

# Journal of System Simulation

---

Volume 29 | Issue 10

Article 2

---

6-4-2020

## Adaptive Mutative Scale Chaos Particles Swarm Optimization Based on Logistic Mapping

Yanyang Zeng

*College of Computer Science and Technology of Henan Polytechnic University, Jiaozuo 454000, China;*

Yunxia Feng

*College of Computer Science and Technology of Henan Polytechnic University, Jiaozuo 454000, China;*

Wentao Zhao

*College of Computer Science and Technology of Henan Polytechnic University, Jiaozuo 454000, China;*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>

 Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

---

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

---

# Adaptive Mutative Scale Chaos Particles Swarm Optimization Based on Logistic Mapping

## Abstract

**Abstract:** To overcome the shortcomings of Particle Swarm Optimization (PSO), an Adaptive Mutative Scale Chaos Particles Swarm Optimization (ACPSO) based on Logistic Mapping was proposed. *The chaos method was used to initialize the particles. The adjustment method of the inertia weight depended on the particle's fitness; it could avoid premature convergence for the particles. When the particles fell into the local optimum, mutative scale chaos optimization strategy was adopted to adjust the optimal particles.* To test the effectiveness of the algorithm, three representative algorithms were compared with. The results show that the algorithm has high convergence speed and high precision.

## Keywords

PSO, mutative scale, chaos optimization, adaptive adjustment, learning factor, inertia weight

## Recommended Citation

Zeng Yanyang, Feng Yunxia, Zhao Wentao. Adaptive Mutative Scale Chaos Particles Swarm Optimization Based on Logistic Mapping[J]. Journal of System Simulation, 2017, 29(10): 2241-2246.

# 基于 logistic 映射的自适应变尺度混沌粒子群算法

曾艳阳, 冯云霞, 赵文涛

(河南理工大学计算机科学与技术学院, 焦作 454000)

**摘要:** 为克服粒子群优化算法(Particle Swarm Optimization, PSO)存在的缺陷, 提出基于 Logistic 映射的自适应变尺度混沌粒子群优化算法(Adaptive Chaos PSO, ACPSO)。采用混沌方法对粒子进行初始化; 根据不同状态下粒子适应值的大小对惯性权重采取不同的调整方法; 异步变化的学习因子使粒子随着迭代步数的增加, 避免粒子发生早熟收敛现象; 当粒子陷入局部最优时, 对部分较优粒子采用变尺度混沌局部优化策略。为了检验算法的有效性, 将该算法与 3 种有代表性的算法进行比较, 结果表明该算法收敛速度快, 求解精度高。

**关键词:** 粒子群优化; 变尺度; 混沌优化; 自适应; 学习因子; 惯性权重

中图分类号: TP391.9 文献标识码: A 文章编号: 1004-731X (2017) 09-2241-06

DOI: 10.16182/j.issn1004731x.joss.201710002

## Adaptive Mutative Scale Chaos Particles Swarm Optimization Based on Logistic Mapping

Zeng Yanyang, Feng Yunxia, Zhao Wentao

(College of Computer Science and Technology of Henan Polytechnic University, Jiaozuo 454000, China)

**Abstract:** To overcome the shortcomings of Particle Swarm Optimization (PSO), an Adaptive Mutative Scale Chaos Particles Swarm Optimization (ACPSO) based on Logistic Mapping was proposed. The chaos method was used to initialize the particles. The adjustment method of the inertia weight depended on the particle's fitness; it could avoid premature convergence for the particles. When the particles fell into the local optimum, mutative scale chaos optimization strategy was adopted to adjust the optimal particles. To test the effectiveness of the algorithm, three representative algorithms were compared with. The results show that the algorithm has high convergence speed and high precision.

**Keywords:** PSO; mutative scale; chaos optimization; adaptive adjustment; learning factor; inertia weight

## 引言

粒子群优化算法(PSO)由 Eberhart 和 Kennedy 提出, 该算法的优点是操作简单, 不需要调整太多参数, 容易实现。但是算法后期种群多样性差, 进化速度慢, 易出现停滞现象, 在应用过程中, 经常

会陷入局部最优而发生早熟收敛现象<sup>[1-2]</sup>。

由于在一定范围内, 混沌变量具有遍历性和随机性特点, 研究者提出混沌粒子群优化算法(Chaos Particle Swarm Optimization, CPSO)<sup>[3-4]</sup>, 来改善粒子群算法易陷入局部最优解, 收敛精度低的现状。文献[5]通过计算粒子群适应度方差, 对粒子进行混沌更新, 进而避免粒子群过早收敛。文献[6]采用混沌方法对部分种群进行初始化, 并动态改变混沌的控制参数。文献[7]用混沌方法更新劣质粒子的速度, 进而提高粒子群优化能力。

惯性权重和学习因子的设置对于粒子群优化



收稿日期: 2017-05-18 修回日期: 2017-07-17;  
基金项目: 国家自然科学基金(61503124), 高等学校  
重点科研项目(15A520018);  
作者简介: 曾艳阳(1987-), 男, 河南固始, 博士,  
讲师, 硕导, 研究方向为仿真方法及应用; 冯云霞  
(1991-), 女, 河南修武, 硕士生, 研究方向为智能优  
化、体绘制。

算法也是十分重要的，参数设置的好坏，会影响到算法的收敛速度和实验结果的精度。通过调节惯性权重和学习因子，进而更好的平衡算法的全局和局部搜索能力。但是固定的惯性权重和学习因子容易导致优化效果不够理想。文献[8]提出了一种线性递减的惯性权重法，该方法在一定程度上提高了算法的搜索能力。但是算法中惯性权重的变化只与迭代次数线性相关，并没考虑到粒子适应值的好坏。文献[9]利用粒子之间距离提供的信息来判断粒子所处的状态，根据状态的不同从而采用不同的参数调整方案。文献[10]采用一种自适应惯性权重方法(Adaptive Particle Swarm Optimization, APSO)，根据当前粒子适应值的不同，对粒子的惯性权重采用不同的确定方法。

本文将自适应惯性权重法和混沌粒子群算法相结合，并且对学习因子采取异步变换的学习因子法，在不同状态下对惯性权重采取不同的调节方法，以调整算法在求解空间内的全局和局部搜索能力。最后，结合早熟收敛判断机制对部分较优粒子进行变尺度混沌局部策略，从而使得算法的收敛速度更快，求解精度更高。

## 1 经典粒子群优化算法

假设这样一个场景：有一群鸟在空间中寻找食物，该空间只有一个食物，每只鸟都不知道食物在哪，但是它们每飞行一次，它们知道目前自己的位置，自己和食物之间的距离以及空间中离食物最近的鸟的位置。为了快速找到食物，它们不断搜索距离食物最近的鸟的周围区域。

在粒子群中，每个粒子都有一个速度，该速度决定了粒子飞行的方向和距离。设在  $d$  维搜索空间中， $\mathbf{X}^i = (x_{i1}, x_{i2}, \dots, x_{id})$  和  $\mathbf{V}^i = (v_{i1}, v_{i2}, \dots, v_{id})$  分别表示第  $i$  个粒子的位置和速度，在迭代时，粒子通过跟踪个体极值  $\mathbf{p}_b$  和全局最优解  $\mathbf{p}_g$  来调整自己新的位置。其中， $\mathbf{p}_b^i = (p_{i1}, p_{i2}, \dots, p_{id})$ ， $\mathbf{p}_g = (p_{g1}, p_{g2}, \dots, p_{gd})$ 。粒子的速度和位置根据公式(1)(2)进行更新。

$$\begin{aligned} v_{ij}(t+1) &= \omega v_{ij}(t) + c_1 r_1 [p_{ij} - x_{ij}(t)] + \\ &\quad c_2 r_2 [p_{gi} - x_{ij}(t)] \end{aligned} \quad (1)$$

$$x_{ij}(t+1) = x_{ij}(t) + v_{ij}(t+1) \quad j = 1, 2, \dots, d \quad (2)$$

式中： $\omega$  为惯性权重； $c_1$ 、 $c_2$  分别代表正的自我学习因子和社会学习因子； $r_1$ 、 $r_2$  为 0~1 之间均匀分布的随机数； $v_{ij}(t+1)$  表示在  $t+1$  次迭代中，第  $i$  个粒子在第  $j$  维的速度； $x_{ij}(t+1)$  表示在  $t+1$  次迭代中，第  $i$  个粒子在第  $j$  维的位移。

## 2 ACPSO 算法的主要思想

### 2.1 基于 Logistic 映射的粒子群混沌初始化

粒子群的初始化对 PSO 算法的收敛速度和解质量的精确度非常重要。在粒子群初始化时，由于没有任何先验知识可利用，粒子的位置和速度一般采取随机初始化的方法来确定。这样虽然在一定程度上保证了粒子群的随机分布，但是有些粒子由于远离最优解，从而会影响算法的收敛速度。而混沌运动在其混沌吸引域内是各态历经的，且又不会失去粒子群初始化的随机性要求。利用这一特点，在初始化种群位置和速度时，采用 Logistic 映射，这是一种经典的混沌映射，其表达式如下：

$$z_{k+1} = \mu z_k (1 - z_k) \quad z_k \in (0, 1) \quad (3)$$

式中： $\mu \in (2, 4]$  为混沌参数， $\mu$  越大，混沌性越高。

### 2.2 自适应调整参数策

#### 2.2.1 惯性权重 $\omega$ 的调整策略

**定义 1：**

$p_g$ ：当代全局最优解

$\bar{f}$ ：当代所有粒子适应值的平均值

$f_p$ ：当代所有比  $\bar{f}$  适应值好的粒子适应值的平均值

$f_i$ ：当代第  $i$  个粒子的适应值

(1) 当  $f_i < f_p$  时，此时粒子距离最优粒子较近，为了避免速度过大而跳过最佳位置，此时惯性权重应给予一个较小的值，惯性权重表达式如下：

$$\omega = \omega_{med} - \left| \frac{f_i - fp}{p_g - fp} \right| \times (\omega_{med} - \omega_{min}) \quad (4)$$

$$\omega_{med} = \frac{\omega_{max} + \omega_{min}}{2}$$

(2) 当  $f_i > \bar{f}$  时, 此时粒子距离最优粒子比较远, 该粒子较不理想。为了让该粒子尽快靠近最优粒子, 应该给予一个相对较大的惯性权重, 从而获得较大的速度, 此时惯性权重表达式如下:

$$\omega = \omega_{med} + \frac{(\omega_{max} - \omega_{min})}{2} \times rand \quad (5)$$

(3) 当  $\bar{f} < f_i < fp$  时, 该类粒子优劣程度介于(1)(2)之间, 此时惯性权重采用非线性增长策略, 表达式如下:

$$\omega = \omega_{max} - (\omega_{max} - \omega_{min}) \times \frac{t}{T} \quad (6)$$

### 2.2.2 学习因子 $c_1$ 、 $c_2$ 的调整策略

在 PSO 算法中, 学习因子赋予粒子自我总结能力和向全局最优粒子学习的能力。本文采用异步变化的学习因子,  $c_1$ 、 $c_2$  公式如下:

$$c_1 = 2.4 - \frac{1.4t}{T} \quad (7)$$

$$c_2 = 0.9 + \frac{1.6t}{T}$$

从式中可以看出, 学习因子  $c_1$  随着迭代次数的增加线性递减,  $c_2$  线性递增。在优化的初期,  $c_1$  较大,  $c_2$  较小, 有利于加强全局搜索能力, 在优化后期,  $c_2$  逐渐增大,  $c_1$  不断减小, 有利于收敛到全局最优解。

### 2.3 早熟收敛判断方法

随着迭代步数的不断增加, 粒子之间的差异逐渐变小, 即等价于粒子适应值相差越来越小。文中采用种群适应度的方差  $\delta^2$  判断粒子是否早熟收敛, 其表达式如下:

$$\delta^2 = \sum_{i=1}^M \left[ \frac{f_i - \bar{f}}{f} \right]^2 \quad (8)$$

$$f = \begin{cases} \max \left\{ \left| f_i - \bar{f} \right| \right\} & \left( \max \left\{ \left| f_i - \bar{f} \right| \right\} \geq 1 \right) \\ 1 & \text{(其他)} \end{cases}$$

式中:  $f_i$  为第  $i$  个粒子的适应度;  $\bar{f}$  为当代粒子的平均适应度;  $\delta^2$  为当代粒子群适应度方差;  $f$  为归一化因子。

### 2.4 基于 Logistic 映射的变尺度混沌局部搜索

本文将变尺度混沌优化方法与 PSO 算法相结合, 利用混沌的随机性和遍历性等优点, 从而提高粒子群算法的精度和收敛速度。当粒子群发生早熟收敛现象时, 在适应度较好的粒子周围进行局部搜索, 使得这些粒子找到更好的位置。为了提高局部搜索效率, 随着迭代步数的增加, 逐渐变小搜索范围。变尺度混沌局部搜索的主要步骤如下:

(1) 按下式减小混沌变量的搜索范围;

$$\begin{cases} x_{min,j}^{m+1} = \max \{x_{min,j}^m, p_{i,j} - \phi(x_{max,j}^m - x_{min,j}^m)\} \\ x_{max,j}^{m+1} = \min \{x_{max,j}^m, p_{i,j} + \phi(x_{max,j}^m - x_{min,j}^m)\} \end{cases}$$

式中:  $m$  为已进行局部搜索的次数;  $p_{i,j}$  为第  $i$  个粒子的个体极值  $p_b^i$  在第  $j$  维的分量;  $\phi$  为搜索因子, 表达式如下:

$$\phi = \exp \left( \frac{-1}{|x_{max,j}^m - x_{min,j}^m|} \right)$$

(2) 将较优粒子的初始混沌变量  $cx_j^k$  按式(3)产生下一代混沌变量  $cx_j^{k+1}$ , 并且根据下式转换成新的混沌变量  $cx_j'$ :

$$cx_j' = \beta \times cx_j^{k+1} + (1 - \beta) \times Q_{i,j}^*$$

式中:  $Q_{i,j}^*$  为个体极值  $p_{i,j}$  映射到搜索区域  $[x_{min,j}^{m+1}, x_{max,j}^{m+1}]$  的混沌变量;  $\beta$  为自适应调节系数, 其表达式分别为:

$$Q_{i,j}^* = \frac{p_{i,j} - x_{min,j}^{m+1}}{x_{max,j}^{m+1} - x_{min,j}^{m+1}}$$

$$\beta = 1 - \left( \frac{k-1}{k} \right)^\eta$$

式中:  $\eta$  为正整数, 其值由目标函数决定;  $k$  为混沌搜索的迭代次数。

(3) 将  $cx_j'$  按下式转换成新的决策变量  $x_j'$ 。

$$x_{i,j}' = x_{min,j}^{m+1} + cx_j' (x_{max,j}^{m+1} - x_{min,j}^{m+1})$$

(4) 得到新  $X'_i = (p_{i,1}, p_{i,2}, \dots, x'_{i,j}, \dots, p_{i,d})$ , 若  $f(X'_i) < f(p_b^i)$ , 则  $p_b^i = X'_i$ ; 若  $f(X'_i) < f(p_g)$ , 则  $p_g = X'_i$ ; 否则  $k=k+1$  转向(2)。当  $k$  超过最大混沌迭代次数  $C_{\max}$  时,  $j=j+1$ , 并转向(1); 当  $j>d$  时, 结束混沌局部搜索。

### 3 算法的具体描述

在经典粒子群优化算法中, 当粒子找到全局最优解时, 邻域中的其它粒子会快速向该粒子移动。如果该粒子是局部最优解, 此时该算法容易陷入局部最优。为了改变这种现状, 本文使用混沌优化方法获得更加合理的初始粒子; 将粒子适应度方差作为粒子早熟收敛判断的机制, 若方差小于设定阈值并且满足混沌搜索条件, 采用变尺度混沌方法对适应度较好的前 20% 粒子进行处理, 从而获得更优粒子; 使用自适应惯性权重法保证惯性权重的多样性和有效性; 使用异步变换的学习因子法, 使粒子随着迭代次数的增加粒子社会学习能力增加和自我学习能力减小, 有利于收敛到全局最优解。

本文的算法步骤如下:

输入: 粒子个数  $M$ , 粒子维数  $d$ , 算法迭代次数  $T$ , 混沌迭代次数  $C_{\max}$ , 阈值  $\sigma$

输出: 全局最优解  $p_g$

1) 设置算法参数, 利用基于 Logistic 映射对

粒子的速度和位置进行初始化。

2) 计算各粒子适应度  $f_i$ , 将粒子的初始化位置作为个体最优位置  $p_b$ , 将所有个体中适应值最优粒子的位置作为全局最优位置  $p_g$ 。

3) 根据公式(4)~(6)计算惯性权重  $\omega$ , 公式(7)计算学习因子  $c_1$ 、 $c_2$ 。

4) 按公式(1)(2)更新粒子的速度和位置, 再次计算粒子适应值并更新  $p_b$  和  $p_g$ 。

5) 根据式(8)计算粒子群适应度方差  $\delta^2$ 。如果  $\delta^2$  小于阈值  $\sigma$ , 采用变尺度混沌方法对适应度较好的前 20% 粒子进行局部混沌搜索, 搜索结束转向 3); 否则直接转向 3)。

6) 若满足停止条件(迭代次数), 结束搜索, 输出结果, 否则返回 3)继续搜索。

### 4 实验结果与分析

为了验证本文提出的基于 logistic 映射的自适应变尺度混沌粒子群优化算法的有效性, 采用四个经典基准函数对算法性能进行测试, 基准函数见表 1。并且将本文中算法(ACPSO)与基本 PSO 算法, 自适应惯性权重法(APSO), 混沌粒子群优化算法(CPSO)进行对比。算法的实验环境基于 Windows 7 系统, MATLAB 仿真平台, 使用 Inter Core i5-4570 处理器, 主频为 3.2 GHz 的计算机进行的。

表 1 基准函数  
Tab.1 Benchmark function

函数名	函数表达式	搜索区间	理论极值
$f_1$	$f(x) = \sum_{i=1}^n x_i^2$	$[-100, 100]$	$f_{\min}=0$
$f_2$	$f(x) = \sum_{i=1}^n i x_i^4 + \text{random}[0,1]$	$[-25, 25]$	$f_{\min}=0$
$f_3$	$f(x) = \sum_{i=1}^n (x_i^2 - 10 \cos(2\pi x_i) + 10)$	$[-50, 50]$	$f_{\min}=0$
$f_4$	$f(x) = -20 \exp\left(-0.2 \sqrt{\sum_{i=1}^n x_i^2 / n}\right) - \exp\left(\sum_{i=1}^n \frac{\cos(2\pi x_i)}{n}\right) + 20 + e$	$[-32, 32]$	$f_{\min}=0$

在进行对比试验时, 实验次数设为 300, 每次实验的迭代次数为 200, 粒子维度为 30, 粒子个数为 40。实验结果从不同算法在同样的实验环境下

的最小值和平均值两方面进行比较。在 PSO 算法中, 惯性权重  $\omega=0.5$ , 学习因子  $c_1=c_2=2$ 。APSO 采用文献[10]的方法, CPSO 采用文献[5]的方法,

本文阈值  $\sigma=10$ ,  $\omega_{\max}=0.9$ ,  $\omega_{\min}=0.4$ 。实验结果如表 2。为了更直观比较 PSO、APSO、CPSO、ACPSO 四种算法, 图 1 和图 2 分别为函数  $f_2$ 、 $f_3$  的寻优曲线。

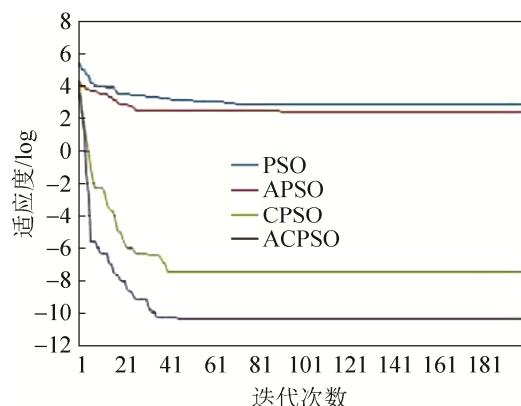


图 1 函数  $f_2$  的寻优曲线  
Fig.1 Optimizing curves of  $f_2$

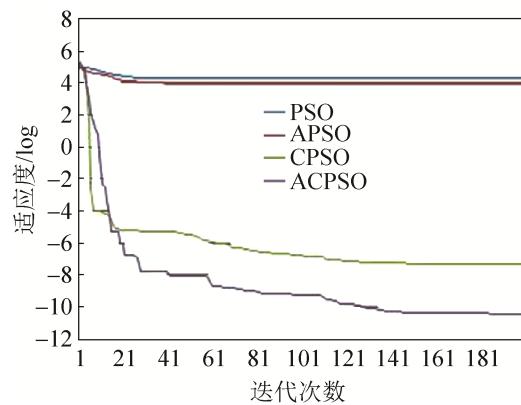


图 2 函数  $f_3$  的寻优曲线  
Fig.2 Optimizing curves of  $f_3$

表 2 中加粗的为本文提出的方法, 可以看出, 在迭代次数、粒子维度、粒子个数相同的条件下, 本文提出的基于 logistic 映射的自适应变尺度混沌粒子群优化算法的求解精度明显高于其他三种算法。图 1 为函数  $f_2$  的寻优曲线, 开始时 CPSO、ACPSO 算法的曲线低于 PSO、和 APSO, 说明混沌初始化方法能够提高该函数初始解的质量。APSO 算法求解精度优于 PSO 算法, 说明采用自适应惯性权重粒子群优化算法可以提高算法初期的寻优能力。从第 5 次迭代开始, ACPSO 算法的求解精度明显高于其它 3 种算法。图 2 为函数  $f_3$

的寻优曲线, 虽然前 16 次 CPSO 算法优于 ACPSO 算法, 但是随着迭代次数的增加, CPSO 算法容易快速陷入局部最优, 而 ACPSO 算法能够快速跳出局部最优, 从而提高算法的求解精度。

表 2 实验结果  
Tab.2 Experimental result

函数名	算法	最小值	平均值
$f_1$	PSO	7.14E+03	5.71E+04
	APSO	2.51E+03	1.25E+04
	CPSO	8.06E-18	2.93E-01
	<b>ACPSO</b>	<b>6.82E-22</b>	<b>7.57E-05</b>
$f_2$	PSO	1.29E+01	6.75E+02
	APSO	1.34E-01	1.03E+02
	CPSO	5.92E-15	5.42E-08
	<b>ACPSO</b>	<b>7.61E-20</b>	<b>5.48E-11</b>
$f_3$	PSO	4.51E+03	1.71E+04
	APSO	7.59E+02	5.81E+03
	CPSO	1.65E-14	3.56E-08
	<b>ACPSO</b>	<b>7.91E-17</b>	<b>6.43E-10</b>
$f_4$	PSO	3.14E-02	7.10E+01
	APSO	8.43E-04	9.83E-01
	CPSO	7.46E-17	4.72E-06
	<b>ACPSO</b>	<b>5.71E-19</b>	<b>6.53E-08</b>

实验结果表明, 该方法可以提高粒子的搜索能力, 根据不同状态下粒子适应值的大小, 对粒子采取不同的惯性权重, 异步变换的学习因子使粒子在算法初期有较大的社会学习能力, 随着迭代步数的增加, 粒子收敛到一定程度, 社会学习能力逐渐减小, 自我学习能力逐渐增大, 从而有利于收敛到全局最优。当粒子陷入局部最优时, 对较优粒子采用变尺度混沌方法, 使粒子跳出局部最优解, 进而提高算法的求解精度。

## 5 结论

基于 logistic 映射的自适应变尺度混沌粒子群优化算法是将自适应惯性权重和混沌方法结合起来的粒子群优化算法。在迭代过程中, 根据当前粒

子适应值的不同,对粒子的惯性权重采用不同的确定方法。当粒子群适应度方差小于阈值时,对较优粒子采用变尺度混沌局部搜索方法,粒子每改变一维坐标,计算其适应度并与该粒子个体极值比较。由仿真结果可知,该方法既保留了混沌粒子群优化算法的优点,又保持了粒子群体的多样性,有效提高了算法的全局搜索能力和收敛性能。

## 参考文献:

- [1] Couceiro M, Ghamisi P. Particle Swarm Optimization [M]// Fractional Order Darwinian Particle Swarm Optimization. Germany: Springer International Publishing, 2016: 149-150.
- [2] Zhang Y, Wang S, Ji G. A Comprehensive Survey on Particle Swarm Optimization Algorithm and Its Applications [J]. Mathematical Problems in Engineering, (S1024-123X), 2015, 2015(1): 1-38.
- [3] 李建美,高兴宝. 基于自适应变异的混沌粒子群优化算法 [J]. 计算机工程与应用, 2016, 52(10): 44-49. (Li Jianmei, Gao Xingbao. Chaotic particle swarm optimization algorithm with adaptive mutation [J]. Computer Engineering and Applications, 2016, 52(10): 44-49.)
- [4] Xu X, Rong H, Trovati M, et al. CS-PSO: Chaotic Particle Swarm Optimization Algorithm for Solving Combinatorial Optimization Problems [J]. Soft Computing (S1432-7643), 2016, 1-13.
- [5] Yong D, Chuansheng W, Haimin G. Particle Swarm Optimization Algorithm with Adaptive Chaos Perturbation [J]. Cybernetics & Information Technologies, (S1311-9702), 2015, 15(6): 70-80.
- [6] 虎涛涛,单要楠. 一种混沌变参数粒子群优化算法 [J]. 自动化仪表, 2017, 38(3): 37-40. (Hu Taotao, Shan Yaonan. A Chaotic Particle Swarm Optimization algorithm with variable parameters [J]. Process Automation Instrumentation, 2017, 38(3): 37-40.)
- [7] Božena Borowska. An Improved CPSO Algorithm [C]// International Scientific and Technical Conference Computer Sciences and Information Technologies (CSIT). Lviv, Ukraine: IEEE, 2016: 1-3.
- [8] Eberhart R C, Shi Y H. Comparing Inertia Weights and Construction Factors in Particle Swarm Optimization [C]// Proceedings of the 2000 Congress on Evolutionary Computation. California, USA: IEEE, 2000: 84-88.
- [9] 李太勇,吴江,朱波,等. 一种基于距离度量的自适应粒子群优化算法 [J]. 计算机科学, 2010, 37(10): 214-216. (Li Taiyong, Wu Jiang, Zhu Bo, et al. Distance measurement based adaptive Particle Swarm Optimization [J]. Computer Science, 2010, 37(10): 214-216.)
- [10] Liu Y. Study on an Improved PSO Algorithm and Its Application for Solving Function Problem [J]. International Journal of Smart Home (S1975-4094), 2016, 10(3): 51-62.

(上接第 2240 页)

- [24] Denil M, Bazzani L, Larochelle H, et al. Learning Where to Attend With Deep Architectures for Image Tracking [J]. Neural Computation (S0899-7667), 2014, 24(8): 2151-2184.
- [25] Rush A M, Chopra S, Weston J, et al. A Neural Attention Model for Abstractive Sentence Summarization [R/OL]. (2015) [2017-08-30]. [http://people.seas.harvard.edu/~srush/emnlp2015\\_slides.pdf](http://people.seas.harvard.edu/~srush/emnlp2015_slides.pdf).
- [26] Vaswani A, Shazeer N, Parmar N, et al. Attention Is All You Need [R/OL]. (2017) [2017-08-30] <http://arxiv.org/pdf/1706.03762.pdf>.
- [27] 马新星,沈同圣,徐健. 一种基于 ROI 的红外舰船目标定位方法 [J]. 红外技术, 2013, 35(11): 702-706. (Ma Xinxing, Shen Tongsheng, Xu Jian. An Object

Localization Algorithm Based on ROI for Ship IR Image [J]. Infrared Technology, 2013, 35(11): 702-706.)

- [28] Xia L, Xing Q H, Fan H X. Threat Evaluation of Air Attack Targets Based on Vague Matter-Element and Entropy Weight [J]. Fire Control & Command Control (S1002-0640), 2012, 37(2): 84-88.
- [29] Zhu Y G, Zhao J J, Xin L. Tank Night Firing Target Selection Based on Entropy Weight and Grey Relation Analysis Process [J]. Fire Control & Command Control (S1002-0640), 2013, 38(8): 76-24.
- [30] Yuan J X, Zhao J F, Dong Z P, et al. Method of Threat Assessment based on Grey Target Theory [J]. Fire Control & Command Control (S1002-0640), 2007, 32(4): 56-58.