

文章编号:1001-9081(2014)07-2085-05

doi:10.11772/j.issn.1001-9081.2014.07.2085

基于爆炸冲击波模型的粒子群优化算法

闫 涛*, 古乐野, 阮 波

(中国科学院 成都计算机应用研究所, 成都 610041)

(*通信作者电子邮箱 yt19870033@163.com)

摘要:针对基本粒子群优化(PSO)算法在解决复杂多峰问题时易于陷入局部最优解的问题,提出一种基于爆炸冲击波模型的PSO算法(简称BW-PSO算法)。该算法通过加入种群多样性监督条件,使得当种群数量缩小至给定阈值时,触发粒子冲击波过程:最优粒子与次优粒子进行交叉变异,处于爆炸半径内的粒子受到牵引力,加速收敛至当前极值;处于爆炸半径外的粒子受到冲击力向外扩散,增加了找到全局最优值的可能性。BW-PSO算法不仅能够通过最优粒子变异操作提升当前解的精度,而且通过粒子冲击波过程,增加了种群多样性,提升了粒子对全局空间开发的能力。实验结果表明,基于爆炸冲击波模型的PSO算法在求解多峰问题表现优于变异PSO算法与带电PSO算法。

关键词:粒子群优化算法;爆炸冲击波;种群多样性;交叉变异;多峰函数

中图分类号: TP18 文献标志码:A

New particle swarm optimization based on blast wave model

YAN Tao*, GU Leye, RUAN Bo

(Chengdu Institute of Computer Applications, Chinese Academy of Sciences, Chengdu Sichuan 610041, China)

Abstract: A new Particle Swarm Optimization (PSO) algorithm based on the blast wave model (referred to as BW-PSO algorithm) was proposed aiming at the problem that the basic PSO algorithm when solving complex multimodal problems is easy to fall into local optimal solution. The supervision conditions of population diversity were added to the basic PSO algorithm so that the process of particle shock was triggered when the population decreased to a given threshold value. Crossover and mutation occurred between optimal and suboptimal particles so that the particles within the blast radius by the traction were subjected to accelerate convergence to the current extreme and the particles outside the blast radius were subjected to spread out, which increased the possibility of finding the global optimum value. BW-PSO algorithm not only improved the accuracy of the current solution by the mutation between optimal and suboptimal particles, but also increased the population diversity with the shock wave process of the particles and enhances the ability of the global space development of the particles. Compared with the mutative PSO and charged PSO, the results indicate that the BW-PSO algorithm has a better performance to solve multi-modal optimization problem.

Key words: Particle Swarm Optimization (PSO) algorithm; blast wave; population diversity; crossover and mutation; multi-modal function

0 引言

粒子群优化(Particle Swarm Optimization, PSO)^[1]算法自1995年被提出以来,由于其设置参数少、算法收敛快、实现容易等优点,受到学术界广泛重视,并在函数优化、工业控制、神经网络、图像处理、模式分类以及其他工程领域得到广泛应用^[2]。

尽管基本PSO在解决大多数优化问题时表现良好,但分析表明,其在解决多峰问题时容易在后期陷入局部最优解,出现早熟现象^[3]。因此运用其他算法的优势弥补PSO的缺陷成为当前研究热点之一。Qin等^[4]将局部搜索算法引入PSO中,防止出现局部最优解聚集现象,但其挖掘全局最优解的能力有限;Liu等^[5]在PSO中加入了鲶鱼效应机制,但易导致种群无法收敛;Robinson等^[6]提出了遗传算法与PSO相结合的混合算法,但是其在迭代后期随着样本学习数量的减少容易导致解的质量下降;Lovberg等^[7]利用交叉算子用两个随机选

择的粒子产生后代,但是假使变异粒子的适应度变差,其他粒子则会被吸引至一个较差解;带电PSO^[8]虽然在解决多峰问题有一定的优势,但其计算复杂度高,实际可操作性有一定的局限。

为了提高PSO在解决复杂多峰问题的解的精度和提升算法的运行效率,本文提出了一种新型物理化PSO模型。模型的创新性在于将爆炸冲击波的物理过程引入算法迭代过程,使粒子在受到个体极值和全局极值影响的基础上,还受到了第三方的冲击波的影响,该算法对于机械平台多参数控制优化有一定的应用价值。

1 爆炸冲击波模型

爆炸冲击波模型的基本思想:当爆炸引发的冲击波到达x点时,x受到压力会瞬时升高到一个峰值,即此点受冲击的速度和动压达到峰值,当上升持续一定的时间后,压力开始下

收稿日期:2013-12-30;修回日期:2014-02-12。

作者简介:闫涛(1987-),男,山西忻州人,硕士研究生,主要研究方向:图像处理; 古乐野(1960-),男,重庆人,研究员,博士生导师,主要研究方向:嵌入式系统、图像处理; 阮波(1971-),男,重庆人,副教授,主要研究方向:图像处理。

降,直至到达零点,压力低于波前静止的大气压,出现负压, x 点的速度则与原先的冲击方向同向转为反向,最后逐渐降为零点^[9]。

冲击波典型波形见图 1。受爆炸冲击波过程启发,横轴时间 T 类比 PSO 中粒子与最佳位置点之间距离,采用欧氏距离表示;纵轴压力 P 类比 PSO 中各粒子所受到的冲击力强度;在 t_1 时间段,处于爆炸半径外的粒子受到爆炸冲击波向外扩散冲击力;在 t_2 时间段,处于爆炸半径内的粒子受到牵引力。

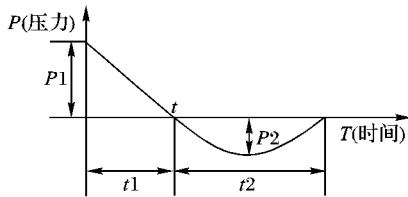


图 1 冲击波典型波形

2 爆炸冲击波 PSO 算法

2.1 算法介绍

爆炸冲击波 PSO (PSO algorithm based on the Blast Wave, BW-PSO) 算法基本思想:将粒子个体假设为爆炸冲击波中受到冲击后的物体,分析物体受冲击后的响应用以模拟粒子的迭代过程。具体过程如下:

1) 初始阶段。运行标准 PSO 算法,每次迭代过程结束对种群多样性进行评价。

2) 触发阶段。当发现种群多样性下降至预先设定的阈值时,触发爆炸冲击波 PSO 过程。

3) 爆炸阶段。最优粒子(P_{best})和次优粒子(次 P_{best})进行交叉变异,提升当前极值解的准确性。通过计算剩余粒子到最优粒子的欧氏距离,将剩余粒子划分为两大类,爆炸半径内粒子受到中心的牵引力(类比于冲击波模型的负压),提高粒子收敛到当前极值的速度;爆炸半径外的粒子受到中心的冲击力(类比于冲击波模型的超压),扩展了粒子多样性。粒子爆炸冲击波过程示意图见图 2。

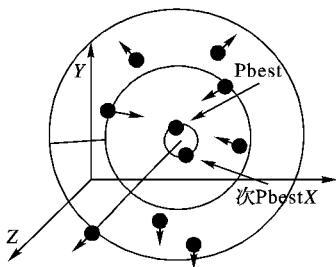


图 2 爆炸冲击波 PSO 过程

4) 结束阶段。当粒子运行到指定迭代次数时停止。

2.2 关键过程

2.2.1 种群多样性度量

一个基于种群的优化算法中,种群多样性是一项非常重要的指标,因为较高的种群多样性意味着较大的探索空间^[10],种群多样性经常被用于度量算法的运行效率。本文算法中,种群多样性为算法过程关键的控制因素。对于种群多样性度量的指标,采用 Riget 等^[11]提出的度量方法,见式(1):

$$diversity(S(t)) = \frac{1}{diameter(S(t)) \cdot N} \sum_{i=1}^N \sqrt{\sum_{j=1}^{n_x} (x_{ij}(t) - \bar{x}_j(t))^2} \quad (1)$$

式中: $diameter(S(t))$ 是种群直径,即种群中相隔最远的粒子之间的距离,这里采用欧氏距离计算; N 为种群粒子个数, n_x 为粒子搜索空间维数。

2.2.2 最优粒子变异

BW-PSO 算法的变异操作只针对最优粒子与次优粒子展开,从而缩小了粒子收敛到较差解的范围,对局部区域的最优值进行更好的挖掘。

当触发爆炸冲击波过程时,首先要进行最优粒子和次优粒子的交叉变异,相应的位置更新按照 Lovberg 等提出的公式进行计算:

$$x_{ii}(t+1) = r(t)x_{ii}(t) + (1-r(t))x_{i2}(t) \quad (2)$$

$$x_{i2}(t+1) = r(t)x_{i2}(t) + (1-r(t))x_{ii}(t) \quad (3)$$

速度更新为:

$$v_{ii}(t+1) = \frac{v_{ii}(t) + v_{i2}(t)}{\|v_{ii}(t) + v_{i2}(t)\|} \|v_{ii}(t)\| \quad (4)$$

$$v_{i2}(t+1) = \frac{v_{i2}(t) + v_{ii}(t)}{\|v_{i2}(t) + v_{ii}(t)\|} \|v_{i2}(t)\| \quad (5)$$

2.2.3 冲击波函数

除最优粒子与次优粒子外的其他粒子受到冲击波的影响,设定爆炸内核半径系数 r ,内核半径内的粒子受到中心最优粒子的牵引力,内核半径外的粒子受到爆炸向外的冲击力。所以在速度更新项中引入第三项,见式(6):

$$v = c \cdot f(\lambda, x) \cdot r_3 \quad (6)$$

$$f(\lambda, x) = \frac{1}{1 + \exp(-(\text{Sign}(x)/x)\lambda)} \quad (7)$$

$$x = \frac{P_{Best}(t) - P_i(t)}{P_{Best}(t) - P_{Far}(t)} \quad (8)$$

$$\text{Sign}(x) = \begin{cases} -1, & x < 1/r \\ 1, & x \geq 1/r \end{cases} \quad (9)$$

式(6)中包含三部分:1) 冲击波函数: $f(\lambda, x)$ 中 λ 为放大系数, x 为距离尺度因子;式(8)中 $p_{Best}(t)$ 为当前代最优粒子的位置, $p_{Far}(t)$ 为距离 $p_{Best}(t)$ 最远的粒子;式(9)中 r 为爆炸半径系数。通过选取适当的参数,当粒子处于爆炸内核半径内时,爆炸会对粒子产生牵引力,从而增强了局部搜索能力,加速收敛;当粒子处于爆炸内核半径外时,粒子收到了爆炸冲击力,此时冲击力强度增大,粒子增强了向外扩散的能力,从而增强了种群多样性,提升了找到更优解的可能性;2) 随机成分: r_3 ,使得种群尽可能地均匀分布;3) 加速度常量 c : 用来度量冲击波对粒子速度造成的影响。

更新后的粒子速度和位置公式为:

$$v = wv + c_1r_1(p_{Best} - x) + c_2r_2(n_{Best} - x) + c \cdot f(\lambda, x) \cdot r_3 \quad (10)$$

$$x = x + \Delta t \quad (11)$$

算法流程见图 4。

3 实验分析

3.1 实验平台

为了测试本文算法的运行效率和性能,选择 6 个常用检测函数进行验证,分别是单峰函数 Sphere,多峰函数 Rosenbrock、Ackley、Geiewank、Rastrigin 和 JD Schaffer。各函数的参数见表 1。

表1 各检测函数参数

函数	函数表达式	搜索空间	最小值坐标	全局最小值
Sphere	$f(x) = \sum_{i=1}^n x_i^2$	$ x_i \leq 100$	$x_i = 0$	0
Rosenbrock	$f(x) = \sum_{i=1}^{n-1} [100(x_i^2 - x_{i+1})^2 + (x_i - 1)^2]$	$ x_i \leq 30$	$x_i = 1$	0
Ackley	$f(x) = -20\exp\left(-0.2\sqrt{\frac{1}{n}\sum_{i=1}^n x_i^2}\right) - \exp\left(\frac{1}{n}\sum_{i=1}^n \cos(2\pi x_i)\right) + 20 + e$	$ x_i \leq 32$	$x_i = 0$	0
Geiewank	$f(x) = \sum_{i=1}^n \frac{x_i^2}{4000} - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	$ x_i \leq 600$	$x_i = 0$	0
Rastrigin	$f(x) = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10]$	$ x_i \leq 5.12$	$x_i = 0$	0
JD Schaffer	$f(x) = \sum_{i=0}^{n-1} \frac{\sin^2 \sqrt{x_i^2 + x_{i+1}^2} - 0.5}{[1 + 0.001(x_i^2 + x_{i+1}^2)]^2} - 0.5$	$ x_i \leq 100$	$x_i = 0$	-1

注: $i = 1, 2, \dots, n$ 。

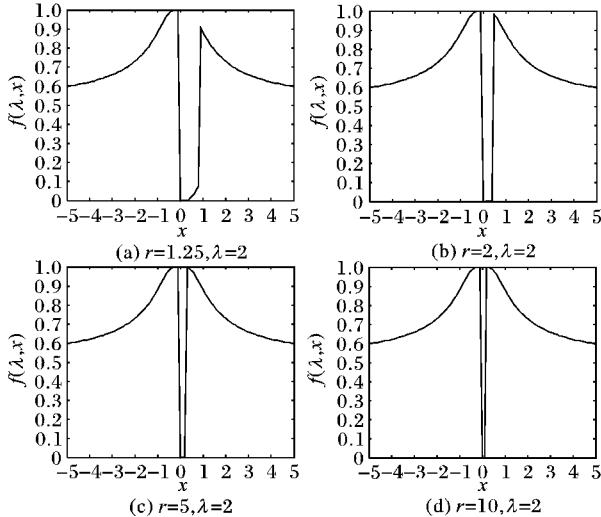
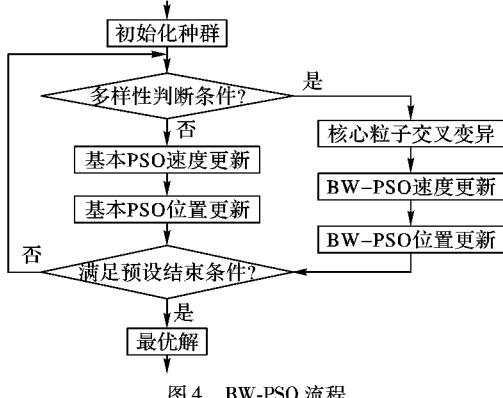
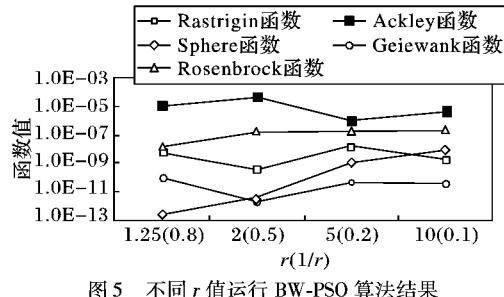
图3 不同 r 值的冲击函数图形

图4 BW-PSO 流程

3.2 爆炸冲击波半径系数 r 的选取

为了研究爆炸半径系数 r 的选取对 BW-PSO 算法性能的影响。本文选择 r 为 1.25、2、5、10 四个采样点: 单峰函数 Sphere、多峰函数 Rosenbrock、Ackley、Geiewank、Rastrigin 五个函数作为评价函数。

30 个粒子 10^3 次迭代后采用归一化处理, 并去除离散点干扰, 如图 5 所示。从结果可以看出 Sphere 函数曲线中 r 越小, 结果越精确。因为随着 r 的减小, 处于爆炸半径内粒子的数目增加, 加速收敛至局部最优解的速度也加快, 符合本文算法对求解单峰函数的理论预期。多峰函数中除 Rosenbrock、Ackley 函数外, 其余函数在 r 取 2 时相对其他半径系数在函数精度和稳定性方面有较好的效果。即假设粒子初始化均匀分布, 则有一半粒子处于爆炸半径内, 另一半处于爆炸半径外。

图5 不同 r 值运行 BW-PSO 算法结果

3.3 算法实验结果分析

各目标函数采用 LPSO(局部)、GPSO(全局)^[12]、GA-PSO(变异 PSO)、带电 PSO、BW-PSO 算法进行测试, 各算法参数见表 2。

表2 各算法参数设置

算法	种群数目	参数设置	惯性权重	学习样本	附加策略
LPSO	30	$c_1 = c_2 = 2$	线性递减	PBest, Gbest(邻域)	无
GPSO	30	$c_1 = c_2 = 2$	线性递减	PBest, Gbest(ALL)	无
GA-PSO	30	$c_1 = c_2 = 2$	线性递减	PBest, Gbest(ALL)	粒子变异
带电 PSO	30	$R_c = 1, R_p = \sqrt{3}X_{\max}, Q_i = 16$	线性递减	PBest, Gbest(邻域)	粒子带电
BW-PSO	30	$c_3 = 2, r = 2, \lambda = 2$	线性递减	PBest, Gbest(邻域)	粒子变异、冲击波

各检测函数在五种算法中运行的收敛趋势见图 6。检测函数在运行 10^4 次后函数的均值和最佳极值点见表 3。

对于单峰 Sphere 函数: 在迭代前期, 除带电 PSO 算法与 BW-PSO 算法外, 其余算法都能较快收敛; 但在迭代后期, LPSO

算法与 GA-PSO 算法呈现出种群多样性减少、学习样本下降的趋势, GPSO 算法曲线在第 0.5×10^3 次迭代后表现出解的精确度不稳定问题。所以带电 PSO 算法与 BW-PSO 算法的表现优于其他三种算法。对于多峰函数: Rosenbrock 函数在 10^4 次迭代后, 除 BW-PSO 算法外, 其他四种算法都出现了早熟现象, 无法跳出局部最小值。BW-PSO 算法的种群监控策略使得在迭代后期粒子有足够的样本学习空间, 因此能够继续提升解的精度。在 Rastrigin 函数和 Ackley 函数中 GA-PSO 算法在第 10^3 代表现优

于其他算法, 但随着迭代次数增加, 解的质量反而出现了下降。虽然 GA-PSO 算法在局部解的挖掘方面有一定的优势, 但相比 BW-PSO 算法在求解多峰问题的稳定性方面还有一定不足。在 Geiewank 函数中, 传统的 LPSO 与 GPSO 算法在 0.5×10^3 至 5×10^3 代范围内解的精度不如其他三种带有附加策略的算法。JD Schaffer 函数中各算法在迭代后期都收敛到极小值。所以, 由结果可以看出: BW-PSO 算法相比其他四种算法在优化多峰问题方面有一定的优势。

表 3 各函数在迭代 10^4 代后的均值和最佳位置

算法	结果	Sphere	Rosenbrock	Ackley	Geiewank	Rastrigin	JD Schaffer
LPSO	均值	6.87864E - 017	2.2124E - 013	9.3555E - 008	8.88178E - 016	2.6483E - 010	-1
	最佳位置	8.23976E - 009	0.999998	-2.33887E - 008	4.1639E - 008	1.15537E - 006	5.62921E - 007
GPSO	均值	3.80703E - 015	6.55732E - 010	1.79837E - 005	3.93674E - 012	6.93278E - 010	-1
	最佳位置	-6.17011E - 008	1.00003	4.49565E - 006	-2.8057E - 006	-1.86935E - 006	1.19716E - 006
GA-PSO	均值	9.93213E - 016	9.83569E - 015	2.72269E - 006	2.84495E - 009	6.05905E - 008	-1
	最佳位置	3.15153E - 008	1	6.80667E - 007	-7.54125E - 005	1.74759E - 005	1.30639E - 006
带电 PSO	均值	5.34783E - 018	7.24625E - 014	3.36869E - 007	1.77636E - 015	1.39073E - 010	-1
	最佳位置	2.31253E - 009	1	-8.42172E - 008	5.89766E - 008	-8.37255E - 007	5.36802E - 006
BW-PSO	均值	4.68746E - 018	4.301575E - 014	1.01919E - 009	5.55112E - 016	6.13731E - 012	-1
	最佳位置	-2.16505E - 009	1	-2.54808E - 010	-3.17995E - 008	1.75886E - 007	3.76991E - 007

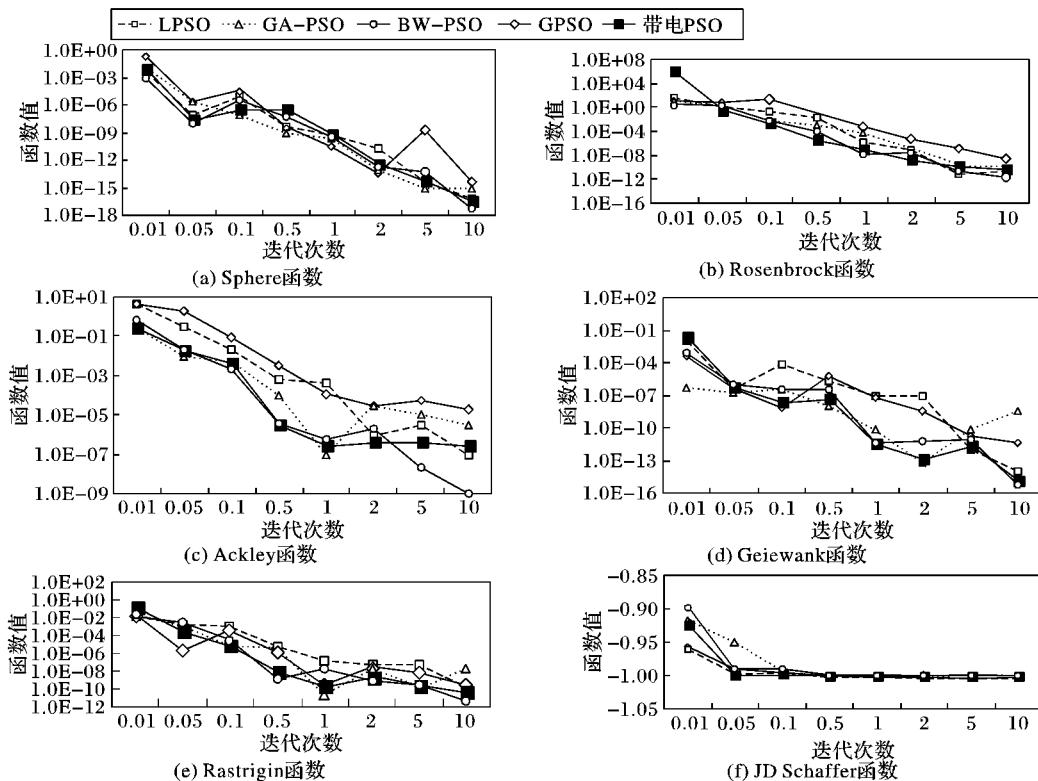


图 6 各算法收敛曲线

3.4 算法的计算复杂度分析

基本 PSO 算法的时间复杂度为 $T_{\text{PSO}}(N) = O(NDT)$, 而 BW-PSO 算法在标准 PSO 算法的基础上增加了交叉变异操作和爆炸冲击波策略。所以 BW-PSO 的时间复杂度为 $T_{\text{BW-PSO}}(N) = O(NDT) + O(D)$ 。其中: T 表示最大迭代次数, N 表示粒子总数, D 表示搜索维数。表 4 所示为各算法迭代 5×10^4 次所用的计算时间, 可以看出, BW-PSO 算法的附加策略并没有增加计算复杂度, 与基本 PSO 算法保持一个数量级。因为带电 PSO 算法的迭代过程中附加全部粒子的距离计算,

导致增加计算复杂度, 所以运算时间要长于 BW-PSO 算法。

4 结语

本文提出的基于爆炸冲击波模型的粒子群算法 (BW-PSO), 通过最优粒子与次优粒子交叉变异, 使得核心粒子能够更好地加强局部搜索能力。处于爆炸半径内的粒子模拟冲击波负压过程, 加速收敛至当前最优解, 提升了当前解的收敛速率; 处于爆炸半径外的粒子模拟冲击波的超压过程, 增强了粒子多样性, 进而使粒子能够探索更广的空间, 提高了找到最

优解的可能性。实验结果表明, 相比变异 PSO 算法和带电 PSO 粒子群算法, BW-PSO 算法对于求解多峰问题有收敛速度快、解的精度高、时间复杂度低的优势。

表 4 各算法的计算时间

算法	Sphere	Rosenbrock	Ackley	Geiewank	Rastrigin	JD Schaffer	s
LPSO	0.157	0.214	0.364	0.223	0.228	0.467	
GPSO	0.138	0.198	0.350	0.214	0.213	0.460	
GA-PSO	0.164	0.232	0.351	0.226	0.234	0.479	
带电 PSO	0.185	0.235	0.372	0.224	0.232	0.485	
BW-PSO	0.178	0.209	0.346	0.241	0.223	0.475	

参考文献:

- [1] KENNEDY J, EBERHART C. Particle swarm optimization[C]// Proceedings of the 1995 IEEE International Conference on Neural Networks. Piscataway: IEEE, 1995: 1942 – 1948.
- [2] LIU Y, NIU B. New particle swarm optimization theory and practice [M]. Beijing: Science Press, 2013: 1 – 3. (刘衍民, 牛奔. 新型粒子群算法理论与实践[M]. 北京: 科学出版社, 2013: 1 – 3.)
- [3] van den BERGH F. An analysis of particle swarm optimizers[D]. Pretoria: University of Pretoria, 2002.
- [4] QIN J, YIN Y, BAN X. A hybrid of particle swarm optimization and local search for multimodal functions[C]// Advances in Swarm Intelligence – First International Conference. Berlin: Springer, 2010: 589 – 596.
- [5] JI C, LIU F, ZHANG X. Particle swarm optimization based on catfish effect for flood optimal operation of reservoir[C]// Proceedings of the 7th International Conference on Natural Computation.
- [6] ROBINSON J, SINTON S, RAHMAT-SAMII Y. Particle swarms, genetic algorithm, and their hybrids; optimization of a profiled corrugated horn antenna[C]// Proceedings of the 2002 IEEE International Symposium on Antennas and Propagation Society. Piscataway: IEEE, 2002: 314 – 317.
- [7] LOVBERG M, RASMUSSEN T K, KRINK T. Hybrid particle swarm optimizer with breeding and subpopulations[C]// Proceedings of the Genetic and Evolutionary Computation Conference. New York: ACM, 2001: 469 – 476.
- [8] BLACKWELL T M, BENTLEY P J. Dynamic search with charged swarms[C]// Proceedings of the 2002 Genetic and Evolutionary Computation Conference. New York: Elsevier Science and Technology Books, 2002: 19 – 26.
- [9] QIAO D. Explosion and shock waves in the air(I) : the basic theory [J]. Explosion and Shock Waves, 1985, 10(5) : 79 – 80. (乔登江. 空中爆炸冲击波(I) : 基本理论[J]. 爆炸与冲击, 1985, 10(5) : 79 – 80.)
- [10] VESTEROM J S, RIGET J, KRINK T. Division of labor in particle swarm optimization[C]// Proceedings of the 2002 IEEE Congress on Evolutionary Computation. Piscataway: IEEE, 2002: 1570 – 1575.
- [11] RIGET J, VESTERSTROM J S. A diversity-guided particle swarm optimizer-the ARPSO technical report[D]. Aarhus: University of Aarhus, 2002.
- [12] CLERC M, KENNEDY J. The particle swarm-explosion, stability, and convergence in a multidimensional complex space[J]. IEEE Transactions on Evolutionary Computation, 2002, 6(1) : 58 – 73.

(上接第 2060 页)

- [3] BARUTCUOGLU Z, SCHAPIRE R E, TROYANSKAY O G. Hierarchical multi-label prediction of gene function [J]. Bioinformatics, 2006, 22(7) : 830 – 836.
- [4] YANG S J, JIANG Y, ZHOU Z H. Multi-instance multi-label learning with weak label [C]// Proceedings of the 23rd International Joint Conference on Artificial Intelligence. Menlo Park: AAAI Press, 2013: 1862 – 1868.
- [5] XU M, LI Y, ZHOU Z. Multi-label learning with PRO loss[C]// Proceedings of the 27th AAAI Conference on Artificial Intelligence. Menlo Park: AAAI Press, 2013: 998 – 1004.
- [6] XU M, JIN R, ZHOU Z H. Speedup matrix completion with side information: Application to multi-label learning [C]// Advances in Neural Information Processing Systems 26. Cambridge: MIT Press, 2013: 2301 – 2309.
- [7] ZHANG Y, ZHOU Z. Multilabel dimensionality reduction via dependence maximization [J]. ACM Transactions on Knowledge Discovery from Data, 2010, 4(3) : 1 – 21.
- [8] WANG H, DING C, HUANG H. Multi-label linear discriminant analysis[C]// Proceedings of the 11th European Conference on Computer Vision. Berlin: Springer Press, 2010: 126 – 139.
- [9] TAI F, LIN H T. Multi-label classification with principle label space transformation [J]. Neural Computation, 2012, 24(9) : 2508 – 2542.
- [10] TSOUMAKAS G, KATAKIS I, VLAHAVAS I. Random k-labelsets for multi-label classification [J]. IEEE Transactions on Knowledge and Data Engineering, 2011, 23(7) : 1079 – 1089.
- [11] TSOUMAKAS G, DIMOU A, SPYROMITROS E, et al. Correlation-based pruning of stacked binary relevance models for multi-label learning [C]// Proceedings of the 2009 Workshop on Learning from Multi-Label Data. Berlin: Springer, 2009: 101 – 116.
- [12] READ J, PFAHRINGER B, HOLMES G, et al. Classifier chains for multi-label classification [J]. Machine Learning, 2011, 85(3) : 333 – 359.
- [13] HUANG S J, ZHOU Z. Multi-label learning by exploiting label correlations locally [C]// Proceedings of the 26th AAAI Conference on Artificial Intelligence. Menlo Park: AAAI Press, 2012: 949 – 955.
- [14] HOSKULDSSON A. PLS regression methods [J]. Journal of Chemometrics, 1988, 2(3) : 211 – 228.
- [15] ZHANG M, ZHOU Z. A review on multi-label learning algorithms [J]. IEEE Transactions on Knowledge and Data Engineering, 2013, 99(99) : 1.
- [16] ZHANG M L, ZHOU Z. ML-kNN: A lazy learning approach to multi-label learning [J]. Pattern Recognition, 2007, 40(7) : 2038 – 2048.
- [17] CHENG W, HULLERMEIER E. Combining instance-based learning and logistic regression for multilabel classification [J]. Machine Learning, 2009, 76(2/3) : 211 – 225.
- [18] TSOUMAKAS G, KATAKIS I, VLAHAVAS I. Effective and efficient multilabel classification in domains with large number of labels [C]// Proceedings of ECML/PKDD 2008 Workshop on Mining Multidimensional Data. Berlin: Springer, 2008: 30 – 44.