自适应柯西蜂群及其收敛性分析

张 鑫,陈国初,公维祥

(上海电机学院 电气学院, 上海 200240)

摘 要: 针对人工蜂群算法容易陷入局部最优的缺陷, 提出一种自适应柯西变异人工蜂群算法. 该算法引入自适应因子来扩大蜂群的搜索范围, 并利用柯西分布的特点对全局进行搜索, 提高了蜂群搜索的普遍性. 然后利用随机过程理论, 对自适应柯西变异人工蜂群算法进行了理论分析, 论证了该算法的收敛性. 最后将改进的人工蜂群算法应用到风电功率短期预测模型参数的优化中, 与单一支持向量机模型比较, 表明该方法拟合精度更高. 关键词:自适应; 柯西变异; 收敛性分析; 风功率预测; 应用

Artificial Bee Colony Algorithm Based on Adaptive Cauchy Mutation and Its Convergence Analysis

ZHANG Xin, CHEN Guo-Chu, GONG Wei-Xiang

(School of Electronic Engineering, Shanghai Dianji University, Shanghai 200240, China)

Abstract: As to the problem of falling into the local optimum in standard artificial bee colony, it is proposed to introduce an adaptive factor which can expand the search of the swarm and use the Cauchy distribution to improve the universality of colony search. This improved algorithm named adaptive Cauchy mutation artificial bee colony (ACMABC). Then the ACMABC is analyzed in theory by using the theory of random process to prove the convergence of the algorithm. Finally, this modified method is applied to the optimization of the parameters of wind power short-term prediction model, compared with standard statistic strategy, an illustration with higher precision is given.

Key words: adaptive; Cauchy mutation; convergence analysis; Wind power short-term prediction; application.

人工蜂群算法(Artificial Bee Colony, ABC)是由 D.Karaboga^[1]于 2005 年提出的一种群体智能寻优搜索 方法,相对于其他优化算法,其具有原理简单、参数 少、易实现、全局搜索能力强的优点,被广泛应用到 各种问题优化中^[2,3].

尽管 ABC 具有简单、高效的特点,但在接近全局 最优解时易陷入极值点,降低了优化效果,在高维多 峰优化函数中尤为突出^[4].为此,近年来出现了不少 对其改进的文章.比如,邻域搜索中引入惯性递减权 重,性能参数分段搜索^[5],邻域搜索方程中增加调节扰 动^[6],邻域搜索采用量子位 Bloch 坐标编码变换^[7]等. 虽然这些方法一定程度上提高了算法的精度和收敛速 度,但是没有从根本上增加种群的多样性,邻域搜索 虽引入衰减权重,但同一代种群采用统一权重,这样 无法有效开发不同蜜蜂邻域搜索的能力.基于此,本 文引入自适应调节函数确定邻域搜索权重,增加了种 群的多样性,有效开发了种群邻域搜索能力,理论上 避免种群陷入局部最优.在搜索后期,种群最优值若 连续几代没有变化,则引入柯西变异算子,及时使种 群跳出局部极值,把该方法称为自适应柯西变异人工 蜂群算法(Adaptive Cauchy mutation artificial bee colony, ACMABC);对其进行收敛性分析并将其应用 到支持向量机的短期风电功率预测模型参数优化中, 对实测风电功率数据进行建模仿真,通过与单一的支 持向量机(Support Vector Machine, SVM)预测模型进行 性能对比,验证该方法的有效性.

基金项目:上海市教委科研创新项目(13YZ140);上海市自然科学基金(11ZR1413900);上海市教委重点学科(J51901) 收稿时间:2015-03-17;收到修改稿时间:2015-05-04

1 人工蜂群算法

1.1 标准人工蜂群算法

在 ABC 算法中,人工蜂群有引领蜂(leaders)、跟随 蜂(followers)和侦察蜂(scouts)三种角色. 引领蜂在搜 索空间开采花蜜,即寻找最优解,同时引领蜂会记录 食物源的相关信息. 跟随蜂按轮盘赌选择策略选择引 领蜂进行跟随,并在其附近进行采蜜;当引领蜂放弃 食物源时,便会变成侦察蜂重新寻找食物.

实际优化问题中, 蜜源的位置代表优化问题的可行解, 蜜源的丰富程度代表解的质量^[7]. 在蜂群搜索的过程中, 首先在搜索空间会生产初始解 $X_i(i=1,2,...,SN)$ SN 为蜜源个数, 每个初始解 X_i 是一个 d 维的向量. 然后, 引领蜂根据下式进行搜索:

$$V_{ii} = x_{ii} + R_{ii}(x_{ii} - x_{ii})$$
(1)

 V_{ij} 是新的食物源的位置, R_{ij} 是一个[-1,1]范围内的随机数, $k \in \{1, 2, ..., SN\}$,并且 $k \neq i; j \in \{1, 2, ..., d\}$. 搜索之后,比较最优解和搜索解,当搜索解比最优解更优时则替换掉最优解.反之,则保持最优解不变.

跟随蜂根据轮盘赌选择策略^[8]来选择食物源采蜜, 选择概率由下式确定:

$$P_i = \frac{fit_i}{\sum_{i=1}^{SN} fit_i}$$
(2)

其中, *fu*_i 是第 *i* 个解的适应度函数值, *SN* 是解的个数. 选择引领蜂之后并在其附近进行领域搜索.

当引领蜂 X_i 连续 *limit* 次迭代都没有改变,则此引领蜂转变成侦察蜂,由侦察蜂通过下式随机生成一个新解来代替 X_i.

 $x_{i}^{j} = x_{\min}^{j} + rand(0,1)(x_{\max}^{j} - x_{\min}^{j})$ (3) 其中, $j \in \{1,2,...,d\}$, x_{\max}^{j} 和 x_{\min}^{j} 表示所有蜂群中第j维的最大值和最小值.

1.2 自适应柯西变异人工蜂群算法

1.2.1 搜索步长的自适应调整

ABC 算法在初始搜索阶段不一定可以保证蜂群 的全局性,且在随后的搜索中也可能陷入局部搜索, 不能保证算法的整体性能.因此本文引入一种自适应 因子w,使其在初始阶段搜索范围扩大,在最优解附 近区域缩小搜索范围.

在蜂群迭代寻优过程中,初始阶段搜索进程快,步 长较大可以扩大蜂群搜索范围,此时要求自适应因子 w较大,同时各引领蜂平均适应值和最小适应值之差 比较小;当引领蜂接近最优解区域时,引领蜂要精细 搜索,此时要求自适应因子w较小,同时平均适应值 和蜂群最小值之差较大.鉴于此,自适应因子w可以 随搜索的进行自身进行调整,本文约定自适应因子w 的调整公式如下:

 $w = w_{\min} + (fv(j) - f_{\min}) \cdot (w_{\max} - w_{\min}) / (f_{vag} - f_{\min})$ (4) 式中, w_{\max} , w_{\min} 分别为最大,最小惯性权值; fv(j), f_{vag} , f_{\min} 分别为引领蜂当前适应度值、平均适应度值、 群体最小适应度值.引入自适应因子 w 后,引领蜂和 跟随蜂进行位置更新的公式如式(5)所示:

$$V_{ij} = x_{ij} + w \cdot R_{ij} (x_{ij} - x_{kj})$$
(5)

由公式(4)可以看出, 在初始阶段, 平均适应值和 群体最小适应值之差较小, 而($f_v(j) - f_{min}$)/($f_{veg} - f_{min}$) 的值较大, 所以自适应因子较大, 算法容易从局部极 值跳出, 从而扩大搜索范围. 同理, 在后期蜂群搜索 阶 段, 平均值和群体最小适应值较大, ($f_v(j) - f_{min}$)/($f_{veg} - f_{min}$)的值较小, 所以自适应因子较 小, 加强引领蜂局部搜索. 这样能够提高引领蜂动态 搜索性能.

1.2.2 侦察蜂根据柯西分布搜索新解

1

24

当引领蜂 X_i 连续迭代 Limit 次后适应值仍不变, 则该引领蜂变成侦察蜂.本文在侦察蜂搜索公式中引 入柯西分布,以便提高算法的扰动能力,使人工蜂群 更容易跳出局部极值,充分利用当前搜索到的信息, 柯西分布^[8]是概率论与数理统计中的一类常见分布, 一维柯西分布概率密度函数为

$$f(x) = \frac{1}{\pi} \cdot \frac{t}{t + x^2}, -\infty < x < +\infty$$

当t=1时,称为标准柯西分布.图1是标准柯西和 标准高斯分布概率密度函数曲线.由图1可知柯西分 布原点处的峰值比高斯分布小以便提高扰动能力,并 且两端长扁形状趋于零的速度比高斯分布慢,这样可 以使算法更易避免早熟现象.本文中采用的柯西分布 随机变量生成函数为 $\eta = \tan[(\xi - 0.5)\pi]$,其中 $\xi \in [0,1]$ 上的随机变量.鉴于此,侦察蜂搜索的公式改进为:

$$x_{i}^{j} = x_{\min}^{j} + Cauchy(0,1) \cdot (x_{\max}^{j} - x_{\min}^{j})$$
(6)

式中, Cauchy(0.1)为标准柯西分布.

1.2.3 自适应柯西变异人工蜂群算法

自适应柯西变异人工蜂群算法(adaptive Cauchy mutation artificial bee colony, ACMABC)的基本思想是 在人工蜂群搜索初期运用式(5)进行搜索, 增加蜂群的

Software Technique • Algorithm 软件技术 • 算法 119

多样性,有利于跳出局部极值进行全局搜索.在算法 迭代过程中,蜂群迭代后见种群中最优解与历史最优 值进行比较,如果优于历史最优值,则将其取代.当 历史最优值在连续两次迭代过程中都没有改变,则利 用式(6)产生新解.算法步骤如下所示:



图1 标准柯西、高斯分布概率密度函数曲线

①算法初始化.包括初始化种群规模,控制参数 "*limit*",最大迭代次数;随机产生初始解 *x_i*,*i* = 1,2,...,*SN*, 并计算每个解的适应度函数值.

②引领蜂根据公式(5)在搜索空间搜索蜜源*V*_i并计 算其适应值;如果*V*_i的适应值优于初始解*x*_i,则替代*x*_i. 否则,保持初始解不变.

③计算所有 x_i 的适应度值,运用公式(2)计算与 x_i 相关的概率值 P_i.

④跟随蜂采用轮盘赌选择策略选择引领蜂进行跟随,并根据公式(5)在其附近搜索新解V_i,然后计算其适应值并将其与历史最优值比较,更新历史最优值.

⑤若蜜源开采到一定程度后适应度仍没有得到改善善,则该引领蜂变成侦察蜂,侦察蜂运用柯西分布特 点根据式(6)搜索新解*x_i*.

⑥一次迭代完成之后,记录到目前为止最好的解.

⑦若迭代次数满足终止条件,则输出最优解,否则返回②.

1.3 ACMABC 算法优化性能

1.3.1 测试函数

(1)Sphere 函数

$$\min f(x) = \sum_{i=1}^{n} x_i^2 , \quad -10 \le x_i \le 10$$

该函数只有一个全局最小点: (0, ..., 0), 最小值 为 0.

(2)Ackley 函数

$$\min_{\substack{f(x) = -20 \cdot e^{-0.2\sqrt{\frac{1}{n} \sum_{j=1}^{n} x_j^2} \\ -5 \le x_j \le 5}} - e^{\frac{1}{n} \sum_{j=1}^{n} \cos(2 \cdot \pi \cdot x_j)} + 22.71282$$

此函数有一个(0, 0)为全局最小,最小值为 0. 这 个函数的搜索十分困难. 求解 Ackley 函数的最小值是 优化算法应用的一个有力的例证.(可取 n=2).(函数最 后的常数最好为: 22.718281828459043).

(3)Rastrigin 函数

 $\max f(x) = \sum_{i=1}^{n} (x_i^2 - 10 \cdot \cos(2\pi x_i) + 10), \quad -5.12 \le x_i \le 5.12$ 当 *n* = 2 时,该函数有 4 个全局最大值点,全局最 大值为 80.7066.

(4)Griewangk 函数

$$\min f(x) = \sum_{i=1}^{n} \frac{x_i^2}{4000} - \prod_{i=1}^{n} \cos(\frac{x_i}{\sqrt{i}}) + 1, \quad -600 \le x_i \le 600$$

此函数有一个(0,0,.....,0)为全局最小,全局最小 值为0. 此函数时典型的非线性多模态函数,具有广泛 的搜索空间,通常认为是优化算法很难处理的复杂多 模态问题.

(5)Schwefel 函数

$$\min f(x) = \sum_{i=1}^{n} (-x_i) \cdot \sin(\sqrt{|x_i|}) , \quad -500 \le x_i \le 500$$

此函数有一个(420.9687,, 420.9687)为全局最 小,最小值为-n×418.9829.

1.3.2 优化结果与分析

在 ACMABC 算法的测试实验过程中,为了实验 结果更具有说服力, 将对以上五种种测试函数进行优 化,并与标准的 ABC 算法进行比较.测试函数如表 1 所示. 根据经验性方法理论, 本文通过大量实验确定 算法参数阈值. 参数阈值的选择对算法的收益和收敛 性都有很大的影响,参数选择的不好往往会导致结果 的错误或者使该算法不收敛.因此,本文通过大量实 验确定了适合该算法的参数阈值,使算法的收益最优 并收敛. 两种算法的参数设置如下: 蜜蜂种群数目为 50, 迭代次数为 2000, 误差极限为 1E-20, 开采次数为 50, ACMABC 最小权重系数为 0.08, 最大权重系数为 1.8. 对每一个测试函数都进行2维,10维和30维的测 试,每组实验都独立进行 20 次,并比较运行结果中的 最优值、平均值及20次独立实验中接近最优值的概率, 本文中接近最优值的概率是以最优值的±5%为标准进 行计算的. 优化的结果如表 1 所示, 曲线收敛图如图 2-6.

优化函数	ABC			ACMABC				
	维数	最优值	平均值	达优概率(%)	维数	最优值	平均值	达优概率(%)
Sphere	2	0.2788	1.4747	40	2	0.1489	0.8691	65
	10	0.1427	1.1122	55	10	0.0888	0.5162	80
	30	0.0041	0.1697	88	30	0.0003	0.0116	96
Ackley	2	0.4984	1.6426	30	2	0.5679	1.2234	35
	10	0.3486	1.4851	35	10	0.0422	1.1213	50
	30	0.0152	0.5133	60	30	0.0013	0.1597	75
Rastrigin	2	80.2023	70.9918	25	2	80.1333	77.1056	30
	10	80.5472	79.1918	35	10	80.5160	80.1156	70
	30	80.6008	79.9518	55	30	80.6070	80.3171	85
Griewangk	2	0.3315	0.4367	15	2	0.1500	0.2868	30
	10	0.2642	0.3441	25	10	0.1420	0.2544	35
	30	0.2028	0.3007	30	30	0.0418	0.1399	40
Schwefel	2	-835.7881	-834,7558	65	2	-837.8944	-836.8940	75
	10	-4.1800e+03	-4.1774e+03	70	10	-4.1894e+03	-4.1790e+03	80
	30	-1.2567e+04	-1.2521e+04	80	30	-1.2569e+04	-1.2559e+04	85





图 2 Sphere 函数优化曲线





图 4 Rastrigin 函数优化曲线



Software Technique • Algorithm 软件技术 • 算法 121



图 6 Schwefel 函数优化曲线

从表 2 的优化结果来看,在每组测试函数中,无 论是 ABC 算法还是 ACMABC 算法,维数的不同优化 的结果差异较大,将其平均值和最优值与测试函数的 最优值进行比较都可以看出,维数越高,其优化结果 越精准,并且达到最优解的概率也更高,这说明无论 是 ABC 算法还是 ACMABC 算法对高维的优化问题是 有效的.再比较 ABC 和 ACMABC 算法的结果,当维 数一定时, ACMABC 算法的最优解和平均值都优于 ABC 算法的结果,并且 ACMABC 算法的达优概率明 显高于 ABC 算法,因此,与基本的 ABC 算法相比, ACMABC 算法的寻优性能更优,结果更加精准一些.

图 2~图 6 为 ACMABC 算法和 ABC 算法搜索最 优解过程的收敛曲线图. 由图中可见,在 2000 次的迭 代过程中,ACMABC 算法能更准确的找到最优解,该 曲线下降收敛的速度优于 ABC 算法的收敛曲线,并且 ACMABC 算法的曲线更接近最优解.在迭代次数不 到 2000 次时已经找到 ABC 算法优化的最优解,可见 ACMABC 算法比 ABC 算法更有效率.

2 ACMABC算法收敛性分析

ACMABC 算法同 ABC 算法一样都属于随机搜索 算法^[9-10]的范畴,对于优化函数方面的收敛性, ACMABC 算法同样可以通过随机算法收敛准则判定 ACMABC 的收敛性.

2.1 相关数学描述和定义

为了说明 ACMABC 算法的收敛性, 需要先给出 一些相关的数学描述和定义.

定义 1. 人工蜂群在搜索过程中搜索到的蜜源的 位置称为人工蜂状态,记为X, $X \in A$, A为可行解空



间.人工蜂群中,所有人工蜂状态称为人工蜂群状态, 记为*s* = (*X*₁,*X*,,...,*X*_{sv}).

定义 2. 人工蜂所有状态的集合称为人工蜂群状态空间,记为 $X = \{X | X \in A\}$.所有人工蜂的状态空间的集合称为人工蜂群状态空间,记为 $S = \{s = (X_1, X_2, ..., X_{SN}) | X_i \in X, 1 \le i \le SN\}$.

定义 3. 在 ACMABC 算法中,人工蜂由一个状态 X_i 转移到另一个状态 X_i ,称为人工蜂状态转移,记为 $T_s(X_i) = X_j$.人工蜂转移状态的概率称为转移概率,记 $p(T_s(X_i) = X_j)$.

定义4. 对于 $\forall s_i \in S$, $\forall s_j \in S$, ACMABC算法迭代 中,人工蜂群状态由 s_i 一步转移到 s_j ,记为 $T_s(s_i) = s_j$. 人工蜂群状态由 s_i 一步转移到 s_i 的转移概率为

$$P(T_{s}(s_{i}) = s_{j}) = \prod_{m=1}^{SN} p(T_{s}(X_{im}) = X_{jm}$$
(7)

定理 1. ACMABC 算法中,人工蜂状态由 X_i 一步 转移到 X_i 的转移概率的表达式为

$$p(T_{s}(X_{i}) = X_{j}) = \begin{cases} p_{em}(T_{s}(X_{i}) = X_{j}) \\ p_{on}(T(X) = X) \\ p_{sc}(T(X) = X) \\ p_{em}(T(X) = X) \times p_{on}(T(X) = X) \end{cases}$$
(8)

2.2 收敛准则

1000

对于优化问题<A,f>,有随机优化算法 D,第 k次迭代的结果为 x_k ,则下一次迭代的结果为 $x_{k+1} = D(x_k,\varsigma)$.其中,A为可行解空间,f为适应度函数, ς 为算法 D 迭代中曾经搜索到的解^[12].

假设 1:
$$f(D(x,\zeta)) \le f(x)$$
,若 $\zeta \in A$,则有
 $f(D(x,\zeta)) \le f(\zeta)$ (9)
假设 2: 对于 A 的任意 Borel 子集 B $sty[B] > 0$

则有 $\prod_{k=0}^{\infty} (1 - u_k[B]) = 0$. 其中 $u_k[B]$ 为算法 D 第 k 次

迭代搜索解在集合 B 上的概率测度.

定理 2. 算法全局收敛的充要条件是算法 D 既满 足假设 1 又满足假设 2.

证明: 若算法 D 满足假设 1 则可以说明算法的适 应度值 f(x) 是递减的;若满足假设 2 则说明算法迭代 足够多次后,不能搜索到近似最优解的概率为 0. 也就 是说,算法如果满足了假设 1 和假设 2, 那么算法在迭 代一定次数后,找到最优解的概率为 1,即算法是收敛 的.

2.3 ACMABC 算法的收敛性分析

引理 1. ACMABC 算法满足假设 1.

证明: ACMABC 算法的每一次迭代都要进行贪婪选择,即

$$v_{i} = \begin{cases} v_{i}, f(v_{i}) \le f(x_{i}) \\ x_{i}, f(v_{i}) > f(x_{i}) \end{cases}$$
(10)

所以,ACMABC 算法每次迭代都保存了群体最优解, 满足假设 1.

定义 5. 人工蜂群最优状态集合为 $G = \{s^* = (X) | f(X) = f(g^*), s \in S\}, 其中g^* 是优化问题的$ $最优解, 且<math>G \subset S$.

定理 3. ACMABC 算法中,对人工蜂群状态序列 $\{s(t); t \ge 0\}$ 而言,最优人工蜂群状态集合 G 是状态空间 S 的有一个闭集.

证明: 设 $\forall s_i \in G$, $\forall s_j \notin G$, 对于任意转移步长 $l, l \ge 1, P_{s_i,s_j}^l$ 表示蜂群由状态 s_i 经过l步转移到状态 s_j 的 概率可表示为:

$$P_{s_{i},s_{j}}^{l} = \sum_{s_{n} \in s} \cdots \sum_{s_{n-1}} P(T_{s}(s_{i}) = s_{n})$$

$$\times P(T_{s}(s_{n}) = s_{r_{2}}) \cdots P(T_{s}(s_{n-1}) = s_{j})$$
(11)

在式(17)中每一项乘积表达式中都有 $P(T(s_{r_{c_1}})=s_{r_c}),满足s_{r_{c_1}} \in G _ s_{r_c} \notin G,其中1 \le c \le l,则$ 由定义4可得蜂群转移概率为

$$p(T_{S}(s_{r_{c-1}}) = s_{r_{c}}) = \prod_{m=1}^{SN} p(T_{S}(X_{im}) = X_{jm})$$
(12)

由 $s_{r_{c-1}} \in G$ 和 $s_{r_c} \notin G$, 有 $f(X_c) > f(X_{c-1}) = f(g^*) = \inf(f(a))$, $a \in A$, 则至少存在 $p(T_s(s_{r_{c-1}}) = s_{r_c}) = 0$, 故此时 $P'_{s_i,s_j} = 0$, 因此G是S上的一 个闭集.

定理 4. 人工蜂群状态空间 *S*, 不存在非空间闭集 *M*, 使得 $M \cap G = \varphi$.

证明: 假设状态空间 *S* 存在一个非空闭集 *M* 使 $M \cap G = \varphi$. 设 $s_i = (g^*, g^*, \dots, g^*) \in G$, $\forall s_j = (x_{j_1}, x_{j_2}, \dots, x_{j_d}) \in M$, 有 $f(x_{j_c}) > f(g^*)$,则经过有 限迭代会满足定理1中条件,即 $p_{sc}(T_i(X_s) = X_j) > 0$.因 此,当 $l \to \infty$ 时,展开式中一定有某些表达式使其满足 定理1 中的式(8),也就是 $P(T(s_{r_{est}}) = s_{r_{est+1}}) > 0$.又由定 理3可知 $P_{s_i, s_j}^l > 0$,则 M 不是闭集,与题设矛盾,因此 原结论得证,即状态空间 *S* 不含除 *G* 以外的闭集.

定理 5. 当蜂群内部迭代趋于无穷时,蜂群状态序 列必将进入最优状态集 G.

证明: 由定理 4 可知, 人工蜂群的最优状态集 G 是一个闭集. 由定理 5 可知, 蜂群状态 S 中不含除最优

状态集 *G* 以外的闭集. 当 $i \notin G$ 时, 有 $\lim_{n \to \infty} P(X_n = i) = 0$, 即当 $n \to \infty$ 时, 人工蜂群搜索不到最优解的概率为 0, 也就是说蜂群状态必将进入最优状态集 *G*.

引理 2. ACMABC 算法满足假设 2.

证明: 若使假设 2 成立,则要求算法 D 连续无穷 次未搜索到 B 中元素的概率为 0,其中 B 在 ACMABC 中指优化函数的最优解.由定理 5 可知,算法连续无 穷次搜索到全局最优解的概率为 0,则有 0 < u_k[B] < 1,

 $\prod_{k=0}^{\infty} (1 - u_k[B]) = 0$ 满足假设 2.

定理 6. ACMABC 算法全局收敛.

证明: 由于 ACMABC 算法满足假设 1 和假设 2, 通过定理 2 全局收敛的充要条件可得, ACMABC 算法 是全局收敛.

3 基于ACMABC-SVM风电功率短期预测

3.1 基于 ACMABC-SVM 风电功率短期预测模型

近年来,为了应对环境和能源问题,风力发电技 术迅速发展;然而,风电输出功率的不确定性,势必 严重冲击电力系统的稳定性.风电功率短期预测能够 提前预测风电场输出功率,为电力系统调度、安排发 电计划提供可靠依据.本文将 ACMABC 算法应用于 风电功率预测中,预测模型采用常用的支持向量机^[11] (Support Vector Machine,SVM)模型,然而,惩罚系数*C* 和核函数参数σ²影响 SVM 预测回归性能^[11],本文采 用 ACMABC 算法优化 SVM 中的惩罚参数和核参数. 具体预测步骤如图 7 所示.



图 7 ACMABC-SVM 风电功率短期预测模型

3.2 实例分析

本文以上海某近海风场 5-6 月份实测风电功率数

Software Technique • Algorithm 软件技术 • 算法 123

据为例,对预测模型进行测试,验证该模型的可行性. 该风电场风电功率序列间隔时段为1小时,取200点数据用来建模,预测未来48点风电功率值.利用 ACMABC 算法寻优,优化 SVM 核函数参数和惩罚系数;设定 SVM 核函数参数搜索空间为0.01-100,惩罚 系数搜索空间为0.01-100,蜂群规模为100,循环次数 为50次.本文将 ACMABC-SVM 预测模型与 SVM 预 测模型相比,预测结果如图8所示.



图 8 给出风电功率预测值与实际值的对比,由图可以看出,二种方法的预测效果均能反应实际风电功率的变化效果,且 ACMABC-SVM 模型拟合效果明显优于 SVM 模型,尤其是两个峰值点的逼近效果.为了更有效的说明该模型的可行性,表 2 给出了两种模型实验结果的平均绝对百分误差(Mean Absolute Percentage Error简称 MAPE),均方根误差(Root Mean Square Error简称 RMSE)及最大误差(Maximum Error,简称, MaxE);由表1可见,方法2的 MAPE为7.85%,预测精度比方法1降低了3个百分点,且方法2的 RMSE 和 MaxE 明显优于方法1,进而验证了ACMABC-SVM预测方法的可行性.

表 2 预测结果的 N	IAPE,	RMSE 及	MaxE	的比较
-------------	-------	--------	------	-----

预测模型	SVM	ACMABC-SVM
MAPE/%	0.1132	0.0785
RMSE/%	0.0554	0.0299
MaxE/kw	209.3511	125.8896

4 结语

为了开发蜜蜂搜索能力,蜜蜂搜索时引入自适应 权重,其权重大小的确定根据蜜蜂收益进行动态调整, 增强搜索目标性;同时引入不同于常规的边界设定方法,更好地保存群体的结构,增加种群的多样性;另 外当蜜蜂收益连续几代不变时,采用柯西变异算子的 方法变异更新当前最优位置,使蜜蜂及时跳出局部极 值.对几个测试函数的优化结果表明,改进的人工蜂 群算法精度明显提高,而且收敛速度加快.然后将改 进的人工蜂群算法用于风电功率短期预测模型的参数 优化,与常规交叉法相比,结果表明ACMABC的优化 性能更好,拟合精度更高.

参考文献

 Karaboga D. An idea based on honey bee swarm for numerical optimization, Vol.06: Kayseri, Erciyes University: Engineering Faculty, 2005, 10.

- 2 Abu-Mouti FS, El-Hawary ME. Optimal Distributed Generation Allocation and Sizing in Distribution Systems via Artificial Bee Colony Algorithm. IEEE Trans. on Power Delivery, 2011,26(4):2090–2101.
- 3 Akay B, Karaboga D. A modified Artificial Bee Colony algorithm for real-parameter optimization. Information Sciences, 2012,192:120–142.
- 4 Karaboga D, Akay B. A comparative study of Artificial Bee Colony algorithm. Applied Mathematics and Computation, 2009, 214 :108–132.
- 5 Coelho LS, Alotto P. Gaussian artificial bee colony algorithm approach applied to loney's solenoid benchmark problem. IEEE Trans. on Magnetics, 2011,47 (5):1326–1329.
- 6 易正俊,何荣花,侯坤.量子位 Bloch 坐标的量子人工蜂群优 化算法.计算机应用,2012,32(7):1935–1938.
- 7 张长胜.多目标人工蜂群算法及遗传算法的研究与应用.沈 阳:东北大学出版社,2013.
- 8 杨淑莹,张桦.群体智能与仿生计算.北京:电子工业出版社, 2012:74-77.
- 9 Szeto WY, Wu YZ, Sin CH. An artificial bee colony algorithm for the capacitated vehicle routing problem. European J of Operational Research, 2011, 215(1):126–135.
- 10 任子晖,王坚,高岳林.马尔科夫链的粒子群优化全局收敛 性分析.控制理论与应用,2011,28(4):462-466.
- 杨洪,古世甫,崔明东等.基于遗传优化的最小二乘支持向 量机风电场风速短期预测.电力系统保护与控制,2011, 39(11):44-48.