

交叉前置式粒子群优化算法及其在催化裂化 C_3 含量软测量中的应用

商雨青¹, 许 伟², 顾幸生²

(1. 上海电机学院电气工程系, 上海 200240; 2. 华东理工大学化工过程先进控制和
优化技术教育部重点实验室, 上海 200237)

摘 要: 针对粒子群优化算法易陷入局部极小点, 出现早熟收敛的问题, 本文提出了一种交叉前置式粒子群优化算法(PSOPC). 该算法引入了一个辅助种群, 将其中的个体与粒子群中的粒子在粒子更新之前进行预先的交叉操作. 辅助种群所包含的是每次迭代后所生成的适应值较差但多样性较高的粒子. 前置式交叉操作能够增加粒子群的多样性, 有效改善算法的全局收敛能力. 标准函数测试结果表明, PSOPC 比基本 PSO 具有更好的优化性能. 最后, 将 PSOPC 应用于催化裂化装置干气中 C_3 含量软测量建模, 通过与实际的工业数据的对比, 结果表明基于 PSOPC 的神经网络 C_3 含量软测量模型具有较高的精度和较强的泛化能力.

关键词: 粒子群优化算法; 优化; 催化裂化; C_3 含量

中图分类号: TP183 **文献标识码:** A **文章编号:** 0372-2112 (2012)09-1885-04

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2012.09.029

Particle Swarm Optimization with Pre-Crossover and Its Application in Soft-Sensor of C_3 Concentration of FCCU

SHANG Yu-qing¹, XU Wei², GU Xing-sheng²

(1. Department of Electrical Engineering, Shanghai DianJi University, Shanghai 200240, China;

2. Key Laboratory of Advanced Control and Optimization for Chemical Processes of Ministry of Education,
East China University of Science and Technology, Shanghai 200237, China)

Abstract: An improved particle swarm optimization with pre-crossover(PSOPC) was proposed to avoid the premature convergence of particle swarm optimization algorithm. An auxiliary population was introduced in which the particles with low fitness but high diversity after each generation were stored. The pre-crossover between the particle in the swarm and the individual in the extra population was implemented, which helps increase the diversity of the particle swarm so as to improve the global convergence. PSOPC was used to train BP neural network to construct a soft-sensing model of C_3 concentration of the fluid catalytic cracker unit (FCCU). The experimental results show that the model based on PSOPC and neural network has good precision and strong generalization.

Key words: particle swarm optimization; optimization; fluid catalytic cracker unit; C_3 concentration

1 引言

在自然系统中,许多生物是以群体行为的方式适应周围的环境,完成自身的进化的.近年来,很多学者源于对生物信息的分析和理解,从不同角度研究了鸟群、鱼群等有组织的移动过程. Kennedy 和 Eberhart^[1]基于鸟群的觅食行为,在前人工作的基础上提出了粒子群优化算法(Particle Swarm Optimization, PSO). PSO 算法是一种基于群智能理论的进化算法,种群包含一组“粒子”,分别代表问题空间的一个候选解.粒子从当前位置出发,根据自身经验和整个种群的经验不断更新飞行速度和位置.每个粒子在到达新的位置后,通过适应度函数评价

粒子的表现,并获得粒子自身的最好位置(Personal Best, p_{best})和整个种群的最好位置(Global Best, g_{best}).由以上描述可知,粒子在搜索问题空间的过程中,根据当前速度、当前位置、个体历史最优位置和种群历史最优位置不断调整自身的位置,直到最终找到全局最优解.粒子群算法不仅结构简单,编程方便,而且具有较强的全局收敛能力,收敛迅速.因此,粒子群优化算法已广泛应用于各个领域,如化工^[2]、金融^[3]、交通^[4]、采矿^[5]等.

2 粒子群优化算法的原理

在一个 D 维的问题空间中,种群的第 i 个粒子的速度和位置更新公式^[6]为:

$$v_{id}^{t+1} = wv_{id}^t + c_1 r_1 (p_{id}^t - x_{id}^t) + c_2 r_2 (p_{gd}^t - x_{id}^t), d = 1, 2, \dots, D \quad (1)$$

$$x_{id}^{t+1} = x_{id}^t + v_{id}^{t+1}, d = 1, 2, \dots, D \quad (2)$$

其中 w 为惯性权值; c_1 、 c_2 为两个学习因子; p_i^t 为第 i 个粒子的 p_{best} , p_g^t 为种群的 g_{best} ; r_1 、 r_2 是 $(0, 1)$ 范围内两个均匀分布的随机数. 粒子群优化算法的寻优过程可描述为: 种群中的粒子“追随”两个“最优点”(p_{best} 和 g_{best}), 不断更新自身的飞行速度和位置, 以期找到更优的解, 直到满足终止条件为止.

3 交叉前置式粒子群优化算法

3.1 算法原理

虽然粒子群优化算法的结构简单, 并且具有较强的全局收敛能力, 但是在收敛后期会由于种群逐渐丧失多样性而出现早熟收敛, 导致粒子的进化停滞. 因此, 本文提出了一种交叉前置式粒子群优化算法 (PSO with Pre-Crossover, PSOPC). PSOPC 算法仍采用传统 PSO 算法的粒子更新策略, 只是引入了一个辅助种群, 并将其中的随机个体与当前粒子进行交叉操作. 辅助种群中的个体是由粒子每次位置更新后, 适应值差于原位置的新位置所组成. 这些新位置的适应值较对应的原位置更差, 但不一定比粒子群中的其它粒子差. 并且, 它们的多样性更高, 很可能具备较好的基因. 由此, 将辅助种群中的随机个体与粒子群中的粒子进行预先的交叉操作, 增加了粒子群的多样性, 能够有效的改善算法的收敛能力, 提高算法的收敛精度.

3.2 算法流程

交叉前置式粒子群优化算法的流程如下:

Step 1 初始化设置

首先对算法进行初始化设置, 迭代次数 $t = 0$, 惯性权值随着迭代次数的增加由 0.9 减小到 0.4, 学习因子 $c_1 = c_2 = 2.0$, 粒子群与辅助种群的规模相同, 并在搜索区域内生成两个种群的初始粒子 (个体), 并计算其适应值, 获得 p_{best} 和 g_{best} .

Step 2 交叉操作

将粒子群中的粒子与辅助种群中的随机个体进行交叉操作:

$$y_{id}^t = \begin{cases} z_{\text{rand}, d}^t, & \text{if rand} \leq P \\ x_{id}^t, & \text{otherwise} \end{cases} \quad (3)$$

其中 P 为交叉概率, z_{rand}^t 为辅助种群中的一个随机个体. 随后将试验个体 y_i^t 与粒子 i 进行适应值比较, 若 $\text{fitness}(y_i^t) \leq \text{fitness}(x_i^t)$, 则 y_i^t 替代 x_i^t .

Step 3 粒子速度和位置的更新

按照式 (1)、(2) 的粒子更新方式, 获得新位置 \tilde{x}_i^t , 并对粒子的当前位置进行更新:

$$\tilde{x}_{id}^t = x_{id}^t + wv_{id}^t + c_1 r_1 (p_{id}^t - x_{id}^t) + c_2 r_2 (p_{gd}^t - x_{id}^t) \quad (4)$$

$$x_{id}^{t+1} = \begin{cases} \tilde{x}_{id}^t, & \text{if fitness}(\tilde{x}_i^t) \leq \text{fitness}(x_i^t) \\ x_{id}^t, & \text{otherwise} \end{cases} \quad (5)$$

Step 4 辅助种群的更新

如果新位置 \tilde{x}_i^t 的适应值较原位置更差, 则用其对辅助种群的个体进行更新:

$$z_i^{t+1} = \begin{cases} \tilde{x}_i^t, & \text{if fitness}(\tilde{x}_i^t) > \text{fitness}(z_i^t) \\ & \text{and fitness}(\tilde{x}_i^t) \leq \text{fitness}(z_i^t) \\ z_i^t, & \text{otherwise} \end{cases} \quad (6)$$

Step 5 终止条件

计算当前的全局历史最优值, 随后判断是否达到终止条件. 若达到终止条件, 则跳出迭代, 输出全局最优值; 否则, $t = t + 1$, 并转至 Step 2, 进入下一次迭代.

3.3 仿真实验与结果分析

3.3.1 测试函数

为验证 PSOPC 算法的性能, 采用以下五个标准测试函数进行仿真研究.

① f_1 : Rosenbrock

$$\min f_1(\mathbf{x}) = \sum_{i=1}^{29} (100 \times (x_{i+1} - x_i^2)^2 + (1 - x_i)^2), \\ -30 \leq x_i \leq 30$$

② f_2 : Sphere

$$\min f_2(\mathbf{x}) = \sum_{i=1}^{30} x_i^2, \quad -100 \leq x_i \leq 100$$

③ f_3 : Shubert

$$\min f_3(x, y) = \left\{ \sum_{i=1}^5 i \cdot \cos[(i+1) \cdot x + i] \right\} \\ \cdot \left\{ \sum_{i=1}^5 i \cdot \cos[(i+1) \cdot y + i] \right\} \\ + 0.5 \cdot [(x + 1.42513)^2 \\ + (y + 0.80032)^2], \\ -10 \leq x, y \leq 10$$

④ f_4 : Ackley

$$\min f_4(\mathbf{x}) = 20 + e - 20 \times \exp\left(-0.2 \times \sqrt{\sum_{i=1}^{30} x_i^2 / 30}\right) \\ - \exp\left(\sum_{i=1}^{30} \cos(2\pi x_i) / 30\right), \\ -30 \leq x_i \leq 30$$

⑤ f_5 : Rastrigin

$$\min f_5(\mathbf{x}) = \sum_{i=1}^{30} (x_i^2 - 10 \times \cos(2\pi x_i) + 10), \\ -5.12 \leq x_i \leq 5.12$$

3.3.2 实验结果与分析

选用 PSO 和 PSOPC 算法对 5 个测试函数分别运行 50 次独立的实验. 汇总两种方法多次实验的平均最优

结果以及平均寻优迭代次数和时间,结果如表 1、表 2 所示.

表 1 优化算法平均最优结果比较

算法名称	平均最优结果				
	f_1	f_2	f_3	f_4	f_5
PSO	67.68	1.13×10^{-5}	-182.55	1.16	55.62
PSOPC	33.36	7.73×10^{-17}	-186.72	6.42×10^{-9}	37.35

表 2 优化算法找到最优解的平均迭代次数与时间比较

算法名称	平均迭代次数和时间				
	f_1	f_2	f_3	f_4	f_5
PSO	1332 (0.10s)	1524 (0.34s)	387 (0.10s)	1308 (1.24s)	1402 (1.12s)
PSOPC	906 (0.14s)	757 (0.29s)	192 (0.09s)	1085 (1.61s)	514 (1.04s)

由表 1 可知,PSOPC 算法的优化性能更佳,这充分体现出 PSOPC 算法的全局优化性能.由表 2 可知,在找到全局最优解的前提下,PSOPC 算法所经过的迭代次数明显少于基本 PSO 算法,而花费的时间并没有出现明显的增加,甚至个别函数还有所降低.这表明,在寻优时间没有显著增加的情况下,PSOPC 算法能够找到更好的优化结果.

4 基于 PSOPC 的 BP 神经网络催化裂化 C₃ 含量软测量建模

4.1 辅助变量的选择

吸收-稳定系统工艺流程如图 1 所示,包括吸收塔、解吸塔、再吸收塔和富气压缩机,平衡分离罐及有关的换热设备^[7].影响吸收的因素很多,如操作压力、油气比、操作温度、吸附剂及被吸收气体的性质、塔内气液流动状态、塔板数及塔板结构等.根据机理分析,将干气中影响 C₃ 含量比较大的 14 个可测参数作为辅助变量,并用编号 X₁ - X₁₄表示,如表 3 所示.

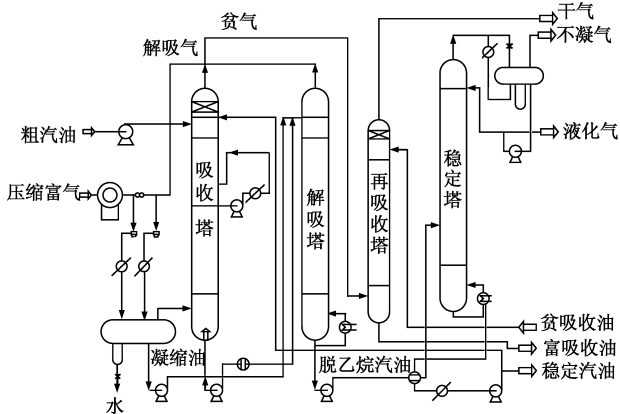


图 1 催化裂化吸收-稳定系统工艺流程图

表 3 辅助变量

编号	辅助变量名称	编号	辅助变量名称
X ₁	富气进料量	X ₈	补充剂温度
X ₂	富气温度	X ₉	一中返塔温度
X ₃	容 301 压力	X ₁₀	二中返塔温度
X ₄	吸收塔顶温度	X ₁₁	解吸气流量
X ₅	粗汽油流量	X ₁₂	解吸塔顶温度
X ₆	粗汽油温度	X ₁₃	再吸收塔顶温度
X ₇	补充剂流量	X ₁₄	贫吸收油流量

4.2 基于 PSOPC 算法的 BP 神经网络 C₃ 软测量模型

该催化裂化装置中再吸收塔塔顶输出的干气中 C₃ 含量由化验员每天化验分析四次,同时记录采样时刻的 14 个辅助变量的操作数据,共采集 113 组数据.经检验识别,有 2 组数据含有过失误差,予以剔除.将剩余的 111 组数据进行归一化处理,其中取 81 组数据作为训练样本,采用 PSOPC 算法优化 BP 神经网络的权值和阈值.神经网络采用三层 BP 网络结构,其中隐含层节点取 10.剩余的 30 组数据作为测试样本,对建立的模型进行测试.训练结果、测试结果与人工分析值的对比图分别如图 2、图 3 所示.由图可知,基于 PSOPC-NN 的 C₃ 含量软测量模型输出能够较好的拟合实际的人工分析值.




图2 基于PSOPC-NN软测量模型训练结果对比图




图3 基于PSOPC-NN软测量模型测试结果对比图

4.3 结果对比

为了进一步验证基于 PSOPC-NN 的 C₃ 含量软测量模型的有效性, 本文将其与另外四种 C₃ 含量软测量模型相比较: BPNN、基于 PSO 的 BPNN 模型 PSO-NN、基于 PSO-NN 模型 PSO-NN 以及基于 SPSO-NN 的 BPNN 模型 SPSO-NN。多个模型的结果对比如表 4 所示。由表 4 可知, 基于 BPNN 的软测量模型出现了过拟合现象, 造成训练误差很小而测试误差很大。而相比于 PSO-NN、PSOCF-NN 和 SPSO-NN, 基于 PSOPC-NN 的 C₃ 含量软测量模型的测试误差更小, 说明该软测量模型的泛化性能较好, 从而进一步表明 PSOPC 算法具有较强的寻优能力。

表 4 多种软测量模型的结果对比

模型	训练		测试	
	均方差	相对误差	均方差	相对误差
BPNN	0.01246	7.1739×10^{-3}	0.23336	0.17287
PSO-NN	0.10453	0.08902	0.09103	0.06845
PSOCF-NN	0.07521	0.06241	0.06182	0.04940
SPSO-NN	0.08743	0.07694	0.07366	0.05506
PSOPC-NN	0.06108	0.04609	0.04052	0.03000

5 结束语

鉴于基本粒子群优化算法易陷入局部极小, 出现早熟收敛的问题, 本文提出了交叉前置式粒子群优化算法。该算法引入了一个辅助种群, 用于存放每次迭代后所生成的适应值较差但多样性较高的粒子。将两个种群的个体(粒子)进行预先的交叉操作, 帮助粒子群维持较高的多样性, 从而有效提高了算法的全局收敛能力。测试函数仿真实验表明, 交叉前置式粒子群优化算法比基本粒子群优化算法具有更好的优化性能。本文还将交叉前置式粒子群优化算法用于 BP 神经网络权值和阈值的优化, 构造 PSOPC-NN 模型, 并将其应用于催化裂化装置干气中 C₃ 含量的软测量建模。仿真结果表明, 基于 PSOPC-NN 的 C₃ 含量软测量模型比其它四种软测量模型具有更高的精度和更好的泛化性能, 能够满足实际生产的需要, 具有良好的应用前景。

参考文献

[1] KENNEDY J, EBERHART R C. Particle swarm optimization [A]. Proceedings of the IEEE International Conference on Neural Networks[C]. Massachusetts: MIT Press, 1995, vol. 4. 1942 – 1948.

[2] PRATA D M, et al. Simultaneous robust data reconciliation and gross error detection through particle swarm optimization for an industrial polypropylene reactor[J]. Chem Eng Sci, 2010, 65 (17): 4943 – 4954.

[3] Sun J, et al. Solving the economic dispatch problem with a modified quantum-behaved particle swarm optimization method [J]. Energ Convers Manage, 2009, 50(12): 2967 – 2975.

[4] YANNIS M, MAGDALENE M, GEORGIOS D. A hybrid particle swarm optimization algorithm for the vehicle routing problem[J]. Eng Appl Artif Intel, 2010, 23(4): 463 – 472.

[5] 汪楚娇, 夏士雄, 牛强. 免疫粒子群算法及其在矿井提升机故障诊断中的应用[J]. 电子学报, 2010, 38(2A): 94 – 98.

WANG Chu-jiao, XIA Shi-xiong, NIU Qiang. Artificial immune particle swarm optimization for fault diagnosis of mine hoist[J]. Acta Electronica Sinica, 2010, 38(2A): 94 – 98. (in Chinese)

[6] SHI Y, EBERHART R C. Parameter selection in particle swarm optimization[J]. Lecture Notes in Computer Science, 1998, 1447: 591 – 600.

[7] 张可伟. 重油催化裂化装置吸收稳定系统流程改进及操作优化[J]. 石油炼制与化工, 2007, 38(12): 16 – 19.

ZHANG Ke-wei. Process modification and operation optimization of absorption and stabilization system of RFCCU [J]. Petroleum Processing and Petrochemicals, 2007, 38(12): 16 – 19. (in Chinese)

[8] CLERC M, KENNEDY J. The particle swarm—explosion, stability, and convergence in multidimensional complex space[J]. IEEE Trans Evolut Comput, 2002, 6(1): 58 – 73.

[9] 高海兵, 高亮, 周驰, 等. 基于粒子群优化的神经网络训练算法研究[J]. 电子学报, 2004, 32(9): 1572 – 1574.

GAO Hai-bing, GAO Liang, ZHOU Chi, et al. Particle swarm optimization based algorithm for neural network learning[J]. Acta Electronica Sinica, 2004, 32(9): 1572 – 1574. (in Chinese)

作者简介



商雨青 男, 1964 年 1 月出生于上海, 现为上海电机学院副教授。主要从事智能化方法与自动控制、楼宇自动化等方面的研究。
E-mail: shangyq@sdju.edu.cn

许伟 男, 1985 年 7 月出生于江西九江, 博士。主要研究方向为复杂化工过程智能建模与优化方法研究。

E-mail: xuwei0729@gmail.com

顾幸生(通讯作者) 男, 1960 年 7 月出生于江苏海门, 教授, 博士生导师。主要研究方向是复杂工业过程建模、控制与优化, 智能优化方法、生产计划与调度、故障诊断等。

E-mail: xsgu@ecust.edu.cn