

王贺,周井泉,范琦. 基于CNN满意度模型的云制造服务组合优化算法[J]. 智能计算机与应用,2024,14(10):25-32. DOI: 10.20169/j.issn.2095-2163.241003

基于CNN满意度模型的云制造服务组合优化算法

王贺,周井泉,范琦

(南京邮电大学 电子与光学工程学院、柔性电子(未来技术)学院,南京 210023)

摘要: 本文研究云制造服务组合问题,针对传统云制造服务组合采用单一的线性加权模型,不能动态地反映用户满意度的需求,提出一种基于卷积神经网络(CNN)的满意度动态模型,从而构建基于动态模型和改进遗传算法的云制造服务组合的优化算法。构造非对称的多尺度卷积神经网络,使用历史数据训练CNN,实现权值的动态调节,从而构建满足用户不同需求的云制造服务满意度的动态模型。对遗传算法采取了动态的精英策略并且引入排挤机制和快速非支配排序。结果表明,得到的云制造服务组合用户满意度相比线性加权模型提高了17.33%,相比BP神经网络构建的非线性模型提高了9.34%,均方误差(MSE)降至0.00226。在云制造服务平台中验证所提模型构造方法和算法策略的可行性和有效性,在高维度模型中收敛速度仍然很快,克服了以往使用固定权值的线性组合的弊端,使得满意度得到提高,同时具有较高的稳定性。

关键词: 云制造; 云制造服务; 服务组合优化; 卷积神经网络; 遗传算法

中图分类号: TP391; TH166

文献标志码: A

文章编号: 2095-2163(2024)10-0025-08

Optimization algorithm for cloud manufacturing service portfolio based on CNN satisfaction model

WANG He, ZHOU Jingquan, FAN Qi

(College of Electronic and Optical Engineering & College of Flexible Electronics (Future Technology), Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

Abstract: This paper investigates the problem of cloud manufacturing service portfolio and proposes a dynamic model of satisfaction based on Convolutional Neural Network (CNN) to build an optimization algorithm for cloud manufacturing service portfolio based on dynamic model and improved genetic algorithm. An asymmetric multi-scale Convolutional Neural Network is constructed and the CNN is trained using historical data to achieve dynamic adjustment of weights, so as to construct a dynamic model of cloud manufacturing service satisfaction that meets different needs of users. A dynamic elite strategy is adopted for the genetic algorithm and a crowding mechanism and fast non-dominated ranking are introduced. The results show that the obtained user satisfaction of the cloud manufacturing service portfolio is 17.33% higher than that of the linear weighted model and 9.34% higher than that of the non-linear model constructed by BP neural network, and the Mean Square Error (MSE) is reduced to 0.00226. The feasibility and effectiveness of the proposed model construction method and algorithm strategy are verified in the cloud manufacturing service platform, and the convergence speed is still fast in the high dimensional model. The proposed model construction method and algorithm strategy are validated in a cloud manufacturing service platform, and the convergence speed is still fast in high-dimensional models, which overcomes the drawbacks of previous linear combinations using fixed weights, resulting in improved satisfaction while having high stability.

Key words: cloud manufacturing; cloud manufacturing services; service portfolio optimization; Convolutional Neural Network; genetic algorithm

0 引言

随着互联网等信息科技的发展,传统制造服务

逐步向云端服务过渡,需求方在公共平台发布需求,服务提供方将服务与资源打包上传到云端平台,由平台方对用户任务进行拆解、资源调配,这样的云端

基金项目: 国家自然科学基金(61401225)。

作者简介: 王贺(1997-),女,硕士研究生,主要研究方向:Web服务组合与优化,智能信息处理;范琦(1997-),女,硕士研究生,主要研究方向:Web服务组合与优化。

通讯作者: 周井泉(1963-),男,博士,教授,主要研究方向:通信网络的信息管理和控制。Email:zhoujq@njupt.edu.cn

收稿日期:2023-05-15

制造服务模式-云制造越来越普及^[1]。云制造将散布在各地的制造资源整合,灵活调配、高效服务。但是随着越来越多的用户、公司、产业涌入云制造行业,云制造服务需求的多样性、复杂性、动态性急剧上升,而资源提供方提供的服务资源质量、服务效率、资源利用效率、性价比等越来越多的参数也使得云制造服务组合的数据维度增加,从而导致了云制造服务组合模型使用的智能优化算法收敛速度变慢、信息利用率低等一系列亟待解决的问题,国内外对云制造服务的研究也正在广泛开展。

针对云制造平台建模问题,2012年Liu等学者^[2]提出了将制造资源和能力虚拟化的方案,将云制造资源与虚拟服务资源打包,将制造资源的功能性特征与非功能性特征添加到云制造资源模型中,使各种服务模型更精准。针对云制造平台方案预警问题,2016年Xu等学者^[3]对于需要重构的项目建立了有效的重构模型,将离散蜜蜂算法(DBA)与离散粒子群优化(DPSO)相结合,只针对局部调配而不再是传统的全局服务资源调配,优化完善局部资源调配替代方案。针对云制造平台信息整合问题,2017年汪卫星等学者结合了多种相似度算法设计了一种语义描述框架,针对云制造平台内的资源进行特征建模,并且对服务策略进行过滤,提高搜索性能效率。随着云制造服务的逐步发展,服务组合方案需要考虑的影响因素也越来越多,针对高维度的云制造服务组合优化问题,2022年尹超等学者^[4]提出基于NSGA-III算法解决云制造服务组合模型无法充分反映单个评价指标对服务组合综合性能的突出影响的问题,同时也针对高维度的服务组合问题求解做出了优化。2021年,Sparr等学者^[5]提出了对于资源搜寻以及分配订单的匹配方案,引入了代理系统用于处理分配好的云制造服务的子需求。

对于云制造服务组合方案的求解,目前广泛应用的解决方法是将成本、时间等影响因子加权后通过线性关系转化为单目标优化问题并进行求解^[6-11],此类方法存在如下问题:各指标的权重分配需要加以衡量,不能灵活地适应不同服务需求模型;各个目标一般存在比较普遍的相互制约的关系,所以线性加权得到的目标函数很难会获得均衡解;对于不同的服务需求方,模型不能动态自适应给出个性化定制方案。

为解决上述问题,云制造服务组合的优化应该将智能优化算法与云制造服务模型有机结合起来,尤其对于不同类型的服务需求,具有自适应性、动态

性的服务优化模型才是更有发展潜力的云制造服务组合优化模型。2022年,蔡安江等学者运用BP神经网络提高服务组合模型的学习精度和学习效率,有效缩短了服务组合搜索时间,但是BP神经网络的训练过程可能会陷入局部极小值,导致模型的性能不能达到全局最优,而且BP神经网络的训练速度较慢,也容易发生过拟合现象。研究可知,CNN不仅没有BP神经网络的上述缺点,而且鲁棒性和准确性都很好。在众多解决云制造服务组合问题的常用算法中,遗传算法^[12]在解决云制造服务选择有效性问题、服务之间的质量相关性等问题上具有收敛性好、有效性高、可行性强等优点。所以本文提出利用CNN网络构建满意度的动态模型,将经济成本、时间成本、服务质量评分、资源利用效率等参数映射成用户满意度,将遗传算法进行改进,以提高用户满意度为目标优化云制造服务组合性能。

1 云制造服务组合模型

1.1 模型设计

云制造服务包含服务需求方(Service Demander, SD)、服务提供方(Service Provider, SP)和云制造服务平台(Cloud Service Platform, CSP)三个组成部分。针对用户的服务需求构建云制造服务组合模型,在保证用户要求时间、经济成本情况下,最大限度保证用户满意度,对服务方案迭代优化。云制造服务组合模型作为一种典型的复杂模型,受到经济成本、时间成本、资源利用效率、服务质量等一系列因素影响,这些因素普遍具有非线性特点。所以使用CNN构造云制造参数和用户满意度的非线性关系模型,利用遗传算法对种群即服务组合进行优化,以提高用户满意度为目标,直到用户满意度稳定达到最大值为止,基于CNN模型进行云制造服务优化流程如图1所示。

1.2 模型指标参数

1.2.1 经济、时间成本

云制造服务平台在处理用户服务需求时首先对服务需求进行拆解,根据服务性质以及所需资源的特性将其拆分成 n 个子任务 $Task_i(i=0, \dots, n-1)$,匹配最佳的服务方案,再进行任务派发。在确定服务组合方案时首要考虑的因素是经济成本和时间成本,服务提供方所需总交付时间(T_{sp})不能超过需求方要求的服务时间(T_{sd}),服务提供方所需总经济成本(M_{sp})不能超过服务需求方提供的经济成本(M_{sd}),约束关系如下式所示:

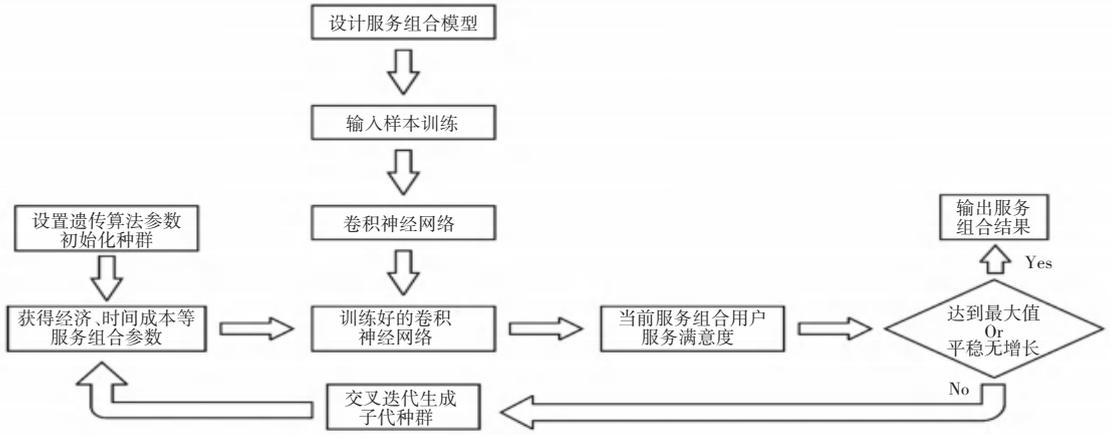


图 1 基于卷积神经网络优化服务组合的结构图

Fig. 1 Structure diagram of service composition optimization based on convolutional neural network

$$s. t. \begin{cases} T_{SP} \leq T_{SD} \\ M_{SP} \leq M_{SD} \end{cases} \quad (1)$$

在 n 个子任务中, 可以并发执行的子任务之间消耗时间无需叠加, 所以根据子任务之间是否可以并发执行对其进行分组, 每组内部子任务之间在必须先后执行的制约关系, 将拆分后的 n 个子任务分为 $m (m \leq n)$ 组, 每组包含若干不能并发执行的子任务, 第 g 组包含 M_g 个子任务, 每组子任务最多为 $n - m + 1$ 个, $n = \sum_{g=0}^{m-1} M_g$ 。云制造总时间成本计算模型如图 2 所示。

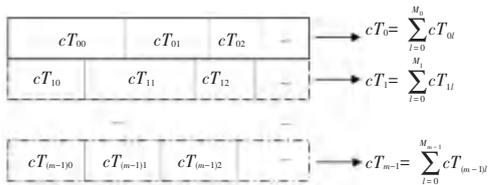


图 2 云制造总时间成本计算模型

Fig. 2 Cloud manufacturing total time costing model

第 g 组的第 l 个子任务 ($0 \leq g < m, 0 \leq l \leq M_g$) 的完成时间为 cT_{gl} , 那么第 g 组子任务的时间成本为 $cT_g = \sum_{l=0}^{M_g} cT_{gl}$, 完成所有子任务所需时间即为每组任务完成时间 cT_g 的最大值, 可由下式进行描述:

$$T_{SP} = \max_{0 \leq g \leq m-1} cT_g = \max_{0 \leq g \leq m-1} \sum_{l=0}^{M_g} cT_{gl} \quad (2)$$

1.2.2 资源利用率

云制造服务将分布在各地的资源在云平台进行统一打包封装、调配, 在确定服务组合方案时需考虑服务资源在各地之间的运输时间、经济成本, 如果运输成本过大, 导致运输成本在服务成本中的占比过

大, 就会导致服务质量降低或者服务时间延长等一系列问题, 也会造成不必要的资源浪费。所以以资源使用效率作为衡量云制造服务组合的重要参数, 如图 3 所示。

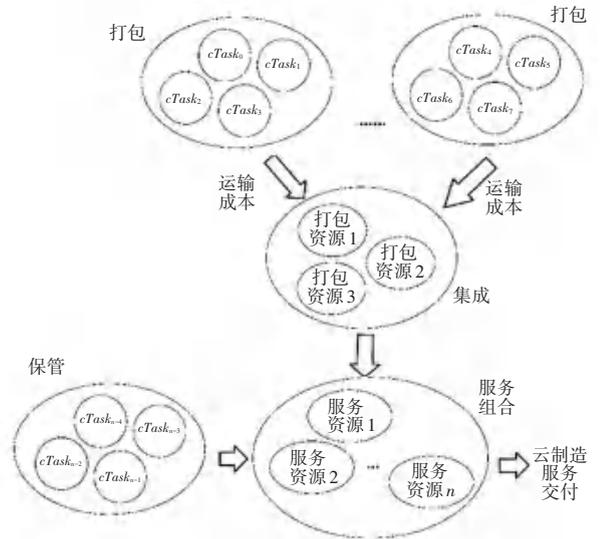


图 3 资源利用率原理图

Fig. 3 Schematic diagram of resource utilization

资源使用效率为打包、集成、运输、保管等成本占用经济成本的比重。同等经济成本的云制造服务需求, 资源利用率越高的, 能提供的服务质量也更高, 响应速度更快, 交付时间更短, 更符合环保制造理念以及可持续发展观。所以资源利用效率是衡量云制造服务组合的合理性、可用性的重要指标。

使用资源调度矩阵 S 表示云制造服务的资源调度成本, $S_{ij} (i \neq j)$ 表示从 i 点到 j 点的运输成本, S_{ii} 表示服务资源在 i 点的保管、存放成本, 具体公式如下:

$$S = \begin{pmatrix} \hat{e} & S_{0 \times 0} & S_{0 \times 1} & \cdots & S_{0 \times (n-1)} \\ \hat{e} & S_{1 \times 0} & S_{1 \times 1} & \cdots & S_{1 \times (n-1)} \\ \hat{e} & \cdots & \cdots & \cdots & \cdots \\ \hat{e} & S_{(n-1) \times 0} & S_{(n-1) \times 1} & \cdots & S_{(n-1) \times (n-1)} \end{pmatrix} \begin{pmatrix} \hat{u} \\ \hat{u} \\ \hat{u} \\ \hat{u} \end{pmatrix} \quad (3)$$

U_{ij} 表示服务组合中是否需要从 i 点调度资源到 j 点, $U_{ij} \neq U_{ji}$, 即单向调度。 $U_{ij} = 1$ 表示需要从 i 点调度到 j 点, $U_{ij} = 0$ 表示不需要从 i 点调度到 j 点, 具体计算公式为:

$$U = \begin{pmatrix} \hat{e} & U_{0 \times 0} & U_{0 \times 1} & \cdots & U_{0 \times (n-1)} \\ \hat{e} & U_{1 \times 0} & U_{1 \times 1} & \cdots & U_{1 \times (n-1)} \\ \hat{e} & \cdots & \cdots & \cdots & \cdots \\ \hat{e} & U_{(n-1) \times 0} & U_{(n-1) \times 1} & \cdots & U_{(n-1) \times (n-1)} \end{pmatrix} \begin{pmatrix} \hat{u} \\ \hat{u} \\ \hat{u} \\ \hat{u} \end{pmatrix} \quad (4)$$

当前服务组合总服务成本为 C , 资源利用效率即为矩阵 U 与 S 的乘积与总服务成本 C 的比值, 可由下式进行计算:

$$r = \frac{S \times U}{C} \quad (5)$$

1.2.3 服务质量

服务质量的来源是服务提供方在历史服务中的综合评分, 因为评价具有动态性, 所以时间越久远的评价参考价值越低, 所以以指数形式采纳服务提供方的历史评价分数, 同时, 用户信誉也是其评价被采纳权重的重要参考, 这里需用到的公式为:

$$Q = \int_{-\infty}^0 r_j f(t) e^{-at} dt \quad (6)$$

$$t = |t_{\text{today}} - t_i| \quad (7)$$

其中, t_i 表示评价时间; t_{today} 表示当前时间; $f(t)$ 表示服务质量; r_j 表示用户信誉度; a 表示衰减系数。

2 基于 CNN 的云制造服务组合满意度模型

2.1 卷积神经网络构造

采用卷积神经网络构建云制造服务组合中时间、经济成本等参数与需求方满意度的关系模型, 将云制造服务历史信息输入卷积神经网络进行训练。因为不同的用户对于不同服务组合参数的重视程度不同, 所以神经网络需要学习多个尺度的服务组合参数对用户满意度的影响权重, 从而正确构造不同服务组合参数与用户满意度的非线性数学模型。

本文对卷积神经网络结构进行改进, 增加卷积神经网络的网络宽度, 融合不同尺度的卷积核以提取不同尺度的特征信息, 从而达到提高卷积神经网络性能的目的。卷积神经网络架构如图 4 所示, 卷积层采用不同尺度的卷积核提取不同尺度的特征,

分别使用大小为 $1 \times 1, 3 \times 3, 5 \times 5$ 的卷积核。同时设置不对称的网络结构, 进一步减少卷积神经网络模型参数, 加快卷积神经网络非线性模型的训练速度。

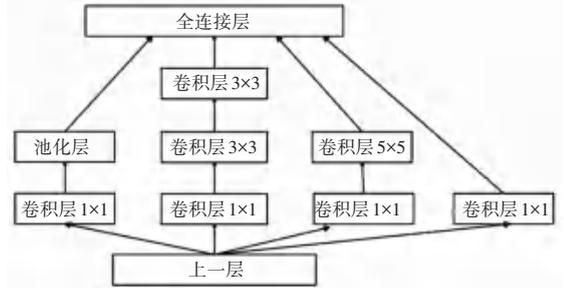


图4 卷积神经网络架构

Fig. 4 Convolutional Neural Network architecture

2.1.1 卷积神经网络卷积层设置

由图 4 可知, 卷积核为 $1 \times 1, 3 \times 3, 5 \times 5$ 的权值矩阵, 与上一层特征面的局部区域连接, 使用反向传输算法进行训练, 通过卷积操作提取输入数据的特征, 第一层卷积层提取基本特征, 如经济成本、时间成本与用户满意度之间的正负相关性, 更高层的卷积层提取更高级的特征。卷积层每个神经元的输出见下式:

$$y_{i,j}^{(l)} = f_{ReLU} \left[\sum_{\alpha=0}^{k-1} \sum_{\beta=0}^{k-1} con_{\alpha,\beta} y_{(i+\alpha),(j+\beta)}^{(l-1)} + o_{\alpha,\beta}^{(l)} \right] \quad (8)$$

其中, l 表示层数; k 表示卷积核的大小, 实验中为 2; α, β 分别表示神经元 (i, j) 平移量; $o_{\alpha,\beta}^{(l)}$ 表示神经元在卷积层的特征图上的偏置; f_{ReLU} 表示激活函数, 选取的激活函数是不饱和非线性 $ReLU$ 函数, 其数学公式如下:

$$f(x) = \max(0, x) \quad (9)$$

2.1.2 卷积神经网络池化层设置

池化层设置在卷积层后, 通过减少卷积层之间的神经元连接数量, 降低模型计算难度。池化层的输入层是卷积层, 池化层的神经元也与其输入层的特征面局部区域相连, 在卷积层后起到二次提取特征的作用, 池化层常用的池化方法有最大池化和均值池化^[13]、随机池化^[14-15]等方法。本文选取随机池化法, 对局部采样点按照其数据特征赋予对应概率值, 根据所赋概率值进行随机选择。这种方法可以确保特征面中的神经元信息都能被利用, 避免过拟合的问题^[16]。池化层的池化核即滑动窗口的大小与卷积核相同, 皆为 2。池化层第 i 个特征面的第 j 个神经元的输出可用下式表示:

$$O_{ij} = f_{\text{ran}}(O_{ik}, O_{i(k+1)}) \quad (10)$$

其中, f_{ran} 表示取样随机值的函数; O_{ik} 表示上一层输入的特征图; $O_{i(k+1)}$ 表示池化层的输出。

2.1.3 卷积神经网络全连接层设置

在 3 层卷积层+池化层结构后,是全连接层。全连接层用于整合卷积层与池化层的局部信息^[17],可以提高卷积神经网络的非线性映射能力。全连接层的每个神经元都与上层相连,神经元的激励函数同样采用 *ReLU* 函数。全连接层的数学模型可表示为:

$$O_j = f_{ReLU} \left(\sum_{i=1}^k x_i^{(l-1)} w_{i,j}^{(l)} + o_{\alpha,\beta}^{(l)} \right) \quad (11)$$

其中, k 表示上一层神经元的数量; l 表示当前所在层数; $w_{i,j}^{(l)}$ 表示神经元与上一层神经元连接的权值; $o_{\alpha,\beta}^{(l)}$ 表示神经元在全连接层上的偏置; f_{ReLU} 表示激活函数。

2.2 神经网络满意度模型的性能

为验证所提模型及方法的可行性和有效性,选择了 4 个数据库进行仿真,分别为 QWS2.0 版本、QWS3.0 版本、WSDREAM 和 TPDS 2012^[18]。根据 1.2 节模型指标参数对数据库的数据进行整理,得到不同服务组合的时间、经济成本、资源利用率、服务质量以及用户满意度,然后对数据进行归一化处理,将每个数据库的样本分为 S1、S2、S3 组。其中, S1、S2 用于训练卷积神经网络, S3 用于评价方法性能。将数据送入编译好的卷积神经网络进行训练,以均方误差 (*MSE*) 作为衡量指标。卷积神经网络训练过程中每次迭代后的训练与测试数据的均方误差值随着迭代次数的增加而下降,不同均方误差精度要求下迭代次数如图 5 所示,要求均方误差不超过 $1e^{-6}$ 时迭代次数显著上升,而均方误差不超过 $1e^{-5}$ 的预测结果即满足实验需求^[19],故实验预测精度保持 $1e^{-5}$ 即可。

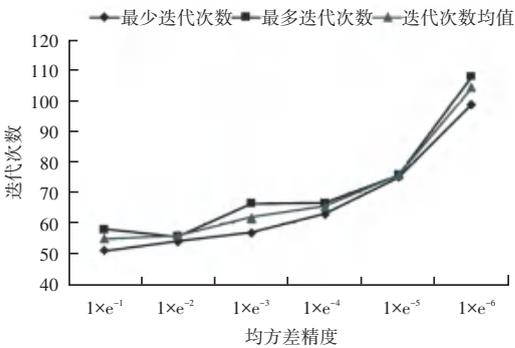


图 5 不同均方误差要求所需迭代次数最大值、最小值、平均值

Fig. 5 Maximum, minimum and average number of iterations required by different mean square errors

将 S3 组数据输入训练好的卷积神经网络得到一组预测的用户满意度,图 6 是绘制回归曲线来衡量卷积神经网络输出与真实数据的拟合程度,拟合程度计算公式可写为:

$$R^2 = 1 - \frac{\sum_{i=0}^{n-1} (S_i - \hat{S})^2}{\sum_{i=0}^{n-1} (S_i - \bar{S})^2} \quad (12)$$

其中, S_i 表示第 i 次实验得到的用户满意度; \hat{S} 表示当前实验真实历史数据的用户满意度; \bar{S} 表示实验用户满意度均值; n 表示数据个数。研究中得到的拟合结果 R^2 高达 0.999 57。

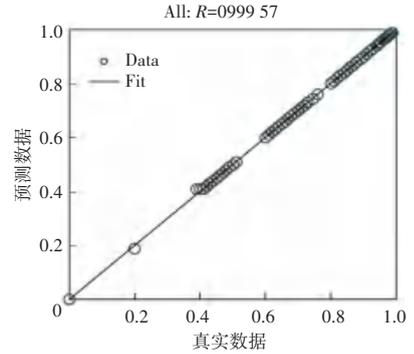


图 6 回归曲线反映的数据拟合程度

Fig. 6 Degree of data fitting reflected in the regression curve

卷积神经网络拟合服务组合的参数与用户满意度的关系基本达到预期的目的,将误差控制在了一定的范围内,说明该方法可以用于不同服务组合的用户满意度的预测。

3 云制造服务组合的优化方法

在 CNN 满意度模型基础上,结合遗传算法构成云制造服务组合优化算法。优化的目标是得到使用户满意度尽可能大的服务组合,所以将服务组合作为遗传算法中的个体,把这样的一组一组的可能解的集合就叫做种群。

初始化遗传算法参数,交叉概率为 1,变异概率为 0.05。将随机生成的 100 个个体输入到已经训练好的卷积神经网络中,得到种群中每一个个体对应的预测样本满意度 g_i ,由此计算出与期望指标的相对误差,相对误差越小个体的适应度越高。计算个体适应度的值具体如下:

$$f = 1 - \max \left\{ \frac{|g_i - e_i|}{e_i} \right\}, i = 1, 2, \dots, 6 \quad (13)$$

选择适应度高的染色体进行复制,然后进行交叉、变异、得到新群体,判断新群体中是否有符合要求的个体,并采用精英策略。

为了使基于 CNN 的云制造优化算法能提高收敛速度,在遗传算法中加入精英策略。在遗传算法

迭代的最初几代生成的种群中适应度高的个体数量必然很少,尤其是处理多目标优化问题的遗传算法。为更加快速找到最优解,同时避免精英策略导致的多样性较差、即种群的熵很小的问题,引入动态精英策略,即以一定概率对父代中比子代优秀的若干个体进行保留,随着迭代次数的增长,降低保留父代优秀个体的概率,即在迭代的第 t 代,父代的优秀个体的保留概率为 λ^t , 经过多次实验对比不同 λ 的取值所需迭代次数和种群的熵,如图 7 所示。最终,选择的 λ 取值为 0.924。

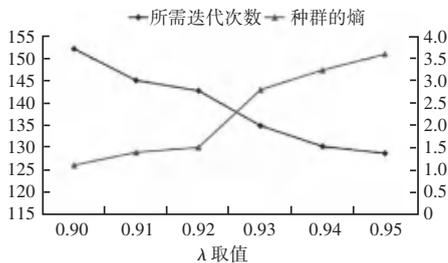


图 7 不同 λ 的取值所需迭代次数和种群的熵

Fig. 7 Number of iterations and entropy of population required for different λ values

在优化算法中引入了排挤机制。排挤机制使解均匀分布,并利用快速非支配排序降低运算的复杂度,在保持种群多样性的同时,也能有效降低多维目标函数的计算代价^[20],当用户满意度达到极大值且稳定时停止迭代输出结果,如果没有,则将得到的新群体重新输入训练好的卷积神经网络,如此循环,直到得到符合要求的种群。算法流程如图 8 所示。

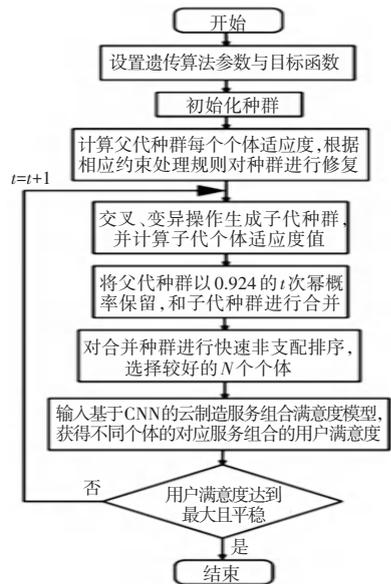
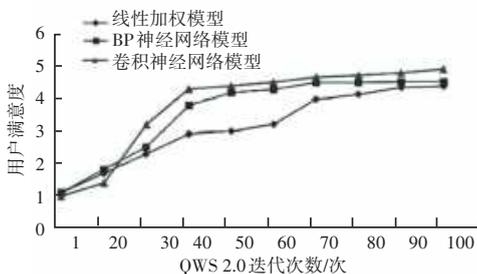


图 8 云制造服务组合的优化方法

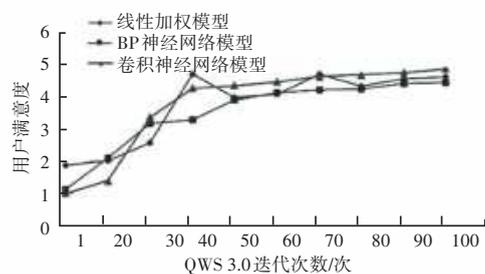
Fig. 8 Optimization method of cloud manufacturing service portfolio

4 实验结果及对比分析

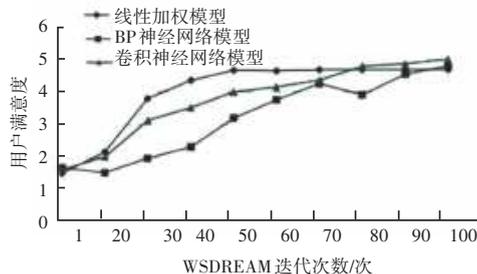
为了验证基于卷积神经网络模型的优化算法的可行性,选取线性加权模型、BP 神经网络模型的运行结果进行比较,选择 2.2 节用到的 4 组数据集,每组实验运行 100 次。基于 CNN 模型的服务组合优化迭代至 100 代时结果趋于稳定,线性加权模型和 BP 神经网络模型分别迭代至 75 代、100 代左右结果趋于稳定。观察对比这 3 种模型的用户满意度如图 9 所示。



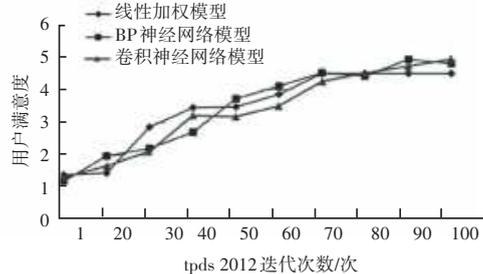
(a) 仿真实验 1



(b) 仿真实验 2



(c) 仿真实验 3



(d) 仿真实验 4

图 9 3 种模型的用户满意度随迭代次数变化情况

Fig. 9 Change of user satisfaction of the three models with the number of iterations

基于 CNN 模型的服务组合优化得到的用户满意度,在迭代至 100 代左右时相比线性加权模型、BP 神经网络模型分别提高了 17.33%、9.34%。

将每组实验重复 100 次,最终实验结果如图 10 所示,虚线标注即 4 组实验的服务满意度最大值,可以看到基于 CNN 的服务组合优化模型得到的用户

满意度相较于历史数据有显著提升。线性加权模型得到的满意度结果比基于 CNN 构建的模型满意度更低的原因是线性模型过于单一,不能完全反映参数与满意度之间的关系,所以在迭代优化的过程中利用的信息较为有限。

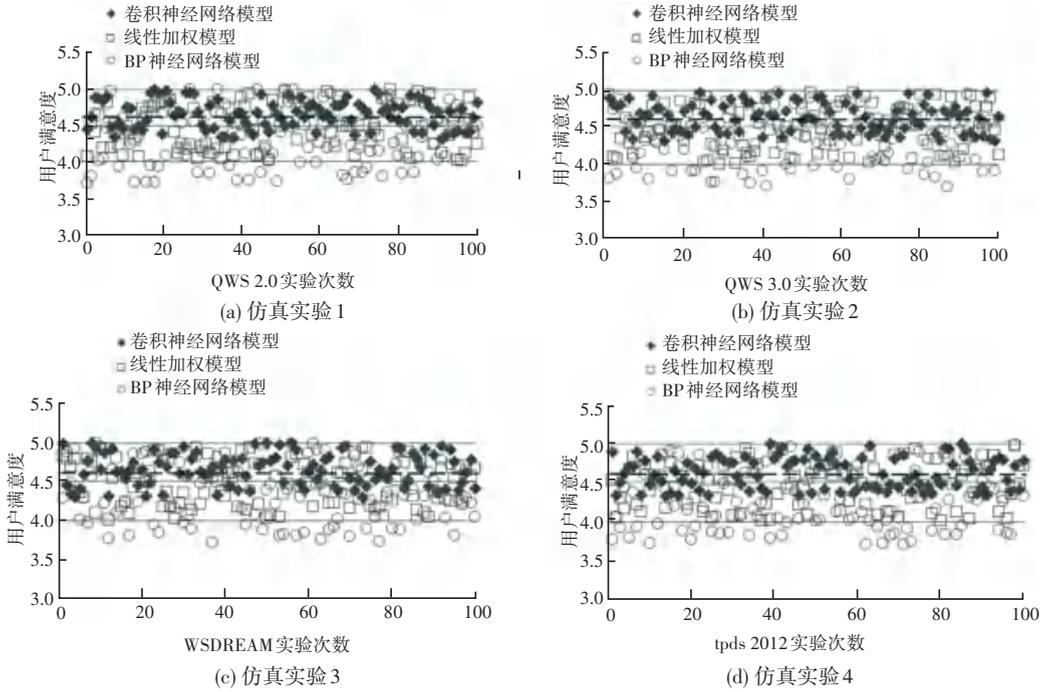


图 10 3 种模型实验 1~4 的 100 次结果对比

Fig. 10 Comparison of 100 times results of experiment 1~4 of the three models

对基于 CNN 的服务组合优化模型与传统线性模型、BP 神经网络模型得到的服务组合用户满意度结果,以均方误差 (MSE)、均方根误差 ($RMSE$)、绝对误差的平均值 (MAE) 三种指标进行评价比较,各指标公式具体为:

$$MSE = \frac{1}{n} \sum_{i=0}^{n-1} (S_i - \hat{S})^2 \quad (14)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=0}^{n-1} (S_i - \hat{S})^2} \quad (15)$$

$$MAE = \frac{1}{n} \sum_{i=0}^{n-1} |(S_i - \hat{S})| \quad (16)$$

其中, S_i 表示第 i 次实验得到的用户满意度; \hat{S} 表示当前实验真实历史数据的用户满意度; \bar{S} 表示实验用户满意度均值; n 表示数据个数。得到评价指标见表 1。

由表 1 分析可知,BP 神经网络模型得到的结果并不稳定,其原因是 BP 神经网络收敛速度慢而且容易陷入局部最优解,所以多次实验的结果稳定性

较差。使用基于 CNN 构建的云制造服务组合满意度模型得到 MSE 、 $RMSE$ 、 MAE 的结果相比使用线性加权模型、BP 神经网络模型的结果有所提升,证明基于 CNN 构建的模型稳定性更好。

表 1 各模型预测结果评价指标

Table 1 Evaluation index of prediction results of each model

模型	MSE	$RMSE$	MAE
卷积神经网络模型	0.002 26	0.047 53	0.004 75
线性加权模型	0.002 51	0.050 19	0.005 02
BP 神经网络模型	0.003 76	0.061 31	0.006 13

5 结束语

基于 CNN 的云制造服务组合优化模型,能动态地将云制造服务组合参数转化为用户满意度,突破了传统服务组合只能使用单一的线性组合导致不能完全反映参数之间的非线性关系的弊端,同时也解决了权值设置的主观性对于模型整体客观性的影响,卷积神经网络通过训练得到的参数与服务满意

度的非线性模型更加客观、完善,可以很好地反映经济成本等参数与用户满意度的关系。相比 BP 神经网络构建的模型,基于 CNN 构造的模型学习速度更快,所以收敛速度也更快,同时也避免了 BP 神经网络模型易陷入局部最优解的问题。该模型能准确地预测不同服务组合下的服务满意度,得益于 CNN 对数据特征有较高的提取能力。在 4 组不同类型的数据集上测试表明,基于 CNN 的云制造服务组合模型的优化算法具有较高的自适应性,针对不同的服务类型、用户类型具有动态调整功能,体现了比线性加权模型和 BP 神经网络模型更好的满意度、结果更稳定。但是基于 CNN 训练得到的服务满意度模型需要大量数据进行训练,而且数据训练计算量很大,训练时间也比较长。但是随着计算机技术的发展和硬件设备性能的提升,这些不足也将得到改进、并日臻完善。

参考文献

- [1] LI Xiaobin, YIN Chao, LIU Fei. A trust estimation method of machine tool resources in the cloud environment[J]. *Journal of Statistical Computation and Simulation*, 2017, 87(13): 2572-2580.
- [2] LIU Ning, LI Xiaoping. A resource virtualization mechanism for cloud manufacturing systems[C]//Enterprise Interoperability: 4th International IFIP Working Conference, IWEI 2012. Harbin, China: Springer, 2012: 46-59.
- [3] XU W, ZHONG X, ZHAO Y, et al. Manufacturing service reconfiguration optimization using hybrid bees algorithm in cloud manufacturing[C]//Challenges and Opportunity with Big Data: 19th Monterey Workshop. Beijing, China: Springer International Publishing, 2016: 87-98.
- [4] 尹超, 许加晟, 李孝斌. 基于 NSGA-III 算法的云制造服务组合优选方法[J]. *计算机集成制造系统*, 2022, 28(4): 1164-1176.
- [5] SPARR K, DREXEL D, HOCH R. Using an auction-based system in cloud manufacturing for selecting manufacturing-as-a-service providers [C]//Advances in Production Management Systems. Artificial Intelligence for Sustainable and Resilient Production Systems; IFIP WG 5.7 International Conference, APMS 2021. Nantes, France: Springer International Publishing, 2021: 445-454.
- [6] YANG Yefeng, YANG Bo, WANG Shilong, et al. An enhanced multi-objective grey wolf optimizer for service composition in cloud manufacturing [J]. *Applied Soft Computing*, 2020, 87: 106003.
- [7] YANG Y, YANG B, WANG S, et al. An improved grey wolf optimizer algorithm for energy-aware service composition in cloud manufacturing [J]. *The International Journal of Advanced Manufacturing Technology*, 2019, 105: 3079-3091.
- [8] LI Feng, ZHANG Lin, LIU Yongkui, et al. A clustering network-based approach to service composition in cloud manufacturing[J]. *International Journal of Computer Integrated Manufacturing*, 2017, 30(12): 1331-1342.
- [9] SEGHIR F, KHABABA A. A hybrid approach using genetic and fruit fly optimization algorithms for QoS-aware cloud service composition[J]. *Journal of Intelligent Manufacturing*, 2018, 29: 1773-1792.
- [10] LIM M K, XIONG W, WANG Y. A three-tier programming model for service composition and optimal selection in cloud manufacturing [J]. *Computers & Industrial Engineering*, 2022, 167: 108006.
- [11] GAVVALA S K, JATOCH C, GANGADHARAN G R, et al. QoS-aware cloud service composition using eagle strategy [J]. *Future Generation Computer Systems*, 2019, 90: 273-290.
- [12] 姚娟, 邢镔, 曾骏, 等. 云制造服务组合研究综述[J]. *计算机科学*, 2021, 48(7): 245-255.
- [13] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. *计算机学报*, 2017, 40(6): 1229-1251.
- [14] BOUREAU Y L, ROUX N L, BACH F, et al. Ask the locals: multi-way local pooling for image recognition [C]//2011 International Conference on Computer Vision. Barcelona, Spain: IEEE, 2011: 2651-2658.
- [15] ZEILER M D, FERGUS R. Stochastic pooling for regularization of deep convolutional neural networks[J]. *arXiv preprint arXiv: 1301.3557*, 2013.
- [16] GU Jiuxiang, WANG Zhenhua, KUEN J, et al. Recent advances in convolutional neural networks[J]. *Pattern Recognition*, 2018, 77: 354-377.
- [17] SAINATH T N, KINGSBURY B, MOHAMED A, et al. Improvements to deep convolutional neural networks for LVCSR [C]//2013 IEEE Workshop on Automatic Speech Recognition and Understanding. Olomouc, Czech Republic; IEEE, 2013: 315-320.
- [18] AL-MASRI E, MAHMOUD Q H. Toward quality-driven web service discovery[J]. *IT Professional*, 2008, 10(3): 24-28.
- [19] 梁斌, 刘全, 徐进, 等. 基于多注意力卷积神经网络的特定目标情感分析[J]. *计算机研究与发展*, 2017, 54(8): 1724-1735.
- [20] LIU Yongkui, LIANG Huagang, XIAO Yingying, et al. Logistics-involved service composition in a dynamic cloud manufacturing environment: A DDPG-based approach [J]. *Robotics and Computer-Integrated Manufacturing*, 2022, 76: 102323.