

文章编号: 2095-2163(2021)12-0072-06

中图分类号: TE341

文献标志码: A

# 基于免疫粒子群算法的分层注水流量调度

蒋敬轩<sup>1</sup>, 张著洪<sup>2</sup>

(1 贵州大学 大数据与信息工程学院, 贵阳 550025;

2 贵州大学 贵州省系统优化与科学计算特色重点实验室, 贵阳 550025)

**摘要:** 针对油井分层注水流量调度问题, 依据油井注水层段流量以及压力关系, 建立双层注水流量调度模型, 并提出求解的免疫粒子群优化算法。算法设计中, 将免疫优化中浓度调节机制引入到粒子群优化中, 增强种群的多样性; 通过设计动态调节惯性权重和学习率因子的规则, 增强粒子的全局开采能力。数值实验结果表明, 所建立的双层注水流量调度模型是有效的; 获得的算法能根据油井注水层段配注量的需求, 较为准确地计算油井层段水嘴的开度值, 使注水偏差量较小及注水量能达到配注的要求; 该模型和算法对油井智能注水具有一定的应用潜力。

**关键词:** 分层注水; 地层压力; 注水量; 流量模型; 免疫粒子群优化

## Separated-layer water flooding flow dispatching based on immune particle swarm optimization

JIANG Jingxuan<sup>1</sup>, ZHANG Zhuhong<sup>2</sup>

(1 College of Big Data and Information Engineering, Guizhou University, Guiyang 550025, China; 2 Guizhou Provincial Characteristic Key Laboratory of System Optimization &amp; Scientific Computation, Guizhou University, Guiyang 550025, China)

**[Abstract]** Aiming at the problem of oil wells' separated-zone water injection flow scheduling, a double-layer scheduling model is acquired by analyzing the relation between water injection pressure and interval flow, and later an immune particle swarm optimization algorithm is designed to solve the model. In the design of the algorithm, a concentration regulation mechanism from the branch of immune optimization is embedded into the standard particle swarm optimization algorithm, in order to strength the diversity of population; a rule to dynamically adjust the inertia weight and learning rate factors is also designed to strenght the ability of global exploration. The numerical results show that the two-layer water injection flow scheduling model is effective; the obtained algorithm can accurately calculate the nozzle opening value of oil well layer according to the demand of injection volume, so that the injection deviation is small and the injection volume can meet the requirement of injection volume; the model and algorithm are of potential to wells' intelligent injection water.

**[Key words]** separated-layer water injection; ground pressure; water injection rate; flow model; immune particle swarm optimization

## 0 引言

随着时代发展步伐的加快, 石油资源的需求不断加大, 导致原油不断枯竭和开发难度增大。由于地层间各储油层物理性质差异较大, 导致储层吸水能力各不相同。当笼统地注水进入地质油层时, 大量的水被高渗透地层吸收, 造成注水吸水剖面不均匀, 注入的水利用率低。由此, 如何依据地层的地质状况, 合理的为地层管道分配水资源, 使得地层稠密的油层得到充分稀释, 已成为石油开采业实现智能注水关注的重要科技问题。

依据注水井分层注水的工艺, 通常采用3种注水方法, 即桥式偏心注水<sup>[1-2]</sup>、同心集成注水<sup>[3-4]</sup>以及恒流量注水<sup>[5-6]</sup>。第一种方法用封隔器, 将注水管柱分隔成能与各注水层位相对应的独立管段, 使得注入的流体能流经桥式偏心配水器和堵塞器进入地层, 但注水流程复杂<sup>[2]</sup>。第二种方法的配水流程与前一种类似, 其通过将可调水嘴与配水器一体化集成, 实现配水器中心通道内水嘴免投捞配水作业, 可提升配水测调的合格率<sup>[3]</sup>, 但测调时间较长。第三种方法, 利用预压缩弹簧来平衡水嘴前后的压差, 尽可能使通过孔径水嘴的流量为常数, 达到恒流量

**基金项目:** 国家自然科学基金(62063002, 61563009)。

**作者简介:** 蒋敬轩(1993-), 男, 硕士研究生, 主要研究方向: 智能优化; 张著洪(1966-), 男, 博士, 教授, 博士生导师, 主要研究方向: 数据科学与计算智能、深度学习等。

**通讯作者:** 张著洪 Email: zhzhang@gzu.edu.com

收稿日期: 2021-09-13

的目的。近来,智能优化已初步渗透到油井分层注水调度优化研究中,并已成为油井注水研究的新课题,为油井注水层段难以按需求注水的问题提供了新的解决路径。其主要目的是将分层注水能耗问题转化为最优问题,进而通过智能优化方法使注水能耗降低<sup>[7-10]</sup>。例如,文献[6]中提出的新型定差式恒流量注水工艺,能在注水井的进口或地层压力发生变化情况下,维持注水量恒定,此方法虽能缩短配水周期,但配水工艺繁琐。文献[7]中提出,以注水能效或单耗为性能指标,建立注水系统优化的数学模型,进而通过设计求解的智能优化算法,使注水能耗尽可能小。

综上,由于油井地下环境复杂、注水管柱受地下环境污染严重、地层压力对注水管柱的影响较大,使得注水层段注水量需求的研究较少,也尚未取得突破性进展。为此,本文从注水层段注水量的需求角度,以注水偏差量为性能指标,建立注水流量模型,进而通过设计免疫粒子群优化算法,寻找最佳水嘴开度方案,使得各注水层的注水量满足注水层配注量的要求。

## 1 双层注水调度模型

### 1.1 注水层注水流量计算

油井分层注水由两个注水层构成,每一个注水层段均安装有一个可调节开度的水嘴。根据流体力学中的伯努利定律,流体流入水嘴的流量与经水嘴流出的流量相等。于是,第一、二注水层的水嘴开度面积  $A_1$ 、 $A_2$  应满足如下等式:

$$\begin{cases} \frac{P_0}{\rho g} + \frac{v_0^2}{2g} + H = \frac{P_1}{\rho g} + \frac{1}{2g} \left( \frac{Q_1}{A_1} \right)^2 + h_{w1}, \\ \frac{P_0}{\rho g} + \frac{v_0^2}{2g} + H + L = \frac{P_2}{\rho g} + \frac{1}{2g} \left( \frac{Q_2}{A_2} \right)^2 + h_{w2} \end{cases} \quad (1)$$

其中,  $P_0$ 、 $P_i$  分别为井口、第  $i$  地层的注入压力 (Pa),  $i = 1, 2$ ;  $h_{wi}$  为第  $i$  注水层中水嘴水头损失 (m);  $v_0$  为井口的流体流速 (m/s);  $Q_i$  为分配给第  $i$  注水层的注水量 ( $\text{m}^3/\text{d}$ );  $A_i$  为第  $i$  注水层中水嘴的开度面积 ( $\text{m}^2$ );  $H$  为井口到第一注水层的深度 (m);  $L$  为第一、二注水层的层间距离 (m);  $\rho$  为注入流体密度 ( $\text{kg}/\text{m}^3$ );  $g$  为重力加速度 ( $\text{m}/\text{s}^2$ )。

第  $i$  注水层的水嘴水头损失  $h_{wi}$  是由水嘴沿程阻力损失<sup>[11]</sup>  $h_{fi}$  与水嘴局部水头损失<sup>[12]</sup>  $h_{ji}$  构成,  $i = 1, 2$ , 即:

$$h_{wi} = h_{fi} + h_{ji} \quad (2)$$

$h_{fi}$  由下式计算:

$$h_{fi} = \lambda \frac{Kv_i^2}{2d_i g} \quad (3)$$

其中,

$$\lambda = \begin{cases} \frac{64}{R_e}, & R_e < 2\,000 \\ \frac{0.3164}{\sqrt[4]{R_e}}, & \text{else} \end{cases} \quad (4)$$

式中,  $\lambda$  为摩擦力系数;  $R_e$  为雷诺数 ( $R_e = \rho v_i d_i \mu^{-1}$ );  $v_i$  为第  $i$  注水层水嘴处流体流速 (m/s);  $\mu$  为流体动力粘度 ( $\text{Pa} \cdot \text{s}$ );  $d_i$  为第  $i$  注水层水嘴管径 (m);  $K$  为水嘴管长 (m)。

当流体流经阀门、弯头、三通等配件时,由于均匀流动受到破坏,流速的大小发生变化,导致管道流动出现局部阻力损失,因此  $h_{ji}$  由下式确定:

$$h_{ji} = 0.5 \left( 1 - \frac{A_{wf}}{A_{pc}} \right) \frac{v_i^2}{2g} \quad (5)$$

式中,  $A_{wf}$  为水嘴阀口的面积 ( $\text{m}^2$ ),  $A_{pc}$  为注水管柱的截面积 ( $\text{m}^2$ )。

此外,依据静水压力平衡的性质<sup>[13]</sup>,式(1)中地层注入压力  $P_1$ 、 $P_2$  可由下列压力模型确定:

$$\begin{cases} P_0 + \rho g H = P_1 + \Delta P_{N1} + \Delta P_{M1} \\ P_0 + \rho g (H + L) = P_2 + \Delta P_{N2} + \Delta P_{M1} + \Delta P_{H2} \end{cases} \quad (6)$$

式中,  $\Delta P_{M1}$ 、 $\Delta P_{N1}$  分别为第  $i$  注水层的沿程阻力损失和水嘴压力损失 (Pa),  $i = 1, 2$ 。其依次由下式确定:

$$\begin{cases} \Delta P_{M1} = 8\lambda \rho \frac{H Q_0^2}{\pi^2 d^5}, \\ \Delta P_{H2} = 8\lambda \rho \frac{L (Q_0 - Q_1)^2}{\pi^2 d^5}, \\ \Delta P_{N1} = 0.5 \left( 1 - \frac{A_{wf}}{A_{pc}} \right) \frac{\rho v_i^2}{2} \end{cases} \quad (7)$$

式中,  $v_i$  为第  $i$  注水层的水嘴处流体流速 (m/s),  $d$  为注水管柱管径 (m)。

### 1.2 注水优化模型

经由式(6)可获得注水层的地层注入压力  $P_1$  和  $P_2$ ,进而经由式(1)可知,  $Q_1$  和  $Q_2$  可由  $A_1$ 、 $A_2$  唯一确定。假定:第一、二注水层的配水量分别为  $q_1$  和  $q_2$ ,则双层注水调度问题即为寻找最优的水嘴开度面积,使得各注水层的注水流量与配水量的偏差在给定限制下达到最小,此可经由求解如下模型得以解决:

$$\min f(x) = \sum_{j=1}^2 (q_j - Q_j), x = (A_1, A_2)$$

$$s.t. \begin{cases} \sum_{j=1}^2 Q_j \leq Q_0, \sum_{j=1}^2 (\Delta P_{Nj} + \Delta P_{Hj}) < P_0, \\ 0 \leq Q_i \leq q_i, P_{ia} \geq P_i, 0 \leq A_i \leq 0.8, i = 1, 2 \end{cases} \quad (8)$$

式中,  $Q_0$  为总注水量 ( $\text{m}^3/\text{d}$ );  $P_{ia}$  和  $P_i$  分别是第  $i$  层的水嘴前注水压力和地层注入压力 (Pa);  $i = 1, 2$ 。

引入如下罚函数:

$$P(x) = \sum_{i=1}^2 \max\{0, 0 - A_i\} + \sum_{i=1}^2 \max\{0, A_i - 0.8\} + \max\{0, \sum_{j=1}^2 Q_j - Q_0\} + \sum_{i=1}^2 \max\{0, 0 - Q_i\} + \sum_{i=1}^2 \max\{0, Q_i - q_i\} + \sum_{i=1}^2 \max\{0, P_{ia} - P_i\} + \max\{0, \sum_{j=1}^2 (\Delta P_{Nj} + \Delta P_{Hj}) - P_0\} \quad (9)$$

则上述注水优化模型可转化为如下含惩罚因子  $\sigma$  的非约束优化模型 (NP):

$$\min F(x) = f(x) + \sigma P(x) \quad (10)$$

## 2 免疫粒子群优化算法

粒子群优化是一种模拟鸟群觅食行为的群智能优化算法。其粒子包含速度和位置属性,速度用于刻画粒子移动的快慢,而位置则用于刻画粒子移动的方向。粒子之间通过合作与竞争来搜索优化问题的最优解。结合以上模型 NP, 候选解或粒子  $x_i$  在迭代过程中,经由下式更新自身位置与速度:

$$v_{id}^{k+1} = \omega^k v_{id}^k + c_1 r_1 [P_{id}^k - x_{id}^k] + c_2 r_2 [P_{gd}^k - x_{id}^k] \quad (11)$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \quad (12)$$

式中,  $d$  为目标搜索空间维数;  $k$  为迭代次数;  $\omega$  为惯性权重;  $c_1, c_2$  为学习因子;  $r_1, r_2$  为介于  $[0, 1]$  之间的随机数;  $P_{id}$  为粒子  $x_i$  在搜索空间中第  $d$  维度方向的个体极值;  $P_{gd}$  为全局最好粒子在搜索空间中第  $d$  维度方向的全局极值。

在粒子群优化算法 (PSO) 中,由于惯性权重和学习因子的缘故,导致在迭代后期的收敛速度慢且易陷入局部搜索。鉴于此,通过使  $\omega, c_1, c_2$  随机扰动或动态变化,以及引入免疫优化中调节群体多样性的抗体浓度<sup>[14]</sup>,获得求解以上模型 (NP) 的免疫粒子群优化 (Immune Particle Swarm Optimization, IPSO) 算法,其流程如图 1 所示:

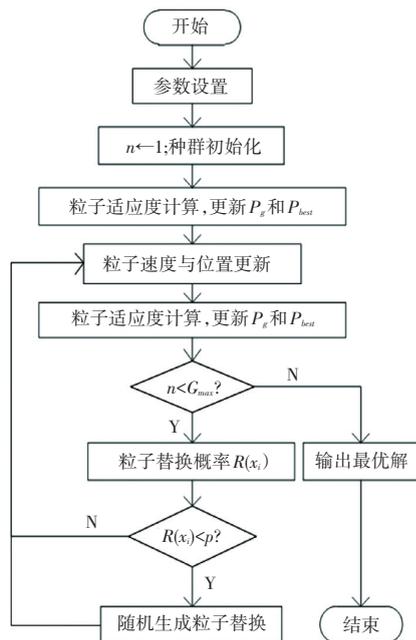


图 1 IPSO 的流程

Fig. 1 IPSO flow chart

经由该图获知,IPSO 利用粒子更新规则引导粒子进化,使粒子更快地朝最优解位置转移,增强粒子群的全局寻优能力;利用粒子浓度调节粒子群的多样性,防止进化后期出现早熟现象。

IPSO 的惯性权重  $\omega$  和学习因子  $c_1, c_2$  可由下式确定:

$$\omega = \omega_{\min} + r_1 (\omega_{\max} - \omega_{\min}) + \alpha \mu, \mu \sim N(0, 1) \quad (13)$$

其中,  $\omega_{\min}, \omega_{\max}$  用于控制  $\omega$  的取值范围,  $\alpha$  为给定的参数。另外,  $c_1, c_2$  分别作为粒子的个体学习因子和社团学习因子,随算法的迭代次数作自适应调节,即:

$$c_k = c_{k, \min} + \frac{n}{G_{\max}} (c_{k, \max} - c_{k, \min}), k = 1, 2 \quad (14)$$

式中,  $c_{k, \min}, c_{k, \max}$  分别表示学习因子  $c_k$  变化的边界值;  $n$  表示当前迭代次数;  $G_{\max}$  表示最大迭代次数。

本文中,取  $\omega_{\min} = 0.4, \omega_{\max} = 0.9, c_{k, \min} = 0.5, c_{k, \max} = 2.5, \alpha = 0.4$ 。

PSO 在进化后期易于出现种群多样不足,致使算法陷入局部搜索。在此,将免疫优化中调节群体多样性的浓度概念用于 IPSO 的粒子替换概率设计,增强种群的多样性,即  $N$  个粒子构成的群体中,第  $i$  个粒子  $x_i$  的替换概率  $R(x_i)$  由下式确定:

$$R(x_i) = \beta \frac{m_i}{N} + (1 - \beta) \frac{G(x_i)}{\sum_{i=1}^N G(x_i)} \quad (15)$$

$0 < \beta < 1, 1 \leq i \leq N$

其中,  $m_i$  表示在半径为  $\tau$  的粒子  $x_i$  邻域内的粒子数;  $\beta$  为加权因子; 式 (15) 中右边的第一个分式刻画种群中与粒子  $x_i$  相似的粒子所在比例; 而第二个分式则度量粒子  $x_i$  在种群中的重要程度。结合式 (13) ~ (15), IPSO 的算法描述如下:

### Step 1 参数设置

其中包括: 种群规模  $N$ , 边界值  $c_{k, \min}$  与  $c_{k, \max}$  ( $k = 1, 2$ ),  $\omega_{\max}$  与  $\omega_{\min}$ , 加权因子  $\beta$ , 邻域半径  $\tau$ , 替换概率  $p$ , 最大迭代数  $G_{\max}$ ;

**Step 2** 置  $n \leftarrow 1$ , 随机生成规模为  $N$  的初始粒子群  $P$ , 初始化惯性权重和学习因子;

### Step 3 粒子更新

(1) 计算种群  $P$  中粒子的适应度, 确定粒子的个体极值  $P_{best}$  及全局极值  $P_g$ ;

(2) 依据式 (11) ~ (12), 更新  $P$  中粒子的速度和位置;

(3) 计算粒子的适应度, 更新个体极值  $P_{best}$  和全局极值  $P_g$ ;

(4) 依据式 (13) ~ (14) 更新惯性权重及学习因子;

### Step 4 粒子替换

(1) 依据式 (15) 计算每个粒子  $i$  的替换概率  $R(x_i)$ ;

(2) 对于每个粒子  $i$ , 若  $R(x_i) < p$ , 则该粒子被随机生成的粒子替换;

**Step 5** 置  $n \leftarrow n + 1$ ; 若  $n < G_{\max}$ , 则执行 Step 3; 否则, 输出最优解。

以上算法的描述中, Step 3 在对粒子位置更新

的同时, 惯性权重和学习因子也作动态变化, 目的在于平衡粒子的局部勘测与全局开采能力; Step 4 将相似度高的粒子依据替换概率进行更新, 增加种群的多样性。IPSO 在一个迭代周期内, Step 3、Step 4 的计算复杂度分别为  $O(N)$  和  $O(2N^2 + N)$ 。因此, IPSO 在最坏情形下的计算复杂度为  $O(2N^2)$ , 表明  $N$  是影响算法效率的关键因素。

## 3 数值实验

在 Windows10 (CPU / i3 4170 3.70 GHz, RAM / 4GB) / MATLAB R2018a 环境下展开数值实验。为验证以上注水优化调度模型的合理性和测试 IPSO 的有效性, 选取粒子群优化算法 (PSO)<sup>[15]</sup>、遗传算法 (GA)<sup>[16]</sup>、正弦余弦优化算法 (SCA)<sup>[17]</sup> 以及灰狼优化算法 (GWO)<sup>[18]</sup> 参与比较。各算法的种群规模为 50, 最大迭代次数为 100; 参与比较的算法无其它可调参数; IPSO 的参数设置为:  $\alpha = 0.4$ ,  $\beta = 0.6$ ,  $p = 0.6$ ,  $\tau = 0.1$ ,  $\omega_{\min} = 0.4$ ,  $\omega_{\max} = 0.9$ ,  $c_{k, \min} = 0.5$ ,  $c_{k, \max} = 2.5$ 。测试事例为 5 口油井的两层水嘴开度面积优化问题。其油井的注水管内径  $D$  均为 62 mm, 水嘴面积开度最大值为 80 mm<sup>2</sup>, 流体动力粘度  $\mu$  为  $1 \times 10^{-6}$  Pa · s。

### 3.1 地层注入压力的计算误差分析

为了检验式 (6) 描述的压力模型求取地层注入压力值的准确性, 以 5 口油井数据为例, 经由式 (6) 计算得到的各口油井中上、下两个注水层压力见表 1。该表中第 2~7 列数据为实测油井数据。

表 1 地层注入压力的计算以及误差比较

Tab. 1 Calculation of stratum injection pressure and error comparison

油井编号	$P_0$ /MPa	$Q_0$ /(m <sup>3</sup> /d)	注水层段	深度/m	实际流量/(m <sup>3</sup> /d)	配注量/(m <sup>3</sup> /d)	实际地层压力/MPa	计算地层压力/MPa	相对误差/%
1	15.4	30	上层	2 140	10.7	10	34.98	36.165	3.39
			下层	2 184	20.5	20	35.5	36.63	3.18
2	12.5	30	上层	1 933.2	15.6	15	32.0	31.38	1.93
			下层	1 963.9	15.5	15	32.2	31.66	1.65
3	12.5	50	上层	1 916	25.6	26	30.6	31.17	1.89
			下层	1 956	24.1	24	31.6	31.64	0.14
4	14.6	45	上层	1 956	24.3	25	33.4	33.71	0.94
			下层	2 025	20.2	20	31.7	34.17	7.80
5	12.8	40	上层	1 901.8	19.5	19	31.1	31.39	0.93
			下层	1 962.1	21	21	31.7	31.97	0.87

由于各油井的注水层段的深度不同,导致各地层注入压力的模型计算值与实际测量值存在不同程度的误差。结合表2中的实测数据,由式(6)获得第9列源自模型计算的地层压力。对比第8、9列的地层压力数据,经由第10列的相对误差数据获知,模型(6)获得的各油井地层压力与测量压力的相对误差较小。因此,该模型计算层段压力是合理和有效的。

表2 各对比算法求解分层注水模型统计结果

Tab. 2 Statistical results of layered water injection model solved by each comparison algorithm

油井编号	层位	GWO		SCA		GA		PSO		IPSO	
		水嘴开度 面积/(cm <sup>2</sup> )	注水偏差 量/(m <sup>3</sup> /d)								
1	上层	0.212	1.749	0.250	0.515	0.246	1.071	0.247	0.553	0.252	0.057
	下层	0.497		0.490		0.480		0.492		0.501	
2	上层	0.376	0.919	0.388	0.409	0.380	1.131	0.389	0.554	0.397	0.057
	下层	0.394		0.394		0.383		0.390		0.396	
3	上层	0.422	1.447	0.441	0.590	0.402	3.494	0.426	1.753	0.443	0.024
	下层	0.403		0.399		0.388		0.394		0.407	
4	上层	0.424	2.053	0.457	0.364	0.449	2.646	0.452	1.035	0.462	0.033
	下层	0.367		0.366		0.332		0.359		0.367	
5	上层	0.393	2.236	0.392	0.225	0.384	1.768	0.370	1.246	0.395	0.021
	下层	0.389		0.432		0.409		0.432		0.434	
注水偏差量均值			1.681		0.421		2.022		1.028		0.038
注水偏差量方差			0.272		0.019		1.079		0.256		0.000 31

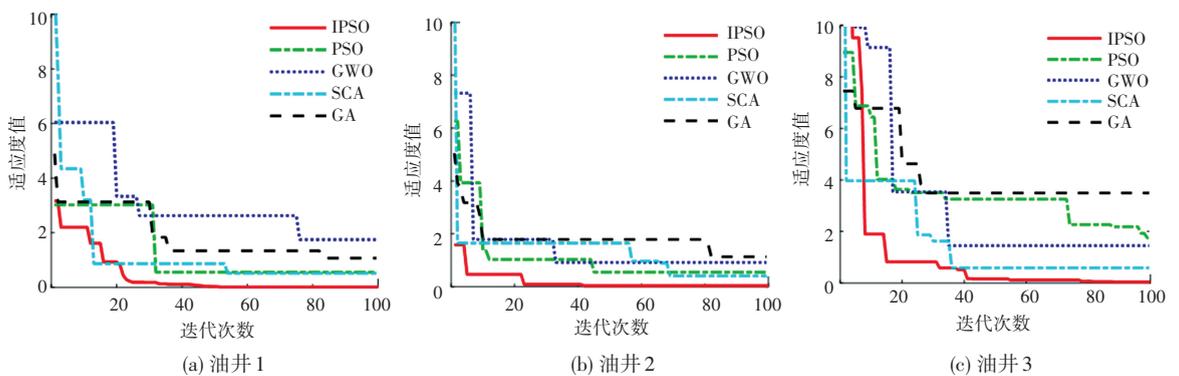


图2 各油井适应度变化曲线图

Fig. 2 Fitness change curve

经由表2可知,IPSO与PSO、GWO、SCA、GA相比,其求解以上双层注水流量调度问题,获得的各层注水量较为接近注水层配注量,产生的注水偏差量均值和方差均小于参与比较算法的均值与方差;GWO、GA以及PSO获得的注水偏差量均值和方差均较大,且明显大于SCA产生的注水偏差量均值和方差。因此,IPSO求解以上问题能获得最好的效

### 3.2 算法性能比较分析

将表1中第2、3、5、7列实测数据代入模型NP中,获得可求解的非约束优化模型,进而以上5种算法可获得各油井上、下注入层的水嘴开度面积,以及作用于5口油井产生的注水偏差量的均值与方差,见表2。进一步,以油井编号1~3为例,各算法的平均搜索曲线如图2所示。

果,且搜索效果较稳定;SCA次之;GWO、GA以及PSO较差。

图2表明,IPSO能有效克服PSO易陷入局部搜索的不足,具有能平衡局部勘测与全局开采的能力,能快速获得全局最优解;GWO、GA以及PSO易于陷入局部搜索,且局部收敛速度也较慢,因而其种群多样性较差,局部勘测能力弱;SCA的进化能力相对较

强,收敛速度快,但获得解的精度偏低。由此可知,IPSO 求解注水流量调度问题时,搜索速度快,获得的解的精度高,且整体性能明显优于其它 4 种算法。

## 4 结束语

油井分层注水优化调度问题一直是油田行业中极为困难的工程问题,也是算法研究中重要的学术性问题。本文通过建立油井流量以及压力模型,得到以油井注水层注水偏差量为性能指标的优化模型,进而将免疫优化中抗体浓度调节种群多样性策略与粒子群优化结合,获得可求解双层注水调度问题的免疫粒子群优化算法(IPSO)。比较性的实验结果表明,获得的地质压力计算模型是有效的;IPSO 能根据注水层配注量的需求,获得较为精确的注水层水嘴的开度值,使得注水量能达到配注的要求,具有一定的应用潜力。

## 参考文献

- [1] 刘秀琪,何文祥. 直读研封仪在桥式偏心配水管柱封隔器验封中的效果分析[J]. 当代化工, 2019, 48(11): 2557-2559,2622.
- [2] 祝传增. 哈萨克斯坦 AK 油田桥式偏心分层注水技术研究与应用[J]. 采油工程, 2020(3): 37-41,81.
- [3] 于九政, 巨亚锋, 郭方元. 桥式同心分层注水工艺的研究与试验[J]. 石油钻采工艺, 2015, 37(5): 92-94.
- [4] 杨玲智, 刘延青, 胡改星, 等. 长庆油田同心验封测调一体化分层注水技术[J]. 石油钻探技术, 2020, 48(2): 113-117.

(上接第 71 页)

## 3 结束语

本文提出了一种基于多任务学习的多传感器模型,对相机与毫米波雷达数据的目标级融合,同时提高单个传感器工作时的可靠性。利用两任务间强相关性,通过窃听机制得到单任务模型训练所不能得到的信息;引入 BN 和残差结构进一步优化模型,完成目标的分类与目标尺寸的预测。通过改善模型的结构与雷达检测系统,对小目标的检测效果还有进步空间。

## 参考文献

- [1] 向滨宏. 基于汽车雷达和摄像头信息融合的目标检测方法研究[D]. 重庆:重庆大学,2017.
- [2] JONG Y D, GUSTAVO V H, JOHN B, et al. Sensor and Sensor Fusion Technology in Autonomous Vehicles: A Review [J]. Sensors, 2021, 21(6): 2140-2184.
- [3] 张暄, 高跃清. 基于卷积神经网络的雷达目标检测方法[J]. 计

- [5] 栾云天. 分层注水技术中恒流堵塞器的应用[J]. 内蒙古石油化工, 2014, 40(6): 102-104.
- [6] 姚春东, 董赵朋. 一种新型定差式恒流量注水堵塞器[J]. 石油机械, 2008(10): 47-50,97-98.
- [7] 崔智敏, 王银凤. 基于遗传算法的油田注水系统运行优化研究[J]. 科学技术与工程, 2012, 12(7): 1656-1658,1666.
- [8] 陈纯炼, 郭绪坤. 基于蚁群算法的油田注水系统优化[J]. 油气田地面工程, 2014, 33(11): 52-53.
- [9] NEGASHI B M, YAW A D. 基于人工神经网络的注水开发油藏产量预测[J]. 石油勘探与开发, 2020, 47(2): 357-365.
- [10] 张瑞杰, 常玉连, 任永良, 等. 油田注水系统生产运行优化[J]. 钻采工艺, 2005, 28(5): 44-46.
- [11] 邢宝海. 井筒注水过程仿真及管柱特性分析[D]. 大庆石油学院, 2005.
- [12] 张华. 管道截面突变处的局部阻力系数[J]. 山西水利科技, 1994(2): 79-83.
- [13] 夏泰淳. 工程流体力学[M]. 上海交通大学出版社, 2006.
- [14] HU F J, LV H X, TUZIKOV A V. Multi-objective cooperative control based on evolutionary process optimization of immune algorithm [J]. Service Oriented Computing and Applications, 2020, 14(PP): 1-8.
- [15] 任永良, 孙凯, 高胜. 基于粒子群算法的油田注水管网摩阻系数反演[J]. 石油机械, 2020, 48(8): 97-103,122.
- [16] 罗小俊. 基于遗传算法的并联注水泵站调控优化[J]. 能源与环保, 2017, 39(5): 166-169,174.
- [17] CHENG J T, DUAN Z M. Cloudmodel based sine cosine algorithm for solving optimization problems [J]. Evolutionary Intelligence, 2019, 12(4): 503-514.
- [18] MEHAK K, SANKALAP A. Chaotic grey wolf optimization algorithm for constrained optimization problems [J]. Journal of Computational Design and Engineering, 2018, 5(4): 458-472.

算机测量与控制, 2021, 29(2): 49-52,57.

- [4] 魏涛, 韩经鲁, 周雨辉, 等. 基于机器学习的毫米波雷达车辆目标检测[J]. 客车技术与研究, 2019, 41(5): 59-62.
- [5] 赵望宇, 李必军, 单云霄, 等. 融合毫米波雷达与单目视觉的前车检测与跟踪[J]. 武汉大学学报(信息科学版), 2019, 44(12): 1832-1840.
- [6] 董小舒, 朱伟, 刘羽, 等. 毫米波雷达与视觉融合的车辆目标检测系统[J]. 指挥信息系统与技术, 2021, 12(1): 91-96.
- [7] JIBRIN A F, Zhang Y X, FU M Z, LI Y H, et al. Application of Deep Learning on Millimeter-Wave Radar Signals: A Review [J]. Sensors, 2021, 21(6): 1951-1994.
- [8] 李雨鑫, 罗丁利, 陈尹翔, 等. 一种基于多任务学习的微多普勒目标识别方法[J]. 火控雷达技术, 2021, 50(1): 65-68.
- [9] 邵蔚元, 郭跃飞. 多任务学习及卷积神经网络在人脸识别中的应用[J]. 计算机工程与应用, 2016, 52(13): 32-37,88.
- [10] SELTZER M L, DROPPA J. Multi-task Learning in Deep Neural Networks for Improved Phoneme Recognition [C]//Proceeding of IEEE International Conference on Acoustics, Speech and Signal Processing. Vancouver: IEEE, 2013: 6965-6969.