

6-2-2020

Energy Efficiency Optimization for Discrete Workshop Based on Parametric Knowledge Pigeon Swarm Algorithm

Shan Xin

Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China;

Wang Yan

Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China;

Zhicheng Ji

Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Energy Efficiency Optimization for Discrete Workshop Based on Parametric Knowledge Pigeon Swarm Algorithm

Abstract

Abstract: Aiming at the characteristics of complexity, constraint in discrete manufacturing workshop, in order to minimize the total energy consumption of the workshop as the target, *discrete knowledge pigeons algorithm* was proposed to solve discrete workshop energy efficiency optimization. In this algorithm, *parameter knowledge was introduced into the optimization process to balance local search and global search, and the convergence and optimization ability of the algorithm were improved. The discrete process was added to the pigeons algorithm, which not only preserved the convergence and optimization ability of the algorithm, but also made the algorithm capable of dealing with discrete problems.* Through the test of concrete examples, the particle swarm optimization, genetic algorithm and pigeons algorithm results were compared and analyzed, the pigeons algorithm in convergence and optimization ability is superior to the other two algorithms, which verifies the rationality and validity of the algorithm.

Keywords

discrete manufacturing workshop, energy efficiency optimization, pigeons algorithm, knowledge parameters, second discrete process

Recommended Citation

Shan Xin, Wang Yan, Ji Zhicheng. Energy Efficiency Optimization for Discrete Workshop Based on Parametric Knowledge Pigeon Swarm Algorithm[J]. Journal of System Simulation, 2017, 29(9): 2140-2148.

基于参数知识鸽群算法的离散车间能效优化

单鑫, 王艳, 纪志成

(江南大学物联网技术应用教育部工程研究中心, 江苏 无锡 214122)

摘要: 针对离散制造车间复杂性、约束性特点, 以车间总能耗最小为优化目标, 提出一种求解离散车间能效优化的离散型知识鸽群算法。该算法在优化过程中引入参数知识以平衡局部收索和全局收索, 提高了算法收敛性和寻优能力。在算法中加入离散过程, 不仅保留算法收敛性和寻优能力的特点, 而且具有处理离散问题的能力。通过实例测试, 将粒子群, 遗传算法与鸽群算法的结果进行比较分析, 鸽群算法在收敛性和寻优能力方面明显优于另外两种算法, 验证了算法的合理性和有效性。

关键词: 离散制造车间; 能效优化; 鸽群算法; 知识参数; 二次离散

中图分类号: TP278

文献标识码: A

文章编号: 1004-731X (2017) 09-2140-09

DOI: 10.16182/j.issn1004731x.joss.201709036

Energy Efficiency Optimization for Discrete Workshop Based on Parametric Knowledge Pigeon Swarm Algorithm

Shan Xin, Wang Yan, Ji Zhicheng

(Engineering Research Center of Internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China)

Abstract: Aiming at the characteristics of complexity, constraint in discrete manufacturing workshop, in order to minimize the total energy consumption of the workshop as the target, *discrete knowledge pigeons algorithm* was proposed to solve discrete workshop energy efficiency optimization. In this algorithm, *parameter knowledge* was introduced into the optimization process to balance local search and global search, and the convergence and optimization ability of the algorithm were improved. The discrete process was added to the pigeons algorithm, which not only preserved the convergence and optimization ability of the algorithm, but also made the algorithm capable of dealing with discrete problems. Through the test of concrete examples, the particle swarm optimization, genetic algorithm and pigeons algorithm results were compared and analyzed, the pigeons algorithm in convergence and optimization ability is superior to the other two algorithms, which verifies the rationality and validity of the algorithm.

Keywords: discrete manufacturing workshop; energy efficiency optimization; pigeons algorithm; knowledge parameters; second discrete process

引言

制造业竞争日益激烈, 能源问题日益凸显, 可



收稿日期: 2017-05-18 修回日期: 2017-07-10
基金项目: 国家自然科学基金(61572238), 国家高技术研究发展计划(2014AA041505), 江苏省杰出青年基金(BK20160001);
作者简介: 单鑫(1991-), 男, 湖北十堰, 硕士生, 研究方向为离散制造能效优化。

持续制造成为当前制造业的必然选择。离散制造系统流程工业能耗量大, 是制造业节能减排的首要对象^[1]。研究表明, 作为离散制造系统耗能主体的机械设备, 其有效能量利用率平均低于 30%, 节能潜力巨大^[2]。我国离散制造业的特点是能耗大且能效低, 导致生产成本上升, 环境污染加剧。因此, 离散制造系统能效优化方面的研究, 对提高能源利用

<http://www.china-simulation.com>

• 2140 •

效率, 加强制造业的竞争力显得很有必要性。

为了寻求科学合理符合实际调度需求的生产调度排产计划、缩短产品生产时间、降低产品能耗, 许多学者从不同的角度提出了多种解决方法, 如: 数学归纳法、规则调度法、系统仿真法、计算智能法, 专家系统等^[3]。离散车间的能效优化主要集中在结构性优化和生产调度安排优化^[4]。其中, 结构性优化主要通过车间整体进行布局和节能设备的更换, 达到能效优化的目的, 具有不可逆性, 应用范围狭窄; 加工过程优化主要通过工件工序合理安排机床加工顺序, 减少能耗, 提高能效优化, 该方法具有普适性, 符合生产实际需要, 研究价值极高。

针对加工过程优化, 国内外学者做了大量的研究工作, 产生了一定的成果, 如, 汪浩祥等^[5]针对知识化制造环境下的自适应调度问题, 提出了基于状态-Q 动作不确定性偏向学习的知识化制造自适应调度策略, 使调度效果更符合实际, 提高了调度效率。A.A.G. Bruzzone 等^[6]通过建立一个能效的调度模型(Energy-aware scheduling; EAS)对作业车间的生产与调度进行优化, 并且建立数学模型有效求解车间能耗和设备空闲时间最小两个目标的优化。魏英姿等^[7]提出了一种基于性能预测的遗传强化学习动态调度方法, 对调度问题最优解采用优先规则编码方式来表达求解; 尹大威等^[8]提出了一种专家系统在炼钢动态调度中的应用, 通过具有调度专家控制方案对炼钢生产调度进行管理和相关数据分析, 以能效优化为目标, 优化炉机匹配过程。龙田等^[9]提出基于调度规则和免疫算法的作业车间多目标调度, 采用优先级对大量调度方案进行求解, 从备选调度规则集中选出单个目标下性能最优的调度规则。

目前针对离散车间能效优化所应用的智能算法主要有遗传算法、粒子群算法、蚁群算法、免疫算法等^[10], 这些算法虽然在离散车间能效优化方面具有一定的研究价值, 但是这些算法的参数设置对运行结果至关重要, 并且还存在着遗传交叉等学习

策略, 致使算法步骤繁琐, 因此若能减少参数设置, 避免遗传交叉等繁琐学习策略, 可以使算法简单实用。2014 年, Duan 等^[11]受自然界鸽子归巢行为的启发, 首次提出了一种基于鸽子归巢行为的新型群体智能优化算法—鸽群优化 (pigeon-inspired optimization, PIO) 算法, 该算法具有收敛速度快, 寻优能力强, 参数较少的优点, 因此该算法近来受到广泛关注。本文通过对鸽群优化算法的大量实验仿真模拟, 采用鸽群参数知识来平衡算法的局部收索和全局收索, 通过鸽群优化算法再加上二次离散过程, 克服该算法不适用于离散制造车间的缺点, 从而提出一种离散知识型鸽群算法 (Discrete knowledge pigeons algorithm, DKPIO), 并将其应用到离散制造车间的能效优化中。最后通过仿真实验数据分析, 验证该方案的有效性。

1 问题描述

在离散制造车间中, n 个待加工工件有 m 台可用机器, 每个工件有 k 道工序, 工件的加工工序所选择的机器具有差异性: 不同的待加工工件有不同的加工工艺路线, 工件的同道工序有 m_1 台机器可加工, 因为机器之间的差异性, 相同工序选择不同的加工机器, 会产生不同的加工时间, 加工能耗, 待机时间, 待机能耗, 这就为离散车间排产调度能效优化带来节能空间。所以如何合理有效的安排工件加工工艺对应的机器及加工顺序, 直接影响离散车间能效优化效率。

对车间调度, 现做如下假设约束:

- (1) 工件工序在机器上加工的顺序是由工艺路线唯一确定的;
- (2) 工件的一道工序一旦开始加工, 在完成该工序之前不能随意停止(即不考虑机器故障的发生);
- (3) 工件在同一时刻只能在一台机器上加工;
- (4) 在零时刻所有工件的加工优先级都相同;
- (5) 不同工件的各工序之间的加工顺序优先级相同。

1.1 数学模型参数定义

现将数学模型中所用的参数进行定义:

m : 表示加工设备的数量;

n : 表示待加工工件的个数;

i : 表示工件号; j 表示工序号; k 表示设备号;

h : 表示设备号;

$M = \{M_k | 1 \leq k \leq m\}$: 表示设备集;

$J = \{J_i | 1 \leq i \leq n\}$: 表示工件集;

Q_i : 表示工件 J_i 的工序集;

s : 表示所有工件中的最大工序数;

O_{ij} : 表示工件 J_i 的工序 j ;

$M_{ij} = \{M_k | X_{ijk} = 1\}$, 表示工件 J_i 的工序 O_{ij} 的可用设备集;

P_{ijk} : 表示工件的某道工序可以在多台设备上加工;

R_c : 两个工件可以在同一台设备上加工;

t_{ijk} : 表示工序 O_{ij} 在设备 M_k 上的加工时间;

S_{ijk} : 表示工序 O_{ij} 在设备 M_k 上加工的开始时间;

E_{ijk} : 表示工序 O_{ij} 在设备 M_k 上的完工时间;

w_k : 表示某个工件的某道工序在设备 M_k 上的耗能量;

WM_k : 表示所有工件在设备 M_k 上的耗能量;

WM : 表示加工所有工件的总能耗;

$$X_{ijk} = \begin{cases} 1, & \text{工序 } O_{ij} \text{ 由设备 } M_k \text{ 加工} \\ 0, & \text{其他} \end{cases}$$

$$R_c = \begin{cases} 1, & O_{ij} \text{ 与 } O_{eg} \text{ 同在 } M_k \text{ 上加工, } O_{ij} \text{ 先加工} \\ 0, & \text{其他} \end{cases}$$

式中: $m, n, M, J, O_i, O_{ij}, M_{ij}, S_{ijk}$ 表示输入变量; $t_{ijk}, E_{ijk}, WM_k, WM$ 表示输出变量; P_{ijk}, R_c 表示决策变量。

1.2 模型建立

离散制造车间的数学模型和约束条件描述如下:

目标函数: 本文取车间加工所有工件时, 设备总耗能最小为目标函数, 具体数学描述如下:

$$f_1 = \min WM = \min \left(\sum_{i=1}^m WM_i \right) \quad (1)$$

$$WM_k = \sum_{i=1}^n \sum_{j=1}^s w_k \quad (2)$$

1) 约束条件:

$$E_{ijk} - E_{egk} \geq t_{egk}$$

$$R_v = 1, P_{ijk} = P_{egk} = 1 \quad (3)$$

式(3)表示每台机器同一时刻只可以加工一个工件。

2) 加工过程约束

$$E_{ijk} - S_{ijk} = t_{ijk}, P_{ijk} = 1 \quad (4)$$

式(4)表示某道工序开始加工便不可中断。

3) 工艺路线约束

$$S_{ijk} - E_{I(j-1)h} \geq 0, P_{ijk} = P_{I(j-1)h} = 1 \quad (5)$$

式(5)表示同一工件的不同工序之间存在顺序约束, 不同工件之间没有工序约束。

2 改进鸽群优化算法

2.1 鸽群优化算法

基本的鸽群优化算法是一种群智能优化算法, 通过对鸽子独特的导航方式启发而来, 最早应用于航天领域。鸽群在寻找旅程的不同阶段使用不同的导航工具, 鸽群在迭代前期 ($N < N_1$ 时, 其中 N 为当前迭代次数) 依赖磁场, 在迭代后期 ($N > N_1$ 时) 依赖地标, 根据迭代数选择不同的导航工具可以平衡局部收索和全局收索的能力, 并且加快收敛和寻优能力。鸽群使用虚拟的导航工具, 初始化鸽子的位置, 并且在多维空间中, 鸽子的初始位置在每一次迭代中都会得到更新。鸽群优化算法就是针对上述鸽子导航行为, 通过模拟其特性, 来寻找全局最优解。

2.2 磁场算子

在鸽群优化模型中, 定义鸽群成员 V^j ($j=1, 2, \dots, N$, 其中 N 为鸽子总数), 每个鸽子维数为 D , 即 $V^j = (v_1, v_2, \dots, v_m)$ 表示第 j 个鸽子在目标收索空间中的位置矢量, 目标优化则为

$f(V^i)$ ($i \in \{1, 2, \dots, N\}$), 即鸽群优化目标受 m 个决策量共同影响, 在本文中 f 值越小能效优化效果越好。当 $f(V^i)$ 在搜索空间最小时, 取此时 V^i 为全局最优值, 鸽群在地图和指南针算子的更新过程如下:

当 $f(V^i)$ 最优时

$$V_g = V^i \quad (6)$$

$$V_{\text{new}}^j = V_{\text{old}}^j \times e^{-Rt} + \text{rand} \times (V_g - V_{\text{old}}^j) \quad (7)$$

式中: V_{old}^j 和 V_{new}^j 分别表示第 j 个鸽子在更新位置前和更新位置后的矢量坐标; R 是地图与指南针因子; rand 是一个 0~1 的随机数, 相当于加入的随机扰动; V_g 是当前鸽群全局最优位置, 可以通过比较所有鸽子的位置并选出适应度函数最优的那个个体来获得。该迭代过程执行若干次后停止并将得到的 V^j 传递给地标算子继续运算。

2.3 地标算子

鸽群在优化目标函数后期, 鸽群逐渐接近目的地以后, 会通过附近熟悉的地标来进行导航。在地标算子阶段, 此时取鸽群位置的中心位置为 Mean , 不需要其他智能算法中的局部最佳位置学习和变异交叉等繁琐步骤, 鸽群利用群体自身信息共享优势, 可以加速收敛, 回归巢穴, 使最后优化效果即能快速收敛, 又能最佳优化。具体的地标算子采用如下公式表示。

$$\text{Mean} = \frac{1}{N} \sum_{i=1}^N V^i \quad (8)$$

$$V_{\text{new}}^j = V_{\text{old}}^j \times e^{-Rt} + \text{rand} \times (V_g - \text{Mean}) \quad (9)$$

2.4 更新阶段

鸽群经过“磁场算子”阶段和“地标算子”阶段优化后, 对鸽群的位置矢量进行更新, 具体更新方式如下:

$$\begin{aligned} & \text{当 } f(V_{\text{old}}^i) < f(V_{\text{new}}^i) \text{ 时} \\ & V^i = V_{\text{old}}^i \end{aligned} \quad (10)$$

$$\text{当 } f(V_{\text{old}}^i) > f(V_{\text{new}}^i) \text{ 时}$$

$$V^i = V_{\text{new}}^i \quad (11)$$

3 离散型鸽群算法

鸽群算法与众多算法一样都是针对连续函数提出的智能算法, 所以在离散问题求解中, 由于变量离散性, 因此, 使用鸽群算法解决离散车间调度问题, 就需要对鸽群算法和离散调度问题进行适当的处理, 使得鸽群算法可以更好的适用于离散车间的能效优化。

3.1 初始化

建立鸽群位置矢量和调度能效优化二者之间的映射关系, 是算法及操作首要关键的问题, 也是鸽群算法应用于作业车间调度问题的关键。根据离散制造车间的工序和机器对应排列的特点, 采用双层设计的方式随机初始化鸽群, 第 1 层 X_p^i 为工序层, 表示第 i 个零件的工序; 第 2 层 X_M^i 为机器层, 表示第 i 个零件某道工序的加工机器。如图 1 所示, 鸽子 X^i 表示一个 3 工件 6 机器的调度安排方案, 其中第 1 排第 1 列中“1”表示工件 1 的第 1 道工序, 第 2 排的第 1 列中的“2”表示工件 1 的第 1 道工序在机器 2 上加工。图 1 中的第 1 行共有 3 个 1, 表示工件 1 共有 3 道工序, 3 个“1”的位置表示 3 道工序被安排加工的顺序, 第 2 排则对应相应的机器号。

X_p^i	1	3	3	2	1	3	2	2	2	1
X_M^i	2	1	4	2	6	3	4	5	5	1

图 1 离散车间编码初始化

Fig. 1 Discrete shop code initialization

3.2 目标函数 $f(X)$

建立时间矩阵 T , T 中存储每台机器加工对应零件工序所需的加工时间, 将鸽子的机器层数据作为横坐标, 工序层数据作为纵坐标, 利用 $(X_M^i(j), X_p^i(j))$ (其中 j 表示列) 调出对应的时间; 建立能耗矩阵 W , 存储每台机器加工对应零件工序时耗能量, 利用 $(X_M^i(j), X_p^i(j))$ (其中 j 表示列)

调出对应的能耗。所有零件完成加工能耗量总和即为目标函数 $f(X)$ ，具体定义如下：

$$f(X) = \sum_{i=1}^n \sum_{j=1}^p W(X_M^i(j), X_P^i(j)) \quad (12)$$

3.3 磁场离散化

鸽群算法在磁场阶段优化中，舍弃鸽群算法求解速度 V 达到更新种群位置速度的方法，在研究当前算法离散化的思路中，将一种“取整补全”的方法应用于智能算法离散化，不仅优化了智能算法离散化过程，易于编码，更加快智能算法的收敛速度与寻优能力。

3.3.1 鸽群位置矢量均不相同

通过鸽群“磁场算子”更新公式(7)会出现连续值，但是，在离散问题求解过程中，变量之间没有连续性，所以求解的值不能够直接适用离散问题。例如“磁场算子”更新公式(7)中假设 $V_g = [2 \ 5 \ 3 \ 1 \ 4]$ ， $V_{old}^j = [4 \ 1 \ 5 \ 3 \ 2]$ ，设 $\text{rand} = 0.5$ ， $e^{-Rt} = 0.5$ ，则公式(7)所求出解结果为 $V_{new}^j = [0.7 \ 3.3 \ 0.9 \ 0.1 \ 2.4]$ ，所求 V_{new}^j 有小数，所以需要位置矢量经过离散化处理。

1) 取整。采用四舍五入取整法，将优化结果全部取整，得到 $V_{new}^j = [1 \ 3 \ 1 \ 1 \ 2]$ 。

对照离散机床能效优化所需离散范围，筛选出重复的数和超过区间的数，将超过区间对应位置矢量置 0；同时从重复的数中随机选择一个数保持不变，其余全部置 0。对 $V_{new}^j = [1 \ 3 \ 1 \ 1 \ 2]$ 中位置矢量有 3 个“1”，所以我们需要将 3 个“1”中的 1 个“1”位置矢量不变，另外将位置矢量中的 2 个“1”置 0（在这里我们取 $V_{new}^j = [1 \ 3 \ 1 \ 1 \ 2]$ 中第二个位置矢量“1”置 0，其余位置上的矢量“1”置 0），得 $V_{new}^j = [0 \ 3 \ 1 \ 0 \ 2]$ 。

2) 补全。由鸽群算法位置矢量中 $V_g = [2 \ 5 \ 3 \ 1 \ 4]$ ， $V_{old}^j = [4 \ 1 \ 5 \ 3 \ 2]$ ，我们可以看出位置矢量由 1-5 构成，且每个数只出现一次，由 $V_{new}^j = [0 \ 3 \ 1 \ 0 \ 2]$ 我们得出遗漏了决策变量“4”和“5”，所以我们需要将鸽群算法中的位

置矢量补充完整。

取决策变量中遗漏的决策变量集合 $U = [4 \ 5]$ ，将 $U = [4 \ 5]$ 中的位置矢量进行排列组合（ A_n^m 中排列），并将所有排列组合一次放入 $V_{new}^j = [0 \ 3 \ 1 \ 0 \ 2]$ 中遗漏的决策变量中，得 $V_{new}^j = [4 \ 3 \ 1 \ 5 \ 2]$ ， $V_{new}^j = [5 \ 3 \ 1 \ 4 \ 2]$ ，挑选出适应度值最好的位置矢量排列方式，使目标函数 $f(X)$ 排列方式的取值最小。

3.3.2 鸽群位置矢量可以相同

通过对鸽群“磁场算子”工件工序编码中，会改变工件工序数目，所以我们需要对鸽群位置矢量可以相同时出现的缺少工序或增加工序作相应的修改。若鸽群中的位置矢量允许重现重复值时，统计鸽群位置矢量重复出现的次数 C_a^b （ a 代表工件号， b 代表工序总数）。先对求解优化结果进行离散化，将位置矢量取整，将超出矢量范围的位置置 0。若优化求解位置矢量超过 C_a^b 时，从该位置矢量相同的数中，随机选择超过的位置矢量置 0；若优化求解位置矢量低于 C_a^b 时，统计该位置矢量低于 C_a^b 的个数 h_a （ a 代表工件号），添加 h_a 个位置矢量至上述集合 U 中，对 U 的排列组合方法同上所述。

4 鸽群知识参数优化

在群智能算法中，参数选择关系到算法的收敛速度和优化结果，参数的选择是优化问题中关键又复杂的部分。第一，参数应用于不同的优化问题会产生不同的优化效果；第二，参数组合的情况复杂多变。因此合理利用参数来动态实时实际的优化所求问题，实现动态实时控制优化局部收索和全局收索的进程，是算法参数研究中重要且不可或缺的一部分。

在基本鸽群算法中，鸽群算法采用固定参数，即磁场因子“ R ”；磁场算子最大迭代次数 N_1 ， N_2 在鸽群优化算法也需要根据实际情况而定。固定参数不能根据优化进程平衡全局收索和局部收索，鲁棒性低，寻优能力低下。在本文我们运用知识参数来动态实时实际的优化所求问题，通过将参数的取

值按照优化结果进程规律的改变而改变, 我们可以实现动态实时控制优化局部收索和全局收索的进程, 增强算法鲁棒性。

4.1 知识优化磁场因子“R”参数

在鸽群算法中, 磁场因子“R”控制鸽子的更新收敛速度, 对鸽群算法优化起着至关重要的作用。通过公式(7)我们发现: 当 R 很小时, e^{-Rt} 的值很大, 鸽子获得更大初始速度, 有利于快速收敛, 并且有更好的全局收索能力; 当 R 变大时, e^{-Rt} 的值变小, 鸽子获得初始速度逐渐变小, 有利于在局部收索中更细致地收索。我们可以合理准确利用鸽群参数指南针因子“R”来平衡鸽群优化算法在全局收索和局部收索的作用。

由实验可得: 参数“ e^{-Rt} ”在范围[0,1]上比较合理有效, 且当 a 取值为 1, b 取值为 100。

$$x = -10 + \frac{ITER \times 20}{(N_1 \max + N_2 \max)} \quad (13)$$

$$f(x) = \frac{1}{a + b \times e^{-t}} \quad (14)$$

公式(13), (14)动态控制参数变化, 使得参数“R”在初始时很小, 有利于鸽群优化算法快速收敛, 并且有更好的全局收索能力; 经过充分地全局收索以后逐渐变大并接近于 1, 更好的完成局部收索。鸽群参数知识优化策略很好地平衡局部收索和全局收索能力, 有很强的适应性和鲁棒性。知识参数优化图像如图 2 所示。

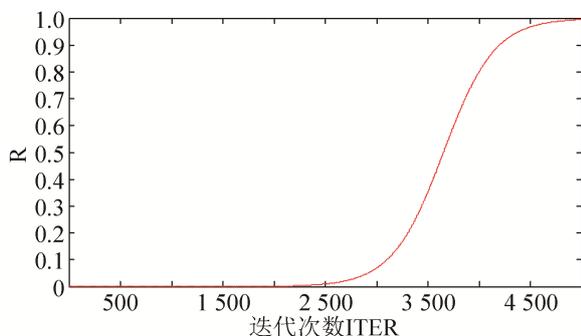


图 2 鸽群知识参数因子“R”迭代变化图像

Fig. 2 Pigeons knowledge parameter "R" iterative image change

4.2 知识优化迭代参数“ N_1, N_2 ”

鸽群算法特有的两段寻优方式(磁场算子, 地标算子)可以使鸽群在寻优的不同阶段具有不同的优化效果。地图和指南针算子阶段便于鸽群进行全局收索, 并具有一定的收敛速度, 不至于寻优速度太慢, 而地标算子中鸽群参考的方向为全局个体的中心位置, 由于不再由个体鸽群本身位置矢量的干扰, 种群可以很快地收敛到最优值。

通过对比本文参数设置和大量试验数据, 我们知道在本实验中当鸽群算法迭代到 3 000~4 000 以后, 由图 3 可看出鸽群的收敛速度变得缓慢, 即使更新多代, 寻优能力开始变得很差, 因此在此阶段进行鸽群的地标算子收索, 不仅可以提高效率, 提高收敛速度, 而且在寻优能力上可以更加优化。因此在本实验鸽群算法中根据大量实验及数据, 我们将 $N_1=3\ 500$, $N_2=1\ 500$ 时, 不仅得到机器耗能总量最优, 而且随着迭代次数的增加, 鸽群算法在后期的寻优能力上与其他算法相比也具有较快的收敛速度和寻优能力。

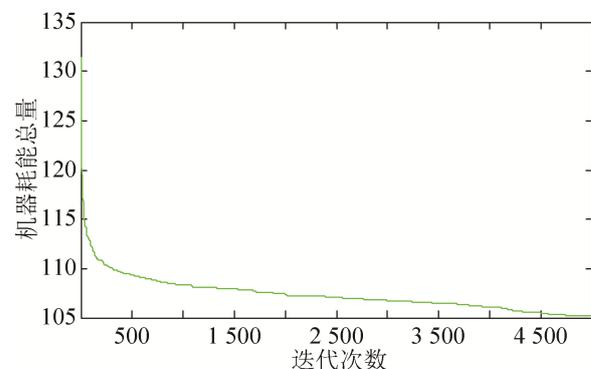


图 3 收敛速度与迭代次数关系

Fig. 3 Relation between convergence rate and iteration number

5 实验结果及分析

本文提出的 DKPIO 算法采用 MATLAB 程序编写, 程序运行环境为 CPU3.40 GHz, 内存 4GB, 软件为 MATLAB R2011b。为了验证所提算法的可行性, 选取实际离散生产车间的真实数据, 选取典型的群智能算法: 遗传算法(GA)和粒子群算法

(PSO), 通过实验仿真与离散知识型鸽群(DKPIO)算法进行比较。

5.1 实验数据设置

该实验数据从实际生产中获得, 如表 1 所示, 本次柔性车间模型采用 6 个零件, 8 台机器, 总共需要 26 道工序。

表 2 给出了每台机器加工期间待机单位耗能情况。

考虑算法运行时间, 我们统一将迭代次数设为 5 000 次, 鸽子数目为 20, 循环迭代次数设为 50。

结合实际生产需要, 将机器的最大完工时间设为 80, 防止算法寻优过程中生成的加工时间, 从而导致生成方案不符合离散车间实际生产情况。机器在最大完工时间内的最优能耗优化可以根据车间生产实际需要调整, 具有很大的灵活性。由于鸽群算法, 粒子群算法, 遗传算法的差异性, 除了迭代次数和循环迭代次数与鸽群算法相同外, 还需要对这 2 种算法设置参数, 其中, 将 PSO 算法的参数设置为: $C_1 = C_2 = 1.5$, $W_{max} = 0.9$, $W_{min} = 0.4$, 将 GA 算法参数设置为: $P_j = 0.8$, $P_b = 0.1$, $L_j = 1$ 。

表 1 零件工序加工信息表
Tab. 1 Parts processing information table

零件	工序	加工所需耗能/kW·h, 所需时间/min							
		K_1	K_2	K_3	K_4	K_5	K_6	K_7	K_8
J_1	O_{11}	--	4.60/12	--	--	4.89/14	--	6.15/20	--
	O_{12}	5.83/18	--	--	6.31/19	--	--	3.95/11	--
	O_{13}	--	--	5.51/14	3.57/9	--	5.76/17	--	--
	O_{14}	--	4.13/11	--	--	3.42/9	--	--	4.47/12
	O_{15}	4.81/15	--	--	3.42/8	--	--	--	6.29/18
J_2	O_{21}	--	--	4.43/12	5.92/19	4.83/14	--	--	--
	O_{22}	3.06/8	--	--	3.09/9	--	--	4.76/15	-
	O_{23}	4.95/16	3.19/7	--	--	--	3.69/9	--	--
J_3	O_{31}	--	--	--	4.24/11	3.80/10	--	--	4.50/13
	O_{32}	--	--	4.54/12	5.83/18	--	--	4.50/14	--
	O_{33}	3.08/9	--	--	4.50/15	2.93/7	--	--	--
	O_{34}	--	4.53/12	--	--	--	2.67/5	--	3.09/9
	O_{35}	1.79/3	--	--	2.59/4	--	3.10/8	--	--
J_4	O_{41}	--	6.05/19	--	--	3.01/7	--	4.44/13	--
	O_{42}	--	--	3.25/8	--	3.96/11	--	--	4.73/16
	O_{43}	--	4.27/11	--	3.74/8	--	--	5.64/18	--
	O_{44}	2.26/6	--	--	--	--	--	4.44/14	3.58/9
J_5	O_{51}	--	--	--	7.43/22	--	4.39/12	4.89/17	--
	O_{52}	--	4.11/18	--	--	3.46/11	--	--	3.60/9
	O_{53}	3.37/9	--	4.55/12	--	--	--	--	2.72/7
J_6	O_{61}	--	4.19/11	--	--	--	3.48/9	3.31/14	--
	O_{62}	3.11/8	--	--	--	3.06/6	--	--	3.79/9
	O_{63}	--	--	4.07/11	--	5.95/17	--	--	5.98/18
	O_{64}	1.92/5	--	--	5.54/15	--	--	2.79/7	--
	O_{65}	--	4.47/11	--	--	--	2.96/8	--	2.98/7
	O_{66}	6.07/19	--	--	4.08/7	--	4.71/15	--	--

表 2 机器单位时间待机耗能

机器号	K_1	K_2	K_3	K_4	K_5	K_6	K_7	K_8
耗能量	0.30	0.42	0.24	0.21	0.21	0.24	0.33	0.42

5.2 实验结果及分析

将 DKPIO, GA, PSO 算法分别应用于离散制造车间能效优化时, PSO 算法、GA 算法和 DKPIO 算法的仿真结果如表 3、图 4~7 所示, 表 3 列出了上述 3 种算法在不考虑最大完工时间时获得的机器总能耗的最优值和平均值, 从最优值和平均值这两个重要的评价指标我们可以明显看出 DKPIO 算法无论在快速收敛, 寻优最值等方面优于 PSO 和 GA。图 4 为 DKPIO, PSO, GA 三种算法迭代过程中获得的机器总能耗的平均曲线, 由图 4 曲线可

以看出 DKPIO 算法在前期求解过程中收敛速度明显优于 PSO, GA 算法, 且迭代寻优结果明显优于其他两种算法。图 5~7 是 3 种算法生成的最优调度方案的甘特图, 可以通过甘特图观察 3 种算法不同的具体调度方案详情, 从对比中我们可以发现 DKPIO 在排产中不仅安排工序能耗消耗最少的机床加工工序, 并且极大的减少了工件加工过程中的待机时间, 因而 PIO 排产结果加工总能耗明显低于 PSO, GA 的加工能耗。

表 3 3 种智能算法机器总能耗/kW·h

算法	最优值	平均值
PSO	113.45	131.79
GA	107.42	114.73
DKPIO	99.23	107.15

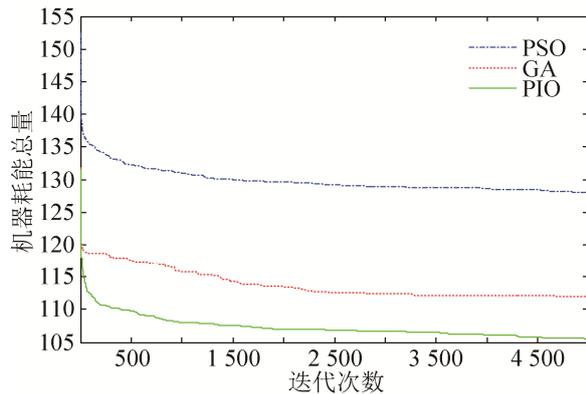


图 4 3 种算法的迭代仿真

Fig. 4 Iterative simulation of 3 algorithms

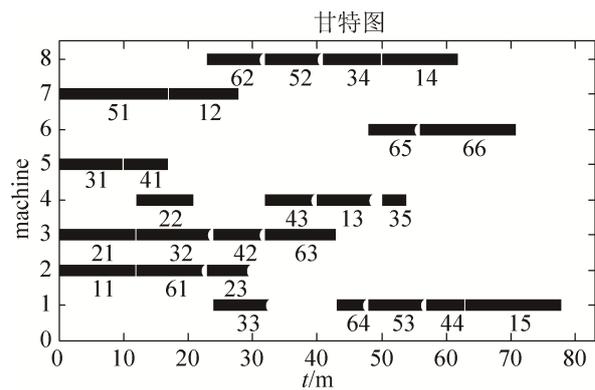


图 5 GA 算法最优调度甘特图

Fig. 5 GA algorithm for optimal scheduling Gantt chart

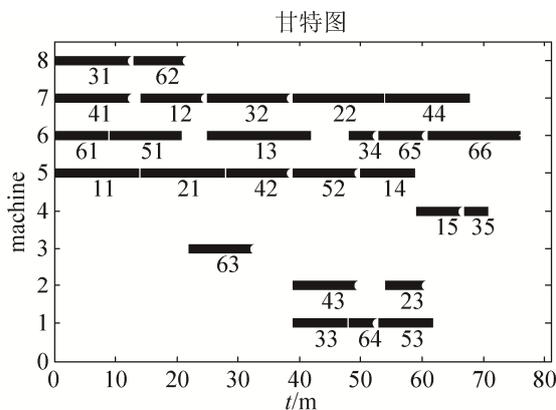


图 6 PSO 算法最优调度甘特图

Fig. 6 PSO algorithm for optimal scheduling Gantt chart

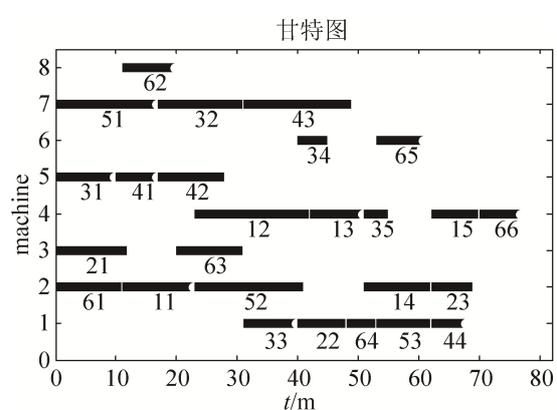


图 7 DKPIO 算法最优调度甘特图

Fig. 7 DKPIO algorithm for optimal scheduling Gantt chart

6 结论

本文针对离散制造车间的能效优化提出了一种离散知识型鸽群优化算法(DKPIO),通过对DKPIO的“磁场算子”和“地标算子”两个阶段离散化处理,使其能够应用到离散制造车间的能效优化中。同时选取PSO和GA两种典型的智能算法进行对比得出,离散知识型鸽群算法具有前期收敛速度快,寻优能力强,后期也可以加速收敛,排产耗能更低的特点,验证了DKPIO算法的可行性。因此,离散鸽群算法可以为离散制造车间能效优化提供更好的排产方案,符合实际。

参考文献:

- [1] Thollander P, Karlsson M, Söderström M, et al. Reducing industrial energy costs through energy-efficiency measures in a liberalized European electricity market: case study of a Swedish iron foundry [J]. *Applied Energy* (S0306-2619), 2005, 1(2): 115-126.
- [2] Rahimifard S, Seow Y, Childs T. Minimising Embodied Product Energy to support energy efficient manufacturing [J]. *CIRP Annals-Manufacturing Technology* (S0007-8506), 2010, 59(1): 25-28.
- [3] 刘爱军. 离散制造车间多生产模式下作业调度研究 [D]. 重庆: 重庆大学, 2011. (Liu Aijun. Study on Job Scheduling in Multi-production Mode for Discrete Manufacturing Workshop [D]. Chongqing, China: Chongqing University, 2011.)
- [4] Driss I, Mouss K N, Laggoun A. A new genetic algorithm for flexible job-shop scheduling problems [J]. *Journal of Mechanical Science and Technology* (S1976-3824), 2015, 29(3): 1273-1281.
- [5] 汪浩祥, 严洪森. 基于SAUBQ学习的知识化制造系统自适应调度策略 [J]. *系统工程理论与实践*, 2014, 34(7): 1885-1894. (Wang Hao-xiang, Yan Hong-sen. Adaptive scheduling strategy in knowledgeable manufacturing system based on SAUBQ-learning [J]. *Systems Engineering-Theory & Practice*, 2014, 34(7): 1885-1894.)
- [6] Bruzzone A A G, Anghinolfi D, Paolucci M, et al. Energy-aware scheduling for improving manufacturing process sustainability: A mathematical model for flexible flow shops [J]. *CIRP Annals-Manufacturing Technology* (S0007-8506), 2012, 61(1): 459-462.
- [7] 魏英姿, 谷侃锋. 基于性能预测的遗传强化学习动态调度方法 [J]. *系统仿真学报*, 2010, 22(12): 2809-2820. (Wei Ying-zi, Gu Kan-feng. Genetic Reinforcement Learning Approach to Dynamic Scheduling Based on Performance Prediction [J]. *Journal of System Simulation*, 2010, 22(12): 2809-2820.)
- [8] 尹大威. 专家系统在炼钢动态调度中的研究 [D]. 济南: 山东大学, 2011. (Yin Da-wei. Expert System Research for Steel Making Dynamic Scheduling [D]. Ji'nan, China: Shandong University, 2011.)
- [9] 龙田, 王俊佳. 基于调度规则和免疫算法的作业车间多目标调度 [J]. *信息与控制*, 2016, 45(3): 278-286. (Long Tian, Wang Junjia. Multi-target Job-shop Scheduling Based on Dispatching Rules and Immune Algorithm [J]. *Information and Control*, 2016, 45(3): 278-286.)
- [10] 刘想德. 作业车间实时调度若干关键问题研究 [D]. 重庆: 重庆大学, 2013. (Liu Xiang-de. Research on Some Critical Issues about Job Shop Real Time Scheduling [D]. Chongqing, China: Chongqing University, 2013.)
- [11] Duan H, Qiao P. Pigeon-inspired optimization: a new swarm intelligence optimizer for air robot path planning [J]. *International Journal of Intelligent Computing and Cybernetics* (S1756-378X), 2014, 7(1): 24-37.