

# 基于深度学习进化的超大规模业务请求与服务功能链高效匹配

王东博

贵州大学大数据与信息工程学院, 贵州 贵阳

收稿日期: 2024年10月21日; 录用日期: 2024年11月8日; 发布日期: 2025年1月10日

## 摘要

随着5G技术与电子商务平台的深度融合, 实现业务请求与服务功能链(SFC)之间的高效匹配, 对于保障电子商务各类交易的平稳运行与顺利实施具有深远的研究意义。如何为这些多样化的业务请求匹配到满足其特定需求的SFC, 已成为当前电子商务领域亟待解决的重要问题。为应对上述挑战, 本文深入剖析了电子商务业务请求与NFC的固有特征, 并据此构建了两者的精准匹配模型。本文创新性地设计了一个基于深度学习进化的优化算法, 旨在高效求解所建立的匹配模型。该算法通过巧妙引入卷积神经网络处理业务请求特征并求解适应度函数为遗传算法提供优化的搜索环境, 显著提升了匹配模型的精度与效率, 并有效降低了计算复杂度, 从而为电子商务环境中的服务功能链匹配问题提供了一种新颖且实用的解决方案。

## 关键词

电子商务, 超大规模, 高效匹配, 深度学习, 遗传算法

# Efficient Matching of Ultra-Large-Scale Business Requests to Service Function Chains Based on Deep Learning Evolution

Dongbo Wang

College of Big Data and Information Engineering, Guizhou University, Guiyang Guizhou

Received: Oct. 21<sup>st</sup>, 2024; accepted: Nov. 8<sup>th</sup>, 2024; published: Jan. 10<sup>th</sup>, 2025

## Abstract

The deep integration of 5G technology with e-commerce platforms underscores the profound

文章引用: 王东博. 基于深度学习进化的超大规模业务请求与服务功能链高效匹配[J]. 电子商务评论, 2025, 14(1): 910-918. DOI: 10.12677/ec.2025.141114

research significance of achieving efficient matching between business requests and service function chains (SFC) to ensure the smooth operation and successful implementation of diverse e-commerce transactions. A pivotal challenge in the current e-commerce domain is matching these diversified business requests to SFC that meet their specific needs. To address this challenge, this paper conducts an in-depth analysis of the inherent characteristics of e-commerce business requests and SFCs, and subsequently constructs a precise matching model between them. Innovatively, we design an optimization algorithm based on deep learning evolution, tailored to efficiently solve the established matching model. By ingeniously incorporating convolutional neural networks (CNNs) to process business request features and solving the fitness function to provide an optimized search environment for the genetic algorithm, the proposed algorithm significantly enhances the accuracy and efficiency of the matching model while effectively reducing computational complexity. This paper thus presents a novel and practical solution to the problem of service function chain matching in e-commerce environments.

## Keywords

E-Commerce, Ultra-Large Scale, Efficient Matching, Deep Learning, Genetic Algorithm

Copyright © 2025 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

## 1. 引言

随着 5G 技术与电子商务的深度融合，我们正迈入一个万物智联的新纪元，其中电子商务业务请求与服务功能链(SFC)之间的高效、精准匹配，不仅是理论研究的前沿课题，更是工程实践中的核心需求[1][2]。从理论研究的视角出发，构建高效、精准的匹配机制能够优化网络资源分配，缓解网络拥堵，提升服务品质，为电子商务的可持续发展奠定坚实的理论基础[3]。这要求我们深入洞察电子商务业务请求的多样性与实时变化性，以及网络服务的功能多样性与可用性，进而开发出更加智能、自适应的匹配模型与算法。在工程实践层面，这一匹配机制对于保障电子商务各类业务的平稳运行与高效实施具有不可估量的战略意义。无论是线上购物、在线支付，还是物流配送、售后服务等关键环节，都高度依赖于稳定、高效的网络服务来确保其业务的连续性与顺畅性[4][5]。因此，实现电子商务业务请求与 SFC 之间的高效、精准匹配，不仅能够显著提升用户体验，增强电商平台的业务竞争力，还能够推动整个电子商务生态系统的繁荣发展。这一目标的实现，将为电子商务行业带来前所未有的发展机遇，助力其在新时代背景下实现更高质量的发展[6]。

在 5G 与电子商务深度融合的场景下，业务请求与 SFC 技术均呈现出前所未有的超大规模特性，这一趋势给网络服务在处理海量、多样化的电商业务需求时带来了严峻的资源分配与调度挑战[7][8]。特别是在网络资源相对有限的情况下，如何确保每一个电商业务请求都能获得及时且有效的响应，成为了一个亟待攻克的关键问题[9]。

对于电子商务中的时间敏感型业务，如即时支付确认、库存实时更新、在线订单追踪等，任何响应的延迟都可能对用户体验造成负面影响，甚至引发信任危机，导致潜在的经济损失[10]。在这样一个实时且大规模的网络环境中，根据电商业务请求的特性和网络资源的实时状态，动态地、高效地匹配最优的 SFC 服务，面临着以下诸多挑战：

电商业务请求场景的业务往往具有高度的时间敏感需求，快速匹配成为挑战。

如何在保证业务连续性的同时，最大化利用有限的网络资源也是一个挑战。

大规模的业务及 SFC 的匹配本身就是一个 NP 难问题。

为了解决以上挑战，启发式算法，如遗传算法、粒子群优化和蚁群优化，通过模拟生物进化及集体行为，有效应对复杂非线性多目标优化问题[11][12]。但在每次迭代中，需计算适应度函数以评估进化状态，这通常依赖于耗时的物理控制方程求解。因此，尽管启发式算法能得出准确结果，但整个优化过程的收敛速度相对较慢。为了提高物理求解效率，深度学习神经网络(CNN)已被用作替代基于物理控制方程的工具，展现出高效与准确性[13][14]。然而，在进化算法的优化问题中，CNN 需多次计算，且特定问题因素会在迭代过程中被放大或继承，增加了复杂性[15]。在本文中，我们希望将启发式算法与 CNN 相结合，以优化搜索的效率和准确性，实现大规模应用环境中 SFC 匹配的高效性。

综上所述，在电子商务领域，当前采用的业务与 SFC 匹配方法主要聚焦于有限的、单一特征维度的匹配任务，这在面对电子商务环境中庞大且多样化的业务需求时显得力不从心。鉴于此，本文提出了一种创新的物理监督高效准确深度学习优化算法(GADLO)，旨在通过监督 CNN 的优化策略，精准识别并妥善处理电子商务业务数据中的错误或异常特征。该算法不仅能够有效提升匹配的准确性，还能在确保高效性的前提下，实现多维特征业务与 SFC 之间的精准匹配。通过 GADLO 算法的引入，我们成功在电子商务的复杂业务环境中，实现了匹配准确性与匹配效率的双重优化，为电子商务平台的高效运营和用户体验的显著提升奠定了坚实基础。

因此，本文的主要贡献如下：

在电子商务领域，我们聚焦业务需求及网络系统资源有限的问题，并建立了一种数学模型，旨在实现大规模场景下的高效匹配。

我们创新性的将 GA 与 CNN 相结合，提出了一种协同策略对模型进行求解，该方法实现了在进化优化过程中实现效率和准确性的平衡。

我们设计了大量模拟实验来验证所提出的方法的性能。

## 2. 系统模型与问题描述

### 2.1. 系统模型

基于深度学习进化的超大规模业务请求与 SFC 高效匹配架构如图 1 所示。图 1 显示了当不同终端设备发送网络服务请求时，系统从现有的 SFCs 中为业务请求匹配最优的 SFC，其中 SFC 是由承载不同网络功能的节点按一定顺序互联组成。业务请求经系统分析后产生的虚拟请求，虚拟请求包含业务请求所需的 VNF，每个 VNF 所需的各种资源特征和资源数量。SFCs 表示为 SFC 集合，每一个 SFC 也可表示为由多个 VNF 按照特定顺序串联起来，并包含特定资源特征和资源数量的链条。

### 2.2. 业务请求与 SFC 模型

首先定义电子商务场景中存在的 SFC 集合为  $S = \{s_1, s_2, \dots, s_n\}$ 。  $s_i \in S$  包含此条 SFC 的服务能力  $C_{s_i} = (R_{s_i}, Q_{s_i}^A)$ ，  $R_{s_i}$  可用资源的数量，  $A = \{a_1, a_2, \dots, a_g\}$  表示服务属性集合，  $Q_{s_i}^A = \{q_{a_1}^{s_i}, q_{a_2}^{s_i}, \dots, q_{a_g}^{s_i}\}$  是  $A$  的声明属性值。业务请求模型定义为  $U = \{u_1, u_2, \dots, u_m\}$ ，  $u_j \in U$  表示第  $j$  个业务请求且包含  $R_{u_j} = (B_{u_j}^{s_i}, Q_{u_j})$ ，  $B_{u_j}^{s_i}$  是资源需求，  $Q_{u_j}^A = \{q_{a_1}^{u_j}, q_{a_2}^{u_j}, \dots, q_{a_g}^{u_j}\}$  是属性  $A$  的需求值，  $Q_{u_j} (0 \leq Q_{u_j} \leq 1)$  是业务可以容忍的最低量化 QoS [16]。

### 2.3. QoS 模型

QoS 标准化模型[17]：考虑到服务属性的量化有多种标准，我们将服务属性的取值范围定为[0, 1]。

定义  $s_i$  属性的规范化值  $a_i \in A$  为  $q_{a_k}^{s_i, u_j}$ ，其由 QoS 规范化模型基于  $q_{a_k}^{s_i}$  和  $q_{a_k}^{u_j}$  计算得到。然后，通过下式计算  $s_i$  面向  $u_j$  服务的归一化 QoS 值：




Figure 1. Efficient matching architecture

图 1. 高效匹配架构

$$Q_{u_j}^{s_i} = \sum_{a_k \in A} w_k \times q_{a_k}^{s_i, u_j} \quad (1)$$

其中， $w_k$  描述属性的重要性且  $0 \leq w_k \leq 1$ ， $\sum_{a_k \in A} w_k = 1$ 。 $Q_{a_k}^{u_j}$  反映了服务质量的水平，它受到各种属性的归一化值的约束。

## 2.4. 收益模型

定义 SFC  $s_i$  为  $u_j$  匹配服务所需单位资源的成本为  $c_{u_j}^{s_i}$ ，用户需要为请求  $u_j$  获得的服务支付的价格为  $P_{u_j}^{s_i}$ 。此时，收益模型可以量化为

$$\Phi_{u_j}^{s_i} = P_{u_j}^{s_i} - c_{u_j}^{s_i} \times B_{u_j}^{s_i} \quad (2)$$

## 2.5. 问题描述

业务向系统发送网络服务请求时，有必要为业务请求定义匹配模型以便其获得满足其需求的网络服务。定义服务匹配决策变量为  $Y = \langle y_{u_1, s_1}, y_{u_1, s_2}, \dots, y_{u_m, s_n} \rangle$ ，其中

$$y_{u_j, s_i} = \begin{cases} 1, & s_i \text{ provides service for } u_j \\ 0, & \text{otherwise} \end{cases} \quad (3)$$

用户的收益可以用总的 QoS 值来描述：

$$Q(X) = \sum_{u_j \in U} \sum_{s_i \in S} Q_{u_j}^{s_i} \times y_{u_j, s_i} \quad (4)$$

服务提供商的总收益模型描述为:

$$\Phi(X) = \sum_{u_j \in U} \sum_{s_i \in S} \Phi_{u_j}^{s_i} \times y_{u_j, s_i} \quad (5)$$

在电子商务场景中, 用户和服务提供商希望通过提供服务或接受服务来获得利益。对于用户来说, 好处是得到满意的服务, 这可以通过服务的 QoS 来量化。对服务提供商来说, 好处是通过提供服务获得的利润。因此, 我们将服务匹配问题表述为一个双目标问题, 称为 RSM, 如下所示:

$$\max_X \Omega(X) = (Q(X), \Phi(X)) \quad (6a)$$

$$\text{s.t. } O_1: \Phi_{u_j}^{s_i} \times y_{u_j, s_i} \geq 0, (\forall u_j \in U, \forall s_i \in S), \quad (6b)$$

$$O_2: (Q_{u_j}^{s_i} - Q_{u_j}) \times y_{u_j, s_i} \geq 0, (\forall u_j \in U, \forall s_i \in S), \quad (6c)$$

$$O_3: \sum_{u_j \in U} B_{u_j}^{s_i} \times y_{u_j, s_i} \leq R_{s_i}, (\forall s_i \in S) \quad (6d)$$

在公式(6b~6d)中, 约束条件  $O_1$  确保服务费用不超过用户的支付。约束  $O_2$  保证 SFC 提供的服务满足用户的最低服务要求。约束条件  $O_3$  保证与 SFC 匹配的服务请求不会超过 SFC 的能力。

RSM 含有两个冲突的目标函数, 其最优解是一个解集。在 RSM 问题中, 总利润和 QoS 是两个目标。因此, 当没有解  $X$  满足  $Q(X) \geq Q(X^*)$  且  $\Phi(X) \geq \Phi(X^*)$  时,  $X^*$  是最优的[18]。为了解决 RSM 问题并获得 Pareto 解集[19], 我们使用线性组合加权和的方法来衡量这两个目标,

$$\max_X E(X) = \alpha Q(X) + \beta \Phi(X), \quad (7)$$

其中,  $\alpha, \beta$  是权重系数,  $\alpha + \beta = 1$ 。权重系数并不反映决策者对目标函数的偏好, 而只是优化因子。通过动态调整它们的值, 得到 Pareto 最优解集中的多个解。

### 3. 业务请求和 SFC 匹配方法

为了在电子商务场景中, 实现业务请求与 SFC 的高效匹配, 本文创新性地提出了一种基于深度学习进化的业务与 SFC 匹配策略(GADLO), 主要包括利用深度学习精准捕捉并分析业务请求中的信息特征, 利用遗传算法(GA)迅速定位并构建满足业务请求具体需求的服务功能链。此方法旨在优化匹配过程, 确保电子商务系统中业务与服务精准对接与高效运行。

#### 3.1. 选择、交叉和变异操作

本文所用的选择、交叉和变异操作如算法 1 所示[20] [21]。

**Algorithm 1.** Selection, crossover, and mutation operations

**算法 1.** 选择、交叉、变异操作

输入: 父代解方案  $X_j$ , 选择、交叉、变异概率为  $p_1$ 、 $p_2$ 、 $p_3$ , 种群大小为  $S$

输出: 子代解决方案  $s_k$

1)  $X_s \leftarrow$  采用“适者生存”原则, 保留适应度前  $c\%$  的个体

2) While  $|X_s| < |X_j|$

3) 使用“轮盘赌”选择一定数量的父代

续表

- 4) 使用单点交叉和两点交叉生成子代  $g1$
- 5)  $X_s \leftarrow X_s + \{g1\}$
- 6) End while
- 7) 随机选择子代  $X_s$  进行变异
- 8)  $X_{sk} \leftarrow X_s$

其中，选择策略采用轮盘赌法；交叉策略采用单点交叉与两点交叉；变异策略采用 0~1 单点变异。

### 3.2. GADLO 框架

GADLO 框架整合了 CNN 特征提取能力和 GA 优化搜索机制，实现了业务请求与服务功能链的精准匹配[22]。该框架首先利用 CNN 提取业务请求的特征向量，然后将这些特征向量作为 GA 的输入，通过 GA 搜索并构建最优服务功能链，最终输出满足业务请求的服务配置。GADLO 的核心原理是在由进化方法驱动的深度学习算法中建立准确性和效率之间的平衡。

GADLO 的详细过程如图 2 所示。首先生成初始种群，通过对 CNN 计算的适应度函数进行排序形成父种群，第一代子种群与 GA + CNN 方法中的子种群相同。现在，为了避免 GA + CNN 的固有问题，这里采用基于物理学的监督作为关键步骤来重新评估该群体的最佳表现者，然后重新对它们进行排序，即，物理学监督的深度学习优化。表现最好的人的数量是一个经验，它平衡了算法的准确性和效率。重复这个过程，直到达到收敛。




Figure 2. GADLO algorithm logic  
图 2. GADLO 算法逻辑



4. 仿真结果分析

本文在仿真中，主要注重在以下方面：GADLO 与其他策略的比较。

4.1. 实验环境配置

为了验证 GADLO 方法的收敛性和性能，基于表 1 中列出的参数进行了一系列仿真实验。这些模拟实验主要考虑的应用虚拟请求由 9 种类型且数量为 25 个的 VNF 随机组成，NFC 则由类型为 9，数量为 20~35 个 VNF 随机形成。每个 VNF 包含四个特征，实现不同网络功能需要消耗一定的虚拟资源块(服务器资源、带宽资源以及存储资源) [23]。除上面信息外，还规定了不同类型的虚拟资源块的价格。

Table 1. Table of key simulation parameters  
表 1. 关键模拟参数表

| 参量         | 值                                                 |
|------------|---------------------------------------------------|
| Windows 10 | Python 10.0                                       |
| 设备         | Intel(R) Core(TM) i7-8750H CPU @ 2.20GHz 2.21 GHz |
| 节点数量       | 4                                                 |
| 数据数量       | $1 \times 10^7$ (NFCs)                            |
| 虚拟功能       | 20~35                                             |
|            | 25                                                |

在本研究中，我们首先将所收集的数据集划分为训练集与测试集两部分，其中测试集占据了总数据集的 10%。为了提高模型的训练效率与泛化性能，我们对数据实施了预处理步骤，具体包括数据的标准化与归一化处理。在模型训练阶段，我们采纳了批量梯度下降算法，通过每次迭代不断更新网络的权重与偏置参数。为确保网络权重得到充分的学习与收敛，我们设定了 10,000 个训练周期(epochs)。为了有效防止模型出现过拟合现象，我们引入了提前停止机制：若验证损失在连续多个迭代周期内未出现显著下降，则训练过程将提前终止。训练结束后，我们利用测试集对模型的性能进行了全面评估，以量化模型的预测准确性。

4.2. 性能分析

我们为在线测试构建了一个模拟在线环境(适应于我们的情况)。我们将 GADLO 与 GA、CRO、PSO 进行对比。




Figure 3. Objective function  
图 3. 目标函数

在图 3 中, 我们比较了 GA、PSO 和改进的 GADLO 算法在求解不同规模业务请求与 SFC 匹配问题中的表现。对于所有方法, 我们观察到随着搜索次数的增加, 它们最终都能搜索到最优结果。然而, 在迭代时间和适应度函数上存在细微差异。从结果中可以看出, GA、PSO 和改进的 GADLO 算法收敛时间和适应度函数值均相差不大, 但 GADLO 算法的收敛速度明显更快。收敛时间: GA: 0.5927 s, PSO: 0.471 s, RSTCRO: 0.0848 s。可以看出 GADLO 显示出最高的效率。与 GA、PSO 相比, RSTCRO 不仅在适应度函数值上可以保持相同的精度, 在收敛速度上更具优势, 收敛时间提高了 81.72%。

图 4 比较了不同策略(GA, PSO, GADLO)得到的最优 SFC 在 QoS 以及服务收益方面的表现。图 4 展示了在不同规模数据集条件下, 三种策略搜索到的最优解的 QoS (左边)和服务收益(右边)表现。可以直观的看到, 随着数据规模的扩大, GA、PSO 策略可能由于陷入局部最优解等原因搜索到的最优解的 QoS 较 GADLO 低。无论在什么条件下, GADLO 得到解的 QoS 满足率可以达到 85%以上, 状态稳定, 而 GA、PSO 则随着数据规模的增加变得不稳定, QoS 保证率降低。而服务收益则相差不大, 与其他基准策略相比, 我们提出的方法始终提供稳定性能, 展示了其在高效匹配过程中 QoS 保证和服务收益的双重挑战方面的有效性。




Figure 4. QoS versus service benefits

图 4. QoS 和服务收益对比

## 5. 结论

在电子商务迅速发展的背景下, 业务请求与网络服务之间的高效匹配问题愈发凸显其重要性[24]。本文致力于解决这一关键问题, 通过深入分析电子商务业务请求与服务功能链(SFC)的固有特征, 我们构建了一个精准匹配模型, 旨在实现两者之间的有效对接。首先, 我们观察到电子商务业务请求具有数量庞大、种类繁多、特征维度高等特点, 这给传统的服务提供机制带来了巨大挑战。为了应对这些挑战, 我们基于业务请求和 SFC 的特性, 构建了匹配模型。该模型能够捕捉业务请求的多样性, 并将其与相应的 SFC 进行精确匹配, 从而满足电子商务环境中的各种需求。为了求解这一匹配模型, 我们创新性地设计了一个基于深度学习进化的优化算法。该算法通过引入 CNN 来处理业务请求的特征, 利用 CNN 的强大特征提取能力, 我们能够更准确地理解业务请求的需求。同时, 我们将 GA 作为优化框架, 通过求解适应度函数来提供优化的搜索环境。CNN 和 GA 的结合使得算法能够在复杂的问题空间中高效搜索, 并找到最优解。

本文提出的基于深度学习进化的优化算法为电子商务环境中的服务功能链匹配问题提供了一种有效的解决方案。该算法不仅提高了匹配的准确性和效率, 还降低了计算复杂度, 为电子商务的平稳运行和



顺利实施提供了有力保障。未来,我们将继续研究和完善这一算法,以适应电子商务领域的不断发展变化。

## 参考文献

- [1] 方雪昀. 5G 环境下移动电子商务模式发展研究[J]. 商场现代化, 2024(17): 32-34.
- [2] 赵季红, 罗兴刚, 曲桦, 等. 工业物联网中基于多维特征业务的网络切片匹配算法[J]. 计算机应用研究, 2023, 40(2): 549-553+570.
- [3] 贾昱, 狄然, 王念新, 等. 信息技术与业务匹配研究进展评述——基于社会网络分析法[J]. 计算机应用与软件, 2017, 34(1): 1-8+20.
- [4] 完颜绍澎, 于佳. 5G 技术性能与电力业务的匹配性分析[J]. 山东电力技术, 2022, 49(7): 1-7.
- [5] 刘如月. 信息技术与业务战略匹配对制造企业服务化的影响研究[D]: [博士学位论文]. 济南: 山东大学, 2020.
- [6] 郭江洲. 计算机网络安全技术在电子商务中的应用[J]. 网络安全技术与应用, 2022(3): 98-99.
- [7] 梁勇康. 基于数字孪生的移动通信网络资源调度算法研究[D]: [硕士学位论文]. 成都: 电子科技大学, 2024.
- [8] 彭开来, 王旭, 唐琴琴. 算力网络资源协同调度探索与应用[J]. 中兴通讯技术, 2023, 29(4): 26-31.
- [9] 郝一浩. 考虑业务特性的需求响应信息传输优化技术研究[D]: [硕士学位论文]. 北京: 华北电力大学(北京), 2023.
- [10] 荆元春. 电子商务环境下基于实时信息的单类协同过滤算法研究[D]: [硕士学位论文]. 北京: 北京交通大学, 2015.
- [11] 廖想, 周安琪, 刘珂, 等. 海狸算法: 一种自然启发的元启发式算法[J/OL]. 控制与决策, 1-7. <https://doi.org/10.13195/j.kzyjc.2024.0362>, 2024-10-14.
- [12] 熊福力, 陈思远, 熊宁馨, 等. 基于两阶段混合迭代贪婪算法的分布式异构非置换流水车间调度[J/OL]. 计算机集成制造系统, 1-19. <https://doi.org/10.13196/j.cims.2024.0232>, 2024-10-14.
- [13] 辛锐, 吴军英, 薛冰, 等. 基于深度强化学习的电力物联网动态切片策略研究[J]. 无线电工程, 2024, 54(6): 1380-1387.
- [14] 戚银城, 唐奕明. 基于多智能体深度强化学习的智能电网光网络切片方案[J]. 半导体光电, 2022, 43(5): 979-985.
- [15] 杨锦辉. 基于深度学习的目标检测方法轻量化研究[D]: [硕士学位论文]. 北京: 中国科学院大学(中国科学院光电技术研究所), 2022.
- [16] Dai, M., Guo, S., Guo, S., Shao, S. and Qiu, X. (2024) Trusted Sharing of Computing Power Resources: Benefit-Driven Heterogeneous Network Service Provision Mechanism. *IEEE Transactions on Services Computing*, 17, 1265-1278. <https://doi.org/10.1109/tsc.2024.3394697>
- [17] Wang, H., Yu, C., Wang, L. and Yu, Q. (2018) Effective Bigdata-Space Service Selection over Trust and Heterogeneous QoS Preferences. *IEEE Transactions on Services Computing*, 11, 644-657. <https://doi.org/10.1109/tsc.2015.2480393>
- [18] Zitzler, E., Thiele, L., Laumanns, M., Fonseca, C.M. and da Fonseca, V.G. (2003) Performance Assessment of Multiobjective Optimizers: An Analysis and Review. *IEEE Transactions on Evolutionary Computation*, 7, 117-132. <https://doi.org/10.1109/tevc.2003.810758>
- [19] Cho, J., Wang, Y., Chen, I., Chan, K.S. and Swami, A. (2017) A Survey on Modeling and Optimizing Multi-Objective Systems. *IEEE Communications Surveys & Tutorials*, 19, 1867-1901. <https://doi.org/10.1109/comst.2017.2698366>
- [20] 冯睿锋, 陈彦如. 融合深度强化学习的改进遗传算法求解众包车辆-公共交通协同配送问题[J/OL]. 计算机工程, 1-11. <https://doi.org/10.19678/j.issn.1000-3428.0069548>, 2024-10-14.
- [21] 范海菊, 马锦程, 李名. 基于深度神经网络的遗传算法对抗攻击[J/OL]. 河南师范大学学报(自然科学版), 1-10. <https://doi.org/10.16366/j.cnki.1000-2367.2023.09.21.0003>, 2024-10-14.
- [22] Li, X., Chang, L., Cao, Y., Lu, J., Lu, X. and Jiang, H. (2023) Physics-Supervised Deep Learning-Based Optimization (PSDLO) with Accuracy and Efficiency. *Proceedings of the National Academy of Sciences of the United States of America*, 120, e2309062120. <https://pubmed.ncbi.nlm.nih.gov/37603744/>
- [23] Zou, S., Wang, W., Ni, W., Wang, L. and Tang, Y. (2022) Efficient Orchestration of Virtualization Resource in RAN Based on Chemical Reaction Optimization and Q-Learning. *IEEE Internet of Things Journal*, 9, 3383-3396. <https://doi.org/10.1109/jiot.2021.3098331>
- [24] 杨婉玥. 基于适配机制的 Web 服务匹配研究[D]: [硕士学位论文]. 南昌: 江西财经大学, 2021.