

基于一种新的粒子群算法的天线方向图综合技术

高波 金荣洪 耿军平
(上海交通大学电子工程系 上海 200240)

摘要: 该文在线性递减权重粒子群算法的基础上提出了一种新的准粒子群优化算法。新算法借鉴了遗传算法中交叉的思想并采用了对偶算法模型改善了算法的优化速度和收敛特性。仿真表明, 将此算法应用在天线方向图综合中, 取得了良好的优化效果。

关键词: 阵列天线; 粒子群优化算法; 遗传算法; 早熟收敛; 方向图综合

中图分类号: TN820.1

文献标识码: A

文章编号: 1009-5896(2007)12-3015-05

Pattern Synthesis of Antenna Array Using a Novel Quasi PSO Algorithm

Gao Bo Jin Rong-hong Geng Jun-ping

(Dept. of Electronic Engineering, Shanghai Jiaotong University, Shanghai 200240, China)

Abstract: In this paper, a novel Quasi Particle Swarm Optimization(Quasi-PSO)based on Linear Decreasing Weight Particle Swarm Optimization(LDW-PSO) is presented. In order to improve the optimization speed and convergence performance, the novel algorithm is built by employing the idea of crossover of the genetic algorithm and adopting an antithetic algorithmic model. The simulation results show that it has achieved relatively high performance in the radiation pattern synthesis of antenna arrays.

Key words: Array antennas; Particle Swarm Optimization(PSO); Genetic Algorithms(GA); Premature convergence; Patterns synthesis

1 引言

随着大规模集成电路技术和相关计算智能算法的发展, 基于模拟自然界和人类社会的进化算法受到越来越多的重视。模拟自然选择和生物进化机制的寻优程序的遗传算法^[1](GA)和模拟鸟群、鱼群等觅食行为状态搜索问题最优解的粒子群优化算法^[2](PSO)相继被提出。遗传算法是借由染色体来共享信息, 通过基因单元的进化来实现优化的目的; 而PSO算法通过个体之间的协作, 分享社会知识来达到进化优化的效果。相比通过模拟自然进化过程的遗传算法, PSO算法具有收敛速度快, 运算简单, 易于实现等优点。

近年来, 由于粒子群算法采用的速度-位移模型, 操作简单, 控制变量相对较少, 算法模型较复杂的遗传操作简洁, 故受到了广泛的关注。但是基本的粒子群算法和别的进化算法一样都存在早熟收敛、搜索范围不大、易陷入到局部极值等问题。目前已有多种改进的算法模型被提出来^[3-6]以克服基本PSO算法早熟等问题。其中惯性权重(inertia weight)和压缩因子(constriction factor)^[3,4]方法是目前应用比较广泛的两种改进思路。特别是惯性权重的方法使得粒子群算法在收敛效率上大为提升; 而压缩因子则是从确保粒子群算法

收敛的角度, 讨论了学习因子应满足的条件限制; 还有模糊最优判断准则^[5](CBPE)和混合收敛边界^[6]等则是从算法的性能和收敛条件上对算法作了论述。

本文针对基本粒子群优化算法早熟收敛的缺点, 并结合遗传算法的一些基本思想, 提出一种新的 PSO 算法模型。新的算法在文献[3]粒子群算法模型的基础上首先对原算法模型中的学习因子作非一致性操作, 形成动态学习因子的算法模型, 再对此模型中的学习因子作对偶交叉, 生成双交叉的准粒子群算法模型(Quasi-PSO)。新的算法继续保持了原算法模型简洁特性的同时, 大大改善了算法的收敛特性和收敛速度。

Eberhart和Kennedy^[2]于1995年提出粒子群优化算法(PSO), 最初主要是借由算法模型来研究并解释复杂的社会行为。但随着研究的进一步深入, 人们发现粒子群算法和遗传算法一样在多目标函数优化, 模糊控制系统和射频电路设计与优化等领域亦有着好的应用^[7-9]。现行的阵列天线方向图综合问题, 实质上就是多目标函数的优化问题。通常是通过阵列激励大小和相位以及阵元位置的调节来实现方向图的自适应综合。文献[8]和文献[10]分别将线性递减权重粒子群算法(LDW-PSO)和遗传算法应用在天线方向图的综合之中, 在旁瓣抑制和深零陷生成上取得了一定的效果。但由于LDW-PSO算法和遗传算法本身的局限性, 二者均很难在特

定的搜索空间内寻得最优解。仿真结果表明,将本文提出的 Quasi-PSO 算法应用在天线方向图综合的多目标优化中,在全局最优解的寻取上有一定的改善。

2 线性递减权重粒子群算法

文献[8]所用的线性递减权重粒子群算法是由 Shi 等人^[3]在基本粒子群算法^[2,11]的基础上提出的。基本粒子群算法模型如下式所示:

$$\left. \begin{aligned} \mathbf{v}_{id}^{k+1} &= \mathbf{v}_{id}^k + c_1 \text{rand}_1^k (\text{pbest}_{id}^k - \mathbf{x}_{id}^k) \\ &\quad + c_2 \text{rand}_2^k (\text{gbest}_d^k - \mathbf{x}_{id}^k) \\ \mathbf{x}_{id}^{k+1} &= \mathbf{x}_{id}^k + \mathbf{v}_{id}^{k+1} \end{aligned} \right\} \quad (1)$$

\mathbf{v}_{id}^k 是群中粒子 i 在第 k 次迭代中第 d 维的速度向量; c_1, c_2 是加速系数(或称学习因子), 分别用于调节向全局最好粒子和个体最好粒子方向飞行的最大步长。 $\text{rand}_{1,2}$ 是 $[0,1]$ 之间的随机数; \mathbf{x}_{id}^k 是粒子 i 在第 k 次迭代中第 d 维的当前位置; pbest_{id}^k 是粒子 i 在第 d 维的个体极值点的位置; gbest_d^k 是整个群体在第 d 维的全局极值点的位置。通常令 $c_1 = c_2 = 2$ (或 $c_1 = c_2 = 1.5$); 在算法实现的过程中, 速度和位置向量会被限定在一定的值域内, 防止群内粒子逸出。

线性递减权重粒子群算法(LDW-PSO)是在上述算法模型的基础上增加了 ω 这个惯性权重, 算法模型如下式所示:

$$\left. \begin{aligned} \mathbf{v}_{id}^{k+1} &= \omega \mathbf{v}_{id}^k + c_1 \text{rand}_1^k (\text{pbest}_{id}^k - \mathbf{x}_{id}^k) \\ &\quad + c_2 \text{rand}_2^k (\text{gbest}_d^k - \mathbf{x}_{id}^k) \\ \mathbf{x}_{id}^{k+1} &= \mathbf{x}_{id}^k + \mathbf{v}_{id}^{k+1} \end{aligned} \right\} \quad (2)$$

线性递减权重粒子群算法(LDW-PSO)和基本的粒子群算法最大的不同就在于改进的算法在速度计算模型上引入了线性递减权重 ω , 将权重从基本粒子群算法的常量 1 变为一个随迭代次数线性变化的量。有效地增强了粒子的活性。但是和基本 PSO 一样, LDW-PSO 往往也会收敛于局部极值, 很难在特定的解空间内有效地寻出全局最优解, 这一点在多目标优化问题中体现的尤为突出。这样, 在更大程度上激活粒子并使其在更大概率上收敛于全局最优解, 同时又能保持算法原有的简洁和易操作性将是我们对模型作优化的出发点。

3 改进的粒子群算法

3.1 改进的粒子群算法模型

如前所述, 现有的 LDW-PSO 保持了基本 PSO 算法模型的简洁和高效。但是在多目标优化问题中, 仍然易陷入局部极值。仔细分析式(2)中的速度向量表达式, 不难看出, 其第 2 项和第 3 项权重同为随机量的线性组合形式, 且二者大小关系呈现极大随机性, 这就使得粒子在趋近个体极值 pbest 和全局极值 gbest 的过程中的随机性过大, 这就会导致粒子在优化的过程中难以最优的线路移动; 同时, 由于

在速度向量表达式中学习因子和随机数的积构成了算法模型中的两个权重, 两个权重与随机量均保持线性关系。这就使得粒子在向全局最优粒子和当前个体最优粒子的“聚集”的过程中呈现均衡性。粒子在此模式下, 极易“聚集”在一个或几个特定位置。从优化的结果上看, 就会导致常见的早熟和陷入局部极值的问题。

最近, 针对上述粒子群算法中粒子自身寻优能力不足的问题, 一些算法混合的思路被提出。其中, 具有代表性的就是粒子群算法和遗传算法的混合^[12]。主要途径还是将被选个体按一定的比例去划分, 然后分别用 GA 和 PSO 算法去优化, 并比较二者的优化结果, 得出最优的个体。此类思路的提出具有十分重要的意义, 为算法的改进提供了一种有益的选择和参考。但是由于通常的 GA 算法的寻优效率较 PSO 算法低, 上述思路有一定的局限性。

本文在上述思路的启发下, 考虑到 PSO 算法模型自身的简洁和高效的优点。采取的改进思路是以现有的 PSO 算法为主体, 并将遗传算法中的遗传操作思想融入到对 LDW-PSO 算法模型的修正中以构建新的算法模型。而遗传算法的核心思想就在于选择, 交叉, 变异等 3 个遗传操作(算子)。有鉴于此, 本文在 LDW-PSO 算法模型的基础上, 融合了遗传算法中算法操作的核心思想, 提出了 Quasi-PSO 算法模型。具体而言, 就是首先对被选的粒子按照一定的原则分组, 以实现粒子的“选择性”。然后, 对 PSO 算法中的学习因子权重重新构造, 生成新算法的子模型 1。在学习因子的构造中, 主要是将其中随机变量 rand 变成了动态学习因子函数 c_1, c_2 的自变量, 且二者的函数取为非一致性, 以达到“变异”的目的; 再在子模型 1 的基础上交叉动态学习因子生成新算法的子模型 2。这样, Quasi-PSO 算法模型由两个对偶的子模型构成。其数学模型可表达如下:

子模型 1

$$\mathbf{v}_{id}^{k+1} = \omega \mathbf{v}_{id}^k + (c_1(\text{rand}))^k (\text{pbest}_{id}^k - \mathbf{x}_{id}^k) + (c_2(\text{rand}))^k (\text{gbest}_d^k - \mathbf{x}_{id}^k) \quad (3)$$

$$\mathbf{x}_{id}^{k+1} = \mathbf{x}_{id}^k + \mathbf{v}_{id}^{k+1} \quad (4)$$

子模型 2

$$(\mathbf{v}_{id}^{k+1})^* = \omega \mathbf{v}_{id}^k + (c_2(\text{rand}))^k (\text{pbest}_{id}^k - \mathbf{x}_{id}^k) + (c_1(\text{rand}))^k (\text{gbest}_d^k - \mathbf{x}_{id}^k) \quad (5)$$

$$\mathbf{x}_{id}^{k+1} = \mathbf{x}_{id}^k + (\mathbf{v}_{id}^{k+1})^* \quad (6)$$

由上述迭代模型可以看出, 新的 PSO 算法对学习因子作了重新构造, 将学习因子构造为随机量的函数。且两个学习因子的函数表达采用非一致性函数关系。至此, 构造合适的学习因子函数就成了问题的关键。在函数特性上, 考虑到幂函数在自变量位于 $[0, 1]$ 时表现出幂次越大, 函数值越小的特性; 并在借鉴 LDW-PSO 中学习因子取值经验的基础上, 在实际使用中采用如式(5)所示的函数关系表达就可以取得好的效果。

$$c_1(\text{rand}) = 1.49\text{rand}, \quad c_2(\text{rand}) = 1.49\text{rand}^2 \quad (7)$$

进一步, 为使算法具有较高的鲁棒性, 本文在仿真测试的基础上, 将 rand 的值域限定于区间[0.8, 1]。

算法的流程如图 1 所示。

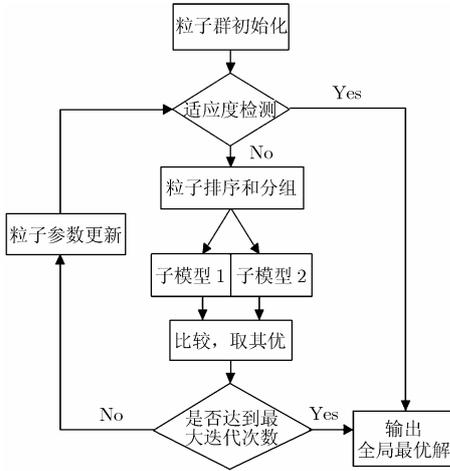


图 1 QUASI-PSO 算法流程图

(1)对粒子和相关量做初始化。这一步与通常的 PSO 算法相同。

(2)对粒子排序并分组。分组时采取最优适应度分组原则。就是在分组时, 选出经前一次迭代后适应度最优的粒子, 并将其作为分组的边界。

(3)在采用非一致性学习因子的基础上, 生成新的子迭代模型。再对上述学习因子作对偶交叉, 形成包含 2 个子模型的双迭代模型。再分别对(2)中的分组粒子使用这 2 个子迭代模型作迭代优化。

(4)迭代完成后, 再对上述两个分组的最优粒子的适应度作比较, 二者取其优。

(5)判断适应度和迭代次数, 如果均未达到要求和预设置的值, 则进行新一轮的迭代。

(6)重复上述操作, 直至结束。

通过与常见的 PSO 算法模型比较, 新的算法做出的改进主要有两点:

(1)对粒子所作的非对称性分组。分组是按照适应度最优原则。采用这样的分组方式, 可避免通常对称分组目的性不强, 麻木的弱点。使得分组的个体数体现出一定的随机性和对适应度标准下的同分布性。这一步很关键, 以确保后面的双迭代模型能够有的放矢。

(2)在迭代模式上, 算法引入了改进的 GA 算法常见的非一致和交叉的概念。首先对原迭代模型中学习因子作非一致性操作, 从而有效改善了粒子的寻优轨迹。同时在此基础上, 通过模型自身的交叉变异, 形成双对称的算法模型, 避免了使用单一模型上的寻优效率不够理想的问题。新的算法保持了原有算法简洁易操作的特点, 没有采用常规的陷入局部最优后的扰动策略, 因为这种策略本身没有提升粒子的寻

优能力; 而是从激发粒子活性的角度, 采用两个迭代模式来驱动粒子, 使其有更优的寻优轨迹。并且由于引入了对偶的双交叉的思想, 使得粒子在活性被释放的同时, 更能有效地趋于收敛。

3.2 基于适应度进化曲线的算法性能分析

为直观和形象地比较和分析改进的新算法模型在算法性能上的优势, 本文给出了如图 2 所示的适应度进化曲线。图中曲线针对例 2 中多目标优化问题, 并选取 100 个粒子的情形下得到的。其中实线所示为本文提出的 Quasi-PSO 算法对应的适应度进化曲线, 而虚线为 LDW-PSO 对应的适应度进化曲线。从图 2 中可以看出, 新的算法在 60 代左右就已经接近最优解, 而原有的算法在迭代 100 次后仍未收敛于最优解。很明显, 新的算法无论在收敛效果和收敛速度都较原算法有显著提高。

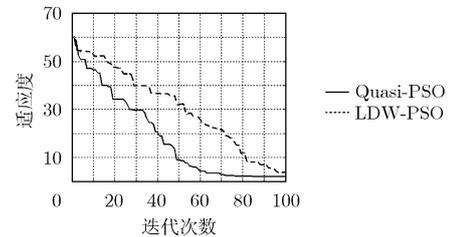


图 2 两种算法的适应度进化曲线比较

4 仿真实例

4.1 阵列天线方向图综合

通常, 考虑由 N 个阵元的直线阵列, 其阵因子为

$$A_F(\theta) = \sum_{i=1}^N w_i \exp\left(j \frac{2\pi}{\lambda} x_i \sin \theta\right) \quad (8)$$

其中 w_i 是阵元激励, 通常为复数; x_i 是天线阵元相对于原点的位置; λ 是波长。不考虑阵元间耦合。

目标函数选取的函数表达与文献[10]中一致, 定义如下:

$$f = \alpha |\text{MSLL} - \text{SLVL}| + \beta |\text{NULL_PAT} - \text{NLVL}| + \gamma \text{NULL_STD} \quad (9)$$

其中 MSLL 是最高旁瓣电平, SLVL 是参考旁瓣电平, NULL_PAT 是平均零陷深度, NLVL 是参考零陷深度。 α, β, γ 可根据具体情形来灵活地设定, 特殊情形下, 可直接设其中一个或两个为零, 这主要用于单目标优化的情形下, 如例 1。在多目标优化中一般可设定为 $\alpha = 0.8, \beta = 0.2, \gamma = 0.5$, 如例 2 和例 3。

4.2 实例

例 1 一个等间距的 16 元线性阵列, 设天线阵工作频率为 1.308GHz, 单元间距为 0.45λ , 采用本文提出的 Quasi-PSO 算法进行优化, 得到的方向图如图 3 所示。

在文献[13]中作者采用的是遗传算法, 得到的最高旁瓣电平大约在 -30dB , 而本文得到的最高旁瓣电平大约在

-33.5dB。可以看出, 相比遗传算法的优化结果, 本算法取得的结果更优。表 1 为优化后的激励电流幅值。

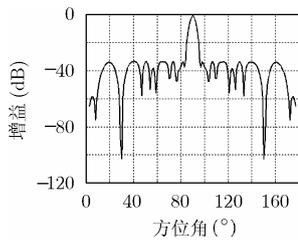


图 3 16 元线阵天线方向图

例 2 由 $N=11$ 个天线阵元形成均匀直线阵, 阵元间距为 $\lambda/2$, 激励电流的相位均为 0(边射阵), 电流幅值对称, 对电流幅值进行优化。

设计指标为, 旁瓣电平在 -15dB 以下, 在 40° 到 60° 的范围内形成 5 个连续的 -100dB 的零陷。

仿真结果如图 4 所示, 由图可以看出, 经过优化后, 方向图达到了预定的目标。零陷均达到 100dB, 最高旁瓣电平为 -19.17dB。激励电流幅值见表 2。

例 3 在文献[8]中, 作者采用 LDW-PSO 算法, 分别在 28 个阵元和 32 个阵元的情况下, 在特定的主瓣内, 在旁瓣抑制和零陷生成上取得了好的结果。而在采用本文的

Quasi-PSO 算法后, 在 17 个阵元的情况下, 就同时实现了上述两种情况下的要求, 具体数据见表 3。

从图 5 可以看出, 方向图在零陷生成和旁瓣抑制上均取得了好的效果。激励电流幅值见表 4。

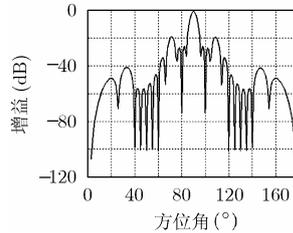


图 4 11 元线阵天线方向图

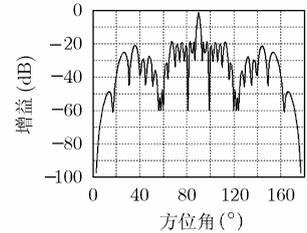


图 5 17 元线阵天线方向图

一般来说, 在使用 Quasi-PSO 算法的过程中, 粒子数量和迭代次数的选择应根据所要达到的优化目标的需要来决定。如针对例 1 中优化目标相对简单的问题, 通常使用 40 个粒子, 迭代 40 次左右就可以得到比较好的结果; 而对于复杂优化目标的问题, 如例 2 和例 3, 通常选取 60-100 个粒子, 一般迭代 80 次左右就可以得到比较好的结果。

表 1 例 1 中 16 元阵列的优化后电流幅值表(10mA)

阵元号	1	2	3	4	5	6	7	8
优化后幅值	0.1542	0	0.2752	0	0.5351	0	0.6611	0.3592
阵元号	9	10	11	12	13	14	15	16
优化后幅值	0.9013	0.5002	1.0000	0.6744	1.0000	1.0000	1.0000	1.0000

表 2 例 2 中 11 元阵列的优化后电流幅值表(10mA)

阵元号	1	2	3	4	5	6
优化后幅值	0.1567	0.3089	0.4614	0.4295	0.4116	0.4680
阵元号	7	8	9	10	11	
优化后幅值	0.6265	0.8069	0.8385	0.7992	0.7155	

表 3 优化后目标参量的指标比较(与 LDW-PSO 算法)

算法	阵元数	主瓣宽度	最高旁瓣电平	零陷生成
LPSO	28	86° 到 94°	-13dB	55° 到 60° 与 120° 到 125° 分别生成 3 个连续的-60dB 零陷, 共 6 个零陷(间隔为 2.5°)
	32	87° 到 93°	-19dB	在 81° 和 99° 共生成 2 个-60dB 零陷
QPSO	17	87° 到 93°	-19dB	56° 到 60° 与 120° 到 124° 分别生成 3 个连续的-60dB 零陷(间隔为 2°), 同时在 81° 和 99° 共生成 2 个-60dB 零陷, 共 8 个零陷

表 4 例 3 中 17 元阵列的优化后电流幅值表(10mA)

阵元号	1	2	3	4	5	6	7	8	9
优化后幅值	0.3219	1.0000	0.5654	1.0000	0.1765	0.4189	0.8448	0.6090	1.0000

阵元号	10	11	12	13	14	15	16	17
优化后幅值	0.4172	0.9469	0.6928	1.0000	0.8472	0.7242	1.0000	1.0000

5 结束语

本文在总结现有 PSO 粒子群算法的基础上, 针对现有 PSO 算法在非线性和多峰值问题中寻优效果不够理想的问题, 提出了一种新的准 PSO 算法。新的 PSO 算法融合了改进 GA 算法中的非一致性和交叉操作的思想, 使得算法在寻优效率上有了本质上的提高。特别是在阵列天线方向图综合这类多目标优化问题中优势更为明显。通过仿真表明, 本文在相同或更为苛刻的情形下, 取得了比现有文献更为优越的解。新的算法在相关的阵列天线方向图综合中将具有广阔的前景。

参 考 文 献

- [1] 王小平, 曹立明. 遗传算法——理论, 应用与软件实现[M]. 西安: 西安交通大学出版社, 2002: 1-38.
- [2] Kennedy J and Eberhart R C. Particle swarm optimization. Proc. IEEE International Conference on Neural Networks, IEEE Service Center, 1995, IV: 1942-1948.
- [3] Shi Y and Eberhart R C. A modified particle swarm optimizer [C]. Proceeding of the IEEE Congress on Evolutionary Computation (CEC 1998), Piscataway, N J, 1998: 69-73.
- [4] Eberhart R C and Shi Y. Comparing inertia weights and constriction factors in particle swarm optimization. Proceedings of the 2000 Congress on Evolutionary Computation, La Jolla, CA, Vol 1, 2000: 84-88.
- [5] Eberhart R C and Shi Y. Fuzzy adaptive particle swarm optimization. Proceedings of the Congress on Evolutionary Computation, Seoul, Volume 1, 2001: 101-106.
- [6] Huang T and Mohan A S. A hybrid boundary condition for robust particle swarm optimization[J]. *Antennas and Wireless Propagation Letters*, 4, 2005, 4: 112-117.
- [7] Ciuprina G, Ioan D, and Munteanu I, Use of intelligent-particle swarm optimization in electromagnetics. [J]. *IEEE Trans. on Magnetics*, 2004, 38(2): 1037-1040.
- [8] Khodier M M and Christodoulou C G. Linear array geometry synthesis with minimum sidelobe level and null control using particle swarm optimization [J]. *IEEE Trans. on Antennas and Propagation*, 2005, 53(8): 2674-2679.
- [9] Park J, Choi K, and Allstot D J. Parasitic-aware RF circuit design and optimization [J]. *IEEE Trans. on Circuits Syst.-I*, 2004, 51(10): 1953-1966.
- [10] 范瑜, 金荣洪. 基于一种新的遗传算法的天线方向图综合技术[J]. *电波科学学报*, 2004, 19(2): 182-186.
- [11] Eberhart R C and Kennedy J. A new optimizer using particle swarm theory [C]. Proceeding of Sixth International Symposium on Micro Machine and Human Science, Nagoya, Japan, 1995: 39-43.
- [12] 刘自发, 葛少云, 余贻鑫. 一种混合智能算法在配电网网络重构中的应用[J]. *中国电机工程学报*, 2005, 25(15): 73-78.
- [13] 董涛, 徐晓文. 遗传算法在低副瓣天线阵综合中的应用[J]. *北京理工大学学报*, 2001, 21(6): 770-773.

高 波: 男, 1982 年生, 硕士, 从事智能进化算法、天线分析与设计及无线通信技术等方面的研究工作。

金荣洪: 男, 1963 年生, 博士, 教授, 博士生导师, 主要从事现代通信天线理论和设计、数字波束形成技术、多波束天线、数值分析技术等领域的教学和研究工作。

耿军平: 男, 1972 年生, 博士, 讲师, 主要从事智能天线与电磁兼容等方面的研究工作。