



计算机科学

COMPUTER SCIENCE

基于生成对抗网络的云制造工业服务选择方法

郑秀宝, 李静, 祝铭, 宁莹莹

引用本文

郑秀宝, 李静, 祝铭, 宁莹莹. 基于生成对抗网络的云制造工业服务选择方法[J]. 计算机科学, 2025, 52(4): 54-63.

ZHENG Xiubao, LI Jing, ZHU Ming, NING Yingying. [Selection Method for Cloud Manufacturing Industrial Services Based on Generative Adversarial Networks](#) [J]. Computer Science, 2025, 52(4): 54-63.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[一种面向车联网的零日攻击检测方法](#)

Zero Day Attack Detection Method for Internet of Vehicles

计算机科学, 2024, 51(12): 334-342. <https://doi.org/10.11896/jsjcx.231000117>

[基于生成对抗网络的下肢X光图像三维重建算法](#)

3D Reconstruction Algorithm for Lower Limb X-ray Images Based on Generative Adversarial Networks

计算机科学, 2024, 51(11A): 230900089-7. <https://doi.org/10.11896/jsjcx.230900089>

[专利交易中区块链应用的三方演化博弈分析](#)

Tripartite Evolutionary Game Analysis of Blockchain Applications in Patent Transactions

计算机科学, 2024, 51(10): 432-441. <https://doi.org/10.11896/jsjcx.230800116>

[基于生成对抗网络的系统调用主机入侵检测技术](#)

System Call Host Intrusion Detection Technology Based on Generative Adversarial Network

计算机科学, 2024, 51(10): 408-415. <https://doi.org/10.11896/jsjcx.230700014>

[NLGAE:一种基于改进网络结构及损失函数的图自编码器节点分类模型](#)

NLGAE:A Graph Autoencoder Model Based on Improved Network Structure and Loss Function for Node Classification Task

计算机科学, 2024, 51(10): 234-246. <https://doi.org/10.11896/jsjcx.230700122>

基于生成对抗网络的云制造工业服务选择方法

郑秀宝 李静 祝铭 宁莹莹

山东理工大学 山东 淄博 255000

(22505030025@stumail.sdut.edu.cn)

摘要 随着信息技术和制造技术的深度融合,云制造工业生产已成为制造业的关键部分。云制造环境的动态性和服务资源间的相互依赖关系,使得选择最佳工业资源服务变得困难。现有的选择优化方法大多基于启发式算法,但这些算法往往缺乏对云制造环境的自适应能力。因此,文中构建了一种云制造环境下的服务选择模型,提出了一种基于深度学习和生成对抗网络思想的服务选择算法,该模型能够灵活适应环境变化,利用图表示学习方法构建任务服务约束图,根据任务、服务和工业生产约束之间的内在联系学习资源服务特征,在算法改进阶段引入梯度优化和损失函数策略,选择最佳工业资源服务。实验结果表明,所提算法相较于其他对比算法表现出了更强的性能优势。

关键词: 云制造;工业生产约束;图表示学习;生成对抗网络;梯度损失函数

中图分类号 TP399

Selection Method for Cloud Manufacturing Industrial Services Based on Generative Adversarial Networks

ZHENG Xiubao, LI Jing, ZHU Ming and NING Yingying

School of Computer Science and Technology, Shandong University of Technology, Zibo, Shandong 255000, China

Abstract With the deep integration of information technology and manufacturing technology, cloud manufacturing industrial production has become a key part of the manufacturing industry. Due to the dynamics of the cloud manufacturing environment and the interdependencies between service resources, it isn't easy to select the best industrial resource services. Most of the existing selection optimization methods are based on heuristic algorithms, but these algorithms cannot often adapt to the cloud manufacturing environment. Therefore, this paper constructs a service selection model in the cloud manufacturing environment, proposes a service selection algorithm based on deep learning and generative adversarial network ideas, which can flexibly adapt to environmental changes, uses the graph representation learning method to construct a task service constraint graph, and then learns the characteristics of resource services according to the intrinsic relationship between tasks, services, and industrial production constraints, and introduces gradient optimization and loss function strategies in the algorithm improvement stage and select the best industrial resource services. Experiments show that the proposed algorithm has stronger performance advantages than other comparison algorithms.

Keywords Cloud manufacturing, Industrial production constraints, Graph represents learning, Generate adversarial networks, Gradient loss function

1 引言

云制造作为一种新型网格化制造模式,以云计算技术为核心,借助虚拟化技术将资源虚拟封装为云服务,使客户能够灵活获取资源,从而有效地降低资源利用成本,推动制造业

生产的优化和发展^[1]。随着人工智能、工业互联网、物联网等前沿技术的不断进步,云制造工业生产中根据制造需求和制造环境快速选择合适的服务已成为云制造模式高质量发展的关键因素^[2]。由于客户在云制造工业生产中的制造需求往往错综复杂,涉及多种不同类型的制造服务,因此云制造工业生

到稿日期:2024-10-19 返修日期:2025-02-18

基金项目:国家留学基金管理委员会“促进与加拿大、澳大利亚、新西兰及拉美地区科研合作与高层次人才培养项目”(留美金[2023]21号);教育部高等学校科学研究发展中心中国高校产学研创新基金-新一代信息技术创新项目(2023IT056)

This work was supported by the China Scholarship Council “Promoting Scientific Research Cooperation and High-level Talent Training Program with Canada, Australia, New Zealand and Latin America”(Liu Mei Jin [2023] No. 21) and Research and Development Center of Colleges and Universities of the Ministry of Education, China University Industry-University-Research Innovation Fund-New Generation Information Technology Innovation Project(2023IT056).

通信作者:李静(li_jing@sdut.edu.cn)

产中的服务选择问题——如何在众多服务中为客户匹配最佳服务以满足其复杂需求,一直是云制造领域的一个重要研究课题。

针对云制造工业生产中的服务选择问题,学者们提出了多种求解策略,除了启发式算法^[3](如遗传算法、模拟退火等),还包括多种解析求解方法^[4]以及近似求解方法^[5],这些方法包括线性规划、动态规划以及基于启发式和元启发式的代理模型。尽管这些方法在各自的领域内各有优势,且适用于不同的场景和需求,但在云制造这一复杂且动态变化的领域中,传统算法往往难以有效适应服务间的复杂依赖关系和环境的快速变化,可能会陷入局部最优解,导致解决方案的不确定性和局限性^[6]。因此,云制造工业生产中的服务选择问题需要一种更高效的算法。

近年来,深度学习(Deep Learning, DL)作为一种基于人工神经网络的技术,旨在模拟和解决复杂的学习和决策问题,已在多个领域取得显著成果^[7]。其凭借对云制造动态环境的适应性和对服务依赖的灵活性,有望成为解决服务选择问题的新方法^[8]。尽管如此,在追求服务选择领域的最优解过程中,DL技术也面临一定的挑战。由于训练数据可能存在的局限性以及模型结构本身的限制,DL模型有时难以确保达到全局最优解。因此,本文采取了一种集成学习的策略,结合了多种模型的优势,以规避局部最优解的陷阱,并提高决策的整体效能和模型的泛化性能。鉴于此,本文在考虑云制造服务之间的相互关系以及运行过程的动态变化的情况下,提出了一种基于DL技术和生成对抗网络(Generative Adversarial Networks, GANs)的生成网络服务选择算法(Generative Network Service Selection Algorithm, GNSS)。该算法采用DL技术来感知动态变化的环境,利用GANs生成模型根据服务资源与生产约束之间的复杂关系学习资源服务特征,在考虑工业生产约束条件的基础上,为客户选择出最佳匹配的工业资源服务。具体来说,本文的贡献和创新点如下:

1)构建了一种云制造环境下的服务选择模型(Service Selection Model, SSM),该模型能够灵活适应环境变化,为云制造工业生产中的服务选择提供了有力保障。

2)采用图表示方法构建任务服务约束图(Task Service Constraints Graph, TCG),学习资源服务特征。

3)提出了一种GNSS算法,在考虑3个不可忽略的工业生产约束的基础上,为客户选择最佳的工业资源服务。

本文第2章介绍了相关工作;第3章给出了所研究的数学模型;第4章阐述了设计的优化策略和算法制定;第5章进行了实验验证和结果分析;第6章进行了案例分析;最后总结全文。

2 相关工作

本章将对云制造工业生产中基于传统算法的服务选择方法、基于DL和GANs的服务选择方法进行介绍。

2.1 基于传统算法的服务选择方法

在云制造工业生产的领域里,服务选择问题始终占据着举足轻重的地位,研究者们提出了各种方法来解决服务选择问题。例如,Li等将云制造工业资源服务间的依赖关系作为

约束规则,应用遗传算法寻找最佳工业资源服务^[9]。Zhang等设计了一种增强型多目标人工蜂鸟算法,以处理云制造任务中的服务异常^[10]。Yang等考虑现实世界各种不确定因素对云制造任务顺利进行的影响,为每个子任务安排优先和替代服务,提出了一种人工蜂群-灰狼优化算法,提高了制造服务选择的效率^[11]。尽管这些方法在一定范围内有效,但随着问题规模的增加,这些算法在处理复杂流程和动态环境下的局限性逐渐显现。因此,云制造工业生产需要考虑新的和有效的服务选择算法。

2.2 基于DL和GANs的服务选择方法

DL技术凭借其强大的感知能力成为近年来研究的热点之一^[12],已经被广泛应用于游戏博弈^[13]、工业制造^[14]和工业机器人^[15]等领域。Ma等提出了一种基于监督学习的重选择预测技术,利用选择请求的预先信息,提高移动网络的选择成功率^[16]。Du等构建了云制造工业服务调度框架,针对车间制造任务资源共享不足的问题,提出了基于DL的服务协同优化方法,提高了制造系统的综合性能^[17]。以上研究表明,DL技术在处理大规模云制造工业生产服务选择问题、动态环境和服务资源关系方面取得了巨大成功。然而,云制造环境中往往面临着高质量、全面服务数据获取难度大的挑战,这一瓶颈限制了模型性能的进一步提升。GANs作为一种深度学习算法,在处理大规模、高维度、非线性方面展现出显著优势,能够有效捕捉数据中的复杂模式和关联关系^[18]。目前为止,已经有一些利用GANs解决云制造服务选择问题的研究。Wang等使用数据挖掘技术构建预测模型,研究了GANs对服务选择策略的有效性^[19]。Niu等针对基于服务级联关系的服务选择问题,提出了一个基于GANs的模型来预测用户在一系列服务之间的选择偏好^[20]。但以上研究仅侧重于单一的数据挖掘或GANs方法,而没有充分利用深度学习与其他技术相结合的潜力,导致模型在泛化能力、预测准确度以及处理复杂服务选择问题方面的不足。此外,这些研究未充分考虑云制造环境生产约束的多变性和动态性。鉴于此,本文考虑集成学习的策略,旨在结合DL与GANs的优势,构建针对服务选择问题的模型,该模型不仅能够利用DL技术在感知和特征提取方面的能力,还能够通过GANs学习服务资源与生产约束特征,生成高质量的数据,以克服云制造环境中服务数据获取的挑战。

2.3 总结

云制造工业生产的复杂环境给服务选择带来了挑战。表1列出了多个文献在解决云制造工业生产服务选择问题中考虑的不同方面。

表1 文献比较

Table 1 Literature comparison

文献来源	启发式算法	DL算法	工业生产约束	依赖关系
2024 Zhang et al. ^[10]	✓			
2024 Niu et al. ^[20]		✓		✓
2023 Wang et al. ^[19]		✓		✓
2022 Yang et al. ^[11]	✓			✓
2020 Li et al. ^[9]	✓		✓	
2020 Ma et al. ^[16]		✓	✓	✓
2019 Du et al. ^[17]		✓		

由于传统算法解决云制造工业生产服务选择问题时缺乏环境自适应性和服务资源间的依赖性,因此本文在考虑云制造服务之间的相互关系以及运行过程的动态变化的情况下,改进深度学习算法,满足客户复杂需求,选择最佳服务解决方案。

3 问题陈述

本章将从问题模型、服务和解决方案、工业生产约束

和目标函数这 4 部分对云制造工业生产服务选择问题进行详细介绍。

3.1 问题模型

本文将 SSM 分为 4 层,具体架构如图 1 所示。决策应用层负责完成整个云制造服务选择的过程和系统参数协调工作,涵盖了智能制造背景、算法选择、模型训练和决策输出等关键步骤。

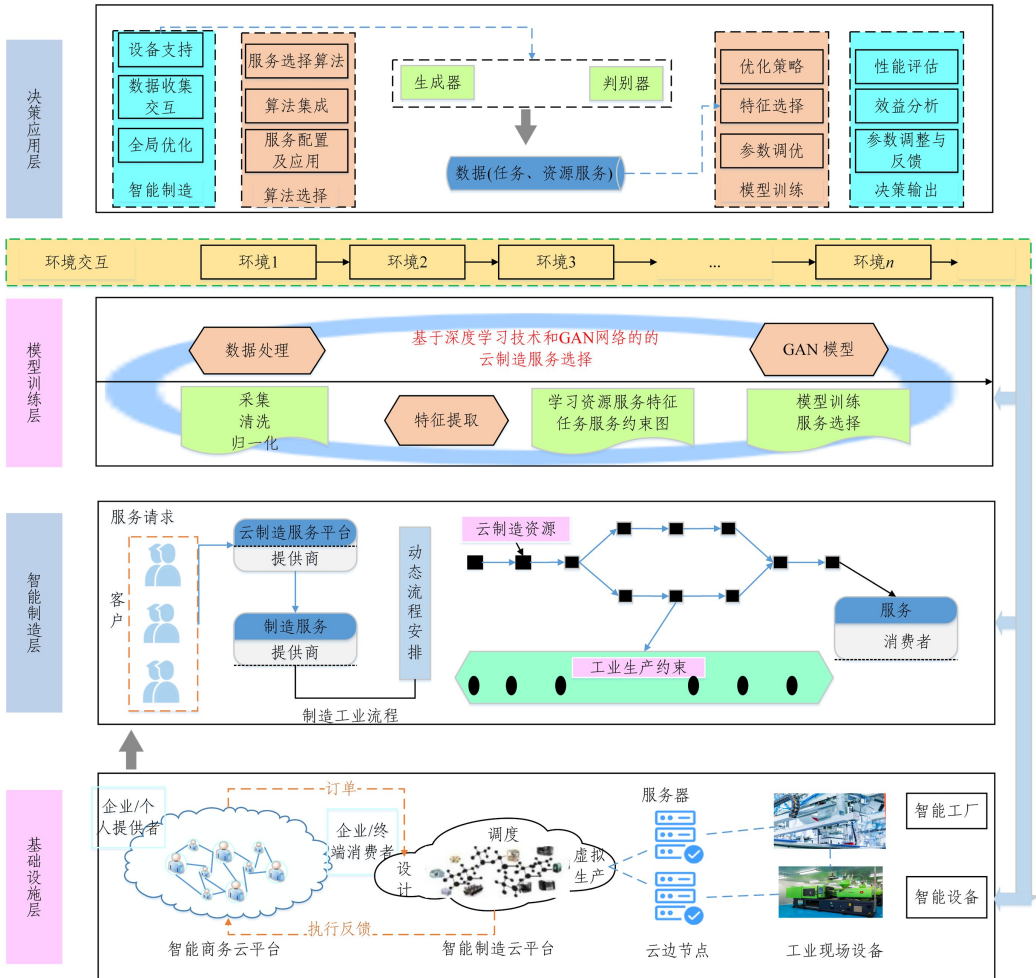


图 1 模型架构图

Fig. 1 Model architecture diagram

模型训练层为决策应用层的重要部分,主要包括数据处理、特征提取、GANs 模型 3 部分。数据处理阶段采集原始样本数据进行清洗和归一化处理,确保数据的质量和可用性;特征提取阶段从处理后的原始样本数据中学习并提取资源服务

特征,这些特征将作为 GANs 模型训练的输入,进行模型训练。图 2 给出了可视化 GANs 模型训练流程。两层训练过程与环境不断交互,最后评估系统参数后得到一个适用的服务解决方案。




图 2 GANs 模型训练图

Fig. 2 GANs model training graph

智能制造层根据客户需求,在考虑工业生产约束的条件下为模型训练层提供云制造资源,根据云制造工业流程实现服务选择和匹配,详细约束内容见 3.3 节。基础设施层由智能商务云平台、智能云制造平台、云边节点和工业现场设备组成,为云制造服务选择提供了坚实的硬件设备支持。

3.2 服务和解决方案

用户任务通常在服务选择中会被分解为几个不同类型的任务和相应的工作流。例如, $Task = \langle T, workflow \rangle$, 其中 $T = \{t_1, t_2, \dots, t_n\}$ 为任务集, $workflow$ 为任务执行的相关顺序。 $S = \{s_1, s_2, s_3, \dots, s_n, \dots, s_m\}$ 为所有执行任务的候选服务集,任务 T 由服务 S 执行。在服务选择中, n 表示任务的个数, m 表示服务的数量。如果任务 t_1 选择服务 s_1 , t_2 选择服务 s_2 , 以此类推,那么所有选定的业务构成解决方案为 $sol = \{s_1, s_2, s_3, \dots, s_n\}$ 。

3.3 工业生产约束

基于上述定义,在云制造工业生产中主要考虑耦合制造资源约束、制造服务资源重构过程约束以及服务质量限制约束。表 2 列出了本节使用的关键符号。

表 2 参数定义

Table 2 Parameter definitions

参数/变量	含义
i, j, l	索引号
$R_{si,j}$	第 i 个任务中的第 j 个 R_s
t_{pi}	第 i 个任务中的服务完成时间
$cost_{wait}$	服务资源的等待成本
$Life_{i,j}$	第 i 个任务的第 j 个服务当前寿命
$LifeLimit_{i,j}$	第 i 个任务的第 j 个服务有效寿命
c_r	服务资源重新配置成本,设置为 2000
t_r	每次重新配置的基本时间,设置为 5
$ QoS $	QoS 属性的个数
AGG	QoS 聚合函数值
$AGG(q_l)$	sol 的第 l 个 QoS 聚合函数值
w_l	用户确定的第 l 个 QoS 值的权重
c_i/t_i	第 i 个约束,第 i 个任务

3.3.1 耦合制造资源约束

在云制造过程中,由于制造资源系列的技术标准是相互依赖的,因此,相邻的任务往往需要选择相互匹配的制造资源。

$$t_2 \rightarrow s_2 \leq t_1 \rightarrow s_1, s_i = \{S\} \wedge t_i = \{T\}$$

其中, \rightarrow 表示选择, \leq 表示依赖关系。在任务 t_2 开始之前,必须有任务 t_1 选择了服务 s_1 ,那么 t_2 才能选择与之相匹配的服务 s_2 ,确保任务顺利完成。

3.3.2 制造服务资源重构过程约束

制造资源服务经常因工具寿命或能量消耗而需要进行重构和调整,使其实际服务时间发生动态变化。使用决策变量 DV_{ij} 来判断制造资源服务的可用性。其中下标 i 表示第 i 个任务,下标 j 表示该任务中的第 j 个服务, DV_{ij} 用于表示在给定任务和服务条件下是否需要服务进行重构的决策时机。 $Life_{ij}$ 表示第 i 个任务的第 j 个服务的当前寿命, $MTime_{ij}$ 是完成该服务所需的制造时间, $LifeLimit_{ij}$ 是该服务的有效寿命阈值。本文 DV 阈值设定基于文献[21]提出的联合决策优化规范以及 1.3 节中约束(5)的设定,反映工业生产中的资源

重构需求。在此条件下,当任务 i 中的第 j 个服务的制造时间 $MTime_{ij}$ 与当前寿命超过有效寿命时取值为 5,否则为 0。

$$DV_{ij} = \begin{cases} 5, & Life_{ij} + MTime_{ij} \geq LifeLimit_{ij} \\ 0, & \text{otherwise} \end{cases}$$

3.3.3 服务质量限制约束

服务质量(Quality of Service, QoS)评估网络服务性能。服务 s_i 对应一组 QoS 值, $QoS_i = \{q_{i,1}, q_{i,2}, \dots\}$, 其中 $q_{i,l}$ 为服务 s_i 的第 l 个 QoS 值。QoS 约束限制设置约束集, $C = \{c_1, c_2, \dots\}$, 其中 c_i 为不等式约束。

$$c_i = AGGT_{c_i}(q_l) < k_i$$

其中, T_{c_i} 为 c_i 受约束的任务, k_i 为 c_i 的约束值, $AGGT_{c_i}$ 为 T_{c_i} 对应的子解的第 1 个 QoS 聚合函数值。AGG 函数的计算依赖于工作流的组成结构,这些结构包括顺序、并行、条件和循环。表 3 列出了一些常见的 QoS 聚合函数,其中 pro_i 代表在条件结构中服务 s_i 被选中的概率。此外,循环结构的 QoS 聚合函数通过将循环次数乘以内部结构的聚合函数值来计算。

表 3 不同类型的 QoS 聚合函数的工作流结构

Table 3 QoS aggregation functions for different workflow structures

QoS 属性	顺序	并行	条件(pro_i)
响应时间 (Response Time)	$\sum_{i=1}^n q_{i,rt}$	$\max_{q_{i,rt}}$	$\sum_{i=1}^n q_{i,rt} * pro_i$
成本(Cost)	$\sum_{i=1}^n q_{i,ct}$	$\min_{q_{i,ct}}$	$\sum_{i=1}^n q_{i,ct} * pro_i$
可靠性(Reliability)	$\prod_{i=1}^n q_{i,rel}$	$\prod_{i=1}^n q_{i,rel}$	$\prod_{i=1}^n q_{i,rel} * pro_i$
吞吐量(Throughput)	$\min_{q_{i,tp}}$	$\min_{q_{i,tp}}$	$\sum_{i=1}^n q_{i,tp} * pro_i$

3.4 目标函数

3.4.1 优化目标

加工时间 $PTime$ 是所有任务完成后的最终时间,每项任务的完成时间包括制造时间 $MTime$ 、等待时间 $WTime$ 和重构时间 $RTime$ 。计算式如式(1)所示:

$$PTime = \sum_{i=1}^n (MTime_i + WTime_i + RTime_i)$$

$$WTime = t_{pi}(RS_{i,j}) - t_{pi}(RS_{i,j-1}) \quad (1)$$

$$RTime = \sum_{i=1, j=1}^n DV_{i,j} * RTime_{i,j}$$

其中, $RS_{i,j}$ 表示第 i 个任务中的第 j 个制造资源服务; t_{pi} 表示第 i 个任务中服务完成的时间; $t_{pi}(RS_{i,j})$ 和 $t_{pi}(RS_{i,j-1})$ 分别代表第 i 个任务中第 j 个服务和第 $j-1$ 个服务的完成时间; $WTime$ 指在第 i 个任务中,第 j 个服务开始执行前,服务的前一个服务完成之后到第 j 个服务开始之间的时间差; $DV_{i,j}$ 表示第 i 个任务的第 j 个服务是否需要重构的决策变量,若该服务需要重构,则 $RTime_{i,j}$ 表示该服务的重构时间。

加工成本 $PCost$ 是所有任务的总成本,每项任务的花费包括制造花费 $MCost$ 、等待成本 $WCost$ 和资源重构成本 $RCost$ 。计算式如式(2)所示:

$$PCost = \sum_{i=1}^n (MCost + WCost + RCost)$$

$$WCost = \sum_{i=1}^n WTime_i * cost_{wait} \quad (2)$$

$$RCost = \sum_{i=1}^n c_i * t_r * DV_{i,j}$$

3.4.2 目标函数

本文用目标函数 F 来评价 sol 的适应度。最小化的服务选择定义如下：

$$\min F(sol) = \sum_{l=1}^{|QoS|} AGG(q_l) * \omega_l \quad (3)$$

其中, $|QoS|$ 表示 QoS 属性的个数, AGG 代表 QoS 聚合函数值, 采用表 3 所列的并行结构计算 QoS 聚合函数, ω_l 表示各 QoS 属性的权重值。

多目标权重系数的确定对缺乏制造知识的服务需求者而言具有挑战性。层次分析法 (Analytic Hierarchy Process, AHP) 是一种由美国运筹学家 Thomas Saaty 在 20 世纪 70 年代提出的理论框架^[22], 其在多目标决策分析中得到了广泛应用。AHP 将复杂问题分解为多个层次, 通过成对比较与专家评分, 对各个决策因素进行定性和定量的评估, 从未确定各决策方案的优先级排序。该方法在资源分配^[23]、项目评估^[24]、风险管理^[25] 等众多领域被证明是有效的。它利用人们在成对比较中直观判断优先级的能力来简化多目标决策过程, 有助于决策者进行更加科学、合理的决策^[26]。

本文使用 AHP 来确定权重。具体地, 本文基于文献^[27]中的表 2 进行了成对比较, 以量化各属性的相对重要性。在此基础上, 本文构建了如式(4)所示的权重系数矩阵 W 。在此矩阵中, w_{ij} 代表指标 i 的重要性值相对于指标 j 的比值。计算矩阵 W 的最大特征值及其相应的特征向量 w , 将 w 归一化为 $w_l = w_i + w_c$, 其中 w_i 和 w_c 分别表示加工时间和加工成本权值, 满足 $w_l = 1$ 。

$$W = \begin{bmatrix} 1 & w_{tc} \\ w_{ct} & 1 \end{bmatrix} \quad (4)$$

4 基于 DL 技术和 GANs 服务选择算法

本章旨在阐述所应用算法的理论基础, 并详细介绍旨在优化算法性能的改进策略。

4.1 提出算法

本研究中的 GANs 利用其对事物的感知和表达能力在复杂的任务中做出高质量的决策^[28]。GANs 的结构巧妙地由两个神经网络相互协作构成, 分别是生成器和判别器。这两大结构之间的博弈关系构成了 GANs 运作的核心机制, 它们已通过不断迭代和竞争, 互相促进对方的性能提升, 并借助了多层神经网络结构和非线性变换的强大能力, 使得这种独特的架构能够捕捉到数据序列中的复杂模式和动态变化^[29]。

在生成模型和判别模型中皆采用了多层感知机结构, 定义噪声 $Z \sim N(0, 1)$ 作为先验, 其中 N 表示模型分布满足均值为 0、标准差为 1 的正态分布。生成器模型负责学习原始样本数据的特征, 并生成模拟数据来训练模型, 而判别器模型的主要任务是评估训练数据的质量。这两个模型通过相互博弈进行训练, 训练目标如式(5)所示：

$$\min_G \max_D V(D, G) = E(x) [\log D(x)] + E(z) [\log(1 - D(G(z)))] \quad (5)$$

其中, $\min_G \max_D V(D, G)$ 为最小化生成器最大化判别器的训练目标, $D(x)$ 表示判别器对 X 的输出, $E(x)$ 和 $E(z)$ 表示模型训练过程中模拟生成数据的期望值。

4.2 GNSS 算法

生成器模型承担着学习资源服务特征并生成模拟数据对模型网络进行训练的任务。但在学习资源服务特征信息时无法对离散数据进行解析, 可能导致解的质量降低。因此, 本文利用图表示学习方法构建 TCG 来解决这一问题^[30]。判别器模型则通过包含展平层、泄漏 ReLU 激活函数和各层间的相互作用, 提高了评估服务数据质量的能力。在生成器和判别器博弈过程中, 本文采用了梯度惩罚策略来优化损失函数, 进一步增强了网络的稳健性和泛化能力。图 3 清晰地给出了 GNSS 的模型训练流程, 算法 1 为 GNSS 伪代码, 表 4 列出了本文网络模型的超参数。

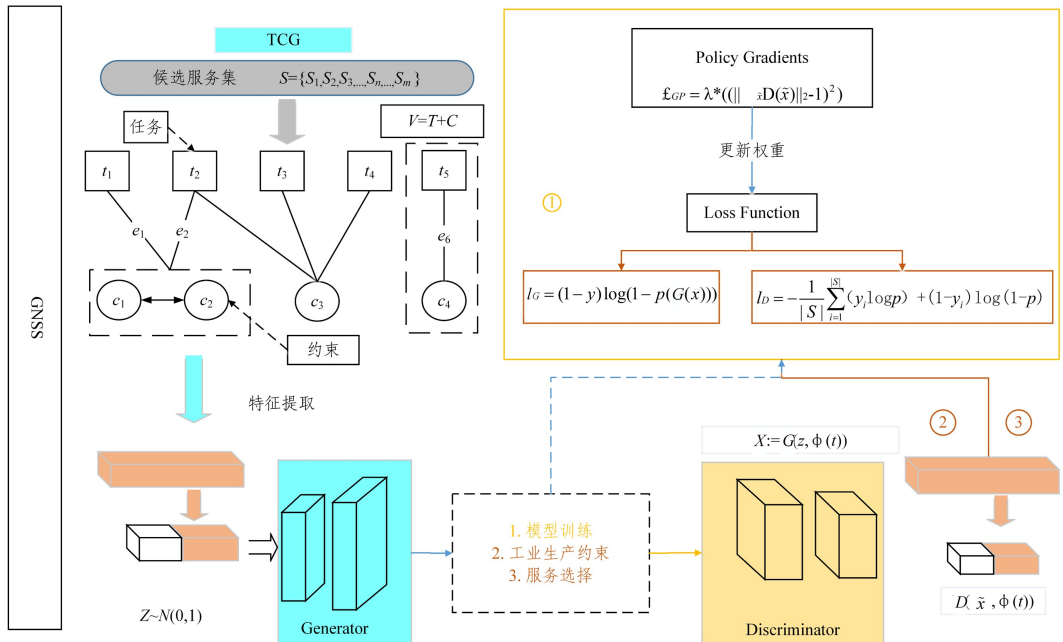


图 3 GNSS 模型训练流程图

Fig. 3 GNSS model training flowchart

表 4 设置超参数

Table 4 Setting hyperparameters

参数名称	参数含义	数值大小
batch_size	批次大小	200
samole_interval	采样间隔	100
generator_alpha	生成器学习率	0.5
discriminator_alpha	判别器学习率	0.2
momentum	动量	0.9
iteration	迭代次数	3000

图 4 直观地介绍了 GNSS 算法的具体流程,主要分为以下几个步骤:

- 1) 输入数据:输入原始样本数据 X 。
- 2) 初始化参数:初始化生成器网络和判别器网络的参数。
- 3) 构建 TCG:利用图表示学习方式构建 TCG,学习资源服务特征。
- 4) 数据生成:使用生成器生成模拟数据训练网络。
- 5) 网络训练:式(6)和式(7)分别定义生成器网络和判别器网络的损失函数,前者衡量模拟数据与真实数据之间的差异,后者衡量生成数据的准确性。
- 6) 更新权重:根据式(8)更新策略梯度规则,调整参数。
- 7) 服务选择:考虑工业生产约束,根据式(1)、式(2)判断是否达到客户订单需求,评估网络的训练输出。

器的损失函数如下:

$$l_G = (1-y)\log(1-p(G(x))) \quad (6)$$

$$l_D = -\frac{1}{|S|} \sum_{i=1}^{|S|} (y_i \log p) + (1-y_i) \log(1-p) \quad (7)$$

其中, y 表示样本期望值, $y_i \in \{0,1\}$ 表示是否使用 s_i 构建任务对应的业务解决方案, p 表示真实样本的预测概率, $1-p$ 为假样本预测概率, $G(x)$ 为生成器对样本 X 的输出。为提高训练稳定性并避免模式崩溃,在二元交叉熵损失函数的基础上添加一个梯度惩罚项,梯度惩罚损失函数的表达式如下:

$$\mathcal{L}_{GP} = \lambda * ((\|\nabla_{\tilde{x}} D(\tilde{x})\|_2 - 1)^2) \quad (8)$$

其中, λ 是梯度惩罚项的权重参数, \tilde{x} 是在真实数据和模拟数据之间线性插值的样本, $D(\tilde{x})$ 是判别器的输出, $\nabla_{\tilde{x}} D(\tilde{x})$ 是判别器相对于输入样本的梯度。

GNSS 的伪代码如算法 1 所示。

算法 1 GNSS

输入: X

输出:FinaSoutlion

1. 输入原始样本数据
2. 初始化生成器和判别器网络参数
3. 利用图表示学习方式构建 TCG,学习资源服务特征,生成器生成模拟数据训练网络
4. 根据式(6)、式(7)训练 GANs 网络
5. for $(i+1) * \text{batch_size} \leq \text{totalnumber}$ do
6. if $\text{iterations} / \text{samole_interval} \leftarrow 0$ then
7. $\text{generated_data}[(i * \text{batch_size}):((i+1) * \text{batch_size}, :)] \leftarrow \text{fack_data}$
8. else
9. $\text{generated_data}[(i * \text{batch_size}):,:] \leftarrow \text{fack_data}[:, \text{totalnumber} - (i * \text{batch_size})]$
10. 根据式(8)更新策略梯度权重
11. 判别器考虑工业生产约束和客户需求,评估生成器的训练输出;
12. 生成模型根据式(3)选择 FinaSoutlion

算法 1 中,输入真实样本数据集,初始化生成器和判别器的网络参数,根据式(6)、式(7)训练网络,其中 batch_size 逐步更新数据,当 iterations 达到采样 samole_interval 时,生成器完成一次训练,之后根据式(8)更新策略梯度权重,判别器在考虑工业生产约束条件和客户需求的基础上评估生成器的输出,根据式(3)选择最终的解决方案(FinaSoutlion)。

5 实验

本章首先介绍实验设置和数据集,然后依据评估指标将本文算法与其他算法进行比较,最后对实验结果进行分析,证明了本文算法的有效性。

5.1 实验设置

本文的实验环境是在 Linux 虚拟环境中进行的,软件配置如表 5 所列。由于在服务选择问题上没有包含任务、服务和约束的公开可用数据集,类似大多数服务选择实验^[31-33],本文使用了两个数据集来评估所提算法的性能和泛化能力。

首先选择了电梯云制造平台中部署的计算服务集(Compute Service Sets, CSS),该数据集是从实际环境中收集的,包含了待加工的零部件、所需的加工参数以及多项 QoS 属性,如响应时间、成本等^[33]。CSS 数据集经过精心清洗和预处理以消除噪声和异常值,最终包含 47 个类别的 5847 个服务实

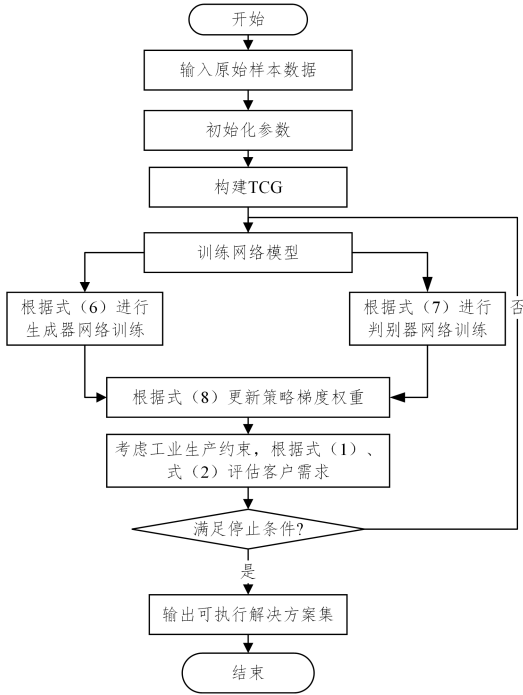


图 4 GNSS 算法流程图

Fig. 4 GNSS algorithm flowchart

4.2.1 任务服务约束图

将图 3 中构造的 $TCG = \langle V, E \rangle$ 作为模型的输入,其中 $V = T + C$ 表示 TCG 中任务与约束构成的节点集。而 $E = \{e_1, e_2, \dots\}$ 则表示 TCG 中任务与约束的边集。图中虚线框视为一个节点, $T_{c_1} = T_{c_2} = \{t_1, t_2\}$, $T_{c_3} = \{t_2, t_3, t_4\}$, $T_{c_4} = \{t_3\}$ 表示 TCG 应用规则。所有完成任务的服务皆从候选服务集中选择。

4.2.2 优化策略

为了优化判别器的权重,使其能够更准确地评估数据质量,选取二元交叉熵损失训练函数进行训练。生成器和判别

例,每个服务实例都由一组详细的特征描述,包括服务的类型、预期性能指标以及相关的 QoS 属性。为了进一步验证算法的泛化能力,本文设计了一个合成数据集(Synthetic Dataset, SD)。SD 数据集通过 GANs 的生成模型生成,旨在模拟 CSS 数据集的分布特性,但在任务数量、类型及 QoS 属性值上有所不同,我们随机选择 40~50 个抽象服务组成用户任务并添加生产约束,生成 6 000 个作为任务数据集,其中 5 000 个任务用于模型训练,1 000 个用于算法性能测试。本文选择以下算法进行对比实验:循环神经网络(Recurrent Neural Networks, RNN)^[34]、K 近邻算法(K-Nearest Neighbors, KNN)^[35]、随机森林(Random Forests, RF)^[36],以及粒子群优化(Particle Swarm Optimization, PSO)^[37]。

表 5 Linux 环境设置

Table 5 Linux environment settings

配置	说明	内存/版本
cpu	中央处理器	8 核
gpu	图形处理器	10 GB
RAM	存储器	32 GB
gym	构建学习场景	0.18.0
matplotlib	图表绘制	3.5.1
torch_geometric	图处理库	1.7.0
numpy	数字计算库	1.22.1

5.2 评估指标



准确率(Accuracy):模型正确预测的样本数量占总样本数量的比例。

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (9)$$



其中, TP 表示模型正确预测的正样本数; TN 表示模型正确预测的负样本数; FP 表示模型错误预测的负样本数,即负样本被错误地预测为正样本; FN 表示模型错误预测的正样本数,即正样本被错误地预测为负样本。

成功率(Success Rate):

$$Success Rate = \frac{Successful_n}{Total_n} \quad (10)$$



(a)



(b)

图 6 梯度惩罚项比较结果

Fig. 6 Gradient penalty term comparison results

其中, $Successful_n$ 为成功实验次数, $Total_n$ 为总的实验次数。

收敛性(Convergence):奖励的稳定性,即训练序列是否收敛到一个稳定的值。

$$Convergence = \frac{\max_{t \in T} R_t - \min_{t \in T} R_t}{\max_{t \in T} R_t} \quad (11)$$

其中, T 是训练时间序列, R_t 是第 t 个时间步的训练结果。式(11)衡量了训练序列的最大值和最小值之间的差异相对于最大值的比率。

解决方案质量(Solution Quality):

$$Solution Quality = \frac{F(sol^*)}{F(sol)} \quad (12)$$

其中, sol^* 为最优服务解。最优解的解质量为 1。所有其他解的值都在 0 到 1 之间。解决方案质量越大,解决方案越好。

5.3 实验结果

图 5 给出了截取的 50~300 训练批次结果,图中的生成器损失函数 Gloss、判别器损失函数 Dloss 和准确率 accuracy 结果在训练批次为 200 时最高,证明本文调整数据训练批次大小是有效的。图 6 为算法改进阶段加入梯度惩罚项的效果图,图 6(a)为采用二元交叉熵损失函数的显示结果,图 6(b)为加入梯度惩罚项的显示结果。从图中可以看出,加入梯度惩罚项后的训练模型更加稳定,有效避免了大量数据导致模型崩溃和梯度下降的现象。




图 5 训练批次

Fig. 5 Training batches

在表6所示的算法对比实验中,以 $t=400$ 为统一参数配置,对不同数据集上的算法性能进行了评估。实验结果显示,GNSS算法通过整合多种优化策略,在成功率和准确性上均

表现出显著优势。RF算法在CSS数据集上展现出了极高的准确度,得益于其集成学习的特性,有效降低了过拟合的风险。PSO算法凭借其高效的群体搜索机制,实现了出色的性能。

表6 不同数据集对比结果

Table 6 Compare results between different datasets

Algorithm	Dataset	Success Rate/%	Accuracy/%	Convergence/(0,1)	Solution Quality
KNN	CSS	83.96	85.33	0.563	0.9115±0.1343
	SD	84.62	87.49	0.712	0.8675±0.1375
RF	CSS	86.78	97.02	0.793	0.8412±0.2245
	SD	88.50	92.70	0.874	0.8746±0.1423
RNN	CSS	79.99	86.57	0.731	0.8919±0.1446
	SD	82.73	84.22	0.663	0.8581±0.1669
PSO	CSS	83.64	86.54	0.867	0.9524±0.0577
	SD	88.57	88.21	0.921	0.9351±0.0322
GNSS	CSS	95.75	93.40	0.989	0.9673*±
	SD	97.46	98.35	0.947	0.9751*±

相对而言,KNN和RNN在本实验中由于搜索策略的限制以及未能充分利用数据特性,表现一般。此外,在解决方案质量的对比中,GNSS和PSO算法提供了较高质量的解决方案,而RE,KNN和RNN则在一定程度上受到生产约束的影响,部分解决方案的质量不够理想。综合来看,GNSS算法在本次实验环境中表现出色,为服务选择问题提供了有效且高质量的解决方案。图7给出了不同算法在加工时间和加工成本方面的表现。GNSS算法依托其深度学习框架,虽然在模型训练阶段耗费了一定时间,导致总体时间上不及PSO算法,但其在服务选择方案上的优势依然明显。KNN算法由于训练过程较为复杂,对服务资源的需求较高,因此时间和成本均消耗较大。综合本实验模型的服务选择方案来看,GNSS算法在效率和成本效益上均优于其他算法,在服务选择问题上展现出卓越性能。




图7 加工时间和加工成本的对比

Fig. 7 Comparison of processing time and processing cost

6 案例分析

本章通过一个模具制造的例子来展示本文方法的工作过程。案例分析模型表示为5_3,表示模具制造公式接收的每个订单分为5项任务,每项任务有3个候选制造服务,任务总量为200个模具。假设模具制造公司要求在30天内完成所有订单。

其中第2个任务的第1个候选资源服务和第4个任务的第2个候选资源服务在资源耦合上受到约束。第2个任务的第2个候选资源服务在服务过程中受到资源重构约束,并且该服务需要重构。表7列出了候选资源之间的关系和约束信息。

表7 候选资源之间的关系和约束信息(加工成本(万)/加工时间(天))

Table 7 Relationship and constraint information for candidate resources(PCost(ten thousand)/PTime(days))

任务	候选服务 s_1	候选服务 s_2	候选服务 s_3	耦合制造资源约束	制造服务资源重构过程约束
任务 t_1	(9.5,4.5)	(9.2,3.8)	(9.5,3.5)	—	—
任务 t_2	(10.3,8.7)	(10.8,4.9)	(10.5,4.8)	s_1	s_2
任务 t_3	(9.5,5.5)	(9.5,5.5)	(9.5,5.5)	—	—
任务 t_4	(9.4,5)	(9.4,4.8)	(9.6,5.5)	s_2	—
任务 t_5	(21,5.8)	(26,5.1)	(32,6.7)	—	—
				$s_1(-) s_2$	5

表7中, $s_1(-) s_2$ 表示在两者发生资源耦合约束时加工需要的时间相同。而第2个任务的第2个候选资源服务需要重构,那么在最终计算加工时间时,决策变量取值为5。针对此案例SSM模型训练输出的最终解为 $\{TS_{12}, TS_{21}, TS_{32}, TS_{42}, TS_{51}\}$ 。 TS_{ij} 表示第*i*个任务中的第*j*个资源候选服务。

为确定全部任务是否在客户要求的截止日期前顺利完成,根据式(1)和式(2)计算总加工时间和总加工成本。

$$PTime = 3.8 + 8.7 + 5.5 + 4.8 + 5.8 = 28.6$$

$$PCost = 9.2 + 10.3 + 9.5 + 9.4 + 21 = 59.4$$

总加工时间为28.6天,总加工成本为59.4万元,订单在期限内顺利完成。

结束语 随着现代技术的不断发展,传统云制造工业生产逐渐朝着智能化、服务化的智能制造模式转变。现有方法大多基于启发式算法解决工业生产的服务选择问题,但在面对云制造环境动态性和服务资源之间的依赖时,往往无法有效应对。因此,本文在云制造环境下构建服务选择模型,并提出了一种基于DL技术和GANs的生成网络服务选择算法。该算法利用图表示学习方法构建任务服务约束图,学习资源服务特征,并通过引入梯度优化和损失函数策略,为云制造工业生产提供一种有效的生产方案选择方法。

尽管本文提出的模型在解决云制造服务选择问题上取得了显著进展,但仍存在一定的局限性和不足。模型的泛化能力依赖于高质量的训练数据,但在实际应用中,获取大规模且高质量的数据可能很困难。此外,GANs模型的训练过程可

能不稳定,需要仔细调整超参数以确保模型的收敛性。针对以上局限性,首先进一步探索数据增强技术,减少对大量标注数据的依赖,其次考虑在本文基础上结合更多先进技术,如强化学习、联邦学习、大语言模型等,以进一步提升服务选择的智能化和自适应能力,提高工业生产效率。

参 考 文 献

- [1] TAO F, HU Y F, ZHOU Z D. Study on manufacturing grid & its resource service optimal-selection system[J]. *The International Journal of Advanced Manufacturing Technology*, 2008, 37:1022-1041.
- [2] ZHANG L, LUO Y, TAO F, et al. Cloud manufacturing: a new manufacturing paradigm[J]. *Enterprise Information Systems*, 2014, 8(2):167-187.
- [3] HANNA A C, WHITING J, HUANG B, et al. Heuristic algorithms for design of integrated monitoring of geologic carbon storage sites[J]. *International Journal of Greenhouse Gas Control*, 2024, 135:104157.
- [4] BAHGA T, MOHAMED S M, SEBAQ A M. An Analytical Computational Algorithm for Solving a System of Multipantograph DDEs Using Laplace Variational Iteration Algorithm [J]. *Advances in Astronomy*, 2021, 1:7741166.
- [5] XIAO Y, GU Z, ZHANG Q, et al. New semi-analytical algorithm for solving PKEs based on Euler-Maclaurin approximation [J]. *Annals of Nuclear Energy*, 2020, 141:107308-107308.
- [6] ZHANG H, WU X J, WANG J. Study on the Evaluation Theoretical Structure Building of Deep Learning[J]. *China Educational Technology*, 2014, 7:51-55.
- [7] CHEN E, ANDERSEN S M, CHANDRA R. Deep learning framework with Bayesian data imputation for modelling and forecasting groundwater levels [J]. *Environmental Modelling and Software*, 2024, 178:106072.
- [8] CHU N, NG K K H, LIU Y, et al. Assessment of approach separation with probabilistic aircraft wake vortex recognition via deep learning[J]. *Transportation Research Part E: Logistics and Transportation Review*, 2024, 181:103387.
- [9] LI H, TONG J, ZHANG Z, et al. Selection of resource service chain with conflict-free dependencies in cloud manufacturing systems[J]. *International Journal of Internet Manufacturing and Services*, 2020, 7(3):216-236.
- [10] ZHANG Q, LI S, PU R, et al. An adaptive robust service composition and optimal selection method for cloud manufacturing based on the enhanced multi-objective artificial hummingbird algorithm[J]. *Expert Systems with Applications*, 2024, 244:122823.
- [11] YANG B, WANG S, LI S, et al. A robust service composition and optimal selection method for cloud manufacturing[J]. *International Journal of Production Research*, 2022, 60(4):1134-1152.
- [12] SUTTON R S, BARTO A G. Reinforcement learning: An introduction[J]. *Robotica*, 1999, 17(2):229-235.
- [13] TESAURO G. TD-Gammon, a self-teaching backgammon program, achieves master-level play[J]. *Neural computation*, 1994, 6(2):215-219.
- [14] DE BLASI S, KLÖSER S, MÜLLER A, et al. Kicker: an industrial drive and control foosball system automated with deep reinforcement learning[J]. *Journal of Intelligent & Robotic Systems*, 2021, 102(1):20.
- [15] LIU Y, YAO J, LIN T, et al. A framework for industrial robot training in cloud manufacturing with deep reinforcement learning[C]// *International Manufacturing Science and Engineering Conference*. American Society of Mechanical Engineers, 2020.
- [16] MA Y, XU W, TIAN S, et al. Knowledge graph-based manufacturing capability service optimal selection for industrial cloud robotics[C]// *International Manufacturing Science and Engineering Conference*. American Society of Mechanical Engineers, 2020.
- [17] DU H, XU W, YAO B, et al. Collaborative optimization of service scheduling for industrial cloud robotics based on knowledge sharing[J]. *Procedia CIRP*, 2019, 83:132-138.
- [18] GUO X, SHI L, CHEN X, et al. TAI-GAN: A Temporally and Anatomically Informed Generative Adversarial Network for early-to-late frame conversion in dynamic cardiac PET inter-frame motion correction [J]. *Medical Image Analysis*, 2024, 96:103190.
- [19] WANG R. Research on communication user churn prediction model based on GAN [D]. Jiangxi: Jiangxi Normal University, 2023.
- [20] NIU L, LI Z, LI S. MMD Fence GAN Unsupervised Anomaly Detection Model Based on Maximum Mean Discrepancy[J]. *International Journal of Cognitive Informatics and Natural Intelligence*, 2024, 18(1):1-13.
- [21] CUI F, GENG N, JIANG Z B, et al. Research on Joint Optimization of Reconfigurable Manufacturing Flow Line Configuration and Production Planning under Uncertain Demand[J]. *Frontier of Engineering Management Technology*, 2024, 43(2):29-37.
- [22] SAATY L T. Correction to: Some mathematical concepts of the analytic hierarchy process [J]. *Behaviormetrika*, 2021, 48(1):1-2.
- [23] HUANG J J, CHEN Y C. Resource Allocation of Cooperative Alternatives Using the Analytic Hierarchy Process and Analytic Network Process with Shapley Values [J]. *Algorithms*, 2024, 17(4):152.
- [24] AUGUSTINAS M, ANDREJ B, REGINA O Š, et al. Decision Tree and AHP Methods Application for Projects Assessment: A Case Study [J]. *Sustainability*, 2021, 13(10):5502-5502.
- [25] WU H, CAI X, FENG M. Risk management of engineering projects installation using analytic hierarchy process [J]. *Infrastructure Asset Management*, 2024, 3:1-39.
- [26] ARICAN H O, KARA E G E. Selection model of chemical tanker ships for cargo types using fuzzy AHP and fuzzy TOPSIS [J]. *Regional Studies in Marine Science*, 2024, 78:103724-103724.
- [27] CAO Y, WANG S, KANG L, et al. A TQCS-based service selection and scheduling strategy in cloud manufacturing [J]. *The International Journal of Advanced Manufacturing Technology*, 2016, 82(1/2/3/4):235-251.

- [28] WEI Y, DENG Y, SUN C, et al. Deep learning with noisy labels in medical prediction problems: a scoping review[J]. *Journal of the American Medical Informatics Association*, 2024, 31(7): 1596-1607.
- [29] KISHORE A, KUMAR A, DANG N. Enhanced Image Restoration by GANs using Game Theory [J]. *Procedia Computer Science*, 2020, 173(C): 225-233.
- [30] XU K, HU W, LESKOVEC J, et al. How powerful are graph neural networks? [J]. arXiv:1810.00826, 2018.
- [31] KUMAR S G, JATOTH C, GANGADHARAN G, et al. QoS-aware cloud service composition using eagle strategy [J]. *Future Generation Computer Systems*, 2018, 90: 273-290.
- [32] ZHANG Z, XU X, GAO F, et al. An adaptive approach to manufacturing service portfolio based on dynamic matching network [J]. *Journal of Software*, 2018, 29: 3355-3373.
- [33] WANG X, XU H, WANG X, et al. A graph neural network and pointer network-based approach for QoS-aware service composition [J]. *IEEE Transactions on Services Computing*, 2022, 16(3): 1589-1603.
- [34] WANG H, LI J, YU Q, et al. Integrating recurrent neural networks and reinforcement learning for dynamic service composition [J]. *Future Generation Computer Systems*, 2020, 107: 551-563.
- [35] JIA W, CHEN S, YANG L, et al. Ankylosing spondylitis prediction using fuzzy K-nearest neighbor classifier assisted by modified JAYA optimizer [J]. *Computers in Biology and Medicine*, 2024, 175: 108440.
- [36] MONGE J J, PARKER W J, RICHARDSON J W. Integrating forest ecosystem services into the farming landscape: a stochastic economic assessment [J]. *Journal of Environmental Management*, 2016, 174: 87-99.
- [37] FREIBOTT C R, GERBOLÉS C G C, SÁNCHEZ G A, et al. MILP and PSO approaches for solving a hydropower reservoirs intraday economic optimization problem [J/OL]. <https://link.springer.com/article/10.1007/s10100-024-00934-z>.



ZHENG Xiubao, born in 1999, postgraduate, a member of CCF (No. R8865G). His main research interests include intelligent manufacturing, service computing, artificial intelligence and graph neural networks.



LI Jing, born in 1986, Ph. D, associate professor, graduate supervisor, is a member of CCF (No. C9194M). Her main research interests include edge computing, cloud computing, and service choices.

(责任编辑:喻黎)