

计算智能

现代科学技术发展的一个显著特点就是信息科学与生命科学的相互交叉、相互渗透和相互促进,生物信息学就是两者结合而形成的新的交叉学科。计算智能则是另一个有说服力的示例。计算智能涉及神经计算、模糊计算、进化计算、粒群计算、蚁群算法、自然计算、免疫计算和人工生命等领域,它的研究和发展正反映了当代科学技术多学科交叉与集成的重要发展趋势。

创造、发明和发现是千千万万科技开拓者的共同品性和永恒追求。包括牛顿、爱因斯坦、图灵和维纳等科学巨匠在内的科学家们,都致力于寻求与发现创造的技术和秩序。人类的所有发明,几乎都有它们的自然界配对物。原子能的和平利用和军事应用与出现在星球上的热核爆炸相对应;各种电子脉冲系统则与人类神经系统的脉冲调制相似;蝙蝠的声呐和海豚的发声起到一种神秘电话的作用,启发人类发明了声呐传感器和雷达;鸟类的飞行行为激发了人类飞天的梦想,因此发明了飞机和飞船,实现了空中和宇宙飞行。科学家和工程师们应用数学和科学来模仿自然、扩展自然。人类智能已激励出高级计算、学习方法和技术。毫无疑问,智能是可达的,其证据就在我们眼前,就发生在我们的日常工作和生活中。

3.1 粒子群优化算法

自然界中很多生物以社会群居的形式生活在一起,如鸟群、鱼群、蚁群、人群等。群体智能系统研究的热点之一是探索这些生物如何以群体的形式存在。受对群体运动行为模拟的启发,研究人员提出了大量的群体智能系统,其中以粒子群优化算法(particle swarm optimization, PSO)和蚁群优化算法(ant colony optimization, ACO)最具代表性。本节和 3.2 节分别讨论群体智能(swarm intelligence)行为及其优化计算方法,包括粒子群优化算法和蚁群算法。本节先讨论粒子群优化算法。

3.1.1 群体智能和粒子群优化概述

1. 群体智能概念

自 20 世纪 70 年代开始,科学家对这些群体行为展开了研究,许多人通过计算机来模拟

群体的运动行为。其中,最具代表性的当属 C. W. Reynolds 和 F. Heppner 对鸟群运动行为的模拟。C. W. Reynolds 将鸟群的飞行视为一种舞蹈,并且从美学的角度出发进行了模拟。动物学家 F. Heppner 更关注鸟群运动的潜在准则,例如,为什么鸟群可以同步飞行、可以突然变向、规模较小的鸟群可以聚集成规模较大的鸟群、规模较大的鸟群可以分裂为若干规模较小的鸟群等。社会生物学家 E. O. Wilson 还对鱼群的运动行为进行了模拟,并提出了以下猜想:同类生物之间的信息共享常常提供了一种进化的优势。他的这一猜想后来成为研究各种群体智能系统的基础。此外,还有研究人员对人类的运动行为进行模拟。鸟群和鱼群通过调整自身的运动来避免碰撞、寻找食物和同伴、适应周围的环境(如温度)等。

假定你和你的朋友正在执行寻宝的任务,这个团队内的每个人都有一个金属探测器并能把自己的通信信号和当前位置传给 n 个最邻近的伙伴。因此,每人都知道是否有一个邻近伙伴比他更接近宝藏。如果这样,你就可以向该邻近伙伴移动。这样做的结果就使得你发现宝藏的机会得以改善,而且,找到该宝藏也可能要比你单人寻找快得多。

这是一个群体行为(swarm behavior)的极其简单的实例,其中,群中个体交互作用使用比单一个体更有效的方法求解全局目标。

可把群体(swarm)定义为某种交互作用的组织或真体之结构集合。在群体智能计算研究中,群体的个体组织包括蚂蚁、白蚁、蜜蜂、黄蜂、鱼群和鸟群等。在这些群体中,个体在结构上是很简单的,而它们的集体行为却可能变得相当复杂。例如,在一个蚁群中,每只蚂蚁个体只能执行一组很简单任务中的一项,而在整体上,蚂蚁的动作和行为却能够确保建造最佳的蚁巢结构、保护蚁后和幼蚁、清静蚁巢、发现最好的食物源及优化攻击策略等全局任务的实现。

社会组织的全局群体行为是由群体内个体行为以非线性方式出现的。于是,在个体行为和全局群体行为之间存在某种紧密的联系。这些个体的集体行为构成和支配了群体行为。另外,群体行为又决定了个体执行其作用的条件。这些作用可能改变环境,因而也可能改变这些个体自身的行为及其地位。由群体行为决定的条件包括空间和时间两种模式。

群体社会网络结构形成该群存在的一个集合,它提供了个体间交换经验知识的通信通道。群体社会网络结构的一个惊人的结果是它们在建立最佳蚁巢结构、分配劳力和收集食物等方面的组织能力。

2. 粒子群优化概念

粒子群优化(particle swarm optimization, PSO)算法是一种基于群体搜索的算法,它建立在模拟鸟群社会的基础上。粒子群概念的最初含义是通过图形来模拟鸟群优美和不可预测的舞蹈动作,发现鸟群支配同步飞行和以最佳队形突然改变飞行方向并重新编队的能力。这个概念已包含在一个简单和有效的优化算法中。

在粒子群优化中,被称为粒子(particles)的个体是通过超维搜索空间“流动”的。粒子在搜索空间中的位置变化是以个体成功地超过其他个体的社会心理意向为基础的。因此,群中粒子的变化是受其邻近粒子(个体)的经验或知识影响的。粒子的搜索行为受到群中其他粒子的搜索行为的影响。由此可见,粒子群优化是一种共生合作算法。建立这种社会行为模型的结果是:在搜索过程中,粒子随机地回到搜索空间中一个原先成功的区域。

3.1.2 粒子群优化算法

粒子群优化是以邻域原理(neighborhood principle)为基础进行操作的,该原理来源于社会网络结构研究。驱动粒子群优化的特性是社会交互作用。群中的个体(粒子)相互学习,而且基于获得的知识移动到更相似于它们的、较好的邻近区域。邻域内的个体进行相互通信。

群是由粒子的集合组成的,而每个粒子代表一个潜在的解答。粒子在超空间流动,每个粒子的位置按照其经验和邻近粒子的位置而变化。令 $\mathbf{x}_i(t)$ 表示 t 时刻 P_i 在超空间的位置。把速度矢量 $\mathbf{v}_i(t)$ 加至当前位置,则位置 P_i 变为

$$\mathbf{x}_i(t) = \mathbf{x}_i(t-1) + \mathbf{v}_i(t)$$

速度矢量推动优化过程,并反映出社会所交换的信息。下面给出了 3 种不同的粒子群优化算法,它们对社会信息的交换扩展程度是不同的。这些算法概括了初始的 PSO 算法。

1. 个体最佳算法

对于个体最佳(individual best)算法,每个个体只把它的当前位置与自己的最佳位置 pbest 相比较,而不使用其他粒子的信息。具体算法如下:

(1) 对粒子群 $P(t)$ 初始化,使得 $t=0$ 时每个粒子 $P_i \in P(t)$ 在超空间中的位置 $\mathbf{x}_i(t)$ 是随机的。

(2) 通过每个粒子的当前位置评价其性能 $\mathcal{F}$ 。

(3) 比较每个个体的当前性能与它至今有过的最佳性能,如果

$\mathcal{F}(\mathbf{x}_i(t)) < \text{pbest}_i$, 那么

$$\begin{cases} \text{pbest}_i = \mathcal{F}(\mathbf{x}_i(t)) \\ \mathbf{x}_{\text{pbest}_i} = \mathbf{x}_i(t) \end{cases}$$

(4) 改变每个粒子的速度矢量

$$\mathbf{v}_i(t) = \mathbf{v}_i(t-1) + \rho(\mathbf{x}_{\text{pbest}_i} - \mathbf{x}_i(t))$$

其中, ρ 为一位置随机数。

(5) 每个粒子移至新位置

$$\begin{cases} \mathbf{x}_i(t) = \mathbf{x}_i(t-1) + \mathbf{v}_i(t) \\ t = t + 1 \end{cases}$$

其中, $\mathbf{v}_i(t) = \mathbf{v}_i(t) \Delta t$, 而 $\Delta t = 1$, 所以 $\mathbf{v}_i(t) \Delta t = \mathbf{v}_i(t)$ 。

(6) 转回步骤(2),重复递归直至收敛。

上述算法中粒子离开其先前发现的最佳解答越远,该粒子(个体)移回它的最优解答所需要的速度就越大。随机值 ρ 的上限为用户规定的系统参数。 ρ 的上限越大,粒子轨迹振荡就越大。较小的 ρ 值能够保证粒子的平滑轨迹。

2. 全局最佳算法

对于全局最佳(global best)算法,粒子群的全局优化方案 gbest 反映出一种被称为星形(star)的邻域拓扑结构。在该结构中,每个粒子能与其他粒子(个体)进行通信,形成一个全连接的社会网络,如图 3.1(a)所示。用于驱动各粒子移动的社会知识包括全群中选出的最佳粒子位置。此外,每个粒子还根据先前已发现的最好的解答来运用它的历史

经验。

全局最佳算法如下：

(1) 对粒子群 $P(t)$ 初始化,使得 $t=0$ 时每个粒子 $P_i \in P(t)$ 在超空间中的位置 $\mathbf{x}_i(t)$ 是随机的。

(2) 通过每个粒子的当前位置 $\mathbf{x}_i(t)$ 评价其性能 $\mathcal{F}$ 。

(3) 比较每个个体的当前性能与它至今有过的最好性能,如果 $\mathcal{F}(\mathbf{x}_i(t)) < \text{pbest}_i$, 那么

$$\begin{cases} \text{pbest}_i = \mathcal{F}(\mathbf{x}_i(t)) \\ \mathbf{x}_{\text{pbest}_i} = \mathbf{x}_i(t) \end{cases}$$

(4) 把每个粒子的性能与全局最佳粒子的性能进行比较,如果 $\mathcal{F}(\mathbf{x}_i(t)) < \text{gbest}_i$, 那么

$$\begin{cases} \text{gbest} = \mathcal{F}(\mathbf{x}_i(t)) \\ \mathbf{x}_{\text{gbest}_i} = \mathbf{x}_i(t) \end{cases}$$

(5) 改变粒子的速度矢量

$$\mathbf{v}_i(t) = \mathbf{v}_i(t-1) + \rho_1(\mathbf{x}_{\text{pbest}_i} - \mathbf{x}_i(t)) + \rho_2(\mathbf{x}_{\text{gbest}} - \mathbf{x}_i(t))$$

其中, ρ_1 和 ρ_2 为随机变量; 上式中的第 2 项称为认知分量; 最后一项称为社会分量。

(6) 把每个粒子移至新的位置

$$\begin{cases} \mathbf{x}_i(t) = \mathbf{x}_i(t-1) + \mathbf{v}_i(t) \\ t = t + 1 \end{cases}$$

(7) 转向步骤(2),重复递归直至收敛。

对于全局最佳算法,粒子离开全局最佳位置 and 它自己的最佳解答越远,该粒子回到它的最佳解答所需的速度变化也越大。随机值 ρ_1 和 ρ_2 确定为 $\rho_1 = r_1 c_1$, $\rho_2 = r_2 c_2$, 其中 r_1 , $r_2 \sim U(0,1)$, 而 c_1 和 c_2 为正加速度常数。

3. 局部最佳算法

局部最佳(local best)算法用粒子群优化的最佳方案 lbest 反映一种称为环形(ring)的邻域拓扑结构。该结构中每个粒子与它的 n 个中间邻近粒子通信。如果 $n=2$, 那么一个粒子与它的中间相邻粒子的通信如图 3.1(b)所示。粒子受它们邻域的最佳位置和自己过去经验的影响。




图 3.1 粒子群优化的邻域拓扑结构

本算法与全局算法不同之处仅在步骤(4)和步骤(5)中,以 lbest 取代 gbest。在收敛方面,局部最佳算法要比全局最佳算法慢得多,但局部最佳算法能够求得更好的解答。

以上各种算法的步骤(2)检测各粒子的性能。其中,采用一个函数来测量相应解答与最佳解答的接近度。在进化计算中,称这种接近度为适应度函数。

上述各算法继续运行直至其达到收敛为止。通常对一个固定的迭代数或适应度函数估计执行粒子群优化算法。此外,如果所有粒子的速度变化接近 0,那么就中止粒子群优化算法。这时,粒子位置将不再变化。标准的粒子群优化算法受 6 个参数影响,分别为问题维数、个体(粒子)数、 ρ 的上限、最大速度上限、邻域规模和惯量。

除了上面讨论过的几种算法,即 pbest, gbest, lbest 外,近年来的研究使这些原来的算法得以改进,其中包括改善其收敛性和提高其适应性。

粒子群优化已用于求解非线性函数的极大值和极小值,也成功地应用于神经网络训练。这时,每个粒子表示一个权矢量,代表一个神经网络。粒子群优化也成功地应用于人体颤抖分析,以便诊断帕金森(Parkinson)疾病。

总而言之,粒子群优化算法已显示出它的有效性和鲁棒性,并具有算法的简单性。不过,需要开展更进一步的研究,以便充分利用这种优化算法的益处。

3.2 蚁群算法

蚂蚁是一种众所周知的群居性小昆虫,单只蚂蚁很难完成复杂的任务,但是蚁群却拥有巨大的能量。人们知道它能够预报暴雨和洪涝气象,也听说它能够毁坏河堤和水坝,引起水患。这个个体甚微的小生灵,作为群体表现出十分独特的生物特征和生命行为。1992 年,意大利学者多里戈(M. Dorigo)在他的博士论文中提出了蚁群算法。1999 年,多里戈和迪卡罗(G. Di Caro)给出了蚁群算法的一个通用框架,对蚁群算法的发展具有重要意义。同年,马尼佐(V. Maniezzo)和科洛龙(A. Colomi)从生物进化和仿生学角度出发,研究蚂蚁寻找路径的自然行为,并用该方法求解 TSP 问题、二次分配问题和作业调度问题等,取得较好结果。蚁群算法已显示出它在求解复杂优化问题特别是离散优化问题方面的优势,是一种很有发展前景的计算智能方法。

3.2.1 蚁群算法理论

1. 蚁群算法基本原理

蚁群算法(又称为人工蚁群算法)是受到对真实蚁群行为研究的启发而提出的。为了说明人工蚁群系统的原理,先从蚁群搜索食物的过程谈起。像蚂蚁、蜜蜂等群居昆虫,虽然单个昆虫的行为极其简单,但由单个简单的个体所组成的群体却表现出极其复杂的行为。仿生学家经过大量细致观察研究后发现,蚂蚁个体之间是通过一种称为外激素(pheromone)的物质进行信息传递的。蚂蚁在运动过程中能够在它所经过的路径上留下该种物质,并在运动过程中感知这种物质,以此指导自己的运动方向。因此,由大量蚂蚁组成的蚁群的集体行为便表现出一种信息正反馈现象:某一路径上走过的蚂蚁越多,则后来者选择该路径的概率就越大。蚂蚁个体之间就是通过这种信息的交流达到搜索食物的目的。

下面用多里戈所举的例子来说明蚁群系统的原理。如图 3.2 所示。设 A 是蚂蚁的巢穴, E 是食物源, HC 为一障碍物。由于存在障碍物, 蚂蚁只能绕经 H 或 C 由 A 到达 E , 或由 E 到达 A 。各点之间的距离见图 3.2。设每个时间单位有 30 只蚂蚁由 A 到达 B , 又有 30 只蚂蚁由 E 到达 D , 蚂蚁过后留下的外激素为 1。为便于讨论, 设外激素停留的时间为 1。在初始时刻, 由于路径 BH 、 BC 、 DH 、 DC 上均无信息存在, 位于 B 和 D 的蚂蚁可以随机选择路径。从统计的角度可以认为它们以相同的概率选择 BH 、 BC 、 DH 、 DC 。经过一个时间单位后, 在路径 BCD 上的信息量是路径 BHD 上的信息量的两倍。在 $t=1$ 时刻, 将有 20 只蚂蚁由 B 和 D 到达 C , 有 10 只蚂蚁由 B 和 D 到达 H 。随着时间的推移, 蚂蚁将会以越来越大的概率选择路径 BCD , 最终完全选择路径 BCD , 从而找到由蚁巢到食物源的最短路径。由此可见, 蚂蚁个体之间的信息交换是一个正反馈过程。




图 3.2 蚁群系统示意图

2. 蚁群系统模型

以求解 n 个城市 TPS 的问题为例来说明蚁群系统模型。为了模拟实际蚂蚁的行为, 令 m 表示蚁群中蚂蚁的数量, $d_{ij}(i, j=1, 2, \dots, n)$ 表示城市 i 和城市 j 之间的距离, $b_i(t)$ 表示 t 时刻位于城市 i 的蚂蚁个数, $m = \sum_{i=1}^n b_i(t)$, $\tau_{ij}(t)$ 表示 t 时刻在 ij 连线上残留的信息量。在初始时刻, 各条路径上信息量相等, 设 $\tau_{ij}(0) = C$ (C 为常数)。蚂蚁 k ($k=1, 2, \dots, m$) 在运动过程中, 根据各条路径上的信息量决定转移方向。 $p_{ij}^k(t)$ 表示在 t 时刻蚂蚁由位置 i 转移到位置 j 的概率:

$$p_{ij}^k = \begin{cases} \frac{\tau_{ij}^\alpha \eta_{ij}^\beta(t)}{\sum_{s \in \text{allowed}_k} \tau_{is}^\alpha \eta_{is}^\beta(t)}, & j \in \text{allowed}_k \\ 0, & \text{其他} \end{cases}$$

其中, $\text{allowed}_k = \{0, 1, \dots, n-1\}$ 表示蚂蚁 k 下一步允许选择的城市; α, β 分别表示蚂蚁在运动过程中所积累的信息及启发式因子在蚂蚁路径选择中所起的不同作用; η_{ij} 表示由城市 i 转移到城市 j 的期望程度, 可根据某种启发式算法具体确定。与真实蚁群系统不同, 人工蚁群系统具有一定的记忆功能, 这里用 tabu_k ($k=1, 2, \dots, m$) 记录蚂蚁 k 目前已经走过的城市。随着时间的推移, 以前留下的信息逐渐消逝, 用参数 $(1-p)$ 表示信息消逝程度, 经过 n 个时刻, 蚂蚁完成一次循环。各路径上信息量要根据下式作调整:

$$\tau_{ij}(t+n) = \rho \cdot \tau_{ij}(t) + \Delta\tau_{ij}$$

$$\Delta\tau_{ij} = \sum_{k=1}^m \Delta\tau_{ij}^k$$

其中, $\Delta\tau_{ij}^k$ 表示第 k 只蚂蚁在本次循环中留在路径 ij 上的信息量, $\Delta\tau_{ij}$ 表示本次循环中留在路径 ij 上的信息量:

$$\Delta\tau_{ij}^k = \begin{cases} \frac{Q}{L_k}, & \text{若第 } k \text{ 只蚂蚁在本次循环中经过 } ij \\ 0, & \text{其他} \end{cases}$$

其中, Q 是常数, L_k 表示第 k 只蚂蚁在本次循环中所走过的路径长度。在初始时刻, $\tau_{ij}(0) = C(\text{const})$, $\Delta\tau_{ij} = 0$, 其中, $i, j = 0, 1, \dots, n-1$ 。根据具体算法的不同, τ_{ij} , $\Delta\tau_{ij}$ 及 $p_{ij}^k(t)$ 的表达形式可以不同, 要根据具体问题而定。多里戈曾给出三种不同模型, 分别称为 ant-cycle system, ant-quantity system, ant-density system。参数 $Q, C, \alpha, \beta, \rho$ 可以用实验方法确定其最优组合。停止条件可以用固定循环次数或当进化趋势不明显时便停止计算。

上述蚁群系统模型是一个递归过程, 易于在计算机上实现。其实现过程可用伪代码表示如下。

```

begin
  初始化过程:
  ncycle:=0;
  bestcycle:=0;
   $\tau_{ij} := C$ ;
   $\Delta\tau_{ij} = 0$ ;
   $\eta_{ij}$  由某种启发式算法确定;
   $\text{tabu}_k = \emptyset$ ;
  while(not termination condition)
  {ncycle:=ncycle+1;
  for (index = 0; index < n; index++) 这里, index 表示当前已经走过的城市个数
  {for( $k = 0$ ;  $k < m$ ;  $k++$ )
  {以概率  $p_{[\text{tabu}_k][\text{index-1}][j]}^k$  选择城市  $j$ ;
   $j \in \{0, 1, \dots, n-1\} - \text{tabu}_k$ ;
  }
  将刚刚选择的城市  $j$  加到  $\text{tabu}_k$  中
  }
  计算  $\Delta\tau_{ij}^k(\text{index}), \tau_{ij}(\text{index}+n)$ 
  确定本次循环中找到的最佳路径
  }
  输出最佳路径及最佳结果
end

```

由算法复杂度分析理论可知, 该算法复杂度为 $O(nc, n^3)$, 其中 nc 表示循环次数。以上是针对求解 TSP 问题说明蚁群问题的, 对该模型稍作修正, 便可以应用于其他问题。

实验和比较结果表明, 在 ant-cycle system, ant-quantity system 和 ant-density system 三种算法中, ant-cycle system 算法的效果最好。这是因为它能够使用全局信息, 并能保证残留信息不被无限累积, 使算法忘记不好的路径。图 3.3 给出了 ant-cycle system 算法框图。




图 3.3 ant-cycle system 算法框图

3.2.2 蚁群算法的研究与应用

1. 蚁群算法的研究

自 1991 年多里戈等提出蚁群算法以来,吸引了许多研究人员对该算法进行研究,并成功地运用于解决组合优化问题,如 TSP、QAP(quadratic assignment problem)、JSP(job-shop scheduling problem)等。对于许多组合优化问题,只要:①能够用一个图来阐述将要解决的问题;②能定义一种正反馈过程,如问题中的残留信息;③问题结构本身能提供解题用的启发式信息如 TSP 问题中城市的距离;④能够建立约束机制(如 TSP 问题中已访问城市的列表),那么就能够用蚁群算法加以解决。自从包含蚁群算法在内的蚁群优化(ant colony optimization, ACO)出现之后,许多相关算法的框架被提出。1998 年召开了关于蚁群优化的第一届学术会议(ANTS'98),更引起了研究者的广泛关注。

蚁群系统(ant system, AS)是随蚁群概念最早提出来的算法,它首先被成功地运用于 TSP 问题。虽然与一些比较完善的算法(如遗传算法等)相比,基本蚁群算法计算量比较大,效果也并不一定更好,但是它的成功运用范例还是激起人们对蚁群算法的极大兴趣,并吸引了一批研究人员从事蚁群算法的研究。蚁系统的优点在于:正反馈能迅速找到好的解决方法,分布式计算可以避免过早地收敛,强启发能在早期的寻优中迅速找到合适的解决方案。蚁群算法已被成功地应用于许多能被表达为在图表上寻找最佳路径的问题。

蚁群系统区别于蚁群算法之处主要在于:在蚁群系统算法中,蚂蚁在寻找最佳路径的过程中只能使用局部信息,即采用局部信息对外激素浓度进行调整;在进行寻优的所有蚂蚁结束路径寻找后,外激素的浓度会再一次调整,这次采用的是全局信息,而且只对过程中

发现的最后路径上的外激素浓度进行加强。有一个状态传递机制,用于指导蚂蚁最初的寻优过程,并能积累问题目前状态。

最大-最小蚁群系统(MAX-MIN ant system, MMAS)是到目前为止解决 TSP、QAP 等问题最好的蚁群优化类算法。和其他寻优算法相比,它属于最好的解决方案之一。MMAS 的特点是:只对最佳路径增加外激素的浓度,从而更好地利用了历史信息(这与 ACS 算法调整方案有点类似)。为了避免算法过早收敛于非全局最优解,把各条路径可能的外激素浓度限制于 $[\tau_{\min}, \tau_{\max}]$,超出这个范围的值被强制设为 $\tau_{\min}$ 或者 $\tau_{\max}$,这样可以有效地避免某条路径上的信息量远大于其余路径,使得所有蚂蚁都集中在一条路径上,从而使算法不再扩散;将各条路径上的外激素的起始浓度设为 $\tau_{\max}$,这样便可以更加充分地进行寻优。

2. 蚁群算法的应用

对蚂蚁行为的研究已导致各种相关算法的开发,并把它们应用于求解各种问题,这些算法建立了蚂蚁搜索行为(如收集食物)的模型,产生了新的组合优化算法,应用于网络路径选择和作业调度等。蚂蚁动态地分配劳动力产生自适应任务分配策略。它们合作搬运的特性产生了机器人式的实现。把蚁群算法进行优化的工作称为蚁群优化(ant colony optimization, ACO),它已在解决组合优化问题中显示出优越性。

蚁群算法和蚁群优化已被成功地应用于二次分配问题(quadratic assignment problem, QAP)、作业调度问题(job-scheduling problem, JSP)、图表着色问题(graph coloring problem, GCP)、最短公超序问题(shortest common supersequence problem, SCSP, 一种 NP 难题)、电话网络和数据通信网络的路由优化及机器人建模和优化等。

蚁群算法源于对自然界中的蚂蚁寻找从蚁巢到食物及从食物回到蚁巢的最短路径方法的研究。它是一种并行算法,所有“蚂蚁”均独立行动,没有监督机构。它又是一种合作算法,依靠群体行为进行寻优;它还是一种鲁棒算法,只要对算法稍作修改,就可以求解其他组合优化问题。

3.3 进化算法与遗传算法

达尔文于 1859 年完成的科学巨著《物种起源》中,提出了自然选择学说,指出物种是在不断演变的,而且这种演变是一种由低级到高级、由简单到复杂的过程。1868 年,达尔文的第 2 部科学巨著《动物和植物在家养下的变异》问世,进一步阐述了他的进化论观点,提出了物种的变异和遗传、生物的生存斗争和自然选择的重要论点。生物种群的生存过程普遍遵循达尔文的物竞天择、适者生存的进化准则。种群中的个体根据对环境的适应能力而被大自然所选择或淘汰。进化过程的结果反映在个体结构上,其染色体包含若干基因,相应的表现型和基因型的联系体现了个体的外部特性与内部机理间的逻辑关系。生物通过个体间的选择、交叉、变异来适应大自然环境。生物染色体用数学方式或计算机方式来体现就是一串数码,仍叫染色体,有时也叫个体;适应能力用对应一个染色体的数值来衡量;染色体的选择或淘汰问题是按求最大还是最小问题来进行的。为求解优化问题,人们试图从自然界中寻找启示。20 世纪 60 年代以来,如何模仿生物来建立功能强大的算法,进而将它们运用于复杂的优化问题,越来越成为一个研究热点。对优化与自然界进化的深入观察和思考导致

了进化算法(evolutionary algorithms,EAs)的诞生,并已发展成为一个重要的研究方向。

进化计算包括遗传算法(genetic algorithms,GA)、进化策略(evolution strategies)、进化编程(evolutionary programming)和遗传编程(genetic programming),本节将讨论进化算法和遗传算法。

3.3.1 进化算法原理

为了求解优化问题,研究人员试图从自然界中寻找答案。优化是自然界进化的核心,每个物种都在随着自然界的进化而不断优化自身结构。

对进化算法的研究可追溯到 20 世纪 50 年代。当时,研究人员已经开始意识到达尔文的进化论可用于求解复杂问题。受达尔文进化论“物竞天择,适者生存”思想的启发,20 世纪 60 年代美国密歇根大学的 J. Holland 提出了遗传算法。K. De Jong 率先将遗传算法应用于函数优化。20 世纪 60 年代中期,L. J. Fogel 等美国学者提出了进化编程(evolutionary programming,EP)。几乎在同一时期,德国学者 I. Rechenberg 和 H. P. Schwefel 开始了进化策略(evolution strategy,ES)的研究。在随后的 15 年里,上述 3 种算法独立地得到了发展。直到 20 世纪 90 年代,GA、EP 和 ES 才逐步走向统一,统称为进化算法。很快,进化算法又增加了一个新的成员——遗传编程(genetic programming,GP),它由美国斯坦福大学的 J. R. Koza 于 20 世纪 90 年代早期创立。GA、EP、ES 和 GP 是进化算法的 4 大经典范例,它们为研究人员求解优化问题提供了崭新的思路。

由于进化算法求解优化问题的巨大潜力,大批研究人员开始参与进化算法的研究,并取得了显著进展。目前,进化算法已经在许多领域得到了非常广泛的应用,并受到生物学、心理学、物理学等众多学科的关注。进化计算领域的第一本国际期刊 *Evolutionary Computation* 于 1993 年问世,由麻省理工学院出版社(MIT Press)出版。美国电气和电子工程师协会(Institute of Electrical and Electronics Engineers,IEEE)于 1996 年创办了国际期刊 *IEEE Transactions on Evolutionary Computation*。进化计算在 IEEE 中起初隶属于神经网络协会。2004 年 2 月,IEEE 神经网络协会正式更名为 IEEE 计算智能协会。此后,进化计算、神经网络、模糊计算作为 3 个主要分支共同隶属于 IEEE 计算智能协会。进化计算领域还举办了许多高水平的国际学术会议,如 IEEE 每年举办的进化计算大会(IEEE Congress on Evolutionary Computation),国际计算机组织(Association for Computing Machinery,ACM)每年举办的遗传和进化计算大会(ACM Genetic and Evolutionary Computation Conference)等。

事实上,随着对自然界的进一步认识和研究的不深入,30 多年来研究人员又提出了大量的进化算法范例。根据我们对文献的搜集发现,现有的进化算法范例已超过 30 种。例如,M. Dorigo 于 1992 年提出了蚁群算法(ant colony optimization);R. G. Robert 于 1994 年提出了文化算法(cultural algorithm);R. Eberhart 和 J. Kennedy 于 1995 年发明了粒子群优化算法(particle swarm optimization);同年,R. Storn 和 K. Price 提出了差异进化算法(differential evolution)。此外,人工免疫系统(artificial immune system)、量子进化算法(quantum-inspired evolutionary algorithm)、和声搜索算法(harmony search)、细菌觅食算法(bacterial foraging optimization)、人工鱼群算法(artificial fish swarm algorithm)、人口迁移算法(population migration algorithm)、文化基因算法(memetic algorithm)、人工蜂群