

量子行为粒子群优化算法在公交调度优化中的应用^①

李欣然¹, 靳雁霞²

¹(中北大学 电子与计算机科学技术学院, 太原 030051)

²(中北大学 仪器科学与动态测试教育部重点实验室, 太原 030051)

摘 要: 以公交费用最小和乘客平均等待时间最短为目标构建优化调度模型, 针对已有算法在求解这类调度问题存在的早熟收敛、优化效率较低的缺点, 提出了一种惯性权重自适应调整的量子行为粒子群优化算法。首先引入聚焦距离变化率的概念, 将惯性权重因子表示为关于聚焦距离变化率的函数, 从而使算法具有动态自适应性; 同时在算法中嵌入了一种判断和避免搜索早熟和停滞的有效方法。优化实例的结果分析表明, 该算法能有效地解决公交车辆的调度优化问题。

关键词: 基于量子行为的粒子群优化算法(QPSO); 惯性权重; 聚焦距离变化率; 变异; 公交车调度

Intelligent Dispatching of Public Transit Vehicles Using Quantum-Behaved Particle Swarm Optimization Algorithm

LI Xin-Ran¹, JIN Yan-Xia²

¹(College of Computer Science and Technology, North University of China, Taiyuan 030051, China)

²(Ministry of Education Key Laboratory of Instrumentation Science and Dynamic Measurement, North University of China, Taiyuan 030051, China)

Abstract: For the premature convergence and low efficiency optimization of the existing public transit vehicle dispatching algorithm, this paper puts forward a quantum particle swarm optimization algorithm with weight adaptive adjustments to construct optimal dispatching model aiming at the minimum cost and the shortest passenger's mean waiting time. Firstly, the concept of focusing distance changing rate was introduced in this algorithm and inertial weighting factor was formulated as a function of focusing distance rate so as to provide the algorithm with effective dynamic adaptability. Meanwhile, a method of effective judgment of premature and stagnation is embedded in the algorithm. The optimization results show that this algorithm can effectively solve public transit vehicle dispatching problems.

Key words: quantum-behaved particle swarm optimization; inertia weight; rate of cluster focus distance changing; mutation; public transit vehicle dispatching

合理的公交调度,可以充分发挥城市交通系统的最大效益,便于居民的出行,减轻城市道路系统的交通压力,节约整个社会的公共交通出行费用,对提高整个城市的交通效率具有重要意义。公交调度必须考虑乘客的利益及企业的运营成本,实质上是一个多重约束目标的优化问题,其解决的关键体现在高效、强壮的算法上。目前应用于公交车智能调度的算法主要有遗传算法^[1,2]、粒子群优化算法^[3]、蚁群优化算法^[4]等。

其中,蚁群算法较复杂,需要较长的搜索时间,容易出现停滞现象;遗传算法染色体互相共享信息,整个种群比较均匀的向最优区域移动;粒子群算法只有全局极值提供信息给群内的粒子,是单向的信息流动,与遗传算法相比,所有的粒子会更快收敛于最优解。但是粒子群算法与其他进化算法一样,不可避免的存在着早熟收敛现象。

为此,本文提出了一种改进的具有量子行为的粒

① 基金项目:国家自然科学基金(61004127);中北大学青年基金

收稿时间:2011-12-21;收到修改稿时间:2012-01-17

子群算法,新算法首先引入聚焦距离变化率的概念,将惯性因子表示为关于聚焦距离变化率的函数,从而使算法具有动态自适应性;其次,在算法中嵌入有效判断早熟停滞的方法,一旦检索到早熟迹象,根据构造的变异概率对粒子进行变异使粒子跳出局部最优,从而减少无效迭代。并尝试将权重自适应调整的量子粒子群算法应用于公交车智能调度中。实验结果表明,该方法能更有效地解决公交调度问题。

1 公交调度优化模型

1.1 模型假设

公交调度具有受影响因素多,客流变化大等特点;例如,受季节、节假日、天气、突发事故等外部因素影响,因此建立模型之前需要对实际情况进行简化。模型的假设条件如下:

针对城市公交系统中的某一路线公交车辆调度;模型建立时只考虑这一路线的单行情况;根据全线路客流划分时段,同一时段内发车间隔相等,单位时间内的期望到达人数不变,服从均匀分布;假定每辆车经过各车站时乘客全部上车且忽略乘客上下车时间;忽略线路交通事故等原因造成的到站时间延误;全程票价统一。

1.2 模型变量及符号说明

1) I 为时段集 $I=\{1 \dots I\}$, i 表示第 i 个时段; F_i 表示第 i 时段的类型(高峰时段、平缓时段和低谷时段), F_i^{\min} 为该时段内最小发车间隔, F_i^{\max} 为该时段内最大发车间隔。

2) S 为车站集 $S=\{1 \dots S\}$, s 表示第 s 个车站;

3) Δt_i 为第 i 个时段的发车间隔即公交优化的对象;根据 F_i 的值有不同的取值范围。

4) T_i 表示第 i 时段的时间长度; u_{is} 表示第 i 时段第 s 站的上车乘客数;

5) $\rho_{is}=u_{is}/T_i$ 表示第 i 时段第 s 站的乘客到达率(假设乘客到达车站服从均匀分布,则 $\Delta t_i/2$ 为第 i 时段乘客的平均等车时间);

6) E_1 为每公里每辆公交车消耗的费用; E_2 为一个乘客等待一个单位时间平均损失费用;

7) W_1 表示公交公司消耗费用的加权系数; W_2 表示乘客等待时间所损失费用的加权系数;如果希望某方消耗的费用小,就增大某方的加权系数,同时减少另一方的加权系数,并保持加权系数的关系为 $W_1+W_2=1$;

8) p 为全程公交票价; L 为线路的总公里数;

9) $m_i=T_i/\Delta t_i$ 表示第 i 时段的总发车车次等于该时段的时段长度与发车间隔的比值。

1.3 目标函数

公交车辆调度要考虑公交公司和乘客双方的利益,其中,公交公司的利益以发车次数最少,即以公司运营成本最低来保证;乘客的利益以等车时间最小,即以所有乘客等车所损失的费用最低来保证。于是建立如下目标函数:

$$\min f(\Delta t_i) = W_1 E_1 L \sum_{i=1}^I \frac{T_i}{\Delta t_i} + W_2 E_2 \sum_{i=1}^I \sum_{s=1}^{m_i} \sum_{s=1}^S \left(\frac{\rho_{is} \Delta t_i^2}{2} \right) \quad (1)$$

其中, $E_1 L \sum_{i=1}^I \frac{T_i}{\Delta t_i}$ 为一天公交线路运营总费用,

$E_2 \sum_{i=1}^I \sum_{s=1}^{m_i} \sum_{s=1}^S \left(\frac{\rho_{is} \Delta t_i^2}{2} \right)$ 为一天乘客等待总费用。这两

个目标综合时存在一个权值的问题,如果希望乘客等车时间比较短,设置乘客等车时间的加权系数要大些;如果希望公交公司运营成本低,设置公交公司发车次数加权系数要大些。其他约束条件如下:

$$F_i^{\min} \leq \Delta t_i \leq F_i^{\max}$$

2 改进的量子行为粒子群优化算法

2.1 量子行为 PSO 算法(QPSO)

为了使粒子能够更好地满足全局收敛,2004年江南大学孙俊等人运用量子力学理论,并将量子进化算法引入到粒子群优化算法中,提出了量子粒子群算法(QPSO)^[5]。这种算法以 DELTA 势阱为基础,认为粒子具有量子行为。由于在量子空间中的粒子满足聚集态的性质完全不同,粒子移动时没有确定的轨迹,这使粒子可以在整个可行解空间中进行探索寻找全局最优解,因而 QPSO 算法的全局搜索能力远远优于经典的 PSO 算法。在量子空间中,粒子的速度和位置是不能同时确定的。通过波函数来描述粒子的状态,并通过求解薛定谔方程得到粒子在空间某一点出现的概率密度函数,又通过 Monte Carlo 随机模拟方式得到粒子的位置方程为: $X(t) = P \pm \ln \left[\frac{1}{u} \right]$, 式中: u 为服从在 $[0,1]$ 上均匀分布的随机数; L 值由式 $L(t+1) = 2 \cdot b \cdot |$

mbest-X(t) 确定。最后得到 QPSO 算法的进化方程为:

$$P = \alpha * Pbest(i) + (1-\alpha) * Gbest \quad (2)$$

$$mbest = \frac{1}{M} \sum_{i=1}^M Pbest(i) \quad (3)$$

$$b = 1.0 - \text{generation} / \text{maxgeneration} * 0.5 \quad (4)$$

$$\text{position} = P \pm b * |mbest - \text{position}| * \ln(1/\mu) \quad (5)$$

其中, M 为种群规模, $mbest$ 是粒子群 $Pbest$ 的中间位置, 即平均值; b 为收缩扩张系数, 在 QPSO 收敛过程中线性减小; α 、 μ 为 0 至 1 之间的随机数, 如果产生的 μ 大于 0.5, 则式(5)取加, 否则取减; generation 为当前进化代数, maxgeneration 为设定的最大进化代数。

2.2 量子粒子群优化算法的改进策略

2.2.1 随机惯性权重的构造

在粒子群优化算法中, 惯性权重 ω 对算法收敛具有重要影响, 它使粒子保持运动惯性, ω 值较大有利于全局搜索, 收敛速度快, 但是不易得到精确的解; ω 值较小有利于局部搜索, 能得到较为精确的解, 但收敛速度慢。

本文按照文献[6]的方法定义粒子的最大聚焦距离(式 6)和粒子平均聚焦距离(式 7), 分别为。

$$MaxDist = \max_{i=1,2,\dots,m} \left(\sqrt{\sum_{i=1}^D (Gbest - Pbest(i))^2} \right) \quad (6)$$

$$MeanDist = \frac{\sum_{i=1}^m \left(\sqrt{\sum_{i=1}^D (Gbest - Pbest(i))^2} \right)}{m} \quad (7)$$

其中, m 为粒子数, D 为每个粒子的维数, $Gbest$ 为粒子群目前搜索到的最优位置, $Pbest(i)$ 为每个粒子目前搜索到的最优位置。粒子当前聚焦距离变化率定义为

$$k = \frac{MaxDist - MeanDist}{MaxDist} \quad (8)$$

当聚焦距离变化率较大时表明粒子的最大聚焦距离和平均聚焦距离相差较大, 此时粒子的全局搜索较差, 故应使粒子尽快地进入全局搜索, 当聚焦距离变化率较小时, 应该提高粒子的局部搜索能力。根据聚焦变化率的变化可以调整惯性权重来控制粒子的收敛速度。本文依据聚焦变化率定义惯性权重, ω 表示为

$$\omega = \begin{cases} (a_1 + |r|/2.0|\ln k|), & |k| > 1 \\ a_1 a_2 + |r|/2.0, & 0.05 \leq |k| \leq 1 \\ (a_2 + |r|/2.0)/|\ln k|, & |k| < 0.05 \end{cases} \quad (9)$$

其中, $a_1=0.3$, $a_2=0.2$, r 为一个 [0, 1] 间均匀分布的随机数。该选择策略即随机地选取 ω 值, 使 ω 随聚焦距离的变化率自适应地调整。此时, 将式(5)改写为:

$$\text{position} = \begin{cases} P \pm ((a_1 + |r|/2.0|\ln k|) * |mbest - \text{position}| * \ln(1/\mu)) & |k| > 1 \\ P \pm ((a_1 a_2 + |r|/2.0|\ln k|) * |mbest - \text{position}| * \ln(1/\mu)) & 0.05 \leq |k| \leq 1 \\ P \pm ((a_2 + |r|/2.0|\ln k|) * |mbest - \text{position}| * \ln(1/\mu)) & |k| < 0.05 \end{cases} \quad (10)$$

2.2.2 判断并克服早熟停滞的方法

随机惯性权重能够提高解的质量, 但不能从根本上克服易陷入局部收敛的缺陷, 只是增强了全局搜索的能力。QPSO 面对的主要问题是随着优化问题规模的增加, 粒子易于落入到局部最优解, 而导致搜索能力的下降。本文利用全局最大适应值与个体平均最大适应值的比值来判断是否早熟停滞, 根据构造的变异概率对粒子进行变异使粒子克服早熟。

设第 t 代粒子群发现的全局最大适应值 $Gbest$, 个体平均最大适应值 $mbest$ 即式(3)。如果 $Gbest(t+1)$ 优于 $Gbest(t)$ 或 $mbest(t+1)$ 优于 $mbest(t)$, 则说明粒子群正在向好的方向进化。在算法运行初期, 由于粒子之间的差异较大, 全局最大适应值与个体平均最大适应值之比 γ 即式(11)一般比较大; 当算法接近收敛时, γ 趋向于 1。因而如果 γ 长时间接近 1 但仍不满足终止准则, 则认为粒子群处于暂时停滞状态。根据构造的变异概率对粒子进行变异使粒子分散开来。根据式(12)^[7]对每个个体极值进行一个扰动。

$$\gamma = Gbest / mbest \quad (11)$$

$$Pbest(i) = Pbest(i) + 0.5\eta \quad (12)$$

这里, $Pbest(i)$ 是第 i 个粒子目前为止的最好位置, η 是服从 (0, 1) 正态分布的 n 维随机向量。通过这种判断停滞和增加随机扰动的方法, 可有效地减少无效迭代, 从而提高算法的收敛速度和优化求解精度。

对典型函数的测试结果表明, 改进量子粒子群算法的收敛速度明显优于基本的 QPSO, 收敛精度也有所提高。所以本文提出的改进策略具有可行性。

3 基于改进量子粒子群算法的公交调度优化方法

公交调度主要任务是以客流数据为主要依据,对发车间隔进行优化。

3.1 粒子编解码

从调度优化模型可知, 目标函数是发车间隔的函数, 由于所建模型是分时段等间隔的, 所以必须采用整数形式进行编码。对式(10)进行取整得到

$$\text{position} = (\text{int})(P \pm \omega * |\text{mbest-position}| * \ln(1/\mu)) \quad (13)$$

因为位置公式更新后可能会超出取值范围(F_i^{\max})所以采用求余的方法限制 x 的值。

$$\text{if}(x > F_i^{\max}) \quad \text{position} = \text{position} \quad \text{mod} \quad F_i^{\max} \quad (14)$$

其中, mod 为求余运算。

结合实际情况, 规定 F_i^{\min} 不得小于 3 分钟, F_i^{\max} 不得大于 18 分钟, 即区间长度为 16, 可以采用 1 位 16 进制代码表示, 编码与区间的映射关系为: 3→0, 4→1, ..., 18→F。具体编码过程如下: 假设全天分为 4 个时段, 发车间隔分别为 13 分钟, 4 分钟, 8 分钟, 16 分钟, 则经过映射后粒子表示为 [A | 1 | 5 | D] 解码时依据映射关系进行反向映射即可得到发车时序。

3.2 适应度评价

量子粒子群算法通过适应度来评价粒子当前位置的优劣。对应公交调度方案的总费用越低, 则适应度越高。相应的适应度函数为:

$$F = 1 / f(\Delta t_i) \quad (15)$$

3.3 算法描述

步骤 1. 编码和初始化粒子群。

步骤 2. 根据目标函数式(15)计算每一个粒子的适应度; 判断算法收敛准则是否满足, 如果满足, 转步骤 7; 否则, 执行步骤 3。

步骤 3. 根据式(6)~(8)计算出聚集距离的变化率, 从而按式(9)确定惯性权重 ω 的值。

步骤 4. 对于粒子群中的所有粒子, 根据其适应度, 更新个体最优位置 $P_{\text{best}}(i)$ 和群体最优位置 G_{best} ; 根据公式(2)~(4)和式(13)以一定概率取加或减, 更新每个粒子的位置, 生成新的粒子群体。如果位置超出取值范围(F_i^{\max})采用式(14)更正。

步骤 5. 根据式(3)和式(11)计算 γ 的值。如果 γ 长

时间接近 1 但仍不满足终止准则, 按式(12)执行变异操作; 否则, 转向步骤 6。

步骤 6. 若达到终止条件(足够小的适应值或预设的最大迭代次数)则转向步骤 7; 否则返回步骤 2。

步骤 7. 输出全局最优位置 G_{best} 及其适应值。

4 实例研究

以文献[3]中的客流数据为例进行计算。该条公交线路运营长度为 8 公里, 共设 4 站, 运营时间为 6:00~21:00, 表 1 给出该线路对应时间段内各站的乘客流量[3]。算法主要参数设置: 共划分 5 个时段; 6:00—8:30, 8:31—12:00, 12:01—16:00, 16:01—19:00, 19:01—21:00, 其中 6:00—8:30 和 16:01—19:00 是高峰期, 19:01—21:00 是低谷期, 8:31—12:00, 12:01—16:00 是平缓期。

发车间隔变化区间高峰期[3, 6], 平缓期为[6, 12], 低谷期为[12, 18], 公交车综合运营费用为 3 元/km; 乘客等待成本为 0.2 元/min; 加权系数 $W_1=W_2=0.5$; 粒子群规模为 200; 最大进化代数 200。应用改进量子粒子群算法得优化发车间隔如表 2 所示。

表 1 对应时间段内各站的乘客客流量

时段	站点/人			
	1	2	3	4
6: 00—8: 30	674	625	49	39
8: 31—12: 00	495	374	133	282
12: 01—16: 00	190	119	232	316
16: 01—19: 00	515	507	355	324
19: 01—21: 00	90	99	34	105

表 2 优化发车间隔表

时段	发车间隔	发车班次
6: 00—8: 30	5	30
8: 31—12: 00	9	23
12: 01—16: 00	10	24
16: 01—19: 00	4	45
19: 01—21: 00	15	8

根据乘客流量计算出发车间隔和发车车次, 图 1 为计算输出结果。

图 1 中曲线所表示的是客流在全天内分布的情况, 柱状图表示根据算法求出的各时段发车间隔计算得到的各时段的发车车次。从图中的输出结果来看, 基本上能满足乘客多, 发车车次多, 乘客较少发车次

数较少的要求。从输出结果还可看出应用此模型能够解决目标问题,表明此模型和算法是有效的。

实验中还发现,加权系数对优化结果影响很大。通过改变加权系数得到优化发车间隔及发车班次对比如图 2,图 3 所示。




图 1 客流数据变化趋势与生成车次次数对比图




图 2 加权系数变化引起发车间隔变化图




图 3 加权系数变化引起发车班次变化图

图 2 图 3 说明 W_1 系数从 0.6 变化至 0.4, 也即公交公司利益变小, 代表乘客利益系数 W_2 逐渐变大; 则发车间隔不断变小, 同时发车次数逐渐变大。

4 结语

本文以公交公司运营费用最低及乘客平均等车时间最少为原则构建公交调度优化的综合模型, 基于惯性权重自适应调整的 QPSO 算法求解该公交优化问题。仿真实验与粒子群算法^[3]进行比较, 文献[3]利用在收缩因子的基础上融入基于遗传操作的 PSO 算法, 实际上是通过增加种群多样性试图克服早熟收敛, 并未能彻底解决早熟收敛问题; 本文利用全局最大适应值与个体平均最大适应值的比值来判断是否早熟停滞, 根据构造的变异概率对粒子进行变异使粒子克服早熟。所以本文提出算法收敛较快、性能较好, 能更好地完成公交优化要求。本文基于 QPSO 改进的公交调度优化算法仅对某线路指定乘客流量进行优化, 算法性能还有待于在实际的公交线路优化中进行测试, 还需要在实践中不断完善和改进。

参考文献

- 张洪明. 基于遗传算法的公交优化设计与实现. 计算机应用与软件, 2010, 27(5): 200-208.
- 王庆荣, 朱昌盛, 梁剑波, 等. 基于遗传算法的公交智能排班系统应用研究. 计算机仿真, 2011, 28(3): 345-348.
- 雷秀娟, 史忠科, 付阿利. 改进的粒子群优化算法求解车辆调度问题. 计算机应用研究, 2008, 25(9): 2674-2696.
- 于滨, 杨忠振, 程春田. 并行蚁群算法在公交线网优化中应用. 大连理工大学学报, 2007, 47(2): 211-214.
- Sun J, Feng B, Xu WB. Particle swarm optimization with particles having quantum behavior. Proc. of 2004 Congress on Evolutionary Computation. Piscataway, NJ: IEEE Press, 2004. 325-331.
- 任子晖, 王坚. 一种动态改变惯性权重的自适应粒子群算法. 计算机科学, 2009, 36(2): 227-229.
- 刘俊芳, 高岳林. 带自适应变异的量子粒子群优化算法. 计算机工程与应用, 2011, 47(3): 41.