



## 基于事件触发的全信息粒子群优化器及其应用

王闯 韩非 申雨轩 李学贵 董宏丽

### Full-information Particle Swarm Optimizer Based on Event-triggering Strategy and Its Applications

WANG Chuang, HAN Fei, SHEN Yu-Xuan, LI Xue-Gui, DONG Hong-Li

在线阅读 View online: <https://doi.org/10.16383/j.aas.c200621>

---

## 您可能感兴趣的其他文章

### 基于异步动态事件触发通信策略的综合能源系统分布式协同优化运行方法

Distributed Collaborative Optimization Operation Approach for Integrated Energy System Based on Asynchronous and Dynamic Event-Triggering Communication Strategy

自动化学报. 2020, 46(9): 1831–1843 <https://doi.org/10.16383/j.aas.c200172>

### 一种求解符号回归问题的粒子群优化算法

A Particle Swarm Optimization Approach for Symbolic Regression

自动化学报. 2020, 46(8): 1714–1726 <https://doi.org/10.16383/j.aas.c180035>

### 基于透镜成像学习策略的灰狼优化算法

Grey Wolf Optimizer Algorithm Based on Lens Imaging Learning Strategy

自动化学报. 2020, 46(10): 2148–2164 <https://doi.org/10.16383/j.aas.c180695>

### 基于Word2vec和粒子群的链路预测算法

Link Prediction Algorithm Based on Word2vec and Particle Swarm

自动化学报. 2020, 46(8): 1703–1713 <https://doi.org/10.16383/j.aas.c180187>

### 基于变换函数与填充函数的模糊粒子群优化算法

Fuzzy Partical Swarm Optimization Based on Filled Function and Transformation Function

自动化学报. 2018, 44(1): 74–86 <https://doi.org/10.16383/j.aas.2018.c160547>

### 一种基于自适应模糊支配的高维多目标粒子群算法

Many-objective Particle Swarm Optimization Based on Adaptive Fuzzy Dominance

自动化学报. 2018, 44(12): 2278–2289 <https://doi.org/10.16383/j.aas.2018.c170573>

# 基于事件触发的全信息粒子群优化器及其应用

王闯<sup>1,2</sup> 韩非<sup>1,2</sup> 申雨轩<sup>1,2</sup> 李学贵<sup>1,3</sup> 董宏丽<sup>1,2</sup>

**摘要** 针对标准粒子群优化算法存在早熟收敛和容易陷入局部最优的问题, 本文提出了一种基于事件触发的全信息粒子群优化算法 (Event-triggering-based full-information particle swarm optimization, EFPSO). 首先, 引入一类基于粒子空间特性的事件触发策略实现粒子群优化算法 (Particle swarm optimization, PSO) 的模式切换, 更好地维持了算法搜索和收敛能力之间的动态平衡. 然后, 鉴于引入历史信息能够降低算法陷入局部最优的可能性, 提出一种全信息策略来克服 PSO 算法搜索能力不足的缺陷. 数值仿真实验表明, EFPSO 算法在种群多样性、收敛率、成功率方面优于其他改进的 PSO 算法. 最后, 应用 EFPSO 算法对变分模式分解 (Variational mode decomposition, VMD) 去噪算法进行改进, 并在现场管道信号去噪取得了很好的效果.

**关键词** 粒子群优化器, 事件触发策略, 全信息策略, 去噪算法, 变分模式分解

**引用格式** 王闯, 韩非, 申雨轩, 李学贵, 董宏丽. 基于事件触发的全信息粒子群优化器及其应用. 自动化学报, 2023, 49(4): 891–903

**DOI** 10.16383/j.aas.c200621

## Full-information Particle Swarm Optimizer Based on Event-triggering Strategy and Its Applications

WANG Chuang<sup>1,2</sup> HAN Fei<sup>1,2</sup> SHEN Yu-Xuan<sup>1,2</sup> LI Xue-Gui<sup>1,3</sup> DONG Hong-Li<sup>1,2</sup>

**Abstract** In this paper, an event-triggering-based full-information particle swarm optimization algorithm (EFPSO) is proposed with the purpose of decreasing the possibility of premature convergence and local optimization. First of all, an event-triggering strategy is employed to achieve the mode switching of the particle swarm optimization (PSO) algorithms in terms of the spatial properties of the particles, which better maintains a dynamic balance between the convergence and population diversity. Next, a full-information strategy is introduced to overcome the defect, i.e., the poor exploration ability of the PSO algorithm, where the historical information is considered to reduce the possibility of falling into the local optimum. Experiment results demonstrate the superiority of the proposed EFPSO algorithm over existing popular PSO algorithms in terms of population diversity, convergence rate, and success ratio. Finally, an EFPSO-optimized variational mode decomposition (VMD) denoising algorithm is designed and applied successfully in the field pipeline signal denoising.

**Key words** Particle swarm optimizer (PSO), event-triggering strategy, full-information strategy, denoising algorithm, variational mode decomposition (VMD)

**Citation** Wang Chuang, Han Fei, Shen Yu-Xuan, Li Xue-Gui, Dong Hong-Li. Full-information particle swarm optimizer based on event-triggering strategy and its applications. *Acta Automatica Sinica*, 2023, 49(4): 891–903

收稿日期 2020-08-05 录用日期 2020-12-01

Manuscript received August 5, 2020; accepted December 1, 2020

国家自然科学基金 (U21A2019, 61873058, 61933007, 62073070), 海南省科技专项基金 (ZDYF2022SHFZ105), 黑龙江省省属高校基本科研业务费 (2022TSTD-04) 资助

Supported by National Natural Science Foundation of China (U21A2019, 61873058, 61933007, 62073070), Hainan Province Science and Technology Special Fund (ZDYF2022SHFZ105), and Heilongjiang Provincial Universities Basic Research Operation Fee (2022TSTD-04)

本文责任编辑 倪茂林

Recommended by Associate Editor NI Mao-Lin

1. 东北石油大学人工智能能源研究院 大庆 163318 2. 黑龙江省网络化与智能控制重点实验室 大庆 163318 3. 东北石油大学计算机与信息技术学院 大庆 163318

1. Artificial Intelligence Energy Research Institute, Northeast Petroleum University, Daqing 163318 2. Heilongjiang Provincial Key Laboratory of Networking and Intelligent Control, Northeast Petroleum University, Daqing 163318 3. School of Computer and Information Technology, Northeast Petroleum University, Daqing 163318

近年来, 优化问题得到了学术界的广泛关注, 学者们先后提出了一系列进化算法及其变体 (遗传算法、蚁群算法、粒子群优化算法等). 其中, 粒子群优化算法 (Particle swarm optimization, PSO) 具有参数简单、容易执行等优点, 现在已经成为解决优化问题的有力工具<sup>[1]</sup>. PSO 算法已经广泛应用于许多实际问题, 如参数优化、神经网络训练、聚类分析、组合优化等. 然而, PSO 算法与其他群智能算法一样存在着早熟收敛和容易陷入局部最优的问题. 为了解决这一问题, 许多专家学者先后提出了多种改进的 PSO 算法, 大致可以分为以下 4 类: 1) 参数控制; 2) 引入新的策略; 3) 改变种群拓扑结构; 4) 融合其他算法.

惯性权重 ( $\omega$ ) 是影响 PSO 算法搜索性能的一

个重要参数<sup>[2]</sup>, 如何控制惯性权重成为改进 PSO 算法的一个重要方向. Shi 等<sup>[3]</sup> 首次研究了惯性权重对搜索性能的影响, 指出较大的惯性权重有利于进行全局搜索, 而较小的惯性权重有利于局部搜索. 因此, Shi 等<sup>[3]</sup> 提出了一个线性递减策略的改进 PSO 算法. 随后出现了各种惯性权重变体 (分段函数、非线性函数等) 和时变的加速因子<sup>[4-5]</sup>. 可以引入新的策略来提升 PSO 算法的寻优能力, 例如: 变异策略<sup>[6]</sup>、混沌策略<sup>[7]</sup> 等. 也可以从拓扑结构的角度对 PSO 算法进行改进, 例如: 静态拓扑结构<sup>[8]</sup>、动态拓扑结构<sup>[9-11]</sup> 等. 最近, 采用优势互补的思想, 融合其他算法成为了改进 PSO 算法的研究热点, 例如: 遗传-粒子群优化算法<sup>[12]</sup>、模拟退火-粒子群优化算法<sup>[13]</sup> 等.

引入一定历史信息 (即粒子前  $k-1$  时刻的位置信息  $\{\mathbf{x}_i(1), \mathbf{x}_i(2), \dots, \mathbf{x}_i(k-1)\}$ ) 既有助于粒子对整个空间进行彻底搜索, 又避免了粒子搜索的盲目性, 因此增加了粒子跳出局部最优解的可能性. 文献 [14-16] 通过引入时滞来提升 PSO 算法的性能. 然而, 这可能会面临以下两个不足: 1) 时滞引入的是某个特定时刻的历史信息, 如果这个信息选择不恰当, 可能会导致粒子陷入局部最优; 2) 时滞的发生时刻是随机的, 这可能会导致粒子陷入局部最优<sup>[16]</sup>. 为解决上述问题, 本文引入了全信息策略和事件触发策略. 全信息策略采用过去时刻所有信息的平均值, 这样可以更好地指导粒子收敛于全局最优解, 解决了问题 1); 事件触发策略根据粒子的种群空间特性 (即种群多样性) 来动态调整历史信息的发生与否, 解决了问题 2).

本文针对 PSO 算法容易陷入局部最优和早熟收敛的问题, 提出了一种基于事件触发的全信息粒子群优化算法 (Event-triggering-based full-information particle swarm optimization, EFPSO). 本文的主要贡献总结如下: 1) 事件触发策略的引入保证了 PSO 算法在种群多样性和收敛性之间的动态平衡, 即, 根据粒子的空间特性选择事件触发函数, 有效地保证了在搜索阶段, 粒子高度分散能够彻底探索整个空间, 同时在收敛阶段, 所有粒子朝着最优粒子移动, 最终收敛到全局最优位置; 2) 在粒子速度更新模型中, 考虑了过去所有信息对当前位置的影响, 增加了两个全信息项, 使得粒子在寻优过程中参考了更多的历史信息, 从而增加了粒子跳出局部最优的机会; 3) 通过对比一些经典 PSO 算法, 从种群多样性、收敛率、成功率等多个角度验证了 EFPSO 算法的优越性; 4) 考虑到油田管道泄漏检测系统收集到的数据中存在大量噪声容易导致漏报、误报等进而造成油田事故, 本文提出了一种基于 EFPSO 优化的变分模态分解 (Variational mode

decomposition, VMD)<sup>[17]</sup> 去噪算法, 成功解决了管道数据去噪问题, 进一步验证了本文提出算法的有效性和实用性.

## 1 粒子群优化算法

### 1.1 标准 PSO 算法

粒子群优化算法 (PSO)<sup>[18]</sup> 是一种仿生的启发式进化算法. 群体中的粒子模拟鸟群、鱼群的觅食行为, 通过自身学习和信息交换来不断调整搜索策略, 最终实现群体趋于最优位置. 在 PSO 算法中, 把每个粒子看作优化问题的一个候选解. 考虑一个  $D$  维搜索空间中有  $m$  个粒子, 第  $i$  个粒子的速度和位置分别可以表示为  $\mathbf{v}_i(k) = (\mathbf{v}_{i1}(k), \mathbf{v}_{i2}(k), \dots, \mathbf{v}_{iD}(k))$  和  $\mathbf{x}_i(k) = (\mathbf{x}_{i1}(k), \mathbf{x}_{i2}(k), \dots, \mathbf{x}_{iD}(k))$ . 在迭代过程中, 每个粒子更新状态依赖于自身信息和交互信息, 即  $\mathbf{p}_i = (\mathbf{p}_{i1}, \mathbf{p}_{i2}, \dots, \mathbf{p}_{iD})$  和  $\mathbf{p}_g = (\mathbf{p}_{g1}, \mathbf{p}_{g2}, \dots, \mathbf{p}_{gD})$ . 具体地, 粒子状态更新计算为

$$\begin{cases} \mathbf{v}_i(k+1) = \omega \mathbf{v}_i(k) + c_1 r_1 (\mathbf{p}_i(k) - \mathbf{x}_i(k)) + \\ \quad c_2 r_2 (\mathbf{p}_g(k) - \mathbf{x}_i(k)) \\ \mathbf{x}_i(k+1) = \mathbf{x}_i(k) + \mathbf{v}_i(k+1) \end{cases} \quad (1)$$

式中,  $k$  表示迭代次数,  $\omega$  代表惯性权重,  $c_1$  和  $c_2$  为加速因子, 分别代表认知系数和社会系数.  $r_1$  和  $r_2$  是均匀分布在  $[0, 1]$  之间的随机数.

值得提及的是, 在不失一般情况下, 考虑求解最小化参数任务, 其中  $f(\cdot)$  是目标函数. 我们可以得到  $\mathbf{p}_i(k+1)$  和  $\mathbf{p}_g(k+1)$  的具体计算为

$$\mathbf{p}_i(k+1) = \begin{cases} \mathbf{p}_i(k), & P \\ \mathbf{x}_i(k+1), & Q \end{cases} \quad (2)$$

$$\mathbf{p}_g(k+1) = \min\{\mathbf{p}_i(j), j = 1, 2, \dots, k+1\} \quad (3)$$

其中,  $P$  和  $Q$  分别定义为  $P = \{\text{if } f(\mathbf{x}_i(k+1)) \geq f(\mathbf{p}_i(k))\}$ ,  $Q = \{\text{if } f(\mathbf{x}_i(k+1)) < f(\mathbf{p}_i(k))\}$ .

### 1.2 PSO 算法的发展

标准 PSO 算法存在早熟收敛、易陷入局部最优等缺点. 为此, 学者们先后提出了多种改进 PSO 算法. 例如, Shi 等在文献 [19] 中提出了一种惯性权重线性递减策略的 PSO 算法 (PSO algorithm with a linearly decreased inertia weigh, PSO-LIDW). 该算法的惯性权重选择策略如下: 在搜索阶段, 采用较大的惯性权重来帮助粒子跳出局部极小值点, 以便于全局搜索; 而在收敛阶段, 该算法选取较小的惯性权重来促使粒子对当前目标区域进行精细搜索, 以便于算法收敛. 算法的惯性权重计算为

$$\omega = \omega_i - (\omega_i - \omega_f) \frac{k}{k_{\max}} \quad (4)$$

其中,  $k$  和  $k_{\max}$  分别代表当前迭代次数和最大迭代次数,  $\omega_i$  和  $\omega_f$  分别表示惯性权重的初始值和最终值. 在此基础上, 文献 [4] 提出了一种时变的加速因子策略 (PSO algorithm with time-varying acceleration coefficients, PSO-TVAC), 即: 认知因子  $c_1$  线性递减; 社会因子  $c_2$  线性递增. 该策略更符合认知规律. 两个加速度因子  $c_1$  和  $c_2$  的计算为

$$c_1 = (c_{1f} - c_{1i}) \frac{k_{\max} - k}{k_{\max}} + c_{1i} \quad (5)$$

$$c_2 = (c_{2f} - c_{2i}) \frac{k_{\max} - k}{k_{\max}} + c_{2i} \quad (6)$$

其中,  $c_{1i}$  ( $c_{2i}$ ) 和  $c_{1f}$  ( $c_{2f}$ ) 分别表示加速度系数的初始值和最终值.

## 2 基于事件触发的全信息粒子群优化器

本文提出了一种基于事件触发策略的全信息粒子群优化器, 主要创新点在于: 1) 事件触发策略的引入; 2) 全信息策略的考虑.

### 2.1 事件触发策略

在网络化控制系统中<sup>[20]</sup>, 传感器产生的信号传输到控制器/滤波器过程中, 考虑到带宽和能耗限制, 学者们提出了事件触发策略来确保有用信息的传输和有效地利用网络资源<sup>[21]</sup>. 本文中事件触发策略更多地考虑用来实现 PSO 算法的模态切换, 更好地维持种群多样性和收敛性之间的一个动态平衡. 粒子寻优过程中, 历史信息的引入有助于找到全局最优解, 但也会增加一定的计算负担. 因此, 引入了事件触发策略来降低了计算负担, 同时也保证了粒子搜索特性的一个动态切换.

粒子的寻优过程一般分为搜索和收敛两个阶段. 粒子的状态转换一般采用时间触发策略, 例如, 通过线性时变策略调整惯性权重和加速因子来实现由探索阶段到收敛阶段的转换. 然而, 这样会面临以下问题: 1) 由搜索阶段到收敛阶段切换的时间节点一般是模糊的, 这会导致 PSO 算法的性能下降, 甚至粒子陷入局部最优; 2) 时间触发策略有可能会造成一些不必要的迭代运算, 增加了计算存储和运行时间. 因此, 本文从粒子空间特性角度出发, 提出了一种基于事件触发策略的 PSO 算法.

种群多样性是衡量 PSO 算法性能的一个重要指标, 与其他群智能优化算法一样, 在探索阶段, 需要保证较高的种群多样性, 使粒子分布在空间

来更好地探索全局最优解. 而在收敛阶段, 则需要一个较低的种群多样性, 以保证粒子朝着全局最优解收敛. 值得提及的是, 大多数文献通过实时调整惯性权重和加速因子来控制粒子的集散程度, 即, 惯性权重和加速因子是时变参数. 然而, 这样的改进可能远远不够, 因此, 本文设计了一种基于粒子空间特性的事件触发策略来改变种群的拓扑结构, 提高 PSO 算法的种群多样性, 以期缓解早熟收敛的不足. 其中, 关键一步是如何设计一个事件触发函数, 以便在每次迭代中充分考虑到所有  $\mathbf{p}_{\text{best}}$  和  $\mathbf{g}_{\text{best}}$  对当前位置的影响.

根据文献 [5], 定义粒子在第  $k$  次迭代的种群多样性为

$$S_i(k) = \sqrt{\sum_{j=1}^D (\mathbf{x}_{ij}(k) - \bar{\mathbf{x}}_j(k))^2} \quad (7)$$

式 (7) 是一个针对每个粒子的局部指标, 表示单个粒子偏离整体的程度 (即粒子的集散度).  $D$  为搜索空间的维数.  $\mathbf{x}_{ij}(k)$  表示第  $j$  维空间中的第  $i$  个粒子,  $\bar{\mathbf{x}}_j(k)$  代表在第  $k$  次迭代过程中第  $j$  维空间中所有粒子的平均值.

事件触发函数  $f(\cdot)$  定义为

$$f(S_i(k)) = H_k(S_i(k)) - \gamma_i(k) \quad (8)$$

式中,  $\gamma_i(k)$  是阈值,  $H_k(\cdot)$  函数定义为

$$H_k(S_i(k)) = \frac{S_i(k) - S_{\min}(k)}{S_{\max}(k) - S_{\min}(k)} \quad (9)$$

式中,  $S_{\max}(k)$  和  $S_{\min}(k)$  分别是种群中  $S_i(k)$  的最大值和最小值.

事件触发指标  $\alpha_i(k)$  定义为

$$\alpha_i(k) = \begin{cases} 1, & S_i(k) \notin \chi_k \\ 0, & S_i(k) \in \chi_k \end{cases} \quad (10)$$

式中,  $\chi_k = \{S_i(k) \in \mathbf{R} \mid f(S_i(k)) < 0\}$ .

与时变参数策略相比, 基于粒子空间特性的事件触发策略具有以下优点: 1) 可以实现速度更新模型自适应切换, 保证种群多样性和收敛性之间的动态平衡; 2) 能够促使粒子朝着  $\mathbf{p}_{i, \text{best}}$  和  $\mathbf{p}_{g, \text{best}}$  移动, 从而提高了收敛速率.

粒子在寻优过程中一般会处于搜索状态或收敛状态. 在搜索状态时, 要尽可能保持较高的种群多样性, 便于在整个空间内搜索全局最优解; 而在收敛状态时, 需要较低的种群多样性, 以保证粒子向着全局最优解收敛. 粒子的状态转换常采用时间触发机制, 通过时变策略对参数进行调整, 从而完成从搜索状态到收敛状态的切换. 但采用这种方法从



搜索状态到收敛状态的切换时刻是无法精准把握的,从而可能会导致粒子陷入局部最优.为解决上述问题,本文采用事件触发策略来控制粒子的集散程度,使得粒子可以自适应地在搜索状态和收敛状态中切换,从而保证种群多样性和收敛性之间的动态平衡.

## 2.2 全信息策略

历史信息的引入有助于对整个解空间实现彻底搜索,降低粒子陷入局部最优的可能性<sup>[14]</sup>. Zeng等在文献[15]中提出了切换时滞粒子群优化算法(Switching delayed PSO, SDPSO),该算法首次将时滞引入到PSO算法中,通过马尔科夫链实现粒子状态的切换,与一些经典改进PSO算法相比,SDPSO算法性能得到了大大的提升.之后, Song等<sup>[16]</sup>提出了多峰值时滞PSO算法(Multimodal delayed PSO, MDPSO),对比SDPSO算法,性能得到了进一步提升.在此基础上,文献[14]和文献[22]分别提出了分布式时滞PSO算法和带有饱和的混合时滞PSO算法.然而,上述改进PSO算法,仅仅考虑了部分历史信息的使用,可能会导致粒子飞行轨迹效果不好(如果历史信息没有选择好).因此,本文提出一种基于全信息策略的PSO算法.

本文的个体 $C_p$ 和全局 $C_g$ 全信息策略分别定义如下:

$$C_p = c_3 r_3 \left( \frac{1}{k-1} \sum_{n=1}^{k-1} \mathbf{p}_i(k-n) - \mathbf{x}_i(k) \right) \quad (11)$$

$$C_g = c_4 r_4 \left( \frac{1}{k-1} \sum_{n=1}^{k-1} \mathbf{p}_g(k-n) - \mathbf{x}_i(k) \right) \quad (12)$$

其中, $c_3$ 和 $c_4$ 是加速因子, $r_3$ 和 $r_4$ 是 $[0, 1]$ 之间的随机数.不失一般性,假设 $c_3 = c_1$ , $c_4 = c_2$ ,值得一提的是,时滞(历史信息)的引入可以扩大搜索空间,从而降低粒子陷入局部最优的可能性.与其他文献不同的是,其他文献选取的是过去的部分历史信息,具有一定的随机性,而本文的 $\mathbf{x}_i(k)$ 与过去 $k-1$ 个时刻 $\mathbf{p}_i$ 和 $\mathbf{p}_g$ 的平均值进行了比较,这有助于防止早熟收敛和不期望的散度.

## 2.3 EFPSO 算法

全信息策略(即利用过去 $k-1$ 时刻的 $\mathbf{p}_i$ 和 $\mathbf{p}_g$ 信息)的引入有助于对于整个问题空间进行彻底搜索,找到全局最优解,降低陷入局部最优的可能性.事件触发策略的考虑实现了搜索状态和收敛状态之间的一个动态切换,这样可以避免早熟收敛和不期望的散度.基于此,本文提出了一种新的基于事件

触发的全信息粒子群优化算法.

在EFPSO算法中,第 $i$ 个粒子的速度和位置更新计算为

$$\begin{cases} \mathbf{v}_i(k+1) = \omega \mathbf{v}_i(k) + c_1 r_1 (\mathbf{p}_i(k) - \mathbf{x}_i(k)) + \\ \quad c_2 r_2 (\mathbf{p}_g(k) - \mathbf{x}_i(k)) + \\ \quad \alpha_i(k) (\mathbf{C}_p + \mathbf{C}_g) \\ \mathbf{x}_i(k+1) = \mathbf{x}_i(k) + \mathbf{v}_i(k+1) \end{cases} \quad (13)$$

式中, $\alpha_i(k)$ 是第 $k$ 时刻粒子 $i$ 的事件触发指标, $\mathbf{C}_p$ 和 $\mathbf{C}_g$ 分别是个体和全局的全信息项.

值得注意的是, $\alpha_i(k)$ 的不同取值刻画了粒子 $i$ 在 $k$ 时刻的搜索特性.本文中 $\alpha_i(k)$ 可取两个值.当 $\alpha_i(k) = 1$ 时,粒子处于搜索状态,希望遍历整个搜索空间来发现全局最优解;当 $\alpha_i(k) = 0$ 时,粒子处于收敛状态,希望尽快向全局最优粒子移动.

1) 从单个粒子角度分析速度多样性

单个粒子的速度更新方程为

$$\begin{cases} \mathbf{v}(k+1) = \omega \mathbf{v}(k) + c_1 r_1 (\mathbf{p}(k) - \mathbf{x}(k)) + \\ \quad c_2 r_2 (\mathbf{g}(k) - \mathbf{x}(k)) + \\ \quad \alpha(k) (\mathbf{C}_p + \mathbf{C}_g) \\ \mathbf{x}(k+1) = \mathbf{x}(k) + \mathbf{v}(k+1) \end{cases} \quad (14)$$

其中, $\mathbf{C}_p = c_3 r_3 ((1/(k-1)) \sum_{n=1}^{k-1} \mathbf{p}(k-n) - \mathbf{x}(k))$ 和 $\mathbf{C}_g = c_4 r_4 ((1/(k-1)) \sum_{n=1}^{k-1} \mathbf{g}(k-n) - \mathbf{x}(k))$ .

根据式(10)可知,当 $\alpha(k) = 0$ 时,式(14)为标准形式粒子群优化算法,即

$$\begin{cases} \mathbf{v}(k+1) = \omega \mathbf{v}(k) + c_1 r_1 (\mathbf{p}(k) - \mathbf{x}(k)) + \\ \quad c_2 r_2 (\mathbf{g}(k) - \mathbf{x}(k)) \\ \mathbf{x}(k+1) = \mathbf{x}(k) + \mathbf{v}(k+1) \end{cases} \quad (15)$$

当 $\alpha(k) = 1$ 时,式(14)为

$$\begin{cases} \mathbf{v}(k+1) = \omega \mathbf{v}(k) + c_1 r_1 (\mathbf{p}(k) - \mathbf{x}(k)) + \\ \quad c_2 r_2 (\mathbf{g}(k) - \mathbf{x}(k)) + \\ \quad (\mathbf{C}_p + \mathbf{C}_g) \\ \mathbf{x}(k+1) = \mathbf{x}(k) + \mathbf{v}(k+1) \end{cases} \quad (16)$$

在式(16)中,考虑了前 $k-1$ 时刻的个体最优( $\bar{\mathbf{p}}_{\text{past/best}}$ )和全局最优( $\bar{\mathbf{g}}_{\text{past/best}}$ )的均值对当前 $k$ 时刻的影响.从图1可以看出,标准粒子群优化算法的搜索速度矢量( $\mathbf{v}(k+1)$ )是由自身惯性速度( $\omega \mathbf{v}(k)$ )和个体最优位置( $\mathbf{p}_{\text{best}}$ )以及全局最优位置( $\mathbf{g}_{\text{best}}$ )三个矢量合成,而本文引入全信息项,速度矢量( $\mathbf{v}(k+1)$ )由自身惯性速度( $\omega \mathbf{v}(k)$ )、个体最优位置( $\mathbf{p}_{\text{best}}$ )、个体过去最优位置均值( $\bar{\mathbf{p}}_{\text{past/best}}$ )、全局最优位置( $\mathbf{g}_{\text{best}}$ )以及全局过去最优位置均值( $\bar{\mathbf{g}}_{\text{past/best}}$ )五个矢量合成,在原来的基础上增加了两个自由度,进而增加了粒子运动方向的多样性,可以彻底探索整个问题空间.




图 1 PSO 算法寻优过程

Fig.1 Optimization process of the PSO algorithm

2) 从整个粒子群角度分析种群多样性

$$\begin{cases} \mathbf{v}_i(k+1) = \omega \mathbf{v}_i(k) + c_1 r_1 (\mathbf{p}_i(k) - \mathbf{x}_i(k)) + \\ \quad c_2 r_2 (\mathbf{p}_g(k) - \mathbf{x}_i(k)) + \\ \quad \alpha_i(k) (\mathbf{C}_p + \mathbf{C}_g) \\ \mathbf{x}_i(k+1) = \mathbf{x}_i(k) + \mathbf{v}_i(k+1) \end{cases} \quad (17)$$

根据式 (7) ~ (10) 可知, 不同的粒子所处的状态是不同的, 既可能处于搜索状态 (由式 (16) 描述), 也可能处于收敛状态 (由式 (15) 描述), 而且粒子的状态会根据粒子的种群空间特性进行实时动态调整, 这样不仅增加了粒子的种群多样性, 而且也保证了粒子搜索和收敛状态之间的一个动态平衡, 可以有效地避免粒子陷入局部最优。

EFPSO 算法流程图如图 2 所示。

### 3 仿真实验分析与讨论

本节给出一系列仿真实验对比, 并讨论和评估 EFPSO 算法的性能。在对比实验中, 选取了 5 种经典的改进 PSO 算法 (PSO-LDIW<sup>[6]</sup>, PSO-TVAC<sup>[7]</sup>, SDPSO<sup>[15]</sup>, MDPSO<sup>[16]</sup>, 压缩因子粒子群算法 (PSO algorithm with the constriction factor, PSO-CK)<sup>[23]</sup>), 在 8 个单峰值和多峰值测试函数上进行。参数设置如下: 粒子个数  $S = 20$ , 群体维数  $D = 20$ , 最大迭代  $k_{\max} = 20000$ , 每个实验重复次数  $T = 50$ 。根据式 (4), 惯性权重 ( $\omega$ ) 是线性递减的。因此, 惯性权重的初值和终值分别设置如下:  $\omega_i = 0.9$ ,  $\omega_f = 0.4$ ; 根据式 (5), 加速因子 ( $c_1 = c_3$ ) 是线性递减的。因此, 加速因子 ( $c_1 = c_3$ ) 的初值和终值分别设置如下:  $c_{1i} = c_{3i} = 2.5$ ,  $c_{1f} = c_{3f} = 0.5$ ; 根据式 (6), 加速因子 ( $c_2 = c_4$ ) 是线性递增的。因此, 加速因子 ( $c_2 = c_4$ ) 的初值和终值分别设置如下:  $c_{2i} = c_{4i} = 0.5$ ,  $c_{2f} = c_{4f} = 2.5$ 。针对本文中提及的对比算法 (PSO-LDIW<sup>[6]</sup>, PSO-TVAC<sup>[7]</sup>, SDPSO<sup>[15]</sup>, MDPSO<sup>[16]</sup>, PSO-CK<sup>[23]</sup>), 所有参数按照原文献给定。式 (18) ~ (25) 分别给出了 8 种测试函数, 其中 Sphere 函数是一个典型的单峰函数, 常用来证明 PSO 算法的收敛速度; Rastrigin 函数和 Griewank 函数存在大量的局部最优解, 很难发现全局最优解; Sch-

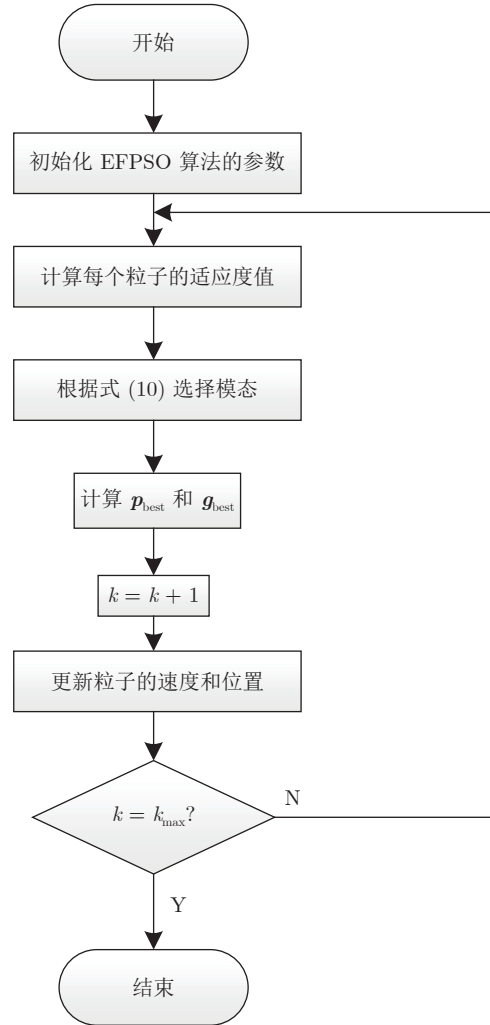


图 2 EFPSO 算法流程图

Fig.2 The flowchart of the EFPSO algorithm

wefe 2.22 函数、Schwefe 1.2 函数和 Penalized 1 函数是典型的多峰函数, 常用来评估算法的寻优能力。表 1 中给出了各个测试函数的维数、搜索范围、阈值和极值等细节。

1) Sphere 函数

$$f_1(x) = \sum_{i=1}^D x_i^2 \quad (18)$$

2) Ackley 函数

$$f_2(x) = -20e^{-0.2\sqrt{\frac{1}{D}\sum_{i=1}^D x_i^2}} + 20 + e - e^{\frac{1}{D}\sum_{i=1}^D \cos 2\pi x_i} \quad (19)$$

3) Rastrigin 函数

$$f_3(x) = \sum_{i=1}^D (x_i^2 - 10 \cos 2\pi x_i + 10) \quad (20)$$

表 1 基准函数配置

Table 1 The benchmark function configuration

函数	名称	搜索范围	维数	阈值	最优值
$f_1(x)$	Sphere	[-100 100]	20	0.01	0
$f_2(x)$	Ackley	[-32 32]	20	0.01	0
$f_3(x)$	Rastrigin	[-5.12 5.12]	20	50	0
$f_4(x)$	Schwefe 2.22	[-10 10]	20	0.01	0
$f_5(x)$	Schwefe 1.2	[-100 100]	20	0.01	0
$f_6(x)$	Griewank	[-600 600]	20	0.01	0
$f_7(x)$	Penalized 1	[-100 100]	20	0.01	0
$f_8(x)$	Step	[-100 100]	20	0.01	0

4) Schwefe 2.22 函数

$$f_4(x) = \sum_{i=1}^D |x_i| + \prod_{i=1}^D |x_i| \quad (21)$$

5) Schwefe 1.2 函数

$$f_5(x) = \sum_{i=1}^D (\sum_{j=1}^i x_j)^2 \quad (22)$$

6) Griewank 函数

$$f_6(x) = \frac{1}{4000} \sum_{i=1}^D x_i^2 + 1 - \prod_{i=1}^D \cos(\frac{x_i}{\sqrt{i}}) \quad (23)$$

7) Penalized 1 函数

$$f_7(x) = \sum_{i=1}^D \mu(x(i), 10, 100, 4) + \frac{\pi}{D} \left( 10 \sin^2(\pi x(1)) + (x(D) - 1)^2 + \sum_{i=1}^D (x(i) - 1)^2 \times (1 + \sin^2(10\pi x(i + 1))) \right) \quad (24)$$

8) Step 函数

$$f_8(x) = \sum_{i=1}^D (|x_i + 0.5|)^2 \quad (25)$$

为了验证 EFPSO 算法的优越性, 本文使用 3 个常用的性能指标来评价算法的性能 (即收敛率、成功率和种群多样性). 收敛率是衡量 PSO 算法精度的一个重要指标, 成功率是衡量 PSO 算法跳出局部最优能力的一个指标, 种群多样性通常用来评价 PSO 算法的寻优能力.

图 3~10 给出了所有 PSO 算法收敛特性曲线, 其中, 横坐标为迭代次数, 纵坐标为平均适应度值的对数形式. 从图中可以清晰地发现, EFPSO 算法




图 3 Sphere 函数收敛特性

Fig.3 Convergence characteristics of Sphere




图 4 Ackley 函数收敛特性

Fig.4 Convergence characteristics of Ackley




图 5 Rastrigin 函数收敛特性

Fig.5 Convergence characteristics of Rastrigin

比其他 PSO 算法具有更好的性能. 具体地, 在图 4~10 中可以看出, EFPSO 算法搜索能力是所有算法中最好的. 对于图 3, 尽管 EFPSO 算法不是最优的,




图 6 Schwefe 2.22 函数收敛特性

Fig.6 Convergence characteristics of Schwefe 2.22




图 9 Penalized 1 函数收敛特性

Fig.9 Convergence characteristics of Penalized 1




图 7 Schwefe 1.2 函数收敛特性

Fig.7 Convergence characteristics of Schwefe 1.2




图 10 Step 函数收敛特性

Fig.10 Convergence characteristics of Step




图 8 Griewank 函数收敛特性

Fig.8 Convergence characteristics of Griewank

但是 EFPSO 算法的最小值、均值、标准差和成功率等都是满足性能要求的。

表 2 给出了所有 PSO 算法的统计特性, 包括

最小值、均值和标准差, 以此来评估 PSO 算法的搜索能力和种群多样性. 最小值代表 PSO 算法最好的寻优结果, 平均值代表算法的稳定性, 因为 PSO 算法是一种启发式算法, 并非每一次搜索都可以发现最优解. 因此, 一般采用均值衡量算法寻优的稳定性, 标准差衡量粒子最后收敛的一致性, 标准差越小代表粒子高度一致. 从表 2 可以看出, EFPSO 算法的最小值、平均值和标准差都是最小的, 或者是趋于最小的, 这表明 EFPSO 算法在寻优能力和种群多样性方面是优于其他 PSO 算法的。

除此之外, 表 2 还给出了所有 PSO 算法对于测试函数的寻优成功率, 其中 EFPSO 算法对于除了 Griewank 函数的所有测试函数的结果都是 100%, 说明了该算法的强大寻优能力. 至于 Griewank 函数, 从表 2 中可以发现, EFPSO 算法的收敛成功率是 40%, 高于其他 PSO 算法. 导致所有 PSO 算法成功率都非常低的原因是 Griewank 函数是一个典型的多峰函数, 包含大量的局部极小值点. 对比



表 2 6 种 PSO 算法测试结果统计  
Table 2 Six PSO algorithms test results statistics

		PSO-LDIW	PSO-TVAC	PSO-CK	SDPSO	MDPSO	EFPSO
$f_1(x)$	最小值	$2.44 \times 10^{-202}$	$8.44 \times 10^{-152}$	0	$6.85 \times 10^{-13}$	$7.57 \times 10^{-68}$	$1.60 \times 10^{-139}$
	均值	$1.90 \times 10^{-188}$	$3.49 \times 10^{-58}$	0	$4.26 \times 10^{-9}$	$2.99 \times 10^{-46}$	$1.63 \times 10^{-75}$
	标准差	0	$2.47 \times 10^{-57}$	0	$9.72 \times 10^{-9}$	$1.89 \times 10^{-45}$	$7.32 \times 10^{-75}$
	成功率 (%)	100	100	100	100	100	100
$f_2(x)$	最小值	$2.66 \times 10^{-15}$	$2.66 \times 10^{-15}$	$2.66 \times 10^{-15}$	$4.09 \times 10^{-7}$	$2.66 \times 10^{-15}$	$2.66 \times 10^{-15}$
	均值	$5.15 \times 10^{-15}$	$5.50 \times 10^{-15}$	2.72	$7.14 \times 10^{-6}$	$8.06 \times 10^{-15}$	$5.50 \times 10^{-15}$
	标准差	$1.64 \times 10^{-15}$	$1.43 \times 10^{-15}$	4.00	$5.89 \times 10^{-6}$	$3.22 \times 10^{-15}$	$1.45 \times 10^{-15}$
	成功率 (%)	100	100	20	100	100	100
$f_3(x)$	最小值	3.97	2.98	20.8	3.99	5.96	4.97
	均值	17.1	10.2	56.3	19.5	21.1	9.50
	标准差	15.3	4.10	22.6	12.7	12.3	2.44
	成功率 (%)	96	100	50	94	98	100
$f_4(x)$	最小值	$5.09 \times 10^{-119}$	$1.07 \times 10^{-37}$	$6.60 \times 10^{-65}$	$2.46 \times 10^{-8}$	$4.37 \times 10^{-34}$	$1.99 \times 10^{-32}$
	均值	12.6	$6.00 \times 10^{-1}$	$3.11 \times 10^{-3}$	3.00	1.40	$2.96 \times 10^{-18}$
	标准差	11.9	2.39	8.40	5.05	3.50	$1.32 \times 10^{-17}$
	成功率 (%)	28	94	44	72	86	100
$f_5(x)$	最小值	$4.31 \times 10^{-27}$	$4.15 \times 10^{-33}$	$2.70 \times 10^{-104}$	$9.40 \times 10^{-2}$	$1.92 \times 10^{-21}$	$6.56 \times 10^{-26}$
	均值	$2.56 \times 10^3$	133	$1.33 \times 10^3$	204	533	$3.32 \times 10^{-15}$
	标准差	$3.91 \times 10^3$	942	$2.49 \times 10^3$	988	$1.63 \times 10^3$	$1.12 \times 10^{-14}$
	成功率 (%)	64	98	76	0	90	100
$f_6(x)$	最小值	0	0	0	$2.98 \times 10^{-13}$	0	0
	均值	1.84	$3.69 \times 10^{-2}$	1.82	$2.43 \times 10^{-2}$	$2.82 \times 10^{-2}$	$2.03 \times 10^{-2}$
	标准差	12.7	$2.92 \times 10^{-2}$	12.7	$2.08 \times 10^{-2}$	$2.80 \times 10^{-2}$	$2.35 \times 10^{-2}$
	成功率 (%)	12	14	28	34	36	40
$f_7(x)$	最小值	$2.35 \times 10^{-32}$	$2.35 \times 10^{-32}$	$2.35 \times 10^{-32}$	$3.77 \times 10^{-16}$	$2.35 \times 10^{-32}$	$2.35 \times 10^{-32}$
	均值	$2.35 \times 10^{-32}$	$2.43 \times 10^{-32}$	$2.60 \times 10^{-1}$	$3.46 \times 10^{-9}$	$2.37 \times 10^{-32}$	$2.35 \times 10^{-32}$
	标准差	$2.73 \times 10^{-34}$	$4.49 \times 10^{-33}$	$5.17 \times 10^{-1}$	$1.70 \times 10^{-8}$	$1.09 \times 10^{-33}$	$2.80 \times 10^{-48}$
	成功率 (%)	100	100	52	100	100	100
$f_8(x)$	最小值	0	0	0	0	0	0
	均值	200	0	401	0	0	0
	标准差	$1.41 \times 10^3$	0	$1.97 \times 10^3$	0	0	0
	成功率 (%)	98	100	62	100	100	100

其他算法, 可以发现 EFPSO 算法的跳出局部极小值能力是优于其他经典 PSO 算法的。

在此讨论了  $\gamma_i(k)$  对 EFPSO 算法性能的影响. 根据式 (9) 可知,  $H_k(S_i(k))$  是一个  $[0, 1]$  之间的数, 因此  $\gamma_i(k)$  在  $[0, 1]$  之间取值. 当  $\gamma_i(k) = 0$  时, 每个时刻  $k$  都触发, 粒子一直处于搜索状态. 当  $\gamma_i(k) = 1$  时, 一直不触发, 粒子一直处于收敛状态, 粒子容易陷入局部最优. 因此,  $\gamma_i(k)$  的选择不宜过大, 也不宜过小. 本文结合实际问题, 分别针对不同  $\gamma_i(k)$  取值下的仿真结果进行对比以找到最佳取值. 对应的仿真结果见表 3 所示.

表 3 给出了不同  $\gamma_i(k)$  对 EFPSO 算法性能的影响. 从表 3 可以看出, 对于函数  $f_1(x)$ ,  $f_2(x)$ ,  $f_3(x)$ ,  $f_6(x)$ ,  $f_7(x)$ ,  $f_8(x)$ , 在  $\gamma_i(k) = 0.5$  时取得了最优结果; 对于  $f_4(x)$ , 在  $\gamma_i(k) = 0.4$  时取得了最优结果; 对于  $f_5(x)$ , 在  $\gamma_i(k) = 0.3$  时取得了最优结果. 不难发现,  $\gamma_i(k)$  取值为  $0.2 \sim 0.7$  时对应的结果先增加后减小. 通过对比可知,  $\gamma_i(k) = 0.4$  时 EFPSO 算法的性能最优, 因此本文选取  $\gamma_i(k) = 0.4$ .

#### 4 EFPSO 算法的应用

随着社会经济和科学技术的发展, 现代化的油

表 3 不同  $\gamma_i(k)$  的 EFPSO 算法统计结果比较  
 Table 3 The statistical results of the EFPSO algorithm with different  $\gamma_i(k)$  are compared

		$\gamma_i(k) = 0.2$	$\gamma_i(k) = 0.3$	$\gamma_i(k) = 0.4$	$\gamma_i(k) = 0.5$	$\gamma_i(k) = 0.6$	$\gamma_i(k) = 0.7$
$f_1(x)$	最小值	$1.42 \times 10^{-25}$	$2.31 \times 10^{-101}$	$1.69 \times 10^{-139}$	$6.03 \times 10^{-90}$	$7.91 \times 10^{-53}$	$5.14 \times 10^{-30}$
	均值	$5.14 \times 10^{-35}$	$3.34 \times 10^{-60}$	$1.63 \times 10^{-75}$	$4.32 \times 10^{-65}$	$2.24 \times 10^{-32}$	$7.98 \times 10^{-7}$
	标准差	$3.21 \times 10^{-35}$	$3.95 \times 10^{-60}$	$7.32 \times 10^{-75}$	$3.98 \times 10^{-65}$	$3.41 \times 10^{-32}$	$5.31 \times 10^{-7}$
	成功率 (%)	100	100	100	100	100	100
$f_2(x)$	最小值	$2.60 \times 10^{-15}$	$2.66 \times 10^{-15}$	$2.66 \times 10^{-15}$	$2.66 \times 10^{-15}$	$3.45 \times 10^{-12}$	$2.97 \times 10^{-7}$
	均值	$3.91 \times 10^{-14}$	$6.29 \times 10^{-15}$	$5.50 \times 10^{-15}$	$7.14 \times 10^{-14}$	$3.63 \times 10^{-10}$	$5.48 \times 10^{-7}$
	标准差	$4.32 \times 10^{-14}$	$8.91 \times 10^{-15}$	$1.45 \times 10^{-15}$	$8.93 \times 10^{-14}$	$2.97 \times 10^{-10}$	$6.92 \times 10^{-7}$
	成功率 (%)	100	100	100	100	100	100
$f_3(x)$	最小值	9.01	12.6	4.97	9.12	13.1	11.1
	均值	18.3	17.2	9.50	12.9	20.0	13.8
	标准差	6.59	3.33	2.44	3.39	8.18	2.23
	成功率 (%)	100	100	100	100	100	100
$f_4(x)$	最小值	$1.69 \times 10^{-24}$	$1.59 \times 10^{-24}$	$1.99 \times 10^{-32}$	$2.24 \times 10^{-40}$	$2.41 \times 10^{-35}$	$5.71 \times 10^{-20}$
	均值	$5.38 \times 10^{-16}$	$1.78 \times 10^{-16}$	$2.96 \times 10^{-18}$	$2.56 \times 10^{-32}$	$7.98 \times 10^{-22}$	$6.94 \times 10^{-7}$
	标准差	$7.69 \times 10^{-17}$	$0.97 \times 10^{-16}$	$1.32 \times 10^{-17}$	$1.68 \times 10^{-32}$	$6.54 \times 10^{-22}$	$3.89 \times 10^{-7}$
	成功率 (%)	100	100	100	100	100	100
$f_5(x)$	最小值	$2.31 \times 10^{-28}$	$7.34 \times 10^{-30}$	$6.56 \times 10^{-26}$	$7.19 \times 10^{-20}$	$5.34 \times 10^{-20}$	$1.53 \times 10^{-9}$
	均值	$5.46 \times 10^{-15}$	$3.84 \times 10^{-15}$	$3.32 \times 10^{-15}$	$7.34 \times 10^{-9}$	$8.91 \times 10^{-9}$	$8.72 \times 10^{-5}$
	标准差	$2.49 \times 10^{-15}$	$2.96 \times 10^{-15}$	$1.12 \times 10^{-14}$	$1.36 \times 10^{-9}$	$6.37 \times 10^{-9}$	$6.54 \times 10^{-5}$
	成功率 (%)	100	100	100	100	100	100
$f_6(x)$	最小值	$2.72 \times 10^{-7}$	$1.31 \times 10^{-7}$	0	$5.18 \times 10^{-7}$	$9.07 \times 10^{-7}$	$1.01 \times 10^{-6}$
	均值	$1.54 \times 10^{-2}$	$1.19 \times 10^{-2}$	$2.03 \times 10^{-2}$	$4.45 \times 10^{-3}$	$1.03 \times 10^{-2}$	$2.40 \times 10^{-2}$
	标准差	$3.04 \times 10^{-2}$	$9.57 \times 10^{-3}$	$2.35 \times 10^{-2}$	$6.16 \times 10^{-3}$	$1.05 \times 10^{-2}$	$3.15 \times 10^{-2}$
	成功率 (%)	30	40	40	42	38	36
$f_7(x)$	最小值	$2.35 \times 10^{-32}$	$2.35 \times 10^{-32}$	$2.35 \times 10^{-32}$	$2.35 \times 10^{-32}$	$4.67 \times 10^{-20}$	$2.37 \times 10^{-16}$
	均值	$2.43 \times 10^{-32}$	$2.35 \times 10^{-32}$	$2.35 \times 10^{-32}$	$2.35 \times 10^{-32}$	$8.96 \times 10^{-20}$	$8.91 \times 10^{-9}$
	标准差	$3.71 \times 10^{-34}$	$3.69 \times 10^{-33}$	$2.80 \times 10^{-48}$	$4.96 \times 10^{-33}$	$7.69 \times 10^{-20}$	$7.34 \times 10^{-8}$
	成功率 (%)	100	100	100	100	100	100
$f_8(x)$	最小值	0	0	0	0	0	0
	均值	0	0	0	0	0	0
	标准差	0	0	0	0	0	0
	成功率 (%)	100	100	100	100	100	100

气管网系统规模不断扩大, 系统越来越复杂, 随之而来出现了许多问题和挑战, 例如: 管道信号去噪、管道故障诊断、管道寿命预测、管道风险评估等. 管道信号去噪是前提和重要环节. 管道所处现场环境十分复杂, 车辆的行驶、现场施工等都会对管道信号采集带来一定影响, 进而会影响管道健康监测系统的准确性, 增加了误报率和漏报率. 基于上述问题, 研究管道信号去噪问题显得十分迫切和必要. VMD 算法由于具有操作简单、能够自适应分解信号等优势, 常用来处理信号去噪和故障诊断<sup>[24-25]</sup>等问题. 然而, VMD 算法在分解过程中严重依赖专家

经验知识, 需要人工设定模态分解数  $K$  和惩罚因子  $\alpha$ , 这会对去噪效果造成不良影响. 为了解决 VMD 分解过程中参数选择依赖于人工经验的问题, 本文采用提出的 EFPSO 算法优化 VMD 的模态分解数  $K$ 、惩罚因子  $\alpha$  以及重构模态数  $N$ .

本文选取如下函数作为适应度函数:

$$J(K, \alpha, N) = - \sum_{t=1}^M p_t \lg p_t + \frac{1}{L(N)} \quad (26)$$

式中,  $p_t$  为由包络信号得到的概率分布序列, 计算式为

$$p_t = \frac{a(t)}{\sum_{t=1}^M a(t)} \quad (27)$$

式中,  $a(t)$  是管道信号分量  $\text{IMF}_k$  经过希尔伯特变换得到的包络信号, 其中  $t = 1, 2, \dots, M$ ,  $M$  为第  $k$  个 IMF (Intrinsic mode function) 分量的长度,  $k = 1, 2, \dots, K$ .

式 (26) 中,  $L(N)$  的计算式为

$$L(N) = KL(\rho|\rho_{N+1}) - KL(\rho|\rho_N) \quad (28)$$

式中,  $\rho$  为管道信号的概率密度函数,  $\rho_N$  为 VMD 分解得到的第  $N$  个 IMF 分量的概率密度函数, 其中,  $N = 1, 2, \dots, K - 1$ . KL (Kullback Leibler) 散度计算式为

$$KL(\rho|\rho_N) = \rho \lg \frac{\rho}{\rho_N} + (1 - \rho) \lg \frac{1 - \rho}{1 - \rho_N} \quad (29)$$

适应度函数式 (26) 中, 第 1 项用来优选  $K$  和  $\alpha$  的包络熵函数<sup>[26]</sup>; 第 2 项为 IMF 分量与原始信号相似度梯度的倒数, 用来优选重构模态数  $N$ .

以下是 EFPSO 优化的 VMD 去噪算法的具体步骤.

### 算法 1. 基于 EFPSO 优化的 VMD 去噪算法

输入. 种群粒子数  $m$ , 种群空间维数  $D$ , 最大迭代次数

$k_{\max}$ , 粒子个体最优  $p_{\text{best}}$  和粒子全局最优  $g_{\text{best}}$ ;

输出. 全局最优解  $\alpha$ ,  $K$ ,  $N$ ;

1 初始化 EFPSO 算法的参数和计算适应度函数值;

2 将 VMD 需要优化的参数  $\{\alpha, K, N\}$  作为 EFPSO 的位置  $x_i(k)$ ;

3 while  $k < k_{\max}$  do

4 for  $i = 1$  to  $m$  do

5 初始化参数  $\{\hat{\mu}_k^1\}$ ,  $\{\hat{\omega}_k^1\}$ ,  $\hat{\lambda}^1$  和  $n$ , 并将  $n$  的初始值定义为 0;

6 循环开始  $n = n + 1$ ;

7 求变分模态函数  $\mu(k)$  的极小值

$$\hat{u}_k^{n+1}(\omega) = \frac{\hat{f}(\omega) - \sum_{i \neq k} \hat{u}_i^n(\omega) + \frac{\hat{\lambda}(\omega)}{2}}{1 + 2\alpha(\omega - \omega_k)^2} \quad (30)$$

8 求中心频率  $\omega_k$  的极小值

$$\hat{\omega}_k^{n+1} = \frac{\int_0^\infty \omega |\hat{u}_k^{n+1}(\omega)|^2 d\omega}{\int_0^\infty |\hat{u}_k^{n+1}(\omega)|^2 d\omega} \quad (31)$$

9 迭代终止条件为

$$\sum_k \frac{\|\hat{u}_k^{n+1} - \hat{u}_k^n\|_2^2}{\|\hat{u}_k^n\|_2^2} < \varepsilon \quad (32)$$

10 比较各个适应度值, 更新粒子个体最优  $p_{\text{best}}$  和粒子全局最优  $g_{\text{best}}$ ;

11 根据式 (10), 选取速度更新模态;  
12 根据式 (4)~(6), 更新惯性权重和加速因子;  
13 根据式 (13), 更新 EFPSO 算法的速度  $v_i(k)$  和位置  $x_i(k)$ ;  
14 end for  
15  $k = k + 1$ ;  
16 end while

本文选取某输油管线现场信号作为去噪对象, 图 11 给出了未去噪的原始数据. 这里, 我们选取了信噪比 (Signal to noise ratio, SNR) 和均方误差 (Mean squared error, MSE) 两个性能指标, 通过对比经验模态分解 (Empirical modal decomposition, EMD) 算法、VMD 算法和 PSO-VMD 算法, 验证本文提出的 EFPSO-VMD 算法的优越性.




图 11 原始现场管道信号

Fig.11 Signal of original pipeline

实验结果总结如下: EMD 去噪算法优选模态  $K = 9$ , 重构模态  $N = 2$ ; VMD 去噪算法优选模态  $K = 5$ ,  $\alpha = 3000$ , 重构模态  $N = 2$ ; PSO-VMD 去噪算法优选模态  $K = 5$ ,  $\alpha = 1853$ , 重构模态  $N = 2$ ; EFPSO-VMD 去噪算法优选模态  $K = 7$ ,  $\alpha = 3637$ , 重构模态  $N = 2$ .

表 4 给出了 4 种算法对应的信噪比 (SNR) 和均方误差 (MSE). 从表 4 可以看出, EFPSO-VMD 算法的  $\text{SNR} = 28.6010$ ,  $\text{MSE} = 0.2351$ , 其中 SNR 是所有值中最大的, MSE 是所有值中最小的. 两个性能指标表明, EFPSO-VMD 算法可以有效地将噪声信号与管道信号分离开来.

图 12~15 分别给出了 EMD、VMD、PSO-VMD 和 EFPSO-VMD 去噪算法重构后的管道信号, 从图中可以看出, EMD 算法去除了部分有效的管道信号, VMD 算法和 PSO-VMD 算法重构的管道信号仍含有少量噪声信号, 而 EFPSO-VMD 算法既保留了原始信号的特性, 又有效地去除了噪声信号, 从

表 4 测试算法的信噪比和均方误差  
Table 4 SNR and MSE of test algorithm

算法	信噪比 (dB)	均方误差
EMD	28.3163	0.2429
VMD	28.4436	0.2394
PSO-VMD	28.4799	0.2384
本文算法	<b>28.6010</b>	<b>0.2351</b>




图 12 EMD 算法去噪后的现场管道信号  
Fig. 12 Pipeline signal denoised by EMD algorithm




图 13 VMD 算法去噪后的现场管道信号  
Fig. 13 Pipeline signal denoised by VMD algorithm

而进一步验证了本文提出算法的有效性和优越性.

此外, 图 16 中给出了 EFPSO 优化 VMD 的收敛曲线, 从图 16 中可以看出, 整个优化过程是快速收敛的.

## 5 结束语

本文提出了一种新的粒子群优化算法 (EFPSO), 事件触发策略和全信息策略的使用有效地避免了早熟收敛和粒子陷入局部最优的问题. 事件触发策略的引入充分利用了粒子的空间特性, 保证了粒子的搜索和收敛性能之间的动态平衡; 全信息策略的考




图 14 PSO-VMD 算法去噪后的现场管道信号  
Fig. 14 Pipeline signal denoised by PSO-VMD algorithm




图 15 EFPSO-VMD 算法去噪后的现场管道信号  
Fig. 15 Pipeline signal denoised by EFPSO-VMD algorithm




图 16 EFPSO 优化的 VMD 去噪算法适应度函数收敛曲线  
Fig. 16 Convergence curve of the EFPSO optimized VMD denoising algorithm

虑有效地利用了粒子的过去信息, 扩大了搜索空间, 这有助于粒子跳出局部最优. 仿真实验表明, 从种群多样性、成功率和收敛率等方面对比发现 EFPSO



算法优于其他经典算法. 最后, 提出了一种基于 EFP-SO 优化的 VMD 去噪算法, 成功应用于现场管道信号去噪中, 实验结果验证了提出算法的实用性和有效性. 未来的研究方向可从以下几个方面展开: 1) 本文选取的是静态事件触发机制, 未来可以考虑应用动态事件触发策略, 进一步增强算法的性能; 2) 如何将提出的算法应用在管道泄漏检测和管道寿命预测以及故障诊断等方向中.

## References

- Wang C, Han F, Zhang Y, Lu J Y. An SAE-based resampling SVM ensemble learning paradigm for pipeline leakage detection. *Neurocomputing*, 2020, **403**: 237–246
- Wang Dong-Feng, Meng Li. Performance analysis and parameter selection of PSO algorithms. *Acta Automatica Sinica*, 2016, **42**(10): 1552–1561  
(王东风, 孟丽. 粒子群优化算法的性能分析和参数选择. *自动化学报*, 2016, **42**(10): 1552–1561)
- Shi Y H, Eberhart R C. Parameter selection in particle swarm optimization. In: Proceedings of the 7th International Conference on Evolutionary Programming. San Diego, USA: ACM, 1998. 591–600
- Ratnaweera A, Halgamuge S K, Watson H C. Self-organizing hierarchical particle swarm optimizer with time-varying acceleration coefficients. *IEEE Transactions on Evolutionary Computation*, 2004, **8**(3): 240–255
- Liu W B, Wang Z D, Yuan Y, Zeng N Y, Hone K, Liu X H. A novel Sigmoid-function-based adaptive weighted particle swarm optimizer. *IEEE Transactions on Cybernetics*, 2021, **51**(2): 1085–1093
- Jana B, Mitra S, Acharyya S. Repository and mutation based particle swarm optimization (RMPSO): A new PSO variant applied to reconstruction of gene regulatory network. *Applied Soft Computing*, 2019, **74**: 330–355
- Liu B, Wang L, Jin Y H, Tang F, Huang D X. Improved particle swarm optimization combined with chaos. *Chaos, Solitons and Fractals*, 2005, **25**(5): 1261–1271
- Kennedy J, Mendes R. Population structure and particle swarm performance. In: Proceedings of the Congress on Evolutionary Computation. Honolulu, HI, USA: IEEE, 2002. 1671–1676
- Zeng N Y, Wang Z D, Liu W B, Zhang H, Hone K, Liu X H. A dynamic neighborhood-based switching particle swarm optimization algorithm. *IEEE Transactions on Cybernetics*, 2022, **52**(9): 9290–9301
- Dong H L, Hou N, Wang Z D, Ren W J. Variance-constrained state estimation for complex networks with randomly varying topologies. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, **29**(7): 2757–2768
- Dong H L, Hou N, Wang Z D. Fault estimation for complex networks with randomly varying topologies and stochastic inner couplings. *Automatica*, 2020, **112**: Article No. 108734
- Moslehi F, Haeri A, Martínez-Álvarez F. A novel hybrid GA-PSO framework for mining quantitative association rules. *Soft Computing*, 2020, **24**: 4645–4666
- Wu Z H, Wu Z C, Zhang J. An improved FCM algorithm with adaptive weights based on SA-PSO. *Neural Computing and Applications*, 2017, **28**(10): 3113–3118
- Liu W B, Wang Z D, Liu X H, Zeng N Y, Bell D. A novel particle swarm optimization approach for patient clustering from emergency departments. *IEEE Transactions on Evolutionary Computation*, 2018, **23**(4): 632–644
- Zeng N Y, Wang Z D, Zhang H, Alsaadi F E. A novel switching delayed PSO algorithm for estimating unknown parameters of lateral flow immunoassay. *Cognitive Computation*, 2016, **8**(2): 143–152
- Song B Y, Wang Z D, Zou L. On global smooth path planning for mobile robots using a novel multimodal delayed PSO algorithm. *Cognitive Computation*, 2017, **9**(1): 5–17
- Dragomiretskiy K, Zosso D. Variational mode decomposition. *IEEE Transactions on Signal Processing*, 2013, **62**(3): 531–544
- Kennedy J, Eberhart R C. Particle swarm optimization. In: Proceedings of the IEEE International Conference on Neural Networks. Perth, Australia: IEEE, 1995. 1942–1948
- Shi Y H, Eberhart R C. Empirical study of particle swarm optimization. In: Proceedings of the IEEE Congress on Evolutionary Computation. Washington, DC, USA: ACM, 1999. 1945–1950
- Li J H, Dong H L, Wang Z D, Bu X Y. Partial-neurons-based passivity-guaranteed state estimation for neural networks with randomly occurring time-delays. *IEEE Transactions on Neural Networks and Learning Systems*, 2020, **31**(9): 3747–3753
- Dong H L, Wang Z D, Shen B, Ding D R. Variance-constrained  $H_\infty$  control for a class of nonlinear stochastic discrete time-varying systems: The event-triggered design. *Automatica*, 2016, **72**: 28–36
- Wang C, Zhang Y, Song J B, Liu Q Q, Dong H L. A novel optimized SVM algorithm based on PSO with saturation and mixed time-delays for classification of oil pipeline leak detection. *Systems Science and Control Engineering*, 2019, **7**(1): 75–88
- Clerc M, Kennedy J. The particle swarm: Explosion, stability, and convergence in a multi-dimensional complex space. *IEEE Transactions on Evolutionary Computation*, 2002, **6**(1): 58–73
- Liu Jian-Chang, Quan He, Yu Xia, He Kan, Li Zhen-Hua. Rolling bearing fault diagnosis based on parameter optimization VMD and sample entropy. *Acta Automatica Sinica*, 2022, **48**(3): 808–819  
(刘建昌, 权贺, 于霞, 何侃, 李镇华. 基于参数优化 VMD 和样本熵的滚动轴承故障诊断. *自动化学报*, 2022, **48**(3): 808–819)
- He Xiao, Guo Ya-Qi, Zhang Zhao, Jia Fan-Lin, Zhou Dong-Hua. Active fault diagnosis for dynamic systems. *Acta Automatica Sinica*, 2020, **46**(8): 1557–1570  
(何潇, 郭亚琦, 张召, 贾繁林, 周东华. 动态系统的主动故障诊断技术. *自动化学报*, 2020, **46**(8): 1557–1570)
- Tang Gui-Ji, Wang Xiao-Long. Parameter optimized variational mode decomposition method with application to incipient fault diagnosis of rolling bearing. *Journal of Xi'an Jiaotong University*, 2015, **49**(5): 73–81  
(唐贵基, 王晓龙. 参数优化变分模态分解方法在滚动轴承早期故障诊断中的应用. *西安交通大学学报*, 2015, **49**(5): 73–81)



王 闯 东北石油大学博士研究生.  
主要研究方向为深度学习与管道完整性分析.  
E-mail: wangchuang64@126.com  
(WANG Chuang Ph.D. candidate  
at Northeast Petroleum University.  
His research interest covers deep  
learning and pipeline integrity analysis.)



**韩非** 东北石油大学人工智能能源研究院教授. 2017 年获得上海理工大学系统分析与集成专业博士学位. 主要研究方向为分布式滤波与控制, 深度学习和强化学习.

E-mail: tomcumt@126.com

**(HAN Fei** Professor at the Artificial Intelligence Energy Research Institute, Northeast Petroleum University. He received his Ph.D. degree in system analysis and integration from University of Shanghai for Science and Technology in 2017. His research interest covers distributed filtering and control, deep learning, and reinforcement learning.)



**申雨轩** 东北石油大学人工智能能源研究院副教授. 2020 年获得东华大学控制科学与工程专业博士学位. 主要研究方向为网络化系统的滤波与控制.

E-mail: shenyuxuan5973@163.com

**(SHEN Yu-Xuan** Associate professor at the Artificial Intelligence Energy Research Institute, Northeast Petroleum University. He received his Ph.D. degree in control science and engineering from Donghua University in 2020. His research interest covers filtering and control of networked systems.)



**李学贵** 东北石油大学计算机与信息技术学院副教授. 2017 年获得东北石油大学地质资源与地质工程专业博士学位. 主要研究方向为深度学习和大数据分析, 微地震监测技术.

E-mail: lixg82@163.com

**(LI Xue-Gui** Associate professor at the School of Computer and Information Technology, Northeast Petroleum University. He received his Ph.D. degree in geological resources and geological engineering from Northeast Petroleum University in 2017. His research interest covers deep learning and big data analysis, and microseismic monitoring technology.)



**董宏丽** 东北石油大学人工智能能源研究院教授. 2012 年获得哈尔滨工业大学控制科学与工程专业博士学位. 主要研究方向为网络化控制系统, 智能控制, 传感器网络信息处理. 本文通信作者.

E-mail: shiningdhl@gmail.com

**(DONG Hong-Li** Professor at the Artificial Intelligence Energy Research Institute, Northeast Petroleum University. She received her Ph.D. degree in control science and engineering from Harbin Institute of Technology in 2012. Her research interest covers networked control system, intelligent control, and sensor network information processing. Corresponding author of this paper.)