

8-13-2020

Energy Efficiency Optimization for Discrete Manufacturing Workshop Based on Discrete Teaching-learning-based Optimization Algorithm

Junhui Xu

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;

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 Manufacturing Workshop Based on Discrete Teaching-learning-based Optimization Algorithm

Abstract

Abstract: Because the discrete manufacturing workshop is multi-objective and multi-constraint, an energy efficiency optimization model whose optimization objective was to minimize the total energy consumption was built for discrete manufacturing workshop. Besides, an improved teaching-learningbased (TLBO) optimization algorithm for discrete energy efficiency workshop optimization was proposed. *This improved algorithm introduced adaptive parameter in training phase to improve the learning efficiency and adaptability of the algorithm.* In addition, *second discrete process was introduced in the teaching stage and learning stage, respectively.* This algorithm could be applied to the optimization of discrete manufacturing workshop under the precondition of ensuring the convergence of the algorithm is fast and strong searching ability of the characteristics. The experimental result was compared with basic teaching-learning-based optimization algorithm (TLBO), particle swarm optimization algorithm (PSO), chicken swarm optimization (CSO). Based on the analysis, optimization of this improved algorithm is superior to the other two algorithms, which indicates that the proposed algorithm is effective.

Keywords

discrete manufacturing workshop, energy efficiency optimization, teaching-learning-based optimization algorithm, adaptive parameter, second discrete process

Recommended Citation

Xu Junhui, Wang Yan. Energy Efficiency Optimization for Discrete Manufacturing Workshop Based on Discrete Teaching-learning-based Optimization Algorithm[J]. Journal of System Simulation, 2016, 28(12): 3019-3026.

基于改进教与学算法的离散制造车间能效优化

徐军辉, 王艳

(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: 针对离散制造车间多目标性、多约束性的特点, 以车间总耗能最小为优化目标, 构建离散制造车间能效优化模型; 针对上述模型提出了一种基于改进教与学算法的离散车间能效优化方法, 该改进算法在教阶段引入自适应参数, 提高算法的学习效率和适应性, 同时在教和学两个阶段加入二次离散过程, 在保证算法的收敛性快速和寻优能力强特点的前提下, 使该算法能够应用于离散制造车间优化中。对具体实例进行测试, 将基本教与学算法、粒子群算法、鸡群算法与改进教与学算法的结果进行比较, 通过分析该改进算法优化的能效明显优于另外两种算法, 验证了算法的有效性。

关键词: 离散制造车间; 能效优化; 教与学优化算法; 自适应参数; 二次离散

中图分类号: TP278

文献标识码: A

文章编号: 1004-731X (2016) 12-3019-08

DOI: 10.16182/j.issn1004731x.joss.201612020

Energy Efficiency Optimization for Discrete Manufacturing Workshop Based on Discrete Teaching-learning-based Optimization Algorithm

Xu Junhui, Wang Yan

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

Abstract: Because the discrete manufacturing workshop is multi-objective and multi-constraint, an energy efficiency optimization model whose optimization objective was to minimize the total energy consumption was built for discrete manufacturing workshop. Besides, an improved teaching-learning-based (TLBO) optimization algorithm for discrete energy efficiency workshop optimization was proposed. *This improved algorithm introduced adaptive parameter in training phase to improve the learning efficiency and adaptability of the algorithm.* In addition, *second discrete process was introduced in the teaching stage and learning stage, respectively.* This algorithm could be applied to the optimization of discrete manufacturing workshop under the precondition of ensuring the convergence of the algorithm is fast and strong searching ability of the characteristics. The experimental result was compared with basic teaching-learning-based optimization algorithm (TLBO), particle swarm optimization algorithm (PSO), chicken swarm optimization (CSO). Based on the analysis, optimization of this improved algorithm is superior to the other two algorithms, which indicates that the proposed algorithm is effective.

Keywords: discrete manufacturing workshop; energy efficiency optimization; teaching-learning-based optimization algorithm; adaptive parameter; second discrete process

引言

21 世纪以来, 中国已经发展成为世界制造业



收稿日期: 2016-06-12 修回日期: 2016-07-20;
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: 徐军辉(1990-), 男, 河南许昌, 硕士
生, 研究方向为离散制造能效优化; 王艳(1978-),
女, 教授, 博导, 研究方向为网络控制优化。

大国, 离散制造车间作为产品制造企业的主要载体^[1], 是我国工业自动化和现代化的主要发展目标。当前离散制造车间总体表现为高耗能、低能效、自动化程度低, 这与国家正在大力倡导绿色制造的概念相背离, 这对离散制造车间的加工过程中的能效优化提出了更高的要求。因此, 开展对如何提高离散制造车间的能效的研究也显得十分有必要。

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

• 3019 •

当前离散制造车间具有多目标性、多约束性、离散性等特点,对其进行的能效优化主要集中在结构性优化和生产调度安排优化^[2]。其中,结构性优化主要集中在车间建设阶段,通过对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,该方法可研究范围较窄;另外,对加工过程进行生产调度安排,合理安排机床加工顺序,减少加床待机能耗,提高加工效率,从而达到能效优化的目的,该方法具有普适性,研究价值更高。

针对上述第二种优化方法做了大量的研究工作,已经产生一定的成果,如,方水良等^[3]提出一种改进遗传算法,采用机器分配链和工序顺序链的双链的结构进行编码,利用新生策略改进下一代生成的种群,提高了求解的精度。A. Mahdavi 等^[4]通过改进蚁群算法的信息素更新规则,减少了传统蚁群算法的时间复杂度,提高了求解问题的速度。S. Karthikeyan 等^[5]提出一种混合萤火虫算法来求解多目标柔性作业车间调度问题,将邻域搜索算法和萤火虫算法相结合,进而实现了全局搜索与局部探索的有效平衡。彭建刚等^[6]提出了基于进化算法的柔性车间调度方法,运用云模型揭示模糊性和随机性的优良特性维护进化种群设计算法,提高了算法的收敛性和求解问题的准确性。

目前针对离散车间能效优化所应用的算法主要有,遗传算法^[7]、粒子群算法^[8]、人工蜂群算法^[9]、蚁群算法^[10]和鸡群算法^[11],这些算法的参数设置对运行结果的影响至关重要,人为因素对问题的求解有较大影响,因此若能减少人为因素的影响,则能取得更优的求解结果。2011年,Rao 等^[12-14]从实际的老师的教学和学生之间的学习过程中得到启发,提出了一种新型的群智能算法—教与学优化算法 (teaching-learning-based optimization, TLBO),该算法具有收敛速度快,能够屏蔽参数干扰的优点,能够最大程度避免人为因素的影响,因此,现已被广泛应用于各种连续优化问题中。鉴于该算法能够有效屏蔽参数干扰的优良特点,本文通过改变部分参数更新方式,增加离散化过程,克服

了该算法不适用于离散制造车间的缺点,从而提出一种离散教与学算法(ITLBO),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,来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,不同的待加工工件有不同的加工工艺路线,不同的加工工艺路线所选的机器具有差异性;同时,若相同工序加工机器选择的不同,对应机器的耗能情况也不同。当一工序被安排到不合理的机床加工时,即该机床加工该工序时,相对其他机床加工时的耗能更大,从而增加了离散车间的制造耗能;另外,工件被安排的对应的加工机器合理性,也直接影响加工的效率,延长机器的待机时间,从而增加机床的待机耗能。

现做如下假设:

- 1) 某道工序在某一时刻只能用同一台机器进行加工;
- 2) 某个工件的一道工序一旦开始加工,在该工序完成之前不能随意终止(即不考虑机器故障的发生);
- 3) 在零时刻所有工件的加工优先级都相同;
- 4) 不同工件的各工序之间的加工顺序优先级相同,同一工件的各工序的加工必须按照之前约定好的加工顺序。

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;

c : 表示 $ijegk$ 的缩写, i, e 均表示工件号,

j, g 均表示工序号, 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;

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

其中: 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:

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

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

约束条件:

1) 机器约束

$$E_{ijk} - E_{egk} \geq t_{egk}, R_v = 1, P_{ijk} = P_{egk} = 1 \quad (3)$$

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 改进教与学优化算法

2.1 基本教与学优化算法

基本的教与学优化算法(TLBO)是一种典型的群智能优化算法, 通过效仿一个“班级”的学习方式进行算法的更新。每个学生水平的提高需要“老师”和其他“同学”的帮助, 一方面, 老师将优化过的知识“教”给学生; 另一方面, 同学之间通过互相之间的“学”过程, 汲取之间优点。其中, 老师和学生相当于算法的独立个体, 老师是所有个体中适应度最好的个体之一, 每个学生拥的若干个科目相当于对应的若干个决策量。

1) 老师的“教”阶段

在TLBO算法中, 定义班级成员为 j ($j=1, 2, 3, \dots, N$, 其中 N 为学生总数), 每个成员假定有 m 门科目, 科目集合 $V^j = [v_1, v_2, \dots, v_m]$ (即每个成员 j 由 m 个决策量组成), 设目标值为 $f(V^i)$ ($i \in \{1, 2, \dots, N\}$), 即 $f(V^i) = f(v_1, v_2, \dots, v_m)$, $f(V^i)$ 的值受 m 个决策量共同影响, 一般假定 $f(V^i)$ 的值越小效果越好, 函数关系 f 由实际模型而定。当 $f(V^i)$ 最小时, 取此时的 V^i 作为老师 $V_{teacher}$, 取学生科目的平均值作为 $Mean$, 具体教学过程公式如下:

$$\text{Step 1: 当 } f(V^i) \text{ 最优时, } V_{teacher} = V^i \quad (6)$$

$$\text{Step 2: } Mean = \frac{1}{N} \sum_{i=1}^N V^i; \quad (7)$$

$$\text{Step 3: } V_{new}^j = V_{old}^j + r_j(V_{teacher} - TF \cdot Mean); \quad (8)$$

即, V_{old}^j 和 V_{new}^j 分别表示第 j 个学生“教”阶段前和“教”阶段后的科目集合, 这里设定两个关键的参数用于调整学习的速度, TF 为教学因子 $TF = \text{round}[1 + \text{rand}(0, 1)]$, r_i 为学习步长 ($r_i = \text{rand}(0, 1)$), 相当于加入的随机扰动。

2) 学生的“学”阶段

在学生的互相“学”阶段，每个学生 $V^g (g \in \{1, 2, \dots, N\})$ 随机从所有的经过“教”阶段后的学生中选取一个对象 $V^c (c \in \{1, 2, \dots, N\})$ 其中 $g \neq c$ ， V^g 通过和 V^c 进行比较两者之间的差异化，吸取 V^c 的优势部分来提升自己，具体的学过程采用如下公式表示：

$$V_{new}^g = \begin{cases} V_{old}^g + r_g \cdot (V^g - V^c) & f(V^g) < f(V^c) \\ V_{old}^g + r_g \cdot (V^c - V^g) & f(V^g) > f(V^c) \end{cases} \quad (9)$$

式中： r_g 表示第 g 个学生的学习步长， $r_g = rand(0, 1)$ 。

3) 更新阶段

学生分别经过“教”阶段和“学”阶段之后，成绩要进行更新优化，具体更新方法如下：

$$V^z = \begin{cases} V_{old}^z & f(V_{old}^z) < f(V_{new}^z) \\ V_{new}^z & f(V_{old}^z) > f(V_{new}^z) \end{cases} \quad (10)$$

式中：学生 $z \in \{1, 2, 3, \dots, N\}$ 。

2.2 改进的教与学优化算法(ITLBO)

基本的TLBO主要是针对解决连续问题提出的，相关学者已经通过实例证明能够有效的解决连续问题，离散制造车间能效优化问题属于离线复杂性问题，因此TLBO不能有效应用于该能效优化问题中，故提出改进教与学优化算法(ITLBO)用于解决此类离散优化问题。本文关于具体改进过程^[15]主要有两方面，一方面，改进平均成绩 $Mean$ 参数，提出自适应 \overline{Mean} ；另一方面，对学生经过“教”阶段产生的 V_{new}^i 进行离散化，即对该参数进行“再编译”，采取同样的处理方式对“学”阶段产生的 V_{new}^i 进行离散化的“再编译”。

2.2.1 自适应 \overline{Mean}

教与学算法在求解平均值时，不可避免的出现小数位的值，但是，在离散问题求解过程中，由于变量之间没有连续性，所以求解的平均值不能够直接适用于离散问题中。例如假设两个学生 $V^1 = [1 \ 3 \ 2 \ 5 \ 4]$ ， $V^2 = [4 \ 1 \ 5 \ 3 \ 2]$ ，求取平均值 $Mean = [2.5 \ 2 \ 3.5 \ 4 \ 3]$ ，所求得平均值出现了小数

位，以及遗漏了决策量“1”和“5”，需要对数据进行再处理，显然该算法不能有效应用于离散问题中，所以，提出了一种新的自适应 \overline{Mean} 求解方法，即从学生中选取一个与 $f(Mean)$ 效果最接近的值作为 $Mean$ ，从而达到增强算法的适应性和提高求解速度的效果，具体改进过程如下：

Step 1: 求解 $Mean$ 值，然后分别求解出 $f(Mean)$ 和各个学生的目标值 $f(V^e)$ (其中， $e = 1, 2, \dots, N$ ， N 为学生总数) 的值；

Step 2: 取每个学生的目标值与平均目标值之间的绝对值 D_e ： $D_e = abs(f(Mean) - f(V^e))$ ；

Step 3: 假设 $e = k$ 时，即 $D_k = \min(D_e)$ ，令 $\overline{Mean} = V^k$ 。

其中， V^e 为班级的某个学生， $e, k \in \{1, 2, \dots, N\}$ (N 为学生总数)。

2.2.2 “教”阶段离散化

学生通过“教”阶段后，其对应的科目集合需要经过离散化处理，若每个科目的决策量均不相同，首先采用取整法，将每个科目的决策量的余数去掉，然后筛选出重复的数和超过区间的数，将超过区间得科目的决策量置零，同时，从重复的数中随机选择一个数保持不变，其余全部置零，取集合 U (U 为未正常显示的科目集合，总数为 n)，将 U 中的科目进行排列组合，有 A_n^n 种排列，将所有排列方法依次放到上述决策量置零的科目中，挑选出目标值最优的科目的决策量排列方式，即为该学生经过“教”之后的结果。取 $V_{new}^i = [1 \ 3.3 \ 4.1 \ 2.2 \ 3.5 \ 5.4 \ 5.7 \ 0.8]$ ，举例如图1所示。




图1 “教”阶段离散

若学生的各科目的决策量允许出现重复值时, 统计各个决策量重复出现的次数 $v_a (a=1, 2, \dots, b, b$ 为不相同的决策量个数总和), 进行离散化时, 先将每个科目的决策量的余数去掉, 然后超过区间的决策量置零。为了减少算法的复杂性, 若决策量超过 v_a 时, 从所有该相同的数中, 随机选择超过的个数置为零; 若低于 v_a , 统计该决策量低于 v_a 的个数 l_a , 添加 l_a 个该决策量至上述集合 U 中, 对 U 的排列组合方法同上所述。

2.2.3 “学”阶段离散化

“学”阶段的离散化过程与“教”阶段基本相似, 不同之处在于, “学”阶段在 V^i 与 $V^j (V^i, V^j$ 为两个不同的学生) 相减之后需要进行离散化过程, 该过程采用向下取整法, 只保留整数位。由于“学”之后产生的 V_{new}^i 的离散化过程与“教”阶段的离散化方式相同, 这里不再做详细介绍。

3 基于改进教与学算法的能效优化方法

3.1 初始化

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每个学生, 第一层 $X_{process}^k$ 即为工序层, 表示第 k 个零件的工序; 第二层 $X_{machine}^k$ 即为机器层, 表示第 k 个零件的工序加工时的机器。如下图1所示, 学生 X^k 表示一个3工件5机器的调度安排方案, 其中第一排第一列中的“1”表示工件1的第一道加工工序, 第二排的第一列中的“2”表示工件1的第一道工序在机器2上加工。图2中第一排共有三个“1”, 表示工件1共有三道工序, 三个“1”的位置表示三道工序被安排加工的顺序。

$X_{process}^k$	1	2	1	3	1	2	3	3
$X_{machine}^k$	2	1	4	2	3	1	5	3

图2 初始化学生

3.2 定义 $f(X)$

建立时间矩阵 T , 用于约束机器之间的加工顺序。时间矩阵存储每台机器加工对应零件时所需的时间, 将学生的机器层数据作为横坐标, 工序层数据作为纵坐标, 利用 $(X_{machine}^k(\eta), X_{process}^k(\eta))$ (其中 η 表示列) 调出对应的时间; 同时, 建立对应能耗矩阵 W , 存储每台机器加工对应零件时的耗能量, 利用 $(X_{machine}^k(\eta), X_{process}^k(\eta))$ (其中 η 表示列) 调出对应的能耗量。所有能耗量的总和即为目标函数 $f(X)$, 具体定义式如下:

$$f(X) = \sum_{i=1}^n \sum_{j=1}^p W(X_{machine}^i(j), X_{process}^i(j)) \quad (11)$$

式中: p 为编码后的列数。

3.3 TLBO 二次离散

由于离散制造车间模型中, 每个学生采用双层设计, 所以每次“教”和“学”过程分别进行之后, 需要将结果进行二次离散, 离散处理之后的结果才能满足调度要求。

3.3.1 工序层离散

离散过程大致同2.2.3小节的过程相同, 不同之处是工序的重复在该离散车间中是允许的。首先采用向下取整法, 然后根据每个零件的工序数, 随机置零 $m' (m'$ 为多余的个数) 个 $y' (y'$ 为多出工序的零件号), 其对应的机器层同时置零。假设零件数为 N , 每个零件的工序总数为 N_i , 统计每个零件出现的个数 h' , 若 $h' < N_i$, 则随机从工序层为零的位置中挑选出 $(h' - N_i)$ 个置为 i , 该过程具有随机性。

3.3.2 机器层离散

将机器层的数据先采用取整法处理, 然后找出该层中为零的位置, 根据工序层离散后的对应的零件号, 将可以用于加工的机器数, 产生 m 种调度安排。尝试每种调度安排, 比对 $f(X)$ 的值, 将取得最小值的调度安排输出, 作为ITLBO算法各个阶段的运算结果。

4 实验结果及分析

本文提出的ITLBO算法采用MATLAB程序编写,程序的运行环境为cpu 3.40 GHz,内存4 GB,软件为MATAB R2014a。为了验证所提算法的可行性,选取实际生产中的真实数据,选取典型的群智能算法:粒子群算法(PSO)和鸡群算法(CSO),同

时选取为改进的教与学算法(TLBO),通过实验仿真与所提出的改进算法进行比较。

4.1 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8台机器,6个零件,总共需要26道工序。

表1 零件工序加工信息表

零件	工序	加工所需耗能($w/kw.h$) / 所需时间(t/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给出了每台机器加工期间待机期间的单位耗能情况。

表2 机器单位时间待机耗能/kw.h

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

考虑到算法运行的时间问题,将迭代次数设为

6 000次,学生数为20,循环迭代数设为50,未改进的教与学算法参数设置保持一致。结合实际生产需要,将机器的最大完工时间设为85,防止算法寻优过程中生成的加工时间,从而导致生成的方案脱离实际。机器的最大完工时间可以根据实际需要调整,灵活性较大。由于PSO、CSO算法的差异性,除了迭代次数和循环迭代次数与TLBO相同外,需

要对这两种算法设置另外的参数, 其中, 将 PSO 算法的参数设置为: $C_1 = C_2 = 2.0$, $w_{max} = 0.9$, $w_{min} = 0.4$, 将 CSO 算法的参数设置为: 种群规模为 20 只, 其中公鸡 4 只, 母鸡 12 只, 小鸡 4 只, $w_{max} = 0.9$, $w_{min} = 0.4$, $G = 10$, $R_{max} = 1$, $R_{min} = 0.1$ 。

4.2 实验结果及分析

在应用于离散制造车间的能效优化时, PSO 算法、CSO 算法、TLBO 算法和 ITLBO 算法的仿真结果如下述图和表所示, 表 3 列出了四种算法获得的机器总耗能的最优值和平均值, 从最优值和平均值两方面都能明显的看出 ITLBO 算法优于 PSO 和 CSO 这两种群智能算法, 相对于基础 TLBO 算法, ITLBO 算法改进效果明显。图 3 生成了迭代过程中获得的机器总耗能的平均值曲线, ITLBO 算法在求解过程中收敛性明显快于另外三种, 且迭代结果更优。图 4~7 是四种算法生成的最优调度方案的甘特图, 可以观察具体生产调度安排详情, 图 7 对比图 6、图 5 和图 4 的结果, ITLBO 的排产结果待机时间极大程度上低于 TLBO、PSO 和 CSO 的排产调度时间, 从而使待机耗能大幅度减少, 另外 ITLBO 排产结果的加工耗能明显低于另外两种。

表 3 三种算法获得的机器总耗能值 kw.h

算法	最优值	平均值
PSO	121.22	128.11
CSO	111.42	117.7
TLBO	106.33	114.6
ITLBO	100.33	108.11




图 3 四种算法的迭代仿真

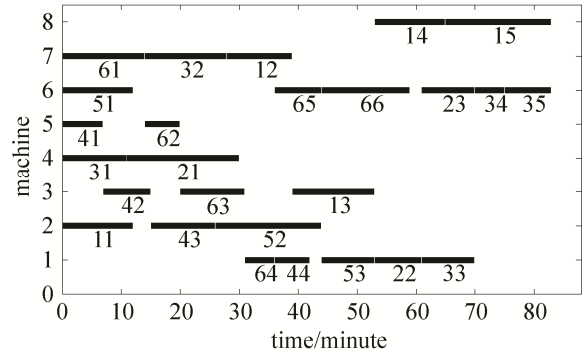


图 4 PSO 算法最优调度甘特图




图 5 CSO 算法最优调度甘特图




图 6 TLBO 算法最优调度甘特图




图 7 ITLBO 算法最优调度甘特图

5 结论

本文针对离散制造车间的能效优化提出了一种改进教与学优化算法(ITLBO),通过对 TLBO 的“教”和“学”两个阶段的离散化处理,使其能够更有效应用到离散制造车间能效优化中。同时,通过与选取的两种典型的群智能算法和未改进的教与学算法进行对比得出,改进教与学优化算法具有收敛速度快、调度结果更优、能效更高的特点,验证了该算法的可行性。因此,改进教与学优化算法应用到离散制造车间的能效优化中是可行的,为实际生产提供了理论依据。

参考文献:

- [1] Steuben J C, Iliopoulos A P, Michopoulos J G. Discrete element modeling of particle-based additive manufacturing processes [J]. *Computer Methods in Applied Mechanics and Engineering* (S0045-7825), 2016, 305(15): 537-561.
- [2] 王艳, 纪志成. 机床产品制造系统能效的最优控制 [J]. *控制理论与应用*, 2014, 31(10): 1431-1440. (Wang Yan, Ji Zhicheng. Optimal control of energy efficiency for machine tool manufacturing systems [J]. *Control Theory & Applications* (S1000-8152), 2014, 31(10): 1431-1440.)
- [3] 方水良, 姚嫣菲, 赵诗奎. 柔性车间调度的改进遗传算法 [J]. *浙江大学学报(工学版)*, 2012, 46(4): 629-635. (Fang Shuilang, Yao Yanfei, Zhao Shikui. Improved genetic algorithm for flexible job shop scheduling [J]. *Journal of Zhejiang University (Engineering Science)* (S1008-973X), 2012, 46(4): 629-635.)
- [4] Mahdavi A, Shiri M E. An augmented Lagrangian ant colony based method for constrained optimization [J]. *Computational Optimization & Applications* (S0926-6003), 2015, 60(1): 263-276.
- [5] Karthikeyan S, Asokan P, Nickolas S. A hybrid discrete firefly algorithm for multi-objective flexible job shop scheduling problem with limited resource constraints [J]. *The International Journal of Advanced Manufacturing Technology* (S0268-3768), 2014, 72(9/12): 1567-1579.
- [6] 彭建刚, 刘明周. 基于改进非支配排序的云模型进化多目标柔性作业车间调度 [J]. *机械工程学报*, 2014, 50(12): 198-205. (Peng Jiangan, Liu Mingzhou. Cloud Model Evolutionary Multi-objective Flexible Job-shop Scheduling Based on Improved Non-dominated Sorting [J]. *Journal of Mechanical Engineering* (S057-7-6686), 2014, 50(12): 198-205.)
- [7] 李耀华, 王磊. 基于改进遗传算法的飞机排班优化方法研究 [J]. *系统仿真学报*, 2016, 28(3): 620-626. (Li Yanhua, Wang Lei. Study on Aircraft Scheduling Optimization Based on Improved Genetic Algorithm [J]. *Journal of System Simulation* (S1004-731X), 2016, 28(3): 620-626.)
- [8] 田娜, 纪志成. 改进量子粒子群求解多目标柔性作业车间调度 [J]. *系统仿真学报*, 2015, 27(12): 2948-2957. (Tian Na, Ji Zhicheng. Improved Quantum-behaved Particle Swarm Optimization for Solving Multi-objection Flexible Job-Shop Scheduling Problems [J]. *Journal of System Simulation* (S1004-731X), 2015, 27(12): 2948-2957.)
- [9] Thammano A, Phuang A. A Hybrid Artificial Bee Colony Algorithm with Local Search for Flexible Job-Shop Scheduling Problem [J]. *Procedia Computer Science* (S1877-0509), 2013, 20(10): 96-101.
- [10] Mora A M, García-Sánchez P, Merelo J J, et al. Pareto-based multi-colony multi-objective ant colony optimization algorithms: an island model proposal [J]. *Soft Computing* (S1432-7643), 2013, 17(7): 1175-1207.
- [11] Fang K, Uhan N, Zhao F, et al. A new approach to scheduling in manufacturing for power consumption and carbon footprint reduction [J]. *Journal of Manufacturing Systems* (S0278-6125), 2011, 30(4): 234-240.
- [12] Rao R V, Savsani V J, Vakharia D P. Teaching-learning-based optimization: A novel method for constrained mechanical design optimization problems [J]. *Computer-Aided Design* (S0010-4485), 2011, 43(3): 303-315.
- [13] Rao R V, Savsani V J, Vakharia D P. Teaching-Learning-Based Optimization: An optimization method for continuous non-linear large scale problems [J]. *Information Sciences* (S0020-0255), 2012, 183(1): 1-15.
- [14] Rao R V, Patel V. An elitist teaching-learning based optimization algorithm for solving complex constrained optimization problems [J]. *International Journal of Industrial Engineering Computations* (S2251-712X), 2012, 3(4): 710-720.
- [15] Li J Q, Pan Q K, Mao K. A discrete teaching-learning-based optimisation algorithm for realistic flowshop rescheduling problems [J]. *Engineering Applications of Artificial Intelligence* (S0952-1976), 2015, 37(10): 279-292.