

基于聚集度的异化磷虾群算法

刘 楷, 沈菊红, 万仁霞, 李延延

(北方民族大学 数学与信息科学学院, 宁夏 银川 750021)

摘 要: 针对标准磷虾群算法存在着不易跳出局部寻优、搜索精度低等问题, 提出了一种基于聚集度的异化磷虾群算法. 本算法根据种群多样性指标聚集度的变化, 通过在两个相反位置移动方向的选择策略来增加磷虾进化多样性, 同时引入了随机数策略来模拟磷虾的外部扰动, 从而取代原磷虾群算法中的随机扩散运动的影响. 再引入平均距离指标来增加局部搜索的变异概率, 同时将背向最优位置的速度方向作为搜索变异方向, 从而扩大了群体的搜索空间, 保证算法的全局搜索能力. 通过对九个典型不同类型的基准函数进行实验测试, 结果表明了改进策略对算法的全局搜索能力和优化精度有很大的提高, 能达到更好的收敛速度和寻优精度.

关键词: 磷虾群算法; 异化; 聚集度; 变异策略

中图分类号: TP18

文献标识码: A

文章编号: 1000-7180(2017)07-0011-07

The Dissimilated Krill Herd Algorithm with Aggregation Degree

LIU Kai, SHEN Ju-hong, WAN Ren-xia, LI Yan-yan

(Beifang University of Nationalities, Yinchuan 750021, China)

Abstract: In view of shortcomings of the basic krill herd algorithm (KH)—easily trapping in local optimization and low search accuracy, a dissimilated krill herd algorithm with aggregation degree is proposed in this paper. According to the variation of concentration (which plays as the diversity criterion of population), the algorithm increases the krill's evolving diversity by a selection strategy on two opposite directions, moreover, a random number strategy is introduced to simulate the external disturbance of krill, which actually takes the place of the influence of stochastic diffusion movement of original krill herd algorithm, and then the average distance index is used to increase the dissimulation probability of local search. Also the proposed algorithm takes the reverse of optimal position as the dissimulation search direction to expand the search space of the group, so that it can ensure a satisfied the global search ability. The experimental results show that the dissimulation strategy can gain the promising availabilities of the optimization accuracy and the global search ability.

Key words: krill herd algorithm (KH); dissimilated; aggregation degree; dissimulation strategy

1 引言

磷虾群算法(KH)是一种群体智能优化算法, 2012年由 Gandomi AH 首次提出^[1], 该算法是对南极磷虾生化环境演变响应过程的仿真模拟^[2]. 磷虾群算法是新近出现的全局优化算法, 和其他传统的智能优化算法相比, 磷虾群算法在处理一些复杂优化问题时有其良好特性, 然而由于该算法的理论与应用研究刚刚起步, 处理一些高维多模态优化问题

时还存在着早熟、易陷入局部最优、后期收敛速度慢等不足^[3-5].

文献[6]将 KH 的不足归纳出以下原因: (1)KH 算法在迭代后期易陷入局部极值, 磷虾个体周围的邻居会聚集在极值点附近, 群体多样性降低. 因而运动向量 N_i , 更主要地受到局部极值点的影响, 局部搜索能力不强. (2)由于食物的位置是虚拟的, 由磷虾的当前位置估计出. 当虾群被局部极值吸引时, 觅食运动向量 F_i 易受其影响, 个体的局部搜

索能力变差。(3) 出于算法收敛的考虑, 扩散运动向量 D_i , 在算法迭代的后期影响逐渐减弱, 也不具备强的局部搜索能力。

本文根据上述问题, 通过调整磷虾粒子的移动位置公式和整体位置公式, 引入聚集度的概念等措施, 得到一种变异的磷虾群算法。

2 标准磷虾群算法

磷虾群算法(KH) 是一种新型生物启发算法, 为了探索生存区域, 使种群尽可能地获取食物同时减少被捕食的几率, 南极磷虾不断聚集以增大种群密度, 向食物靠近。因为虾群形成主要由虾群密度和食物吸引两方面决定, 而磷虾个体的移动位置主要受到一定范围内相邻磷虾的吸引或排斥, 觅食活动和随机扩散运动三方面的影响, 并以此建立拉格朗日模型:

$$\frac{dX_i}{dt} = N_i + F_i + D_i \quad (1)$$

式中, $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})$ 是 n 维向量, 代表各个磷虾粒子的位置向量, N_i, F_i, D_i 分别代表粒子移动位置受上述三方面的影响, 它们都与时间 t 有关。

2.1 相邻磷虾的诱导

KH 算法中为了维持较高的虾群密度, 每个磷虾除了受到周围磷虾个体的局部吸引, 还受到当前全局最优个体的吸引。因此, 模型中的运动向量 N_i 定义为:

$$N_i = N_{\max}(\alpha_i^{\text{local}} + \alpha_i^{\text{target}}) + \omega_n N_i^{\text{old}} \quad (2)$$

式中, $N_{\max}$ 是最大诱导速度, α_i^{local} 代表受周围邻居影响的运动向量, α_i^{target} 代表受当前最优个体影响的运动向量, ω_n 是惯性权重。

2.2 觅食活动

觅食运动向量 F_i , 受到当前估计食物位置 and 前一次觅食活动及位置的影响, 这里定义为:

$$F_i = V_f(\beta_i^{\text{food}} + \beta_i^{\text{best}}) + \omega_f F_i^{\text{old}} \quad (3)$$

式中, V_f 表示最大觅食速度向量, $\beta_i^{\text{food}} + \beta_i^{\text{best}}$ 表示由当前估计的食物位置和个体历史最优觅食位置共同计算出的吸引度值, ω_f 是惯性权重, F_i^{old} 代表前一次的觅食运动向量。

2.3 随机扩散运动

物理扩散运动向量 D_i 表示磷虾个体的随机扩散行为, 定义为

$$D_i = D_{\max} \left(1 - \frac{t}{t_{\max}}\right) \delta \quad (4)$$

式中, $D_{\max}$ 代表最大扩散速度值, 通常取值于

$[0.002, 0.01]$, 本文取 0.005. t 和 $t_{\max}$ 分别表示当前迭代次数和最大迭代次数, δ 表示随机扩散方向向量, 取值于 $(-1, 1)$ 。

磷虾粒子整体位置的更新公式定义为

$$X_i(t + \Delta t) = X_i(t) + \frac{dX_i}{dt} \times \Delta t \quad (5)$$

$$\Delta t = C_t \sum_{j=1}^{N_v} (\text{UB}_j - \text{LB}_j) \quad (6)$$

这里, Δt 是一个特殊的比例因子, 相当于速度向量的比例因子. C_t 为步长缩放因子, 在 $[0, 2]$ 间取值, N_v 代表所有变量的数目, $\text{UB}_j / \text{LB}_j$ 分别代表第 j 个变量的上 / 下界。

3 基于聚集度的异化磷虾群算法

为了改善 KH 算法在运行后期种群多样性降低而陷入局部最优的问题, 我们用欧几里得距离来衡量粒子间的相似程度, 定义聚集度来衡量种群多样性, 并根据聚集度的大小重新分配适应值, 采用新的位置更新公式来调整粒子(磷虾) 的搜索空间, 以此达到跳出局部最优的目的, 同时通过多样性变异策略来进一步提高算法的全局寻优能力。

3.1 欧几里得距离和聚集度的定义

考虑到平均粒子间的距离可以描述种群中各粒子间分布的离散程度, 其值越大, 种群分布的离散程度也就越大, 多样性就越高, 所以将欧几里得距离 S_i 和聚集度 C 分别定义为

$$S_i = \sqrt{\sum_{d=1}^n (X_{id} - \bar{P}_d)^2} \quad (7)$$

$$C = \frac{\sum_{i=1}^N S_i}{\max|\text{UB} - \text{LB}|} \quad (8)$$

这里 n 表示解空间维数, N 表示种群粒子个数, X_{id} 为第 i 个粒子的第 d 维坐标值, $\bar{P}_d$ 表示所有粒子的第 d 维坐标值的平均值. UB / LB 为搜索空间的上 / 下界. S_i 表示 X_i 与平均位置的距离, C 越大, 多样性也越高, 越有利于算法跳出局部最优。

3.2 多样性变异策略

在文献[1] 的 KH 算法中, 为了增强 KH 算法的群体多样性及局部搜索能力而采用的自适应交叉算子和变异算子, 具有明显随机性的特点, 当种群聚集在局部极值点附近时, 交叉和变异的概率非常低, 算子也难以发挥有效作用。为了使个体跳出局部最优, 本文在文献[1] 的基础上通过改进变异操作来增大其变异概率, 使其有方向性地背离最优个体。

$$X_{i,m} = \begin{cases} X_{r,m}, & \text{rand}_{i,m} < C_r; \\ X_{i,m}, & \text{else.} \end{cases} \quad (9)$$

$$C_r = 0.2\hat{K}_{i,\text{best}}$$

如果 $S_i < \text{mean}(S)$ 或 $\text{rand} < M_u$, 即当个体 X_i 离平均位置的距离小于平均距离时, 或随机数满足变异率时:

$$\begin{cases} V_{i,m} = X_{i,m} - G_{\text{best}} \\ X_{i,m} = X_{i,m} + V_{i,m} \times \gamma \end{cases} \quad (10)$$

否则, $X_{i,m} = X_{i,m}$;

这时 $V_{i,m}$ 是以 G_{best} 为起点 $X_{i,m}$ 为终点构造的一个速度向量, 使得 $X_{i,m}$ 背向 G_{best} 运动, 这样能够使得 $X_{i,m}$ 跳出局部搜索, 提高种群多样性; γ 是速度系数, 决定 $X_{i,m}$ 的运动步长, γ 越大, 则 $X_{i,m}$ 跳出局部最优的概率越大, 本文 $\gamma \in [0, 2]$ 随机数。

3.3 异化的磷虾群算法

一方面是对粒子移动位置更新公式的改进, 随着迭代次数的增大, 扩散运动向量 D_i 的影响逐渐减弱, 并不具备强的局部搜索能力, 这里我们将粒子的扰动影响通过异化策略加到位置更新公式中, 代替 D_i 的影响, 从而得到下式:

$$\frac{dX_i}{dt} = N_i + F_i \quad (11)$$

另一方面是对粒子整体位置更新公式的改进, 由文献[6]归纳算法易陷入局部最优的原因[6]可知, 粒子在食物和群体最高密度区域引导下, 会一直处于收缩状态, 当找到一个最优解后粒子就很难跳出局部最优。本文根据聚集度的大小重新分配粒子位置, 当种群多样性降低到某种程度时, 扩大速度向量的比例因子 Δt , 并将其移动位置改成反方向, 这样就引导粒子远离当前搜索到的最优粒子, 扩大了群体的搜索空间。同时为了还原随机扩散运动的影响, 在其原有位置上增加一个随机数, 如下式:

以初始种群的多样性 $C(1)$ 的 α 倍为标准, 如果 $C(t) > \alpha \times C(1)$, 即多样性高于标准时:

$$X_i(t + \Delta t) = X_i(t) \cdot \text{rand} + \frac{dX_i}{dt} \times \Delta t$$

$$\Delta t = C_t(\text{UB} - \text{LB}) \quad (12)$$

当 $C(t) \leq \alpha \times C(1)$, 即多样性低于标准时, 反方向移动:

$$X_i(t + \Delta t) = X_i(t) \cdot \text{rand} - \frac{dX_i}{dt} \times \Delta t \quad \Delta t = \beta \cdot \Delta t \quad (13)$$

式中, 经试验表明, 当 α 取值为 0.3, β 取值为 2 时效

果较好。

3.4 算法流程

由上述分析可知, 该算法的过程描述如下:

步骤 1 初始化: 随机产生 n 个磷虾粒子及参数设置;

步骤 2 评价确定每个粒子的适应度;

步骤 3 根据式(2)、(3) 计算粒子移动位置的两个分量 N_i 和 F_i ; 根据式(11)、(5) 分别计算粒子的移动位置 $\frac{dX_i}{dt}$ 和整体位置 $X_i(t)$;

步骤 4 由式(7) 计算相似度 S_i , 再由式(8) 计算聚集度 C ;

步骤 5 如果 $C(t) > 0.3 \times C(1)$, 由式(12) 重新更新整体位置 $X_i(t)$; 否则, 由式(13) 重新更新整体位置 $X_i(t)$;

步骤 6 由式(9)、(10) 进行交叉变异操作;

步骤 7 若条件没有满足且未达到最大迭代, 就返回步骤 2。

4 算法的实验分析

4.1 测试函数

为验证算法的可靠性, 我们选取了具有不同特点的函数进行测试, 如表 1 所示。其中 Brown 函数, Sphere 函数, Chung Reynolds 函数, Rosenbrock 函数和 Schwefel 2.22 函数为单模函数, Sphere 函数为非线性对称单模函数, 是区分局部优化方法优劣的多峰函数, 该函数相对较简单, 大多数算法都能够轻松地找到最优解。而 Alpine 函数, Csendes 函数, Ackley 函数和 Rastrigin 函数为多模函数。其中, Rastrigin 函数使用余弦函数产生了大量的局部最小值, 是一个典型复杂多模函数, 具有大量局部最优解, 一般的优化算法易于陷入局部最优, 却难以找到全局最优解[7]。

4.2 算法的参数设置

在本次实验中, 群体规模均为 40, 每个函数独立运行 30 次, 最大迭代次数设为 1 000。

在 KH 中, $\omega_n = \omega_f = 0.9, C_t = 0.5$;

在 KHL D^[8] 和 CSKH 中, $\omega_n = \omega_f = 0.9, C_t = C_{\text{max}} - (C_{\text{max}} - C_{\text{min}}) \times \frac{t}{t_{\text{max}}}, C_{\text{max}} = 1.0, C_{\text{min}} = 0.5, N_{\text{max}} = 0.01, V_f = 0.02$;

在 PSO^[9] 中, $c_1 = c_2 = 1.494 45, \omega = 0.8$;

表 1 测试函数

函数名	表达式	全局最优点	全局最优值
Brown	$f_1 = \sum_{i=1}^{n-1} (x_i^2)^{(x_{i+1}^2+1)} + (x_{i+1}^2)^{(x_i^2+1)} \quad x_i \in [-1,4]$	$\{0,\cdots,0\}$	0
Sphere	$f_2 = \sum_{i=1}^n x_i^2 \quad x_i \in [-100,100]$	$\{0,\cdots,0\}$	0
Chung Reynolds	$f_3 = (\sum_{i=1}^n x_i^2)^2 \quad x_i \in [-100,100]$	$\{0,\cdots,0\}$	0
Rosenbrock	$f_4 = \sum_{i=1}^{n-1} (100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2) \quad x_i \in [-30,30]$	$\{0,\cdots,0\}$	0
Schwefel 2, 22	$f_5 = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i \quad x_i \in [-10,10]$	$\{0,\cdots,0\}$	0
Alpine	$f_6 = \sum_{i=1}^n x_i \sin(x_i) + 0.1x_i \quad x_i \in [-10,10]$	$\{0,\cdots,0\}$	0
Csendes	$f_7 = \sum_{i=1}^n x_i^6 (2 + \sin \frac{1}{x_i}) \quad x_i \in [-1,1]$	$\{0,\cdots,0\}$	0
Ackley	$f_8 = -20\exp(-0.2\sqrt{\frac{1}{n}\sum_{i=1}^n x_i^2}) - \exp(\frac{1}{n}\sum_{i=1}^n \cos(2\pi x_i)) + 20 + e$ $x_i \in [-30,30]$	$\{0,\cdots,0\}$	0
Rastrigin	$f_9 = \sum_{i=1}^n (x_i^2 - 10\cos(2\pi x_i) + 10) \quad x_i \in [-5.12,5.12]$	$\{0,\cdots,0\}$	0

将取得最好和最差的全局最优值(评价算法在多次运行中能达到的最优和最差值),及其平均值

(评价算法所能达到的精度)和方差(评价算法的稳定性和鲁棒性),测试结果如表 2 所示.

表 2 函数测试结果

函数	算法	全局最优值			
		最好	最差	平均	方差
f_1	KH	0.001 390 129	0.003 797 011	0.002 491 412	0.000 929 1
	KHLD	0.000 101 254	0.000 248 091	0.000 183 086	4.28E-05
	PSO	0.048 799 874	0.221 827 964	0.136 530 093	0.048 321 318
	CSKH	5.45E-28	1.88E-18	1.90E-19	5.94E-19
f_2	KH	3.844 388 289	14.37 602 881	9.629 534 891	3.128 411 319
	KHLD	0.233 384 438	0.452 580 911	0.332 932 895	7.68E-02
	PSO	0.032 047 033	0.277 652 967	0.141 563 94	0.075 267 033
	CSKH	1.89E-19	1.48E-06	1.61E-07	4.64E-07
f_3	KH	3.844 388 289	14.37 602 881	9.629 534 891	3.128 411 319
	KHLD	0.233 384 438	0.452 580 911	0.332 932 895	7.68E-02
	PSO	0.032 047 033	0.277 652 967	0.141 563 94	0.075 267 033
	CSKH	1.89E-19	1.48E-06	1.61E-07	4.64E-07
f_4	KH	95.919 164 74	797.195 359 6	226.399 875 8	221.846 060 9
	KHLD	30.874 586 08	360.905 309 3	77.466 331 62	1.08E+02
	PSO	31.856 846 53	208.799 649 2	88.557 089 53	57.225 519 22
	CSKH	2.89E+01	2.90E+01	2.90E+01	2.75E-02

f_5	KH	0.921 079 084	60.214 236 95	11.470 686 17	20.437 402 72
	KHLD	4.281 680 52	18.860 233 28	12.068 993 75	3.67E+00
	PSO	2.375 884 425	7.864 094 669	4.696 773 606	1.724 224 297
	CSKH	2.45E-05	3.37E-03	1.16E-03	1.29E-03
f_6	KH	0.129 508 657	2.168 680 164	0.712 096 05	0.624 722 018
	KHLD	0.040 676 067	0.663 913 845	0.194 866 38	1.96E-01
	PSO	0.252 376 995	1.646 195 699	0.912 690 723	0.432 173 939
	CSKH	6.18E-07	2.22E-04	7.31E-05	7.08E-05
f_7	KH	2.25E-12	9.94E-11	2.47E-11	3.69E-11
	KHLD	5.96E-16	1.05E-14	4.07E-15	3.83E-15
	PSO	3.69E-06	0.000 187 126	5.81E-05	6.37E-05
	CSKH	2.52E-148	4.64E-69	4.64E-70	1.47E-69
f_8	KH	0.949 985 902	2.963 335 741	2.001 957 515	0.682 325 543
	KHLD	0.428 736 934	0.670 077 13	0.555 174 221	0.082 801 975
	PSO	3.395 500 626	6.887 540 549	5.315 631 746	1.172 618 415
	CSKH	1.62E-05	0.000 830 359	0.000 387 371	0.000 252 198
f_9	KH	123.186 559 8	65.434 472 06	93.349 250 8	22.144 426 02
	KHLD	162.865 115 6	101.577 922 9	129.776 925 6	21.945 915 07
	PSO	132.333 353 3	70.652 812 7	103.402 858	25.880 844 79
	CSKH	36.328 107 06	0	11.330 139 1	17.614 733 67

同时为更直观地体现本文算法的稳定性,我们选取了以上四种粒子群算法比较有代表性的收敛曲线图,如图 1 至图 9。




图 1 对 f_1 的寻优效果图

4.3 算法的结果分析

比较表 2 中的最优值、最差值、均值和方差,我们可以看出,对于具有不同特点的单模和多模函数,本文提出的异化算法(CSKH)在寻优能力、收敛速度和解的稳定性方面较优于其他三种算法.算法的鲁棒性较强,精度较高。

并且从测试图中我们可以看出,本文算法具有很强的全局寻优能力,这一点在处理复杂的多模函




图 2 对 f_2 的寻优效果图




图 3 对 f_3 的寻优效果图




图 4 对 f_4 的寻优效果图




图 7 对 f_7 的寻优效果图




图 5 对 f_5 的寻优效果图




图 8 对 f_8 的寻优效果图




图 6 对 f_6 的寻优效果图




图 9 对 f_9 的寻优效果图

数上更能体现出来,以具有大量局部最优点的 Rastigrin 函数为例,其他三种算法在处理此函数时或多或少会陷入局部最优,而 CSKH 则能较好地跳出局部最优,避免早熟收敛问题,这是由于选择性的位置移动和背向最优位置变异的改进策略使得种群能够保持很好的多样性。

5 结束语

为克服磷虾群算法易陷入局部最优,出现早熟

收敛的问题,本文利用聚集度的概念来自适应的调整算法中的移动位置方向,并通过变异策略增加种群多样性。通过数值实验对比表明,本文提出的异化算法(CSKH)在收敛能力和收敛稳定性较优于其他三种算法。

参考文献:

[1] Gandomi A H, Alavi A H. Krill herd: a new bio-inspired optimization algorithm [J]. Communications in Nonlinear Science and Numerical Simulation, 2012, 17

- (12):4831-4845.
- [2] Hofmann E E, Haskell A G E, Klinck J M, et al. Lagrangian modeling studies of antarctic krill (*Euphausia superba*) swarm formation[J]. ICES J Mar Sci, 2004 (61):617-31.
- [3] Wang G G, Guo L H, Wang H Q, et al. Incorporating mutation scheme into krill herd algorithm for global numerical optimization[J]. Neural Computing and Applications, 2014, 24 (3/5):853-871.
- [4] Mandal B, Roy P K, Mandal S. Economic load dispatch using krill herd algorithm [J]. International Journal of Electrical Power & Energy Systems, 2014, 57(5):1-10.
- [5] Saremi S, Mirjalili S M, Mirjalili S. Chaotic krill herd optimization algorithm [J]. Procedia Technology, 2014, 12(1):180-185.
- [6] 王磊, 张汉鹏. 基于混沌搜索与精英交叉算子的磷虾觅食算法[J]. 计算机工程, 2015, 41(3):156-161.
- [7] 王维博. 粒子群优化算法研究及其应用[D]. 成都: 西南交通大学, 2012.

- [8] Li J P, Tang Y G, Hua C C, et al. An improved krill herd algorithm: Krill herd with linear decreasing step [J]. Applied mathematics and computation, 2014, 234(10):356-367.
- [9] Kennedy J, Eberhart R C. Particle swarm optimization [C]// Proc. IEEE Int. Conf. Neural Netw. Perth, Australia, 1995(4):1942-1948.

作者简介:

刘楷女, (1991-), 硕士研究生. 研究方向为应用统计、智能计算等.

沈菊红女, (1970-), 副教授, 硕士生导师. 研究方向为支持向量机、应用统计、最优化理论等.

万仁霞(通讯作者) 男, (1975-), 博士, 副教授, 硕士生导师. 研究方向为智能计算、数据挖掘、模式识别等.

Email: wanrx1022@126.com.

李延延 男, (1990-), 硕士研究生. 研究方向为数据挖掘与模式识别.

(上接第 10 页)

- [6] 孟锦, 马驰, 何加浪, 等. 基于 HHGA-RBF 神经网络的网络安全态势预测模型[J]. 计算机科学, 2011, 37(7):70-72.
- [7] 孙健, 申瑞民, 韩鹏. 一种新颖的径向基函数(RBF)网络学习算法[J]. 计算机学报, 2003, 25(11):1562-1567.
- [8] Mirjalili S, Mirjalili S M, Lewis A. Grey wolf optimizer[J]. Advances in Engineering Software, 2014, 69(3):46-61.
- [9] Mirjalili S, Mirjalili S M, Lewis A. How effective is the grey wolf optimizer in training multi-layer perceptrons[J]. Appl Intell, 2015, 43(3):150-161.
- [10] 龙文, 赵东泉, 徐松金. 求解约束优化问题的改进灰狼优化算法[J]. 计算机应用, 2015, 34(9):2590-2595.
- [11] 陈昌帅. 二进制灰狼优化算法的研究与分析[J]. 信息系统工程, 2016, 28(7):136-138.

- [12] 殷勇, 邱明. 一种基于高斯核的 RBF 神经网络学习算法[J]. 计算机工程与应用, 2002, 38(21):118-119.

- [13] 肖汉光, 蔡从中. 特征向量的归一化比较性研究[J]. 计算机工程与应用, 2009, 45(22):117-119.

- [14] 刘金生. 网络入侵检测的建模与仿真研究[J]. 计算机仿真, 2012, 28(12):103-106.

作者简介:

郭振洲 男, (1976-), 博士, 讲师. 研究方向为密码学与信息安全、数据挖掘与分析.

刘然(通讯作者) 男, (1993-), 硕士研究生. 研究方向为数据挖掘与分析. E-mail: 824267051@qq.com.

拱长青 男, (1965-), 博士, 教授. 研究方向为云计算.

赵亮 男, (1983-), 博士. 研究方向为无线网络路由、智能交通.