第 i 个蛭螂个体在第 t 轮的参数组合; α_b 为全局最优的个体参数; α_g 为某局部最优的个体参数; c_1, c_2 为学习因子, 控制个体更新的幅度; m_1, m_2 为随机数, 用于引入随机性。

4) 优化评估, 计算当前蛭螂位置对应的 SNR, 若不满足 $SNR_{t+1} > SNR_t$, 则第 t 次迭代位置更优, 更新蛭螂位置变量代替原蛭螂位置; 否则保留当前位置。当位置变量在连续迭代中不再变化时, 循环终止, 输出当前位置作为最优解。

5) 输出最优解, 并将其幅值赋予遗忘因子 α 。

综上, 本文提出的 FFAEKF-DBO 协同优化算法流程如图 2。该算法通过 DBO 的全局寻优机制动态调整遗忘因子, 有效克服了传统 FFAEKF 中固定遗忘因子在时变噪声环境下适应性不足的局限。

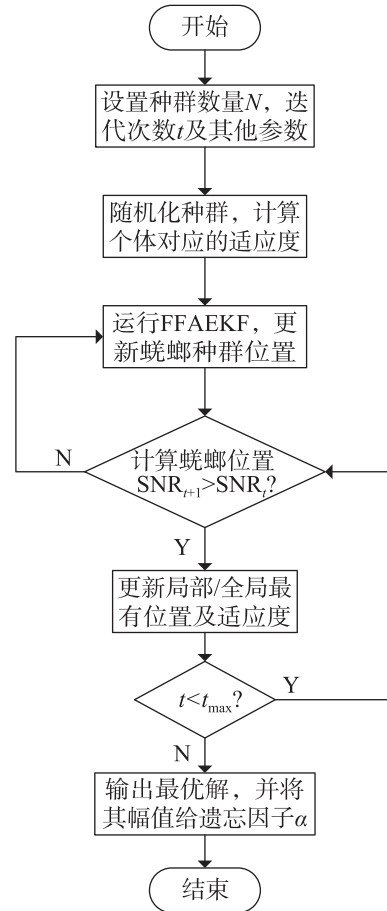


图2 FFAEKF-DBO 协同优化算法的流程图

Fig. 2 Flowchart of the FFAEKF-DBO collaborative optimization algorithm

3 实验与结果分析

为验证本文算法对实际有色噪声和工程应用中的降噪效果, 选取 2 种数据集开展多维度测试实验。第一种为英国感知技术研究院语音研究部门公开的实测有色噪声数据集, 包含典型有色噪声信号, 用于评估算法在不同频谱特性噪声环境下的处理能力; 第二种采用美国凯斯西储大学轴承数据中心发布的滚动轴承故障振动信号数据集, 包括外圈故障、内圈故障和滚动体故障三类典型机械故障信号, 以检验算法在实际工程场景中对复杂振动信号的噪声处理能力。2 种数据集采样频率均为 1 kHz, 采样时间均为 1 s, 前者侧重于模拟典型有色噪声环境, 后者则聚焦于机械故障信号中的实际降噪问题。

3.1 有色噪声信号的仿真验证

从有色噪声数据集中随机选取粉红、蓝色、泊松和红色四类典型噪声进行测试。其中粉红噪声作为一种主要分布在低频段的背景噪声, 其功率谱密度与频率成反比, 即频率越低噪声强度越高。在实

验过程中,通过将有用信号与粉红噪声叠加构建混合信号,其时域波形如图3。由图3可看出:粉红噪声的引入导致原始信号波形产生明显扭曲与失真。经计算,该混合信号的信噪比(SNR)为2.38 dB。




图3 混合信号的时域波形

Fig. 3 Time-domain waveform of the mixed signal

假设系统参数矩阵、噪声驱动矩阵及测量系统参数矩阵均为一阶单位矩阵,设定蜣螂种群规模为特定值,最大迭代次数为200,个体学习因子与群体学习因子均取1.5,遗忘因子寻优范围为 $0.950 \leq \alpha \leq 0.995$ 。在相同条件下,分别采用EKF, AEKF, FFAEKF及本文算法对混合信号进行仿真实验,结果如图4。在仿真过程中,通过DBO优化得到的最优遗忘因子为0.9941,而FFAEKF中固定遗忘因子为0.9750。由图4可看出:本文算法展现出显著的噪声抑制优势,其处理后的信号波形平滑度明显优于对比算法;此外能够更好地保留信号细节,即使在高峰和低谷部分,即在噪声较强的情况下仍能保持波形特征的稳定性,表现出良好的鲁棒性。

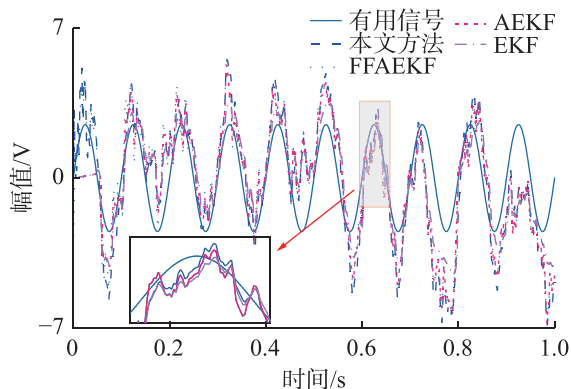


图4 混合信号的处理结果

Fig. 4 Processing result of the mixed signal

选用平均绝对误差(mean absolute error, MAE)、均方根误差(root mean square error, RMSE)、归一化互相关系数(normalized correlation coefficient, NCC)和SNR评价信号处理的效果。其中NCC通过去噪前后信号波形的整体相似度反映对有用信号的保留程度,NCC值越大说明有用信号保留的程度越大,NCC的计算式可表示为:

$$NCC = \frac{1}{n} \sum_{x,y} \frac{1}{\sigma_f \sigma_t} (f(x,y) - \mu_f)(t(x,y) - \mu_t) \quad (22)$$

式中: f, t 为2种信号样本; n 为向量维数或窗口大小; σ 为样本的标准差; μ 为样本的均值。EKF, AEKF, FFAEKF及本文算法对四类有色噪声信号的处理效果指标如表1。

表1 不同算法对四类有色噪声的滤波效果对比

Tab. 1 Comparison of filtering performance of different algorithms for four types of colored noise

噪声类型	处理算法	MAE/V	RMSE/V	NCC	SNR/dB
粉红噪声	EKF	1.548	1.940	0.682	2.56
	AEKF	1.452	1.820	0.692	2.83
	FFAEKF	1.454	1.837	0.714	3.08
	本文算法	1.286	1.591	0.741	3.49
蓝色噪声	EKF	3.006	3.126	0.586	0.85
	AEKF	3.001	3.105	0.589	0.89
	FFAEKF	2.887	3.607	0.621	0.97
	本文算法	2.638	3.259	0.648	1.14
泊松噪声	EKF	0.298	0.301	0.688	5.88
	AEKF	0.289	0.291	0.702	6.79
	FFAEKF	0.276	0.286	0.708	6.81
	本文算法	0.240	0.247	0.715	8.64
红色噪声	EKF	1.999	2.234	0.682	1.79
	AEKF	2.187	2.439	0.682	1.24
	FFAEKF	2.056	2.538	0.713	1.29
	本文算法	1.999	2.529	0.723	1.82

从表1可见:与EKF, AEKF和FFAEKF相比,本文算法展现出全面优势。从粉红噪声来看,相较于基准EKF算法,本文算法的MAE与RMSE分别降低了约16.93%和17.99%;同时,SNR获得了最高0.93 dB的显著提升;此外,本文算法的NCC值始终保持最高。以上结果表明,本文算法在误差控制、噪声抑制和信号保真方面均优于传统算法。

综上所述,本文算法通过动态优化机制有效增强了抗干扰能力,在粉红、蓝色、泊松及红色噪声等多种复杂环境中均展现出优异的环境适应性,即使面临突发噪声干扰仍能保持稳定的滤波性能和较高的估计精度。

3.2 滚动轴承振动信号的仿真实验验证

为进一步验证本文算法的实际应用效果, 采用 EKF, AEKF, FFAEK 和本文算法对轴承振动信号数据集进行对比实验分析。实验选用通过电火花加工制备的单点故障轴承, 故障直径为 0.177 8 mm, 涵盖外圈故障 (outer ring failure, OF)、球面故障 (ball failure, BF)、内圈故障 (inter ring failure, IF) 3 种典型故障类型。针对滚动轴承信号中的非平稳噪声特性, 采用自回归积分滑动平均模型 (auto-regressive integrated moving average, ARIMA) 对轴承进行降噪, 其主要包括随机序列平稳性检验、差分阶数 d 确定、模型定阶 (p, d, q)、参数估计与模型诊断等流程。三类故障信号的静态数据特征如图 5。




图5 滚动轴承信号的原始输出特征

Fig. 5 Raw output feature of rolling bearing signal

设 ARIMA(p, d, q) 模型如下^[21]:

$$x_k = \sum_{j=1}^p a_j x_{k-j} + \varepsilon_k + \sum_{j=1}^q b_j \varepsilon_{k-j} \quad (23)$$

式中: x_k 为 k 时刻随机噪声; a_j 为自回归系数; b_j 为滑动平均系数; ε_k 为未知方差的白噪声。

通过平稳性检验确定模型阶数 $p = 2, d = 0, q = 2$; 采用最大似然估计法对模型系数 (a_i, b_j) 进行参数估计, 所得结果见表 2。

表 2 滚动轴承随机噪声 ARIMA 模型参数


Tab. 2 Parameters of ARIMA model for rolling bearing random noise

轴承信号	阶数	自回归系数(a_j)	滑动平均模型(b_j)
BF信号	1	0.369 2	0.002 1
	2	0.095 0	-0.981 1
OF信号	1	0.412 1	0.022 4
	2	-0.411 5	-0.977 6
IF信号	1	0.808 9	0.007 7
	2	-0.317 3	-0.988 0


将获得的 ARIMA ($p, 0, q$) 模型参数转换为滤波系统的状态方程与测量方程。令状态向量 $\mathbf{X}_k = [x_k x_{k-1} \cdots x_{k-p+1}]^T$, 建立本文算法的滤波状态方程和测量方程:

$$\begin{cases} \mathbf{X}_k = \begin{bmatrix} a_1 & a_2 & \cdots & a_p \\ 1 & 0 & \cdots & 0 \\ 0 & 1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 1 \end{bmatrix} \mathbf{X}_{k-1} + \begin{bmatrix} 1 & b_1 & \cdots & b_q \\ 0 & 0 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 0 \\ 0 & 0 & \cdots & 0 \end{bmatrix} \begin{bmatrix} \varepsilon_k \\ \varepsilon_{k-1} \\ \vdots \\ \varepsilon_{k-q} \end{bmatrix} \\ Y_k = [1 \ 0 \ \cdots \ 0] \mathbf{X}_k + v_k \end{cases} \quad (24)$$

为验证本文算法的有效性, 将式 (24) 替换式 (2) 进行实验。图 6 为 EKF, AEKF, FFAEKF 及本文算法对三类轴承振动信号滤波处理后的局部放大对比结果, 表 3 为上述 4 种算法的处理效果统计指标。



(a) BF信号处理结果



(b) OF信号处理结果




图6 三类轴承振动信号滤波处理后的局部放大对比结果

Fig. 6 Comparative results of locally amplified filtered vibration signals for three bearing types

表3 不同算法处理结果的统计特性

Tab. 3 Statistical characteristics of processing results from different methods

故障信号	原始数据及处理算法	均值/V	均方差/V	NCC
BF信号	原始数据	0.006 4	0.002 1	1.000 0
	EKF	0.006 1	0.001 8	0.863 7
	AEKF	0.005 8	0.001 7	0.878 7
	FFAEKF	0.006 4	0.001 3	0.778 4
	本文算法	0.006 3	0.001 0	0.954 5
OF信号	原始数据	0.006 4	0.002 1	1.000 0
	EKF	0.005 8	0.001 9	0.673 4
	AEKF	0.006 1	0.001 5	0.808 3
	FFAEKF	0.006 3	0.001 7	0.807 8
	本文算法	0.006 4	0.001 2	0.950 0
IF信号	原始数据	0.006 4	0.002 1	1.000 0
	EKF	0.006 0	0.002 0	0.693 8
	AEKF	0.006 3	0.001 8	0.835 5
	FFAEKF	0.006 3	0.001 8	0.838 8
	本文算法	0.006 4	0.001 5	0.952 4

综合分析图 5, 6 及表 3 可以看出: 4 种算法均有效降低了轴承信号中的随机噪声成分, 且对各故障类型信号处理后的均值与原始数据基本保持一致, 表明 4 种算法都具有良好的无偏估计特性。从均方误差降低效果看, 本文算法表现最为突出: 对于 BF 信号, EKF, AEKF, FFAEKF 和本文算法使均方差分别降低 14.29%, 19.05%, 38.10%, 52.38%; 对于 OF 信号, 相应降幅为 9.52%, 28.57%, 19.48%, 42.86%; 对于 IF 信号, 相应降幅为 4.76%, 14.29%, 14.29%, 28.57%。结果表明, 本文算法在抑制随机噪声方面具有显著优势; 与其他 3 种算法相比, 本文算法处理后的三类故障信号 NCC 均最高, 说明其在滤除噪声的同时对原始有用信号的保留程度也最优。

综上所述, 本文算法在滚动轴承故障信号

处理中也展现出显著优势, 该算法通过减小对历史数据的依赖, 有效提升了信号估计精度, 从而显著抑制了有色噪声干扰, 且在复杂噪声环境下保持了稳定的诊断性能。

4 结论

针对传统 AEKF 在处理有色噪声时因过度依赖历史数据而导致估计精度下降的问题, 提出一种融合蜣螂优化 (DBO) 与遗忘因子机制的协同优化算法。该算法基于有色噪声特性, 在 AEKF 预测模型中引入遗忘因子以削弱历史噪声对状态估计的影响, 并利用 DBO 的全局寻优能力动态优化遗忘因子, 从而增强算法对时变噪声的适应性和滤波精度。实验表明: 在四类典型有色噪声数据集上, 相较于 EKF 算法、AEKF 及 FFAEKF 算法, 本文算法显著降低了混合信号的 MAE 和 RMSE; 在滚动轴承振动信号数据集中, 本文算法在维持信号均值稳定的同时, 使均方差最大降低 52.38%, 且 NCC 接近原始信号, 验证了其在保留有用信号细节与抑制有色噪声方面的优越性能。本文算法通过动态优化遗忘因子, 有效解决了 AEKF 的历史数据依赖性问题, 为复杂工业场景下的高精度信号处理与故障诊断提供了可靠技术支撑。未来研究聚焦于该算法在强非线性系统及多源噪声耦合环境中的适用性拓展, 进一步推动其工程应用。

参考文献:

- [1] LI J H, DING F. Maximum likelihood stochastic gradient estimation for Hammerstein systems with colored noise based on the key term separation technique[J]. *Computers & Mathematics with Applications*, 2011, 62(11):4170-4177.
- [2] KHANZADI M R, KRISHNAN R, ERIKSSON T. Estimation of phase noise in oscillators with colored noise sources[J]. *IEEE Communications Letters*, 2013, 17(11):2160-2163.
- [3] DAI Q, XIAO G R, WAN R, et al. An improved Gaussian sum extended Kalman filter with colored noise for GNSS/SINS tightly coupled positioning and attitude determination systems[J]. *IEEE Access*, 2024, 12:73279-73291.
- [4] 张运来, 张华, 陈丰, 等. 基于 Shi-Tomasi 角点检测算法的番茄枝条分权点识别算法 [J/OL]. *安徽科技学院学报*, (2025-03-06). <https://link.cnki.net/urlid/34.1300.N.20250306.1348.004>.
ZHANG Y L, ZHANG H, CHEN F, et al. Tomato branch fork point recognition method based on Shi-Tomasi corner

- detection algorithm [J/OL]. Journal of Anhui Science and Technology University,(2025-03-06). <https://link.cnki.net/urlid/34.1300.N.20250306.1348.004>.
- [5] LUO Y, ZHOU J Y, YANG W. Distributed state estimation with colored noises[J]. IEEE Transactions on Circuits and Systems II: Express Briefs, 2022, 69(6):2807-2811.
- [6] 赵辰乾, 刘益辰, 刘欣. 有色噪声下 GNSS 空时抗干扰算法的性能分析和改进 [J]. 电子与信息学报, 2022, 44(4):1388-1394.
- ZHAO C Q, LIU Y C, LIU X. Effect of colored noise on STAP algorithm for GNSS anti-jamming and algorithm improvement[J]. Journal of Electronics & Information Technology, 2022, 44(4):1388-1394.
- [7] 陈明建, 胡振彪, 陈林, 等. 非均匀噪声背景下混合信号 DOA 估计算法 [J]. 信号处理, 2019, 35(2):168-175.
- CHEN M J, HU Z B, CHEN L, et al. The algorithm for direction-of-arrival for uncorrelated and coherent signals estimation in the presence of unknown nonuniform noise fields[J]. Journal of Signal Processing, 2019, 35(2):168-175.
- [8] WANG Y J, DING F, XU L. Some new results of designing an IIR filter with colored noise for signal processing[J]. Digital Signal Processing, 2018, 72:44-58.
- [9] QIAN Q, HU T Y, ZENG T S. Weak seismic signal enhancement for low signal-to-noise ratio data using adaptive nonstationary signal decomposition[J]. IEEE Geoscience and Remote Sensing Letters, 2024, 21:3001305.
- [10] YUN J, CHOI Y, LEE J, et al. State-of-charge estimation method for lithium-ion batteries using extended Kalman filter with adaptive battery parameters[J]. IEEE Access, 2023, 11:90901-90915.
- [11] 戎靖, 李入作, 王杰, 等. 基于卡尔曼滤波算法的电机速度数据自动采集系统设计 [J]. 电子设计工程, 2024, 32(22):63-67.
- RONG J, LI R Z, WANG J, et al. Design of automatic data acquisition system for motor speed based on Kalman filter algorithm[J]. Electronic Design Engineering, 2024, 32(22):63-67.
- [12] 谢良海, 彭斌, 单祎莹, 等. 基于多通道卡尔曼滤波方法的砖砌体墙基本频率识别 [J]. 上海理工大学学报, 2023, 45(5):495-502.
- XIE LH, BENG B, DAN W Y, et al. Basic frequency identification for brick masonry walls based on multi-channel Kalman filtering[J]. Journal of University of Shanghai for Science and Technology, 2023, 45(5):495-502.
- [13] 赖欣, 杨肖, 张启灿. 基于自适应 EKF 的摄像机标定优化算法 [J]. 光学学报, 2023, 43(23):2315002.
- LAI X, YANG X, ZHANG Q C. Adaptive EKF-based camera calibration optimization method[J]. Acta Optica Sinica, 2023, 43(23):2315002.
- [14] ELMENSHAWY M S, MASSOUD A M. Short-term load forecasting in active distribution networks using forgetting factor adaptive extended Kalman filter[J]. IEEE Access, 2023, 11:103916-103924.
- [15] LYU L X, JIANG H, YANG F. Improved dung beetle optimizer algorithm with multi-strategy for global optimization and UAV 3D path planning[J]. IEEE Access, 2024, 12:69240-69257.
- [16] 丁磊, 吴蔚劫, 方挺. 基于扩展卡尔曼滤波的多旋翼飞行器融合姿态解算算法 [J]. 安徽工业大学学报(自然科学版), 2018, 35(3):240-248.
- DING L, WU W J, FANG T. Fusion attitude solving algorithm of multi rotor aircraft based on extended Kalman filter[J]. Journal of Anhui University of Technology (Natural Science), 2018, 35(3):240-248.
- [17] 高凤强, 王若宇, 曹光求, 等. 基于扩展卡尔曼滤波的疏散行人密度预测算法研究 [J]. 仪器仪表学报, 2024, 45(5):281-290.
- GAO F Q, WANG R Y, CAO G Q, et al. Research on the evacuation pedestrian density prediction algorithm based on extended Kalman filter[J]. Chinese Journal of Scientific Instrument, 2024, 45(5):281-290.
- [18] ZHANG D M, WANG Z J, ZHAO Y Q, et al. Multi-strategy fusion improved dung beetle optimization algorithm and engineering design application[J]. IEEE Access, 2024, 12:97771-97786.
- [19] WANG Z L, SHAO P. A multi-strategy dung beetle optimization algorithm for optimizing constrained engineering problems[J]. IEEE Access, 2023, 11:98805-98817.
- [20] XUE J K, SHEN B. Dung beetle optimizer: a new meta-heuristic algorithm for global optimization[J]. The Journal of Supercomputing, 2023, 79(7):7305-7336.
- [21] GEORGE E P, GWILYM M, JENKINS G E P, et al. Time Series Analysis, Forecasting and Control[M]. Rev ed. San Francisco: Holden-Day, 1976.