

基于联合熵驱动改进麻雀搜索优化VMD的DAS信号去噪方法

杨孟威

河北地质大学信息工程学院, 河北 石家庄

收稿日期: 2026年7月18日; 录用日期: 2026年8月19日; 发布日期: 2026年8月27日

摘要

分布式光纤声波传感(Distributed Acoustic Sensing, DAS)系统采集的振动信号易受到环境噪声和系统噪声干扰, 导致有效特征提取困难。针对传统变分模态分解(Variational Mode Decomposition, VMD)参数依赖经验选取以及单一评价指标难以准确表征分解质量的问题, 提出一种联合熵驱动的改进麻雀搜索优化变分模态分解(EI-PE-ISSA-VMD) DAS信号去噪方法。以模态数 K 和惩罚因子 α 为优化对象, 引入Tent混沌初始化、自适应发现者比例和自适应步长策略对麻雀搜索算法(SSA)进行改进, 实现VMD参数自适应优化; 构建包络熵(Envelope Entropy, EE)与排列熵(Permutation Entropy, PE)联合适应度函数, 从信号能量分布和时间序列复杂度两个维度综合评价VMD分解质量; 同时采用基于相关系数的本征模态函数(IMF)筛选重构策略, 提高信号重构精度和噪声抑制能力。基于MATLAB平台, 本文参考PubDAS公开数据集及相关文献中DAS振动信号的典型时域和频谱特征, 构建模拟DAS振动信号, 并与小波阈值去噪、传统VMD、SSA-VMD及ISSA-VMD方法进行对比实验。实验结果表明, 本文方法获得的最优参数组合为 $K=10$ 、 $\alpha=646$, 信噪比(SNR)达到10.2629 dB, 均方根误差(RMSE)降低至0.2982。与传统VMD相比, SNR提高8.11%, RMSE降低8.47%; 与ISSA-VMD相比, SNR进一步提高0.4817 dB。结果表明, 所提方法能够有效抑制噪声干扰, 在保留有效振动特征的同时提高信号重构质量, 为DAS信号降噪及智能光纤感知系统信号处理提供了一种有效技术方案。

关键词

分布式光纤声波传感, 变分模态分解, 改进麻雀搜索算法, 联合熵, 信号去噪

Joint Entropy-Driven Improved Sparrow Search Optimized VMD for DAS Signal Denoising

Mengwei Yang

School of Information Engineering, Hebei GEO University, Shijiazhuang Hebei

Abstract

Distributed Acoustic Sensing (DAS) signals are susceptible to environmental and system noise interference, which makes useful vibration feature extraction difficult. To address the dependence of Variational Mode Decomposition (VMD) on empirical parameter selection and the limited ability of a single evaluation index to characterize decomposition quality, this paper proposes a joint entropy-driven Improved Sparrow Search Algorithm optimized VMD (EE-PE-ISSA-VMD) method for DAS signal denoising. The modal number K and penalty factor α are taken as optimization variables. Tent chaotic initialization, an adaptive discoverer ratio, and an adaptive step-size strategy are introduced to improve the Sparrow Search Algorithm (SSA), thereby realizing adaptive optimization of VMD parameters. A joint fitness function combining Envelope Entropy (EE) and Permutation Entropy (PE) is constructed to evaluate VMD decomposition quality from the perspectives of energy distribution and time-series complexity. In addition, a correlation coefficient-based Intrinsic Mode Function (IMF) selection and reconstruction strategy is employed to improve reconstruction accuracy and noise suppression capability. Simulation experiments were conducted on simulated DAS vibration signals constructed in MATLAB with reference to the typical time-domain and spectral characteristics of DAS vibration signals reported in the PubDAS public dataset and related literature. The experimental results show that the optimal parameter combination obtained by the proposed method is $K = 10$ and $\alpha = 646$, achieving a Signal-to-Noise Ratio (SNR) of 10.2629 dB and a Root Mean Square Error (RMSE) of 0.2982. Compared with conventional VMD, the proposed method improves the SNR by 8.11% and reduces the RMSE by 8.47%. Compared with ISSA-VMD, the SNR is further improved by 0.4817 dB. The results demonstrate that the proposed method can effectively suppress noise interference while preserving useful vibration features and improving signal reconstruction quality, providing an effective technical solution for DAS signal denoising and intelligent fiber-optic sensing applications.

Keywords

Distributed Acoustic Sensing (DAS), Variational Mode Decomposition (VMD), Improved Sparrow Search Algorithm (ISSA), Joint Entropy, Signal Denoising

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

分布式光纤声波传感(Distributed Acoustic Sensing, DAS)技术利用光纤作为连续传感介质,通过检测光纤中瑞利散射光相位变化实现沿光纤全程振动信息的实时感知。相比传统点式传感器,DAS具有监测距离长、空间分辨率高、抗电磁干扰能力强以及环境适应性好等优点,已广泛应用于油气管道安全监测、周界安防、轨道交通运行监测、结构健康监测以及地震勘探等领域[1]-[5]。随着智慧城市、智能交通及工业物联网技术的快速发展,DAS系统在大范围、多场景振动监测中的应用需求不断增长,对信号处理与特征提取技术提出了更高要求。

然而,在实际工程环境中,DAS系统采集的振动信号通常受到环境噪声、设备噪声及随机扰动等因素影响,导致信号信噪比较低,微弱振动特征容易被噪声淹没,进而影响后续事件识别、目标定位和状

态评估的准确性。因此,研究高效、稳定且具有良好特征保持能力的 DAS 信号去噪方法,对于提升 DAS 系统监测性能和工程应用价值具有重要意义。

针对非平稳信号去噪问题,国内外学者开展了大量研究。小波变换(Wavelet Transform, WT)凭借良好的时频局部化能力被广泛应用于振动信号降噪,但其处理效果依赖于小波基函数和阈值参数的选择[6]。经验模态分解(Empirical Mode Decomposition, EMD)能够实现非线性、非平稳信号的自适应分解,但存在模态混叠和端点效应等问题[7]。随后提出的集合经验模态分解(Ensemble Empirical Mode Decomposition, EEMD)通过引入辅助白噪声改善了模态混叠现象,但仍存在计算复杂度较高和重构误差累积等不足[8]。因此,如何实现更加稳定、高效的信号分解与去噪成为当前研究热点。

变分模态分解(Variational Mode Decomposition, MD)由 Dragomiretskiy 等提出[9],其通过构建严格的变分约束模型,将复杂信号分解为若干具有有限带宽的本征模态函数(Intrinsic Mode Function, IMF),能够有效抑制模态混叠并提高频谱分离精度。相比 EMD 类方法,VMD 具有更好的数学理论基础和噪声鲁棒性,已广泛应用于机械故障诊断、生物医学信号处理、电力系统分析以及光纤传感信号处理等领域[10]-[16]。近年来,研究人员将 VMD 引入 DAS 及光纤传感信号分析过程中,通过对振动信号进行多尺度分解与重构,实现噪声抑制和特征增强,取得了较好的应用效果。

然而,VMD 分解效果高度依赖于模态数 K 和惩罚因子 α 的设置。当参数选择不合理时,容易出现欠分解或过分解现象,从而影响信号重构质量和特征提取效果。为实现参数自适应优化,研究人员将粒子群优化算法(Particle Swarm Optimization, PSO)、灰狼优化算法(Grey Wolf Optimizer, GWO)、鲸鱼优化算法(Whale Optimization Algorithm, WOA)以及麻雀搜索算法(Sparrow Search Algorithm, SSA)等智能优化算法应用于 VMD 参数寻优。其中,SSA 因具有参数少、实现简单和全局搜索能力较强等特点,在 VMD 参数优化领域受到广泛关注[17]-[21]。

目前,基于 SSA 优化 VMD 参数的研究已经取得一定进展。例如,有学者利用 SSA 实现 VMD 参数自动寻优,并应用于轴承故障诊断、旋转机械状态监测及振动信号降噪等领域,取得了较好的效果。然而,传统 SSA 仍存在种群初始化随机性较大、搜索后期易陷入局部最优以及收敛稳定性不足等问题。此外,现有研究大多采用单一包络熵作为适应度函数评价 VMD 分解质量,仅能反映信号能量分布特征,难以同时表征时间序列复杂度信息,从而限制了参数优化精度和去噪性能。与此同时,VMD 分解后产生的部分 IMF 分量仍可能包含较强噪声成分,若全部参与信号重构,将导致重构结果中残留较多噪声信息。

针对上述问题,本文提出一种联合熵驱动的改进麻雀搜索优化变分模态分解(EE-PE-SSA-VMD)DAS 信号去噪方法。首先,引入 Tent 混沌映射、自适应发现者比例及自适应步长策略对传统 SSA 进行改进,提高算法全局搜索能力和收敛稳定性;其次,构建包络熵(Envelope Entropy, EE)与排列熵(Permutation Entropy, PE)联合适应度函数,从信号能量分布特征和复杂度特征两个方面综合评价 VMD 分解质量,实现参数 K 和 α 的自适应优化;最后,引入基于相关系数的 IMF 筛选重构机制,抑制噪声模态对重构结果的影响,提高最终去噪性能。

2. VMD 算法原理

2.1. VMD 变分约束模型

变分模态分解(Variational Mode Decomposition, VMD)是由 Dragomiretskiy 和 Zosso 于 2014 年提出的一种自适应信号分解方法。与 EMD 及其改进算法相比,VMD 通过构建严格的变分优化模型实现信号分解,能够有效抑制模态混叠现象,具有良好的频谱分离能力和噪声鲁棒性。

VMD 的核心思想是将输入信号分解为若干个具有有限带宽的本征模态函数(IMF),并使各模态围绕

不同中心频率分布。设原始信号为： $f(t)$ 分解后得到 K 个模态分量： $u_k(t), k=1,2,\dots,K$ 。首先，对每个模态进行 Hilbert 变换，构造解析信号：

$$u_k(t) + \frac{j}{\pi t} u_k(t) \quad (2-1)$$

其中，“*”表示卷积运算。

随后，将各模态调制到对应中心频率 ω_k 附近，从而获得单边频谱表示：

$$\left[u_k(t) + \frac{j}{\pi t} u_k(t) \right] e^{-j\omega_k t} \quad (2-2)$$

通过计算解析信号梯度平方范数来衡量模态带宽，构建变分约束模型：

$$\min \left\{ \sum_k \left\| \partial_t \left\{ \left[\delta(t) + \frac{j}{\pi t} u_k(t) \right] e^{-j\omega_k t} \right\} \right\|^2 \right\} \quad (2-3)$$

同时满足信号重构约束：

$$\sum_k u_k(t) = f(t) \quad (2-4)$$

2.2. 增广拉格朗日函数构建

为了求解上述约束优化问题，引入二次惩罚因子 α 和拉格朗日乘子 $\lambda(t)$ ，构造增广拉格朗日函数：

$$\begin{aligned} L(\{u_k\}, \{\omega_k\}, \lambda) = & \alpha \sum_k \left\| \partial_t \left\{ \left[\delta(t) + \frac{j}{\pi t} u_k(t) \right] e^{-j\omega_k t} \right\} \right\|^2 \\ & + \left\| f(t) - \sum_k u_k(t) \right\|^2 + \left\langle \lambda(t), f(t) - \sum_k u_k(t) \right\rangle \end{aligned} \quad (2-5)$$

其中： α 用于控制模态带宽约束强度； $\lambda(t)$ 用于保证信号重构约束条件成立。通过增广拉格朗日函数可将约束优化问题转化为无约束优化问题，从而提高求解效率。

2.3. ADMM 迭代求解过程

VMD 采用交替方向乘子法(Alternating Direction Method of Multipliers, ADMM)对模态分量和中心频率进行迭代更新。在频域中，第 k 个模态更新表达式为：

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (2-6)$$

中心频率更新为：

$$\omega_k^{n+1} = \frac{\int \omega |\hat{u}_k(\omega)|^2 d\omega}{\int |\hat{u}_k(\omega)|^2 d\omega} \quad (2-7)$$

拉格朗日乘子更新为：

$$\lambda^{n+1} = \lambda^n + \tau \left[f - \sum_k u_k \right] \quad (2-8)$$

其中 τ 为更新步长参数。

2.4. 收敛条件与参数影响分析

当连续两次迭代结果满足：

$$\sum_k \frac{\|u_k^{n+1} - u_k^n\|^2}{\|u_k^n\|^2} < \varepsilon \quad (2-9)$$

时认为算法收敛，其中 ε 为预设收敛阈值。

在 VMD 算法中，模态数 K 和惩罚因子 α 是影响分解效果的关键参数。当 K 取值过小时，不同频率成分容易混叠，导致欠分解现象；当 K 取值过大时，则容易产生过分解现象，增加冗余模态。与此同时， α 决定了模态带宽约束强度，不合理的参数设置会导致频谱分离效果下降。因此，实现 K 与 α 的自适应优化是提升 VMD 分解性能和信号去噪效果的重要途径。

针对上述问题，本文采用改进麻雀搜索算法对 VMD 参数进行智能寻优，并结合 EE-PE 联合适应度函数实现参数自适应优化，从而获得更优的 DAS 信号去噪效果。

3. 联合熵驱动的 ISSA-VMD DAS 信号去噪方法

3.1. 方法总体流程

针对传统 VMD 参数依赖经验选取以及单一评价指标难以准确反映信号分解质量的问题，本文提出一种联合熵驱动的改进麻雀搜索优化变分模态分解(EE-PE-ISSA-VMD) DAS 信号去噪方法。

本文所提 EE-PE-ISSA-VMD 方法的总体流程如图 1 所示。

该方法以 VMD 中的模态数 K 和惩罚因子 α 作为优化对象，通过改进 SSA 实现参数自适应寻优，并结合 EE-PE 联合适应度函数评价参数组合优劣。同时，为进一步提高重构质量，采用相关系数对 VMD 分解得到的 IMF 分量进行筛选，实现有效信号保留和噪声抑制。




Figure 1. Overall flowchart of the proposed method

图 1. 本文方法总体流程图

3.2. 改进麻雀搜索算法

SSA 是一种模拟麻雀觅食行为的群智能优化算法，具有结构简单、参数少以及收敛速度快等优点。

然而传统 SSA 仍存在种群初始化随机性较强、后期搜索能力下降以及容易陷入局部最优等问题。

为提高参数寻优能力, 本文从种群初始化、发现者比例和搜索步长三个方面进行改进。

3.2.1. Tent 混沌初始化

传统 SSA 采用随机方式初始化种群, 容易造成个体分布不均匀。为提高种群多样性, 本文采用 Tent 混沌映射进行初始化[22]。

$$\text{Tent 映射表达式为: } z_{n+1} = \begin{cases} 2z_n, & 0 \leq z_n < 0.5 \\ 2(1-z_n), & 0.5 \leq z_n \leq 1 \end{cases} \quad (3-1)$$

$$\text{利用生成的混沌序列映射至参数空间: } X_{i,j} = lb_j + z_{i,j}(ub_j - lb_j) \quad (3-2)$$

其中: lb_j 为下界; ub_j 为上界; $X_{i,j}$ 为第 i 个个体的第 j 维参数。

通过 Tent 映射能够提高初始种群覆盖范围, 增强算法全局搜索能力。

3.2.2. 自适应发现者比例策略

传统 SSA 中发现者比例固定。然而优化初期需要较强探索能力, 而后期更需要局部开发能力。因此设计自适应发现者比例:

$$PD(t) = PD_{\min} + (PD_{\max} - PD_{\min}) \left[1 - \left(\frac{t}{T} \right)^2 \right] \quad (3-3)$$

其中: $PD_{\max} = 0.30$, $PD_{\min} = 0.10$ 随着迭代进行, 发现者数量逐渐减少, 实现搜索重心由全局探索向局部开发转变。

3.2.3. 自适应步长策略

为了避免算法后期震荡, 本文设计自适应步长因子:

$$w(t) = w_{\min} + (w_{\max} - w_{\min}) \left(1 - \frac{t}{T} \right)^2 \quad (3-4)$$

其中: $w_{\max} = 0.8$, $w_{\min} = 0.1$ 。

在迭代前期采用较大步长进行全局搜索, 在后期逐渐减小步长以提高收敛精度。

3.3. EE-PE 联合适应度函数

适应度函数决定了参数优化方向。传统研究大多采用包络熵(EE)作为评价指标[23]。

包络熵定义为:

$$EE = - \sum_{i=1}^N p_i \ln p_i \quad (3-5)$$

其中: $p_i = \frac{a_i}{\sum_{i=1}^N a_i}$, a_i 为 Hilbert 包络幅值。包络熵越小, 表示能量分布越集中。然而 EE 仅反映能量特征。

为了进一步描述信号复杂度, 引入排列熵(PE)。排列熵定义为[24]:

$$PE = - \sum_{j=1}^{m!} P_j \ln P_j \quad (3-6)$$

其中: P_j 为不同排列模式概率, m 为嵌入维数。PE 越小, 说明序列规律性越强。

因此构建联合适应度函数:

$$\text{Fitness} = \lambda \text{EE} + (1 - \lambda) \text{PE} \quad (3-7)$$

其中： $\lambda = 0.7$ ，适应度越小表示 VMD 分解效果越优。

3.4. 基于相关系数的 IMF 筛选重构

VMD 分解后得到多个 IMF 分量。若直接重构全部 IMF，容易引入噪声成分。因此采用相关系数进行筛选。

设：原始信号为 $x(t)$ ，第 i 个 IMF 为 $u_i(t)$ 。

相关系数定义为：

$$r_i = \frac{\sum_{t=1}^N (u_i - \bar{u}_i)(x - \bar{x})}{\sqrt{\sum_{t=1}^N (u_i - \bar{u}_i)^2} \sqrt{\sum_{t=1}^N (x - \bar{x})^2}} \quad (3-8)$$

计算所有 IMF 相关系数后，以平均值作为阈值，满足条件 $r_i > \bar{r}$ 的 IMF 参与重构。最终信号表示为： $\hat{x}(t) = \sum_{i \in S} u_i(t)$ 其中 S 为保留 IMF 集合。

3.5. 本文算法流程

综合 Tent 混沌初始化、自适应发现者比例、自适应步长策略、EE-PE 联合适应度函数以及相关系数筛选重构机制，本文提出的 EE-PE-ISSA-VMD 算法总体流程如下。首先构建含噪 DAS 信号，并采用 Tent 混沌映射初始化麻雀种群；其次，以模态数 K 和惩罚因子 α 作为优化变量，利用 EE-PE 联合适应度函数评价个体优劣，通过改进麻雀搜索算法实现 VMD 参数自适应优化；随后采用最优参数对信号进行 VMD 分解，并计算各 IMF 分量与原始信号之间的相关系数，根据筛选阈值选取有效 IMF 进行重构；最终获得去噪后的 DAS 信号。算法具体流程如表 1 所示。

Table 1. Algorithm flow of the proposed method

表 1. 本文算法流程

项目	内容
输入(Input)	含噪 DAS 信号 $x(t)$ 、参数范围 K 、 α 、种群规模 N 、最大迭代次数 T
输出(Output)	去噪后信号 $\hat{x}(t)$
Step 1	输入含噪 DAS 信号，设置 VMD 参数搜索范围。
Step 2	采用 Tent 混沌映射初始化 SSA 种群。
Step 3	设置发现者比例、自适应步长等参数。
Step 4	将个体参数映射为 VMD 参数(K, α)，执行 VMD 分解。
Step 5	计算 EE 和 PE，构建联合适应度函数 $\text{Fitness} = \lambda \text{EE} + (1 - \lambda) \text{PE}$ 。
Step 6	根据适应度更新 SSA 种群，迭代搜索最优参数(K^*, α^*)。
Step 7	利用最优参数重新进行 VMD 分解，得到各 IMF 分量。
Step 8	计算各 IMF 与原始信号相关系数，筛选有效 IMF。
Step 9	重构信号，输出最终去噪结果。

4. 实验与结果分析

4.1. 实验平台与评价指标

为验证所提 EE-PE-ISSA-VMD 算法的有效性，本文在 MATLAB R2016b 平台完成算法实现与实验验

证。实验过程中，将本文方法与小波阈值去噪、传统 VMD、SSA-VMD 以及 ISSA-VMD 方法进行对比分析，并采用统一的模拟 DAS 振动信号作为测试对象。

采用信噪比(Signal-to-Noise Ratio, SNR)和均方根误差(Root Mean Square Error, RMSE)作为性能评价指标，同时利用包络熵(Envelope Entropy, EE)和排列熵(Permutation Entropy, PE)构建联合适应度函数，对 VMD 分解质量进行综合评价。

4.1.1. 仿真信号构建

为验证所提方法的有效性，本文并非直接使用 PubDAS 真实数据进行实验，而是参考公开 DAS 数据集 PubDAS 中典型振动信号的时域波形及相关文献报道的信号特征，在 MATLAB 平台构建模拟 DAS 振动信号[4] [10]-[16]。模拟信号由多个不同频率的振动分量叠加构成，其表达式为：

$$s(t) = \sum A_i \sin(2\pi f_i t + \varphi_i)$$

在原始模拟信号基础上叠加高斯白噪声，得到含噪 DAS 信号：

$$x(t) = s(t) + n(t)$$

其中， $s(t)$ 为原始模拟 DAS 振动信号， $n(t)$ 为高斯白噪声， $x(t)$ 为含噪信号。本文实验信号采样点数为 5001，噪声类型为高斯白噪声，初始含噪信号 SNR 为 1.8543 dB，RMSE 为 0.7852。通过该方式构建的模拟信号能够反映 DAS 振动信号的非平稳性和噪声干扰特征，为不同去噪算法性能对比提供统一实验条件。

4.1.2. 实验参数与评价指标

VMD 参数搜索范围为 $3 \leq K \leq 10$ ， $500 \leq \alpha \leq 5000$ 。

ISSA 参数如下：

Table 2. Parameter settings of ISSA

表 2. ISSA 参数设置

参数	取值	设置依据
K	3~10	参考 VMD 常用参数范围，避免欠分解和过分解
α	500~5000	覆盖 VMD 常用惩罚因子范围
种群规模	20	兼顾优化精度与计算效率
最大迭代次数	30	根据收敛曲线确定
发现者比例	自适应	本文改进策略
步长因子	自适应	本文改进策略

由表 2 可知，本文在给定范围内搜索 VMD 模态数 K 和惩罚因子 α ，并设置种群规模、最大迭代次数、发现者比例和步长因子等 ISSA 参数。评价指标采用信噪比(SNR)和均方根误差(RMSE)，其中 SNR 越大表示去噪效果越好，RMSE 越小表示重构信号与原始信号越接近。

4.2. SSA 与 ISSA 参数优化结果对比

为验证改进麻雀搜索算法(ISSA)在 VMD 参数优化中的应用效果，分别采用传统 SSA 和 ISSA 对模态数 K 和惩罚因子 α 进行优化。图 2 给出了两种算法的收敛曲线，表 3 列出了对应优化结果。




Figure 2. Convergence curves of SSA and ISSA

图 2. SSA 与 ISSA 收敛曲线

Table 3. SSA and ISSA parameter optimization results

表 3. SSA 与 ISSA 参数优化结果

算法	K	α	Fitness
SSA	7	500	6.0541
ISSA	7	508.48	6.0541

由图 2 可以看出, SSA 与 ISSA 均能够在有限迭代次数内完成参数优化任务, 并获得较为稳定的收敛结果。由表 3 可知, SSA 获得的最优参数为 $K = 7$ 、 $\alpha = 500$, 对应适应度值为 6.0541; ISSA 获得的最优参数为 $K = 7$ 、 $\alpha = 508.48$, 对应适应度值同样为 6.0541, 两者最终适应度接近。

因此, 在本组实验条件下, ISSA 并未表现为最终适应度值上的显著优势, 其改进意义主要体现在通过 Tent 混沌初始化、自适应发现者比例以及自适应步长策略提高种群多样性和搜索稳定性, 从而为后续 VMD 参数优化提供可靠基础。

4.3. EE-PE 联合适应度函数有效性验证

为验证联合适应度函数有效性, 分别采用 EE 和 EE+PE 进行参数优化。

Table 4. Comparison of EE and EE-PE fitness functions

表 4. EE 与 EE-PE 适应度函数比较

方法	K	α	SNR/dB	RMSE
EE	7	500	9.7632	0.3159
EE+PE	10	646	10.2629	0.2982

为进一步直观展示不同适应度函数对参数优化结果的影响, 根据表 4 中的实验结果绘制 EE 与 EE-PE 联合适应度函数性能对比图, 如图 3 所示。




Figure 3. Comparison of EE and EE-PE fitness functions
图 3. EE 与 EE-PE 适应度函数对比

由图 3 可以看出，采用 EE-PE 联合适应度函数后，优化所得信号的 SNR 明显高于单一 EE 适应度函数，而 RMSE 进一步降低。相比单一包络熵评价方式，联合熵评价策略同时考虑信号能量分布特征和时间序列复杂度特征，能够更加全面地表征 VMD 分解质量，从而获得更加合理的参数组合。

由表 4 可知，EE-PE 联合适应度函数在信噪比和均方根误差两个指标上均优于单一 EE 适应度函数，说明联合熵评价策略能够从能量分布和序列复杂度两个角度综合评价分解结果，从而提高参数寻优质量。

4.4. IMF 筛选有效性验证




Figure 4. Correlation coefficients of IMF components
图 4. IMF 相关系数分布图

为验证相关系数筛选重构策略的有效性, 计算各 IMF 分量与原始信号之间的相关系数, 并以平均相关系数作为筛选阈值, 结果如图 4 所示。

由图 4 可以看出, 不同 IMF 分量与原始信号之间的相关性存在明显差异。其中, IMF1 和 IMF2 的相关系数分别为 0.7325 和 0.4822, 均高于平均阈值 0.3186, 表明其包含较多有效振动特征信息; 其余 IMF 分量的相关系数均低于阈值, 主要反映随机噪声成分。

因此, 本文保留 IMF1 和 IMF2 参与信号重构, 其余模态予以剔除。采用筛选后的 IMF 进行重构后, 信号的 SNR 提高至 10.2629 dB, RMSE 降低至 0.2982。相比未筛选重构结果, 降噪性能得到进一步提升, 说明相关系数筛选策略能够有效减少噪声模态对重构结果的影响, 提高信号重构质量和特征保留能力。

Table 5. Verification of IMF screening

表 5. IMF 筛选有效性验证

T 方法	参数	重构方式	SNR/dB	RMSE
EE+PE-VMD	$K = 10, \alpha = 646$	全部 IMF 直接重构	2.3890	0.7383
EE+PE-VMD	$K = 10, \alpha = 646$	相关系数筛选 IMF 重构	10.2629	0.2982

由表 5 可知, 采用相关系数筛选后的重构结果在 SNR 和 RMSE 指标上均优于全部 IMF 直接重构结果, 说明该策略能够有效抑制噪声模态干扰, 提高信号重构质量和特征保留能力。

4.5. 不同方法去噪性能对比

为进一步验证本文方法的去噪性能, 选取小波阈值去噪(Wavelet Threshold Denoising)、传统 VMD、SSA-VMD、ISSA-VMD 以及本文提出的 EE-PE-ISSA-VMD 方法进行对比实验。采用信噪比(SNR)和均方根误差(RMSE)作为评价指标, 其中 SNR 越大表示去噪效果越好, RMSE 越小表示重构信号与原始信号越接近。

表 6 给出了不同方法的去噪性能对比结果。

Table 6. Comparison of denoising performance of different methods

表 6. 不同方法去噪性能比较

方法	SNR/dB	RMSE
含噪信号	1.8543	0.7852
小波阈值去噪	4.9587	0.5492
VMD	9.4931	0.3258
SSA-VMD	9.7632	0.3159
ISSA-VMD	9.7812	0.3152
本文方法	10.2629	0.2982

由表 6 可以看出, 各种去噪方法均能够在不同程度上提高信号质量。其中, 小波阈值去噪方法能够有效抑制部分随机噪声, 但仍存在较明显的特征信息损失, 其 SNR 仅提高至 4.9587 dB。相比之下, 基于 VMD 的方法表现出更好的频谱分离能力, 传统 VMD 的 SNR 提高至 9.4931 dB, RMSE 降低至 0.3258。

在引入 SSA 和 ISSA 进行参数优化后, VMD 去噪性能得到进一步提升。其中 SSA-VMD 和 ISSA-VMD 分别获得 9.7632 dB 和 9.7812 dB 的信噪比, 说明智能优化算法能够有效提高 VMD 参数选择的合理性, 从而改善信号分解效果。

本文提出的 EE-PE-ISSA-VMD 方法取得了较好的去噪效果, 其 SNR 达到 10.2629 dB, RMSE 降低至 0.2982。与传统 VMD 相比, 信噪比提高约 8.11%, 均方根误差降低约 8.47%; 与 ISSA-VMD 相比, 信噪比进一步提高 0.4817 dB, 均方根误差降低 0.0170。结果表明, EE-PE 联合适应度函数能够更充分地评价 VMD 分解质量, 相关系数筛选重构策略能够有效抑制噪声模态影响, 两者共同作用提升了本文方法的去噪性能。

综上所述, 在本文构建的模拟 DAS 信号实验条件下, 所提 EE-PE-ISSA-VMD 去噪模型在信号特征保留和噪声抑制方面取得了较好的综合表现。

4.6. 时频域结果分析

为进一步验证所提 EE-PE-ISSA-VMD 方法对 DAS 信号的降噪性能, 从时域和频域两个角度对处理结果进行分析, 结果如图 5~7 所示。




Figure 5. Comparison of DAS signal time-domain waveforms
图 5. DAS 信号时域波形对比




Figure 6. Enlarged local time-domain waveforms of DAS signals
图 6. DAS 信号局部放大图

由图 5 可知, 含噪信号受到随机噪声干扰, 波形中存在较明显的高频波动和随机扰动, 导致部分有效振动特征被噪声淹没。经过本文方法处理后, 信号整体波形更加平滑, 随机波动明显减弱, 同时能够较好地保持原始信号的整体变化趋势, 说明 EE-PE-ISSA-VMD 方法在实现噪声抑制的同时, 能够有效保留 DAS 振动信号中的主要特征信息。

为了进一步考察局部区域内的特征恢复能力, 对 1000~1300 采样点区间进行局部放大分析, 结果如图 6 所示。由图 6 可知, 含噪信号在局部区域内存在较明显的随机偏移和振幅波动, 而本文方法处理后的波形与原始信号更加接近, 在峰值位置、波谷位置以及信号变化趋势等方面均保持了较高一致性, 表明所提方法能够降低噪声干扰并提高有效振动信息的保留能力。




Figure 7. Comparison of DAS signal spectra
图 7. DAS 信号频谱对比

由图 7 可知, 原始信号的主要能量集中在低频特征频段, 而含噪信号由于叠加随机噪声, 在较宽频率范围内均表现出较高的频谱幅值, 导致频谱结构受到明显污染。经本文方法处理后, 主要特征频率成分得到有效保留, 非特征频段的噪声能量明显降低, 频谱分布更加接近原始信号, 说明 EE-PE-ISSA-VMD 方法能够有效抑制噪声频率成分, 同时保持原始信号的主要频谱结构。

结合表 6 中的定量评价结果可以进一步发现, 本文方法获得了最高的信噪比和最低的均方根误差。其中 SNR 达到 10.2629 dB, RMSE 降低至 0.2982, 均优于小波阈值去噪、传统 VMD、SSA-VMD 以及 ISSA-VMD 方法。综合时域波形、局部放大结果及频谱分析可知, 所提 EE-PE-ISSA-VMD 方法能够在有效抑制噪声干扰的同时最大程度保留原始振动特征, 实现 DAS 信号的高质量重构, 从而验证了本文方法在 DAS 信号去噪中的有效性和优越性。

4.7. 结果讨论

实验结果表明, 本文提出的 EE-PE-ISSA-VMD 方法能够有效提高 DAS 信号去噪性能, 其性能提升主要来源于以下三个方面。

首先, Tent 混沌初始化、自适应发现者比例以及自适应步长策略提高了 SSA 种群多样性和搜索稳定性, 使优化算法能够为 VMD 参数寻优提供较可靠的搜索基础。

其次, EE-PE 联合适应度函数同时考虑信号能量分布特征和时间序列复杂度特征, 克服了单一包络

熵评价指标信息不足的问题。实验结果表明,引入排列熵后,最优参数由 $K=7$ 、 $\alpha=500$ 调整为 $K=10$ 、 $\alpha=646$,信噪比提高 0.4997 dB,均方根误差降低 0.0177,验证了联合评价策略的有效性。

最后,相关系数筛选重构策略能够有效识别与原始信号相关性较高的 IMF 分量,抑制噪声模态对重构结果的影响。实验结果显示,经过相关系数筛选后,信噪比由 2.3890 dB 提高至 10.2629 dB,均方根误差由 0.7383 降低至 0.2982,说明该策略能够显著提高信号重构质量。

综合来看,参数优化、联合熵评价以及 IMF 筛选策略具有协同作用,是本文方法性能提升的主要原因。

5. 结论

针对分布式光纤声波传感(Distributed Acoustic Sensing, DAS)信号易受噪声干扰、传统变分模态分解(VMD)参数依赖经验选取以及单一评价指标难以准确反映分解质量的问题,本文提出了一种联合熵驱动的改进麻雀搜索优化变分模态分解(EE-PE-ISSA-VMD) DAS 信号去噪方法。通过引入 Tent 混沌初始化、自适应发现者比例和自适应步长策略,对传统麻雀搜索算法进行改进,实现 VMD 参数的自适应优化;同时构建包络熵与排列熵联合适应度函数,从信号能量分布和复杂度两个维度评价 VMD 分解质量;并结合基于相关系数的 IMF 筛选重构策略,提高信号重构精度和噪声抑制能力。

通过仿真 DAS 振动信号开展实验研究,得到如下结论:

(1) 改进麻雀搜索算法通过增强种群多样性和优化搜索机制,提高了参数寻优的稳定性和全局搜索能力,能够获得更加合理的 VMD 参数组合。

(2) EE-PE 联合适应度函数同时考虑信号能量分布特征和时间序列复杂度特征,相较于单一包络熵评价指标能够更加全面地反映 VMD 分解质量,从而提升参数优化效果。

(3) 基于相关系数的 IMF 筛选重构策略能够有效抑制噪声模态对重构结果的影响,提高信号重构质量和特征保留能力。

(4) 与小波阈值去噪、传统 VMD、SSA-VMD 及 ISSA-VMD 方法相比,本文提出的 EE-PE-ISSA-VMD 方法获得了更优的去噪性能。其中最优参数组合为 $K=10$ 、 $\alpha=646$,信噪比达到 10.2629 dB,均方根误差降低至 0.2982,验证了所提方法在 DAS 信号去噪中的有效性和优越性。

综上所述,本文提出的 EE-PE-ISSA-VMD 方法能够有效提高 DAS 信号的信噪比和重构精度,在保留有效振动特征的同时实现噪声抑制,为分布式光纤振动信号处理提供了一种新的技术思路和实现方法。本文实验主要基于参考公开 DAS 数据特征构建的模拟信号开展验证,后续将进一步结合 PubDAS 等公开真实 DAS 数据集以及实验室实际采集数据开展实验,以进一步评估算法在复杂工程环境中的泛化能力和工程应用价值。

参考文献

- [1] 饶云江. 长距离分布式光纤传感技术研究进展[J]. 物理学报, 2017, 66(7): 139-135.
- [2] 马皓钰, 王夏霄, 马福, 等. Φ -OTDR 型分布式光纤声波传感器研究进展[J]. 激光与光电子学进展, 2020, 57(13): 58-72.
- [3] 孙琪真, 王一帆, 刘国军, 等. 光纤分布式声波传感技术在石油行业的研究进展[J]. 石油物探, 2022, 61(1): 50-59, 77.
- [4] Spica, Z.J., Ajo-Franklin, J., Beroza, G.C., Biondi, B., Cheng, F., Gaithe, B., et al. (2023) PubDAS: A Public Distributed Acoustic Sensing Datasets Repository for Geosciences. *Seismological Research Letters*, **94**, 983-998. <https://doi.org/10.1785/0220220279>
- [5] Hartog, A.H. (2017) An Introduction to Distributed Optical Fibre Sensors. CRC Press.

- [6] Mallat, S. (2008) A Wavelet Tour of Signal Processing. 3rd Edition, Academic Press.
- [7] Huang, N.E., Shen, Z., Long, S.R., Wu, M.C., Shih, H.H., Zheng, Q., *et al.* (1998) The Empirical Mode Decomposition and the Hilbert Spectrum for Nonlinear and Non-Stationary Time Series Analysis. *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, **454**, 903-995. <https://doi.org/10.1098/rspa.1998.0193>
- [8] Wu, Z. and Huang, N.E. (2009) Ensemble Empirical Mode Decomposition: A Noise-Assisted Data Analysis Method. *Advances in Adaptive Data Analysis*, **1**, 1-41. <https://doi.org/10.1142/s1793536909000047>
- [9] Dragomiretskiy, K. and Zosso, D. (2014) Variational Mode Decomposition. *IEEE Transactions on Signal Processing*, **62**, 531-544. <https://doi.org/10.1109/tsp.2013.2288675>
- [10] Liu, W., Liu, Y., Li, S. and Chen, Y. (2023) A Review of Variational Mode Decomposition in Seismic Data Analysis. *Surveys in Geophysics*, **44**, 323-355. <https://doi.org/10.1007/s10712-022-09742-z>
- [11] Rehman, N.U. and Aftab, H. (2019) Multivariate Variational Mode Decomposition. *IEEE Transactions on Signal Processing*, **67**, 6039-6052. <https://doi.org/10.1109/tsp.2019.2951223>
- [12] Zhang, X., Chen, Y., Jia, R. and Lu, X. (2022) Two-Dimensional Variational Mode Decomposition for Seismic Record Denoising. *Journal of Geophysics and Engineering*, **19**, 433-444. <https://doi.org/10.1093/jge/gxac032>
- [13] Jing, G., Zhao, Y., Gao, Y., Marin Montanari, P. and Lacidogna, G. (2023) Noise Reduction Based on Improved Variational Mode Decomposition for Acoustic Emission Signal of Coal Failure. *Applied Sciences*, **13**, Article 9140. <https://doi.org/10.3390/app13169140>
- [14] Yao, Z., Li, W., Zhu, J., Hao, L. and Xing, M. (2025) Seismic Random Noise Separation and Suppression Based on Improved Variational Mode Decomposition via Grey Wolf Optimization. *PLOS One*, **20**, e0330988. <https://doi.org/10.1371/journal.pone.0330988>
- [15] Sun, H., Ren, H.Y., Chen, R., Huang, X.G., Zhang, W., Li, Y., *et al.* (2025) Improved PSO-VMD Seismic Signal Denoising Method Combined with Modified Wavelet Transform. *Applied Geophysics*. <https://doi.org/10.1007/s11770-025-1289-6>
- [16] Zhang, S., Zhang, L. and Qin, X. (2025) Seismic Signal Denoising Using Variational Mode Decomposition and a Denoising Convolutional Neural Network. *Journal of Seismic Exploration*, **34**, 44-59. <https://doi.org/10.36922/jse025260030>
- [17] Xue, J. and Shen, B. (2020) A Novel Swarm Intelligence Optimization Approach: Sparrow Search Algorithm. *Systems Science & Control Engineering*, **8**, 22-34. <https://doi.org/10.1080/21642583.2019.1708830>
- [18] Du, H., Wang, J., Qian, W. and Zhang, X. (2024) An Improved Sparrow Search Algorithm for the Optimization of Variational Modal Decomposition Parameters. *Applied Sciences*, **14**, Article 2174. <https://doi.org/10.3390/app14052174>
- [19] Wang, B., Tang, H., Zu, X. and Chen, P. (2024) Adaptive Feature Extraction Using Sparrow Search Algorithm-Variational Mode Decomposition for Low-Speed Bearing Fault Diagnosis. *Sensors*, **24**, Article 6801. <https://doi.org/10.3390/s24216801>
- [20] 刘建昌, 于晓洋, 高强, 等. 基于参数优化 VMD 和样本熵的滚动轴承故障诊断[J]. 自动化学报, 2022, 48(9): 2221-2232.
- [21] 杨厚明, 张勤, 黄观文, 等. SSA-VMD 与小波分解结合的 GNSS 坐标时序降噪方法[J]. 大地测量与地球动力学, 2024, 44(3): 319-325.
- [22] Wang, Y., Zhang, X., Yu, D., Bai, Y., Du, J. and Tian, Z. (2022) Tent Chaotic Map and Population Classification Evolution Strategy-Based Dragonfly Algorithm for Global Optimization. *Mathematical Problems in Engineering*, **2022**, 1-18. <https://doi.org/10.1155/2022/2508414>
- [23] Ding, J., Huang, L., Xiao, D. and Li, X. (2020) GMPSO-VMD Algorithm and Its Application to Rolling Bearing Fault Feature Extraction. *Sensors*, **20**, Article 1946. <https://doi.org/10.3390/s20071946>
- [24] Bandt, C. and Pompe, B. (2002) Permutation Entropy: A Natural Complexity Measure for Time Series. *Physical Review Letters*, **88**, Article 174102. <https://doi.org/10.1103/physrevlett.88.174102>