

两群微粒群优化算法及其应用

陈国初^{1,2}, 俞金寿²

(1. 上海电机学院 电气学院, 上海 200240; 2. 华东理工大学 自动化研究所, 上海 200237)

摘要: 针对微粒群优化算法容易陷入局部极值的缺陷, 提出两群微粒群优化算法. 通过对5种常用测试函数进行测试和比较, 结果表明两群微粒群优化算法比基本微粒群优化算法更容易找到全局最优解, 优化效率明显提高. 然后将两群微粒群优化算法用于催化裂化装置主分馏塔轻柴油95%点软测量建模, 通过与实际工业数据对比, 表明该软测量模型具有高的精度、好的性能和广阔的应用前景.

关键词: 微粒群优化算法; 优化; 催化裂化装置; 轻柴油95%点; 软测量

中图分类号: TP273 **文献标识码:** A

Two sub-swarms particle swarm optimization algorithm and its application

CHEN Guo-chu^{1,2}, YU Jin-shou²

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

2. Research Institute of Automation, East China University of Science and Technology, Shanghai 200237, China)

Abstract: In order to improve optimization performance of particle swarm optimization algorithm(PSO), a new two sub-swarms particle swarm optimization algorithm(TSPSO) is proposed in this paper. Then, both TSPSO and PSO are used to resolve five well-known and widely used test functions' optimization problems. Results show that TSPSO has greater efficiency and better performance than PSO. TSPSO is also applied to train artificial neural network(NN)to construct a practical soft-sensor for the 95%-point light diesel oil in a main fractionator of fluid catalytic cracking unit(FCCU). The obtained results and comparison with actual industrial data indicate that the proposed method is feasible and effective in soft-sensor for the 95%-point light diesel oil.

Key words: PSO(particle swarm optimization algorithm); optimization; fluid catalytic cracking unit; light diesel oil; soft-sensor

1 引言(Introduction)

微粒群优化算法(particle swarm optimization algorithm, PSO)是Kennedy和Eberhart^[1,2]1995年提出的进化计算算法, 它简单且对许多优化问题优化性能良好, 可用于解决大量非线性、不可微和多峰值等优化问题, 并已越来越广泛地应用于科学和工程领域. 但是PSO存在进化后期收敛速度慢、对复杂优化问题容易陷入局部极值的缺陷^[3]. 本文将微粒分成有着不同飞行方式的两分群, 提出两群微粒群优化算法(two sub-swarms PSO, TSPSO), 并将其应用于催化裂化(FCCU)主分馏塔轻柴油95%点软测量.

2 两群微粒群优化算法(Two sub-swarms particle swarm optimization algorithm)

2.1 基本微粒群优化算法(Basic particle swarm optimization algorithm)

假设在 D 维搜索空间中, 有 m 个微粒组成一微粒群, 其中第 i 个微粒的空间位置为 $X(i) = (x_{i1}, x_{i2}, \dots, x_{iD}) (i = 1, 2, \dots, m)$, 所经历的最优位置为其个体历史最优位置 P_i , 相应的适应值为其个体历史最优适应值 F_i , 微粒的飞行速度为 V_i . 所有微粒经历过的最优位置为全局历史最优位置 P_g , 相应的适应值为全局历史最优适应值 F_g . 对第 i 个第 d 维第 n 代微粒, 根据如下方程迭代:

$$v_{id}^{n+1} = \chi(\omega v_{id}^n + c_1 r_1 (p_{id}^n - x_{id}^n) + c_2 r_2 (p_{gd}^n - x_{id}^n)), \quad (1)$$

$$x_{id}^{n+1} = x_{id}^n + v_{id}^{n+1}. \quad (2)$$

其中: χ 为收缩因子, ω 为惯性权值, c_1 和 c_2 为加速系数, r_1 和 r_2 是两个在 $[0, 1]$ 范围内变化的随机数.

2.2 两群微粒群优化算法(Two sub-swarms particle swarm optimization algorithm)

2.2.1 算法原理(Principle of TSPSO)

如果将微粒群分成搜索空间相同但飞行方向不同的两分群, 一分群朝着最好微粒飞行, 另一分群则朝着相反方向飞行. 飞行时, 每一微粒下一步飞行的速度和位置不仅与微粒本身先前的飞行经验和本分群历史最优微粒的位置有关, 还与全群历史最优微粒的位置有关. 搜索时, 如果全群历史最优微粒的适应值连续若干步迭代后没有得到改善而适应值误差又不能满足要求, 就将两分群微粒进行交换, 即强迫两分群微粒改变飞行方向. 为了延续分群历史最优微粒的搜索优势, 交换微粒分群时, 保留本分群的分群历史最优微粒取代交换群的最差微粒以使得分群微粒数量保持不变. 这样在整个微粒群的搜索过程中, 每一微粒都有可能经常改变飞行方向, 而且交换微粒后, 由于分群历史最优微粒位置的变化, 陷入局部极值点而失去活力的微粒会可以因此获得生命力; 对于整个微粒群来说, 不会因为遇到局部极值点而一直停止不动, 微粒在整个搜索过程中都会有充足的生命力在搜索空间进行搜索, 找到全局最优解的概率得到提高.

2.2.2 算法方程(Equations of TSPSO)

在TSPSO中, 为了使微粒的飞行既朝着全群历史最优微粒飞行, 同时又不脱离本分群历史最优微粒的影响, 本文对第 i 个第 d 维第 n 代微粒的迭代方程修正如下:

$$v_{id}^{n+1} = \chi(\omega v_{id}^n + c_1 r_1 (p_{id}^n - x_{id}^n) + \mu_1 c_2 r_2 (p_{gd}^n - x_{id}^n) + \mu_2 c_3 r_3 (p_{pd}^n - x_{id}^n)), \quad (3)$$

$$x_{id}^{n+1} = x_{id}^n + \kappa v_{id}^{n+1}. \quad (4)$$

上式中: c_1, c_2 和 c_3 为加速系数; r_1, r_2 和 r_3 是3个在 $[0, 1]$ 范围内变化的随机数; p_{pd} 是分群历史最优位置; μ_1 和 μ_2 为影响因子, 分别表示全群历史最优位置和分群历史最优位置对微粒飞行的影响; κ 是飞行方向标识符, 朝着最优微粒飞行时为1, 背离最优微粒飞行时为-1.

2.2.3 算法流程图(Algorithm flow of TSPSO)

两群微粒群优化算法流程图如图1所示.

3 在函数优化中的应用(Application in optimizing test functions)

3.1 测试函数(Test functions)

$$F_1 = 21.5 + x_1 \sin(4\pi x_1) + x_2 \sin(20\pi x_2). \quad (5)$$

函数 F_1 中, $-3.0 \leq x_1 \leq 12.1, 4.1 \leq x_2 \leq 5.8$.

$$F_2 = \frac{\sin(\sqrt{(x_1-50)^2 + (x_2-50)^2} + e)}{\sqrt{(x_1-50)^2 + (x_2-50)^2} + e} + 1. \quad (6)$$

函数 F_2 中, $-100.0 \leq x_1, x_2 \leq 100.0$.

$$F_3 = 0.5 - \frac{(\sin \sqrt{x_1^2 + x_2^2})^2 - 0.5}{1 + 0.001(x_1^2 + x_2^2)}. \quad (7)$$

函数 F_3 中, $-10 \leq x_1, x_2 \leq 10$.

$$F_4 = \sum_{i=1}^5 i \cos[(i+1)x_1 + i] \sum_{i=1}^5 i \cos[(i+1)x_2 + i] + 0.5[(x_1 + 1.42513)^2 + (x_2 + 0.80032)^2]. \quad (8)$$

函数 F_4 中, $-10 \leq x_1, x_2 \leq 10$.

$$F_5 = \sum_{i=1}^n \frac{x_i^2}{4000} - \prod_{i=1}^n \cos(\frac{x_i}{\sqrt{i}}) + 1. \quad (9)$$

函数 F_5 中, $-600 \leq x_i \leq 600$.

以上测试函数都是很难的多峰值优化函数, 依次称F1函数、F2函数、Schaffer F6函数、Shubert函数和Griewangk函数.

3.2 允许全群历史最优微粒适应值连续不改善次数 N 的讨论(Discussion about N)

在TSPSO算法中, 如果允许全群历史最优微粒适应值连续不改善次数 N 的取值过小, 虽然TSPSO交换微粒时保留了最优微粒, 但是过小的 N 可能影响有潜力微粒的飞行, 导致寻优时达优率降低; 相反, 如果 N 过大, 则有过多的计算量浪费在差适应值的状态的搜索上, 体现不出TSPSO的优越性. 为了考察 N 为多大较为合适, 本文做了不同函数时达优率与 N 的关系、不同微粒个数时达优率与 N 的关系和不同最大允许迭代步数时达优率与 N 的关系3组实验. 实验结果见图2~图4.

在图2中, 对于F1, F2函数, 当 N 很小时, 达优率很低; 随着 N 增大, 达优率逐渐增大, 当 N 为15时达优率达最大; 然后, 随着 N 的增大, 达优率逐渐降低. 对于Schaffer F6函数, 在 N 为20以前, 达优率均为100%; 然后, 随着 N 的增大, 达优率缓慢降低. 对于Shubert, Griewangk函数, 均在 N 为1时达优率最大, 然后达优率缓慢降低. 从这5种函数来看, N 太大时, 所有函数的达优率都降低, N 太小时, 有些函数的达优率很低. 综合来看, N 的取值为10~20比较合适. 由图3可知, 不同微粒个数时的达优率与 N 的关系相似, N 的选择与微粒个数关系不大. 由图4可知, 不同最大允许迭代步数时的达优率与 N 的关系相似, N 的选择与最大允许迭代步数关系不大.






图1 两群微粒群优化算法流程图

Fig. 1 Algorithm flow of TSPSO

图2 不同函数时达优率与 N 的关系Fig. 2 Relationships between N and success rates with different test functions图3 不同微粒个数时达优率与 N 的关系Fig. 3 Relationships between N and success rates with different sizes of sub-swarms




图4 不同最大允许迭代步数时达优率与 N 的关系
Fig. 4 Relationships between N and success rates with different largest iteration steps

3.3 优化结果及讨论(Results and discussion)

本文同时用TSPSO和PSO对以上函数进行优

化, 寻优时最大允许迭代次数为2000, ω 从1.8减小到0.02, c_1, c_2, c_3 都为2, TSPSO的 χ 为0.5, μ_1 和 μ_2 都为0.5, PSO的 χ 为1, TSPSO每分群微粒个数为30, N 为15, PSO的微粒个数为60. 由于TSPSO和PSO都是随机搜索算法, 本文从概率角度来对比两算法的优化性能, 优化时用每一算法对每一测试函数都进行500次独立测试, 并进行统计汇总, 结果见表1.

由表1可知, TSPSO算法寻优时获得最优解的概率明显高于PSO算法寻优时获得最优解的概率, TSPSO比PSO更容易找到全局最优解, 优化效率明显提高.

表1 函数优化结果统计汇总对比

Table 1 Success rate and fitness of functions found for the five test functions with TSPSO and PSO

优化函数	TSPSO			PSO		
	达优率/ %	适应值平均值	适应值最优值	达优率/ %	适应值平均值	适应值最优值
F1函数	79.2	38.829	38.8503	0.4	38.677	38.8503
F2函数	65	1.1459	1.1511	9.8	1.131	1.1511
SchafferF6	100	1	1	56.2	0.99593	1
Shubert	81	-186.08	-186.7309	51.4	-185.60	-186.7309
Griewangk	98.2	8.8753×10^{-5}	0	67.2	0.00234	0

4 在FCCU主分馏塔轻柴油95%点软测量中的应用(Application in soft-sensor of light diesel oil 95% point of main fractionator of FCCU)

本文以某80万吨/年的催化裂化装置为背景, 建立其主分馏塔轻柴油95%点软测量模型. 目前软测量建模的有力工具之一为神经网络(NN)^[4,5], TSPSO算法作为一种简单有效的优化算法, 是一种非常有力潜力的神经网络训练算法, 将它用于神经网络的训练, 构造两群微粒群神经网络(TSPSONN).

4.1 基于TSPSONN的轻柴油95%点软测量模型(Soft-sensing model based on TSPSONN)

将TSPSONN用于FCCU主分馏塔轻柴油95%点的软测量建模, 构建出基于TSPSONN的FCCU主分馏塔轻柴油95%点软测量模型. 经过工艺机理分析、主成分分析和多次测试, 本文选用塔顶油气出口温度、塔顶回流温度、轻柴油抽出口温度、轻柴油流量、18层温度、11层温度、一中返塔温度、一中回流流量、油气进料温度共9个输入信号, 中间层节点数为16, 输出信号为轻柴油95%点所构成的结构为9-16-1神经网络为所用的软测量

模型. 中间层神经元节点的传递函数选用双曲正切函数, 输出层神经元节点的传递函数选用非对称S型函数.

此时, TSPSO各参数为: 各分群微粒个数为100, 最大允许迭代次数为22000, ω 从1.8减小到0.02, χ 为0.5, c_1, c_2, c_3 都为2, μ_1 和 μ_2 都为0.5, N 为15, 最大速度为15.

4.2 与其他优化算法的比较与分析(Comparison with other learning algorithms)

对于前向神经网络而言, 倘若神经网络的结构、节点传递函数、神经网络的输入、输出和目标函数不变, 那么, 目标函数在空间的展布就是一定的. 用不同的算法来搜索神经网络的最优连接权值和最佳阈值, 就相当于用不同的方法在神经网络目标函数在空间的展布上寻找最小值点. ①倘若各种算法都能找到最小值点、而目标函数在空间的展布又只有惟一最小值点, 那么各种方法所找到的连接权值和阈值就完全相同. ②倘若各种算法所得到的目标函数适应值相当, 那么各种算法所得到的神经网络模型的误差是相当的, 此时各种算法所得到的神经网络模型的拟合精度应该

是相当的;对于检验样本,只要检验样本的模式被包括在训练样本的模式之中,那么各种算法所得到的神经网络模型的外推精度也是相当的.③许多优化算法,如:误差反向传播算法、遗传算法、微粒群算法、混沌算法、蚁群算法、模拟退火法等,在训练神经网络时,如果参数选择得当,都有找到好解的可能.不同的是各种算法均有自己的特点,有些算法寻优时达优概率高些,容易找到好解;有些算法寻优时达优概率低些,难于找到好解.

关于TSPSO和PSO优化性能的对比前面已有讨论,下小节只给出基于TSPSONN的FCCU主分馏塔轻柴油95%点软测量模型的实验结果及讨论.

4.3 实验结果及讨论(Experiment results and discussion)

用经过检错、平滑、归一化预处理后的85组训练样本对所建模型进行训练.训练结束后,经统计,学习样本85.88%的样本误差小于 $\pm 1^{\circ}\text{C}$, 98.82%的样本误差小于 $\pm 2^{\circ}\text{C}$ 、均方差为 0.72071°C 、绝对误差的平均值为 0.5668°C .这些数据表明所建模型的预测值与实际化验值的拟合程度较好,训练过程满足要求.




图5 模型预测值与实际化验值检验结果对比图

Fig. 5 Comparison between model's predictive values and actual values

再用同样经检错、平滑、归一化预处理后的40组没参加训练的检验样本对所建模型进行检

验,检验结果与实际化验结果的对比见图5.在40组检验样本中,72.5%的样本误差小于 $\pm 1^{\circ}\text{C}$, 97.5%的样本误差小于 $\pm 2^{\circ}\text{C}$ 、样本均方差为 0.81678°C 、绝对误差的平均值为 0.70398°C .这些数据及图5表明,所建模型的外推性较好,模型具有较高的预测精度.

5 结束语(Conclusion)

本文提出的两群微粒群优化算法是一种改进的微粒群优化算法,它能较好地搜索到全局最优解,优化效率比基本微粒群优化算法有明显提高.将两群微粒群优化算法用于轻柴油95%点软测量,得到的软测量模型具有高的精度、好的性能和好的应用前景.

参考文献(References):

- [1] KENNEDY J, EBERHART R C. Particle swarm optimization[C]// *Proc of IEEE Int Symposium on Neural Networks*. New York: IEEE Service Center, 1995: 1942 – 1948.
- [2] EBERHART R C, KENNEDY J. A new optimizer using particle swarm theory[C]// *Proc of the Sixth Int Symposium on Micro Machine and Human Science*. New York: IEEE Service Center, 1995: 39 – 43.
- [3] PARASOPOULOS K E, VRAHATIS M N. Recent approaches to global optimization problems through particle swarm optimization[J]. *Natural Computing*, 2002, 1(2-3): 235 – 306.
- [4] 张晓东,王伟,王小刚.选矿过程神经网络粒度软测量方法的研究[J]. *控制理论与应用*, 2002, 19(1): 85 – 88. (ZHANG Xiaodong, WANG Wei, WANG Xiaogang. Learning algorithm and convergence of tracking control[J]. *Control Theory & Applications*, 2002, 19(1): 85 – 88.)
- [5] 孙炜,王耀南.模糊小波基神经网络的机器人轨迹跟踪控制[J]. *控制理论与应用*, 2003, 20(1): 49 – 53. (SUN Wei, WANG Yaonan. Learning algorithm and convergence of tracking control[J]. *Control Theory & Applications*, 2003, 20(1): 49 – 53.)

作者简介:

陈国初 (1971—),男,博士,研究领域为化工过程建模、仿真与智能算法及其应用, E-mail: chgcs@sohu.com;

俞金寿 (1939—),男,教授,博士生导师,研究领域为工业过程的建模、仿真、优化与控制等, E-mail: jshyu@vip.sina.com.