

基于改进 NSGA-III 的网络协同制造 服务分包方法研究

徐汉昌^{1,2}, 陈松航^{2,3}

(1. 福建农林大学 机电工程学院, 福州 350002; 2. 中国科学院福建物质结构研究所, 福州 350100;
3. 中国科学院大学 福建学院, 福州 350100)

摘要: 网络协同制造是传统纺织行业转型升级的重要路径, 针对核心的服务分包问题, 提出了一种基于改进 NSGA-III 的调度优化方法, 以订单的生产成本、总完工时间、生产质量、客户满意度和资源利用率为优化目标, 建立了网络协同制造模型; 在 NSGA-III 算法的基础上, 结合了 SPSA 算法, 提出一种具有更强局部搜索能力和收敛能力的模型求解算法, 并基于层次分析法和熵权法的组合赋权法从 Pareto 解集中选择最适合的方案; 通过标准算例的对比分析, 结果显示改进的 NSGA-III 算法在收敛性和解的多样性方面均优于 NSGA-II 和 NSGA-III 算法; 通过具体的网络协同制造算例, 验证了所提方法的有效性和优越性。

关键词: 网络协同制造; 多目标优化; NSGA-III; 任务调度; 纺织行业

Collaborative Manufacturing Service Subcontracting Method for Networks Based on Improved NSGA-III

XU Hanchang^{1,2}, CHEN Songhang^{2,3}

(1. College of Mechanical and Electrical Engineering, Fujian Agriculture and Forestry University,
Fuzhou 350002, China;
2. Fujian Institute of Research on the Structure of Matter, Chinese Academy of Sciences,
Fuzhou 350100, China;
3. Fujian University, University of Chinese Academy of Sciences, Fuzhou 350100, China)

Abstract: Network collaborative manufacturing is an important path for the transformation and upgrading of the traditional textile industry. For the core service outsourcing problem, a scheduling optimization method based on an improved nondominated sorting genetic algorithm III (NSGA-III) is proposed. This method takes the production cost, total completion time, production quality, customer satisfaction, and resource utilization rate of orders as optimization objectives, and establishes a network collaborative manufacturing model. Based on the NSGA-III algorithm and simultaneous perturbation stochastic approximation (SPSA) algorithm, a model-solving algorithm with stronger local search capability and convergence ability is proposed. By using a combined weighting method with analytic hierarchy process (AHP) and entropy weight method (EWM), the most suitable solution is selected from the Pareto optimal set. Through comparative analysis of standard test cases, the results show that the improved NSGA-III algorithm outperforms the NSGA-II and NSGA-III algorithms in terms of convergence and solution diversity. The effectiveness and superiority of the proposed method are verified through specific network collaborative manufacturing cases.

Keywords: network collaborative manufacturing; multi objective optimization; NSGA-III; task scheduling; textile industry

收稿日期:2024-12-20; 修回日期:2025-02-07。

基金项目:泉州市科技计划项目(2023C011R)。

作者简介:徐汉昌(1996-),男,硕士。

通讯作者:陈松航(1988-),男,博士,副研究员。

引用格式:徐汉昌,陈松航. 基于改进 NSGA-III 的网络协同制造服务分包方法研究[J]. 计算机测量与控制, 2026, 34(1): 134-141, 149.

0 引言

纺织行业作为传统制造业的重要组成部分, 面临着技术落后、创新能力不足、资源利用率低等问题。特别是在我国, 纺织行业的中小企业多为区域集群分布, 这些企业虽然具有较大的发展潜力, 但常因规模较小、资源有限而面临生产能力不足、可承接订单规模小且数量少、调度效率低下等问题。为了解决这些问题, 实现产业的转型升级, 提升国际竞争力, 我国明确提出要推动智能化和网络化制造的发展, 鼓励企业通过互联网与产业链各环节紧密协同, 实现智能制造和网络化协同制造^[1]。这一转型不仅能够缩短供应链条、降低交易成本, 还能够提高生产效率和产品质量, 形成区域优势的产业聚集群体和产业生态圈。

网络协同制造是利用网络技术和信息技术, 通过资源共享, 实现企业内部以及供应链上下游企业之间的产品设计、生产、物流、销售和服务等活动协同工作的一种制造模式^[2]。在网络协同制造环境中, 任务调度问题备受关注。已有研究从多个角度探讨了这一问题, 但仍存在不少不足。文献 [3] 提出了一种基于多代理系统的分布式任务调度方法, 利用多代理强化学习技术解决了云制造环境中的任务调度问题; 文献 [4] 探讨了雾-云环境下的任务调度问题, 提出了一种混合启发式算法, 提高了成本效率和服务质量; 文献 [5] 基于深度强化学习, 研究了多目标动态自动引导运输车调度方法, 用于解决动态制造环境中的运输问题; 文献 [6] 针对船用协同设计与制造中的任务调度问题, 提出了一种基于数据驱动的方法, 实现了资源的优化配置。尽管这些研究在一定程度上解决了任务调度问题, 但它们多集中在单一制造环境的任务调度上, 未能充分考虑网络协同制造环境中的多企业协作和资源优化配置。文献 [7] 提出了在云-边缘协同制造系统中, 利用大规模混合任务调度方法, 结合深度卷积递归网络辅助的随机差分进化算法, 解决大规模任务调度问题; 文献 [8] 研究了工业互联网在协同制造任务调度中的应用, 提出了一种基于工业互联网的多企业动态任务调度方法, 增强了调度的规模和效率; 文献 [9] 结合多云协同计算网络的资源融合, 研究了智能调度方法, 实现了资源的高效利用; 文献 [10] 提出了一种改进的第二代非支配排序遗传算法 (NSGA-II, nondominated sorting genetic algorithm II), 用于解决多目标优化问题, 特别是在多企业协作环境中的资源优化配置。尽管这些研究在一定程度上解决了任务调度问题, 但它们在实际应用中仍然面临许多挑战, 如算法的鲁棒性、实时性和可扩展性等问题, 且对实际生产环境中的复杂因素考虑不足。

为了解决纺织行业的网络协同制造服务分包问题,

本文将订单分配作为调度核心, 以订单的生产成本、总完工时间、生产质量、客户满意度和资源利用率为优化目标, 建立了网络协同制造模型, 在第三代非支配排序遗传算法 (NSGA-III, nondominated sorting genetic algorithm III) 的基础上, 结合了同步扰动随机逼近 (SP-SA, simultaneous perturbation stochastic approximation) 算法对其求解, 并基于层次分析法 (AHP, analytic hierarchy process) 和熵权法的组合赋权法选择最优解。最后, 通过标准算例和具体实例验证了该方法在网络协同制造服务分包问题上的优越性和有效性。

1 网络协同制造模型

1.1 问题描述

在区域纺织网络协同制造系统中, 订单的复杂制造任务通常需要分解为多个子任务, 并分配给不同的纺织企业来共同完成。这是因为纺织行业中的制造任务可以根据工艺环节进行细化, 如图 1 所示, 从原材料采购到织造、染整、服装制造、物流等环节, 每个环节都可以独立完成。此外, 每个环节的制造任务本身也包含了多层次的生产流程, 如图 2 所示, 服装制造可以根据款式、部件和工序进一步分解为具体任务, 例如西装、卫衣、裤子等不同种类的服装及其相关部件的加工、缝制、组装等操作。由于各个制造任务环节之间不仅存在串行关系, 还可能存在并行关系, 这使得生产调度变得极为复杂。不同企业之间的任务协调、资源分配以及时序安排都需要通过高效的调度算法来优化, 以确保生产过程的顺畅和高效。因此, 任务调度不仅要考虑每个任务的加工顺序, 还要优化资源利用率、生产时间以及各企业之间的协同效率, 进而提升整体订单交付的及时性和质量。




图 1 纺织工艺流程图

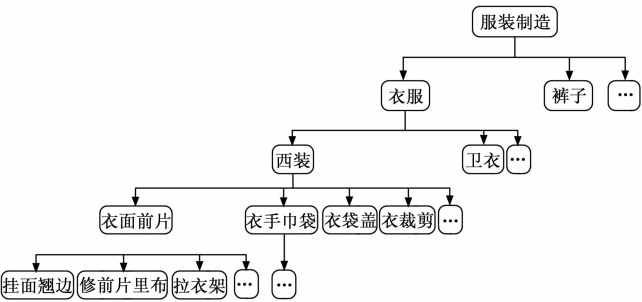


图 2 服装制造任务分解架构图

同时,针对纺织行业的特点和网络协同制造的需求,还需要考虑完成订单的生产成本、总完工时间、生产质量、客户满意度和资源利用率。因此,如何在保证订单任务按时完成的前提下,通过合理的调度计划尽量减少生产成本、缩短生产时间等目标,成为提高企业生产制造能力、获取更大利润的关键。

数学描述为:假设一个纺织订单可以被分解为 n 个子任务,系统内共有 m 个纺织制造企业,对于任意一个子任务,系统中有 m_i 个具备相应生产能力的企业可以承担该任务的生产制造。基于订单分配的网络协同制造服务分包问题,旨在合理地将订单的各个子任务分配至某一制造企业,并期望在生产过程中同时优化生产成本、总完工时间、生产质量、客户满意度和资源利用率,最终找到最优的调度方案。

1.2 调度模型

模型的符号定义说明如表 1 所示。

表 1 符号含义说明

符号	内容含义
n, m	子任务数量;制造企业数量
i, q	子任务编号 $i, q \in (1, n)$
j, k	企业编号 $j, k \in (1, m)$
m_i	能完成子任务 i 的企业数量
$x_{ij}(t_i)$	若 t_i 时刻子任务 i 由企业 j 完成,则 $x_{ij}(t_i)=1$,反之为 0
O_{qi}	若子任务 i 是子任务 q 的前置子任务,则 $O_{qi}=1$,反之为 0
C_{ij}	子任务 i 由企业 j 制造的生产成本
dC_{jk}	企业 j 与企业 k 之间的运输成本
T_{ij}	子任务 i 由企业 j 制造的生产时间
t_i	子任务 i 的开始时间
dT_{jk}	企业 j 与企业 k 之间的运输时间
Q_{ij}	子任务 i 由企业 j 制造的生产质量
S_{ij}	对企业 j 制造的子任务 i 的客户满意度
R_{ij}	对企业 j 制造的子任务 i 的资源利用率

调度模型的目标函数:

1) 订单的生产成本主要包括企业完成生产任务的所需成本和运输成本,因此成本优化目标为:

$$f_1 = \min C = \sum_{i=1}^n \sum_{j=1}^{m_i} C_{ij} x_{ij}(t_i) + \sum_{i=1}^{n-1} \sum_{q=1}^n O_{qi} \sum_{j=1}^{m_i} \sum_{k=1}^{m_q} dC_{jk} x_{ij}(t_i) x_{qk}(t_q) \quad (1)$$

2) 订单的总完工时间主要包括完成制造任务的生产时间以及运输时间,因此时间优化目标为:

$$f_2 = \min T = \max_{q \in \{1, \dots, n\}} \left(\max_{i \in \{1, \dots, n-1\}} (t_i + \sum_{j=1}^{m_i} T_{ij} x_{ij}(t_i) + O_{iq} \sum_{k=1}^{m_q} dT_{jk} x_{ij}(t_i) x_{qk}(t_q)) \right) = d_i \quad (2)$$

3) 订单的生产质量为制造各子任务完成质量的均值,因此质量优化目标为:

$$f_3 = \max Q = \left(\sum_{i=1}^n \sum_{j=1}^{m_i} Q_{ij} x_{ij}(t_i) \right) / n \quad (3)$$

4) 订单的客户满意度为制造各子任务的客户满意度的均值,因此客户满意度优化目标为:

$$f_4 = \max S = \left(\sum_{i=1}^n \sum_{j=1}^{m_i} S_{ij} x_{ij}(t_i) \right) / n \quad (4)$$

5) 订单的资源利用率为制造各子任务的资源利用率的均值,因此资源利用率优化目标为:

$$f_5 = \max R = \left(\sum_{i=1}^n \sum_{j=1}^{m_i} R_{ij} x_{ij}(t_i) \right) / n \quad (5)$$

根据上面的目标函数,设置约束条件:

1) 每个子任务必须从 m_i 个企业中选择一个企业进行生产,且每个子任务只能选择一个企业进行生产:

$$\sum_{j=1}^{m_i} \sum_{t=0}^{d_i} x_{ij}(t_i) = 1, i = \{1, 2, \dots, n\} \quad (6)$$

2) 有时序的两个子任务,前一个子任务的结束时间小于后一个子任务的开始时间:

$$d_i < t_q \sum_{k=1}^{m_i} x_{qk}(t_q) \quad (7)$$

3) 最后一个子任务的完成时间必须不大于整个订单的交货期 D :

$$d_n \leq D \quad (8)$$

4) 对子任务的生产质量不低于最低的生产质量:

$$Q \geq Q_{\min} \quad (9)$$

5) 对子任务的客户满意度不低于最低的客户满意度:

$$S \geq S_{\min} \quad (10)$$

6) 对子任务的资源利用率不低于最低的资源利用率:

$$R \geq R_{\min} \quad (11)$$

2 基于改进 NSGA-III 的模型求解算法

本文将网络协同制造模型当作多目标优化问题(MOP, multi-objective optimization problem)来展开探究。在 MOP 里,需要同时对多个目标函数进行优化,这些目标函数之间不可直接比较,并且可能存在相互冲突的情况^[11]。由于目标函数间存在这种相互制约的关系,通常不会存在唯一的最优解,而是会出现一系列在不同目标的权重之间进行权衡的解,这些解构成的集合被称作 Pareto 前沿^[12]。因此,本文的目标是选择 Pareto 前沿上最优的调度方案。为此引入 SPSA 算法对 NSGA-III 算法进行改进,通过改进的 NSGA-III 算法求解网络协同制造服务分包问题,并对得到的 Pareto 前沿的调度方案进行评判选择。改进的 NSGA-III 算法的流程图如图 3 所示。

2.1 NSGA-III 算法

NSGA-III^[13]是在 NSGA-II^[14]基础上的改进,适用

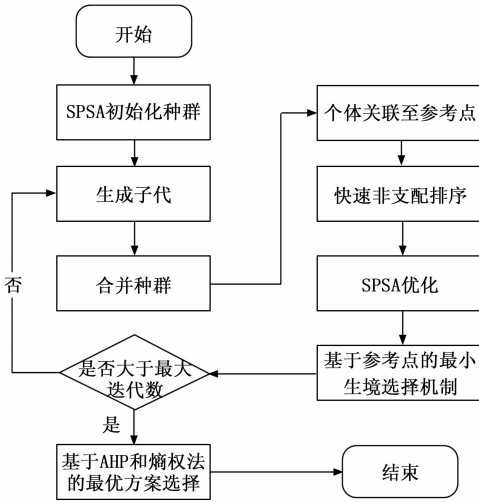


图 3 改进的 NSGA-III 算法流程

于 MOP 求解。通过引入均匀分布的参考点和基于参考点的小生境选择策略, NSGA-III 克服了 NSGA-II 中拥挤度排序计算复杂和解空间多样性不足的问题。这不仅提高了算法的收敛速度, 还确保了解集在目标空间中的均匀分布。此外, NSGA-III 采用精英保留、快速非支配排序和自适应归一化技术, 实现了种群的快速迭代和均匀分布, 特别在三维以上多目标优化问题中表现出色。主要步骤如下:

- 1) 初始化参数。初始化种群大小 N , 交叉概率 P_c , 变异概率 P_m , 迭代次数并完成种群初始化。
- 2) 生成参考点。根据目标函数的数量, 生成一组均匀分布的参考点, 这些点在目标空间中均匀分布, 帮助引导种群的进化。
- 3) 快速非支配排序。对初始种群进行快速非支配排序, 确定每个个体的非支配层级, 并构建支配关系。
- 4) 个体关联至参考点: 将每个个体与目标空间中的一个参考点关联, 根据其距离分配。此步骤有助于保证种群个体在 Pareto 前沿上的均匀分布。
- 5) 基因操作: 执行基因操作, 包括选择、交叉和变异, 用于生成新的解。目标是通过遗传操作生成可能改进现有解的后代, 同时保持种群的多样性。
- 6) 小生境选择策略: 采用小生境选择策略以增强种群的多样性。该策略确保个体在多个区域内均匀分布, 避免解集中在目标空间的某个区域, 从而促进全面的搜索。
- 7) 终止判断: 判断终止条件, 可以根据代数、种群收敛性或其他预定条件进行判断。如果满足终止条件, 则停止算法; 否则, 继续执行到下一代。

2.2 SPSA 算法

初始种群的质量对 NSGA-III 算法的收敛效率具有重要影响。为了优化初始种群并提高 NSGA-III 的局部

搜索能力, 本文采用 SPSA 算法对种群进行初始化和局部优化。传统常见的多目标求解算法, 如遗传算法等, 在求解高维问题时收敛速度较慢甚至无法获得最优解。SPSA 算法是一种用于优化复杂多维系统的随机优化算法, 特别适合处理高维、噪声和不确定性强的优化问题, 并且与其他随机优化算法相比收敛更快^[15]。但是已有的 SPSA 只能用于求解单目标优化问题, 因此本文采用基于 Pareto 优化的方法来改进已有的 SPSA 算法, 使其能够处理多个目标的梯度信息, 并有效地探索解空间中的 Pareto 最优解, 算法步骤如下:

1) 设置参数。设定初始参数向量 θ_1 , 设置步长序列 $k=1$ 、选择控制步长的正序列 a_k 、扰动大小的正序列 c_k 以及 Pareto 集为空。

2) 生成扰动向量。在每次迭代 k 时, 随机生成一个对称分布的扰动向量 Δ_k 。

3) 目标函数评估。计算每个目标函数正负扰动的目标函数值。根据当前变量 $\hat{\theta}_k$ 和扰动 Δ_k , 代入系统状态迭代算法扰动后的参数向量 $\hat{\theta}_k^+ = \hat{\theta}_k + c_k \Delta_k$ 、 $\hat{\theta}_k^- = \hat{\theta}_k - c_k \Delta_k$ 以及两个损失函数评估值 $F_1(\hat{\theta}_k^+)$ 和 $F_1(\hat{\theta}_k^-)$ 。

4) 估计梯度。计算每个目标函数的梯度:

$$\hat{g}_{k,i}(\hat{\theta}_k) = \frac{F_i(\hat{\theta}_k + c_k \Delta_k) - F_i(\hat{\theta}_k - c_k \Delta_k)}{2c_k \Delta_k} \quad (12)$$

式中, $\hat{g}_{k,i}(\hat{\theta}_k)$ 是对第 i 个目标函数的梯度估计。

5) 参数更新。根据多目标策略, 设定每个目标函数的权重为 λ_i , 整合所有目标函数的梯度估计 $\hat{g}_k(\hat{\theta}_k) = \sum_{i=1}^m \lambda_i \hat{g}_{k,i}(\hat{\theta}_k)$, 更新参数向量 $\hat{\theta}_{k+1} = \hat{\theta}_k - a_k \hat{g}_k(\hat{\theta}_k)$ 。

6) 非支配排序与 Pareto 前沿维护。在每次迭代中, 取当前解 $\hat{\theta}_{k+1}$ 与已有的 Pareto 前沿解进行非支配性比较; 如果 $\hat{\theta}_{k+1}$ 不被现有任何 Pareto 前沿解支配, 则将其加入 Pareto 前沿集, 并移除被支配的解。

7) 更新迭代次数。设置 $k=k+1$, 返回第二步, 当连续多代解不更新或达到最大迭代次数时算法中止, 输出 Pareto 解。

结合 SPSA 的高效梯度估计和局部搜索能力, 改进后的 NSGA-III 算法不仅提升了初始种群的质量, 还显著增强了其在多目标优化问题中的整体性能。

2.3 编码与解码

本文采用一段式编码方式对染色体进行编码, 根据纺织订单可分解的子任务数量 n 来确定每条染色体的长度, 染色体的每个基因代表一个子任务, 基因位序代表子任务编号 i , 基因值代表其对应的纺织制造企业编号 j 。染色体结构示意图如图 4 所示, 第一个数字“5”表示为将子任务 1 分配给编号 5 的企业完成。

解码就是将得到的染色体转换成实际的生产调度计划。解码方案分为两步, 第一步将染色体中的基因值转

染色体:	5	4	2	3	1	2
------	---	---	---	---	---	---

图 4 染色体结构示意图

换得到调度方案；第二步，根据第一步中的调度方案，查找对应企业的生产成本、生产时间、运输时间等信息，确定完成整个调度方案的所需资源。

2.4 调度方案选择

MOP 问题通常会得到多个 Pareto 解，但在实际生产中需要确定一个具体的调度方案。本文结合 AHP 和熵权法对各调度方案进行比较和选择。AHP 能够系统、直观地处理复杂决策问题，而熵权法则通过科学的方式客观评估各指标的重要性。两者的结合有效平衡了主观判断与客观数据的差异，使评价结果更加准确、可靠^[16]。

1) 采用 AHP 进行主观赋权。通过邀请专家对各评价指标的重要程度进行分析和打分，形成初步的权重判断。具体操作中，专家们对评价指标进行两两比对评分，分值取整数且根据其指标的重要性从小到大分值为 1~9 分，并据此构建判断矩阵。为确保判断的一致性和可靠性，对判断矩阵进行一致性检验，其核心指标为一致性指数 (CI) 和检验系数 (CR)。一致性指数 CI 的公式如下：

$$CI = \frac{\lambda_{\max} - t}{t - 1} \quad (13)$$

式中， λ_{\max} 是判断矩阵的最大特征根， t 为矩阵的阶数。检验系数公式如下：

$$CR = \frac{CI}{RI} \quad (14)$$

式中， RI 是平均随机一致性指标， RI 值与矩阵阶数有关，当时 $t=5$ ， $RI=1.12$ 。当 $CR<0.1$ 时，则认为该判断矩阵通过一致性检验。

2) 采用熵权法进行客观赋权。通过计算评价指标的信息熵来确定指标的客观权重。根据信息熵的定义，对于某项指标可用熵值来判断某个指标的离散程度，其熵值越小，指标的离散程度越大，该指标的权重也越大。第 j 个评价指标的信息熵 E_j 和权重 w_j 的计算公式如下：

$$E_j = -\frac{1}{\ln n} \sum_{i=1}^n p_{ij} \ln p_{ij} \quad (15)$$

$$w_j = \frac{1 - E_j}{\sum_{j=1}^m (1 - E_j)} \quad (16)$$

其中： n 为评价对象数量， m 为评价指标数量； p_{ij} 为第 i 个评价对象在第 j 个指标上的归一化值 $p_{ij} = \frac{z_{ij}}{\sum_{i=1}^n z_{ij}}$ ， z_{ij} 为评价数据归一化后的值， $i=1, 2, \dots, n$ ； $j=1, 2, \dots, m$ 。

3) 结合 AHP 和熵权法的权重通过线性加权的方法得到各评价指标的综合权重，得到评价指标的综合权重向量 A ，即：

$$A = \alpha\mu + \beta\nu \quad (17)$$

式中， α, β 为比例系数，取值范围为 $[0, 1]$ ， μ, ν 分别是 AHP 和熵权法的权重向量。

3 计算实验

为了验证改进的 NSGA-III 算法的性能，本文基于标准测试集 MK01~10 对所提算法进行了测试。同时，为了进一步验证调度优化方法的有效性，还进行了仿真实例分析，并通过 Python 编程实现。本次仿真实验在 Python 3.8.0 和 PyCharm 2019.3.5 环境中进行，运行平台为 Windows 10 64 位系统的台式机，配备 6 核 AMD Ryzen 5 5600G 处理器（主频 3.90 GHz）和 32 GB 内存。

3.1 算法对比

多目标优化算法的解集通常使用多种评价指标进行评估。本文采用了超体积^[17] (HV, hypervolume)、反世代距离^[18] (IGD, inverted generational distance) 和世代距离^[19] (GD, generational distance) 作为评价指标。其中，HV 值越大，表示算法的解集越接近 Pareto 最优前沿；IGD 值越小，表示算法的解集不仅收敛性好，而且多样性高；GD 越小，表示算法的收敛性越好，即解集越接近于真实的 Pareto 前沿。其计算公式如下：

$$HV(X, P^*) = \bigcup_{x \in X} v(x, P^*) \quad (18)$$

$$IGD(X, P^*) = \frac{\sum_{x^* \in P^*} d(x^*, X)}{|X|} \quad (19)$$

$$GD(X, P^*) = \frac{\sum_{x^* \in P^*} d(x^*, X)}{|P^*|} \quad (20)$$

其中： $v(x, P^*)$ 是各个目标上的最大值形成的向量， P^* 为帕累托前沿， X 为算法所求出的解集， $|X|$ 为所求算法中解的个数， $d(x^*, X)$ 为 X 中的解到 P^* 中所有解的最小欧氏距离， $|P^*|$ 为帕累托前沿中解的个数。

为了体现本文算法的优越性，将其与 NSGA-III 算法和 NSGA-II 算法进行对比，选取了 MK01~10 十个 Brandimarte 数据集^[20] 进行验证。每个数据集测试 10 次，并取平均值作为最终结果，实验结果如表 2 所示。对比可知，改进的 NSGA-III 算法在 HV、IGD 和 GD 这三个关键性能指标上总体上均显著优于 NSGA-III 和 NSGA-II 算法。具体而言，改进的 NSGA-III 在 HV 值上表现出更强的解空间覆盖能力，在 IGD 值上显示出更高的解的精确度，且在 GD 值上具有更好的收敛性。唯一的例外是，在 MK08、MK10 算例中，改进的 NSGA-III 算法的 IGD 值略高于 NSGA-III，但总体趋势仍

表 2 进 NSGA-III 算法与 NSGA-Ⅲ、NSGA-II 算法的 HV、IGD、GD 值比较

测试集	HV			IGD			GD		
	改进 NSGA-III	NSGA-III	NSGA-II	改进 NSGA-III	NSGA-III	NSGA-II	改进 NSGA-III	NSGA-III	NSGA-II
MK01	0.36	0.31	0.18	13.84	13.94	14.03	0.04	0.06	0.45
MK02	0.29	0.26	0.15	14.06	14.11	14.21	0.04	0.06	0.46
MK03	0.22	0.18	0.10	15.75	15.91	16.24	0.05	0.07	0.54
MK04	0.29	0.26	0.16	14.59	14.68	14.86	0.04	0.06	0.48
MK05	0.35	0.30	0.19	14.36	14.36	14.49	0.04	0.04	0.47
MK06	0.24	0.20	0.11	16.09	16.29	16.46	0.04	0.06	0.55
MK07	0.36	0.32	0.19	14.50	14.56	14.69	0.04	0.06	0.47
MK08	0.18	0.14	0.06	18.13	18.10	18.34	0.10	0.14	0.59
MK09	0.17	0.14	0.07	17.15	17.19	17.27	0.08	0.12	0.56
MK10	0.17	0.14	0.07	17.68	17.13	17.89	0.09	0.13	0.58

然表明，改进的 NSGA-III 在大部分情况下具有更优的性能。综上所述，改进的 NSGA-III 算法在处理多目标优化问题时，展示了更优秀的多样性、收敛性和解的精确度。

3.2 实例分析

由于现实中协同制造平台的数据难以获取，本文借鉴文献 [21] 设计了仿真实验，并在广泛阅读相关参考文献的基础上为每个指标设计合理的取值范围和约束条件。

所设计的网络协同制造服务分包问题中，某纺织订单的子任务数量 $n=7$ ，且子任务之间存在并行和串行关系，如图 5 所示。




图 5 子任务时序约束关系图

子任务时序约束为： $O_{12}=1, O_{13}=1, O_{24}=1, O_{25}=1, O_{46}=1, O_{36}=1, O_{56}=1, O_{67}=1$ ；参与协同制造系统

的企业总数 $m=10$ ，编号为：1~10；可完成子任务 T_i 的制造企业 m_i 的集合为： $m_1=\{1,2,4,6,8\}, m_2=\{2,3,6,8\}, m_3=\{3,4,9,10\}, m_4=\{1,4,8,9,10\}, m_5=\{2,4,8\}, m_6=\{4,5,8,9\}, m_7=\{3,5,6,7,9\}$ ；客户要求的最晚交货时间为 $D=80$ 天；获取了协同制造企业完成各子任务的相关数据，包括生产成本（万元）、生产时间（天）、生产质量（取值范围 0~10）、客户满意度（取值范围 0~10）和资源利用率（取值范围 0~1），具体信息如表 3 所示；制造企业之间的运输成本 dC_{jk} 和运输时间 dT_{jk} ；设置订单的生产质量要求 $Q_{\min}=6$ ，客户满意度要求 $S_{\min}=6$ ，资源利用率要求 $R_{\min}=0.6$ ；

$dC_{ij} =$

0	15	20	15	30	10	15	25	15	20
15	0	15	15	20	25	15	20	25	15
20	15	0	20	25	15	30	25	15	30
15	15	20	0	15	25	20	30	15	20
30	20	25	15	0	15	20	15	30	25
10	25	15	25	15	0	20	25	15	20
15	15	30	20	20	20	0	25	15	30
25	20	25	30	15	25	25	0	20	25
15	25	15	15	30	15	15	20	0	25
20	15	30	20	25	20	30	25	25	0

表 3 企业完成各任务信息表

企业	子任务 1	子任务 2	子任务 3	子任务 4	子任务 5	子任务 6	子任务 7
1	200/10/8/9/0.8			190/10/7/8/0.9			
2	150/9/4/6/0.8	280/14/7/7/0.7			400/20/7/7/0.6		
3		310/8/10/9/0.7	240/8/7/6/0.8				180/13/7/6/0.9
4	180/11/8/7/1		260/6/7/6/0.8	240/8/8/7/0.9	420/18/6/5/0.6	230/7/6/5/0.9	
5						200/9/8/8/0.7	160/14/4/4/0.8
6	240/10/10/9/0.9	300/10/7/6/0.8					170/12/7/6/1
7							180/10/6/6/1
8	220/8/6/7/0.9	300/12/9/10/0.8		220/9/7/8/0.9	480/14/10/10/0.6	180/10/8/9/1	
9			280/7/9/9/0.7	200/11/8/8/0.9		240/6/7/7/0.8	200/11/8/8/0.9
10			270/6/8/9/0.7	200/9/5/6/0.8			

$$dT_{ij} = \begin{bmatrix} 0 & 1 & 2 & 2 & 1 & 2 & 1 & 1 & 2 & 1 \\ 1 & 0 & 2 & 1 & 3 & 1 & 2 & 1 & 1 & 2 \\ 2 & 2 & 0 & 1 & 2 & 2 & 1 & 1 & 2 & 1 \\ 2 & 1 & 1 & 0 & 1 & 2 & 1 & 1 & 2 & 2 \\ 1 & 3 & 2 & 1 & 0 & 2 & 1 & 2 & 2 & 1 \\ 2 & 1 & 2 & 2 & 2 & 0 & 1 & 1 & 2 & 1 \\ 1 & 2 & 1 & 1 & 1 & 1 & 0 & 2 & 2 & 1 \\ 1 & 1 & 1 & 1 & 2 & 1 & 2 & 0 & 1 & 1 \\ 2 & 1 & 2 & 2 & 2 & 2 & 2 & 1 & 0 & 2 \\ 1 & 2 & 1 & 2 & 1 & 1 & 1 & 1 & 2 & 0 \end{bmatrix}$$

此例中，初始化种群大小 $N=1\ 000$ ，迭代次数 5 000次，每 100 次为一代。由于存在五个目标函数，且各目标函数优先级平等，因此每个目标函数的权重均设置为 0.2。使用 3 种算法分别对实例进行求解，仿真得到的结果如图 6、表 4 所示。

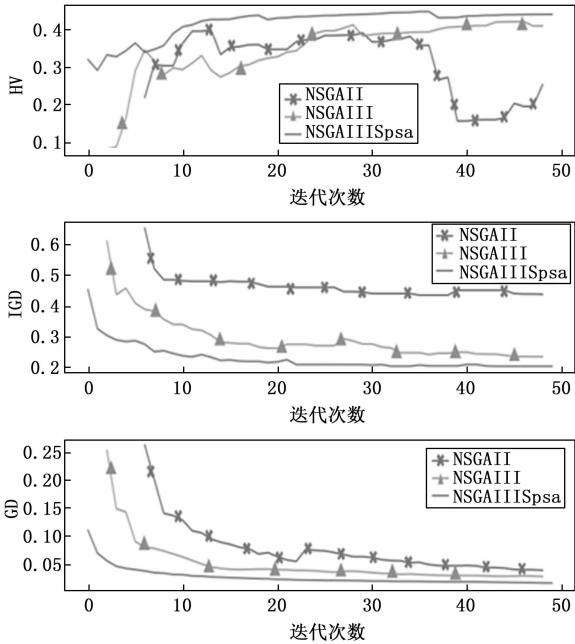


图 6 3 种算法求解实例所得的 HV、IGD、GD 随迭代次数的优化过程

表 4 改进的 NSGA-III、NSGA-III 和 NSGA-II 算法求解实例的结果

性能指标	改进的 NSGA-III	NSGA-III	NSGA-II
HV	0.42	0.34	0.31
IGD	0.22	0.28	0.50
GD	0.02	0.05	0.07

由图 6 可知，改进的 NSGA-III 算法在多目标优化问题上的整体性能相比 NSGA-III 和 NSGA-II 有明显的提升，具有更快的收敛速度、更优的解集质量和更好的稳定性。由表 4 可知，改进的 NSGA-III 算法的 HV 值为 0.42，较 NSGA-III 提高了约 24%，较 NSGA-II 提

升了约 35%，这表明改进的算法能够找到更加多样化且优质的解集。在 IGD 指标上，改进的 NSGA-III 为 0.22，较 NSGA-III 下降了约 21%，相较于 NSGA-II 的 0.50，则大幅降低了约 56%，说明改进算法生成的解集更接近于 Pareto 前沿。在 GD 指标上，改进的 NSGA-III 为 0.02，较 NSGA-III 的 0.05 提升了约 60%，较 NSGA-II 的 0.07 提升了约 71%，意味着改进算法的解集与 Pareto 前沿的距离更小，优化质量更高。综上所述，改进的 NSGA-III 算法通过提升解集的多样性和逼近性，在整体优化性能上表现出显著提升，特别是在 HV 和 GD 指标上的表现尤为突出。

通过对改进的 NSGA-III 算法求解实例得到的调度方案染色体进行解码，得到了对应的调度方案以及该方案的各项优化目标值，具体信息如表 5 所示。从表中数据可以看出，虽然各个方案都能满足调度需求，但它们在具体属性上存在显著差异：例如方案 1 的生产成本最高、资源利用率最低，但在生产质量和客户评价方面表现最佳；方案 2 的总完工时间最短，资源利用率最高，但其他指标较为平均；方案 4 各项指标比较均衡；方案 10 的生产成本最低，但其他指标比较平均。可以发现每个方案各有其优势，但是并不存在绝对意义上的最优方案。因此，在选择调度方案时，需要对各个方案进行综合评价，以确定最合适的方案。

表 5 调度方案

方案	调度计划	生产成本	总完工时间	生产质量	客户评价	资源利用率
1	6-8-9-10-8-5-8	2 065	61	8.43	8.57	0.77
2	2-8-4-9-8-4-7	1 920	55	7.43	7.43	0.83
3	6-2-10-9-8-9-5	2 035	63	7.71	7.71	0.77
4	2-3-4-1-2-9-9	1 870	59	7.43	7.29	0.79
5	4-6-3-1-4-8-6	1 865	67	7.14	6.86	0.87
6	4-2-9-8-4-8-6	1 870	69	7.43	7.43	0.84
7	8-2-10-1-2-8-3	1 875	68	7.14	7.57	0.81
8	6-8-9-9-4-5-7	2 005	63	8.00	8.00	0.80
9	4-6-10-9-2-4-3	1 915	66	7.29	7.00	0.83
10	2-2-4-9-2-8-9	1 800	66	7.29	7.29	0.81

首先邀请 8 位企业的管理人员和 2 名学术界的专家人员，利用其实践经验和专业知识判断各目标的相对重要性。通过对各个目标的打分情况，从而建立起各自的判断矩阵，计算得到各目标的主观权重为 $\mu = \{0.365\ 7, 0.379\ 0, 0.111\ 2, 0.083\ 6, 0.060\ 5\}$ ；然后利用表 5 的调度方案数据，计算各目标的信息熵和客观权重，计算结果如表 6 所示，各目标的客观权重为 $v = \{0.134\ 1, 0.202\ 8, 0.297\ 4, 0.168\ 3, 0.197\ 4\}$ 。

为了综合主客观权重的影响，充分结合 AHP 法和熵权法的优点，避免单一方法的偏差影响最终结果，取比例系数 α, β 都为 0.5，得到综合权重 $A = \{0.249\ 9,$

表 6 调度方案的熵和权重

项	生产成本	总完工时间	生产质量	客户评价	资源利用率
信息熵值 e	0.904	0.855	0.787	0.88	0.859
权重 (%)	13.41	20.28	29.74	16.83	19.74

0.290 9,0.204 3,0.126 0,0.128 9}。将表 5 的调度方案数据分别进行正负指标处理,得到矩阵 y ; 然后计算每个调度方案的具体分数 $R=y * A^T$, 从中选择分数最高的调度方案:

$$y = \begin{bmatrix} 0 & 0.57 & 1 & 1 & 1 \\ 0.55 & 1 & 0.22 & 0.33 & 0.60 \\ 0.11 & 0.43 & 0.44 & 0.50 & 0 \\ 0.74 & 0.71 & 0.22 & 0.25 & 0.20 \\ 0.75 & 0.14 & 0 & 0 & 1 \\ 0.74 & 0 & 0.22 & 0.33 & 0.70 \\ 0.72 & 0.07 & 0 & 0.42 & 0.40 \\ 0.23 & 0.43 & 0.67 & 0.67 & 0.30 \\ 0.57 & 0.21 & 0.12 & 0.08 & 0.60 \\ 1 & 0.21 & 0.12 & 0.25 & 0.40 \end{bmatrix}, R = \begin{bmatrix} 0.50 \\ 0.59 \\ 0.31 \\ 0.50 \\ 0.36 \\ 0.36 \\ 0.30 \\ 0.44 \\ 0.32 \\ 0.42 \end{bmatrix}$$

由 R 可知方案 2 的分数最高, 其生产成本 1 920 万元, 总完工时间 55 天, 生产质量 7.43, 客户评价 7.43 和资源利用率 0.83, 所以选择方案 2 作为最终的调度方案。

4 结束语

本文以纺织订单为调度核心, 将订单分解为多个制造任务, 并分配给区域内的中小纺织企业进行网络协同制造。针对纺织企业的特点及网络协同制造的特性, 构建了网络协同制造模型, 并采用改进的 NSGA-III 算法对该模型进行求解, 生成最优的调度方案, 将订单合理分配给最合适的企业, 协同完成生产任务。此方法不仅有效协调了企业间的资源, 提高了整体生产效率和产品质量, 还避免了资源浪费和重复配置。此外, 本研究对填补国内外在纺织行业中小企业应用领域的研究空白也具有一定的贡献。

在未来的研究中, 仍有许多值得探索的方向。首先, 如何进一步优化调度算法, 以应对更复杂和动态变化的生产环境, 仍是一个重要课题。其次, 结合智能制造技术和大数据分析, 提升调度系统的实时响应能力, 进一步提高生产效率和灵活性, 也将是未来研究的重点。此外, 针对纺织行业中不同类型企业的具体需求, 定制化的调度方案设计也具有较大的研究价值。

参考文献:

[1] 智能制造 网络协同制造 业务架构与信息模型: GB/T 43541-2023 [S]. 北京: 中国标准出版社, 2023.
[2] 网络协同制造平台数据服务要求: GB/T 43843-2024

[S]. 北京: 中国标准出版社, 2024.
[3] WANG X, ZHANG L, LIU Y, et al. Dynamic scheduling of tasks in cloud manufacturing with multi-agent reinforcement learning [J]. Journal of Manufacturing Systems, 2022, 65: 130-145.
[4] HUSSAIN S M, BEGH G R. Hybrid heuristic algorithm for cost-efficient QoS aware task scheduling in fog-cloud environment [J]. Journal of Computational Science, 2022, 64: 101828.
[5] WANG G, ZOU Y, LI S. Multi-objective dynamic AGV scheduling method based on deep reinforcement learning [C] //2024 14th Asian Control Conference (ASCC). IEEE, 2024: 1450-1455.
[6] GAO L, YANG Y, LI J, et al. Research on task scheduling method for ship-oriented collaborative design and manufacturing [C] //International Conference on Mechanical Design and Simulation (MDS 2022). SPIE, 2022, 12261: 321-329.
[7] WANG X, ZHANG L, LAILI Y, et al. Large-scale hybrid task scheduling in cloud-edge collaborative manufacturing systems with FCRN-assisted random differential evolution [J]. The International Journal of Advanced Manufacturing Technology, 2024, 130 (1): 203-221.
[8] ZHANG X, WANG F, GONG T, et al. Multi-enterprise dynamic task scheduling approach for industrial internet-of-things [C] //2024 43rd Chinese Control Conference (CCC). IEEE, 2024: 2136-2141.
[9] YANG M, ZHANG X, GUO R, et al. Research on intelligent scheduling method of multi cloud collaborative computing network fusion resources [C] //2023 4th International Conference on Mechatronics Technology and Intelligent Manufacturing (ICMTIM), IEEE, 2023: 403-407.
[10] CHEN C, YU J, LU J, et al. Service composition and optimal selection of low-carbon cloud manufacturing based on nsga-ii-sa algorithm [J]. Processes, 2023, 11 (2): 340.
[11] HUA Y, LIU Q, HAO K, et al. A survey of evolutionary algorithms for multi-objective optimization problems with irregular Pareto fronts [J]. IEEE/CAA Journal of Automatica Sinica, 2021, 8 (2): 303-318.
[12] 王爽宇, 申庆茂, 孙铭阳, 等. 基于改进 NSGA-III 算法的多无人机协同目标分配 [J]. 航空兵器, 2024, 31 (4): 100-111.
[13] DEB K, JAIN H. An evolutionary many-objective optimization algorithm using reference-point-based nondominated sorting approach, part I: solving problems with box constraints [J]. IEEE transactions on evolutionary computation, 2013, 18 (4): 577-601.