

基于进化控制与非均匀变异的花授粉算法研究^①

张水平^② 陈 阳^③

(江西理工大学信息工程学院 赣州 341000)

摘 要 针对花授粉算法(FPA)优化高维复杂性问题时存在的收敛精度低且收敛速度慢的缺陷,提出一种基于进化控制与非均匀变异的花授粉算法(ENFPA)。该算法引入以余弦函数为控制因子随机调节当前位置与最优位置进化比例,改善算法前期花粉过于聚拢于最优个体而导致进化方向不佳的可能。为一定程度抑制算法进化后期种群多样性降低而出现的优化解聚拢现象,引入非均匀变异策略对当前位置进行改变以拓展新的进化方向。经过仿真数值实验表明,改进算法在函数优化问题上具有更好性能。将改进的算法应用于神经网络优化模型的实验表明,可以一定程度降低神经网络预测的误差。

关键词 花授粉算法(FPA),早熟收敛,进化控制,非均匀变异,神经网络

0 引 言

随着信息技术的发展,现在处于大数据时代背景。数据量几何倍增的同时计算理论亦趋于复杂化。优化算法是一种搜索最优方案寻找最佳解集的算法,已经应用于各个自然科学与工学领域。传统的优化算法如牛顿法、梯度下降法等属于局部优化,即不能保证最终结果为全局最优。这些算法有其用武之地然而应用限制逐渐增加不能满足更高的需求。群体智能算法是一种借助自然界生物进化模式而进行全局优化的算法。经典的如遗传算法、粒子群算法、差分进化算法等^[1-4],这些算法自提出到现在经过研究发展,已成熟地应用于各种现代化行业中。花授粉算法^[5-7](flower pollination algorithm, FPA)是较新的一种群智能优化算法,其创作背景来源于自然界中花朵通过不同的授粉方式进行繁殖,该算法总结群体协作进化的方式后注重区分全局规划与局部挖掘的方式。

花授粉算法提出时间较近却已得到广泛关注,

研究者通过不同的改进方法对其进行改进以提高算法的性能而应用于更多领域。肖辉辉^[8,9]等人分析花授粉算法的收敛性,分别结合引力搜索算法与入侵杂草算法的特点改善花授粉进化后期收敛速度的问题。除了结合其他算法优点之外,Cuevas^[10]提出的多联式改进算法,相比原算法可增强查找到最优解概率。Salgotra等^[11]针对局部搜索易于聚拢的情况,利用一种新的变异算子动态调节局部搜索。文献[12]中自定义了种群差异性指标,结合模拟退火与单纯型技术提出改进算法在多模态问题上具有高性能表现。基于遗传算法思想离散化后的花授粉算法在产品序列规划问题上具有可观的表现^[13]。不仅仅是传统的规划问题,在预测模型[14]与降低能源损耗问题上花授粉算法也是大有用场,文献[15]中混合多重模型提出一种混合授粉算法可以准确评估太阳能光伏系统参数。考虑到动态的气象环境,利用改进算法可解决MPPT问题以最大程度提高太阳能光伏发电产量^[16]。

上述研究分析,都在一定程度上提高了花授粉算法的优化性能。在研究该算法求解较高维度优化

① 国家自然科学基金(11461031,61662028)资助项目。

② 男,1965年生,硕士生导师,教授;研究方向:智能计算、云计算等;E-mail:zhsp650117@126.com

③ 通讯作者,E-mail:shawncy@qq.com

(收稿日期:2017-11-09)

问题时出现的解精度不够,很大程度是由于进化后期种群容易丧失多样性,而导致搜索更优解的可能变低。花授粉算法具有两段更新策略,两段更新方式采用随机概率的方式。第一段更新方式是以当前位置环绕最优解的附近进行莱维飞行而更新,第二段是向当代非最佳解的位置进行更新,这一设计对拓展种群多样性有帮助但只是在小程度上矫正进化方向。本文针对花授粉算法的特性以余弦函数为协调基础,随机给定进化学习的权重,此外在进化后期种群多样性变低时,引入非均匀变异操作以提高更优解进化方向的可能。通过6组测试函数证明了改进算法的有效性。风能是一种可以代替传统能源的新型可再生能源,风速是其重要指标,通过实验证明新算法可成功应用于神经网络并预测某地风速变化情况,具有良好的效果。

1 花授粉算法介绍

花授粉算法的模型是自然界中花朵传播授粉繁殖而设计的优化模型,文献[5]中给出算法的4个标准化背景。其中将授粉过程分为异花授粉与自花授粉,两种授粉方式之间采用转化概率 P 控制,其中 $P \in [0,1]$ 。由于自然界中每一个植物会开多个花且每个花具有多个花粉胚子,为剔除其他因素干扰,认定每个植物有且仅有一个花粉胚子。这些花粉胚子可以由风、蜜蜂等昆虫进行传播授粉,即为设计模型中的全局过程。另外花粉胚子成熟可能跌落在自身花朵上进行自花授粉,即为设计模型中的局部优化。算法进行目标优化时,异花授粉的全局优化方式如式(1)所示,其中 G 表示第 t 代授粉全局最佳位置。 L 表示控制授粉的收缩因子。由于一般的可以协助授粉的昆虫飞行过程不可控, L 采用式(2)进行莱维飞行模式。其中 Γ 函数为标准的 gamma 函数。

$$X_i^{t+1} = X_i^t + L(G - X_i^t) \quad (1)$$

$$L \sim \frac{\lambda \Gamma(\lambda) \sin(\pi\lambda/2)}{\pi} \times \frac{1}{s^{1+\lambda}}, (s \gg s_0 > 0) \quad (2)$$

$$s = \frac{\mu}{|v|^{1/\lambda}}, \mu \sim (0, \sigma^2), v \sim N(0,1) \quad (3)$$

式(3)中 σ 取值满足式(4)。式(5)为自花授粉的局部优化操作,其中 $\zeta \in rand(0,1)$, X_j, X_k 分别表示第 t 代时随机选择的两个个体 j 和 k 的位置,这样设计可在算法整体进化路径上增加其他更优解存在的可能性。

$$\sigma = \left[\frac{\Gamma(1+\lambda)}{\lambda \Gamma(\frac{1+\lambda}{2})} \cdot \frac{\sin(\frac{\lambda}{2}\pi)}{2^{\frac{\lambda-1}{2}}} \right]^{\frac{1}{\lambda}} \quad (4)$$

$$X_i^{t+1} = X_i^t + \zeta(X_j^t - X_k^t) \quad (5)$$

上述公式为花授粉算法执行的核心原理,表1中给出其执行伪代码以方便了解该算法运行流程。

表1 花授粉算法伪码

Algorithm 1 FPA
Begin
初始化最大迭代次数 Maxgen、种群个数 Sizepop、转化概率 P 、问题维度 Dim;
定义适应度函数,即拟解决问题。//以 $\text{Min } F(x)$ 为例
初始化种群位置代入适应度函数求 $\text{Min}F(x)$ 即为第一代全局最佳解。
While $t < \text{Maxgen}$
For $i = 1 : \text{Sizepop}$
If $\text{rand} > P$
执行式(1),得出的解进行边界化处理。
Else
执行式(5),得出的解进行边界化处理。
End
End
If $F_{\text{new}}(X_{\text{new}}) < = \text{Fitness}(X_{\text{last}})$;
$X_{\text{new}} = \text{last}$;
End
If $F_{\text{new}}(X_{\text{new}}) < = \text{Fitness}(G)$
$G = X_{\text{new}}$;
End
$t++$;
End
End

2 基于进化控制与非均匀变异的花授粉算法(ENFPA)

2.1 算法分析与设计

基本花授粉算法利用两段更新操作进行迭代更新而搜索最优解,原始控制两段更新方式的概率 P

取值 0.5, 文献[7]中论证当 P 取 0.2 时实验效果最好。针对参数问题不再讨论。在全局最优化阶段花授粉算法主要以上一代的位置为核心, 围绕上代最优位置附近做莱维飞行。需要考虑的是, 算法初始化具有一定随机性, 如果某一次最佳位置搜索结果有偏差会导致最终的求解精度难以达到目标要求。在迭代次数较大的设定下, 即使最终求解目标精度可以达到, 其收敛速度亦会大打折扣。分析整个进化过程, 智能算法的前期搜索设定范围较大, 目的是为了确定一个最优解范围然后进行精细搜索确定最优解。在高纬度多峰问题上最优解范围确定也是会有偏差的, 一般情况全局更优解的位置往往出现在当前最优解的一个邻域中, 理论上向最优解收敛在规定迭代完成是可以搜索的目标值。但是在高维问题中前期寻优方向一旦出问题, 在规定迭代中算法难以具有快速调整能力, 从而导致收敛变慢、精度不够。协调全局优化搜索时, 一般会采用线性递减的方式分配权重, 在授粉进化前期较多考虑父辈经验, 向全局收敛有一定的比例, 在授粉进化后期加快收敛速度向当代最优解靠拢。这种方式采用式(6), 全程进化规定一个方向, 可以保证收敛速度, 但一定程度缩小了不在规定方向上更优解的可能。

$$w1 = w \max - (\max - w \min) \times t / \maxgen \quad (6)$$

$$w = \cos(h) \quad (7)$$

$$h = \pi/2 \times \text{rand}() \quad (8)$$

本文提出以余弦函数为基础随机分配的方式, 搜索前期可以向最优位置学习快速整合本代个体经验, 如果有局部限制可能下一代进化中更多是向父代学习。这种方式旨在拓展高维问题中寻找到更优解的可能性。选择方式如式(7)、(8)所示, 图 1 中给出两种进化过程控制的方式, 随机分配强大的波动性可探索不同解附近的邻域。因此新算法中将进化方式中式(1)、(5)替换为式(9)、(10)。

$$X_i^{t+1} = wX_i^t + (1 - w)L(G - X_i^t) \quad (9)$$

$$X_i^{t+1} = wX_i^t + (1 - w)\zeta(X_j^t - X_k^t) \quad (10)$$

优化进程后期种群多样性降低, 不可避免地所有个体会聚拢在一起。花授粉算法本身所采用的局部阶段优化便是在优化进程中对种群多样性进行微

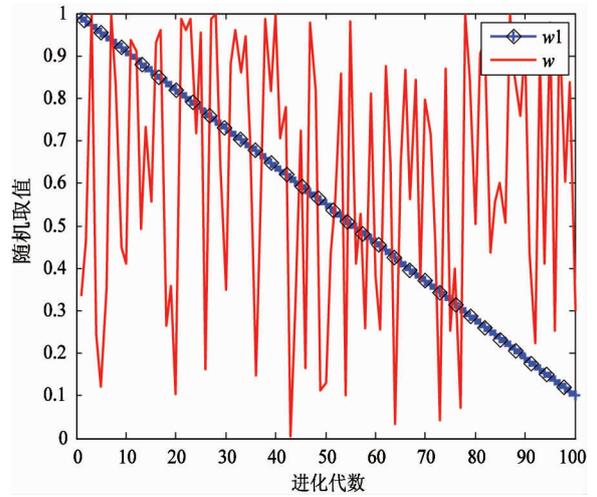


图 1 两种策略比较

调。因此在算法后期设计可以二次寻优的方法, 当种群多样性降低到一定程度, 对该代最优个体进行非均匀变异, 即聚拢现象出现后下一代种群可以在最优个体的某个邻域中搜索更优解, 从而突破限制引导进化方向。在此多样性指标是种群的适应度方差, 由式(11)、(12)求得。式(13)是非均匀变异操作, 其中 X_g^t 表示方差小于设定值那一代的全局最优个体位置, UB 和 LB 是求解问题的范围, r 为随机数 rand 。

$$\sigma^2 = \text{sum}((\text{Fitness} - \text{avg})^2) \quad (11)$$

$$\text{avg} = \text{sum}(\text{Fitness}) / \text{Sizepop} \quad (12)$$

$$X_g^{t+1} = \begin{cases} X_g^t + \Delta(t, UB - X_g^t), & r < 0.5 \\ X_g^t - \Delta(t, X_g^t - LB), & r > 0.5 \end{cases} \quad (13)$$

2.2 算法实现伪代码

经过 2.1 节分析, 表 2 中给出改进算法的执行伪代码。

表 2 改进算法伪码

Algorithm 2 ENFPA	
Begin	初始化操作, 与表 1 中操作相同。
While $t < \text{Maxgen}$	执行式(7)、(8)。
For $i = 1; \text{Sizepop}$	For $i = 1; \text{Sizepop}$
If $\text{rand} > P$	If $\text{rand} > P$
执行式(9), 得出的解进行边界化处理。	执行式(9), 得出的解进行边界化处理。
Else	Else

(续表2)

执行式(10),得出的解进行边界化处理。

```

End
End
If Fnew(Xnew) <= Fitness(Xlast);
Xnew = last;
End
If Fnew(Xnew) <= Fitness(G)
G = Xnew;
End
执行式(11)、(12)。
If  $\delta^2 < TV$  %% TV 表示设定的判断多样性丧失的阈值。
执行式(13)。
End
t++;
End
End
    
```

3 数值实验

3.1 实验说明

本节旨在对比两种算法性能,分别设计两组实验对 FPA 与 ENFPA 的收敛速度、收敛精度进行比较。实验函数信息见表 3,优化问题含有单峰问题与多峰问题。其中 F2 函数理论极值为 -1,其余函数最优值都为 0。为方便函数进化图形的观察,对于表 3 中部分测试函数求解值取 lg10。由于演化

算法属于随机优化算法,每一次的最终优化结果可能存在一定偏差,因此每项实验独立运行 50 次。本章中所有实验数据、图形都是多次独立运行后取得的平均值。具体参数规定如下: Maxgen = 200; Sizepop = 30; Dim = 30; TV = 10E-06;算法对测试函数求解边界化处理限制为各个函数的搜索空间。

3.2 结果分析

独立运行两种算法测试 6 种函数的表现性能,其在 200 次固定迭代中进化曲线如图 2 所示。表 2 中给出独立实验的优化最大最小值、均值以及标准差。ENFPA 在摆脱局部限制,进行更高精度寻优性能优于 FPA。30 维度的设定下,FPA 对 6 种测试函数中都过早陷入局部最优,难以满足性能需求。函数 F1 是一类相对较容易优化的函数,其属于单峰值,主要用来验证 ENFPA 的优化速度,ENFPA 在进化第 15 代左右便探索到新方向优于原算法,最终平均提升 83 个数量精度。F2 是极值为 -1 的高维单峰函数,设计一项最优值为负数的函数是为了证明改进算法的适用面。图 2 中可以看出 ENFPA 在 20 代时即找到理论最优值 -1,而 FPA 早就陷入局部最优解而停止进化寻优。在独立实验中 FPA 搜索到的最小值为 -0.0012,远达不到要求的精度。ENFPA 标准差为 0,每次优化算法都可以搜索到理论

表 3 测试函数信息表

函数名	表达式	维度	搜索空间	理论极值	峰值
Sphere	$f_1(x) = \sum_{i=1}^n x_i^2$	30	[-100,100]	0	单峰
Exponential	$f_2(x) = -\exp(-0.5 \times \sum_{i=1}^n x_i^2)$	30	[-10,10]	-1	单峰
Rosenbrock	$f_3(x) = \sum_{i=1}^{n-1} (100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2)$	30	[-100,100]	0	多峰
Griewank	$f_4(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos(\frac{x_i}{\sqrt{i}}) + 1$	30	[-600,600]	0	多峰
Rastrigin	$f_5(x) = \sum_{i=1}^n (x_i^2 - 10 \cos(2\pi x_i)) + 10$	30	[-5.12, 5.12]	0	多峰
Ackley	$f_6(x) = -20 \exp(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}) - \exp(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)) + 20 + e$	30	[-100,100]	0	多峰

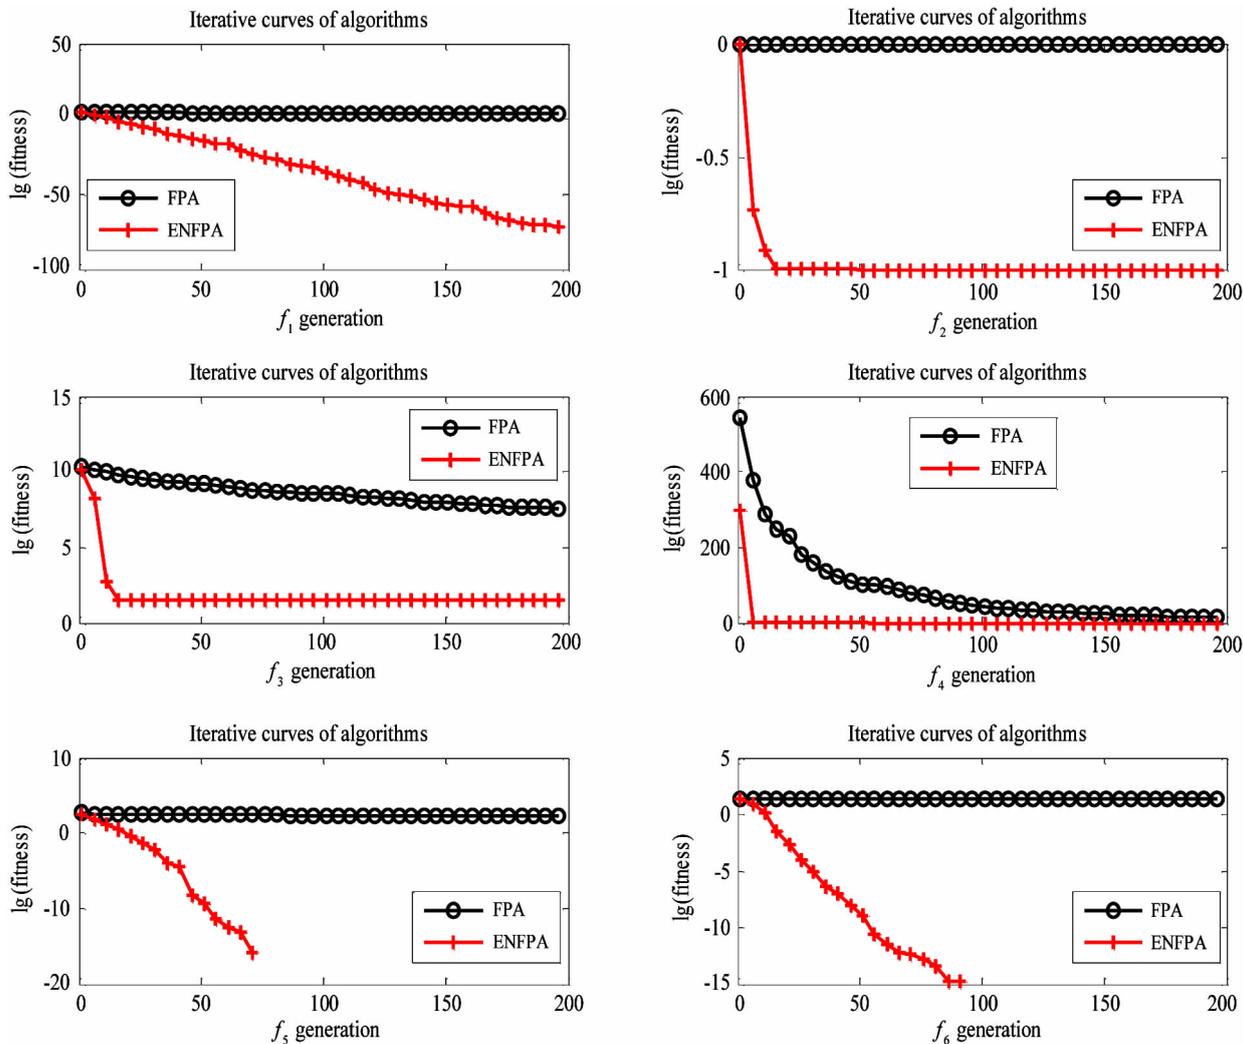


图2 进化曲线

最优值,证明 ENFPA 在此类问题上具有极强的搜索稳定性。F3 是一种形状类似香蕉形的峡谷函数,其最优解位置远离其他局部最优解,此类问题传统算法基本难以解决。实验中 FPA 表现极差,ENFPA 由于利用随机余弦方式分配权重,种群可以在有限迭代范围中更大程度地全面搜索,一定程度上提高了优化效果。多峰函数 F4、F5、F6 优化测试中,ENFPA 可以达到理论极值。图 2 中可以看出这三类优化问题,ENFPA 摆脱聚拢现象后收敛的速度也是极快的。

为进一步证明本文提出的算法 ENFPA 的有效性,将优化均值与相关参考文献中算法进行比较。由表 5 中可知,除对 F1 测试性能较弱于文献[8]中算法 GSFPA 外,ENFPA 性能整体优于相关参考文

献中的优化值。函数 F3 测试中,ENFPA 结果虽然较好,但可看出相关算法对其优化精度都不理想,这也是需要再加深研究的一点。文献[4]、[5]算法对 F4、F5 优化可以达到理论最优值,对 F6 测试求解精度提升明显但弱于 ENFPA。文献[9, 11, 12]中优化效果相对于表 4 中 FPA 给出的值有明显提升,说明这三种针对 FPA 改进的算法与 ENFPA 都有相同目标方向。ENFPA 独有的强探索性与跳离局部限制的能力使其具有明显的优势。表 6 中给出 3 种算法的寻优成功率与达到目标精度停止迭代的进化代数。设定终止迭代的目标精度, FPA 与 ENFPA 为 $10e-10$ 、CLSFPFA 为 $10e-06$ 。FPA 与 ENFPA 的其他参数设定见 3.1 节中,CLSFPFA 中 Maxgen = 10000, Popsize = 50, 独立运行 20 次。寻优成功率 = 达到目

标精度的次数/总迭代次数。因此可知 FPA 无法达到任何一次目标要求,ENFPA 在 6 种函数上都可以成功达标。相比 CLSFPA 算法在 F1、F5、F6 优化效果,ENFPA 在精度要求更高的情况下不但保证了百

分百的寻优成功率,而且很大程度缩短了达到目标精度的迭代步数。综合本节实验整体表明了 ENFPA 在高维问题上具有良好的优化效果以及求解稳定性。

表 4 两种算法优化值比较

函数	算法	均值	最小值	最大值	标准差
F1	FPA	1.7911e+03	1.2651e+03	2.4836e+03	4.3489e+02
	ENFPA	2.8835e-80	4.4345e-103	2.8832e-79	9.1172e-79
F2	FPA	-5.3877e-04	-1.2e-03	-4.3689e-06	3.4140e-04
	ENFPA	-1	-1	-1	0
F3	FPA	1.7317e+06	1.0382e+05	2.4867e+07	4.7578e+04
	ENFPA	28.95	28.91	28.97	1.79e-02
F4	FPA	1.45762e+01	1.18772e+01	1.86565e+01	2.3373
	ENFPA	0	0	0	0
F5	FPA	1.7558e+02	1.4655e+02	1.9919e+02	1.4556e+01
	ENFPA	0	0	0	0
F6	FPA	2.10597e+01	2.09052e+01	2.1135e+01	7.82e-02
	ENFPA	0	0	0	0

表 5 与参考文献算法比较

函数/算法	ENFPA	OOBDE ^[4]	GSFPA ^[8]	IWOFFPA ^[9]	ALFPA ^[11]	NS-FPA ^[12]
F1	2.8835e-80	1.7e-67	0	2.5466e-12	—	1.82e-05
F3	28.95	1.16e+2	—	1.4025e+02	1.48e+06	—
F4	0	0	0	3.0012e+01	1.40	1.32e-03
F5	0	0	0	6.1688	4.26e+01	1.18e-07
F6	0	3.99e-15	8.88E-16	3.369e-07	1.31	1.62e-07

表 6 寻优成功率与平均迭代次数

算法\平均迭代数-成功率	F1	F2	F3	F4	F5	F6
FPA	0-0	0-0	0-0	0-0	0-0	0-0
ENFPA	31.7-1	1-1	30.3-1	35.2-1	32.4-1	47.5-1
CLSFPA	839.5-1	—	141.1-1	—	285.9-1	275.8-1

4 神经网络预测优化

风速预测是风能研究重要的指标,更精确地预测风速可以更大程度利用资源。本节实验将算法 ENFPA 应用于修正 BP 神经网络权值阈值进行风速预测。BP 神经网络是一种按误差反向传播的网络,利用梯度下降法不断修正网络权值。文献[3]中说

明了针对现实中较为复杂的问题,梯度下降法对网络初始权值阈值选择不佳会影响训练结果。引进遗传算法对网络进行优化改进取得一定效果。下面得到某地 145 天的风速情况,以前 100 天的数据作为训练样本,这些数据中每前三天数据拟合后一天的情况。测试样本为后 45 天的数据。

利用 ENFPA 优化网络初始权值阈值参数设置

为 $\text{Maxgen} = 30$, $\text{Sizepop} = 20$ 。神经网络的训练次数 100, 学习率 0.1, 目标精度 $10\text{e-}05$ 。

算法预测基本步骤:

(1) 初始化数据分为训练样本与测试样本。

(2) 设定网络各层节点数, 将训练样本与测试样本归一化操作。

(3) 创建网络, 计算总体权重数, 即为 ENFPA 算法优化的维度。

(4) 设计适应度函数, 利用 ENFPA 寻找误差最小值。保存该个体位置。

(5) 得到最优权值阈值赋值于网络进行训练。比对结果。

图 3 给出 FPA 与 ENFPA 优化 BP 神经网络预测风速的效果图, 图中原始数据表示实际风速情况。可直观得知, ENFPA 优化预测效果相较于 FPA 更接近原始数据。为更好说明 ENFPA 优化预测的效果, 图 4 给出预测误差比值的曲线, 误差比值 = (神经网络

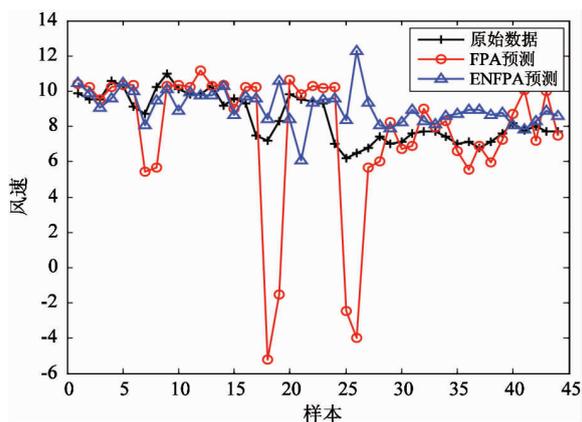


图 3 预测对比图

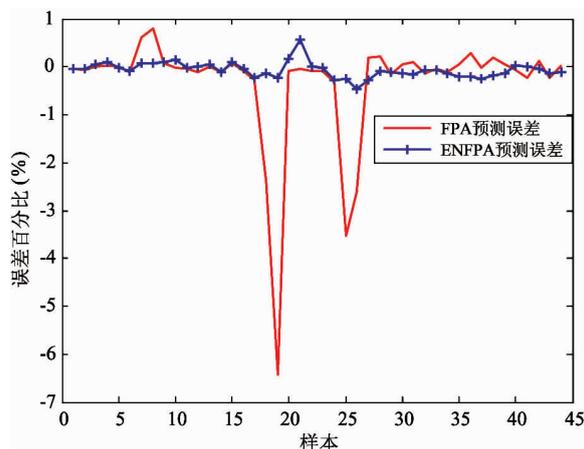


图 4 误差对比图

络预测值—真实值)/真实值。FPA 优化网络预测效果不理想, 网络设定维度过高情况下不能保证其搜索到误差最小值是其主要原因。ENFPA 一定程度上减小了 FPA 优化神经网络效果不佳的缺陷, 进一步证明 ENFPA 具有更好的性能。

5 结论

本文分析花授粉算法的设计模型, 从其自身设计的更新方式出发进行改进, 使其摆脱了在较高纬度问题上收敛慢求解精度不高的缺陷。首先以随机分配思想为主抑制授粉过程不能一味向全局最佳解收敛, 在其自身增加多样性的局部环节也是如此。随机分配以余弦函数为分配因子, 使算法可以在搜索空间中保持极大的灵活性以探索更多最优解可能出现的位置。在进化过程中一旦种群停滞进化, 引入非均匀变异操作, 增加再进化寻优的可能。经过 6 种不同的函数优化问题充分论证本文提出的 ENFPA 的高效性。随后将该算法用于 BP 神经网络初始权值优化中, 对风速数据集进行训练预测, 亦发现 ENFPA 具有良好的性能。如何将 ENFPA 用于解决离散问题将是下一步研究的方向。

参考文献

- [1] 张水平, 王碧, 陈阳. 基于逐层演化的群体智能算法优化[J]. 工程科学学报, 2017, 39(3):462-473
- [2] 赵新超, 刘国莅, 刘虎球, 等. 基于非均匀变异和多阶段扰动的粒子群优化算法[J]. 计算机学报, 2014, 37(9):2058-2070
- [3] 刘浩然, 赵翠香, 李轩, 等. 一种基于改进遗传算法的神经网络优化算法研究[J]. 仪器仪表学报, 2016, 37(7):1573-1580
- [4] 閻大海, 李元香, 祝婕. 基于正交设计的反向学习差分进化算法[J]. 华中科技大学学报(自然科学版), 2017, 45(5):23-27+44
- [5] Yang X S. Flower pollination algorithm for global optimization[C]. In: Proceedings of the International Conference on Unconventional Computation and Natural Computation, Orléans, France, 2012. 240-249
- [6] Yang X S, Karamanoglu M, He X. Multi-objective flower algorithm for optimization [J]. Procedia Computer Sci-

- ence, 2013, 18(1):861-868
- [7] Draa A. On the performances of the flower pollination algorithm-qualitative and quantitative analyses[J]. *Applied Soft Computing*, 2015, 34(C):349-371
- [8] 肖辉辉, 万常选, 段艳明, 等. 基于引力搜索机制的花朵授粉算法[J]. *自动化学报*, 2017, 43(4):576-594
- [9] 肖辉辉, 段艳明. 具有入侵杂草策略的花朵授粉算法[J]. *系统仿真学报*, 2017, 29(2):264-272
- [10] Cuevas E. Flower pollination algorithm for multimodal optimization[J]. *International Journal of Computational Intelligence System*, 2017, 10(1):627-646
- [11] Salgotra R, Singh U. Application of mutation operators to flower pollination algorithm[J]. *Expert Systems with Applications*, 2017, 79:112-129
- [12] 郭庆, 惠晓滨, 张贾奎, 等. 多模态优化的改进花朵授粉算法[J]. *北京航空航天大学学报*, 2018, 44(4):828-840
- [13] 焦庆龙, 徐达, 李闯. 基于花朵授粉算法的产品拆卸序列规划[J]. *计算机集成制造系统*, 2016, 22(12):2791-2799
- [14] Zhang W, Qu Z, Zhang K, et al. A combined model based on CEEMDAN and modified flower pollination algorithm for wind speed forecasting[J]. *Energy Conversion & Management*, 2017, 136:439-451
- [15] Xu S, Wang Y. Parameter estimation of photovoltaic modules using a hybrid flower pollination algorithm[J]. *Energy Conversion & Management*, 2017, 144(15):53-68
- [16] Ram J P, Rajasekar N. A novel flower pollination based global maximum power point method for solar maximum power point tracking[J]. *IEEE Transactions on Power Electronics*, 2016, PP(99):1-1

Flower pollination algorithm based on evolutionary control and non-uniform mutation

Zhang Shuiping, Chen Yang

(School of Information Engineering, Jiangxi University of Science and Technology, Ganzhou 341000)

Abstract

Flower pollination algorithm based on evolutionary control and non-uniform variation (ENFPA) is proposed considering the disadvantages of the traditional flower pollination algorithm (FPA) which is prone to low convergence accuracy and slow convergence rate in solving high-dimensional complex problem. The new algorithm designed a factor randomly regulated by cosine function, which can effectively adjust the ratio of current position to optimal location, and alleviate the probability that the population have a bad direction of evolution seeing individuals was too concentrated in the optimal position in early stage. In order to restrain the clustering phenomenon caused by the decrease of population diversity in the later evolutionary stage of the algorithm, the non-uniform mutation method is used to change the current position to expand the new evolutionary direction. Simulation results demonstrate that the improved algorithm has better performance in function optimization. In addition, the experimental consequences of the improved algorithm in neural network optimization model show that the error of neural network prediction can be reduced.

Key words: flower pollination algorithm (FPA), premature convergence, evolutionary control, non-uniform variation, neural network