

改进免疫粒子群算法在矿车调度优化中的应用^①

张宏艺¹, 洪大华¹, 崔广健¹, 王伟乾², 张 超³

¹(鞍钢集团矿业公司, 鞍山 114001)

²(中国电子科技集团公司第二研究所, 太原 030024)

³(北京科技大学 自动化学院, 北京 100083)

摘 要: 提出了一种基于自适应搜索的改进免疫粒子群算法。算法在传统免疫粒子群算法的基础上, 对子种群进行分组, 以并联形式对算法进行融合, 动态调整各组子种群规模, 根据粒子最大浓度值自适应调整搜索范围。首先, 算法融合了浓度调节机制, 结合粒子最大浓度值来调节子种群数目以充分利用粒子群资源; 与此同时, 针对次优子种群进行疫苗接种, 利用粒子最大浓度值调节接种疫苗的搜索范围, 在避免了种群退化现象的同时, 提高了算法的收敛精度和全局搜索能力。文中建立了露天矿山矿车调度模型并进行了仿真实验, 仿真结果表明, 所提算法充分利用了矿车资源, 具有一定优越性和较好的工程应用价值。

关键词: 粒子群算法; 人工免疫算法; 自适应搜索; 车辆调度

Application of Improved Immune Particle Swarm Algorithm in Vehicle Scheduling Optimization

ZHANG Hong-Yi¹, HONG Da-Hua¹, CUI Guang-Jian¹, WANG Wei-Qian², ZHANG Chao³

¹(Mining Company, Ansteel Group Corporation, Anshan 114001, China)

²(The Second Institute of China Electronic Group Corporation, Taiyuan 030024, China)

³(School of Automation and Electronic Engineering, University of Science and Technology Beijing, Beijing 100083, China)

Abstract: An immune particle swarm algorithm based on adaptive search strategy is proposed in this paper. Based on the traditional immune particle swarm algorithm, the sub populations are grouped on the fusion algorithm in parallel form, the size of each group is adjusted dynamically, and the search range is also adjusted, according to the maximum concentration of particles. Firstly, combing with the adjustment mechanism of concentration and the maximum value of concentration, the algorithm adjusts the number of sub populations, in order to make full use of the particle source. At the same time, the inferior sub-populations are vaccinated, and the maximum concentration of the particles is used to control the search range of the vaccine. Avoiding the degradation of population, the convergence accuracy and the global search ability of the algorithm are improved. A vehicle scheduling model of open-pit mine is established and simulation experiments are carried out. The simulation results show the proposed algorithm makes full use of the tramcar source, and has certain advantage and good engineering application value.

Key words: particle swarm optimization; artificial immune algorithm; adaptive search; vehicle schedule

粒子群优化算法(PSO, Particle Swarm Optimization)^[1]是模仿鸟类飞行觅食过程的算法, 以其速度更新公式使种群中的粒子迅速向种群历史最优值靠拢, 搜索速度快、效率高, 算法简单, 适合处理实数编码问题。该算法一经提出, 便受到众多学者的关注和研究。但是 PSO 与其他群智能算法类似, 算法后期多样性差、进化速度大幅降低, 容易出现停滞现象, 在应用过程中往往会出现陷入局部最优而导致的早熟停滞现象, 造

成算法得不到理想最优解, 尤其是在解决复杂的多峰多谷问题时更为突出^[2,3]。因此, 研究者开始尝试将一些其他智能仿生算法与经典 PSO 相融合, 以弥补 PSO 多样性不足的缺点。如蚁群粒子群算法^[4]、遗传粒子群算法^[5]、免疫粒子群算法^[6]等。

人工免疫优化算法(AIA, Artificial Immune Algorithm)^[7]是由人工免疫系统发展而来, 以其独特的浓度机制, 记忆调节机制和疫苗接种机制来控制种群

① 收稿时间:2016-09-17;收到修改稿时间:2016-11-14 [doi:10.15888/j.cnki.csa.005817]

抗体的多样性, 以确保优秀的抗体始终保持合理的浓度范围. 人工免疫优化算法在遗传优化算法(GA, Genetic Algorithm)^[8]的基础上发展而来, 它很好地克服了易 GA 陷入局部最优的缺点, 但缺点也十分明显, 虽然种群进化方式与 GA 相同, 但收敛速度比大幅落后于 GA. 在融合算法中, AIA 常常作为一种辅助算法用来提高种群多样性^[9].

免疫粒子群算法(IPSO, Immune Particle Swarm Optimization)^[10]是将经典粒子群算法和人工免疫算法相结合的融合算法. 它将粒子群算法的进化机制与人工免疫算法的浓度调节机制相结合, 使融合后的算法全局性搜索能力更强. 不少学者也将免疫粒子群算法改进并运用到实际问题当中, 例如文献[11]提出了一种基于混沌克隆选择的免疫粒子群优化算法(CIPSO), 并将该算法运用到优化 BP 神经网络权值当中. 文献[12]提出了一种改进的粒子群免疫优化算法(IIPSO), 并把这种算法运用到机器人路径规划当中. 文献[13]针对混合车间流水调度问题提出了一种带有动态扰动的免疫粒子群算法(IPSO-DDT). 目前虽然上述改进算法从一定程度上改善了经典粒子群算法的多样性, 但随机疫苗接种也导致了种群退化, 造成一部分粒子的资源浪费.

本文提出的自适应免疫粒子群算法 ASIPSO (Adaptive search Artificial Immune Algorithms-Particle Swarm Optimization)在传统免疫粒子群融合算法基础之上, 动态调整子种群规模, 并根据粒子最大浓度值自动调整搜索范围. 与传统免疫粒子群融合算法相比, ASIPSO 避免了种群退化所造成的种群资源浪费, 而且具有良好的收敛精度和全局搜索性能, 尤其在处理复杂问题时, 由于其可变的搜索范围, 增加了整个种群的多样性, 提高了算法性能.

露天采矿的运输过程就是矿车从采点将矿石装载后, 运输到卸载点的过程. 由于矿区地形复杂、矿石品质限制等各种因素, 在各环节容易产生等待或者不协调等问题, 导致运输成本非常高, 急需合理的调度算法提高车辆的利用率, 减少空车负载和等待现象以减小成本. 在露天矿车调度设计上, 除了根据实际生产情况确定合适的生产设备和数量外, 还要依据露天矿山自身条件给出经济有效的运输方案, 所以露天矿山车辆调度是一个多维度多峰多谷的复杂优化问题.

1 自适应搜索免疫粒子群算法

1.1 算法基本思想

经典免疫粒子群算法通常采用串联方式, 即在种群更新时, 先通过人工免疫算法对种群进行优劣选择, 再按照经典粒子算法的粒子速度、位置更新公式进行种群进化, 如式(1)、式(2)所示. 其中 $i=1,2,\dots,d$. 公式(1)中的 C_1 、 C_2 为学习因子(也是加速常数), r_1 和 r_2 为 $[0,1]$ 之间的两个随机值. ω 为惯性权重, 代表个体过去速度对当下速度的影响.

$$\vec{V}_i(t+1) = \omega(t)\vec{V}_i(t) + C_1 r_1 (\overrightarrow{pbest}_i(t) - \vec{X}_i(t)) + C_2 r_2 (\overrightarrow{gbest}_i(t) - \vec{X}_i(t)) \quad (1)$$

$$\vec{X}_i(t+1) = \vec{X}_i(t) + \vec{V}_i(t+1) \quad (2)$$

经典免疫粒子群算法可以有效提高种群多样性, 但其在算法进化初期存在一定不足, 即在初始粒子种群多样性充足的情况下引入浓度机制和疫苗接种, 在一定程度上降低了种群的多样性. 因此考虑在种群进化初期即多样性充足时减少人工免疫算法的作用, 提高算法效率; 在进化后期加大人工免疫算法作用, 防止早熟停滞.

本文提出的自适应免疫粒子群算法采用并联方式, 即在种群更新时, 经典粒子群算法和人工免疫算法是同时进行的. 它将种群分为两个数目可变的子种群 A 和 B. 子种群 A 保留适应度高浓度低的较优粒子, 对其进行速度和位置更新, 使整个种群朝着最优解进化; 子种群 B 则由适应度差浓度高的劣质粒子组成, 对这些劣质粒子进行疫苗接种, 对记忆细胞中较优粒子进行繁殖, 更新劣质粒子. 以粒子最大浓度值为指标, 调节子种群数量. 采用基于欧式距离的抗体浓度计算方法, 如式(3)和式(4)所示. 式中 d 既是决定簇数目, 也是维数; X_{ik} 为第 i 个抗体的第 k 个抗体决定簇, 对应于粒子群算法即为第 i 个粒子第 k 位的取值. 如果两个抗体特别相近, 那么 $Similar(X_i, X_j)$ 的值就会特别大. 如果在种群某个抗体与多个抗体相似时, 则说明该抗体在种群中的浓度 $Density(X_i)$ 较大.

$$Similar(X_i, X_j) = \frac{1}{\sqrt{\sum_{k=1}^d (X_{ik} - X_{jk})^2}} \quad (3)$$

$$Density(X_i) = \frac{1}{M} \sum_{j=1}^M Similar(X_i, X_j) \quad (4)$$

子种群 A、B 的种群数分别由式(5)、式(6)计算得出. 其中, $popA$ 是子种群 A 的个体数量; $popB$ 是子种

群 B 的个体数量; M 是初始种群个体数量, 也是子种群 A 和 B 的总和; d_{max} 是粒子最大浓度值.

$$popA = d_{max} M \quad (5)$$

$$popB = M - popA \quad (6)$$

当粒子分散时, 整个粒子群多样性好, 不容易陷入局部最优, 这个时候子种群 A 规模较大, 子种群 B 规模较小, 使整个粒子群朝着最优解进化. 当粒子群过于集中时, 整个粒子群多样性差, 容易陷入局部最优, 此时应设定子种群 B 具有较大规模, 子种群 A 规模减小, 以确保一部分优秀粒子进化的同时, 另一部分次优粒子在相邻解空间内进行搜索, 增大整个种群的多样性.

动态改变子种群数目相当于控制两种算法的作用大小. 这样可以使种群在过于拥挤时改善其多样性, 使种群始终朝着更好的方向进化.

1.2 自适应搜索的实现

在传统免疫粒子群算法疫苗接种方式的基础上, 如果能在保证优秀粒子的情况下增加随机性, 可有效提高种群质量, 改善其多样性.

本文所提自适应免疫粒子群算法在继承优秀粒子的基础上, 以记忆库中存入的 $gbest$ 为中心, 添加一定程度的随机范围搜索, 如式(7)和式(8)所示:

$$Vaccine(x_i) = gbest + range(t) \quad i = 1, 2, \dots, popB \quad (7)$$

$$range(t) = rand * R(t) \quad (8)$$

其中, $Vaccine$ 是接种疫苗, $range(t)$ 是第 t 代搜索范围, $R(t)$ 是第 t 代搜索半径. 每一个接种疫苗都落在群体极值周围的一个随机值上.

这样, 在优秀粒子周围的可变范围内产生一些随机粒子, 即保证了继承优秀粒子中的有效信息, 同时增强了种群多样性. 疫苗接种中的可变范围大小也通过粒子最大浓度来调节, 当粒子最大浓度比较高时, 需要增加搜索范围, 使疫苗接种的粒子分散在群体极值周围大范围内, 增加种群多样性. 当粒子最大浓度比较低时, 说明粒子群不缺乏多样性, 需要减少搜索范围, 使疫苗粒子在群体极值周围小范围寻找最优解.

具体实现过程中, 初始搜索范围是以群体极值为圆心, 以粒子群速度极值 V_{max} 为半径的圆, 随后在上一代搜索范围的基础上对其进行改变, 根据当前粒子最大浓度来控制搜索半径范围. 搜索规则采用先验经验知识设置, 如式(9)、式(10)所示:

$$R(1) = V_{max} \quad (9)$$

$$R(t) = R(t-1) \frac{1 + \frac{n(t)}{t_{max}}}{1 + \frac{m(t)}{t_{max}}} \quad (10)$$

这里的 m 和 n 分别是搜索半径扩大数和缩小数, 他们共同决定着搜索半径的大小. t_{max} 是最大迭代代数. 而控制 m 和 n 的是由一系列规则决定的, m 和 n 的初始值为 0.

$$n(t) = \begin{cases} n(t-1) + 2 & d_{max} > 0.8 \\ n(t-1) + 1 & 0.8 \geq d_{max} > 0.6 \\ n(t-1) & d_{max} \leq 0.6 \end{cases} \quad (11)$$

$$m(t) = \begin{cases} m(t-1) + 2 & d_{max} \leq 0.8 \\ m(t-1) + 1 & 0.2 < d_{max} \leq 0.4 \\ m(t-1) & d_{max} > 0.4 \end{cases} \quad (12)$$

当最大粒子浓度变大到一定程度时, 说明整个种群位置过于密集、多样性差. 通过上面的规则, n 增加, m 不变, 整个搜索半径增加; 当最大粒子浓度适中时, 说明种群位置适中, 多样性好. 保证 n 和 m 都不变, 搜索半径也基本不变; 当最大粒子浓度偏低时, 说明整个种群太过分散. 通过以上规则, n 不变, m 增加, 整个搜索半径缩小. 根据最大粒子浓度不断改变搜索半径, 即增加了种群的多样性, 同时也把粒子浓度维持在一个合理区间内.

1.3 算法流程

该算法具体步骤如下, 算法流程图如图 1 所示.




图 1 自适应免疫粒子群算法流程图

Step1. 建立一个种群数量为 M 的粒子群, 并对粒子群的速度和位置进行初始化.

Step2. 根据公式(3)和公式(4)计算初始种群各个粒子浓度, 计算各粒子的亲和力即适应度, 将群体极值位置 $gbest$ 赋值存入记忆库作为疫苗.

Step3. 根据粒子的亲和力从高到低排序.

Step4. 根据粒子群的最大浓度值的大小, 由公式(5)和(6)将父代种群分成两个子种群 A 和 B. 子种群 A 继承了父代亲和力高的粒子, 子种群 B 由剩余粒子组成.

Step5. 子种群 A 通过公式(1)、(2)粒子群算法的速度和位置更新公式进化, 子种群 B 通过公式(7)、公式(8)进行疫苗接种.

Step6. 子种群 A 和子种群 B 合并形成新种群 C.

Step7. 新种群 C 根据粒子群算法的速度和位置公式进化, 形成新父代, 更新个体极值和群体极值.

Step8. 群体极值是否满足循环退出条件, 若满足算法停止运行并输出结果, 否则跳转 step2.

1.4 实验分析

以 Sphere 函数(如式(13))为测试函数, 将本文所提算法(ASIPSO)与经典粒子群算法(PSO)、文献[12]算法(IIPSO)、文献[13]算法(IPSO-DDT)进行对比分析. 仿真软件采用 MATLAB2014a, 运行环境为 WIN7 平台下的 Intel(R)Core(TM)i3-350M 处理器, 2.27G 的主频以及 3G 内存.

$$f(x) = \sum_{i=1}^D x_i^2 \quad (13)$$

设置种群规模 $M=40$, 最大迭代次数 $tmax=200$. 粒子群算法中, 设定惯性权重 $wstart=0.9$, $wend=0.4$, 学习因子 $C_1=C_2=1.5$. 在相同条件下对以下测试函数进行 30 次优化, 评价指标分别是 30 次优化结果里的最优值, 30 次优化结果的平均值, 30 次优化结果里的最差值和 30 次优化结果的标准差. 同时我们将 30 次平均运行时间作为额外参考标准. 实验结果如表 1 所示. 几种算法进化过程中其最优个体适应度值随进化代数变化曲线如图 2 所示.




图2 优化 Sphere 函数各算法进化曲线

表1 几种算法关于 Sphere 函数的求解情况对比

测试函数	优化算法	30 次最优解	30 次平均解	30 次最差解	30 次标准差	耗时(s)
Sphere 函数	PSO	1.101e-23	0.036e-19	0.133e-19	0.058e-19	0.239
	IIPSO	0.0272	0.1105	0.2597	0.0698	0.832
	IPSO-DDT	2.511e-07	0.155e-04	0.386e-04	0.133e-04	0.76
	ASIPSO	4.392e-46	0.027e-41	0.192e-41	0.067e-41	0.457

仿真实验结果说明了改进算法的有效性, 它一定程度上克服了经典免疫粒子群算法因为种群退化导致的算法精度不高等缺陷.

2 露天矿山车辆调度模型

露天矿山车辆运输既要满足矿石生产的产量和质量要求, 也要满足岩石剥离的总量要求. 本文以某露天铁矿运输系统为例, 假设所有卡车载重均为 140 吨, 一个班次为 8 小时, 建立了露天矿山车辆调度模型.

在当前铁矿需求疲软的情况下, 该模型以完成生产计划为目标, 尽可能减少运输成本(总运量)为原则. 这里总运量并非传统意义上的运输量, 而是运输距离与总运输量的乘积, 类似于矿车的有效做功量.

2.1 主目标函数

利用现有车辆设备, 在完成基本生产要求的情况下合理利用矿车资源, 使整个班次总运量达到最小. 其主目标函数如:

$$\min \left\{ \sum_{i=1}^m \sum_{j=1}^n 0.014 x_{ij} d_{ij} \right\} \quad (14)$$

式中 m 为采点总数目; n 为卸点总数目, 卸点包括卸岩点和卸矿点; h 为卸岩点数目; d_{ij} ——从采点 i 到卸点 j 的距离, 单位是 km; x_{ij} 是采点 i 到卸点 j 的这一条路线一个班次的运输总车次, 是被优化量。

由于 d_{ij} 值确定, 对 x_{ij} 进行粒子群编码, 构建若干个 W 维粒子, $W=m \times n$, 每个粒子的位置对应不同运输区间维度中的运载次数。

2.2 约束

2.2.1 矿石品位约束

卸点的矿石需要达到一定的品位要求, 品位过高或过低都不能用于后续的生产工序。本文中某矿山要求该品味为 28.5 ± 0.1 。

$$0.285 \leq \frac{\sum_{i=1}^m 0.014 x_{ij} \rho_i}{\sum_{i=1}^m 0.014 x_{ij}} \leq 0.305 \quad j = 1, 2, \dots, n-h \quad (15)$$

式中 ρ_i 为第 i 个采点经过电铲后产出的矿石品位。

2.2.2 产量要求约束

一个班次的生产活动中, 矿石的产量和岩石的剥离量都必须满足生产计划的安排。

$$\sum_{i=1}^m 0.014 x_{ij} \geq p_j \quad j = 1, 2, \dots, h \quad (16)$$

$$\sum_{i=1}^m 0.014 x_{ij} \geq q_j \quad j = 1, 2, \dots, n-h \quad (17)$$

式中 p_j 是第 j 个卸岩点单位班次要求的岩石剥离量, 单位 10kt; q_j 是第 j 个卸矿点单位班次要求的矿石产量, 单位 10kt。

2.2.3 铲位产量约束

根据生产的实际情况, 某铲位运输的矿石及岩石量不可能超过该铲位的实际生产能力。

$$\sum_{j=1}^h 0.014 x_{ij} \leq w_i \quad i = 1, 2, \dots, m \quad (18)$$

$$\sum_{j=1}^{n-h} 0.014 x_{ij} \leq y_i \quad i = 1, 2, \dots, m \quad (19)$$

式中 w_i 是单位班次内第 i 个铲位岩石产量, 单位 10kt; y_i 是单位班次内第 i 个铲位的矿石产量, 单位 10kt。

2.2.4 电铲装载能力约束

一台电铲不能同时为两台及以上车辆进行装载作业, 所以其在一个班次内的工作次数是有限的。

$$\sum_{j=1}^n x_{ij} \leq \frac{8 \times 60}{l} \quad i = 1, 2, \dots, m \quad (20)$$

其中 l 为装载时间。

2.2.5 卸点卸载能力约束

同电铲一样, 一个卸点同一时刻只允许一代卡车进行卸载作业。

$$\sum_{i=1}^m x_{ij} \leq \frac{8 \times 60}{u} \quad j = 1, 2, \dots, n \quad (21)$$

其中 u 为卸载时间。

2.2.6 单位班次一条线路中一辆车最大运行次数

该约束并不作为优化算法的约束, 而是作为车辆调度的依据。

$$c_{ij} = \left\lceil \frac{\frac{8 \times 60}{2 \times 60 \times d_{ij} + l + u}}{v} \right\rceil \quad (22)$$

2.3 模型数据

本文所模拟的露天铁矿共有铲位 10 个, 其中卸矿点 3 个, 卸岩点 2 个; 电铲 7 台, 卡车 14 辆。各卸点单位班次的产量要求如下, 卸矿点 1 需要 1.2 万吨、卸矿点 2 需要 1.3 万吨、卸矿点 3 需要 1.3 万吨、卸岩点 1 需要 1.9 万吨、卸岩点 2 需要 1.3 万吨。装载时间 l 为 5 min, 卸载时间 u 为 3 min, 卡车速度 v 为 $\text{km} \cdot \text{h}^{-1}$ 。

铲位与卸点之间的距离如表 2 所示。各铲位矿石、岩石储量(万吨)和矿石的品位(%)如表 3 所示。

表 2 铲位和卸点之间的距离(公里)

	1(卸矿点 1)	2(卸矿点 2)	3(卸矿点 3)	4(卸岩点 1)	5(卸岩点 2)
$\sum_{j=1}^n x_{ij} \leq \frac{8 \times 60}{l} \quad i = 1, 2, \dots, m$					
铲位 1	5.26	1.9	5.89	0.64	4.42
铲位 2	5.19	0.99	5.61	1.76	3.86
铲位 3	4.21	1.9	5.61	1.27	3.72
铲位 4	4	1.13	4.56	1.83	3.16
铲位 5	2.95	1.27	3.51	2.74	2.25

铲位 6	2.74	2.25	3.65	2.6	2.81
铲位 7	2.46	1.48	2.46	4.21	0.78
铲位 8	1.9	2.04	2.46	3.72	1.62
铲位 9	0.64	3.09	1.06	5.05	1.27
铲位 10	1.27	3.51	0.57	6.1	0.5

表 3 各铲位矿石、岩石储量(万吨)和矿石的品位(%)

	矿石产量(w)	岩石产量(y)	品位(ρ)
铲位 1	5.26	1.9	5.89
铲位 2	5.19	0.99	5.61
铲位 3	4.21	1.9	5.61
铲位 4	4	1.13	4.56
铲位 5	2.95	1.27	3.51
铲位 6	2.74	2.25	3.65
铲位 7	2.46	1.48	2.46
铲位 8	1.9	2.04	2.46
铲位 9	0.64	3.09	1.06
铲位 10	1.27	3.51	0.57

根据表 2、表 3 中的数据, 矿山车辆调度问题被转化为一个 50 维、多约束的优化问题. 优化算法需在满足约束条件的解空间中, 寻求运量最低的粒子位置.

3 仿真与分析

3.1 仿真实验

采用和 1.4 节一致的仿真环境. 由于改进算法的流程较为复杂, 求解能力强, 种群规模和最大迭代次数可适当选取, 分别设为 40 和 200. 根据经典文献选定粒子群参数, 其中 $c_1 = c_2 = 1.45$, ω 从 0.9 到 0.5 梯度下降.




图 3 两种算法求得最优个体适应度值(总运量)变化曲线

采用改进算法和经典粒子群算法分别对矿车调度模型进行仿真实验, 总运量随进化代数变化曲线如图 3 所示.

3.2 结果分析

通过图 3 我们可以看出, 改进算法优化得到的总运量为 10.36 万吨*公里, 而经典粒子群算法得到的结果为 41.92 万吨*公里. 在完成生产目标情况下, 改进算法的优化得到的运输成本比经典粒子群算法低 300%.

如第 1.1 节所述, 本文所提改进算法通过分组且动态调整分组大小的方式, 尽可能保留种群的多样性, 使整个种群朝着最优解进化; 这种种群多样性体现在初始解适应度值波动大、数值大, 这种情况在较为复杂的规划问题上尤为突出. 在图 3 中, 由于粒子种群数量为 40, 每个粒子 50 维, 算法初始状态随机值较大, 近 106, 而由于扩大随机性的影响, 在 46 代之前, 本文所提算法所求得的最优解逊于经典粒子群算法. 而相对于一般函数的优化问题, 如图 2 中的 sphere 函数优化, 这种扩大随机性造成的算法初期不稳定性并不明显.

与此同时, 如第 1.2 节所述, 本文所提算法有针对性的进行自适应搜索, 在有效寻优方向上适度扩大搜索范围, 从而可以最终求得适应度更高的解. 这在一般函数规划问题的结果如图 2, 复杂规划问题的结果如图 3 中均得到了一定的体现.

3.3 矿车调度优化

采用本文所提算法, 通过计算, 可以得到每条路径上的车辆运行次数(即从铲位 i 到卸载点 j 的车辆运输次数)填入表中, 以便进行车辆调度安排, 如表 4 所示. 根据表 4 中的数据, 可酌情安排各线路上的车辆, 如表 5 所示, 同时可得到车辆调度表, 如表 6 所示.

表 4 优化结果

运输车次(次)	铲位 1	铲位 2	铲位 3	铲位 4	铲位 5	铲位 6	铲位 7	铲位 8	铲位 9	铲位 10
1 卸矿点 1	0	14	0	0	24	0	0	40	0	0

2	卸矿点 2	11	32	0	26	15	0	0	0	0	0
3	卸矿点 3	0	15	0	0	0	0	0	0	0	71
4	卸岩点 1	65	20	40	0	0	0	0	0	0	0
5	卸岩点 2	0	0	0	0	0	0	25	23	35	2

表 5 各线路安排车辆数目

运输车辆(辆)		铲位 1	铲位 2	铲位 3	铲位 4	铲位 5	铲位 6	铲位 7	铲位 8	铲位 9	铲位 10
1	卸矿点 1	0	1	0	0	1	0	0	1	0	0
2	卸矿点 2	0	1	0	1	0	0	0	0	0	0
3	卸矿点 3	0	1	0	0	0	0	0	0	0	2
4	卸岩点 1	1	1	1	0	0	0	0	0	0	0
5	卸岩点 2	0	0	0	0	0	0	1	1	1	0

表 6 车辆调度表

车号	任务 1		任务 2		任务 3		任务四		任务五	
	路径	次数	路径	次数	路径	次数	路径	次数	路径	次数
A	1-4	44								
B	2-1	14	1-2	2						
C	2-2	32	1-2	5						
D	2-3	14								
E	2-4	20	1-2	4	1-4	8				
F	3-4	35								
G	4-2	26	1-4	13						
H	5-1	23								
I	7-5	25	2-3	1	3-4	5	5-1	1	5-2	5
G	8-1	29								
K	8-5	23	5-2	10						
L	9-5	35								
M	10-3	45								
N	10-3	26	8-1	11	10-5	2				

4 结 论

本文对经典粒子群算法和传统免疫粒子群算法进行深入分析,在此基础上,从融合方式和接种机制两个方面对经典算法进行改进.

改进算法具有较强的自适应搜索能力,改善了经典粒子群算法的早熟停滞现象和传统免疫粒子群算法的种群退化现象.

根据生产计划和矿山实际约束情况建立了相关数学模型,并利用改进算法对矿车调度模型进行仿真实验,并根据实验结果制定详细的矿车调度计划.该算法较好地解决了露天矿山矿车调度问题.

参考文献

1 Kennedy J, Eberhart RC. Particle swarm optimization. Proc. of IEEE Conference on Neural Networks. Nagoya. 1995.

1942-1948.

2 随聪慧.粒子群算法的改进方法研究[硕士学位论文].成都:西南交通大学,2007.

3 Khare A, Rangekar S. A review of particle swarm optimization and its applications in Solar Photovoltaic system. Applied Soft Computing Journal, 2012, 11(4): 2997-3006.

4 邓高峰,张雪萍,刘彦萍.一种障碍环境下机器人路径规划的蚁群粒子群算法.控制理论与应用,2009,26(8):879-883.

5 Zhou XC, Zhao ZX, Zhou KJ, He CH. Remanufacturing closed-loop supply chain network design base on genetic particle swarm optimization algorithm. Journal of Central South University, 2012, (19): 482-487.

6 高鹰,谢胜利,免疫粒子群优化算法.计算机工程与应用, 2004,40(6):4-6.

- 7 Woldemariam KM, Yen GG. Vaccine-enhanced artificial immune system for multimodal function optimization. *IEEE Trans. on Systems, Man, and Cybernetics, Part B: Cybernetics*, 2010, 40(1): 218–228.
- 8 Giovanni G. Kalmarnagy T. Genetic Algorithm for Multi-Agent Space Exploration. *Proc. of AIAA 2007 Conference and Exhibit. California*. 2007,7. 199–214.
- 9 李茂军,罗安,童调生.人工免疫算法及其研究.控制理论与应用,2004,21(2):153–157.
- 10 Fang L, Bo P. Immune Particle Swarm Optimization Beats Genetic Algorithms. *Proc. of 2010 Second WRI Global Congress on Intelligent Systems (GCIS)*. New York. 2010. 233–236.
- 11 韩琳.免疫粒子群算法研究及其应用[硕士学位论文].西安:西安工程大学,2008.
- 12 王宏亮.基于粒子群免疫算法的足球机器人路径规划[硕士学位论文].成都:西华大学,2013.
- 13 孙春宇.基于免疫粒子群算法的混合流水车间调度问题研究[硕士学位论文].哈尔滨:哈尔滨理工大学,2012.