

# 基于竞争学习的粒子群优化算法设计及应用

张 钰, 王 蕾, 周红标, 赵环宇

(淮阴工学院 自动化学院, 江苏 淮安 223003)

**摘要:** 针对传统 PSO 算法容易陷入局部最优的问题, 提出一种基于竞争学习的粒子群优化算法 (CLPSO); 在 CLPSO 中, 首先通过动态计算粒子的适应度值将种群分成优选、合理和疏离 3 个子群; 其次, 根据 3 个子群中粒子的进化特性, 为 3 个子群分别设计了不同的更新变异方式; 然后, 利用 12 个基准测试函数对算法的性能进行了验证; 实验结果表明, 所提的竞争学习策略能够有效克服经典 PSO 算法在处理复杂多峰问题时容易陷入局部最优的缺陷; 最后, 利用 CLPSO 算法优化模糊神经网络的参数设计 CLPSO-FNN 算法, 并利用其建立出水氨氮软测量模型, 实验表明, CLPSO-FNN 软测量模型能够更精确、更实时地测量出水氨氮浓度。

**关键词:** 粒子群优化; 多峰问题; 竞争学习; 模糊神经网络; 出水氨氮

## Design and Applications of Particle Swarm Optimization Based on Competitive Learning

ZHANG Yu, WANG Lei, ZHOU Hongbiao, ZHAO Huanyu

(Faculty of Automation, Huaiyin Institute of Technology, Huai'an 223003, China)

**Abstract:** To solve the problem that traditional PSO algorithm is easy to fall into local optimization, a competitive learning-based particle swarm optimization (CLPSO) algorithm is proposed. In CLPSO, first, by dynamically calculating the fitness value of particles, the population is divided into three subgroups: the optimal region, the reasonable region, and the alienated region. Secondly, according to the evolutionary characteristics of the particles in the three subgroups, different updating and variation modes are designed for the three subgroups respectively. Then, 12 benchmark functions are used to verify the performance of the algorithm. The experimental results show that the proposed competitive learning strategy can effectively overcome the premature convergence shortcoming of classical PSO algorithm in dealing with complicated optimization problems. Finally, the CLPSO algorithm was used to optimize the parameters of the fuzzy neural network, and the CLPSO-FNN algorithm was designed, and the soft measurement model of effluent ammonia nitrogen was established. The experiment showed that the CLPSO-FNN soft measurement model could measure the effluent ammonia nitrogen concentration more accurately and in real time.

**Keywords:** particle swarm optimization; multi-modal problems; competitive learning; fuzzy neural network; effluent NH<sub>4</sub>-N

## 0 引言

Kennedy 等人于 1995 年提出的粒子群优化算法具有概念简明、参数易调节、计算效率高和优化精度好的优点, 因此被广泛应用于解决现实生活中各个领域的优化问题<sup>[1-4]</sup>。但是, 随着优化问题复杂度的提高, 传统 PSO 算法的寻优效率越来越低。例如, 在解决复杂的多峰测试问题时, PSO 算法存在早熟收敛现象, 容易陷入局部最优<sup>[5-8]</sup>。在 PSO 算法中, 种群中的每个粒子都代表待优化问题的一个潜在解, 其中粒子状态利用速度向量和位置向量进行表征。在粒子进化过程中, PSO 算法中更新策略的主要目的是推动种群逼近全局最优解。然而, 当全局最优解周围存在多个局部最优时, 种群在飞行过程中有可能会陷入局部

最优<sup>[9-12]</sup>。因此, 如何调整 PSO 算法的飞行参数或重新设计进化机制以提高种群的多样性和优化解的精度是亟待解决的问题。

为了解决此问题, 研究者提出了多种不同的进化策略。文献 [13] 提出了一种改进的分类思想策略, 通过对粒子群进行分类, 进而给不同类设置不同的惯性权重系数和学习因子来平衡粒子的全局探索能力和局部搜索能力。仿真结果表明, 所提策略能够提升算法的收敛速度和寻优精度。文献 [14] 提出了基于协同进化的 PSO 算法 DDAPSO, 将混沌、自适应、非线性和共同演化等诸多策略进行有机集成。仿真结果表明, 该策略能够起到防止算法陷入局部最优的作用。文献 [15] 提出了一种基于双指数自适应惯性

收稿日期: 2020-12-23; 修回日期: 2021-01-20。

基金项目: 国家自然科学基金(61873107); 江苏省“333”工程(BRA2019285)。

作者简介: 张 钰(1994-), 女, 江苏徐州人, 硕士研究生, 主要从事粒子群算法优化方向的研究。

赵环宇(1982-), 男, 江苏淮安人, 教授, 主要从事多智能体方向的研究。

引用格式: 张 钰, 王 蕾, 周红标, 等. 基于竞争学习的粒子群优化算法设计及应用[J]. 计算机测量与控制, 2021, 29(8): 182-189.

权重的 PSO 算法 GPSO-AW。仿真结果表明, 该策略不仅能够加快算法的收敛速度, 而且能够在一定程度上避免算法陷入局部最优。文献 [16] 提出社会粒子群算法, 通过为每个个体设置不同的从众阈值, 相应地决定个体是跟随其他个体还是维持目前状态、或是自由运动, 以保持种群中个体的多样性, 避免算法早熟收敛。文献 [17] 提出混合粒子群算法, 对加速因子采取动态自适应调整策略; 采用混沌序列替代标准粒子群中的随机数; 建立平均粒距、适应度方差并采用混沌算子扰动微粒的位置来跳出局部最优。增强了跳出局部最优的能力。文献 [18] 提出基于学习与竞争的改进 PSO 算法 LC-PSO, 让种群中的个体通过竞争和学习策略替代原有的 PSO 算法迭代公式, 该方法能够在不增加 PSO 算法复杂度的情况下, 克服基本 PSO 算法的不足, 但算法陷入局部最优的可能性依然较大。文献 [19] 提出新颖的 CGCSO, 通过柯西高斯变异更新胜利者的位置, 提高种群的开发能力; 利用环形拓扑结构信息传递速度慢的特点, 将其用于胜利者的学习过程, 增强种群的多样性; 采用可行解优先的约束处理技术, 使该算法能够处理约束优化问题, 该方法在一定程度上提高了算法的性能。

尽管上述 PSO 算法都通过各自所提策略增强了算法跳出局部最优的能力, 但是这些算法中粒子的追随目标仍然以全局最优为主, 陷入局部最优的可能性依然存在<sup>[20]</sup>。因此, 在不过多增加算法复杂度的前提下, 通过重新设计传统 PSO 算法的进化机制, 增强种群多样性, 避免陷入局部最优, 仍然值得进一步的研究。

为了取得全局探索和局部开发的最佳平衡, 本文提出了一种基于竞争学习思想的进化策略, 并将其集成到基本 PSO 算法中, 构建了 CLPSO (competitive learning-based PSO) 算法。在 CLPSO 中, 通过将种群动态地分成 3 个子群, 并为每个子群中的粒子设计不同的进化机制, 从而增强种群多样性, 提高局部搜索能力, 避免了粒子对全局最优粒子的盲目跟随, 克服了在求解多峰问题时容易陷入局部最优的缺陷。

## 1 标准 PSO 算法

在 PSO 算法中, 每个粒子的自身状态都由一组位置和速度向量描述, 分别表示问题的可行解和它在搜索空间中的运动方向。在飞行过程中, 粒子通过不断地学习它所发现的全局最优解和自身历史最优解, 实现全局最优搜索。粒子的速度和位置更新公式如下:

$$v_{ij}(t+1) = \omega v_{ij}(t) + c_1 r_1 (p_{best\ ij}(t) - x_{ij}(t)) + c_2 r_2 (g_{best\ j}(t) - x_{ij}(t)) \quad (1)$$

$$x_{ij}(t+1) = x_{ij}(t) + v_{ij}(t+1) \quad (2)$$

其中:  $\omega$  为惯性权重, 表明粒子的历史速度信息对当前速度的影响, 主要用来权衡算法的局部搜索和全局搜索;  $c_1$  和  $c_2$  为加速度因子, 能够调节个体认知部分和社会部分在粒子群飞行速度中所占比重;  $r$  为  $[0, 1]$  的随机数,

$p_{best}$  为粒子在飞行过程中的历史个体最优位置,  $g_{best}$  为所有粒子飞行过程中的全局最优位置;  $v$  为粒子速度, 通常将粒子的速度限制在  $[-v_{max}, v_{max}]$ , 粒子的速度大小也可以通过惯性权重来平衡;  $x$  为粒子的位置, 即待优化问题的可行解, 通常需要把粒子的搜索范围限定在  $[-x_{max}, x_{max}]$ 。

## 2 基于竞争学习的 PSO 算法

### 2.1 研究动机

首先阐述本文的研究动机。传统 PSO 算法的缺陷如图 1 所示, 其中,  $x_1(t)$  与  $x_2(t)$  表示种群里的两个随机粒子。当粒子的适应度值小于局部最优值、个体最优  $p_{best}$  的位置将远离全局最优而靠近局部最优时, 由于粒子群在进化过程中的飞行状态总是追随个体最优位置  $p_{best}$  和全局最优位置  $g_{best}$ , 因此一旦粒子的  $g_{best}$  陷入局部最优, 种群将不可避免地陷入局部最优。这种现象在复杂的多峰测试问题中表现尤为明显, 如图 1 (a) 所示。另一种情况, 粒子飞行状况良好, 其适应度值介于局部最优值与全局最优值之间, 此时  $p_{best}$  位置不趋近局部最优而是靠近全局最优, 而种群的部分劣质粒子由于只追随个体最优  $p_{best}$  和全局最优  $g_{best}$ , 依然逃不过局部最优的限制, 在进化过程中的适应度值还未达到  $p_{best}$  的值时, 就已陷入局部最优。即使有部分优良粒子可能跳出局部最优, 也会消耗大量的时间。如图 1 (b) 所示。因此, 为了增强种群的多样性和提高种群跳出局部最优的能力, 本文重新定义粒子的更新机制和学习策略, 设计了一套新颖的竞争学习机制。

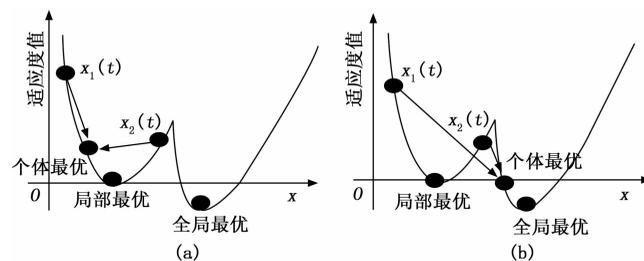


图 1 传统 PSO 算法的缺陷

### 2.2 竞争学习优势

在 CLPSO 算法中, 我们改变了原有粒子的更新策略和学习方式。主要体现在粒子更新过程中, 避开对  $p_{best}$  和  $g_{best}$  的盲目追随, 让所有的粒子通过“竞争上岗”的方式以一定的机率参与或引导整个种群的状态更新。图 2 给出了竞争学习策略的优势示意图, 其中  $x_P(t)$ 、 $x_R(t)$  和  $x_A(t)$  分别代表位于优选区、合理区和疏离区的粒子子群。在 CLPSO 算法中, 优选区粒子通过自我变异进行更新从而增强种群的多样性; 疏离区粒子以优选区粒子为学习目标从而加快收敛速度; 合理区粒子的学习目标在种群  $g_{best}$  和优选区粒子之间进行竞争选择从而平衡算法的探索和开发能力。这样, 即使种群陷入局部最优, 仍然会有部分活跃粒子进行状态的更新, 不但不会造成种群停滞, 反而会扩大种群的寻优空间, 使算法增大跳出局部最优的机率。CLPSO 算

法有效避免了传统 PSO 算法以单一  $p_{best}$  或  $g_{best}$  作为学习对象时存在的局限性。

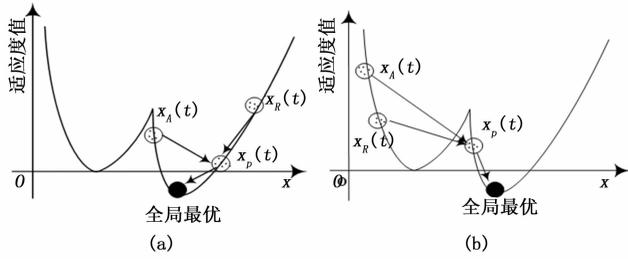


图 2 竞争学习策略的优势

### 2.3 竞争学习机制

本文提出新颖的竞争学习机制来指导粒子调整飞行状态，起到提高 PSO 处理复杂多峰优化问题能力的目的。竞争学习机制的核心是将种群分类。传统的 PSO 算法中粒子的更新方式单一，所有的粒子不论好坏共用同一种更新方式，因此种群缺乏多样性易陷入局部最优。本文所提算法则针对已分组的 3 组粒子的各自特点，设计 3 种独特的更新策略，使每个粒子都能及时调整飞行状态，向全局最优靠近，最终 3 个子群的输出形成新种群  $P(t+1)$ 。

在 CLPSO 中，通过自适应分区操作，每个粒子都参与了适应度值竞争，增强了种群的多样性，扩大了粒子的搜索范围，能够有效避免种群陷入局部最优。下面具体介绍子群的划分依据和每个子群的更新策略。

首先，求出所有粒子的适应度值，按照从小到大排序，再根据适应度值的平均值和标准差对种群中粒子进行分组。平均值和标准差的具体计算公式如下：

$$\bar{f} = \frac{\sum_{i=1}^M f_i}{M} \quad (3)$$

$$\sigma = \sqrt{\frac{1}{M} \sum_{i=1}^M (f_i - \bar{f})^2} \quad (4)$$

其中： $f_i$  为第  $i$  个粒子的适应度值， $N$  为粒子个数， $\bar{f}$  为粒子适应度值的平均值， $\sigma$  为粒子适应度值的标准差。

在划分子群时，首先标记出最靠近平均适应度值的粒子，再以标准差为半径设定合理区粒子的范围，进一步得出疏离区粒子和优选区粒子。子群划分如图 3 所示。

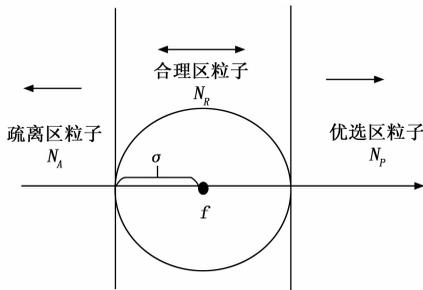


图 3 子群划分图

针对不同的子群，本文分别设计了不同的更新机制。

优选区粒子距离种群最优位置较近，为了避免陷入局部最优，需要增强全局探索能力，因此利用改进的柯西公式设计了自我变异的更新机制。变异后的柯西公式即为优选区粒子更新公式如下：

$$x_{ij}^p(t+1) = x_{ij}^p(t) \cdot (1 + n_i \cdot C(0,1)) \quad (5)$$

$$n_i = \frac{t_{max} - t}{t_{max}} \quad (6)$$

其中： $n_i$  为控制变异步长的参数， $C(0,1)$  是由柯西分布函数产生的随机数。 $x_{ij}^p$  表示优选区粒子的位置。 $t_{max}$  为最大迭代次数， $t$  为当前迭代次数。从公式 (6) 可以看出， $n_i$  能够随着迭代次数的增加而自适应减小，起到了平衡优选区粒子的探索和开发的作用。在进化前期，需要设置一个较大的变异因子值，使得粒子能够跳出局部最优；反之，在进化后期，需要设置一个较小的变异因子值，以加快算法的收敛速度。因此，本文采用了公式 (6) 所示的自适应策略。

疏离区粒子距离种群最优位置较远，为了加快向可能的全局最优解逼近的速度，该区域粒子主要是向优选区粒子进行学习。

疏离区粒子更新公式为：

$$x_{ij}^d(t+1) = c_1 x_{ij}^d(t) + c_2 (x_{ij}^p(t) - x_{ij}^d(t)) + c_3 \alpha (\bar{f} - x_{ij}^d(t)) \quad (7)$$

其中： $c_1$ 、 $c_2$  和  $c_3$  为加速因子。从公式 (7) 可以看出， $x_{ij}^d(t+1)$  是由三部分组成，第一部分和标准 PSO 更新公式的第一部分相同；第二部分中  $x_{ij}^p(t)$  为优选区的粒子，这部分表示疏离区粒子以优选区粒子为学习对象进行状态更新；第三部分引入新的参数  $\alpha$  ( $\alpha$  为一个较小的正数)，这部分表示粒子更新过程还受粒子中心位置的牵制，作用是控制粒子的更新范围，增强算法的收敛性。

合理区粒子需要自适应平衡全局搜索和局部开发，因此为合理区粒子设计了竞争切换机制。合理区粒子更新公式分两种情况：1) 当种群未陷入局部最优时，合理区粒子采用传统的粒子更新方式 (公式 (1)、(2)) 来更新状态，目的是保证种群向全局最优解逐步逼近，保证算法收敛性；2) 当种群陷入局部最优时，粒子当前位置的适应度值与上一次迭代产生的适应度值相同，即  $f(x_i)' - f(x_i)^{t-1} = 0$  时，合理区粒子采用公式 (5) 来更新状态，目的是通过自身变异增强种群搜索能力，增加跳出局部最优的机率。

### 2.4 CLPSO 算法流程

表 1 给出了 CLPSO 算法的伪代码。首先计算初始种群的适应度值并排序，其次按照本文提出的分组标准进行具体分组，然后按照上述公式进行更新形成新的种群，直到满足要求的迭代次数才输出最优解，否则新的种群继续从第一步重复迭代。

### 2.5 复杂度分析

首先假定粒子群规模为  $N$ ，粒子维数为  $D$ ，在原始 PSO 算法中，粒子每进行一次迭代，计算复杂度为  $O(N)$ 。与 PSO 不同，CLPSO 的计算复杂度主要体现在：1) 粒子

每次迭代采用的学习公式的复杂度为  $O(D \times N)$ ; 2) 计算适应度的均值, 其算法复杂度为  $O(N+1)$ ; 3) 以满足要求的迭代次数  $Ite$  作为终止算法的条件, 其算法的整体复杂度为  $O(Ite \times N \times D)$ 。因此, CLPSO 算法整体复杂度为  $O(Ite \times N \times D)$ 。该算法理论复杂度理论上高于经典 PSO 算法, 并且该算法的复杂度会随着粒子个数以及维数的增加而增加, 但在求解时间和效率上, CLPSO 算法具有良好的求解性能。

表 1 CLPSO 伪代码

对 CLPSO 设置初始化参数, i. e., $D=20, N=40, t_{max}=5000$ ;
$t=0$ ;
for $i = 1$ to $N$ do
随机初始化 $x_i$ ;
end for
while 满足迭代条件 do
根据图 3 将种群划分为 3 组;
for $i = 1$ to $N_p$ do
根据公式(5)更新粒子状态;
end for
for $i = 1$ to $N_R$ do
根据公式(2)和公式(5)更新粒子状态;
end for
for $i = 1$ to $N_A$ do
根据公式(7)更新粒子状态;
end for $t=t+1$ ;
end while
输出最终解 $x$

### 3 仿真实验与分析

#### 3.1 基准函数测试

为了验证 CLPSO 算法的性能, 本文采用了 12 个基准测试函数进行验证, 测试函数信息如表 2 所示。前 7 个函数为单峰函数, 其余的均为多峰函数, 并且多个测试函数具有大量的局部极小值, 能够检验 CLPSO 处理多峰问题的能力。

表 2 测试函数

函数	名称	定义域	特性
$f_1(x)$	Sphere	$[-5.12, 5.12]$	unimodal
$f_2(x)$	RHE	$[-65, 536, 65, 536]$	unimodal
$f_3(x)$	Perm	$[-D, D]$	unimodal
$f_4(x)$	Rosenbrock	$[-5, 10]$	unimodal
$f_5(x)$	Dixon-price	$[-10, 10]$	unimodal
$f_6(x)$	Levy	$[-500, 500]$	unimodal
$f_7(x)$	Alpin	$[-10, 10]$	unimodal
$f_8(x)$	Rastrigin	$[-5.12, 5.12]$	multimodal
$f_9(x)$	Girewank	$[-600, 600]$	many local
$f_{10}(x)$	Schwefel	$[-500, 500]$	many local
$f_{11}(x)$	Zakharov	$[-5, 10]$	many local
$f_{12}(x)$	Ackley	$[-32.768, 32.768]$	many local

#### 3.2 参数设置

为了展示 CLPSO 算法的优势, 本文选择了 4 个典型的 PSO 变体与 CLPSO 进行比较, 分别是基本 PSO、带有自适应惯性权重的全局 PSO (GPSO-AW)、DDAPSO、LC-PSO。具体参数设置如表 3 所示。为了确保使用不同算法来进行实验对比的公正性, 实验时, 测试函数的维数  $D$  设为 20, 种群规模  $N$  设为 40, 最大值迭代次数  $t_{max}$  设为 5 000, 每个算法独立运行 100 次。

表 3 算法参数设置

算法	参数
PSO	$\omega=0.6, c_1=c_2=1.49$
GPSO-AW <sup>[15]</sup>	$\omega=[0.4, 0.9], c_1=c_2=1.49$
DDAPSO <sup>[14]</sup>	$\omega=0.6, c_1=c_2=1.49$
LC-PSO <sup>[18]</sup>	$\omega=[0.4, 0.9], c_1=c_2=1.49$
CLPSO	$\omega=[0.4, 0.9], c_1=c_2=1.49$

#### 3.3 实验结果

表 4 给出了不同算法在 12 个基准测试函数上的性能比较结果。图 4 给出了 5 种算法分别在 12 个基准测试函数的收敛性能比较。分析表 4 与图 4 可以看出, 对于  $f_1 \sim f_7$  这 7 个单峰测试函数, CLPSO 的收敛速度明显比其他 4 种算法快很多, 表明 CLPSO 在处理单目标问题时效率较高, 性能较好。在其他机组多峰函数测试中, DDAPSO 在  $f_8$  函数上表现最好, 对于  $f_9 \sim f_{12}$  这 4 个函数, CLPSO 的收敛速度最快, 尤其在  $f_{11}$  与  $f_{12}$  上表现处更优秀的收敛速度, 虽然 CLPSO 有着创新思路, 但在算法性能各方面不可能超越全部变体算法, 能超越大部分算法的性能, 结果可视为较为满意。实验结果表明, 相比传统 PSO、GPSO-AW、DDAPSO 和 LC-PSO 这 4 种变体算法, CLPSO 算法在处理多峰问题上依然具有较大的优势。究其原因, 当种群遭遇陷入局部最优的问题时, CLPSO 算法采用的竞争策略使得优选区粒子仍保持较大活性, 同时疏离区粒子与合理区的粒子都依然有全新的追随目标进行自身飞行状态的更新, 这使得粒子群能够通过自适应变异跳出局部最优, 继而增大寻优精度。

### 4 出水氨氮实验分析

模糊神经网络 (FNN, fuzzy neural network) 一直存在难以选取合理的学习参数的问题, 而粒子群算法具有参数易调节、计算效率高、实现方便等优势, 因此将粒子群算法用于优化模糊神经网络的参数进而提高网络性能已成为研究热点。粒子群算法性能越好, 模糊神经网络的性能也会被优化的越好。因此为了进一步验证 CLPSO 的性能, 在本节采用 CLPSO 算法优化模糊神经网络的中心和宽度参数 (FNN 的最优权值参数采用最小二乘法求解), 构建 CLPSO-FNN 模型, 实现污水处理过程出水氨氮 ( $\text{NH}_4\text{-N}$ ) 预测。

#### 4.1 模糊神经网络

FNN 是在神经网络 (neural network) 和模糊系统 (fuzzy

表 4 不同算法性能比较数据

测试函数	对比标准	PSO	GPSO-AW	DDAPSO	LC-PSO	CLPSO
$f_1$	MEAN	2.647 8	0.152 3	0.192 3	0.039 1	0.009 8
	SD	2.001 2	0.008 9	0.285 4	0.142 5	0.127 8
$f_2$	MEAN	397.267 4	3.912 4	289.524 6	2.997 1	2.417 7
	SD	187.326 7	49.761 9	254.298 5	3.921 0	2.990 1
$f_3$	MEAN	47.235 5	0.602 3	89.352 3	0.502 3	0.499 8
	SD	48.923 4	0.902 3	88.347 9	0.702 3	0.462 3
$f_4$	MEAN	289.123 9	5.912 5	56.102 3	11.034 1	4.203 4
	SD	299.612 3	9.023 4	30.235 2	9.001 2	7.991 2
$f_5$	MEAN	14.102 3	0.039 9	13.102 3	0.182 3	0.005 6
	SD	8.990 1	0.058 8	59.014 5	0.139 1	0.291 8
$f_6$	MEAN	2.95E+04	89.348 1	598.235 6	98.345 4	90.752 3
	SD	1.88E+04	133.134 5	2.11E+03	146.246 3	134.238 5
$f_7$	MEAN	10.342 3	9.991 2	0.309 7	5.035 3	0.391 5
	SD	9.035 1	8.915 6	0.682 4	6.092 3	1.001 2
$f_8$	MEAN	3.014 3	11.653 4	10.201 2	0.102 4	0.021 8
	SD	1.781 2	9.681 4	13.276 9	0.081 3	0.052 3
$f_9$	MEAN	2.91E+04	110.356 1	0.492 0	79.623 4	0.049 8
	SD	1.85E+04	185.392 2	0.401 6	48.340 1	0.116 2
$f_{10}$	MEAN	3.02E+04	145.034 5	1.99E+03	90.341 2	66.305 2
	SD	1.87E+04	188.234 1	471.2943	98.375 1	82.353 1
$f_{11}$	MEAN	12.452 3	99.452 3	8.935 2	6.020 9	1.970 6
	SD	10.342 1	52.351 3	6.130 1	12.004 3	4.342 3
$f_{12}$	MEAN	116.394 1	0.686 2	6.013 5	0.551 2	0.395 2
	SD	78.348 1	1.003 5	7.395 2	1.034 6	1.937 5

systems) 的基础上发展起来的, 是一个集语言计算、逻辑推理、分布式处理和非线性动力学过程为一身的系统。作为新的智能信息处理方法, 它具有良好的发展前景, 受到广泛关注。模糊神经网络是模糊系统与人工神经网络的结合。

模糊神经网络的结构如图 5 所示。

第一层: 输入层。每个神经元接受一个输入数据信号  $x_i$ , 并向下一层传递每个节点为输入节点  $x_i$ 。只有输入信号才能被传递到网络的下一层。

第二层: 隶属函数层。该层功能是对输入层进行模糊化操作, 计算输入变量属于各模糊集的模糊隶属度。节点的激励函数是各条模糊规则的前提中的各模糊集的隶属度函数, 每个隶属度函数为高斯隶属度函数 (sigmoid), 由不确定均值  $[m_{ij1}, m_{ij2}]$  和固定标准差 (STD)  $\sigma_{ij}$  的表示。函数表示如下:

$$x_{ij}^{(2)} = \exp\left\{\frac{[x_i^{(1)} - m_{ij}]^2}{\sigma_{ij}^2}\right\} = N(m_{ij} \cdot \sigma_{ij}; x_i^{(1)}, m_{ij} \in [m_{ij1}, m_{ij2}]) \quad (8)$$

其中:  $m_{ij}$  表示第  $j$  项得第  $i$  次输入的均值,  $\sigma_{ij}$  表示和标准高斯隶属度函数的固定标准差。高斯隶属函数的不确定性足迹表示上隶属函数  $\bar{x}_{ij}^{(2)}$  和下隶属函数  $\underline{x}_{ij}^{(2)}$  的一个有界区间。

第三层: 规则层。节点的输出是输入的乘积, 每一个节点的输出代表输入样本和一条规则的前提的匹配程度。通过代数积计算得到每个规则节点  $\bar{x}_j^{(3)}$  和  $\underline{x}_j^{(3)}$  的激发强度。公式如下:

$$\bar{x}_j^{(3)} = \prod_i \bar{x}_{ij}^{(2)} \text{ and } \underline{x}_j^{(3)} = \prod_i \underline{x}_{ij}^{(2)} \quad (9)$$

其中:  $\prod_i \bar{x}_{ij}^{(2)}$  和  $\prod_i \underline{x}_{ij}^{(2)}$  表示发射强度规则对应的上下边界区间。

第四层: 规范化层。经过去模糊化处理, 实现中心去模糊, 它和第三次的连接权重  $w_{ij}$  是第  $j$  条规则的第  $i$  个输出模糊集的隶属度函数的中心点值, 可以得到一个合理的值。

$$x_j^{(4)} = \frac{\sum_{i=1}^s w_{ij} x_{ij}^3}{\sum_{k=1}^s x_{kj}^3} \quad (10)$$

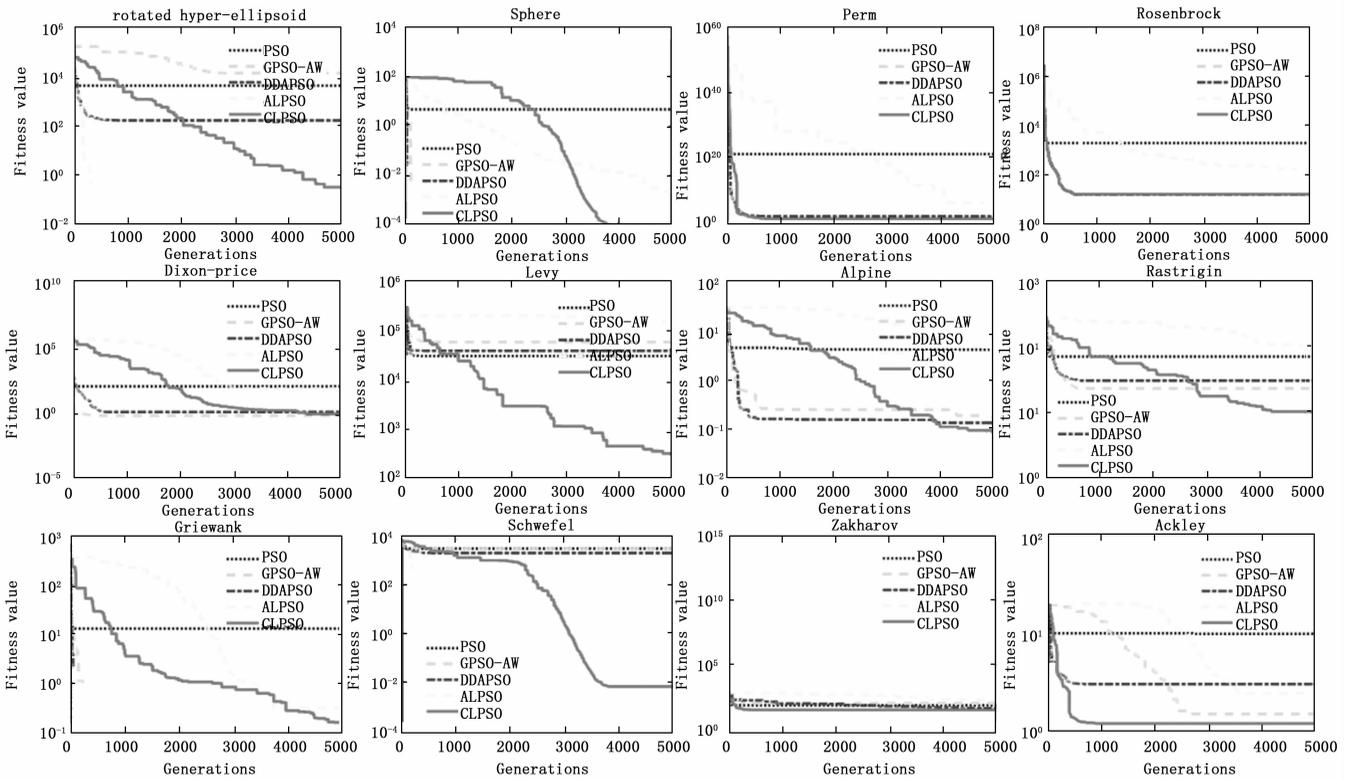


图 4 不同 PSO 变体算法在 12 种基准测试函数上的进化曲线

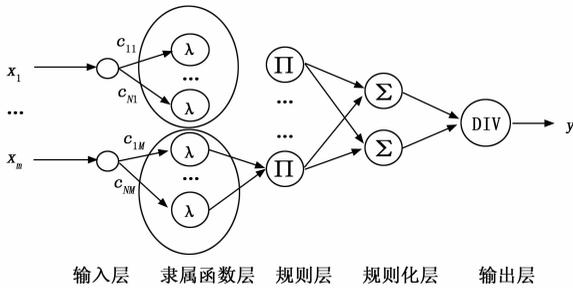


图 5 模糊神经网络结构图

第五层: 输出层。最后通过计算  $\bar{x}^{(4)}$  和  $\bar{x}^{(4)}$  平均值完成去模糊化, 得到输出  $y$ , 在传统模糊神经网络中, 去模糊化过程的计算复杂度通常很高。

$$y = \frac{\bar{x}^{(4)} + \bar{x}^{(4)}}{2} = x^{(5)} \quad (11)$$

### 4.2 CLPSO 优化模糊神经网络

为了获得更好的评价精度, 采用 CLPSO 算法对 FNN 参数进行校正。其原理是将 FNN 初始化的一组参数包括中心值、宽度值输入 CLPSO 算法, 利用 CLPSO 的寻优能力, 找到一组最适合 FNN 的参数后反馈给 FNN 使用。带自适应学习策略的粒子群优化算法通过根据种群本身的分布情况进行自适应的子群划分和粒子更新, 避免了陷入局部最优, 提高了参数优化的准确性。CLPSO 的自适应特征自适应学习策略可以使 FNN 模型来确定最优参数快速、准确。

CLPSO 优化 FNN 伪代码如表 5 所示, 流程如图 6 所示, CLPSO 优化 FNN 流程如下:

表 5 CLPSO 优化 FNN 伪代码

Algorithm: CLPSO
对 CLPSO 设置初始化参数, i. e., $D=20, M=40, t_{\max}=5\ 000$ ;
$t=0$ ;
for $i=1$ to $M$ do
随机初始化 $x_i$ ;
end for
while 满足迭代条件 do
根据图 3 将种群划分为 3 组;
for $i=1$ to $M_p$ do
根据公式(5)更新粒子状态;
end for
for $i=1$ to $M_R$ do
根据公式(2)和公式(5)更新粒子状态;
end for
for $i=1$ to $M_A$ do
根据公式(7)更新粒子状态;
end for
$t=t+1$ ;
end while
输出最终解 $x$

- 1) 设置 FNN 和 CLPSO 算法的初始参数。
- 2) 将样本数据划分为训练集和测试集, 并对样本数据

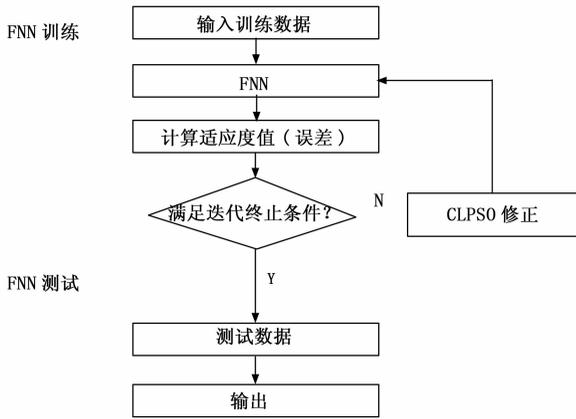


图 6 CLPSO 优化 FNN 流程图

进行归一化预处理，以保证评价结果的质量。

3) 采用 CLPSO 算法对 FNN 参数进行校正。

4) 随机初始化 CLPSO 算法的粒子位置，这些位置分别代表 FNN 的中心值、宽度值和模糊系统参数。

5) 输入训练数据，利用 FNN 算每个粒子的适应度。这里，适应度值是输出值与目标值之间的均方误差 (RMSE)。

6) 计算适应度值，调整 FNN 的权值直到满足终止条件。

7) 使用训练好的 FNN 进行测试。

8) 如果测试结果令人满意，则输出该 FNN。

### 4.3 出水氨氮测量浓度实验

实验采用水温 (WT)、溶解氧 (DO) 浓度、出水 pH、氧化还原电位 (ORP)、出水硝态氮 ( $\text{NO}_3\text{-N}$ ) 这 5 个相关变量作为输入，出水  $\text{NH}_4\text{-H}$  作为唯一的输出。从某小型污水处理厂采样数据 1 000 组，随机间隔抽取 900 组作为训练集，剩余 100 组作为测试集，为取得良好实验结果，将 CLPSO 维度设置 200 维，种群规模为 40，迭代次数为 500 次。

图 7 给出了 4 种对比算法模型对出水  $\text{NH}_4\text{-N}$  浓度的预测结果和预测误差。通过分析比较图 7 (a)，可以看出 CLPSO-FNN 的预测值能够较好地拟合出水  $\text{NH}_4\text{-N}$  实际值，表明 CLPSO-FNN 模型对出水  $\text{NH}_4\text{-N}$  含量具有较高的预测精度。分析图 7 (b) 可知，MLP 与 FNN-EBP 两种模型对出水  $\text{NH}_4\text{-H}$  的预测误差较大，CLPSO-FNN 预测误差最小，主要集中在  $\pm 0.3$  之间，表明 CLPSO-FNN 的预测性能较好，可以用于建立污水处理过程优化控制的优化模型。CLPSO-FNN 模型性能较好的原因有以下几点，首先 FNN 本身就比 Mathematic model 和 Dynamic ARX 以及 MLR 这 3 种数学机理模型性能优越，其次是，由于 FNN 的维数较高，达到 200 维，利用传统的 PSO 优化 FNN 易陷入局部最优，本文 CLPSO 算法性能要优于传统 PSO，因此利用 CLPSO 来优化 FNN 能够避免陷入局部最优，取得更好的网络性能。表 6 给出了不同算法优化 FNN 的性能比较，可以看出，CLPSO-FNN 算法的建模性能不仅优于诸如 Mathematic model 和 Dynamic ARX 等数学机理

模型，而且优于传统的 DFNN、FNN-EBP 以及 PSO 和 LC-PSO 优化的 FNN 模型。

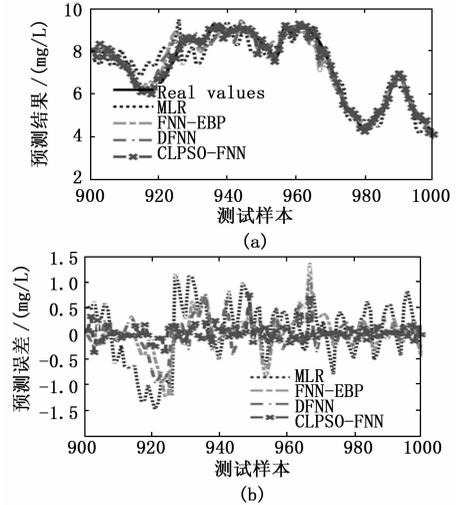


图 7 出水  $\text{NH}_4\text{-N}$  的预测结果和预测误差

表 6 不同算法性能比较

算法	规则数	测试 RMSE	精确度 / %
Mathematic <sup>[22]</sup>	—	—	90.87
DynamicARX <sup>[23]</sup>	—	—	85.12
MLR <sup>[24]</sup>	—	0.624 4	90.51
FNN-GSA <sup>[25]</sup>	16	0.338 0	96.15
D-FNN <sup>[26]</sup>	20	0.283 6	96.28
FNN-EBP	20	0.497 2	94.38
PSO-FNN	20	0.375 8	95.68
LC-PSO-FNN	20	0.223 6	96.64
<b>CLPSO-FNN</b>	<b>20</b>	<b>0.190 3</b>	<b>97.22</b>

## 5 结束语

本文设计了一种基于竞争学习的粒子群优化算法 (CLPSO)，使得算法在处理多峰问题时，能够有效地避免种群早熟收敛和陷入局部最优。12 个基准测试问题的结果表明带有竞争学习机制的 CLPSO 算法能够有效取得探索和开发能力的最佳平衡。从进化曲线可以看出 CLPSO 算法在处理多峰问题时不仅能够跳出局部最优，取得较好的优化解，而且能够通过竞争学习机制在进化前期加快学习速度，统筹考虑了速度和精度。此外，利用 CLPSO 算法优化模糊神经网络的中心和宽度，从而构建污水处理过程出水氨氮的软测量模型，结果表明 CLPSO 算法在处理流程工业数据时也有不错表现，为复杂系统关键变量的预测和控制提供了一种可供选择的方案。下一步的工作是将竞争学习策略引入到多目标粒子群算法，用于解决具有复杂 Pareto 前沿的多目标测试问题和实际工程中多目标优化问题。

### 参考文献:

[1] MAJI T K, ACHARJEE P. Multiple solutions of optimal PMU placement using exponential binary PSO algorithm for smart grid

- applications [J]. IEEE Transactions on Industry Applications, 2017, 53 (3): 2550 - 2559.
- [2] 刘小园. 量子粒子群算法在 WSN 三维定位中的研究 [J]. 计算机应用与软件, 2018, 35 (3): 120 - 123, 144.
- [3] WANG F, ZHANG Y, RAO Q. Exploring mutual information - based sentimental analysis with kernel - based extreme learning machine for stock prediction [J]. Soft Computing, 2017, 21 (12): 3193 - 3205.
- [4] CAI L Y. On cloud computing resource allocation based on particle swarm optimization algorithm [J]. Journal of Southwest China Normal University (Natural Science Edition), 2017, 42 (9): 128 - 132.
- [5] ZHANG M, MA J, GONG M. Unsupervised hyperspectral band selection by fuzzy clustering with particle swarm optimization [J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14 (5): 773 - 777.
- [6] LI P, LI J, HUANG Z. Privacy - preserving outsourced classification in cloud computing [J]. Cluster Computing, 2018, 21 (1): 277 - 286.
- [7] WU H, KUANG L, WANG F. A multiobjective box - covering algorithm for fractal modularity on complex networks [J]. Applied Soft Computing, 2017, 61: 294 - 313.
- [8] PAN X, XUE L, LU Y. Hybrid particle swarm optimization with simulated annealing [J]. Multimedia Tools and Applications, 2019, 78 (21): 29921 - 29936.
- [9] 李 浩, 毕 利, 靳彬锋. 改进的粒子群算法在多目标车间调度的应用 [J]. 计算机应用与软件, 2018, 35 (3): 49 - 53, 74.
- [10] WU X, SUN M, CHEN X. Empirical study of particle swarm optimization inspired by Lotka - Volterra model in Ecology [J]. Soft Computing, 2019, 23 (14): 5571 - 5582.
- [11] 何金超, 罗 芳, 袁知才, 等. 协同过滤和粒子群算法在饮食推荐中的应用 [J]. 计算机应用与软件, 2019, 36 (8): 36 - 40, 59.
- [12] WANG D, TAN D, LIU L. Particle swarm optimization algorithm: an overview [J]. Soft Computing, 2018, 22 (2): 387 - 408.
- [13] TONG Q J, LI M, ZHAO M. Improved particle swarm optimization algorithm based on classification idea [J]. Modern Electronic Technology, 2019, 42 (19): 11 - 14.
- [14] SONG M, GE Y H, LIU J S. An improved dynamic dual adaptive PSO algorithm based on the theory of co - evolution [J]. Computer Engineering and Applications. 2020, 56 (13): 54 - 62.
- [15] HAN H G, LU W, QIAO J F. Design and application of A particle swarm optimization algorithm based on population diversity [J]. Science and Control, 2017, 46 (6): 677 - 684.
- [16] LIANG Y. Search pattern analysis application of the particle swarm optimization [D]. East China University of Science and Technology, 2011.
- [17] 丁 芳, 宋小静. 混合粒子群算法在 ETV 调度优化中的应用 [J]. 计算机应用与软件, 2019, 36 (8): 262 - 267, 316.
- [18] CAI H H. On a modified PSO algorithm based on learning and competitiveness [J]. Journal of Southwest China Normal University (Natural Science Edition), 2019, 44 (5): 115 - 120.
- [19] ZHANG Q, CHENG H, YE Z C. Improved competitive swarm optimizer and its applications [J]. Computer Engineering and Design, 2019, 40 (2): 377 - 383.
- [20] 罗义强, 陈智斌. 基于改进粒子群算法的高校排课问题优化 [J]. 计算机应用与软件, 2018, 35 (6): 241 - 247, 303.
- [21] ZHOU H B, ZHAO H Y, ZHANG Y. Nonlinear system modeling using self - organizing fuzzy neural networks for industrial applications [J]. Applied Intelligence, 2020: 1 - 16.
- [22] WANG Z, CHU J S, SONG Y. Influence of operating conditions on the efficiency of domestic wastewater treatment in membrane bioreactors [J]. Desalination, 2009, 245: 73 - 81.
- [23] YUAN Z G, WANG J J. Research on dynamic model of preheater based on RBF - ARX model [C] //2009 Ninth International Conference on Hybrid Intelligent Systems, Shenyang, 2009: 158 - 162.
- [24] ZHANG R D, TAO J L. A nonlinear fuzzy neural network modeling approach using an improved genetic algorithm [J]. IEEE Transactions on Industrial Electronics, 2018, 65 (7): 5882 - 5892.
- [25] ZHOU H B, QIAO J F. Soft - sensing of effluent ammonia nitrogen using rule automatic formation - based adaptive fuzzy neural network [J]. Desalination and water treatment, 2019, 140 (2): 132 - 142.
- [26] WU S Q, ER M J. Dynamic fuzzy neural networks - a novel approach to function approximation [J]. IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), 2000, 30 (2): 358 - 364.
- [6] 陈 柱, 徐国华, 王冠学, 等. AUV 主动应急自救机制与决策 [J]. 中国舰船研究, 2018, 13 (6): 120 - 127.
- [7] 向先波, 徐国华, 蔡 涛, 等. 水下机器人智能自救系统 [J]. 华中科技大学学报 (自然科学版), 2006, 34 (7): 111 - 114.
- [8] 吕志刚. 一种无人水下航行器智能自救系统的研制 [J]. 舰船电子工程, 2019, 1: 143 - 146.
- [9] 王得成. AUV 浮力调节与安全抛载系统研究 [D]. 哈尔滨: 哈尔滨工程大学, 2015.
- [10] 董升亮, 韦统安, 袁题训, 等. 智能型智能型通用水下自救释放系统 [J]. 现代电子技术, 2011, 34 (21): 133 - 135.