

分类号：
密 级：

学校代码：10389
学 号：12311093008



福建农林大学

硕士学位论文

(学术学位)

动态网络环境下服务功能链协同迁移与准入策略研究

学 习 形 式：全日制

一级学科名称：计算机科学与技术

二级学科名称：

研 究 方 向：计算机网络与信息安全

研究生姓名：罗昱

指 导 教 师：舒兆港 副教授

完 成 时 间：二〇二六年五月

Research on Collaborative Migration and Access Policies for Service Function Chains in Dynamic Network Environments

By

Yu Luo

Supervised by Assoc. Prof. Zhaogang Shu

A Dissertation Submitted to

Fujian Agriculture and Forestry University

in Partial Fulfillment of the Requirements

for

Master Degree of Engineering

College of Computer and Information Science

Fujian Agriculture and Forestry University

Fujian, P.R. China

Completion Date: (May 30, 2026)

Commencement Date (December 13, 2024)

独创性声明

本人声明，所呈交的学位（毕业）论文，是本人在指导教师的指导下独立完成的研究成果，并且是自己撰写的。尽我所知，除了文中作了标注和致谢中已作了答谢的地方外，论文中不包含其他人发表或撰写过的研究成果。与我一同对本研究做出贡献的同志，都在论文中作了明确的说明并表示了谢意，如被查有侵犯他人知识产权的行为，由本人承担应有的责任。

学位（毕业）论文作者亲笔签名：罗昱

日期：2026年5月30日

论文使用授权的说明

本人完全了解福建农林大学有关保留、使用学位（毕业）论文的规定，即学校有权送交论文的复印件，允许论文被查阅和借阅；学校可以公布论文的全部或部分内容，可以采用影印、缩印或其他复制手段保存论文。

延期公开，在 年后可适用本授权书。 ☐

公开，本论文属于不延期公开论文。 ☒

学位（毕业）论文作者亲笔签名：罗昱

日期：2026年5月30日

指导教师亲笔签名：舒明

日期：2026年5月30日

目 录

摘 要.....	III
ABSTRACT.....	IV
1 绪论.....	1
1.1 研究背景及意义.....	1
1.2 国内外研究现状.....	2
1.2.1 面向迁移后 SFC 端到端时延的优化研究	3
1.2.2 面向迁移成本与网络开销的优化研究.....	4
1.2.3 机器学习助力 VNF 迁移研究	5
1.2.4 VNF 迁移机制设计与在线优化研究.....	6
1.2.5 研究现状小结.....	6
1.3 研究内容与组织架构.....	7
1.4 论文的组织结构.....	8
2 相关理论基础.....	10
2.1 新型网络架构基础.....	10
2.1.1 软件定义网络架构.....	10
2.1.2 网络功能虚拟化架构.....	11
2.1.3 服务功能链架构.....	12
2.2 数学优化理论.....	12
2.2.1 拉格朗日松弛与对偶优化理论.....	12
2.2.2 群智能优化与人工鱼群算法.....	12
2.3 微观经济学与拥塞控制理论.....	13
2.4 本章小结.....	13
3 基于优先级感知的多目标 VNF 迁移优化算法.....	14
3.1 引言.....	14
3.2 问题描述与建模.....	14
3.2.1 问题描述.....	15
3.2.2 问题建模.....	15
3.3 问题求解.....	21
3.3.1 算法设计.....	21
3.3.2 算法复杂性分析.....	27

3.4 仿真设计与性能分析.....	27
3.4.1 实验环境和参数设置.....	28
3.4.2 对比算法介绍.....	28
3.4.3 评价指标.....	29
3.4.4 实验结果与分析.....	30
3.4.5 本章小结.....	33
4 基于拥塞反馈与收益最大化的 VNF 迁移机制.....	34
4.1 引言.....	34
4.2 问题描述与建模.....	34
4.2.1 问题描述.....	34
4.2.2 问题建模.....	35
4.3 问题求解.....	40
4.3.1 算法设计.....	40
4.3.2 算法复杂性分析.....	45
4.4 仿真设计与性能分析.....	45
4.4.1 实验环境和参数设值.....	46
4.4.2 对比算法介绍.....	46
4.4.3 评价指标.....	47
4.4.4 实验结果与分析.....	48
4.4.5 本章小结.....	55
5 总结与展望.....	56
5.1 主要工作总结.....	56
5.2 创新点.....	56
5.3 不足与展望.....	57
参考文献.....	59
攻读学位期间的学术论文与研究成果.....	64
致谢.....	65

摘 要

随着网络功能虚拟化（NFV）技术的不断发展，虚拟网络功能（VNF）迁移已成为优化网络资源利用率、降低服务延迟和提高服务质量的关键手段。然而，边缘网络环境具有高度的动态性与资源异构性，如何在常规负载下降低运营成本，并在突发过载下保障关键业务价值，是当前亟待解决的两大挑战。为此，本文从成本优化与价值博弈两个维度展开研究，主要工作如下：

1. 针对资源相对充裕的常规网络环境，提出了一种基于优先级感知与多目标优化的 VNF 迁移算法（LFO-VNM）。区别于传统仅关注单一迁移代价的优化策略，本文综合考虑迁移成本、迁移后路由开销以及节点能耗等多个优化目标，并引入业务优先级感知机制，以增强关键业务在资源竞争条件下的服务保障能力。在此基础上，提出将拉格朗日松弛方法与人工鱼群算法（AFSA）相结合的 LFO-VNM 算法。该算法通过拉格朗日松弛将复杂的多目标优化问题分解为易于求解的线性子问题，利用 AFSA 的全局搜索能力动态调整资源分配与迁移路径。实验结果表明，在非过载场景下，该算法能够有效权衡服务请求优先级，显著降低迁移总成本与网络能耗，优于现有主流迁移算法。

2. 针对突发流量导致的资源受限与过载环境，提出了一种基于拥塞反馈的动态定价准入机制（CF-DPA）。鉴于传统全量接纳策略在资源饱和状态下易引发计算死锁与高价值业务受损的问题，本文进一步引入微观经济学中的影子价格理论，构建了基于动态投资回报率（ROI）的博弈准入模型。该机制将准入控制后置于迁移阶段，通过将物理资源的稀缺程度映射为动态价格信号，构建了“准入筛选-虚拟部署-价格修正”的双层闭环反馈体系。CF-DPA 能够在过载发生时主动清洗低效能负载，优先保障高优先级（如 URLLC）业务的资源供给。实验证明，该机制实现了优化目标从成本最小化到利润最大化的范式转变，有效提升了系统在极端环境下的生存性与运营收益。

关键词：网络功能虚拟化；VNF 迁移；准入控制；多目标优化

ABSTRACT

With the continuous evolution of Network Function Virtualization (NFV), Virtual Network Function (VNF) migration has emerged as a critical mechanism for optimizing network resource utilization, minimizing service latency, and enhancing Quality of Service (QoS). However, the highly dynamic nature and resource heterogeneity of edge network environments present significant challenges. Effectively reducing operational costs under normal load conditions while safeguarding critical service value during burst traffic overloads remains a pressing issue. To address these challenges, this thesis conducts research from two dimensions: cost optimization and value-based game theory. The main contributions are as follows:

1. A priority-aware and multi-objective VNF migration algorithm (LFO-VNM) is proposed for conventional network environments with relatively sufficient resources. Unlike traditional optimization strategies that focus solely on migration cost, the proposed method comprehensively considers multiple optimization objectives, including migration cost, post-migration routing overhead, and node energy consumption, while incorporating a service priority-aware mechanism to enhance the service assurance capability of critical requests under resource competition. On this basis, the LFO-VNM algorithm, which combines Lagrangian relaxation with the Artificial Fish Swarm Algorithm (AFSA), is developed. Specifically, Lagrangian relaxation is employed to decompose the complex multi-objective optimization problem into tractable linear sub-problems, while AFSA leverages its global search capability to dynamically optimize resource allocation and migration paths. Experimental results demonstrate that, in non-overloaded scenarios, the proposed algorithm effectively balances service request priorities and significantly reduces total migration cost and network energy consumption, outperforming existing mainstream VNF migration approaches.

2. A Congestion-Feedback based Dynamic Pricing Admission (CF-DPA) mechanism is proposed for resource-constrained environments facing burst traffic overloads. Addressing the issues of computational deadlock and the impairment of high-value services caused by traditional "all-acceptance" strategies under resource saturation, this thesis introduces shadow pricing theory from microeconomics to construct a game-theoretic admission model based on dynamic Return on Investment (ROI). This mechanism positions admission control within the migration phase, establishing a dual-layer closed-loop feedback system of "admission screening - virtual deployment - price correction" by mapping physical resource scarcity to dynamic price signals. CF-DPA actively purges low-efficiency loads during overloads to prioritize resource provisioning for high-priority services (e.g., URLLC). Experiments verify that this mechanism achieves a paradigm shift from cost minimization to profit maximization, effectively enhancing system survivability and operational revenue in extreme environments.

KEYWORDS: Network Function Virtualization; VNF Migration; Admission Control; Multi-objective Optimization

1 绪论

1.1 研究背景及意义

随着网络功能虚拟化（NFV）^[1-3]技术的兴起，传统网络架构对专用硬件的依赖逐渐显露出局限性，难以满足日益复杂且动态的服务需求。NFV 通过将网络功能与专用硬件解耦，使其在通用计算设备上运行，从而增强网络灵活性与可扩展性。该技术还通过虚拟化实现高效资源利用与灵活部署。作为 NFV 的核心技术之一，虚拟网络功能（VNF）以虚拟机或容器形式运行，多个 VNF 实例通过服务功能链（SFC）^[4,5]串联，从而提供端到端网络服务。SFC 融合 NFV 与软件定义网络（SDN）的优势^[6-8]，不仅实现服务链的动态管理，更优化了物理网络资源的映射关系。如图 1-1 所示，网络功能虚拟化通过虚拟化层将负载均衡器、防火墙和网络地址转换器等物理设备转化为虚拟功能，从而建立逻辑链与物理链之间的关联关系。




图 1-1 网络功能虚拟化图例

然而，在动态网络环境中，用户请求的随机波动与物理资源的不均衡分布常导致节点或链路资源过载。这不仅增加服务延迟甚至可能引发服务中断，更显著降低网络整体资源利用效率，从而影响用户体验。为缓解这些问题，虚拟网络功能迁移技术应运而生^[9,10]。通过将 VNF 从过载节点迁移至低负载节点，该技术能有效平衡资源分配并提升网络性能^[11,12]。但在边缘计算与核心网深度融合的复杂

场景中，VNF 迁移面临多维挑战：一方面，常态运行下的迁移决策需同时权衡迁移带宽消耗、服务中断代价、迁移后路由开销与节点能耗等相互冲突的目标，静态或单目标策略难以获得稳定的全局最优权衡，导致运营支出（OPEX）居高不下。另一方面，在大型活动直播、应急响应等突发场景下，边缘节点易进入资源饱和的极端过载状态，若仍采用尽力而为或全量接纳策略，可能造成资源耗尽、控制平面拥塞甚至“低价值业务挤占高优先级业务”的价值稀释现象，难以满足关键业务的服务等级协议（SLA）要求。现有研究在应对网络时变性方面虽已取得进展，但对平稳到过载的全场景自适应能力仍存在不足。

基于上述背景，本文围绕两类典型运行条件展开研究：在资源相对充裕场景下，面向迁移成本-路由成本-能耗成本等多目标耦合约束构建优化模型并设计高效近似求解框架，对应第三章的多目标迁移优化研究；在资源受限与过载场景下，引入影子价格与拥塞反馈机制，构建动态定价驱动的利润最大化准入与迁移协同框架，对应第四章的准入闭环控制研究。该研究既可丰富动态资源调度的理论体系，也可边缘-核心协同网络中的高价值业务保障与资源博弈提供可解释的工程化支撑。

1.2 国内外研究现状

现代通信网络中，随着运行环境和服务需求的不断变化，资源负载波动频繁，服务质量（QoS）也因此受到影响。用户对网络服务质量的要求日益提高，迫使网络运营商必须灵活调整网络资源配置，以满足动态环境下的多样化需求。然而，在有限的网络资源条件下实现高效的网络管理，依然是一个具有挑战性的问题。

虚拟网络功能（VNF）和服务功能链（SFC）的引入，为动态网络环境中的资源管理提供了新的思路。通过将 VNF 动态部署于物理节点，并以 SFC 的形式链接服务，网络运营商能够更加灵活地分配资源。然而，随着服务请求和资源利用的动态变化，节点和链路的过载问题频发，导致 VNF 迁移成为保持服务质量的重要手段^[13-15]。VNF 迁移过程涉及迁移成本、路由开销、节点能耗等多方面的权衡，如何在降低迁移影响的同时优化资源分配，成为研究的核心问题。现有研究在优先级感知的服务调度^[16,17]、多目标优化^[18,19]和动态负载均衡^[20,21]等领域取得了一定成果。部分研究通过引入 VNF 与物理节点的优先级机制，在资源受限条件下优先保障关键业务，从而提升高优先级服务请求的接纳率。与此同时，也有研究侧重于设计更高效的启发式算法^[22]，或借助机器学习^[23]构建预测与决策模型，以提升资源利用效率、缓解拥塞并降低迁移引发的时延退化。然而，现有

工作多围绕特定网络假设或单一优化目标展开，难以在动态变化的网络环境中同时兼顾服务质量保障、迁移开销控制与全局资源协调等多维需求。因此，如何面向动态网络场景构建可扩展、可解释且具备在线适应能力的综合优化机制，实现多因素耦合约束下的高效资源管理与稳定服务保障，仍是值得深入研究的重要方向。

随着 NFV 与 SFC 技术的发展，VNF 迁移已成为提升网络弹性与服务连续性的关键手段^[24,25]，国内外学者围绕迁移触发、迁移决策与迁移执行过程中的性能权衡开展了系统研究。总体而言，相关工作主要聚焦于迁移过程及迁移后系统状态对多维指标的影响，并通过优化建模与算法设计提升迁移效率与网络适应性。依据研究侧重点的不同，现有 VNF 迁移研究可归纳为以下四类：1) 面向迁移后 SFC 端到端时延的优化研究；2) 面向迁移成本与网络开销的优化研究；3) 机器学习赋能的 VNF 迁移研究；4) VNF 迁移机制设计与在线优化研究。上述分类为本文后续在多目标迁移优化与拥塞反馈动态定价准入机制上的研究展开奠定了清晰的文献脉络与问题背景。

1.2.1 面向迁移后 SFC 端到端时延的优化研究

这类研究主要关注在 VNF 迁移过程中如何尽量减少迁移操作对 SFC 整体延迟的影响。目标是优化 SFC 服务质量(QoS)，确保迁移后服务的稳定性和性能。Shoura F 等人^[26]提出了一种贪婪最小迁移成本(GMMC)算法。将网络功能迁移问题被表述为整数线性规划(ILP)，目标是在满足计算和网络资源容量约束的同时最小化迁移成本，并选择从源到目标节点的成本最低的路径。Qu H 等人^[17]提出了一种新的 VNF 可靠优化迁移 PAVM 算法，该算法区分了网络拥塞和节点故障状态下的两种 VNF 迁移方案，并设计了节点和 VNF 优先级感知机制，能够在合适的节点上选择合适的 VNF 进行迁移。联合利用网络的时延、负载均衡等反馈因素来优化 QoS。Li B 等人^[27]将 VNF 迁移和 SFC 重新配置问题形式化为一个数学模型，旨在最小化所有受影响服务的端到端延迟，并同时保证迁移后的网络负载均衡，为了减少大规模网络的计算开销，设计了一种基于最优顺序的多阶段启发式算法。Qin Y 等人^[28]提出了拓扑感知的最小延迟 SFC 迁移(TMSM)方法，以在 SFC 延迟和迁移成本之间取得理想的平衡。提出了一种基于马尔可夫近似的启发式算法来为每个子问题寻找近似最优解。Yue Y 等人^[29]根据实际网络情况选择并发迁移 VNF 实例的最佳迁移位置。首先，将 VNF 迁移问题制定为优化模型，其目标是最小化所有受影响的 SFC 的端到端延迟，同时保证迁移后的网络负载均衡。接下来，设计了一种基于深度学习的两阶段算法(DLTSA)来解决 VNF

迁移问题。Yue Y 等人^[30]根据实际网络情况选择并发迁移 VNF 实例的最佳迁移位置。首先将 VNF 迁移问题表述为一个优化模型，其目标是最小化所有受影响的 SFC 的端到端延迟，同时保证迁移后的网络负载平衡。接下来设计了两阶段混合遗传进化（T-SHGE）方案来解决 VNF 迁移问题。Song S 等人^[31]集中讨论了集群之间的 VNF 迁移问题，考虑了用户移动性，以最小化服务的 E2E 延迟。Cho D 等人^[32]制定了 VNF 迁移问题，开发了一种称为 VNF 实时迁移(VNF-RM)的新型 VNF 迁移算法，以在动态变化的资源可用性中降低网络延迟。研究进展表明，通过感知网络状态、优化迁移路径以及动态负载平衡^[33]，可以有效降低迁移后延迟。然而，这些方法在面对动态复杂的网络环境时，实时性和鲁棒性仍存在不足，且部分解决方案计算复杂度较高，难以满足大规模网络的应用需求。

1.2.2 面向迁移成本与网络开销的优化研究

此类研究集中于减少迁移过程中的资源开销，如带宽、存储和计算资源的消耗，以及与迁移相关的能源使用和经济成本。研究重点在于开发高效的迁移算法，以降低总体迁移代价。Liu D 等人^[34]首次提出部分迁移模型，该模型专为单个 VNF 实例被多个 SFC 共享的场景设计。完整迁移需要迁移全部相关 VNF 实例，而部分迁移仅选择对系统性能影响较大的关键 VNF 进行选择迁移，以减少迁移成本与服务扰动，该方案仅选择性迁移那些迁移后能最大程度降低端到端延迟的 VNF，从而同时最小化整体链路延迟与迁移开销。此外，该方案整合了实时负载监控功能，可根据资源使用波动动态调整迁移子集。尽管该方法减少了不必要的迁移开销，但仅关注迁移过程中的局部优化，未涉及全局资源管理。部分研究聚焦于 VNF 集群迁移与嵌入优化。Afrasiabi S N 等人^[35]探讨了 VNF 集群迁移问题——同一集群内的 VNF 实例常被多个服务链复用，该研究提出整数线性规划（ILP）模型并设计高效迁移算法以降低嵌入成本，直接支持共享单一 VNF 实例的多 SFC 高效迁移。然而该方法主要适用于静态拓扑结构，在动态环境中适应性有限。Xu S 等人^[36]以提高网络性能和降低网络开销为目标，提出了一种基于开销优化、负载均衡和可靠性的 SFC 映射算法，将 SFC 请求映射到网络上并提供备份。其次，以优化资源配置为目标，提出了一种基于能耗和服务质量的 SFC 迁移方法来整合网络资源。提出了一种基于可靠性和能量平衡的服务功能链映射与迁移方法。Yi B 等人^[37]首先将 VNF 迁移问题表述为一个以最小化影响为目标的数学模型。然后，提出了一种多标准方法来解决这个问题，因为我们需要同时考虑多个服务。特别是，建议的方法也考虑了服务的优先级，以适应实际情况。Zhang F 等^[38]利用时间卷积网络（TCN）来快速准确地预测 VNF 迁移决策的流

量。根据预测结果,定义一个指标,即迁移指数,来表示网络中每个节点的负载趋势。然后基于迁移指标提出一种快速高效的启发式 VNF 迁移算法,目标是 최소화一段时间内的总迁移成本。Xiao J 等^[39]提出了一种基于多目标优化的 SFC 部署策略 MO-SACO,该策略以时延优化、可靠性保证和成本降低为主要目标。然后,将 VNF 放置和流量路由建模为基于云雾边缘协作的计算卸载决策,其目标是根据功能,位置和资源约束进行目标优化。最后,我们还考虑了已部署 SFC 的性能变化,并及时处理不合规的请求。Karim A 等人^[40]将运行 SFC 的 VNF 动态映射到 5G 网络中的不同虚拟机的的问题被表述为多目标线性规划(MOLP)问题。开发的优化模型,即 Trade-Lcm,最大限度地减少了用户应用程序服务延迟,同时降低了迁移与 SFC 相关的虚拟网络功能的成本。Xia J 等人^[41]提出了一种成本模型来测量 VNF 迁移成本,解决了虚拟网络功能的最佳迁移问题,提出了一种启发式算法来计算近似解。Eramo V 等人^[42]开发了一种方法,这三种算法连续使用,导致 VNFI 放置、SFC 路由和 VNFI 迁移,以响应不断变化的工作负载。目标首先是最大限度地减少对 SFC 带宽的拒绝,其次是将 VNFI 整合到尽可能少的服务器中,以减少能源消耗,该策略考虑了由于迁移期间发生的信息丢失而导致用户遭受的 QoS 降级所带来的收入损失。目标是最大限度地减少能源消耗和服务质量下降造成的收入损失所带来的总成本。Zhang Q 等人^[43]提出了一种用于实时 VNF 部署和成本的在线延迟迁移自适应干扰感知算法,优化 VNF 迁移并重新部署被拒绝的请求,旨在最大限度地降低迁移成本和迁移频率。在完整 VNF 迁移方法中,迁移后延迟增加的 SFC 也会被迁移,从而产生额外的迁移成本。相比之下,部分 VNF 迁移可保持这些 SFC 不变,从而降低迁移成本并最大限度地减少总体 SFC 延迟。这些方法能够有效减少迁移的资源开销和频率,同时提升网络资源利用效率。然而,迁移成本与服务质量的平衡仍是一个难题,部分方法虽然在降低迁移开销方面表现出色,但可能导致服务延迟或 QoS 下降。同时,对于大规模复杂网络中的动态环境,现有方法的计算效率和适用性仍有提升空间。

1.2.3 机器学习助力 VNF 迁移研究

机器学习技术^[44]逐渐被引入到 VNF 迁移中,用于预测网络状态、智能决策迁移时间和目标节点,或通过强化学习实现迁移策略优化。这些研究旨在通过智能化手段提升迁移效率和精度。Liu Q 等^[45]提出了一种基于联邦学习和双向门控循环单元(Bi-GRU)的资源需求预测算法(FedBi-GRU)。该算法通过分布式预测减少了迁移频率,同时在隐私保护和计算效率上优于传统集中式方法。此外,他们设计了一种基于深度强化学习的 DPPO 算法,将能耗优化与负载均衡目标

转化为马尔可夫决策过程（MDP），实现了 VNF 迁移策略的高效决策。Zhai D 等^[46]提出一种基于改进的长短期记忆神经网络（PMILSTM）的故障预测方法，利用 LSTM 进行故障预测。为了进一步提高预测精度，采用模拟退火粒子群优化算法对每个长短期记忆层的神经元数量和时间窗口长度进行优化，有效地降低了迁移成本和迁移时间。这些方法通过智能化手段提升了迁移决策的精确性和效率，特别是在动态网络环境中表现出较强的适应能力。然而，现有研究仍存在模型复杂度较高、计算成本较大，以及训练数据需求较高的问题。此外，对于网络状态变化剧烈的场景，预测的准确性和实时性仍需改进。

1.2.4 VNF 迁移机制设计与在线优化研究

这一类研究聚焦于设计灵活高效的迁移机制，包括在线迁移、离线迁移、热迁移与冷迁移等。其目标是确保迁移过程的稳定性，同时考虑服务中断时间和网络资源利用效率。虚拟机（VM）的实时迁移^[47]是减少服务停机时间的有效方法。以下研究对 VNF 迁移机制进行了调查：Ibrahimpasić A L 等^[48]提出了一种新的成本模型和 AI 授权的方法，用于有状态 VNF 的合理迁移，该方法最小化了运营成本和停机造成的潜在损失之和，并且能够处理复杂的现实用户移动模式。Saidi M Y 等人^[49]解决了在线 VNF 放置和链接（VNF-PC）问题，旨在优化整体成本，同时满足资源约束。使用非线性规划来制定 VNF-PC 问题，该规划擅长处理和解决问题的小规模实例。Nobach L 等人^[50,51]提出一种基于新颖接口“statelet”的框架，以实现无缝 VNF 实时迁移和状态转移。Cerroni W 等人^[52]提出了一个模型来评估多个 VM 实时迁移的性能，以最大限度地减少停机时间。Zhang J 等人^[53]通过过滤掉无用的内存页和快速内存压缩，加速了通用 VNF 的迁移过程。此外，容器技术支持更灵活的 VNF 实施，从而实现比传统 VM 更快的实时迁移^[54]。Addad R A 等人^[55]利用了基于容器的实时迁移技术，并提出了两种在边缘云之间快速迁移服务的解决方案。这些方法通过优化迁移流程和状态转移，显著提升了迁移效率和服务稳定性。然而，现有迁移机制在处理多任务并发迁移时，容易面临资源竞争和迁移冲突的问题，同时迁移的全局资源优化仍不足。

1.2.5 研究现状小结

国内外学者对 VNF 迁移进行了广泛研究，主要聚焦于迁移后 SFC 延迟优化、迁移成本控制、机器学习辅助决策及迁移机制设计等方面。现有研究通过感知网络状态、优化迁移路径以及动态负载平衡，在降低延迟和迁移开销、提升资源利

用率方面取得了一定进展；同时，引入机器学习技术显著提升了迁移决策的智能化水平，而针对不同场景设计的灵活迁移机制则有效增强了服务的稳定性。然而，当前研究多侧重于单一目标优化，难以全面权衡迁移成本、路由开销、节点能耗及服务优先级等多重因素，特别是在动态复杂的网络环境中，其实时性、鲁棒性及对大规模网络的适用性仍面临挑战。此外，现有方法在资源过载与服务请求优先级冲突时的处理机制尚显不足，且智能化模型往往伴随较高的计算复杂度与数据依赖。因此，如何在动态变化的网络环境中综合考虑多目标优化，设计高效、灵活且具备优先级感知能力的 VNF 迁移策略，仍是亟待深入探索的关键问题。

1.3 研究内容与组织架构

鉴于现有 VNF 迁移策略在多维资源约束与动态服务需求适配方面的局限性，特别是难以在不同网络负载场景下兼顾迁移成本控制与高价值业务保障，本文分别针对常规负载下的多目标协同优化与资源受限过载下的价值博弈问题，提出了差异化的解决机制，具体研究内容如下：

（1）针对常规网络负载环境下的资源调度难题，本文构建了综合考量迁移成本、路由开销及节点能耗的混合整数线性规划（MILP）模型。为突破该 NP 难问题的求解瓶颈，提出了一种基于优先级感知与拉格朗日松弛优化的 VNF 迁移算法（LFO-VNM）。该算法首先利用拉格朗日松弛技术将复杂的多维资源耦合约束解耦为一系列易于求解的线性子问题，随后结合改进的人工鱼群算法（AFSA）的全局寻优能力对对偶问题进行迭代求解。通过在解空间搜索中动态调整步长与视野，LFO-VNM 算法能够在保障不同优先级服务质量的前提下，有效平衡计算效率与解的质量，实现了网络运营总成本的最小化。

（2）针对突发流量导致的网络过载与资源受限问题，本文进一步从经济学视角出发，设计了一种基于拥塞反馈的动态定价准入机制（CF-DPA）。该机制引入微观经济学中的影子价格理论，建立物理资源稀缺性与业务价值之间的动态映射关系，并通过基于投资回报率（ROI）的博弈模型对服务请求进行精细化筛选。通过构建“准入筛选-虚拟部署-价格修正”的双层闭环反馈体系，CF-DPA 能够在资源饱和时根据节点实时负载动态调整资源定价，主动抑制低价值流量对关键资源的挤占，从而实现了优化目标从“运维侧成本最小化”向“经营侧利润最大化”的范式转变，显著提升了极端工况下系统的鲁棒性与关键业务的保障能力。

1.4 论文的组织结构

基于网络功能虚拟化（NFV）技术在动态网络环境下面临的资源调度复杂性与服务质量保障难题，本文构建了一套涵盖常规负载与极端过载全场景的 VNF 迁移优化体系。本文的具体研究内容和各个章节安排如图 1-2 所示。

第一章：绪论。本章首先阐述了 NFV 与 SFC 技术的发展背景，深入剖析了动态网络环境下 VNF 迁移所面临的资源异构性与流量波动性挑战。随后，系统梳理了国内外在 VNF 迁移成本优化、能耗控制及机制设计等方面的研究现状，指出了现有研究在多目标协同与过载价值保障方面的局限性，从而明确了本文的研究意义、研究内容及组织架构。

第二章：相关技术与理论基础。本章对支撑本文研究的核心技术进行了综述，详细介绍了 NFV 架构标准、SFC 转发机制及 VNF 迁移的基本流程。同时，重点阐述了本文模型构建所需的数学理论基础，包括混合整数线性规划（MILP）建模方法、拉格朗日松弛理论以及群智能优化算法原理，为后续章节的算法设计与模型求解奠定理论基石。

第三章：基于优先级感知与多目标优化的 VNF 迁移策略研究。针对常规网络负载下的多维资源冲突问题，本章构建了综合考量迁移成本、路由开销及节点能耗的协同优化模型。提出了一种结合拉格朗日松弛与人工鱼群算法的 LFO-VNM 迁移策略，通过将复杂约束解耦并进行全局寻优，解决了在满足不同业务优先级 SLA 前提下，如何实现网络运营总成本最小化的问题。

第四章：基于拥塞反馈与动态定价的 VNF 迁移准入机制研究。针对突发流量导致的资源受限与过载场景，本章引入微观经济学理论，设计了基于拥塞反馈的动态定价准入机制（CF-DPA）。通过构建“影子价格更新—ROI 价值筛选—物理资源试探”的双层闭环反馈体系，实现了从成本导向向利润导向的范式转变，有效解决了极端工况下的高价值业务保障与系统鲁棒性问题。

第五章：总结与展望。本章对全文的研究工作与核心创新点进行了全面总结，梳理了 LFO-VNM 与 CF-DPA 策略在不同场景下的性能表现。同时，客观分析了现有研究工作的不足之处，并结合算力网络与 6G 技术的发展趋势，对未来的研究方向进行了展望。




图 1-2 论文的组织结构与章节安排

2 相关理论基础

本章首先阐述支撑本文研究的新型网络架构基础,包括软件定义网络(SDN)、网络功能虚拟化(NFV)及服务功能链(SFC)的核心机制;其次,系统介绍本文用于解决多目标资源调度问题的数学优化理论,重点包括拉格朗日松弛与对偶优化理论;随后,详细论述群智能优化算法及其在网络优化中的应用,特别是人工鱼群算法(AFSA)的原理;最后,引入微观经济学中的影子价格理论与网络拥塞控制模型,为第四章构建基于价值博弈的动态准入机制奠定理论基石。

2.1 新型网络架构基础

2.1.1 软件定义网络架构

软件定义网络(Software Defined Networking, SDN)通过将网络设备的控制平面(Control Plane)与数据转发平面(Data Plane)进行解耦,打破了传统网络设备封闭、垂直集成的架构束缚。软件定义网络(SDN)通过控制平面与数据平面的解耦,构建了包含基础设施层、控制层和应用层的三层逻辑架构^[56],彻底改变了传统网络的封闭式管理模式。如图 2-1 所示。




图 2-1 SDN 架构图

数据转发层层由通用转发设备构成，负责基于流表的数据处理；控制层作为逻辑中心，通过南向接口（如 OpenFlow）实现对底层资源的集中管控与全局状态感知；应用层则通过北向接口向上提供可编程的网络能力，承载流量工程^[57-59]、网络虚拟化^[60,61]、安全防护与流量监测^[62-64]等多种网络应用与服务。在本文研究中，SDN 架构提供的全局网络视图解决了 VNF 迁移中网络状态感知滞后的问题，同时其灵活的流表控制机制为迁移后服务功能链的流量重定向与路径无缝切换提供了执行层面的保障，是实现动态资源调度的基础设施基础。

2.1.2 网络功能虚拟化架构

网络功能虚拟化（NFV）利用虚拟化技术实现了网络功能软件与专用硬件的解耦，依据 ETSI 标准架构，其核心由 NFV 基础设施（NFVI）、虚拟网络功能（VNF）及管理编排系统（MANO）三部分构成，如图 2-2 所示。




图 2-2 NFV 架构图

NFVI 将通用服务器、存储和网络资源虚拟化为资源池，VNF 则以软件形式运行于其上，而 MANO 作为系统的大脑，负责对 VNF 进行全生命周期的编排与管理。本文的研究聚焦于 MANO 层面的决策优化，通过与虚拟化基础设施管理

器（VIM）交互，精确控制 VNF 实例在异构物理节点间的动态实例化、迁移与释放，以应对边缘网络环境下的资源波动挑战。

2.1.3 服务功能链架构

服务功能链（SFC）定义了数据流在网络中处理的逻辑拓扑，即业务流量必须严格按照预定义的顺序经过一系列 VNF（如防火墙、深包检测等）以完成特定的服务逻辑，SFC 架构不仅涉及逻辑层面的功能编排，更通过网络转发图（NF-FG）映射到物理层面的流量引导，分类器（Classifier）与服务功能转发器（SFF）协同工作以确保流量路径的正确性。在动态迁移场景下，VNF 物理位置的变更会直接拉伸或压缩 SFC 的物理路径，进而影响端到端时延与带宽消耗。本文在构建模型时，将维护 SFC 的逻辑连通性作为硬性约束，同时将优化物理路径映射开销作为目标函数的重要组成部分，确保在资源调度的同时保障业务的服务质量（QoS）。

2.2 数学优化理论

2.2.1 拉格朗日松弛与对偶优化理论

拉格朗日松弛（Lagrangian Relaxation）^[65]是一种解决复杂约束优化问题的有效数学方法。其核心思想是将造成问题难解的“硬约束”（如物理节点容量限制）通过引入拉格朗日乘子松弛到目标函数中，转化为带有惩罚项的无约束或简单约束问题，从而构建原问题的对偶问题。根据对偶优化理论，通过次梯度法等迭代算法不断更新乘子，可以逼近原问题的最优解下界。在 VNF 迁移的多目标优化中，该理论为将耦合的全局资源约束分解为一系列可独立求解的子问题提供了理论依据，能够显著降低计算复杂度，并为启发式算法提供高质量的引导方向。

2.2.2 群智能优化与人工鱼群算法

群智能优化算法源于对自然界生物群体协作行为的模拟，利用个体间的局部交互涌现出全局智能，特别适用于解决搜索空间巨大且非线性的组合优化问题。人工鱼群算法（Artificial Fish Swarm Algorithm, AFSA）^[66]作为其中的典型代表，通过模拟鱼群的觅食、聚群和追尾等行为来在解空间中进行并行搜索。在 VNF 迁移策略的求解中，AFSA 利用食物浓度映射目标函数值，通过个体的自主游动

和群体的信息共享，能够有效跳出局部最优陷阱，在保证收敛速度的同时，寻找满足多维资源约束的全局最优部署与迁移方案。

2.3 微观经济学与拥塞控制理论

微观经济学中的供需理论与影子价格机制为解决网络资源稀缺性问题提供了全新的视角。在网络拥塞控制理论中，影子价格被用来量化资源的稀缺程度或边际成本：当资源供不应求（拥塞）时价格上涨，反之则下跌。结合这一理论，可以将网络资源调度问题建模为基于效用的市场博弈过程。通过引入投资回报率（ROI）作为决策依据，不同优先级的业务请求被视为理性的经济代理人，根据实时影子价格调整其接入策略。这种机制能够建立物理拥塞状态与业务准入决策之间的动态反馈闭环，通过经济杠杆实现流量的主动整形与高价值业务的优先保障，从而达到系统总效用（利润）的最大化。

2.4 本章小结

本章主要对论文研究涉及的核心技术与理论基础进行了系统阐述。首先，分析了 SDN、NFV 及 SFC 的体系架构，明确了 VNF 动态迁移的运行环境与底层实施载体；其次，介绍了拉格朗日松弛理论与人工鱼群算法，为解决常规负载下的多目标协同优化问题提供了关键的数学建模方法与求解思路；最后，探讨了微观经济学与拥塞控制理论，为构建过载场景下的动态定价准入机制奠定了理论依据。本章内容为后续章节中 LFO-VNM 策略与 CF-DPA 机制的设计与实现提供了坚实的理论支撑。

3 基于优先级感知的多目标 VNF 迁移优化算法

3.1 引言

VNF 迁移虽然是实现资源整合与负载均衡的有效手段，但其本身是一个耗费网络资源的过程，不可避免地会产生迁移带宽消耗、服务中断及额外的路由开销。现有的迁移策略大多聚焦于单一目标的优化（如仅最小化能耗），往往忽略了异构业务对服务质量（QoS）需求的差异性。在多业务并发场景下，缺乏优先级感知的调度机制极易导致高价值、时延敏感型业务（如 URLLC）的服务等级协议（SLA）受损。此外，VNF 迁移本质上是一个受到节点容量、链路带宽及路径连通性等多重约束的 NP-Hard 组合优化问题，如何在有限的时间内求解出平衡迁移成本、能耗与路由开销的最优解，是当前研究面临的主要挑战。针对上述问题，本章提出一种基于优先级感知的多目标 VNF 迁移优化算法（Lagrangian Fish Swarm Optimization for VNF Migration, LFO-VNM）。首先，综合考虑网络运营的资本支出与运营支出，构建了包含迁移成本、节点能耗及路由开销的混合整数线性规划（MILP）模型，并引入优先级加权机制以量化不同业务的重要性。其次，为解决模型中多维资源约束导致的求解困难，利用拉格朗日松弛技术将原问题中的耦合约束解耦，将其转化为一系列易于处理的线性子问题。最后，结合改进的人工鱼群算法的全局寻优能力，在对偶空间迭代搜索最优的拉格朗日乘子与部署方案。本章旨在通过该算法，在常规网络负载下实现系统综合成本的最小化，同时保障关键业务的服务质量。

3.2 问题描述与建模

本节旨在对 VNF 迁移问题进行形式化描述与建模。首先，剖析动态网络环境下的迁移挑战与核心诉求，进而构建系统整体框架。在此基础上，建立包含关键参数、决策变量及多维约束条件的数学模型，为后续 LFO-VNM 算法的设计与求解提供严谨的理论基石。

3.2.1 问题描述

在 NFV 网络架构中，服务功能链（SFC）的动态部署与维持是一个涉及多维资源约束的复杂优化过程。当网络流量呈现潮汐效应或突发性增长时，初始部署方案往往因资源供需失衡而失效，导致局部节点过载、链路拥塞以及端到端时延剧增。此时，VNF 迁移成为恢复网络健康状态的关键手段，但其决策过程面临着多重冲突：一方面，需通过迁移过载节点上的 VNF 实例以均衡负载并降低能耗；另一方面，迁移操作本身会引入不可忽视的数据传输开销与服务中断时间，且重路由可能破坏原有的服务链逻辑连通性。因此，本节旨在将上述工程问题抽象为数学模型，在满足节点容量、链路带宽及业务优先级等多重约束的前提下，寻求迁移成本、网络能耗与路由开销之间的最优平衡解。

3.2.2 问题建模

1、底层物理网络模型

物理网络可建模为一个无向连通图，记 $G=(N,L)$ ，其中 N 表示物理节点的集合， L 表示物理链路集合，每个节点 n_i 的资源被定义为一个三元组 $n_i=\{C_i, M_i, B_i\}$ ，分别表示 CPU 资源、内存资源和带宽资源。 C_i^{total} 示节点 n_i 的总 CPU 资源容量， M_i^{total} 表示节点 n_i 的总内存资源容量，每条链路 $e_{i,j} \in E$ 具有 $B_{i,j}^{total}$ 和 $L_{i,j}$ 属性， $B_{i,j}^{total}$ 表示节点 n_i 与节点 n_j 之间的最大链路带宽容量， $L_{i,j}$ 表示链路 $e_{i,j}$ 的传输延迟。此外，每个节点的 CPU 资源限制了其能够承载共享 VNF（虚拟网络功能）实例的数量。值得注意的是，物理网络节点具备不同的 VNF 支持能力，每个节点 n_i 仅能支持特定的 VNF 集合 $V_i \in V$ ，其中 V 为系统中所有 VNF 的集合。这种限制要求在 VNF 部署和迁移时充分考虑节点的支持能力。本文假设所有待处理的 SFC 请求均已由 NFV 编排器在服务启动前完成初始化处理。该限制要求在部署和迁移 VNF 时充分考虑节点支持能力。本文假设所有待处理的 SFC 请求已在服务到达前由 NFV 编排器完成初始部署，服务链中的每个 VNF 均已分配至对应物理节点并建立端到端连接。后续阶段的负载检测与迁移均基于此部署状态，初始映射过程在此不作详述。后续阶段的过载检测与迁移基于此部署展开，本文不再赘述初始映射过程。

2、服务功能链模型

服务功能链(Service Function Chain,SFC)请求描述为一组按特定顺序执行的虚拟网络功能(VNF)序列，其功能需按照特定顺序逐一执行，用于提供端到端的网络服务。每个 SFC 请求表示为一个六元组： $r_u=\{s(r_u),d(r_u),F_u,\lambda_u,D_{max}^u,\tau_u\}$ ，其中 $s(r_u)$ 和 $d(r_u)$ 分别为 SFC 请求的源节点和目标节点； $F_u=\{f_1^u, f_2^u, \dots, f_{l_u}^u\}$ 为

SFC 请求需要依次执行 VNF 序列, 按序连接完成服务请求的网络功能。SFC 请求的流量需求用 λ_u 表示, 该值决定了数据包通过服务链时所需的网络带宽。 D_{max}^u 表示该 SFC 请求的最大端到端传输延迟限制, 确保了数据在可接受的时间内完成传输。每个 VNF f_k^u 在执行时需要消耗的物理资源主要体现在 CPU 和内存资源消耗上。同时, SFC 请求的流量需求 λ_u 会直接影响其传输带宽需求。 τ_u 表示该请求所处的时间槽。在时间槽 τ_u 内, 需要完成 SFC 请求的所有 VNF 部署及传输路径分配, 以保证服务质量。

3、优先级感知模型

(1) 网络节点的优先级感知。为确保 VNF 迁移过程中目标节点的合理选择, 本文提出了一种基于节点资源利用率、负载平衡性及网络连通性的优先级感知机制。对于任意节点 n_j , 其优先级计算公式如(3-6)所示:

$$R_j = \alpha * \frac{C_j^{remain}}{C_j^{total}} + \beta * \frac{M_j^{remain}}{M_j^{total}} + \gamma * \frac{B_j^{remain}}{B_j^{total}} \quad (3-1)$$

$$\bar{C} = \frac{\sum_{n \in N} \frac{C_n^{used}}{C_n^{total}}}{|N|} \quad (3-2)$$

$$\bar{M} = \frac{\sum_{n \in N} \frac{M_n^{used}}{M_n^{total}}}{|N|} \quad (3-3)$$

$$L_j = 1 - \left| \frac{C_j^{used}}{C_j^{total}} - \bar{C} \right| - \left| \frac{M_j^{used}}{M_j^{total}} - \bar{M} \right| \quad (3-4)$$

$$C_j = \frac{1}{avg_{hop}(n_j)} \quad (3-5)$$

$$P_j = w_1 * R_j + w_2 * L_j + w_3 * C_j \quad (3-6)$$

其中, R_j 表示节点 n_j 的资源可用性, 表示该节点当前资源的可用程度, 值越大表示节点可用资源越充足。 C_j^{remain} 表示节点 n_j 当前可用的 CPU 资源, C_j^{total} 表示节点 n_j 当前可用的 CPU 总资源, M_j^{remain} 表示节点 n_j 当前可用的内存资源, M_j^{total} 表示节点 n_j 当前的内存总资源容量, B_j^{remain} 表示节点 n_j 当前可用的带宽资源, B_j^{total} 表示节点 n_j 当前的带宽总资源容量。 α 、 β 、 γ 用于平衡 CPU、内存和带宽在资源可用性计算中的权重系数。该公式计算节点 n_j 的剩余资源比例, 通过加权的方式衡量 CPU、内存和带宽的剩余资源情况, 反映节点的资源可用性程度。 L_j 表示节点 n_j 的负载平衡性, 表示节点资源使用率接近网络平均负载的程度, 值越大表示负载越均衡。 C_j^{used} 表示节点 n_j 已使用的 CPU 资源, $\bar{C}$ 表示为网络中所有节点的平均 CPU 使用率, M_j^{used} 表示为节点 n_j 已使用的内存资源, $\bar{M}$ 表示为网络中所有节点的平均内存使用率。该公式计算节点 n_j 的负载平衡性, 通过计算该节点 CPU 和内存使用率与全网平均使用率的偏差来衡量。偏差越小, 则 L_j 越接近 1, 表示节点负载更均衡。 C_j 表示节点 n_j 的网络连通性, 通过节点的平均网络

跳数计算。 P_j 表示节点 n_j 的优先级,用于衡量节点在 VNF 迁移中的重要性,值越大表示节点更适合作为 VNF 迁移目标节点。 w_1 、 w_2 、 w_3 分别表示资源可用性、负载平衡性和连通性在优先级计算中的权重系数,在不同的网络环境下,资源可用性、负载平衡性和连通性的重要性可能会有所不同,所以本文使用相等的权重可以提高算法的适应性,使其在不同应用场景下都能保持较优的性能,而不需要针对特定环境进行复杂的参数调优。该公式通过对资源可用性、负载平衡性和连通性进行加权计算,得到每个节点的综合优先级分数。优先级高的节点在 VNF 迁移过程中会被优先考虑,以确保资源充足、负载均衡且连通性良好。该优先级计算方法有助于在 VNF 迁移过程中选择负载较轻且资源充足的目标节点,从而在网络资源约束下实现更优的迁移性能。

(2) 服务功能链的优先级感知。为了在 VNF 迁移与资源分配过程中更加合理地处理 SFC 请求,本文引入了一种服务功能链(SFC)优先级感知机制。该机制综合考虑了 SFC 请求的带宽需求、端到端时延约束以及服务链长度,以计算每个 SFC 请求的优先级,从而确保资源分配的公平性与高效性。对于任意一个 SFC 请求 r_u ,其优先级的计算如式(3-10)所示:

$$P_{total}^u = \omega_1 * P_{bw}^u + \omega_2 * P_{latency}^u + \omega_3 * P_{length}^u \quad (3-7)$$

$$P_{bw}^u = \frac{B_{max} - \lambda_u}{B_{max}} \quad (3-8)$$

$$P_{latency}^u = \frac{D_{max}^u - D_{current}^u}{D_{max}^u} \quad (3-9)$$

$$P_{length}^u = \frac{1}{|F_u|} \quad (3-10)$$

其中, P_{bw}^u 表示 SFC 请求 r_u 的带宽优先级, B_{max} 表示系统中所有待处理 SFC 请求的最大带宽需求, $P_{latency}^u$ 表示 SFC 请求 r_u 的时延优先级, P_{length}^u 表示 SFC 服务链长度优先级, D_{max}^u 表示 SFC 请求的最大端到端时延。 $D_{current}^u$ 表示当前网络路径的端到端时延。 $|F_u|$ 表示 SFC 请求所需的 VNF 数量。 ω_1 , ω_2 , ω_3 分别表示带宽、时延与服务链长度的权重系数,由于无法预先确定某个因素一定比其他因素更关键,因此我们设置相等权重以确保算法适用于更广泛的应用场景,而不会在特定情况下表现失衡。该优先级机制的设计旨在平衡多维度资源需求,确保在 VNF 部署与迁移过程中合理分配网络资源。本文提出的优先级感知机制旨在通过综合资源可用性、负载平衡性和网络连通性,在 VNF 迁移和 SFC 请求处理中实现更优的资源分配与管理。网络节点的优先级感知通过多维度计算目标节点的适合程度,从而在 VNF 迁移中选择更优的目标节点。服务功能链的优先级感知则根据带宽需求、时延限制和服务链长度计算优先级,以优先分配资源给关键性更高的 SFC 请求。这种双重优先级感知机制能够有效地提升网络资源的利用效率,减少网络拥塞,并保障服务质量。通过多目标优化的资源分配框架下综

合考虑多个关键因素，该模型能够为复杂的 NFV 环境提供一种科学合理的 VNF 迁移与 SFC 请求分配方案，从而实现网络性能与资源利用率的最优化。

4、VNF 迁移模型

为了说明部分 VNF 迁移模型，我们首先描述了 SFCs 和 VNFs 之间的利用关系，SFCs 和物理链路之间的关联，以及 VNF 和节点之间的映射关系。本节定义了 VNF 迁移模型中的关键二值变量与连续变量。

$$X_{ukn}(t) = \begin{cases} 1, & \text{VNF } f_k^u \text{ 在时间槽 } t \text{ 被部署在节点 } n \\ 0, & \text{否则} \end{cases} \quad (3-11)$$

$$Y_{uij}(t) = \begin{cases} 1, & \text{SFC 请求 } r_u \text{ 在时间槽 } t \text{ 使用链路 } e_{ij} \\ 0, & \text{否则} \end{cases} \quad (3-12)$$

$$Z_{ukn}(t) = \begin{cases} 1, & \text{时间槽 } t \text{ 迁移 VNF } f_k^u \text{ 到节点 } n \\ 0, & \text{否则} \end{cases} \quad (3-13)$$

这些变量用于刻画迁移过程中节点与链路的使用状态，是后续目标函数与约束条件的数学基础。

5、约束条件

(1) VNF 部署约束，每个节点可以部署多个 VNF，但需要满足该节点的资源限制以及 VNF 兼容性限制。

$$\sum_{u,k} X_{ukn}(t) * R_k \leq R_n^{total} \quad (3-14)$$

(2) VNF 兼容性约束，并非所有的节点都能够部署任意类型的 VNF。只有满足节点能力条件的 VNF 才能部署在相应节点上。

$$X_{ukn}(t) \leq V_n^{f_k^u} \quad (3-15)$$

(3) 迁移目标节点可用性约束，当 VNF f_k^u 迁移到新的节点时，该节点必须有足够的剩余资源并且支持该 VNF 类型。

$$Z_{ukn}(t) \leq V_n^{f_k^u} * \delta_n(t) \quad (3-16)$$

(4) VNF 顺序保持约束，VNF 必须按照 SFC 请求中的顺序依次执行，以确保服务完整性：

$$\sum_{n \in N} X_{u(k+1)n}(t) \leq \sum_{n \in N} X_{ukn}(t) \quad (3-17)$$

该约束确保只有在 f_k^u 执行完成后， f_{k+1}^u 才能被部署在物理节点上。由此通过防止乱序部署来保障服务链完整性。该机制有别于迁移后最短连续运行时长 τ_u ，后者保证每个迁移后的 VNF 在所需时长内保持稳定在线

(5) 路径连续性约束，迁移后的 VNF 之间必须存在物理链路，形成一条完整的传输路径：

$$X_{ukn}(t) + X_{u(k+1)n}(t) \leq \sum_{(i,j) \in E} Y_{uij}(t) \quad (3-18)$$

该约束确保了如果 f_k^u 和 f_{k+1}^u 部署在不同节点上，那么必须存在一条有效的网

络路径。具体而言，当同一服务链中的第 k 个 VNF 与第 $k+1$ 个 VNF 被映射到不同物理节点时，左端之和等于 2，此时右端必须至少有一条活跃链路 $Y_{uij}(t)=1$ 连接这两个节点，以形成完整的传输路径；若两 VNF 被映射到同一节点，则左端之和为 1 或 0，该约束自动成立，无需额外链路。通过该约束，我们确保了迁移后服务功能链各段在物理层面的连通性，防止出现映射到互不相连节点而无法转发的情况，从而维护了 SFC 的整体服务完整性。

(6) 节点资源约束，节点资源不能超出其物理容量，迁移后的 VNF 必须符合资源限制：

$$C_n^{used}(t) = \sum_{u,k} X_{ukn}(t) * C_k^{cpu} \leq C_n^{total} \quad (3-19)$$

$$M_n^{used}(t) = \sum_{u,k} X_{ukn}(t) * M_k^{mem} \leq M_n^{total} \quad (3-20)$$

$$B_n^{used}(t) = \sum_{u,k} X_{ukn}(t) * B_k^{band} \leq B_n^{total} \quad (3-21)$$

此处， C_k^{cpu} 和 M_k^{mem} 分别表示 VNF 实例 v_k 在其宿主节点上的 CPU 和内存资源消耗； B_k^{band} 则表示该实例在节点网络接口上的带宽需求。这些约束确保节点 n 在任意时刻的总资源使用量均不超过其物理可用容量。

(7) 链路容量约束链路传输的数据量不得超过物理链路带宽：

$$B_{i,j}^{used}(t) = \sum_u Y_{uij}(t) * \lambda_u \leq B_{i,j}^{total} \quad (3-22)$$

(8) 时延约束，链路上的端到端延迟必须满足 SFC 的最大时延限制：

$$\sum_{(i,j) \in P_{i,j}} D_{uij}(t) \leq D_{max}^u \quad (3-23)$$

(9) VNF 迁移触发约束，当 VNF 迁移发生时，需在目标节点重新分配资源：

$$Z_{ukn}(t) \geq X_{ukn}(t) - X_{ukn}(t-1) \quad (3-24)$$

(10) 节点资源使用更新约束，当 VNF 迁移完成后，目标节点的资源状态需要进行更新，以反映资源的使用变化。

$$R_n^{used}(t+1) = R_n^{used}(t) + \sum_{u,k} Z_{ukn}(t) * R_k \quad (3-25)$$

此约束确保了迁移后的资源分配能够被正确更新，从而反映新的资源消耗情况。

6、目标函数

VNF 迁移的综合开销由迁移成本、迁移后路由成本和节点能耗成本三个部分组成。迁移成本，迁移成本主要衡量 VNF 迁移过程中引起的额外资源消耗和服务中断风险。在网络环境中，当一个 VNF 从源节点迁移到目标节点时，会消耗传输资源，同时可能引发服务中断。在本文中我们合理地考虑了带宽消耗、迁移数据量以及链路传输距离，是影响迁移成本的主要因素，符合实际网络资源消

耗情况。我们将其描述如式(3-26)所示：

$$C_{mig}(t) = \sum_{u,k,n} Z_{ukn}(t) * (\lambda_u * D_{i,j} + \beta_u * T_{mig} + \gamma) \quad (3-26)$$

迁移后路由成本，路由代价衡量了迁移过程中网络传输的效率及其对链路的压力，尤其适用于动态流量管理。本文充分考虑了链路的拥塞程度与传输距离，是影响网络性能的重要因素，符合实际网络传输中的拥塞控制机制。我们将其描述如式(3-27)所示：

$$C_{route}(t) = \sum_{(i,j) \in E} Y_{i,j} * \left(\omega_1 * \frac{\lambda_u}{B_{i,j}} + \omega_2 * D_{i,j} + \omega_3 * L_{i,j} \right) \quad (3-27)$$

节点能耗成本，能耗代价反映了网络中节点在处理 SFC 请求与迁移时所消耗的能源。能耗代价的高低直接影响网络的可持续性与能效管理。我们有效考虑了节点的基础能耗与负载依赖的能耗变化，符合现代数据中心和分布式网络中的能耗特性。我们将其描述如式(3-29)所示：

$$U_n(t) = \frac{C_n^{used}(t)}{C_n^{total}} + \frac{M_n^{used}(t)}{M_n^{total}} \quad (3-28)$$

$$C_{energy}(t) = \sum_{n \in N} [p_j^{min} + (p_j^{max} - p_j^{min}) * U_n(t)] \quad (3-29)$$

最后，我们使用以下公式(3-30)来表示我们的总目标。

$$C_{total}(t) = C_{mig}(t) + C_{route}(t) + C_{energy}(t) \quad (3-30)$$

该目标函数的核心目标是最小化三个部分的总和，以满足网络服务的资源约束和服务质量（QoS）需求。同时考虑了迁移成本、路由成本和节点能耗成本，能够全面刻画 VNF 迁移对网络性能的影响。覆盖了带宽、传输距离、链路拥塞、能耗等多维度的影响因素。支持多时间槽的动态迁移建模，适用于复杂的动态 NFV 环境。在 NFV 环境下，该目标函数能够有效指导 VNF 迁移方案的选择，减少迁移引起的服务中断风险和网络拥塞。有助于提高网络资源利用效率，降低能源消耗，从而提升网络整体性能和可持续性。本节涉及的主要参数及意义如表 3-1 所示。

表 3-1 主要参数及含义

符号	描述
$G=(N,L)$	物理网络图，N 表示节点集合，L 表示物理链路集合
$C_i^{total}, M_i^{total}, B_{i,j}^{total}$	节点 n_i 的总 CPU、内存和带宽资源容量
$e_{i,j}$	物理链路，连接节点 n_i 和 n_j
$B_{i,j}^{total}$	链路 $e_{i,j}$ 的最大链路带宽容量
$D_{i,j}$	链路 $e_{i,j}$ 的传输距离
V_i	节点 n_i 可支持的 VNF 集合
V	系统中所有 VNF 的集合

表 3-1 主要参数及含义（续）

符号	描述
r_u	第 u 条 SFC 请求
λ_u	SFC 请求 r_u 的流量需求
D_{max}^u	SFC 请求 r_u 的最大端到端延迟限制
R_k	部署 VNF f_k^u 所需的资源
R_n^{total}	节点 n 可用的资源上限
τ_u	SFC 请求 r_u 的处理时间槽
T_{mig}	迁移 VNF f_k^u 所需的时间
γ	迁移 VNF f_k^u 所需的固定迁移开销
$L_{(i,j)}$	链路 $e_{i,j}$ 的传输时延
ω_1 、 ω_2 、 ω_3	带宽利用率、传输距离和链路时延的权重系数
p_j^{min}	节点 n_j 的基本能耗
p_j^{max}	节点 n_j 的满功率能耗。
$U_n(t)$	节点 n 在时间槽 t 的资源利用率
β_u	VNF 迁移时间因子，用于衡量迁移时间对总成本的影响
$\delta_n(t)$	二值变量，时间槽 t 时节点 n 是否有足够的剩余资源
$V_n^{f_k^u}$	二值变量，节点 n 是否支持 VNF f_k^u
$X_{ukn}(t)$	二值变量，时间槽 t 时 VNF f_k^u 是否部署在节点 n
$Y_{uij}(t)$	二值变量，时间槽 t 时 SFC r_u 是否使用链路 $e_{i,j}$
$Z_{ukn}(t)$	二值变量，时间槽 t 时 VNF f_k^u 是否迁移到节点 n

3.3 问题求解

3.3.1 算法设计

本文提出的虚拟网络功能（VNF）迁移算法旨在通过多阶段优化策略，在动态网络环境中有效管理计算与传输资源，同时最小化迁移成本。为系统描述迁移过程，可将 VNF 迁移划分为连续阶段，以确保服务质量（QoS）与资源利用效率之间的全面平衡。图 3-1 展示了在 Cernet 实施的完整系统运行流程，核心涉及 LFO-VNM 算法的运作机制。系统首先实时监测每个物理节点的 CPU 与内存利用率，结合服务优先级评分（SFC），识别因承载高优先级服务而出现资源瓶颈的过载节点。随后，针对每个待迁移的 VNF，系统根据其 CPU 和内存需求，以及关联 SFC 剩余的端到端时延预算，从全网所有非过载节点中筛选出可映射节点集。针对候选节点，系统基于可用计算资源、存储容量及网络连接性计算综合优先级评分，选取评分最高节点生成初始迁移映射，完成超载节点上 VNF 的优

优先级部署（算法 3）。随后，算法将初始映射作为鱼群种群的起始点，结合当前全局部署状态与网络资源信息，应用算法 2 进行全局搜索，通过在觅食、跟随、聚合和分散行为间动态切换，平衡局部精细搜索与全局多峰探索，同时持续评估资源与 QoS 约束。同时采用拉格朗日松弛技术，将 CPU、内存、延迟等耦合约束松弛至目标函数中。每次迭代后，根据违约程度更新对应乘数，并将约束惩罚反馈至适应度评估，引导后续群解远离劣解区域。该过程持续迭代直至群集收敛或无节点过载，最终输出最优 VNF 迁移方案。通过上述步骤，LFO-VNM 实现了从优先级驱动的局部初始映射到多行为模式全局优化，再到动态约束调整的闭环控制流程，展现出良好的可重复性和可扩展性。




图 3-1 系统运行图 (Cernet)

阶段 1：过载检测与迁移触发

VNF 迁移的初始阶段为网络资源状态的监测与过载节点的识别。当网络节点资源消耗超过预设阈值时，可能导致服务中断或性能下降，从而需要触发 VNF 迁移。具体而言，当节点 n 的资源利用率超出其阈值 θ 时，判定其为过载节点，公式如下所示：

$$U_{cpu}(n) = \frac{R_{cpu_used}(n)}{R_{cpu_total}(n)} > \theta_{cpu} \quad (3-31)$$

$$U_{mem}(n) = \frac{R_{mem_used}(n)}{R_{mem_total}(n)} > \theta_{mem} \quad (3-32)$$

当节点超载时，迁移触发机制被激活，系统进一步分析节点内部各 VNF 的资源消耗情况，以筛选出需要迁移的 VNF 实例。此阶段的目标是防止资源过载引发的网络拥塞与服务质量下降。

阶段 2：候选目标节点筛选

在确定需要迁移的 VNF 实例后，需要选择合适的目标节点以完成迁移。候选节点集合的构建基于以下两个约束条件：

1.资源约束：目标节点必须具备足够的资源以容纳待迁移的 VNF。

2.VNF 支持约束：目标节点必须能够支持特定的 VNF 类型。候选目标节点集合可表示为：

$$N_{v_i}^{can} = \{n_j | R_{cpu}(n_j) \geq V_{cpu}(v_i) \cap R_{mem}(n_j) \geq V_{mem}(v_i)\} \quad (3-33)$$

$V_{cpu}(v_i)$ 和 $V_{mem}(v_i)$ 分别表示 VNF v_i 所需的 CPU 和内存资源。 $N_{v_i}^{can}$ 表示满足资源约束条件的候选目标节点集合。该阶段确保了迁移的可行性，避免因目标节点资源不足导致的迁移失败。

阶段 3：适应度函数设计

在本文提出的 VNF 迁移优化模型中，适应度函数的核心目标是对迁移成本、路由成本和能耗成本三个关键性能指标进行相加，如式(3-34)所示，以便综合衡量候选解的整体性能表现。该函数不仅关注网络资源的利用效率，还在迁移过程中考虑了服务质量与资源约束的满足程度。

$$F(X) = C_{total}(X) + P(X, \lambda, \mu) \quad (3-34)$$

用于抑制违反资源约束的解资源约束的违反程度由 $P(X, \lambda, \mu)$ 表示，该项旨在防止候选解违反节点资源约束。当某一节点的 CPU 或内存资源超载时，该项会被激活，从而增加适应度值，迫使算法远离不可行解。这种设计方法直接对三类成本进行累加，适用于需要兼顾多种性能因素且无法明确区分优先级的多目标优化场景。其优势在于便于解释和实现，同时能够通过惩罚因子 λ 有效约束不可行解的产生。如果节点资源使用量超过总容量，则 $\max$ 函数激活罚分，从而增加适应度值。

阶段 4：多目标优化求解

为进一步提升迁移决策的全局最优性，本文采用了基于拉格朗日松弛与人工鱼群算法的混合求解方法：

拉格朗日松弛原理：拉格朗日松弛通过引入乘子，将约束条件转换为惩罚项加入目标函数，以便于求解。在 VNF 迁移中，目标是最小化迁移成本、能耗与路由成本，同时满足节点资源约束：

$$R_{cpu_{used}}(n) \leq R_{cpu_{total}}(n) \quad (3-35)$$

$$R_{mem_{used}}(n) \leq R_{mem_{total}}(n) \quad (3-36)$$

引入拉格朗日乘子 λ_n 和 μ_n 对于资源约束进行惩罚：

$$P(X, \lambda, \mu) = F(X) + \sum_{n \in N} \lambda_n * \max(0, R_{cpu_{used}}(n) - R_{cpu_{total}}(n)) + \sum_{n \in N} \mu_n * \max(0, R_{mem_{used}}(n) - R_{mem_{total}}(n)) \quad (3-37)$$

在优化过程中，为了逐步增强对资源约束的惩罚力度，引入惩罚因子 $penalty_factor$ 动态调整拉格朗日乘子的更新幅度。其定义如式(3-38)所示：

$$penalty_factor = P_{base} * (1 + r * t) \quad (3-38)$$

其中 P_{base} 为基础惩罚因子，控制初始惩罚力度。 r 为惩罚增长率，控制每次迭代后惩罚因子的增长速度。 t 为当前迭代次数。

拉格朗日乘子的更新，每次迭代后，更新乘子的方式为：

$$\lambda_n^{t+1} = \max\left(0, \lambda_n^t + \alpha * \text{penalty_factor} * (R_{cpu_used}(n) - R_{cpu_total}(n))\right) \quad (3-39)$$

$$\mu_n^{t+1} = \max\left(0, \mu_n^t + \alpha * \text{penalty_factor} * (R_{mem_used}(n) - R_{mem_total}(n))\right) \quad (3-40)$$

其中 α 是学习率，用于控制乘子的更新速度。

算法 2 中的鱼群行为主要由四种行为组成：觅食、聚集、追随和随机游动。以下对各行为的数学描述进行详细说明。

觅食行为鱼群根据目标区域的适应度函数来判断前往更优位置。如果新位置的适应度更优，则前往新位置。

$$X_i(t+1) = X_i(t) + \text{step} * \frac{X_j(t) - X_i(t)}{\|X_j(t) - X_i(t)\|} * \text{rand}() \quad (3-41)$$

$X_j(t)$ 是鱼可视范围内的随机新位置。如果 $f(X_j) > f(X_i)$ ，则鱼前往新位置，否则进行随机移动。 $f(X_i)$ 表示位置 X_i 处的适应度。 $\text{rand}()$ 为[0,1]范围内的随机数。

聚集行为：鱼群有聚集的特性，会朝向周围鱼的中心位置移动，以提高食物浓度，同时避免过度聚集。计算可视范围内的鱼的中心位置 X_c ：

$$X_c = \frac{\sum_{j=1}^{n_f} X_j}{n_f} \quad (3-42)$$

移动公式为：

$$X_i(t+1) = X_i(t) + \text{step} * \frac{X_c - X_i(t)}{\|X_c - X_i(t)\|} * \text{rand}() \quad (3-43)$$

如果 $f(X_c) > f(X_i)$ 且 $\frac{n_f}{N} < \delta$ ，则鱼群向中心靠拢。 n_f 表示可视范围内的鱼的数量。 δ 表示拥挤度阈值。

追随行为：鱼会跟随感知范围内最优的个体进行移动。找到感知范围内最优鱼的位置 X_b ：

$$X_i(t+1) = X_i(t) + \text{step} * \frac{X_b - X_i(t)}{\|X_b - X_i(t)\|} * \text{rand}() \quad (3-44)$$

其中 X_b 是当前可视范围内适应度最高的鱼的位置。

随机游动：若觅食、聚集和追随行为均无法找到更优解，鱼将进行随机游动：

$$X_i(t+1) = X_i(t) + \text{Visual} * \text{rand}() \quad (3-45)$$

自适应步长与视觉：自适应步长 step 和感知范围 Visual 会随迭代次数逐渐减小，以提高收敛精度：

$$\text{Visual}(t) = \text{Visual}_{\min} + (\text{Visual}_{\max} - \text{Visual}_{\min}) * \left(1 - \frac{t}{T_{\max}}\right) \quad (3-46)$$

$$\text{step}(t) = \text{step}_{\min} + (\text{step}_{\max} - \text{step}_{\min}) * \left(1 - \frac{t}{T_{\max}}\right) \quad (3-47)$$

$T_{\max}$ 表示为最大迭代次数。 $\text{Visual}_{\min}$ 和 $\text{step}_{\min}$ 分别为最小感知范围与最小步长。

如 3.3.1 章节算法 1 所示，第 1 至 16 行对应算法的实现过程。在 LFO-VNM

算法的主工作流程中，首先根据公式计算服务功能链（SFC）的优先级（第 1 行），以确定应优先处理哪些 SFC。随后处理 SFC 请求，构建待迁移的虚拟网络功能（VNF）列表（第 2 行）。接着为每个网络节点初始化拉格朗日乘子（第 3 行），以动态调整并约束资源分配。随后调用算法 2 进行全局搜索与优化，同时利用计算出的惩罚因子修正资源违规行为，逐步收敛至最优 VNF 迁移方案（第 4-14 行）。

算法 1 基于拉格朗日鱼群优化的 VNF 迁移算法(LFO-VNM)

输入：物理网络拓扑图、服务功能链请求集合、节点资源状态

输出：VNF 迁移方案

1. 根据公式(3-7)计算 SFC 请求的优先级；
 2. 获取待迁移的 VNF 列表；
 3. 为每个节点初始化拉格朗日乘子 $\lambda[\text{node}]$ ；//初始设置为 1，后续根据资源动态进行更新用于纠正非法解
 4. 对于迭代次数=1 到最大迭代次数执行：
 5. (population, best_solution) = 调用算法 2；//调用算法 2 进行全局优化
 6. 根据公式 (3-38) 计算 惩罚因子 (penalty_factor)；
 7. 对于网络中的每个节点 n 执行：
 8. 计算 CPU 违约量(cpu_violation)；
 9. 计算内存违约量(memory_violation)；
 10. 调整值 = 惩罚因子 * (CPU 违约量 + 内存 违约量)；
 11. 根据公式 (3-39)(3-40) 更新拉格朗日乘子 $\lambda[\text{node}]$ ；
 12. 结束循环
 13. 结束循环
 14. return 最优迁移方案 Mig_s；
-

如 3.3.1 章节算法 2 所示，首先调用算法 3 生成初始种群，其中每个个体代表一个 VNF 迁移方案，并创建帕累托前沿集以存储非支配解（第 1-3 行）。接着设定搜索参数，包括步长和视觉范围（第 4-5 行）。随后遍历种群中每个个体，执行随机游走以生成新解。检查每个解的约束条件，若满足约束则计算其适应度。将适应度与当前最优解比较，必要时更新最优解及帕累托前沿集，确保全局搜索与局部优化相结合（第 6-14 行）。

算法 2 约束条件下的 VNF 迁移人工鱼群搜索算法

输入：初始种群，适应度函数，约束条件集合

输出：更新后的种群，当前最优解

// 初始化阶段

1. 调用算法 3 生成初始种群 (基于节点优先级的贪心部署);
2. 初始化 Pareto 前沿集合为空;
3. 初始化全局最优解 $Best_Solution =$ 种群中的第一个个体;
4. 根据公式(3-46)计算当前步长(Step);
5. 根据公式(3-47)计算当前视野范围(Visual);
6. 对于种群中的每一条人工鱼(Individual)执行:
 - // 执行鱼群行为: 觅食、聚群、追尾、随机移动
7. 新解 (NewSolution) = 执行鱼群行为();
 - // 约束检查与适应度更新
8. 如果 New_Solution 满足所有物理约束 (公式 3-14 至 3-24) 则:
9. 计算 New_Solution 的适应度值 (New_Fitness);
10. 如果 New_Fitness < Best_Fitness 则:
11. $Best_Fitness = New_Fitness$;
12. 结束判断
13. 结束判断
 - //更新 Pareto 前沿 (用于多目标优化)
14. 对于种群中的每一个体执行:
15. 如果该个体未被种群中其他个体支配则:
16. 将该个体加入 Pareto 前沿集合;
17. 结束判断
18. 结束循环
19. 结束循环
20. return Population, Best_Solution;

如 3.3.1 章节算法 3 所示, 从空置放映映射开始, 基于剩余 CPU/内存、连接性及负载均衡因素计算每个节点的静态优先级评分 (第 1-2 行)。构建满足 CPU/内存容量、VNF 类型匹配及对应节点剩余端到端延迟预算的候选节点集 (第 3 行), 通过强制执行 CPU、内存及端到端延迟预算约束 (第 4 行) 构建其候选节点集。选择节点优先级评分最高的候选节点 (第 5 行), 为其分配节点 (第 6 行)。SFC (第 3 行) 通过强制执行 CPU、内存和端到端延迟预算约束 (第 4 行) 来缩小候选节点集。选择具有最高节点优先级评分的候选节点 (第 5 行), 将 VNF 分配至该节点 (第 6 行), 随后扣除其资源需求并重新计算该节点评分 (第 7 行)。当所有 VNF 完成部署后, 将此初始约束感知映射输出至算法 2 进行进一步优化 (第 10-12 行)。

算法 3 基于节点优先级的 VNF 部署算法

输入： SFC 请求集合，节点资源状态

输出： 网络中 VNF 的部署方案

1. 初始化部署方案为空；
2. 计算所有节点的优先级得分(公式 3-6)；
3. 对于每个 SFC 请求执行：
4. 对于 SFC 中的每个 VNF 执行：
5. 获取 候选节点集合；// 筛选满足资源和约束的候选节点
6. 目标节点= 选择优先级最高的候选节点；
7. 记录部署： $\text{placement}[\text{VNF}] = \text{target_node}$ ；
8. 更新目标节点的资源状态；
9. 重新计算节点优先级；
10. 结束循环
11. 结束循环
12. return 部署方案 (placement)；

3.3.2 算法复杂性分析

在计算复杂度方面，LFO-VNM 算法的核心由两个模块构成，即人工鱼群与拉格朗日松弛算法，它们在迭代过程中交替运行。每次迭代中，对于规模为 M 的群体，每个个体需经历服务链构建、功能图嵌入及链上调度迁移三项评估，单次评估复杂度为 $O(|V| + |E| + \sum_{u \in U} |\text{SFC}_u|)$ ，其中 $|V|$ 和 $|E|$ 分别表示网络节点数与链路数， $\sum |\text{SFC}|$ 为当前时隙待处理服务链总长度。若总迭代次数为 T ，整体时间复杂度为 $O(T \cdot M \cdot (|V| + |E| + \sum |\text{SFC}|))$ 。尽管该多项式复杂度会随网络规模和请求量 R 显著增长，但在实际部署中，通过合理选择迭代次数和群集规模，并优化各评估阶段的实现效率，LFO-VNM 可在典型运营级网络中数分钟内完成完整的动态调度与迁移决策，从而满足在线部署的实时要求。

3.4 仿真设计与性能分析

在这一节中，我们将本文提出的算法的性能与已有其他方案进行了详细的分析和比较。为了验证我们的算法在真实应用场景中的有效性，我们在真实的网络拓扑结构上评估我们提出的算法，并根据采用类似的网络，VNF 和 SFC 配置，这确保了数据的通用性。

3.4.1 实验环境和参数设置

网络拓扑：本文采用了网络拓扑 Zoo^[67]中的两种真实网络拓扑结构，分别为 Cernet（包含 41 个节点和 59 条链路）以及 Cogentco（包含 197 个节点和 245 条链路）。网络中的节点被配置了[500,1000]单位范围内的 CPU 资源和内存资源，所有物理链路的带宽容量设置为[1000,1500]Mbps，传播时延为[1,10]ms。

SFC 与 VNF：本文设定了十种 VNF 类型，每个 SFC 由[2,8]个 VNF 组成，业务速率范围为[1,10]Gbps。业务的最大容忍延迟分为两类：[80,201]ms 和 [300,501]ms，以代表不同服务质量要求的请求。源节点和目的节点均随机选自网络拓扑中的节点。此外，VNF 的 CPU 和内存资源需求按照业务速率进行配置，具体为每 10Mbps 需消耗[1,5]个单位的资源。

算法参数：在本实验场景中，为保证不同资源维度对优化目标贡献的公平性，避免权重设置对实验结果产生额外偏置，本文将 CPU、内存和带宽资源赋予相同重要程度，因此我们将 ω_1 ， ω_2 ， ω_3 设置为 1/3，以客观分析算法在综合资源约束下的优化性能。此外在迁移机制中，我们将节点过载阈值设置为 0.4，能够更有效得到更多节点 VNF 迁移数量，如图 3-2 所示。




图 3-2 VNF 迁移数量图

3.4.2 对比算法介绍

在这个模拟中，我们的主要目标是评估 VNF 迁移带来的开销，介绍了两种 VNF 迁移算法，这些算法的细节如下：

LFO-VNM_Ran 是我们提出的 LFO-VNM 算法的受控变体,其中节点优先级部署步骤(算法 3)被随机放置所取代。这将我们基于优先级的部署策略在运行时和迁移开销方面的优势进行了孤立验证。

基于最优顺序的多阶段启发式算法(MSH-OR)^[27]是一种多阶段的启发式方法,该方法通过从过载节点中优先选择具有最高业务速率的虚拟网络功能(VNF),并将这些 VNF 迁移到其他负载较低的目的节点,从而实现服务功能链(SFC)延迟的最小化和网络负载的均衡。

动态延迟感知 VNF 迁移(DLAPM)^[34]算法是一种基于遗传算法(GA)的动态延迟感知部分虚拟网络功能迁移方法。该算法旨在解决节点过载问题,并优化服务功能链的延迟性能。DLAPM 通过对 VNF 进行部分迁移,致力于在减少迁移成本的同时,最小化服务功能链的总延迟,以实现更高效的网络资源利用率和服务质量保障。

我们选择 MSH-OR 和 DLAPM 作为基线方案,因为它们分别代表两种主流的 VNF 迁移范式启发式与进化式且均明确针对节点负载均衡。尽管它们最初旨在优化“迁移成本+延迟”指标,但可直接应用于我们扩展的“迁移成本+路由成本+能耗成本”目标空间进行评估。在相同拓扑结构和工作负载下,这种对齐确保观测到的性能差异反映了各算法的固有优势,而非评估标准不匹配所致。通过对 LFO-VNM_Rand、MSH-OR 和 DLAPM 的基准测试,我们证明结合节点优先级部署与全局多目标优化的框架实现了更低的整体迁移开销和更快的运行时性能。

3.4.3 评价指标

迁移成本: 量化 VNF 状态转移过程中因数据传输产生的额外带宽消耗及潜在的服务中断风险,具体定义如式(3-26)所示。

路由成本: 评估 VNF 迁移后 SFC 数据流在物理链路上传输效率与带宽占用情况,反映了网络链路的负载压力,由式(3-27)计算所得。

节点能耗成本: 表征物理节点在处理 SFC 业务请求及执行迁移操作时的资源消耗,旨在衡量绿色通信能力,计算方式见式(3-29)。

综合开销成本: 通过加权聚合的方式统筹迁移开销、路由效率与节点能耗,全面刻画 VNF 迁移策略对网络运营总成本的影响,由式(3-30)定义。

算法时间成本: 记录算法从输入网络状态到输出决策方案的耗时,用于评估模型求解的时间复杂度与在线动态响应能力。

3.4.4 实验结果与分析

综合开销成本：图 3-3 展示了这些算法在最优总成本方面的最小化结果。较低的总成本表明更优的优化性能。LFO-VNM 方法在两种网络拓扑结构下均展现出显著的适应度优化能力，有效降低了总成本。尤其在大型 SFC 场景中，其分别比 MSH-OR 和 DLAPM 方法优越 13.6%和 13.8%，优势明显。与 LFO-VNM_Ran 方法相比，LFO-VNM 展现出更优的适应度，且在 Cogentco 网络拓扑下，该优势随 SFC 数量增加而逐步扩大。其适应度比 LFO-VNM_Ran 低 3.4%至 4.7%。




图 3-3 最优综合开销成本

最优迁移成本：图 3-4 显示了这些算法在最优迁移成本方面的最小化结果。在 Cernet 网络拓扑上，与 MSH-OR 方法相比，虽然 LFO-VNM 的迁移成本增加了 4.6%，但是从最终的优化目标结果来看，LFO-VNM 在不同业务规模下均表现出更优的整体多目标优化能力，说明所提方法能够实现全局资源协同优化。与 LFO-VNM_Ran 方法相比，LFO-VNM 的迁移成本增加了 2.1%，但是适应度和全局优化能力的提升表明，这一代价是值得的。与 DLAPM 方法相比，LFO-VNM 的迁移成本增加了 7.1%，但 DLAPM 在迁移成本优化上并无显著优势。在 Cogentco 网络拓扑上 LFO-VNM 的迁移成本比 MSH-OR 高 12.3%，但相较于 LFO-VNM_Ran 方法，迁移成本减少了 5.2%，展现了在迁移优化方面的优势。与 DLAPM 相比，迁移成本增加 13.8%，但 LFO-VNM 提供了更为综合的优化能力，弥补了迁移成本的上升。尽管 LFO-VNM 在迁移成本上略有增加，但其在适应度和其他关键指标上的显著优势，使得这一代价是可以接受的。尤其在与 LFO-VNM_Ran 方法相比时，LFO-VNM 展现了更好的迁移效率。




图 3-4 最优迁移成本

路由成本：图 3-5 显示了这些算法在最优路由成本方面的最小化结果。在 Cernet 网络拓扑上，虽然 LFO-VNM 的路由成本比 MSH-OR 增加了 13.2%，但从综合成本结果来看，LFO-VNM 在不同业务规模下均表现出更优的整体优化能力，说明所提方法能够实现全局资源协同优化。与 LFO-VNM_Ran 方法相比，路由成本增加了 4.8%，这一增加仍在可以接受的范围内，且全局优化效果更加全面。与 DLAPM 方法相比，路由成本增加 17.6%，但 LFO-VNM 在综合优化方面展现了更强的能力。在 Cogentco 网络拓扑 LFO-VNM 的路由成本相比 MSH-OR 增加了 9.6%，与 LFO-VNM_Ran 增加了 5.2%，但相较于 DLAPM，路由成本增加的幅度较小，且 LFO-VNM 仍能够实现良好的平衡，优化效果较为全面。LFO-VNM 方法在两个网络拓扑下的路由成本略有上升，但这种增加是优化其他指标的代价，并且其综合优化效果仍然优于传统方法。




图 3-5 最优路由成本

节点能耗成本：图 3-6 显示了这些算法在最优能耗成本方面的最小化结果。该指标衡量的是网络中所有运行中的 VNF 实例在迁移调整完成后后续调度周期

内产生的节点累计能耗。在 Cernet 网络拓扑上, LFO-VNM 显示出极强的节能能力, 较 MSH-OR 降低了 56.2%, 相较于 DLAPM 和 LFO-VNM_Ran, 也分别降低了 56.2%和 2.9%。在 Cogentco 网络拓扑上, LFO-VNM 在 Cogentco 网络中的能效表现同样突出, 较 MSH_OR 降低了 52.1%, 与 DLAPM 方法的能耗相同, 且与 LFO-VNM_Ran 的能耗变化极小, 显示出其在综合优化中的能效优势。在两个网络拓扑中, LFO-VNM 方法在节能方面具有显著优势。




图 3-6 最优节点能耗成本

算法时间成本: 图 3-7 显示了这些算法在运行时间方面的最小化结果。在 Cernet 网络拓扑上, LFO-VNM 显著降低了计算时间, 比 MSH-OR 少了 26.0%, 而与 LFO-VNM_Ran 和 DLAPM 相比, 时间开销分别减少了 31.1%和 30.6%, 显示出 LFO-VNM 在计算效率方面的明显提升。在 Cogentco 网络拓扑上, 同样, LFO-VNM 在 Cogentco 网络中也表现出了显著的计算时间优势, 时间成本比 MSH-OR 减少 31.4%, 相比 LFO-VNM_Ran 减少了 30.2%。LFO-VNM 显著降低了时间开销, 在处理大规模 SFC 时, 表现出明显的计算效率优势。相比其他方法, LFO-VNM 能在更短时间内提供优化结果。




图 3-3 最优算法时间成本

3.4.5 本章小结

本章针对动态网络环境下的资源高效调度与服务质量保障问题,提出了一种基于优先级感知的多目标虚拟网络功能迁移优化算法(LFO-VNM)。首先,通过分析 VNF 迁移对网络性能的多重影响,构建了以最小化迁移成本、节点能耗及路由开销为目标的混合整数线性规划模型,并引入优先级感知机制以满足异构业务的差异化需求。其次,针对该模型在大规模网络场景下的求解瓶颈,利用拉格朗日松弛理论将复杂的多维资源耦合约束进行解耦,成功将其转化为一系列可并行求解的子问题。随后,结合改进的人工鱼群算法,通过动态调整搜索策略,在对偶空间内高效地寻找全局最优的迁移方案。仿真实验结果表明,与现有的 MSH-OR 及 DLAPM 算法相比, LFO-VNM 算法在显著降低系统运营成本的同时,能够更有效地平衡资源利用率与业务响应时延。

4 基于拥塞反馈与收益最大化的 VNF 迁移机制

4.1 引言

在第三章中本文针对资源供给相对充裕、负载处于平稳波动的常态化网络环境，通过多目标优化算法有效降低了系统的运维成本，并在满足业务优先级约束的前提下实现了资源的精细化调度。然而，随着 5G/6G 垂直行业应用的爆发式增长，边缘网络常面临突发性大流量冲击，导致系统进入极端过载工况。在此类场景下，由于物理资源的高度稀缺，仅依赖第三章所述的成本最小化策略已难以维系全量业务的服务质量（QoS），甚至可能引发网络拥塞的连锁反应，导致关键业务的 SLA 严重受损。此外，现有的 VNF 迁移研究多侧重于技术层面的路径优化与负载平衡，缺乏从经济学维度对业务价值进行量化评估，难以在资源受限时做出具有全局收益最优性的准入决策。

针对上述挑战，本章将研究视角从运维侧成本优化转向经营侧收益最大化，提出了一种基于拥塞反馈与动态定价的 VNF 迁移准入机制（Congestion-Feedback Dynamic Pricing Admission, CF-DPA）。首先，引入微观经济学中的影子价格理论，建立物理资源稀缺程度与业务准入成本之间的动态映射模型。其次，设计了一种基于拥塞反馈的闭环控制框架：通过感知节点与链路的实时负载压力生成价格反馈信号，并将其映射为资源稀缺程度下的经济代价。算法在外层以收益为导向对候选请求进行排序，优先尝试接纳具有更高潜在利润和更优 ROI 表现的业务，同时通过资源可行性与拥塞约束抑制低价值业务对关键资源的挤占，从而提升过载场景下的系统鲁棒性与整体收益。通过 CF-DPA 机制，网络能够在极端负载下依然保持高度的鲁棒性，在有效规避拥塞风险的同时，最大化运营商的服务利润与资源配置效率。

4.2 问题描述与建模

4.2.1 问题描述

在边缘网络面临突发性大规模流量并发的过载场景下，物理资源（计算、带宽）呈现高度稀缺性，仅依赖第三章所述的成本最小化策略虽然能优化单个请求

的资源消耗，但缺乏对全局资源竞争的协调机制，极易引发关键节点拥塞与低价值流量对核心资源的抢占。针对这一问题，本章在上一章工作的基础上，进一步聚焦于资源受限环境下的全局准入博弈与价值最大化问题。通过引入微观经济学中的影子价格理论，将物理层的拥塞状态映射为动态变化的准入成本，在多请求并发竞争中建立基于投资回报率（ROI）的筛选机制，旨在解决如何在保障系统鲁棒性的同时，实现网络运营收益与资源配置效率的全局最优平衡。

4.2.2 问题建模

1、底层物理网络模型

物理网络可建模为一个无向连通图，记 $G=(N,L)$ ，其中 N 表示物理节点的集合， L 表示物理链路集合，每个节点 n_i 的资源被定义为一个三元组 $n_i=\{C_i, M_i, B_i\}$ ，分别表示 CPU 资源、内存资源和带宽资源 C_i^{total} 示节点 n_i 的总 CPU 资源容量， M_i^{total} 表示节点 n_i 的总内存资源容量，每条链路 $e_{i,j} \in E$ 具有 $B_{i,j}^{total}$ 和 $L_{i,j}$ 属性， $B_{i,j}^{total}$ 表示节点 n_i 与节点 n_j 之间的最大链路带宽容量， $L_{i,j}$ 表示链路 $e_{i,j}$ 的传输延迟。此外，每个节点的 CPU 资源限制了其能够承载共享 VNF（虚拟网络功能）实例的数量。值得注意的是，物理网络节点具备不同的 VNF 支持能力，每个节点 n_i 仅能支持特定的 VNF 集合 $V_i \in V$ ，其中 V 为系统中所有 VNF 的集合。这种限制要求在 VNF 部署和迁移时充分考虑节点的支持能力。本文假设所有待处理的 SFC 请求均已由 NFV 编排器在服务启动前完成初始化处理。该限制要求在部署和迁移 VNF 时充分考虑节点支持能力。 $\pi_n(t)$ 表示在时间槽 t ，节点 n 单位计算资源的边际拥塞成本。该值随节点负载率动态更新，负载越高，价格越高。 $\pi_{i,l}(t)$ 表示在时间槽 t ，链路 $L_{i,j}$ 单位带宽资源的边际拥塞成本，反映了传输资源的稀缺性。

2、服务功能链模型

服务功能链(Service Function Chain,SFC)请求描述为一组按特定顺序执行的虚拟网络功能(VNF)序列，其功能需按照特定顺序逐一执行，用于提供端到端的网络服务。每个 SFC 请求表示为一个六元组： $r_u=\{s(r_u), d(r_u), F_u, \lambda_u, D_{max}^u, P_{tech}^u, \tau_u\}$ ，其中 $s(r_u)$ 和 $d(r_u)$ 分别为 SFC 请求的源节点和目标节点； $F_u=\{f_1^u, f_2^u, \dots, f_{l_u}^u\}$ 为 SFC 请求需要依次执行 VNF 序列，按序连接完成服务请求的网络功能。SFC 请求的流量需求用 λ_u 表示，该值决定了数据包通过服务链时所需的网络带宽。 D_{max}^u 表示该 SFC 请求的最大端到端传输延迟限制，确保了数据在可接受的时间内完成传输。每个 VNF f_k^u 在执行时需要消耗的物理资源主要体现在 CPU 和内存资源消耗上。同时，SFC 请求的流量需求 λ_u 会直接影响其传输带宽需求。 P_{tech}^u 量化了业务的重要性，直接影响业务的收益定价。 τ_u 表示该请求所处的时间槽。在时间

槽 τ_u 内,需要完成 SFC 请求的所有 VNF 部署及传输路径分配,以保证服务质量。

3、VNF 迁移模型

为了说明部分 VNF 迁移模型,我们首先描述了 SFCs 和 VNFs 之间的利用关系, SFCs 和物理链路之间的关联,以及 VNF 和节点之间的映射关系。本节定义了 VNF 迁移模型中的关键二值变量与连续变量。

$$a_u(t) = \begin{cases} 1, & \text{在时间槽} t \text{ 接纳 SFC 请求 } r_u \\ 0, & \text{否则} \end{cases} \quad (4-1)$$

$$x_{u,k}^n(t) = \begin{cases} 1, & \text{VNF } f_k^u \text{ 在时间槽 } t \text{ 被部署在节点 } n \\ 0, & \text{否则} \end{cases} \quad (4-2)$$

$$y_u^{ij}(t) = \begin{cases} 1, & \text{SFC 请求 } r_u \text{ 在时间槽 } t \text{ 使用链路 } e_{ij} \\ 0, & \text{否则} \end{cases} \quad (4-3)$$

$$z_{u,k}^n(t) = \begin{cases} 1, & \text{时间槽 } t \text{ 迁移 VNF } f_k^u \text{ 到节点 } n \\ 0, & \text{否则} \end{cases} \quad (4-4)$$

这些变量用于刻画迁移过程中节点与链路的使用状态,是后续目标函数与约束条件的数学基础。

4、约束条件

在资源受限与过载场景下,合法的解必须满足以下物理资源约束、逻辑拓扑约束及服务质量约束。特别地,本文引入了准入关联约束,确保只有被接纳的业务才会占用网络资源。

(1) VNF 部署约束,每个节点可以部署多个 VNF,但需要满足该节点的资源限制以及 VNF 兼容性限制。

$$\sum_{u,k} x_{u,k}^n(t) * R_k \leq R_n^{total} \quad (4-5)$$

(2) VNF 兼容性约束,并非所有的节点都能够部署任意类型的 VNF。只有满足节点能力条件的 VNF 才能部署在相应节点上。

$$x_{u,k}^n(t) \leq V_n^{f_k^u} \quad (4-6)$$

(3) 迁移目标节点可用性约束,当 VNF f_k^u 迁移到新的节点时,该节点必须有足够的剩余资源并且支持该 VNF 类型。

$$z_{u,k}^n(t) \leq V_n^{f_k^u} * \delta_n(t) \quad (4-7)$$

(4) VNF 顺序保持约束, VNF 必须按照 SFC 请求中的顺序依次执行,以确保服务完整性:

$$\sum_{n \in N} x_{u,k+1}^n(t) \leq \sum_{n \in N} x_{u,k}^n(t) \quad (4-8)$$

该约束确保只有在 f_k^u 执行完成后, f_{k+1}^u 才能被部署在物理节点上。由此通过防止乱序部署来保障服务链完整性。该机制有别于迁移后最短连续运行时长 τ_u ,后者保证每个迁移后的 VNF 在所需时长内保持稳定在线

(5) 路径连续性约束, 迁移后的 VNF 之间必须存在物理链路, 形成一条完整的传输路径:

$$x_{u,k}^n(t) + x_{u,k+1}^n(t) \leq \sum_{(i,j) \in E} y_u^{ij}(t) \quad (4-9)$$

该约束确保了如果 f_k^u 和 f_{k+1}^u 部署在不同节点上, 那么必须存在一条有效的网络路径。具体而言, 当同一服务链中的第 k 个 VNF 与第 $k+1$ 个 VNF 被映射到不同物理节点时, 左端之和等于 2, 此时右端必须至少有一条活跃链路 $y_{uij}(t)=1$ 连接这两个节点, 以形成完整的传输路径; 若两 VNF 被映射到同一节点, 则左端之和为 1 或 0, 该约束自动成立, 无需额外链路。通过该约束, 我们确保了迁移后服务功能链各段在物理层面的连通性, 防止出现映射到互不相连节点而无法转发的情况, 从而维护了 SFC 的整体服务完整性。

(6) 节点资源约束, 节点资源不能超出其物理容量, 迁移后的 VNF 必须符合资源限制:

$$C_n^{used}(t) = \sum_{u,k} x_{u,k}^n(t) * C_k^{cpu} \leq C_n^{total} \quad (4-10)$$

$$M_n^{used}(t) = \sum_{u,k} x_{u,k}^n(t) * M_k^{mem} \leq M_n^{total} \quad (4-11)$$

$$B_n^{used}(t) = \sum_{u,k} x_{u,k}^n(t) * B_k^{band} \leq B_n^{total} \quad (4-12)$$

此处, C_k^{cpu} 和 M_k^{mem} 分别表示 VNF 实例 v_k 在其宿主节点上的 CPU 和内存资源消耗; B_k^{band} 则表示该实例在节点网络接口上的带宽需求。这些约束确保节点 n 在任意时刻的总资源使用量均不超过其物理可用容量。

(7) 链路容量约束链路传输的数据量不得超过物理链路带宽:

$$B_{i,j}^{used}(t) = \sum_u y_u^{ij}(t) * \lambda_u \leq B_{i,j}^{total} \quad (4-13)$$

(8) 时延约束, 链路上的端到端延迟必须满足 SFC 的最大时延限制:

$$\sum_{(i,j) \in P_{i,j}} D_{uij}(t) \leq D_{max}^u \quad (4-14)$$

(9) VNF 迁移触发约束, 当 VNF 迁移发生时, 需在目标节点重新分配资源:

$$z_{u,k}^n(t) \geq x_{u,k}^n(t) - x_{u,k}^n(t-1) \quad (4-15)$$

(10) 节点资源使用更新约束, 当 VNF 迁移完成后, 目标节点的资源状态需要进行更新, 以反映资源的使用变化。

$$R_n^{used}(t+1) = R_n^{used}(t) + \sum_{u,k} z_{u,k}^n(t) * R_k \quad (4-16)$$

(11) 准入与部署关联约束, 该约束建立了准入决策与物理资源分配之间的逻辑关联。对于任意 SFC 请求 r_u , 其包含的每一个 VNF f_k^u 必须且只能被部署一次, 但前提是该请求已被系统接纳 (即 $a_u(t) = 1$)。若请求被拒绝, 则不进行任

何部署。

$$\sum_{n \in N} x_{u,k}^n(t) = a_u(t), \forall r_u \in R_u, \forall f_k^u \in F_u \quad (4-17)$$

5、业务价值与收益模型

在过载博弈中，运营商需根据业务带来的潜在经济效益进行准入筛选。本文构建的服务收入模型综合考量了资源消耗量与业务优先级溢价。若请求 r_u 被成功接纳并服务，其产生的收益 R_u 定义为：

$$P_{tech}^u = w_1 * e^{-\frac{D_{max}^u}{D_{norm}}} + w_2 * L_{req}^u \quad (4-18)$$

$$R_u = \alpha * \lambda_u * (1 + \beta * P_{tech}^u) \quad (4-19)$$

其中 P_{tech}^u 是量化业务对 QoS 的敏感度及重要性，值越高代表业务越关键。 w_1 、 w_2 用于平衡时延敏感度与基础等级在评分中占比的系数。 L_{req}^u 是用来标识业务类别的常数。 α 表示网络提供基础连接服务时，每消耗 1Mbps 带宽的标准收费价格。 β 用于放大高优先级业务的价值权重， $\beta > 0$ 确保了高 SLA 等级业务能够贡献显著高于普通业务的收益，从而在准入竞争中占据优势。

6、基于影子价格的拥塞反馈模型

为了将物理网络的拥塞状态转化为经济信号，本文引入微观经济学中的影子价格理论。影子价格作为资源的虚拟成本，能够动态反馈网络中供需关系的失衡状态。基于当前的影子价格向量 $\Pi = \{\pi_n, \pi_{i,j}\}$ ，请求 r_u 在特定部署方案下的估算资源成本 $C_{est}^u(\Pi, t)$ 定义为：

$$\pi_n(t+1) = \begin{cases} \pi_n(t) * (1 + \delta * (\rho_n(t) - \rho_{target})), & \rho_n(t) > \rho_{target} \\ \max(1, \pi_n(t) * (1 - \varepsilon)), & \rho_n(t) < \rho_{target} \end{cases} \quad (4-20)$$

$$C_{est}^u(\Pi, t) = \sum_{f_{u,k} \in F_u} \sum_{n \in N} x_{u,k}^n * (a_c * C_k^{cpu} + a_m * M_k^{mem}) * \pi_n(t) + \sum_{(i,j) \in L} y_u^{ij} * (\lambda_u * \pi_{i,j}(t)) \quad (4-21)$$

其中， δ 为价格增长步长控制价格上涨速度的敏感度系数，防止震荡或响应过慢， ε 为价格衰减因子，控制资源空闲时价格回落速度的系数， a_c 、 a_m 分别表示 CPU 和内存资源在成本计算中的相对重要性。

投资回报率 ROI 为潜在收益与估算成本的比值，作为准入筛选的核心依据，其公式定义如下：

$$ROI_n = \frac{R_u}{C_{est}^u(\Pi, t)} \quad (4-22)$$

在本文机制中，ROI 用于外层准入的经济性度量与优先级排序信号，用于辅助识别高收益且资源效率更优的候选请求。需要强调的是，系统实现采用“收益导向排序+物理可行性检查”的联合准入策略，即先结合内层部署结果估计请求的预期利润，再按预期利润从高到低依次尝试准入，最终由资源容量与时延等硬约束决定是否接纳，从而避免单一阈值造成的收益震荡并提升过载场景下的稳定性。

7、目标函数

区别于第三章的单纯成本最小化，本章的目标是在资源受限条件下，通过选择最优的准入子集 $A \in R$ 和部署方案，实现网络总利润最大化。优化目标函数定义为：

$$C_{total}(t) = C_{mig}(t) + C_{route}(t) \quad (4-23)$$

$$C_{mig}(t) = \sum_{u,k,n} z_{u,k}^n(t) * D_{i,j} * (\lambda_u + \beta_u * c_k^{cpu} + \gamma * c_k^{mem}) \quad (4-24)$$

$$C_{route}(t) = \sum_{(i,j) \in L} y_{u,k}^n(t) * \vartheta * v_{i,j} \quad (4-25)$$

$$Max P_{profit} = \sum_{r_u \in R} a_u * R_u - C_{total}(t) \quad (4-26)$$

其中 β_u 和 γ 分别为 $VNF f_k^u$ 所需的 CPU 资源迁移权重系数和内存资源迁移权重系数， c_k^{cpu} 和 c_k^{mem} 分别为 $VNF f_k^u$ 所需的 CPU 资源量和内存资源量。本节涉及的主要参数及意义如表 4-1 所示。

表 4-1 主要参数及含义

符号	描述
$G=(N,L)$	物理网络图，N 表示节点集合，L 表示物理链路集合
$C_i^{total}, M_i^{total}, B_{i,j}^{total}$	节点 n_i 的总 CPU、内存和带宽资源容量
$e_{i,j}$	物理链路，连接节点 n_i 和 n_j
$B_{i,j}^{total}$	链路 $e_{i,j}$ 的最大链路带宽容量
$D_{i,j}$	链路 $e_{i,j}$ 的传输距离
V_i	节点 n_i 可支持的 VNF 集合
V	系统中所有 VNF 的集合
r_u	第 u 条 SFC 请求
λ_u	SFC 请求 r_u 的流量需求
D_{max}^u	SFC 请求 r_u 的最大端到端延迟限制
D_{norm}	时延归一化常数
R_k	部署 $VNF f_k^u$ 所需的资源
R_n^{total}	节点 n 可用的资源上限
τ_u	SFC 请求 r_u 的处理时间槽
$\rho_n(t)$	节点实时负载率
ρ_{target}	目标负载阈值
$L_{(i,j)}$	链路 $e_{i,j}$ 的传输时延
$\pi_n(t)$	节点影子价格
ϑ	链路距离权重系数
$v_{i,j}$	链路 $e_{i,j}$ 的传播代价
$\pi_{i,j}(t)$	链路影子价格
$V_n^{f_k^u}$	二值变量，节点 n 是否支持 $VNF f_k^u$
a_u	二值变量，是否接纳业务请求 r_u

表 4-1 主要参数及含义（续）

符号	描述
$x_{u,k}^n(t)$	二值变量，时间槽 t 时 VNF f_k^u 是否部署在节点 n
$y_u^{ij}(t)$	二值变量，时间槽 t 时 SFC r_u 是否使用链路 $e_{i,j}$
$z_{u,k}^n(t)$	二值变量，时间槽 t 时 VNF f_k^u 是否迁移到节点 n

4.3 问题求解

4.3.1 算法设计

本文提出的基于拥塞反馈与动态定价的 VNF 迁移准入算法（Congestion-Feedback Dynamic Pricing Admission, CF-DPA），旨在在动态网络环境中实现高负载条件下的收益最大化与资源可行性保障。由于准入决策与物理映射强耦合，且节点与链路资源状态随业务到达持续变化，本章将问题求解过程划分为连续阶段，以确保 QoS 约束与资源利用效率之间的平衡。图 4-1 展示了 CF-DPA 实施的完整系统运行流程。系统首先基于网络节点与链路的实时负载状态初始化影子价格向量，随后在外循环中计算动态成本与 ROI 并构建候选集合，再通过利润优先的准入策略决定接纳集合。对候选请求的部署映射由第三章提出的 LFO-VNM 作为内层求解器完成，在给定影子价格引导下搜索满足资源与 QoS 约束的近似最优迁移方案。每轮迭代结束后，拥塞反馈控制器根据节点与链路的违约程度更新影子价格，将拥塞惩罚反馈至下一轮外层筛选，从而形成“拥塞-价格-准入-负载”的闭环控制流程，直至系统收敛或达到最大迭代次数，最终输出准入策略与部署映射方案。




图 4-1 CF-DPA 系统运行流程

阶段 1：网络状态感知与影子价格初始化

CF-DPA 的初始阶段为网络资源状态的监测与影子价格的初始化。系统获取时间槽 t 的节点 CPU 与内存利用率，以及链路带宽利用率，并根据预设阈值识别潜在瓶颈资源。为将资源稀缺性映射为经济信号，分别为节点计算资源与链路带宽资源初始化影子价格向量 $\pi(t)$ 。公式定义如下：

CF-DPA 的初始阶段为网络资源状态的感知与影子价格向量初始化。设时间槽 t 时节点 n 的 CPU 与内存利用率分别为：

$$\rho_n^{cpu}(t) = \frac{U_n^{cpu}(t)}{C_n^{cpu}}, \rho_n^{mem}(t) = \frac{U_n^{mem}(t)}{C_n^{mem}} \quad (4-27)$$

其中 $U_n^{cpu}(t), U_n^{mem}(t)$ 为当前已用资源， C_n^{cpu}, C_n^{mem} 为节点容量。链路 e_{ij} 的带宽利用率定义为：

$$\rho_{ij}^{bw}(t) = \frac{U_{ij}^{bw}(t)}{B_{ij}} \quad (4-28)$$

其中 $U_{ij}^{bw}(t)$ 为链路已用带宽， B_{ij} 为链路带宽容量。

为将资源稀缺性映射为经济信号，定义节点与链路影子价格向量：

$$\pi_n(t) = \{\pi_n^{cpu}(t), \pi_n^{mem}(t)\}, \pi_{ij}(t) = \pi_{ij}^{bw}(t) \quad (4-29)$$

初始化时可取统一常数 $\pi_n^{cpu}(0) = \pi_n^{mem}(0) = \pi_{ij}^{bw}(0) = \pi_0$ ，并设置价格下界 $\pi_{\min}$ 以保证数值稳定性。该阶段的目标是为后续“动态成本估计-准入筛选”提供统一的价格基准，并避免在迭代初期出现价格震荡导致的筛选不稳定。

阶段 2：动态成本与 ROI 计算并生成候选集合

在给定影子价格向量 $\pi(t)$ 下，外层对每个 SFC 请求 r 调用内层 LFO-VNM 求解器获得迁移映射与路径方案，并计算动态估算成本 $C_{est}(r, t)$ 。该成本由节点侧价格化代价与链路侧价格化代价构成：

节点侧估算代价

请求 r 的第 k 个 VNF 映射到节点 n ，其 CPU 与内存需求为 $c_{r,k}^{cpu}, c_{r,k}^{mem}$ ，则

$$C_{node}(r, t) = \sum_k (\alpha_c \cdot c_{r,k}^{cpu} \cdot \pi_n^{cpu}(t) + \alpha_m \cdot c_{r,k}^{mem} \cdot \pi_n^{mem}(t)) \quad (4-30)$$

链路侧估算代价

设请求 r 的业务带宽需求为 λ_r ，其路由路径经过的链路集合为 P_r ，则

$$C_{link}(r, t) = \sum_{(i,j) \in P_r} \alpha_b \cdot \lambda_r \cdot \pi_{ij}^{bw}(t) \quad (4-31)$$

于是动态估算成本为

$$C_{est}(r, t) = C_{node}(r, t) + C_{link}(r, t) \quad (4-32)$$

进一步定义动态投资回报率（ROI）为

$$ROI(r, t) = \frac{R_u(r)}{C_{est}(r, t)} \quad (4-33)$$

其中 $R_u(r)$ 为请求收益（前文已定义，本文不再重复）。外层根据 $ROI(r, t)$ 与 $C_{est}(r, t)$ 生成候选集合 F_{vip} ，用于后续准入排序与可行性筛选。基于 $C_{est}(r, t)$ 与 ROI 的计算结果，外层构建高价值候选集合 F_{vip} ，作为后续准入决策的输入。该阶段保证候选请求在经济性与可行性层面均具有较高优先级，从而降低外层准入的试错成本。

阶段 3：利润优先的顺序准入与资源更新

对候选集合 F_{vip} 中每个请求 r ，内层返回其部署评估结果并给出真实执行成本 $C_{real}(r, t)$ 。由于迁移成本与路由成本的具体表达式已在前文给出，此处仅给出其组合关系：

外层定义预期利润为

$$\hat{\Pi}(r, t) = R_u(r) - C_{real}(r, t) \quad (4-34)$$

并按 $\hat{\Pi}(r, t)$ 从高到低对 F_{vip} 排序，依次尝试准入。对任意请求 r ，若接纳后仍满足硬约束，则令 $\alpha_r = 1$ 并将其加入接纳集合 A_R ，否则令 $\alpha_r = 0$ 。

硬约束检查以资源容量为核心，典型形式如下（示例给出 CPU/内存与链路带宽约束）：

$$U_n^{cpu}(t) + \Delta U_n^{cpu}(r) \leq C_n^{cpu}, U_n^{mem}(t) + \Delta U_n^{mem}(r) \leq C_n^{mem} \quad (4-35)$$

$$U_{ij}^{bw}(t) + \Delta U_{ij}^{bw}(r) \leq B_{ij} \quad (4-36)$$

其中 $\Delta U(\cdot)$ 表示接纳请求 r 带来的增量资源占用。若请求被接纳，则需同步更新节点与链路占用：

$$U_n^{cpu}(t) \leftarrow U_n^{cpu}(t) + \Delta U_n^{cpu}(r), U_n^{mem}(t) \leftarrow U_n^{mem}(t) + \Delta U_n^{mem}(r) \quad (4-37)$$

$$U_{ij}^{bw}(t) \leftarrow U_{ij}^{bw}(t) + \Delta U_{ij}^{bw}(r), \forall (i, j) \in P_r \quad (4-38)$$

该阶段的目标是在保证系统可行性的前提下实现高价值优先的资源分配，并为下一轮拥塞反馈提供真实负载依据。

阶段 4：拥塞反馈控制与影子价格迭代更新

轮外层准入结束后，系统进入拥塞反馈控制阶段。拥塞反馈控制器根据更新后的节点与链路负载率计算违约程度，并按分段乘法规则更新影子价格。负载高于阈值时价格上调，负载低于阈值时价格衰减并设置下界，以保证价格始终为正且更新稳定。更新后的影子价格向量将进入下一轮外循环，用于重新评估 $C_{est}(r, t)$ 与候选集合 F_{vip} ，从而形成负反馈闭环。若检测到系统收敛，例如影子价格变化幅度与接纳集合在连续若干轮迭代中趋于稳定，则终止迭代并输出最终准入策略与部署映射方案。

如 4.3.1 章节算法 1 所示，算法首先初始化影子价格向量并设定阈值与更新参数，用以统一表征节点与链路资源的稀缺程度，为后续迭代提供稳定的定价基准（第 1 行）。随后在外层迭代过程中，算法逐请求调用内层 LFO-VNM 求解器获得迁移部署映射及评估结果，并依据式(4-21)与式(4-22)分别计算估算成本与投资回报率，同时由收益与真实成本计算预期利润，从而构建包含“映射-评估-经

济性指标-资源增量”的候选集合（第 2-9 行）。在此基础上，算法调用算法 3 对候选集合执行以预期利润为主序、投资回报率为次序的排序，并完成利润优先的顺序准入与硬约束检验，输出本轮接纳集合及其对应的迁移部署映射，同时同步更新节点资源增量与链路带宽占用统计，以保证接纳集合的全程可行性与资源一致性（第 10 行）。随后算法调用算法 2，依据本轮接纳集合导致的节点与链路负载变化更新影子价格向量，并将拥塞信息反馈到下一轮候选评估与准入排序中（第 11 行）；最后依据收敛条件判断是否终止迭代，并返回接纳集合与对应迁移部署映射（第 12-14 行）。通过上述闭环过程，算法实现“拥塞-价格-准入-负载”的负反馈调控，使系统能够自适应规避瓶颈资源并优先保障高价值业务。

算法 1 基于拥塞反馈动态定价的 VNF 迁移准入算法（CF-DPA）

输入：物理网络拓扑图 $G(N, L)$ ，SFC 请求集合 R ，节点资源状态与链路资源状态，最大外层迭代次数 K

输出：接纳集合 A_R ，迁移部署映射方案 $Placement$

1. 初始化影子价格向量，设置阈值与更新参数
 2. for $t = 1$ 到 K do
 3. 候选集合 $\leftarrow \emptyset$
 4. for 每个请求 do
 5. 调用内层 LFO-VNM 算法得到迁移部署映射与评估结果
 6. 按式(4-21)计算估算成本，按式(4-22)计算投资回报率
 7. 由收益与真实成本计算预期利润
 8. 将请求及其映射、评估、预期利润与资源增量加入候选集合
 9. end for
 10. 调用算法 3，对候选集合执行利润优先的顺序准入，得到接纳集合
 11. 调用算法 2，依据本轮节点与链路负载更新影子价格
 12. 若满足收敛条件则退出循环
 13. end for
 14. return 接纳集合与对应迁移部署映射
-

如 4.3.1 章节算法 2 所示，算法通过将资源负载映射为影子价格变化，实现拥塞反馈下的动态定价更新。具体而言，算法首先对所有节点逐一计算资源负载率，并依据式(4-20)分别更新节点计算资源影子价格，从而将节点侧拥塞程度转化为边际资源代价（第 1-4 行）。随后对所有链路逐一计算带宽负载率，并同样依据式(4-20)更新链路带宽影子价格，使链路侧拥塞以价格形式进入下一轮成本估计与准入决策（第 5-8 行）。最后输出更新后的影子价格向量 $\pi(t + 1)$ （第 9 行）。该更新机制在负载超过阈值时上调价格以体现稀缺性，在负载较低时衰

减价格并保持下界，从而在数值稳定的前提下为外层准入提供持续的拥塞反馈信号。

算法 2 拥塞反馈控制下的影子价格更新算法

输入： 节点负载率、链路负载率、当前影子价格 $\pi(t)$ ，阈值 ρ_0 ，更新参数

输出： 更新后的影子价格 $\pi(t+1)$

1. for 每个节点 $n \in N$ do
 2. 计算节点计算资源负载率
 3. 按式(4-20)更新节点计算资源影子价格
 4. end for
 5. for 每条链 do
 6. 计算链路带宽负载率
 7. 按式(4-20)更新链路带宽影子价格
 8. end for
 9. return 影子价格 $\pi(t+1)$
-

如 4.3.1 章节算法 3 所示，算法以利润优先为原则实现顺序准入，并通过硬约束筛选保证接纳集合始终可行。算法首先初始化接纳集合、累计节点资源增量以及链路带宽占用统计，为后续试接纳提供统一的资源基线（第 1-3 行）。随后以预期利润为主序、投资回报率为次序对候选集合进行降序排序，确保高利润请求优先进入准入检测（第 4 行）。在顺序遍历过程中，算法对每个候选请求进行试接纳评估：先计算试接纳后的节点与链路负载状态，再进行硬约束检查；若容量不超限、带宽不超限且时延不违约等约束均满足，则接纳请求并同步更新节点资源增量与链路带宽占用统计，否则拒绝并继续下一请求（第 5-12 行）。最后返回最终接纳集合（第 13 行）。该策略通过“排序优先级-硬约束校验-资源同步更新”的联合机制，在过载场景下兼顾收益导向与可行性保障，为外层闭环控制提供稳定且可解释的准入决策基础。

算法 3 利润优先的顺序准入算法

输入： 候选集合及其预期利润与资源增量，当前节点与链路资源状态

输出： 接纳集合 A_R

1. 接纳集合 $\leftarrow \emptyset$
 2. 累计节点资源增量置零
 3. 初始化链路带宽占用统计
 4. 按预期利润降序、投资回报率次序对候选集合排序
 5. for 按序遍历候选集合 do
-

-
6. 计算试接纳后的节点负载与链路负载
 7. if 硬约束均满足（容量不超限、带宽不超限、时延不违约等）则
 8. 接纳该请求
 9. 更新累计节点资源增量
 10. 更新链路带宽占用统计
 11. end if
 12. end for
 13. return 接纳集合 A_R
-

4.3.2 算法复杂性分析

在计算复杂度方面，CF-DPA 由外层动态筛选与顺序准入、以及内层 LFO-VNM 部署求解两部分组成。设时间槽内请求数量为 $|R|$ ，物理网络节点数与链路数分别为 $|N|$ 与 $|L|$ ，单条服务链包含的 VNF 数量为 $|V_r|$ 。外层阶段需要对每个请求调用一次内层求解并计算经济性指标，因此外层的主要开销由“候选生成+排序+逐条准入检查”构成：其中候选集合的利润计算与构建为 $O(|R|)$ ，对候选集合按预期利润排序的复杂度为 $O(|R| \log |R|)$ ；顺序准入过程中每次试接纳需进行节点容量与链路带宽及时延等硬约束检验，其最坏情况下涉及对服务链映射节点与对应路径链路的遍历，复杂度可记为 $O(|V_r| + |P_r|)$ ，于是外层约为 $O(|R| \log |R| + \sum_{r \in R} (|V_r| + |P_r|))$ 。内层采用第三章的 LFO-VNM，设人工鱼群规模为 M ，最大迭代次数为 T ，一次适应度评估需完成映射可行性校验与路径代价计算，其复杂度与网络规模相关，可记为 $\Phi(|N|, |L|)$ ，则单次内层求解复杂度为 $O(T \cdot M \cdot \Phi(|N|, |L|))$ ，对所有请求求解为 $O(|R| \cdot T \cdot M \cdot \Phi(|N|, |L|))$ 。若外层最大迭代轮数为 K ，则 CF-DPA 的总体时间复杂度可概括为 $O(K \cdot (|R| \cdot T \cdot M \cdot \Phi(|N|, |L|) + |R| \log |R| + \sum_{r \in R} (|V_r| + |P_r|)))$ 。因此，该方法通过将 NP-Hard 的全局联合优化分解为“外层筛选调控+内层近似映射”，并可通过限制候选集合规模与外层迭代次数、复用路径评估结果等方式降低常数项，从而满足过载场景下准在线决策的计算需求。

4.4 仿真设计与性能分析

在本节中，我们对本文提出的基于拥塞反馈与动态定价的 VNF 迁移准入算法 CF-DPA 的性能进行系统评估，并与多种典型基线方案进行对比分析。为验证算法在真实应用场景中的有效性，实验在真实网络拓扑上开展，采用统一的 SFC

与 VNF 配置生成方式与一致的负载压力设置，使不同算法在相同网络状态与工作负载下进行公平比较。

4.4.1 实验环境和参数设置

网络拓扑：本文采用了网络拓扑 Zoo^[67]中的真实网络拓扑结构 BsonetEurope（包含 18 个节点和 23 条链路）。该拓扑包含 18 个节点与 23 条物理链路。网络中节点计算资源采用异构配置方式生成，节点 CPU 与内存资源容量范围分别设置为[400,800]单位；物理链路带宽容量设置为[1,10]Gbps，链路传播时延设置为[3,5]ms，从而构建具有异构计算能力与差异化传输能力的真实网络环境，用于评估过载条件下的准入与迁移决策性能。

SFC 与 VNF：本文设定 5 种 VNF 类型，每条 SFC 由[2,5]个 VNF 串联构成，且源节点与目的节点均随机选自网络拓扑中的节点且不相同。业务请求划分为 URLLC、Video 与 IoT 三类，对应的业务带宽需求分别为[1,8]Gbps、[5,20]Gbps 与[1,10]Gbps，最大容忍时延分别为[20,50]ms、[50,150]ms 与[200,500]ms 为体现业务速率对计算资源占用的影响，VNF 的 CPU 与内存资源需求按照业务速率进行配置，具体为每 10Mbps 业务速率需消耗[1,5]个单位的计算资源，从而模拟不同业务规模对节点资源的差异化消耗并保证实验设置与真实场景一致。

4.4.2 对比算法介绍

为客观评估本文提出的 CF-DPA 在过载场景下的准入与迁移协同能力，本文从准入策略对比和迁移算法对比两条主线设置基线方案。前者用于隔离验证外层准入规则对收益与拥塞的影响，后者用于对照不同迁移优化范式在动态网络中的适用性，从而使实验结论能够清晰归因 CF-DPA 的关键机制（影子价格更新、利润优先顺序准入与闭环拥塞反馈）。

对比策略介绍（外层准入机制基线）

到达顺序准入策略（FIFO）：按请求到达顺序依次尝试准入，仅做硬约束可行性检查，不引入经济性排序与拥塞反馈。该策略代表无调控的基础准入机制，用于对比本文方法在高负载下对资源挤占与收益波动的抑制效果。

优先级准入策略（PRIORITY）：按业务优先级排序后顺序准入，体现高等级业务优先保障的服务级别思想，但缺少对节点-链路拥塞的显式定价反馈。该基线用于验证：仅依赖业务等级能提升关键业务接纳，但在瓶颈链路和热点节点出现时，仍可能产生较高成本与较差的全局协调性，从而凸显本文“拥塞定价+

利润排序”的优势。

静态规则/静态定价策略（STATIC）：采用固定阈值或固定成本权重进行准入判断与排序，但不随拥塞状态迭代更新。该基线用于隔离影子价格机制的作用，验证有定价但无反馈在动态负载下难以持续规避瓶颈资源，从而突出 CF-DPA 的闭环更新价值。

迁移算法介绍（迁移优化范式基线）

能耗-QoS 导向迁移算法（SFCM-EQA）^[36]为能耗与服务质量协同优化的迁移范式，通过评价函数在可行迁移方案中进行选择，重点关注能耗与 QoS 指标的折中。

长期预算约束在线迁移（TMSM）^[28]算法通过预算队列或等价反馈变量约束长期迁移开销，并在每个时隙进行在线优化。

本文选择 SFCM-EQA 与 TMSM 作为基线方案，是因为它们分别代表动态网络中两类主流且互补的迁移决策范式：前者以能耗与 QoS 的协同权衡为核心，后者以长期约束下的在线反馈调控为核心，均具备清晰的决策结构与可工程化实现的更新机制。对比算法 SFCM-EQA 与 TMSM 在原始研究中分别面向不同优化目标设计，其目标函数与本文并不完全一致。为保证实验比较的公平性，本文在统一网络拓扑、资源约束及业务生成条件下对相关算法进行复现，并尽可能保持其原始优化机制不变，从而重点比较不同方法在业务接纳能力、资源利用效率及迁移成本控制方面的综合性能表现。通过与这两类代表性范式的对照，我们能够更有针对性地验证 CF-DPA 将节点与链路拥塞映射为影子价格并作用于准入排序的闭环机制，在过载场景下对瓶颈规避与收益提升的优势。

4.4.3 评价指标

接纳数量：统计在每个时间槽内被算法成功接纳并完成部署的 SFC 请求数量，用于衡量算法在资源约束条件下的服务承载能力与准入有效性。

负载方差：用于衡量各物理节点平均负载率的离散程度，方差越小表明负载分布越均匀、热点更少，从而有助于抑制局部拥塞并提升系统鲁棒性，则系统的平均负载率定义如式(4-39)所示：

$$\bar{\rho} = \frac{1}{|N|} \sum_{n \in N} \rho_n \quad (4-39)$$

负载方差定义如式(4-40)所示：

$$\text{Var}_{load} = \frac{1}{|N|} \sum_{n \in N} (\rho_n - \bar{\rho})^2 \quad (4-40)$$

其中， $\rho_n \in [0,1]$ 表示节点 n 的负载率， $\bar{\rho}$ 表示全网节点负载率的均值， Var_{load}

越小表示负载分布越均匀、热点更少。

运营利润：表示接纳请求带来的总收益与其对应的真实执行成本之差，用于评估准入策略在过载场景下的整体运营效益，具体由式(4-26)计算。

总成本：统计接纳集合对应的真实成本总和，用于刻画在获得当前收益水平时系统付出的整体代价，具体定义见式(4-23)。

迁移成本总和：衡量接纳请求在迁移过程中产生的状态传输开销与潜在中断风险的累积水平，用于评估迁移机制对系统开销的贡献，计算方式见式(4-24)。

路由成本总和：反映接纳请求在迁移后数据流映射到物理链路上的带宽占用与传输代价，用于表征链路侧负载压力与传输效率，具体由式(4-25)给出。

4.4.4 实验结果与分析

图 4-2 显示了各策略在不同请求规模 N 下的接纳数量对比结果。随着请求规模 N 增大，各策略的接纳能力总体呈先升后受限的趋势，但 CF-DPA 在全区间内始终保持最高接纳数量，并在过载区间优势显著放大。在中低负载下，CF-DPA 的接纳数量较基线最优提升约 13.16%-22.58%；当系统进入拥塞点（ $N = 180$ ）时，基线策略接纳量出现明显塌陷，而 CF-DPA 仍可维持较高的接纳水平，较基线最优提升达到 66.67%。该结果表明，CF-DPA 通过影子价格将瓶颈资源的边际代价显式注入准入排序，使外层更倾向接纳高价值且可持续承载的请求，从而在过载场景中显著提升系统承载能力。




图 4-2 不同策略下接纳 SFC 数量图

图 4-3 给出了节点平均负载方差的对比结果。节点负载方差结果表明，CF-DPA 能够在多数负载条件下改善负载均衡性。典型地，在较低负载时 CF-DPA 方差为 4.13%，较基线最优降低 17.85%；在高负载时较基线最优降低 27.36%。需

要指出的是，在部分中等负载点位，CF-DPA 的方差略高于最优基线，这与其显著扩大接纳规模并引入更多迁移与重路由行为有关，但总体趋势仍说明影子价格反馈能够有效抑制热点累积并促进资源分散，提升系统鲁棒性。




图 4-3 不同策略下节点平均负载方差图

图 4-4 展示了运营利润的对比结果。运营利润结果进一步验证了 CF-DPA 的收益导向优势。整体上，CF-DPA 在所有负载点均取得最高利润，且在拥塞区间提升幅度更为突出：在中低负载阶段，利润相对基线最优提升约 14.75% 至 17.87%；较高过载时，CF-DPA 的利润相比最优基线提升约 57.26%；在更高负载提升仍达 52.99%。这说明仅采用 FIFO 或优先级排序难以在拥塞时保持收益稳定，而 CF-DPA 通过“拥塞-价格-准入”闭环反馈实现对资源稀缺性的自适应定价，从而在高负载下仍能优先保障高利润请求并维持更高的整体运营效益。




图 4-4 不同策略下运营利润图

图 4-5 显示了迁移成本总和的对比结果。总体而言，随着 N 增大，迁移成本呈上升趋势，且 CF-DPA 在多数负载区间的迁移成本高于 FIFO、PRIORITY 与

STATIC。该现象的关键原因在于 CF-DPA 在资源紧张时显著提升接纳规模并优先保障高价值业务，从而触发更大规模的 VNF 状态迁移与重配置，导致迁移成本以总量形式增加。与之相对，基线策略通过更保守的接纳（拒绝更多请求）压低了迁移活动强度，因此迁移成本更低。结合利润与接纳数量结果可知，CF-DPA 的迁移成本上升并非低效迁移造成，而是以更高服务承载与更高收益输出为代价的合理取舍，体现了收益导向下的资源调度权衡。




图 4-5 不同策略下迁移成本总和图

图 4-6 给出了给出了迁移后 SFC 流量在物理链路上的路由成本总和对比。路由成本同样随 N 增大整体上升，且 CF-DPA 在高负载区间通常显著高于三种基线。这主要源于两点：其一，CF-DPA 接纳数量更大、承载流量更充分，使链路侧占用与传输代价累积更高；其二，CF-DPA 为规避瓶颈链路会将部分业务重路由至替代路径，可能带来更长路径或更高传输代价，从而提高路由成本总和。然而结合运营利润结果可见，尽管路由成本增加，CF-DPA 在过载区间仍能显著提升利润，表明其路由成本的上升对应更高的收益回报，且动态定价机制能够将有限链路资源优先配置给边际收益更高的请求，从而实现更优的收益-拥塞权衡。




图 4-6 不同策略下路由成本总和图

图 4-7 给出了给出了总成本对比结果。CF-DPA 的总成本在高负载下高于基线，但这一增加与其显著提升利润和接纳规模同步出现，反映的是以可解释的资源开销换取更高的运营收益与服务承载的经营决策逻辑。因此，总成本应与利润和接纳数量联合解读，CF-DPA 的优势在于通过动态定价闭环机制提升了过载条件下的收益稳定性与系统可服务能力，而非单纯追求成本最小化。




图 4-7 不同策略下总成本图

图 4-8 可见，三种方法的接纳能力随请求规模 N 增大整体提升，但在高负载阶段呈现明显分化。SFCM-EQA 的接纳数量始终最高，体现其更偏向尽可能承载的策略取向；CF-DPA 的接纳数量稳定处于第二梯队，并显著优于 TMSM，说明动态定价反馈与利润排序能够避免过度保守导致的承载能力损失。尽管 CF-DPA 的接纳数量略低于 SFCM-EQA，但其后续利润与成本表现表明，CF-DPA 并非单纯追求多接纳，而是更强调可持续承载下的收益最优。




图 4-8 不同算法下接纳 SFC 数量图

负载方差反映节点侧负载均衡程度。图 4-9 中显示，CF-DPA 在拥塞与重载阶段表现出更稳定的负载分散能力。相较 SFCM-EQA，CF-DPA 的节点负载方差可降低约 39.2%（拥塞增强阶段）与约 35.9%（重载阶段）；相较 TMSM，在重载阶段可进一步降低约 26.45%。这说明 CF-DPA 的影子价格反馈机制能够抑制热点节点持续挤占，并推动资源使用向更均衡的状态演化，从而提升系统在高负载条件下的鲁棒性与稳定性。




图 4-9 不同算法下节点平均负载方差图

图 4-10 可见，运营利润结果更直接体现了 CF-DPA 的优势。总体上，CF-DPA 在各负载水平下均获得最高利润，且在拥塞与重载阶段优势更为显著。相较 TMSM，CF-DPA 在拥塞阶段的利润提升约 32.71%，在重载阶段仍可保持约 31.00% 的提升；相较 SFCM-EQA，CF-DPA 在中度拥塞时利润优势虽较小（约 1.64%），但在重载阶段可扩展至约 30.40%。该现象表明，CF-DPA 并非单纯追求接纳规模，而是通过影子价格将拥塞代价内生到准入决策中，使资源优先分配给边际

收益更高且可持续承载的请求，从而在拥塞条件下保持更强的收益输出能力。




图 4-10 不同算法下运营利润图

图 4-11 可见，迁移成本结果体现了不同方法在“承载规模-调整强度”上的取舍差异。总体上，TMSM 由于长期约束调控更为保守，迁移成本总和最低；SFCM-EQA 接纳更激进，迁移调整更频繁，迁移成本相对更高；CF-DPA 介于两者之间，在拥塞与重载阶段能够在提升承载与收益的同时保持迁移开销可控。相较 SFCM-EQA, CF-DPA 在高负载阶段的迁移成本可降低约 6.19%。该结果表明，CF-DPA 的迁移成本上升主要源于更高的服务承载与更积极的资源重配置，但其决策仍体现出对迁移代价的抑制与可解释的收益回报。




图 4-11 不同算法下迁移成本总和图

图 4-12 可见，路由成本结果体现了三种机制在链路层面的代价差异。总体上，CF-DPA 的路由成本高 TMSM，但显著低 SFCM-EQA，说明动态定价能够有效抑制高代价路径承载。TMSM 的路由成本较低主要源于承载规模受限；SFCM-EQA 在高负载阶段路由代价显著增大，反映其在链路侧更容易引发高代价承载；

CF-DPA 则通过链路影子价格对拥塞链路进行惩罚，从而有效抑制高代价路径选择。相较 SFCM-EQA，CF-DPA 在拥塞与重载阶段的路由成本可降低约 37.15%-37.39%。这说明动态定价机制能够将链路拥塞外部性转化为可度量的边际代价，并在准入与部署层面实现对瓶颈链路的主动规避。




图 4-12 不同算法下路由成本总和图

图 4-13 可见，总成本结果进一步验证了 CF-DPA 的收益-成本权衡能力。TMSM 因承载保守而总成本最低，但同时牺牲了承载能力与利润；SFCM-EQA 虽接纳规模更大，但在拥塞条件下引入较高的迁移与路由代价，导致总成本显著上升。CF-DPA 通过影子价格反馈抑制高代价资源消耗，使其在保持高利润输出的同时显著压低激进策略的总成本。相较 SFCM-EQA，CF-DPA 在重载阶段的总成本可降低约 26.96%，同时利润仍可提升约 30.40%。这表明 CF-DPA 能在过载场景下实现更优的运营效益与资源代价的综合平衡。




图 4-13 不同算法下总成本图

4.4.5 本章小结

本章面向动态网络环境下的收益最大化与拥塞抑制需求,提出了基于拥塞反馈与动态定价的 VNF 迁移准入算法 CF-DPA。首先,从“收益-成本权衡”出发构建准入决策框架,引入影子价格刻画节点计算资源与链路带宽资源的边际稀缺性,并将其作为外层经济性评估与排序准入的统一度量。其次,设计“外层动态筛选-内层迁移部署求解”的双层闭环结构:外层依据影子价格与预期利润对请求进行利润优先的顺序准入,内层调用 LFO-VNM 生成可行迁移部署方案并输出真实性能评估,从而实现经济决策与物理映射的耦合优化;同时通过拥塞反馈更新影子价格,形成“拥塞-价格-准入-负载”的负反馈闭环调控机制。仿真实验表明,与典型的长期约束反馈策略(TMSM)及能耗-可靠性权衡(SFCM-EQA)策略相比,CF-DPA 在拥塞与重载场景下能够显著提升运营利润与系统承载能力,并有效降低负载离散度与链路侧高代价承载倾向;尽管其在更高承载下会带来一定迁移与路由开销上升,但整体表现出更优的“收益-成本权衡”与更强的拥塞自适应调控能力,为动态网络中的在线准入与迁移协同优化提供了可解释且可落地的解决方案。

5 总结与展望

5.1 主要工作总结

本文面向 5G/6G 网络中 NFV-SFC 的动态编排与资源调度需求，本文从多目标迁移优化到动态定价准入控制形成了互补的两阶段技术体系，第三章面向资源相对充裕的全局多目标优化，第四章面向资源稀缺的收益导向闭环调控，两者共同支撑动态网络中面向业务价值的资源管理需求，围绕常态负载下的多目标迁移优化与过载场景下的价值导向准入控制两类关键问题，提出了从模型构建到算法设计、再到仿真验证的系统化解决方案。

1、针对动态网络环境中 VNF 迁移引起的多维开销耦合问题，本文在第三章构建了以迁移成本、路由开销与节点能耗为核心的多目标联合优化模型，并引入优先级感知机制以刻画异构业务在资源占用与服务质量方面的差异化需求。在此基础上，设计了可扩展的近似求解框架，以在大规模网络条件下实现可行解的快速搜索与多目标权衡。仿真结果表明，相比典型对比算法，所提方法在综合成本控制与资源利用效率方面具有稳定优势，并能够在保证 QoS 约束的前提下实现更优的全局权衡。

2、针对突发流量导致的资源稀缺与过载问题，本文在第四章提出了基于拥塞反馈与动态定价的 VNF 迁移准入算法。该方法以影子价格量化节点与链路资源的边际稀缺性，通过外层候选评估与利润排序实现收益导向的顺序准入，并结合内层迁移部署求解器实现准入决策与物理映射的联动。同时，通过拥塞反馈对影子价格进行迭代更新，形成“拥塞-价格-准入-负载”的负反馈闭环，从而在资源受限条件下抑制拥塞扩散并提升高价值业务的保障能力。实验结果表明，所提出的闭环机制能够在不同请求规模下实现更高的接纳收益与更稳定的负载分布，体现出较强的鲁棒性与可解释性。

5.2 创新点

为应对动态网络环境下 VNF 迁移中多目标耦合难权衡与拥塞场景收益与稳定性难兼顾的双重挑战，本文围绕第三章与第四章提出的两类关键问题，分别从多目标迁移优化建模与近似求解、以及基于影子价格的闭环准入控制机制两个层

面开展研究。相较于现有研究多聚焦单一优化目标、静态资源状态或局部资源调度策略,本文更加关注动态网络环境中资源状态变化对迁移决策与业务保障能力的影响,本文的创新点体现在:既在常态负载下建立可解释的多目标优化框架与优先级保障机制,又在资源稀缺与拥塞场景下引入动态定价思想,将网络负载状态通过影子价格反馈到准入决策中,从而形成可在线迭代的收益导向闭环调控策略。

1、提出一种面向动态网络环境的优先级感知多目标 VNF 迁移优化方法。针对迁移成本、迁移后路由开销与节点能耗等多维目标耦合问题,构建统一多目标优化模型,并引入业务优先级感知机制,实现异构业务的差异化保障。在求解层面,结合拉格朗日松弛与启发式搜索实现复杂约束条件下的近似求解,提高了动态网络场景中的迁移优化能力与可扩展性。

2、提出一种基于拥塞反馈与动态定价的 VNF 迁移准入方法 CF-DPA。针对资源受限场景下的接纳冲突与拥塞扩散问题,引入影子价格刻画资源稀缺程度,构建“价格感知—收益排序—顺序准入—反馈更新”的闭环调控机制,使资源状态能够动态反馈至准入决策过程,在保证 QoS 约束的前提下,实现资源利用效率、高价值业务保障与负载均衡的协同优化。

5.3 不足与展望

本文围绕动态网络环境下的 VNF 迁移优化与准入调控开展研究,构建了优先级感知的多目标迁移优化框架与拥塞反馈动态定价的闭环准入机制。为进一步提升方法在复杂场景下的普适性与工程可用性,后续研究可从以下两个方面持续推进。

1、现有模型已覆盖迁移成本、路由开销、能耗与 QoS 约束等关键因素,并通过优先级机制实现差异化保障,但在真实网络运行中,业务体验往往还受到时延抖动、可靠性、突发拥塞、链路故障与迁移执行过程中的状态同步开销等因素影响。未来可在现有建模框架基础上进一步引入更细粒度的 SLA 指标与违约代价刻画,同时结合参数敏感性分析,研究关键控制参数对模型性能与稳定性的影响,并探索不同网络状态下的自适应参数设置策略,从而提升方法在复杂动态环境中的适用性与鲁棒性。

2、第四章 CF-DPA 通过影子价格实现拥塞反馈驱动的动态定价与准入闭环,但影子价格更新的步长、阈值与价格下界等控制参数将直接影响闭环的收敛速度与数值稳定性。在多瓶颈并发或负载强时变场景下,闭环可能出现收敛变慢或策

略灵敏度不足等问题。后续可结合对偶优化与控制理论对影子价格更新过程给出更严格的稳定性与收敛条件分析，并研究自适应参数调节策略以降低人工调参依赖；同时，面向 SDN 控制器与 NFV 编排框架开展原型化实现，系统评估控制开销、策略下发时延、迁移中断与状态转移代价等工程指标，以验证所提闭环机制在真实在线系统中的可部署性与可扩展性。

参考文献

- [1] Mijumbi R, Serrat J, Gorricho J L, et al. Network function virtualization: State-of-the-art and research challenges[J]. IEEE Communications surveys & tutorials, 2016, 18(1): 236-262.
- [2] Adoga H U, Pezaros D P. Network function virtualization and service function chaining frameworks: A comprehensive review of requirements, objectives, implementations, and open research challenges[J]. Future Internet, 2022, 14(2): 59.
- [3] 祖家琛,胡谷雨,严佳洁,等.网络功能虚拟化下服务功能链的资源管理研究综述[J].计算机研究与发展,2021,58(01):137-152.
- [4] Halpern J, Pignataro C. Service function chaining (SFC) architecture[R]. 2015.
- [5] Mechtri M, Ghribi C, Soualah O, et al. NFV orchestration framework addressing SFC challenges[J]. IEEE Communications Magazine, 2017, 55(6): 16-23.
- [6] 吴宇彤,周金和.一种采用 NFV 架构的服务功能链动态编排与部署[J].电讯技术,2022,62(10):1506-1513.
- [7] Kaur K, Mangat V, Kumar K. A review on Virtualized Infrastructure Managers with management and orchestration features in NFV architecture[J]. Computer Networks, 2022, 217: 109281.
- [8] Xu L, Hu H, Liu Y. SFCSim: a network function virtualization resource allocation simulation platform[J]. Cluster Computing, 2023, 26(1): 423-436.
- [9] 朱晓荣,王一忠.虚拟网络功能迁移研究综述[J].南京邮电大学学报(自然科学版),2018,38(01):45-53.DOI:10.14132/j.cnki.1673-5439.2018.01.005.
- [10] Attaoui W, Sabir E, Elbiaze H, et al. VNF and CNF placement in 5G: Recent advances and future trends[J]. IEEE Transactions on Network and Service Management, 2023, 20(4): 4698-4733.
- [11] Vieira J L, Macedo E L C, Battisti A L E, et al. Mobility-aware SFC migration in dynamic 5G-Edge networks[J]. Computer Networks, 2024, 250: 110571.
- [12] Chen W, Wang Z, Zhang H, et al. Cost-efficient flow migration for SFC dynamical scheduling in geo-distributed clouds[J]. Computer Networks, 2024, 249: 110496.
- [13] Liu Z, Shu Z, Chen S, et al. Low-latency virtual network function scheduling algorithm based on deep reinforcement learning[J]. Computer Networks, 2024, 246: 110418.
- [14] Yi B, Wang X, Huang M, et al. Design and implementation of network-aware VNF migration

- mechanism[J]. IEEE Access, 2020, 8: 44346-44358.
- [15] Sun P, Lan J, Li J, et al. Efficient flow migration for NFV with graph-aware deep reinforcement learning[J]. Computer Networks, 2020, 183: 107575.
- [16] Yu X, Wang R, Hao J, et al. Priority-aware deployment of autoscaling service function chains based on deep reinforcement learning[J]. IEEE Transactions on Cognitive Communications and Networking, 2024, 10(3): 1050-1062.
- [17] Qu H, Wang K, Zhao J. Priority-awareness VNF migration method based on deep reinforcement learning[J]. Computer Networks, 2022, 208: 108866.
- [18] Liang W, Cui L, Tso F P. Low-latency service function chain migration in edge-core networks based on open Jackson networks[J]. Journal of Systems Architecture, 2022, 124: 102405.
- [19] Noghani K A, Kassler A, Taheri J, et al. Multiobjective genetic algorithm for fast service function chain reconfiguration[J]. IEEE Transactions on Network and Service Management, 2022, 20(3): 3501-3522.
- [20] 阳勇,孟相如,康巧燕,等.拓扑与资源感知的虚拟网络功能迁移方法[J].计算机科学与探索,2021,15(11):2161-2170.
- [21] 王昌达,李柔,张治平.服务功能链部署的能耗与负载均衡联合优化[J].计算机应用研究,2025,42(05):1500-1506.
- [22] KONG Z X, LI H, XIANG M, et al. Multicast service chain deployment and adjustment method under user dynamic access[J]. Journal of Beijing University of Posts and Telecommunications, 2022, 45(6): 55.
- [23] Karamchand G. AI-Optimized Network Function Virtualization Security in Cloud Infrastructure[J]. International Journal of Humanities and Information Technology, 2025, 7(03): 01-12.
- [24] Wang Y, Shu Z, Chen S, et al. A cost and demand sensitive adjustment algorithm for service function chain in data center network[J]. Computer Networks, 2024, 242: 110254.
- [25] Feng H, Shu Z, Taleb T, et al. An aggressive migration strategy for service function chaining in the core cloud[J]. IEEE Transactions on Network and Service Management, 2022, 20(2): 2025-2039.
- [26] Shoura F, Gharaibeh A, Alouneh S. Optimization of Migration Cost for Network Function Virtualization Replacement[C]//2020 21st International Arab Conference on Information Technology (ACIT). IEEE, 2020: 1-7.
- [27] Li B, Cheng B, Liu X, et al. Joint resource optimization and delay-aware virtual network function migration in data center networks[J]. IEEE Transactions on Network and Service Management, 2021, 18(3): 2960-2974.

- [28] Qin Y, Guo D, Luo L, et al. Service function chain migration with the long-term budget in dynamic networks[J]. Computer Networks, 2023, 223: 109563.
- [29] Yue Y, Tang X, Zhang Z, et al. Virtual Network Function Migration Considering Load Balance and SFC Delay in 6G Mobile Edge Computing Networks[J]. Electronics, 2023, 12(12): 2753.
- [30] Yue Y, Tang X, Yang W, et al. Virtual Network Function Migration Considering Load Balance and SFC Delay in Cloud Datacenter[C]//2023 IEEE 16th International Conference on Cloud Computing (CLOUD). IEEE, 2023: 1-6.
- [31] Song S, Lee C, Cho H, et al. Clustered virtualized network functions resource allocation based on context-aware grouping in 5G edge networks[J]. IEEE Transactions on Mobile Computing, 2019, 19(5): 1072-1083.
- [32] Cho D, Taheri J, Zomaya A Y, et al. Real-time virtual network function (VNF) migration toward low network latency in cloud environments[C]//2017 IEEE 10th International Conference on Cloud Computing (CLOUD). IEEE, 2017: 798-801.
- [33] 单凯,云红艳,刘甜甜.基于 SDN 的数据中心网络负载均衡策略[J].现代信息科技,2025,9(11):121-126.
- [34] Liu D, Zhou Z, Zhang D, et al. Efficient service reconfiguration with partial virtual network function migration[J]. Computer Networks, 2024, 241: 110205.
- [35] Afrasiabi S N, Ebrahimzadeh A, Promwongsa N, et al. Cost-efficient cluster migration of VNFs for service function chain embedding[J]. IEEE Transactions on Network and Service Management, 2023, 21(1): 979-993.
- [36] Xu S, Liao B, Hu B, et al. A reliability-and-energy-balanced service function chain mapping and migration method for Internet of Things[J]. IEEE Access, 2020, 8: 168196-168209.
- [37] Yi B, Wang X, Huang M, et al. A multi-criteria decision approach for minimizing the influence of VNF migration[J]. Computer Networks, 2019, 159: 51-62.
- [38] Zhang F, Lu H, Guo F, et al. Traffic Prediction Based VNF Migration with Temporal Convolutional Network[C]//2021 IEEE Global Communications Conference (GLOBECOM). IEEE, 2021: 1-6.
- [39] Xiao J, Zheng J, Wen W, et al. Multi-objective optimization of SFC deployment using service aggregation and computing offload[J]. Computer Communications, 2024, 224: 60-71.
- [40] Karim A, Ema J, Yasmin T, et al. Latency and Cost-Aware Deployment of Dynamic Service Function Chains in 5G Networks[C]//2023 International Symposium on Networks, Computers and Communications (ISNCC). IEEE, 2023: 1-6.
- [41] Xia J, Cai Z, Xu M. Optimized virtual network functions migration for NFV[C]//2016 IEEE 22nd International Conference on Parallel and Distributed Systems (ICPADS). IEEE, 2016:

- 340-346.
- [42] Eramo V, Miucci E, Ammar M, et al. An approach for service function chain routing and virtual function network instance migration in network function virtualization architectures[J]. IEEE/ACM Transactions on Networking, 2017, 25(4): 2008-2025.
 - [43] Zhang Q, Liu F, Zeng C. Online adaptive interference-aware VNF deployment and migration for 5G network slice[J]. IEEE/ACM Transactions on Networking, 2021, 29(5): 2115-2128.
 - [44] Cerquitelli T, Meo M, Curado M, et al. Machine learning empowered computer networks[J]. Computer networks, 2023, 230: 109807.
 - [45] Liu Q, Tang L, Wu T, et al. Deep reinforcement learning for resource demand prediction and virtual function network migration in digital twin network[J]. IEEE Internet of Things Journal, 2023, 10(21): 19102-19116.
 - [46] Zhai D, Meng X, Yu Z, et al. A migration method for service function chain based on failure prediction[J]. Computer Networks, 2023, 222: 109554.
 - [47] Clark C, Fraser K, Hand S, et al. Live migration of virtual machines[C]//Proceedings of the 2nd conference on Symposium on Networked Systems Design & Implementation-Volume 2. 2005: 273-286.
 - [48] Ibrahimpasić A L, Han B, Schotten H D. AI-empowered VNF migration as a cost-loss-effective solution for network resilience[C]//2021 IEEE Wireless Communications and Networking Conference Workshops (WCNCW). IEEE, 2021: 1-6.
 - [49] Saidi M Y, Ikhelef I A, Li S, et al. Constrained routing in multi-partite graph to solve VNF placement and chaining problem[J]. Journal of Network and Computer Applications, 2024, 230: 103931.
 - [50] Nobach L, Rimac I, Hilt V, et al. Slim: Enabling efficient, seamless NFV state migration[C]//2016 IEEE 24th International Conference on Network Protocols (ICNP). IEEE, 2016: 1-2.
 - [51] Nobach L, Rimac I, Hilt V, et al. Statelet-based efficient and seamless NFV state transfer[J]. IEEE Transactions on Network and Service Management, 2017, 14(4): 964-977.
 - [52] Cerroni W, Callegati F. Live migration of virtual network functions in cloud-based edge networks[C]//2014 IEEE International Conference on Communications (ICC). IEEE, 2014: 2963-2968.
 - [53] Zhang J, Li L, Wang D. Optimizing VNF live migration via para-virtualization driver and QuickAssist technology[C]//2017 IEEE International Conference on Communications (ICC). IEEE, 2017: 1-6.
 - [54] Tay Y C, Gaurav K, Karkun P. A performance comparison of containers and virtual machines

- in workload migration context[C]//2017 IEEE 37th International Conference on Distributed Computing Systems Workshops (ICDCSW). IEEE, 2017: 61-66.
- [55] Addad R A, Dutra D L C, Bagaa M, et al. Fast service migration in 5G trends and scenarios[J]. IEEE Network, 2020, 34(2): 92-98.
- [56] Oliveira A T, Martins B J C A, Moreno M F, et al. SDN - based architecture for providing quality of service to high - performance distributed applications[J]. International Journal of Network Management, 2021, 31(5): e2078.
- [57] Mehraban S, Yadav R K. Traffic engineering and quality of service in hybrid software defined networks[J]. China Communications, 2024, 21(2): 96-121.
- [58] Beshley M, Kryvinska N, Beshley H, et al. Traffic engineering and QoS/QoE supporting techniques for emerging service-oriented software-defined network[J]. Journal of Communications and Networks, 2024, 26(1): 99-114.
- [59] Pei X, Sun P, Hu Y, et al. Enabling efficient routing for traffic engineering in SDN with Deep Reinforcement Learning[J]. Computer Networks, 2024, 241: 110220.
- [60] 管红光,杨宜镇,任万里,等.基于 OpenFlow 的网络虚拟化技术研究应用[J].电信科学, 2024, 30(1): 96-102.
- [61] Kim Y, Gil J M, Kim D. A location-aware network virtualization and reconfiguration for 5G core network based on SDN and NFV[J]. International Journal of Communication Systems, 2021, 34(2): e4160.
- [62] Ali T E, Chong Y W, Manickam S. Machine learning techniques to detect a DDoS attack in SDN: A systematic review[J]. Applied Sciences, 2023, 13(5): 3183.
- [63] Hnamte V, Najar A A, Nhung-Nguyen H, et al. DDoS attack detection and mitigation using deep neural network in SDN environment[J]. Computers & Security, 2024, 138: 103661.
- [64] 李晓霞. 软件定义网络环境下流量调度与安全防护策略研究[J]. 黑龙江科学, 2026, 17(02): 136-139.
- [65] Bragin M A. Survey on Lagrangian relaxation for MILP: importance, challenges, historical review, recent advancements, and opportunities[J]. Annals of Operations Research, 2024, 333(1): 29-45.
- [66] Pourpanah F, Wang R, Lim C P, et al. A review of artificial fish swarm algorithms: Recent advances and applications[J]. Artificial Intelligence Review, 2023, 56(3): 1867-1903.
- [67] Knight S, Nguyen H X, Falkner N, et al. The internet topology zoo[J]. IEEE Journal on Selected Areas in Communications, 2011, 29(9): 1765-1775.

攻读学位期间的学术论文与研究成果

论文情况:

- [1] Luo Y, Shu Z, Chen S, et al. Multi-objective optimization algorithm for VNF migration with priority awareness in dynamic networks[J]. Computer Networks, 2025: 111666. (CCF-B, SCI 期刊, 第一作者, 已发表)
- [2] Lin Q, Chen S, Xie H, et al. Roodsg: A Routing Optimization Framework for Dcn[J]. Computer Networks, 2026: 112207. (CCF-B, SCI 期刊, 第五作者, 已发表)

参与科研项目:

- [1] 福建省科技厅福厦泉协同创新平台项目, “Research and industrial application of high reliability intelligent gateway devices and systems based on LLM and SD-WAN”, No.2025E3012, 2025.09-2027.09(项目主要成员, 负责智能网关算法优化设计相关任务)
- [2] 来自网络通信公司的产学研项目, “Research on intelligent monitoring and optimization of power information network and its industrial application”, No.KH240131A, 2024.04-2027.04 (项目主要成员, 负责电力网络算法优化设计相关任务)

获得奖项:

- [1] 第六届全国高校计算机能力挑战赛华东赛区本研组 (三等奖, 1/1, 省 A)
- [2] 第九届 ICT 大赛实践赛省赛网络赛道高教组 (三等奖, 1/1, 省 A)
- [3] 第十六届蓝桥杯福建赛区 Python 程序设计研究生组 (二等奖, 1/1, 省 A)
- [4] 第十五届 MathorCup 数学应用挑战赛研究生组赛区 (三等奖, 1/3, 省 C)
- [5] 2025 网络技术挑战赛华东赛区 (三等奖, 1/6, 省 A)
- [6] 第 22 届全国大学生信息安全与对抗技术竞赛 (三等奖, 1/3, 国 A)
- [7] 第十一届全国大学生统计建模浙江赛区研究生组 (二等奖, 2/3, 省 A)
- [8] 2025 睿抗机器人开发者大赛 (RAICOM) 全国总决赛编程技能竞赛项目 (三等奖, 1/1, 国 A)