张禹珊, 赵刚, 万开毅, 等. 基于改进遗传算法的热轧计划优化研究[J]. 智能计算机与应用,2026,16(5):1-9. DOI:10.20169/j.issn.2095-2163.24071302

# 基于改进遗传算法的热轧计划优化研究

张禹珊[1,2], 赵 刚[1,2], 万开毅[1,2], 王子鹏[1,2]
(1 武汉科技大学 冶金装备及其控制教育部重点实验室, 武汉 430081;
2 武汉科技大学 机械传动与制造工程湖北省重点实验室, 武汉 430081)

**摘 要**: 为解决热轧过程中电能消耗和轧辊磨损的多目标热轧计划优化问题,建立以最小化耗电成本和板坯间规格跳跃惩罚值为目标的优化模型,为了高效求解该优化模型,提出了一种改进遗传算法(IGA)。该算法采用嵌入启发式规则的初始化策略以提高初始种群质量;基于 sigmoid 函数的自适应交叉变异操作以提高算法解集的广泛性和多样性;将精英选择与轮盘赌策略结合的选择策略以提高种群多样性并保留进化过程中的优质个体。为了测试改进算法的性能,以某钢厂实际生产数据为例进行求解,设计该算法与传统遗传算法、原始人工蜂群算法、模拟退火算法进行对比,从目标值均值、优化率和变异系数对实验结果进行分析,结果表明改进策略有效提升了遗传算法的探索性和稳定性;与传统遗传算法相比,所提出的改进算法优化率提高了 3.61%,耗电成本降低了 2.87%,即改进后的算法能有效节约能源成本,实现热轧计划优化问题的高效求解 。

**关键词**: 启发式算法; 多目标优化; 能源调度; 批量计划; 热轧
**中图分类号**: TF087 **文献标志码**: A **文章编号**: 2095-2163(2026)05-0001-09

# Research on optimization of hot rolling schedule based on improved genetic algorithm

ZHANG Yushan[1,2], ZHAO Gang[1,2], WAN Kaiyi[1,2], WANG Zipeng[1,2]
(1 Key Laboratory of Metallurgical Equipment and Control Technology, Ministry of Education, Wuhan University of Science and Technology, Wuhan 430081, China; 2 Hubei Key Laboratory of Mechanical Transmission and Manufacturing Engineering, Wuhan University of Science and Technology, Wuhan 430081, China)

**Abstract**: In order to solve the multi-objective hot rolling planning optimization problem of power consumption and roll wear in the hot rolling process, an optimization model is established to minimize power consumption cost and the penalty value of specification jump between slabs. In order to solve the optimization model efficiently, an improved genetic algorithm (IGA) is proposed. The algorithm adopts an initialization strategy embedded with heuristic rules to improve the quality of the initial population. The adaptive crossover and mutation operation based on the sigmoid function to enhance the universality and diversity of the algorithm solution set. A selection strategy that combines elite selection with a roulette strategy to improve population diversity and retain quality individuals in the evolutionary process. To evaluate the enhanced algorithm's performance, real production data from a steel mill was used as an example to solve the algorithm. The original artificial bee colony method, the simulated annealing algorithm, and the conventional genetic algorithm were all used in the construction of the algorithm. Utilizing the mean goal value, optimization rate, and coefficient of variance, the experimental findings were examined. The suggested improved algorithm outperforms the conventional genetic algorithm in terms of optimization rate by 3.61% and power consumption cost by 2.87%. In other words, the improved algorithm effectively reduces energy costs and achieves an efficient solution to the hot rolling plan optimization problem.
**Key words**: heuristic algorithm; multi-objective optimization; Energy dispatching; batch planning; hot rolling

## 0 引 言

在钢铁生产工序中,热轧主要通过加热、粗轧、精轧等操作将板坯加工成更高精度的钢铁成品。热轧批量计划的编制要求是在考虑复杂工艺约束的基础上,确定板坯的轧制顺序,以提高成品质量,降低能源消耗,从而提高企业的整体效益[1]。

目前,热轧批量计划问题已受到国内外学者的广

**基金项目**: 国家自然科学基金(52175480)。
**作者简介**: 赵 刚(1976—),男,博士,教授。主要研究方向:绿色制造。Email:jasonzhao@wust.edu.cn。
**通信作者**: 张禹珊(2001—),女,硕士。主要研究方向:钢铁热轧生产调度,绿色制造。Email:19917625380@163.com。
**收稿日期**: 2024-07-13

泛关注。Tu 等[2]提出了一种考虑奖励收集车辆路径问题模型,该模型考虑了预热材料和主料的合理安排,且基于可变领域禁忌搜索的两阶段算法对该模型进行求解,实验验证了算法的可行性;张旭君等[3]构建了一种综合批量计划约束模型,利用显性基因约束的遗传算法进行优化求解,提高了热轧批量计划的可行性;谭貌等[4]研究了热轧工序两阶段优化问题,第一阶段以最小化板坯间规格跳跃惩罚为目标进行研究,第二阶段以最小化电价成本为目标进行研究,并采用传统遗传算法进行求解;董广静[5]建立了轧制计划模型,考虑了板坯工艺约束和烫辊材与主体材的合理安排,提出了一种基于单亲遗传算子的免疫算法进行求解,结果表明该算法有效降低了钢坯库的搬运次数;Liu 等[6]考虑最小轧制单元数、工艺规程及每吨钢铁的最低电耗等约束条件,建立多目标热轧生产调度模型,并采用模拟退火算法和粒子群混合算法对模型进行求解;幸火林等[7]以轧制单元数和紧邻轧制板坯间总惩罚最小化为目标,提出了一种改进遗传算法,父代双亲通过两交换启发式交叉算子生成惩罚值更小的子代,以提高算法的寻优能力;王明伟等[8]以最小化总余材长度和最小化最大完工时间为优化目标构建非线性规划数学模型,设计了具有初始排序策略和局域优化策略的人工蜂群(Artificial Bee Colony, ABC)算法进行求解。

以上大部分热轧调度研究主要以轧制单元数和板坯间规格跳跃惩罚最小为目标,部分研究结合分时电价的实际情况考虑了轧制计划对耗电成本的影响,在一定程度上降低了耗电成本但缺少对算法的改进。在算法层面,选择精确算法求解小规模案例时,能快速获得最优解,但随着案例规模增大,精确算法求解时间过长,难以满足实际需求;而启发式算法具有快速求解的优点,但存在解的质量和稳定性较差等问题。因此,本文设计了一种改进遗传算法,该算法采用嵌入启发式规则的种群初始化方法,以提高初始种群质量;采用顺序 OX 交叉、随机片段交叉变异和基于 Sigmoid 函数的自适应交叉变异率以提高算法解集的广泛性和多样性;采用精英选择和轮盘赌结合的选择策略以提高种群多样性并保留了进化过程中的优质个体,最后通过实际案例验证了改进算法的优越性。

## 1 热轧批量计划模型的建立

### 1.1 问题描述

热轧主要通过轧辊的压力作用对符合工艺要求的连铸钢坯进行轧制以产出带钢。从生产计划角度出发,合理的热轧编制计划对于提高生产效率,降低能源成本具有至关重要的作用[9]。图 1 所示为热轧批量计划编制过程。

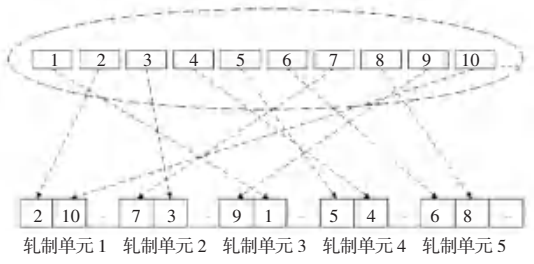



**图 1 热轧批量计划编制过程**

**Fig. 1 Hot rolled batch planning process**

图 1 中,将一组热轧计划分为多个轧制单元计划,每个轧制单元由使用相同工作辊轧制的板坯组合而成。在一个完整的轧制单元中,“主体材”作为主要组成部分,其轧制板坯规格较薄,宽度较宽,硬度较大,且在轧制过程中需满足表 1 所示的工艺要求。

热轧计划编制的目标之一为最小化轧辊的磨损,即最小化板间差异,从而极大程度延长轧辊寿命,降低生产成本[10]。

**表 1 主体材规格约束条件**

**Table 1 Main material specification constraints**

| 序号 | 规格 | 主体材 |
|---|---|---|
| 1 | 长度 | 遵循一定限制 |
| 2 | 宽度 | 保持非增方向变化,跳跃幅度应尽可能小,跳跃差一般不超过 25 cm,宽度反弹时跳跃差应保持在 15 cm 以下。 |
| 3 | 厚度 | 变化应平稳,避免反复跳跃,最好保持非减方向变化。 |
| 4 | 硬度 | 可以逐渐递增或递减,但不允许反复跳跃,尽可能平稳进行。 |

其次,热轧批量计划的编制需考虑能源成本,电能是热轧工序中消耗的主要能源,约占能源消耗的 15%,且耗电量会随着热轧计划中轧制单元和轧制顺序的改变而有所差异。同时由于分时电价的存在,不同时间段消耗同等电量产生的成本也会有所不同,如图 2 所示。

综上所述,热轧计划中轧制单元和板坯顺序的编制对企业降低能源成本有重要作用。目前,钢铁厂大多基于人工经验制定轧制计划,缺乏考虑热轧计划对能源成本和成品质量的影响。针对这一问题,本文以主体材为研究对象,在满足生产工艺要求的基础上,以最小化板坯间规格跳跃惩罚以及轧制过程中产生的耗电成本为目标建立热轧计划模型。

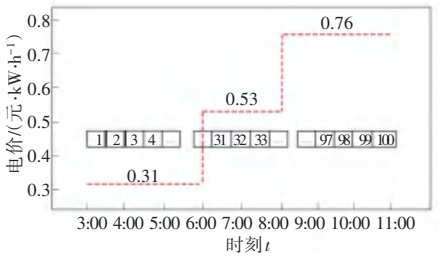



**图 2　分时电价下热轧计划示意图**

**Fig. 2　Schematic diagram of the hot rolling plan under time-of-use-tariffs**

## 1.2　模型构建

### 1.2.1　目标函数的建立

建立热轧生产调度问题的数学优化模型前，先对模型参数符号进行说明(见表 2)。

本文把热轧批量计划的编制问题视为带容量的 VRP 模型，每个轧制计划代表一个可行的路线方案，板坯视为需要访问的客户。结合系统优化理论模型，针对热轧过程中耗电成本和板坯间规格跳跃惩罚值进行双目标优化，目标函数如下：

$$\min f = \min(F_1 + F_2)$$

$$F_1 = \sum_{j=1}^{N}\sum_{i=1,i\neq j}^{N}\{P^{w}\Delta W_{i,j} + P^{G}\Delta G_{i,j} + P^{H}\Delta H_{i,j}\}\cdot y_{ik}\cdot x_{ik}$$

$$F_2 = \sum_{t=1}^{r}\sum_{i=1}^{N}\{C_{\mathrm{ele},t}(P_{\mathrm{ele},t})\} \quad (1)$$

式中：$F_1$ 为板坯间规格跳跃惩罚项总和，$N$ 为待轧制的板坯总数，$F_2$ 为热轧过程的耗电成本总和。

### 1.2.2　确定双目标权重

由于本研究热轧问题的优化目标为双目标，需要先将多目标优化数学模型转化为单目标优化数学模型。本研究通过层次分析法(AHP)-专家评分法-熵值法设定双目标权重，具体步骤如下：

1)初始权重-层次分析法

结合 AHP1-9 标度法[11]对耗电成本与板坯间规格跳跃惩罚值进行重要度评价，得出的重要度判断矩阵见表 3。

**表 2　模型符号和决策变量**

**Table 2　Symbols and decision variables**

| 符号 | 含义 |
|---|---|
| $i,j$ | 板坯编号，$i,j \in I$； |
| $k$ | $k$ 为轧制单元编号，$k \in K$； |
| $f$ | 目标函数值； |
| $F_1$ | 板坯间规格跳跃惩罚值 |
| $F_2$ | 耗电成本 |
| $I$ | 所有板坯的集合，$I = \{1,2,\cdots,N\}$； |
| $N$ | 板坯总量； |
| $T$ | 轧制周期； |
| $K$ | 所有轧制单元序号的集合，$K = \{1,2\cdots,M\}$； |
| $L_{\max}$ | 每个轧制单元的长度限制，取 10 km； |
| $P^{W}$ | 同一轧制单元的连续轧制的板坯间存在的宽度跳跃造成的惩罚值； |
| $P^{G}$ | 同一轧制单元的连续轧制的板坯间存在的厚度跳跃造成的惩罚值； |
| $P^{H}$ | 同一轧制单元的连续轧制的板坯间存在的硬度跳跃造成的惩罚值； |
| $W_{\max}$ | 同一单元内连续轧制的板坯间宽度跳跃上限值； |
| $G_{\max}$ | 同一单元内连续轧制的板坯间厚度跳跃上限值； |
| $H_{\max}$ | 同一单元内连续轧制的板坯间硬度跳跃上限值； |
| $P_{\mathrm{ele},i}$ | 第 $i$ 块板坯的耗电量； |
| $C_{\mathrm{ele},t}$ | $t$ 时刻的电价情况； |
| $\Delta W_{i,j}$ | $\lvert W_i - W_j\rvert$ 表示同一轧制单元相邻板坯宽度的变化值 |
| $\Delta G_{i,j}$ | $\lvert G_i - G_j\rvert$ 表示同一轧制单元相邻板坯厚度的变化值 |
| $\Delta H_{i,j}$ | $\lvert H_i - H_j\rvert$ 表示同一轧制单元相邻板坯硬度的变化值 |
| | 决策变量 |
| $X_{ijk}$ | 当板坯 $j$ 排列在板坯 $i$ 后且同属于一个轧制单元 $k$ 时取值为 1，否则为 0 |
| $Z_{ijk}$ | 当板坯 $j$ 排列在板坯 $i$ 后宽度相同且同属于一个轧制单元时 $k$ 取值为 1，否则为 0 |
| $Y_{ik}$ | 当板坯 $i$ 属于轧制单元 $k$ 时取值为 1，否则为 0。 |

**表 3　指标重要度判断矩阵表**

**Table 3　Matrix for judging the importance of indicators**

| 指标名称 | 耗电成本 | 差异惩罚 |
|---|---|---|
| 耗电成本 | 1 | 5 |
| 差异惩罚 | 1/5 | 1 |

采用方根法计算指标权重，步骤如下：

计算判断矩阵每行元素的乘积：

$$M_y = \prod_{y=1}^{n} a_{yz} \quad (2)$$

计算乘积的 $n$ 次方根，得到初始权重向量：

$$w_y^{'} = \left(\prod_{y=1}^{n} a_{yz}\right)^{\frac{1}{n}} \tag{3}$$

对初始权重进行归一化处理,得到最终初始权重:

$$w_y = \frac{w_y^{'}}{\sum_{y=1}^{n} w_y^{'}} \tag{4}$$

根据公式(2)~(4)计算得到耗电成本以及差异惩罚的初始权重 $w_1^* = 0.83, w_2^* = 0.17$。

2)最终权重-熵值法

通过多名相关领域专家对所有指标进行评分,计算指标 $X_{xy}$ 在各指标 $z$ 下的权重。

$$P_{yz} = \frac{X_{yz}}{\sum_{y=1}^{y} X_{yz}},\ z = 1,2,\cdots,n \tag{5}$$

其中 $X_{yz}$ 为第 $y$ 个评价对象在第 $z$ 个指标下的评分。

计算各指标的熵值:

$$e_z = -u\sum_{y=1}^{y} P_{yz}\ln P_{yz},\ z = 1,2,\cdots,n \tag{6}$$

其中,$u = \frac{1}{\ln y}(u > 0, 0 \leqslant P_{yz} \leqslant 1)$,假设当 $P_{yz} = 0$ 时,$P_{yz}\ln P_{yz} = 0$。

计算差异性因素:

$$g_z = 1 - e_z \tag{7}$$

利用差异性因素对初始权重进行调整:

$$w_z^* = w_y^{'} \times g_z \tag{8}$$

对上式进行归一化处理,得到最终权重:

$$w = \frac{w_z^*}{\sum_{z=1}^{n} w_z^*} \tag{9}$$

表 4 所示为各指标权重表。

**表 4 各指标最终权重表**

**Table 4 Weight table of each indicator**

| 指标名称 | 熵值 $e_z$ | 差异性因素 $g_z$ | 初始权重 $w_y$ | 调整权重 $w_z{}^*$ | 归一化 $w$ |
|---|---|---|---|---|---|
| 耗电成本 | 0.992 2 | 0.007 8 | 0.83 | 0.006 474 | 0.810 6 |
| 跳跃惩罚 | 0.991 1 | 0.008 9 | 0.17 | 0.001 513 | 0.189 4 |

由于模型设定的耗电成本和差异惩罚指标差异过大,无法直接通过设置权重将两者相加计算综合函数值,故采用数据无量纲化处理中的极小值法对双目标进行处理[12]。将算法模型通过 MATLAB 进行求解,多次运行后,分别记录当目标仅为耗电成本最小时调度模型的耗电成本数值和目标仅为板坯间规格跳跃调度模型的最小惩罚值,之后运行多目标调度模型,将程序运行后所得到的结果的每一个目标值均除以上述记录的对应目标的最小数值,由此可将热轧生产调度模型中双目标数学模型转换为单目标数学模型,如下式所示:

$$\min f = \min(0.189\,4 \cdot \frac{f_1}{10\,492.34} + 0.810\,6 \cdot \frac{f_2}{4\,144.72}) \tag{10}$$

其中,$f_1$ 为跳跃惩罚目标值,$f_2$ 为耗电成本目标值。

1.2.3 约束条件

1)确保每一块板坯必须被分配,并且只能分配到一个轧制单元:

$$\sum_{k=1}^{N} y_{ik} = 1, \forall i \in \{1,2,3,\cdots,N\}, \forall k \in \{1,2,3,\cdots,M\} \tag{11}$$

2)保证每个轧制单元内板坯的总长度不超过该轧制单元规定轧制的最大长度:

$$\sum_{i=1}^{N}(L_i \times y_{ik}) \leqslant L_{\max},\ \forall i \in \{1,2,3,\cdots,N\}, \forall k \in \{1,2,3,\cdots,M\} \tag{12}$$

3)在同一轧制单元中,连续轧制的板坯按照宽度递减排列,且相邻板坯的宽度差异不能超过宽度跳跃上限。

$$0 \leqslant x_{ijk}(W_i - W_j) \leqslant W_{\max}, \forall i,j \in \{1,2,3,\cdots,N\}, \forall k \in \{1,2,3,\cdots,M\} \tag{13}$$

4)在同一轧制单元中,要求连续轧制板坯的厚度差异不能超过厚度跳跃上限:

$$0 \leqslant x_{ijk}(G_i - G_j) \leqslant G_{\max}, \forall i,j \in \{1,2,3,\cdots,N\}, \forall k \in \{1,2,3,\cdots,M\} \tag{14}$$

5)在同一轧制单元中,要求相邻板坯硬度差异不能超过硬度跳跃上限:

$$0 \leqslant x_{ijk}(H_i - H_j) \leqslant H_{\max}, \forall i,j \in \{1,2,3,\cdots,N\}, \forall k \in \{1,2,3,\cdots,M\} \tag{15}$$

6)在轧制过程中,每块板坯只能经过一次轧制:

$$\sum_{i=1}^{N} x_{ijk} \cdot \sum_{j=1}^{N} x_{ijk} = 1, \forall i,j \in \{1,2,3,\cdots,N\}, \forall k \in \{1,2,3,\cdots,M\} \tag{16}$$

7)实际热轧过程中电价根据时间的变化情况。

$$C_{\text{ele},t}\begin{cases} C_0, t \in (0,T_0], C_2, t \in (T_1,T_2] \\ C_1, t \in (T_0,T_1] \end{cases} \tag{17}$$

## 2 热轧调度计划模型的求解

### 2.1 算法编制及解码设计

在求解过程中采用基于板坯位置映射的单层编

码方式表征[13-14]，每一条染色体表示一种板坯轧制顺序，染色体的长度为需要轧制的板坯总数 $N$。热轧批量计划中轧制单元数量为 $K$，不同的轧制单元间用虚拟板坯“#”隔开，则需要在热轧批量计划中插入 $K$ 个虚拟板坯“#”，如图 3 所示，其中染色体上每个数字代表板坯编号 $n$，对应数字排布顺序代表板坯的轧制顺序，每个基因代表在轧制单元 $k$ 中第 $r$ 顺序轧制的板坯 $n$。假设 $N=9$，$A=4$，板坯热轧计划可以按照如下顺序进行编码：[2 7 # 8 3 6 # 1 9 # 5 4]。

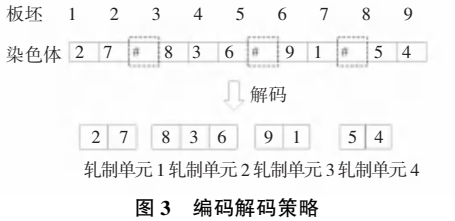



**图 3　编码解码策略**

**Fig. 3　Strategy for encoding and decoding**

根据编码方式还原其对应的轧制顺序可知其解码的热轧批量计划为：$K_1$ 轧制单元板坯顺序为 2、7；$K_2$ 轧制单元板坯顺序为 8、3、6；$K_3$ 轧制单元板坯顺序为 9、1；$K_4$ 轧制单元板坯顺序为 5、4；板坯排列顺序为 2、7、8、3、6、1、9、5、4。

## 2.2　种群初始化的启发式规则

初始种群的质量会影响算法的收敛速度与搜索性能，传统遗传算法（GA）在初始化种群时采用随机初始化的方法，该方法未考虑时间约束，且随机生成的种群在空间上表现不均，降低了生成初始解的效率[15-16]。结合本文求解模型具有种群数量庞大，约束复杂的特点；需保证每个轧制单元轧制板坯总长度不超过限制，及同一个轧制单元内板坯宽度呈倒梯形递减排列，为降低随机初始化带来的不确定性，提高遗传算法的求解效率，对遗传算法的种群初始化策略进行改进，改进过程如下：

（1）任意选择一块板坯 $i_1$，直接将其添加到轧制计划当中，此时轧制板坯数目为 1，轧制单元数为 1。

（2）在剩余板坯中再随机选择一块板坯 $i_2$，对比板坯 $i_1$ 和 $i_2$ 的宽度，若 $i_2$ 的宽度大于 $i_1$，则将其放置到 $i_1$ 位置前，反之，则将其加入到 $i_1$ 之后。

（3）计算该轧制单元内所有板坯的总长度，若添加新板坯 $i$ 后，轧制单元内板坯总长度超出轧制单元长度约束，则重新建立新的轧制单元，将板坯 $i$ 加入其中。

（4）重复（2）、（3），直到所有板坯被加入到轧制单元当中，总共产生 $A$ 个轧制单元。改进后种群初始化流程如图 4 所示。

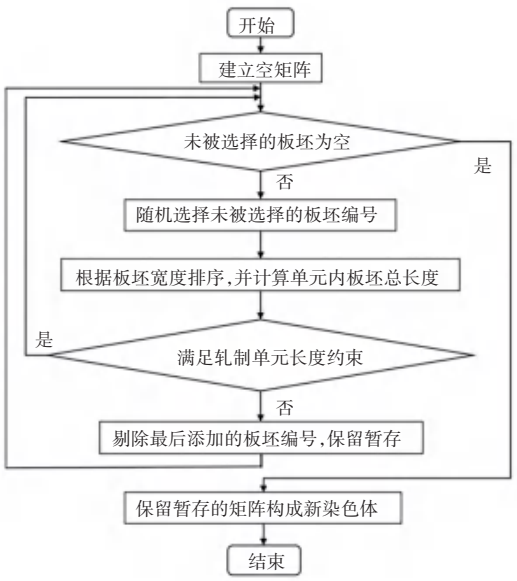



**图 4　IGA 算法初始化种群流程**

**Fig. 4　Population initialization process of IGA algorithm**

## 2.3　适应度函数

个体的适应度值大小决定了个体能否被保留和继续进化，个体适应度值越大，被保留下来的概率越大[17]。本文以目标函数的倒数作为个体的适应度，惩罚值和耗电成本越大则适应度值越小。适应度计算公式如下：

$$fit(n)=\frac{1}{\min f}=\frac{1}{\min\left(0.1894\cdot\dfrac{f_1}{10\,492.34}+0.8106\cdot\dfrac{f_2}{4\,144.72}\right)} \tag{18}$$

## 2.4　遗传算子的设计

### 2.4.1　选择算子

选择策略决定了个体是否能保留下来继续进化。常用的轮盘赌选择法是概率选择的一种，个体被选择的概率与其适应度值大小成正比，但由于该方法是基于概率随机选择，有时适应度值大的个体也无法被选中。相比于轮盘赌法，精英选择策略能将适应度值最好的个体保留下来继续进化，缺点是局部最优个体不易被淘汰[18]。鉴于上述两种方法的优缺点，本文采用精英选择策略和轮盘赌法结合的方式进行个体的选择，具体操作步骤如下：

（1）将交叉、变异操作产生的新个体与父代种群合并，并删除重复个体，得到种群 $M$；

（2）将种群 $M$ 中的个体按照适应度大小降序排列；

（3）从排列中选取数量为 $N/2$、适应度值最大的个体；

(4)根据公式计算($M-N/2$)个剩余个体被选中的概率:

$$p_a=\frac{f_a}{\sum_{a=1}^{M-N/2} f_i}(a=1,2,\cdots,M-N/2) \quad (19)$$

(5)使用轮盘赌法选取 $N/2$ 个个体;

(6)将(3)和(5)中得到的个体合并组成新的种群。

2.4.2 交叉算子

结合模型特点采用顺序 OX 交叉策略来实现交叉操作,随机选择一对父代染色体,选取单位长度为 4 的相同位置基因段进行交叉,其具体操作如图 5 所示。

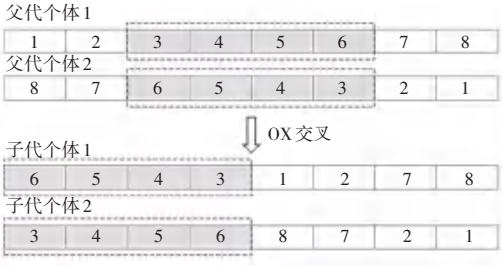



**图 5 OX 交叉策略流程**

**Fig. 5 Process of OX cross strategy**

2.4.3 变异算子

如图 6 所示,采用随机片段交叉变异方式,将同一染色体上两个基因之间片段互换顺序,以达到随机变异的效果,通过上述设计可保证变异后每条染色体上的每个基因不相同,即对应每个序列中每个板坯仅允许被轧制一次。




**图 6 随机片段交叉变异策略流程**

**Fig. 6 Process of random fragment cross mutation strategy**

2.4.4 非法解的处理

交叉和变异后产生的新种群中会产生不满足模型约束的不可行解,因此需要对这部分染色体进行修复。调整板坯轧制顺序,将不满足约束的板坯序列重新组合为满足约束的轧制单元,保证交叉和变异后产生的新种群满足染色体解的可行性。

2.4.5 自适应操作及交叉、变异概率确定

优秀的交叉变异有助于提高解的质量,在算法初期,由于种群质量较差,应给予高交叉变异率以增加种群的多样性,从而防止过早收敛于局部最优解;在迭代后期,算法逐渐接近最优解,此时应适当降低交叉变异概率,以保护已获得的优良基因。因此本文提出了一种基于 sigmoid 函数的自适应交叉变异率策略[19],具体公式如下:

$$P_c=\begin{cases}0.1\times\dfrac{1}{P_{cm}+e^{\frac{fit^b(n)-fit_{\text{avg}}}{fit_{\max}-fit_{\text{avg}}}}}+0.9, & fit(n)>fit_{\text{avg}}\\ 0.9, & fit(n)\leqslant fit_{\text{avg}}\end{cases} \quad (20)$$

$$P_m=\begin{cases}0.1, & fit(n)>fit_{\text{avg}}\\ 0.1\times\left(1-\dfrac{1}{P_{km}+e^{\frac{fit(n)-fit_{\text{avg}}}{fit_{\max}-fit_{\text{avg}}}}}\right), & fit(n)\leqslant fit_{\text{avg}}\end{cases} \quad (21)$$

其中,$fit(n)$ 为当前个体适应度值;$fit_{\text{avg}}$、$fit_{\max}$ 和 $fit_{\min}$ 分别为种群适应度均值、种群适应度最大值及最小值;$fit^b(n)$ 为两个父代中较大的适应度值。通常交叉率最优范围在[0.9,1],式(20)中 $P_{cm}$ 基础交叉率取值范围为[0.5,1]。当适应度值大于均值时,表示新生成的子代解较差,应取较大的交叉率,反之则为 0.9。式(21)中 $P_{km}$ 为基础变异率,范围为[0.05,0.1],变异率最佳取值范围是[0,0.1],自适应变化原理与交叉率相同。

## 2.5 IGA 算法流程图

在求解热轧计划编制问题时,改进遗传算法的操作步骤如图 7 所示。

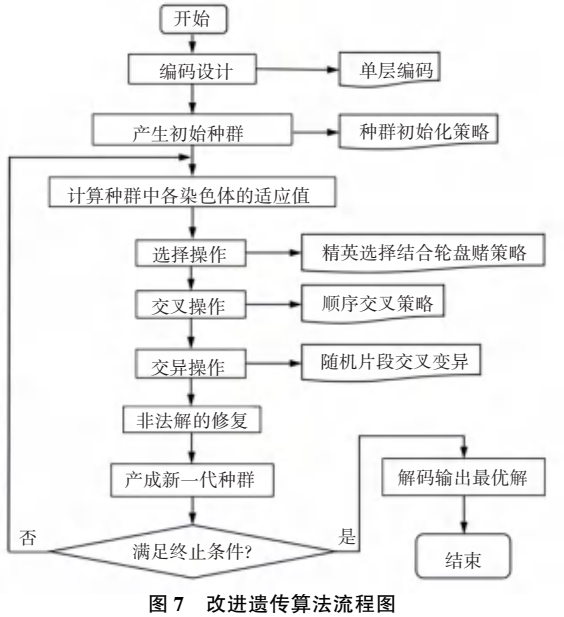



**图 7 改进遗传算法流程图**

**Fig. 7 Flowchart of the improved genetic algorithm**

# 3 实验结果与分析

## 3.1 实验设计

由于每块板坯的轧制时间会受环境、板坯质量

等因素的影响，为便于模型求解，根据轧制规律规定轧制每块板坯所需时间近似为 5 min。表 5～表 7 分别表示板坯因宽度、硬度和厚度差异所带来的惩罚区间值[20]。

**表 5　宽度跳跃惩罚**

**Table 5　Width jump penalty**

| 下跳量/mm | 0～25 | 26～55 | 56～90 | 91～150 |
|---|---|---|---|---|
| 惩罚值 | 1.0 | 3.0 | 5.0 | 7.0 |

**表 6　硬度跳跃惩罚**

**Table 6　Hardness jump penalty**

| 硬度等级 | 1 | 2 | 3 | 4 | 5 |
|---|---|---|---|---|---|
| 惩罚值 | 10 | 16 | 20 | 24 | 30 |

**表 7　厚度跳跃惩罚**

**Table 7　Thickness jump penalty**

| 厚度跳跃量/mm | 上跳惩罚 | 下跳惩罚 |
|---|---|---|
| 0～0.06 | 200 | 400 |
| 0.060 1～0.15 | 300 | 600 |
| 0.150 1～0.24 | 400 | 800 |
| 0.240 1～0.45 | 800 | 1 000 |
| 0.450 1～3.00 | 1 000 | 2 000 |

从表中可以看出规定宽度跳跃值在 0～150 mm 之间，硬度跳跃值不能超过 5，厚度跳跃区间为 [-3,3 ]mm。

表 8 为 A 钢厂的分时段电价基本情况，在生产过程中将一天 24 h 分为 6 个电价区，分别为两个峰段，三个平段，一个谷段。

**表 8　A 钢厂分时段电价情况**

**Table 8　Electricity price by time period at steel plant A**

| 电价区间 | 时间段 | 电价/(元·(kW·h)$^{-1}$) |
|---|---|---|
| 峰段 | 8:00-11:00,16:00-21:00 | 0.76 |
| 平段 | 6:00-8:00,11:00-16:00,21:00-22:00 | 0.53 |
| 谷段 | 22:00-6:00(次日) | 0.31 |

为验证所提智能算法的性能，将该算法传统遗传算法(GA)、原始人工蜂群算法(ABC)、模拟退火算法(SA)进行对比实验。所有算法的终止条件统一设为解码 200 次，仿真环境为 Window 10 系统下的 MATLAB R2019a，处理器为 Inter Core i5。

### 3.2　参数校验

本文采用全因子设计实验来校准参数。首先，用所有参数值的组合对 10 个不同的实例进行 10 次求解。实验完成后，进行多因素方差分析(ANOVA)，表 9 展示了测试算法所用的参数以及各个参数的具体取值。

### 3.3　优化结果分析

#### 3.3.1　IGA 与 GA 结果对比

以实际生产过程中 A 钢厂待加工的 100 块板坯为例，各算法独立运行 20 次，分别记录在传统遗传算法(IGA)和改进遗传算法(GA)下的最优目标函数值，并计算算法的进化率，结果见表 10。由表 10 可知，相较于传统遗传算法，改进遗传算法计算获得的目标函数值更趋近于 1，说明优化算法对跳跃惩罚值和耗电成本的寻优效果更好，算法进化率约为 1.66% 。

**表 9　算法参数及取值**

**Table 9　Algorithm parameters and values**

| 算法名称 | 算法参数 | 参数取值 |
|---|---|---|
| 改进遗传算法 | 种群数量 | 100 |
| | 子代数量 | 100 |
| 遗传算法 | 种群数量 | 100 |
| | 子代数量 | 100 |
| | 交叉概率 | 0.85 |
| | 变异概率 | 0.15 |
| 人工蜂群算法 | 种群数量 | 10 |
| | 交叉概率 | 0.80 |
| | 突变概率 | 0.06 |
| 模拟退火算法 | 初始温度 | 10 |
| | 冷却率 | 0.95 |
| | 终止温度 | 0.000 1 |

**表 10　传统遗传算法和改进遗传算法结果对比**

**Table 10　Comparison of Results between GA and IGA**

| 实验号 | 板坯数/块 | GA | IGA | 进化率/% |
|---|---|---|---|---|
| 1 | 100 | 1.072 9 | 1.045 1 | 2.59 |
| 2 | 100 | 1.056 0 | 1.048 9 | 0.67 |
| 3 | 100 | 1.079 1 | 1.047 4 | 2.94 |
| 4 | 100 | 1.067 9 | 1.052 1 | 1.48 |
| 5 | 100 | 1.066 3 | 1.051 6 | 1.38 |
| 6 | 100 | 1.073 4 | 1.053 4 | 1.86 |
| 7 | 100 | 1.080 6 | 1.049 1 | 2.92 |
| 8 | 100 | 1.067 2 | 1.056 5 | 1.00 |
| 9 | 100 | 1.057 0 | 1.054 8 | 0.21 |
| 10 | 100 | 1.067 4 | 1.042 2 | 2.36 |
| 11 | 100 | 1.078 6 | 1.050 1 | 2.64 |
| 12 | 100 | 1.053 7 | 1.052 0 | 0.16 |
| 13 | 100 | 1.059 6 | 1.039 9 | 1.86 |
| 14 | 100 | 1.083 2 | 1.049 7 | 3.09 |
| 15 | 100 | 1.054 9 | 1.051 5 | 0.32 |
| 16 | 100 | 1.067 7 | 1.049 3 | 1.72 |
| 17 | 100 | 1.085 2 | 1.046 1 | 3.60 |
| 18 | 100 | 1.064 8 | 1.055 4 | 0.88 |
| 19 | 100 | 1.055 7 | 1.054 3 | 0.13 |
| 20 | 100 | 1.071 3 | 1.056 6 | 1.37 |
| Ave | | 1.068 1 | 1.050 3 | 1.66 |

针对两种算法中结果表现最优的迭代过程进行分析，最优迭代曲线如图 8 所示。

图 8 中采用传统遗传算法的第一代种群最优目标函数值为 1.419,经 97 次迭代后收敛致 1.053 7,优化率(即初始目标函数值与迭代后目标函数值的差值与初始目标函数值之比)为 25.74%。采用改进遗传算法的第一代种群最优目标函数值为 1.418,经过 22 次迭代优化后的目标函数值为 1.039 9,优化率为 26.67%。对比两条迭代曲线的寻优趋势可以看出,传统遗传算法的目标函数值虽然在迭代过程中呈下降趋势,但寻优速度较慢,效果较差,改进遗传算法的寻优速度更快,寻优结果更好,在第 22 代即完成收敛,由此说明改进遗传算法可以提高遗传算法的求解效率,能更有效地求解热轧计划调度问题。

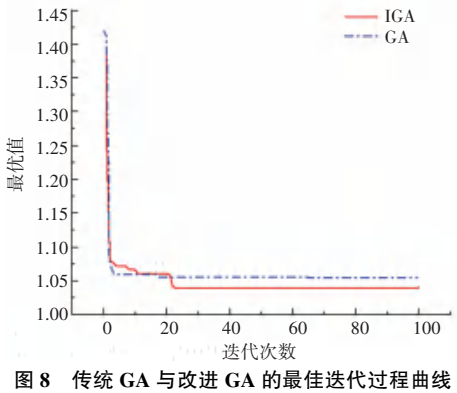



**图 8 传统 GA 与改进 GA 的最佳迭代过程曲线**

**Fig. 8 Optimal iteration process curves of traditional GA and improved IGA**

图 9 为两种遗传算法耗电成本对比结果,采用传统遗传算法计算得到的耗电成本为 4 388 元,改进遗传算法的耗电成本最小为 4 262 元。其中峰段耗电成本为 1 743 元,平段耗电成本为 1 108 元,谷段耗电成本为 1 411 元,算法改进后耗电成本较传统遗传算法降低了 2.87%。因此从实际生产角度出发,应选择改进遗传算法编制的热轧批量计划安排生产,这种方法通过将高耗电负荷的轧制单元安排在低谷电价时段,将低耗电负荷的轧制单元错峰安排在高峰电价时段进行生产,达到“削峰填谷”的作用。

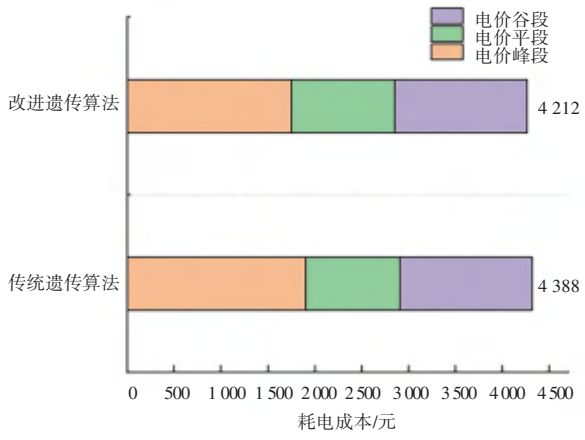



**图 9 两种遗传算法的热轧过程耗电成本对比**

**Fig. 9 Comparison of power consumption costs of two genetic algorithms in the hot rolling process**

### 3.3.2 IGA 与其他算法对比

为了更好地评估 IGA 算法的性能,将 IGA 与另外 3 种智能算法进行对比,各算法分别对 3 种案例连续求解 20 次,计算目标函数结果的最大值、平均值和最小值结果见表 11。

从表 11 可以看出,IGA 的 Max、Min 和 Ave 值都优于其他智能算法,故所提出的改进算法具有优越性。为进一步评估算法性能,采用变异系数(CV)评价算法的稳定性,CV 越小,即算法的稳定性和鲁棒性越好;表 12 展示了不同算例下 IGA 和 3 种智能算法的变异系数(CV)结果。从表中可以看出,IGA 在 CV 方面表现最好,SA 和 ABC 次之,GA 在评价指标上表现最差。

**表 11 目标函数结果对比**

**Table 11 Comparison of objective function results**

| 算例 | IGA | | | GA | | | SA | | | ABC | | |
|---|---|---|---|---|---|---|---|---|---|---|---|---|
| 板坯数/块 | Max | Ave | Min | Max | Ave | Min | Max | Ave | Min | Max | Ave | Min |
| 100 | 1.056 6 | 1.050 3 | 1.039 9 | 1.085 2 | 1.068 1 | 1.053 7 | 1.073 3 | 1.058 6 | 1.049 3 | 1.069 1 | 1.055 4 | 1.049 5 |
| 200 | 1.058 7 | 1.049 5 | 1.038 3 | 1.087 9 | 1.069 9 | 1.054 4 | 1.074 2 | 1.057 7 | 1.048 4 | 1.070 2 | 1.054 9 | 1.049 3 |
| 300 | 1.060 6 | 1.048 9 | 1.037 2 | 1.089 3 | 1.068 6 | 1.052 1 | 1.075 1 | 1.055 3 | 1.048 1 | 1.071 1 | 1.055 1 | 1.048 8 |

**表 12 变异系数对比**

**Table 12 Comparison of coefficient of variation** %

| 算例板坯数/块 | CV | | | |
|---|---|---|---|---|
| | IGA | GA | SA | ABC |
| 小规模 | 0.44 | 9.65 | 2.32 | 1.46 |
| 中规模 | 0.59 | 9.68 | 2.78 | 1.92 |
| 大规模 | 0.71 | 9.97 | 3.04 | 2.14 |

## 4 结束语

(1)本文考虑了热轧过程中电能消耗和轧辊磨损的问题,建立了以最小化耗电成本和板坯间规格跳跃惩罚值为目标的优化模型。并通过阈值法对双优化目标进行去量纲化处理,再结合层次分析法

(AHP)与熵值法为双优化目标设定并修正权重,将双目标模型转化为单目标优化数学模型。

(2)考虑热轧生产特点采用基于板坯位置映射的单层编码方式,提出嵌入启发式规则的种群初始化策略优化初始种群质量;设计了基于 sigmoid 函数的自适应策略,根据进化进程动态调整交叉率、变异率以提高算法的搜索能力;使用精英选择策略和轮盘赌结合的选择策略,保留了进化过程中的优质个体。

(3)结合生产实例,设计改进算法与传统遗传算法、原始人工蜂群算法、模拟退火算法进行对比,从进化率和变异系数对实验结果进行分析,验证了本文算法在种群初始化和收敛性等方面的优势;同时相比于传统遗传算法,改进遗传算法的优化率较传统遗传算法提高了 3.61%,耗电成本降低了 2.87%,即改进后的算法能有效节约能源成本。

在今后的研究中,本文将进一步把电能调度问题扩展至炼钢-连铸等生产环节,以增加问题的实用性。同时,将设计更加高效的初始化策略、基于知识的搜索算子及自适应策略,进一步提升算法的性能。

## 参考文献


[1] 胡正彪. 基于系统优化的钢铁企业能源调度与生产计划调度研究[D]. 北京:北京科技大学, 2023.

[2] TU N, LUO X, HUANG H, et al. Method for hot rolling planning considering material requirements of downstream production lines [C]//Proceedings of the 8th World Congress on Intelligent Control and Automation. Piscataway, NJ: IEEE, 2010:1690-1695.

[3] 张旭君, 吕志民. 炼铸轧集成计划与调度组批模型及算法[J]. 控制与决策, 2013, 28(8):1257-1262.

[4] 谭貌, 段斌, 苏永新, 等. 分时电价下面向经济负荷调度的热轧批量计划两阶段优化[J]. 中南大学学报(自然科学版), 2014, 45(10):3456-3462.

[5] 董广静, 李铁克, 王柏琳. 考虑实时库存的轧制计划调整模型及算法[J]. 系统工程理论与实践, 2015, 35(5):1246-1255.

[6] LIU L, WAN X, GAO Z, et al. Research on modelling and optimization of hot rolling scheduling[J]. Journal of Ambient Intelligence and Humanized Computing, 2019, 10(3): 1201-1216.

[7] 幸火林, 徐安军, 吴双平, 等. 基于改进遗传算法的热轧批量计划优化模型[J]. 中国冶金, 2021, 31(5):47-53.

[8] 王明伟. 考虑柔性预防性维护的热轧计划与调度问题研究[D]. 沈阳:沈阳工业大学, 2023.

[9] 刘健, 王彬, 王柏琳, 等. 板坯热轧计划编制的优化模型与算法[J]. 计算机集成制造系统, 2015, 21(12):3263-3270.

[10] HE D F, LIU P Z, FENG K, et al. Collaborative optimization of rolling plan and energy dispatching in steel plants[J]. China Metallurgy, 2019, 29(4):75-80.

[11] 陈文. 基于 AHP-熵值法的汽车服务质量评价体系研究[J]. 现代商贸工业, 2017,28(22):87-88.

[12] 付子豪. 碳减排目标下炼钢-连铸生产调度研究[D]. 西安:西安建筑科技大学, 2023.

[13] 王子若, 刘明周, 王小巧. 基于改进遗传算法的多线性缓冲区联合调度[J]. 组合机床与自动化加工技术, 2023(9):182-187.

[14] 陈逸维, 刘华秋, 陈洪涛, 等. 基于双种群遗传算法的模具车间作业调度研究[J]. 组合机床与自动化加工技术, 2023(8):183-187.

[15] GUO C, LI W, GUO J. Research on flexible job shop scheduling considering dual resource constraints[J]. Digital Manufacture Science, 2023, 21(1):69-74.

[16] 余佳林, 姚锡凡, 单文俊, 等. 考虑工件运输时间的分布式柔性作业车间调度[J]. 组合机床与自动化加工技术, 2024(6):185-192.

[17] 徐伟华, 邱龙龙, 张根瑞, 等. 求解带容量约束车辆路径问题的改进遗传算法[J]. 计算机工程与设计, 2024, 45(3):785-792.

[18] WU X, BAI W, XIE Y, et al. A hybrid algorithm of particle swarm optimization, metropolis criterion and RTS smoother for path planning of UAVs[J]. Applied Soft Computing, 2018, 73:735-747.

[19] 姜一啸, 吉卫喜, 何鑫, 等. 基于改进非支配排序遗传算法的多目标柔性作业车间低碳调度[J]. 中国机械工程, 2022, 33(21):2564-2577.

[20] 张宏献, 回士敏, 马欣然. 提高热轧带钢成品的宽度控制精度[J]. 中国冶金, 2020, 30(8):60-63.