光电技术及应用

DOI：10.16818/j.issn1001－5868.20251222005

5G电力虚拟专网端到端确定性切片编排算法

唐元春，夏炳森*，陈霖锋，陈　力
（国网福建省电力有限公司 经济技术研究院，福州 350012）

摘　要： 5G电力虚拟专网中不同的电力业务对时延、可靠性等指标有不同的确定性要求，网络切片通过创建虚拟网络可为业务提供定制化服务。为确保服务质量并有效编排网络切片，保障各类业务的确定性服务性能，文章对5G电力虚拟专网中的端到端确定性切片编排问题进行研究。首先，设计一种5G电力虚拟专网和端到端网络切片相结合的架构，并建立包含网元映射过程的5G电力虚拟专用端到端网络切片虚拟网络功能（VNF）部署系统模型。其次，分析业务的服务需求，提出一种同时考虑信息年龄（AoI）和可靠性的新型资源分配优化模型，将系统长期的平均满意度作为优化目标。最后，为解决优化问题，提出一种基于深度强化学习的确定性业务资源分配算法进行求解。仿真结果表明，所提算法在收敛性、时延及平均AoI等方面均表现出更优性能，能够满足5G电力虚拟专网中业务的确定性需求。

关键词： 5G电力虚拟专网；网络切片；深度强化学习
中图分类号： TN915　**文章编号：** 1001－5868(2026)02－0365－08

5G Power Virtual Private Network End-to-End Deterministic Slicing Orchestration Algorithm

TANG Yuanchun, XIA Bingsen, CHEN Linfeng, CHEN Li
(Economic and Technological Research Institute, State Grid Fujian Electric Power Co., Ltd., Fuzhou 350012, CHN)

Abstract: In the 5G power virtual private network (VPN), different power services have different deterministic requirements for latency, reliability, and other metrics. Network slicing creates virtual networks to provide customized services for fulfilling these requirements. In this study, we investigated the end-to-end deterministic slice orchestration problem in the 5G power VPN to ensure service quality, effectively orchestrate network slices, and guarantee the deterministic service performance of various types of services. First, a 5G power VPN architecture, combined with end-to-end network slicing, is designed, and an end-to-end network slice virtual network function (VNF) deployment system model is established, which includes the network element mapping process. Next, the service requirements for different power services are analyzed, and a novel resource allocation optimization model is proposed, which simultaneously considers age of information (AoI) and reliability; the optimization objective of this model is the long-term average satisfaction of the system. Finally, to solve the optimization problem, a deterministic service resource allocation algorithm is proposed based on deep reinforcement learning. Simulation results show that the proposed algorithm outperforms baseline algorithms in terms of convergence, latency, and average AoI, meeting the deterministic requirements of services in 5G power VPNs.

Key words: 5G power virtual private network; network slicing; deep reinforcement learning

收稿日期：2025－12－22.
基金项目：国网福建经研院2024年基于多类业务的5G确定性网络仿真技术研究项目（52130N240008）.
* **通信作者：**夏炳森

0 引言

随着分布式能源、电动汽车及储能等新兴能源形态的迅速发展，电力系统正逐步向源、网、荷、储等多种要素之间互连互通、供需平衡的能源互联网方向演进[1]。数字电网、5G及边缘计算等技术的不断进步，超低时延业务的部署以及网络质量保证面临着日益复杂的应用场景需求，差动保护、远程运维、自动巡检等电力业务在不同的网络环境下，对单向时延具有极高的要求[2]。传统的虚拟局域网(Virtual Local Area Network, VLAN)和基于优先级的技术可以在一定程度上保障时延和丢包率，但这些技术仅在关键数据流占网络容量的比例较小、网络系统运行正常且没有终端中断的情况下才能发挥良好效果。在实际应用中，这些条件往往难以长期维持。

确定性网络(Deterministic Networking, DetNet)在最糟糕的网络条件下也能保证关键数据的网络服务质量，是5G的关键技术之一[3]。确定性网络严格限定了五个服务质量(Quality of Service, QoS)指标：延迟(确定上限)、抖动(确定上限)、丢包率(确定上限)、可靠性(确定下限)和带宽(确定下限)。通过时间敏感网络、灵活以太网、确定性IP等确定性网络技术，可以确保这些指标在传输过程中始终保持在规定范围内，从而实现网络服务从传统的尽力而为向准时、准确、快速的转变[4]。信息年龄(Age of Information, AoI)是一种用于表征5G电力虚拟专网中时间敏感业务数据的信息新鲜度的指标[5]。当新的数据包被接收时，AoI指标会下降以反映自数据包生成以来经过的时间，然后逐渐增加，直到下一次数据包的交付。5G电力虚拟专网中确定性业务传输质量受到数据包丢失、服务节点资源限制的影响，信息的时效性对于系统决策的准确性至关重要。同时，传输可靠性对业务传输质量也有重要的影响，是电力确定性业务传输不可忽视的因素。

网络切片作为5G确定性网络的关键技术，可以构建多个专用、虚拟化、互相隔离的逻辑网络，从而最大限度提升网络对外部环境、客户需求和业务场景的适应性，优化网络资源使用效率[6]。网络切片编排涉及切片的准备、开通、创建、修改和终止，并负责其完整生命周期的管理。为保证5G时延敏感性业务的通信，文献[7]提出应提供端到端(End to End, E2E)网络切片以确保服务质量。在动态流量条件下，管理具有不同业务需求的网络切片是一项具有挑战性的任务，人工智能可以根据流量模式、网络状况或用户需求，协助跨切片进行实时资源分配和优化[8]。

然而，现有研究仅考虑端到端的平均时延，并未考虑业务传输过程中数据的信息度和传输节点的可靠性。传统5G电力虚拟专网使用尽力而为的资源分配方式保障业务平均时延，难以满足确定性网络的需求。基于上述问题，本文首先建立包含网元映射过程的电力虚拟专用端到端网络切片虚拟网络功能(Virtual Network Function, VNF)部署系统模型，并在此基础上提出一种同时考虑AoI和可靠性的新型资源分配优化模型。其次，为解决优化问题，提出一种基于软性演员评论家的资源分配算法进行求解。

1 5G电力虚拟专网端到端切片模型

1.1 系统场景

5G电力虚拟专网端到端网络切片部署示意图如图1所示，不同业务类型的网络切片部署在接入网、传输网和核心网组成的底层物理网络上，切片之间相互连接、彼此协作。端到端确定性网络切片的架构主要包括物理感知层、5G电力专网切片层和应用服务层以及各层之间的接口。物理感知层包括电力业务终端、基站、传输设备(如路由器、交换机)和服务器，是5G电力虚拟专网切片实现确定性传输的重要基础保障等；5G电力专网切片层负责对物理网络节点和链路虚拟映射，并进行网络资源调度和管理；应用服务层包括切片业务管理和控制等多类应用。

将每个切片服务实例建模为一组虚拟网络功能和所需的网络资源，在资源限制条件下将所需的资源分配给切片请求。物理感知层中，底层物理网络的节点资源包括接入网节点、传输网节点、核心网节点。在本研究中，底层物理网络和映射后的虚拟网络横跨接入网域和核心网域，在网络切片请求部署时，每一个节点都与底层物理网络上的节点一一对应，每一条链路与连接节点位置的物理链路相对应[9]。每个节点都具有计算资源值属性，每条通信链路都具有带宽资源值属性。将5G电力虚拟专网中物理基础设施表示为无向图$G=(G_N, G_L)$，其中

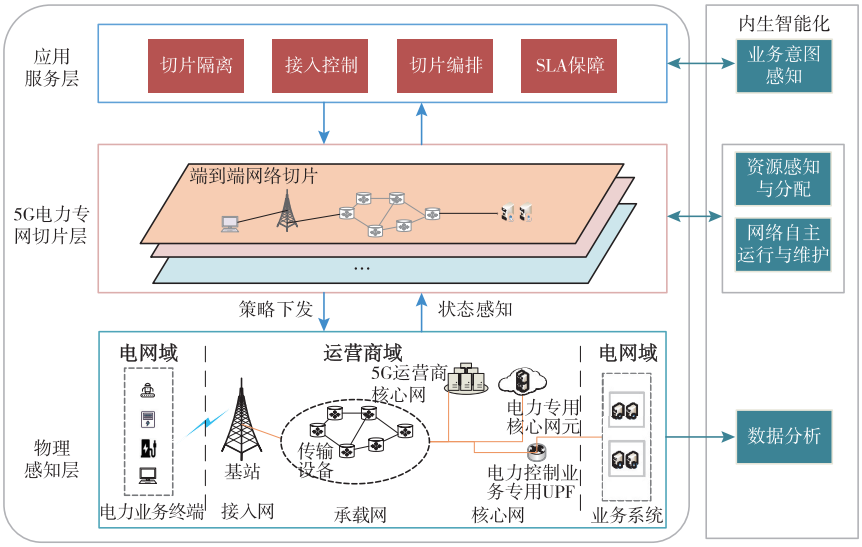


图 1　5G 电力虚拟专网端到端网络切片架构

$G_N=\{1,2,\cdots,n,\cdots,N\}$ 表示节点集合，$G_L=\{1,2,\cdots,l,\cdots,L\}$ 表示链路集合。网络切片中的虚拟无向图可以表示为 $\hat{G}=(G_{\hat{N}},G_{\hat{L}})$，其中 $G_{\hat{N}}$ 表示虚拟切片网络的节点集合，$G_{\hat{L}}$ 表示虚拟切片网络的链路集合。节点上的计算资源集合 $C=\{C_1,C_2,\cdots,C_n,\cdots,C_N\}$，物理节点间通过有线链路链接，链路上的带宽资源 $B=\{B_1,B_2,\cdots B_l,\cdots B_L\}$。

1.2　无线接入网模型

接入网由 k 个不同的蜂窝小区构成，记为集合 $K=\{1,2,\cdots,k\}$，每个小区由一个位于小区中心的基站和 m 个随机分布的电力业务终端构成，电力终端业务集合为 $M=\{1,2,\cdots,m\}$。业务终端 m 是否与基站 k 相连用二元变量 $x_{m,k}$ 表示，当 $x_{m,k}=1$ 时，业务终端 m 接入小区 k。假设每个业务终端 m 在某一时刻只能请求一个业务，则终端 m 只能与一个基站相连：

$$\sum_{k=1}^{K}x_{m,k}=1 \tag{1}$$

在接入网中，总带宽 B Hz 分为一组物理资源块（Physical Resource Block，PRB），时隙 t 内小区各资源块 $R_{\mathrm{RB}}=\{1,2,\cdots,r\}$ 仅能调度给一个电力业务终端 m，用二元变量 $x^m_{\mathrm{RB},r}$ 表示。当 $x^m_{\mathrm{RB},r}=1$ 时，电力业务终端 m 使用小区内部频谱资源块 r，业务 m 所需的 RB 资源数量为 $\omega_m=\sum_{r=1}^{R_{\mathrm{RB}}}x^m_{\mathrm{RB},r}$。基站 k 上所有业务分配的 RB 资源不能超过时频资源的最大 RB 限制：

$$\sum_{m=1}^{M}\omega_m\leqslant R_{\mathrm{RB,max}} \tag{2}$$

时隙 t 内电力业务 m 在基站 k 处的上传数据速率表示为：

$$r_{m,k}(t)=x_{m,k}\frac{\omega_m}{R_{\mathrm{RB,max}}}\log_2\left(1+\frac{pgd^{-\omega}_{m,k}}{\sigma^2+\sum\limits_{\substack{m'\in M,\\ m'\neq m}}\sum\limits_{\substack{k'\in K,\\ k'\neq k}}pgd^{-\omega}_{m',k'}}\right) \tag{3}$$

式中，p 表示发射功率，g 表示信道增益，$d^{-\omega}_{m,k}$ 表示电力终端 m 到基站 k 的路径损耗，ω 表示路径损耗系数，σ^2 表示加性高斯白噪声功率。

为保证业务的 QoS，上行数据速率应满足切片最小上行传输数据速率：

$$\sum_{k=1}^{K}x_{m,k}r_{m,k}(t)\geqslant r^{\min}_m \tag{4}$$

式中，$r^{\min}_m$ 表示业务 m 所需的最小上行传输数据速率。

1.3　核心网模型

定义二元变量 $y^u_{m,i}\in\{0,1\}$ 表示用于传输业务 m 的底层服务节点 i 是否映射到虚拟节点 u，若是，则 $y^u_{m,i}=1$，否则 $y^u_{m,i}=0$。二元变量 $y^{u,v}_{i,j}\in\{0,1\}$ 表示物理链路 (i,j) 是否映射到虚拟链路 (u,v)，若是，则 $y^{u,v}_{i,j}=1$，否则 $y^{u,v}_{i,j}=0$。每个节点上的总可用计算资源为 $C_{\max}$，虚拟节点 u 上满足计算资源约束 $\sum_{m=1}^{M}y^u_{m,i}C_{m,u}(t)\leqslant C_{\max}$。每条链路上的最大可用带宽资源为 $B_{\max}$，满足链路带宽资源约束 $\sum_{m=1}^{M}y^{u,v}_{i,j}B_{m,(u,v)}(t)\leqslant B_{\max}$。不同类型的电力业务对 QoS 指标有不同的要求，确定性传输需要确保网络切片的总延迟在给定范围内，本文考虑时延、吞

吐量、时效性和可靠性等确定性指标，根据网络资源情况动态调整资源分配方案以满足业务需求。

（1）可靠性模型

可靠性对于持续的服务至关重要，也是确保整个网络确定性的关键。受到软件和硬件的损坏或是外界环境的影响，服务节点可能会出现硬件或软件故障，导致电网业务传输任务失败[10]。因此，本文考虑业务数据传输的可靠性问题。软件可靠性被定义为VNF成功完成其预期服务处理的概率，其取决于VNF的复杂性、配置错误和软件错误，每个VNF节点u正常工作的概率为$p_{\text{soft},u}\in(0,1)$。硬件可靠性与承载VNF的物理节点的设备质量有关，每个物理节点i正常工作的概率为$p_{\text{phy},i}\in(0,1)$。电力业务m通过一系列VNF连接的虚拟链路传输数据，分别定义每个业务传输数据发生故障与服务器节点发生故障的故障概率，业务m的可靠性可以计算为该链路中多个节点可靠性的乘积：

$$R_m(t)=\prod_{u\in G_N^m} p_{\text{phy},i}\cdot p_{\text{soft},u}^{y_{m,i}^u} \tag{5}$$

（2）时延模型

5G电力虚拟专网的端到端时延是指业务请求从终端发送到服务端进行处理所用的时延。对于端到端的网络切片请求，用户的时延包括接入网时延和核心网时延，即$d(t)=d_{m,k}^{\text{RAN}}(t)+d_m^{\text{CN}}(t)$。电力设备终端$m$到基站$k$的时延为接入网时延，表示为$d_{m,k}^{\text{RAN}}(t)=x_{m,k}D_m/r_{m,k}$，其中$D_m$表示数据包大小。核心网时延主要由计算时延和链路时延构成，计算时延是指业务数据从处理节点接收并进行计算到转发到链路上的时间，链路时延是指数据在链路上传输花费的时间，将核心网时延表示为$d_m^{\text{CN}}(t)=\sum_{n\in G_N^m} f(D_m)/C_{m,n}(t)+\sum_{l\in G_L^m} d_{m,l}/B_{m,l}(t)$。其中，$G_N^m$表示传输业务$m$的节点集合，$G_L^m$表示对应的链路集合，$f(D_m)$表示传输数据大小为$D_m$所需的计算资源量，$C_{m,n}(t)$表示节点$n$上传输业务$m$分配的计算资源量，$d_{m,l}$表示链路$l$的距离，$B_{m,l}(t)$表示链路$l$分配的带宽资源量。

（3）AoI模型

AoI作为衡量网络QoS的一个关键指标，可以优化网络资源的分配，提升整体服务质量。对于某个信息系统，AoI的值越小表示信息越新，传输越及时；反之，AoI的值越大，则意味着信息越旧，时效性越差。为了对电力确定性业务的传输进行评估，采用AoI衡量信息新鲜度，定义确定性业务的实际AoI为：

$$a_m(t+1)=\begin{cases} d(t), & \text{if}\ \varphi(t)=1 \\ a_m(t)+a_0, & \text{其他} \end{cases} \tag{6}$$

式中，二元变量$\varphi(t)$表示电力虚拟专网设备是否在时隙t内成功传输数据，若是，则$\varphi(t)=1$，否则，$\varphi(t)=0$；$d(t)$表示电力虚拟专网设备时隙t内传输数据的端到端时延，如果电力虚拟专网设备在时隙t期间成功接收数据，则AoI重置为$d(t)$，否则AoI增加a_0。电力确定性业务m的平均AoI表示为：

$$a(t)=\lim_{t\to\infty}\frac{1}{T}\sum_{t=0}^{T-1}a_m(t) \tag{7}$$

每个端到端网络切片考虑时延D、吞吐量r、时效性A和可靠性R四个关键指标。切片资源调度基于性能指标与资源的映射关系进行指导[11]，定义传输延迟的特征函数：

$$f_D(t)=\begin{cases} 0, d(t)/D>1 \\ 1, d(t)/D\leqslant 1 \end{cases} \tag{8}$$

式中，$d(t)$表示确定性业务的实际端到端时延，令M_t表示时隙t中的业务总数，将业务在时间t内的端到端时延评估函数定义为：

$$E_D(t)=\frac{1}{M_t}\sum_{m=1}^{M_t} f_D(t) \tag{9}$$

业务传输吞吐量指标的特征函数定义为：

$$f_T(t)=\begin{cases} 0, r(t)/r_m^{\min}<1 \\ 1, r(t)/r_m^{\min}\geqslant 1 \end{cases} \tag{10}$$

式中，$r(t)$表示确定性服务的实际吞吐量，时隙t服务的传输吞吐量评估函数定义为：

$$E_T(t)=\frac{1}{M_t}\sum_{m=1}^{M_t} f_T(t) \tag{11}$$

对于5G电力虚拟专网中控制指令数量较多、信息时效性要求较高的业务，AoI指数不允许超过规定阈值，否则，控制指令的延迟会造成不可预知的后果。因此，对于确定性业务处理，当信息年龄值大于服务要求值时，服务的网络传输视为无效传输。业务信息年龄指标评估函数为：

$$f_A(t)=\begin{cases} 0, a(t)/A_m>1 \\ 1, a(t)/A_m\leqslant 1 \end{cases} \tag{12}$$

式中，$a(t)$表示确定性服务的时效性，定义信息年龄评估函数来描述确定性业务对传输的满意度：

$$E_A(t)=\frac{1}{M_t}\sum_{m=1}^{M_t} f_A(t) \tag{13}$$

业务传输可靠性指标的特征函数定义为：

$$f_R(t)=\begin{cases}0, R(t)/R\geqslant 1\\ 1, R(t)/R<1\end{cases} \tag{14}$$

式中，$R(t)$表示确定性业务的可靠性，定义可靠性评估函数为：

$$E_R(t)=\frac{1}{M_t}\sum_{m=1}^{M_t} f_R(t) \tag{15}$$

业务满意度中各元素的取值范围为$\{E_D(t), E_T(t), E_A(t), E_R(t)\}\in[0,1]$，越接近1，业务满意度越高。基于上述分析，为衡量系统的QoS，利用性能评价函数Q_m表示网络在给定的传输周期内按照特定的确定性业务指标完成传输的评估指标。Q_m表示单个网络切片m的性能：

$$Q_m=\beta_1 E_D(t)+\beta_2 E_T(t)+\beta_3 E_A(t)+\beta_4 E_R(t) \tag{16}$$

1.4　优化问题表述

根据Q_m确定确定性业务的传输状态，并指导链路资源调度。本文优化目标为最大化网络切片的性能评价函数，因此，优化模型为：

$$\begin{aligned}&\max_{\omega_m, C_m, B_m}\ \bar{Q}=\frac{1}{T}\sum_{t=1}^{T}Q_m\\ &\text{s.t.}C1:\sum_{k=1}^{K}x_{m,k}=1\\ &\quad C2:\sum_{m=1}^{M}\omega_m\leqslant R_{\mathrm{RB,max}}\\ &\quad C3:\sum_{k=1}^{K}x_{m,k}r_{m,k}(t)\geqslant r_m^{\min}\\ &\quad C4:\sum_{m=1}^{M}y_{m,i}^{u}C_{m,u}(t)\leqslant C_{\max}\\ &\quad C5:\sum_{m=1}^{M}y_{i,j}^{u,v}B_{m,(u,v)}(t)\leqslant B_{\max}\\ &\quad C6:\beta_1+\beta_2+\beta_3+\beta_4=1\end{aligned} \tag{17}$$

2　问题求解

2.1　MDP模型

由于优化问题是一个NP难和非凸问题，启发式算法难以有效解决，深度强化学习通过结合深度学习和强化学习，不断与环境进行试探性交互，旨在通过最大化累积回报来找到最优策略[12]。因此，本文考虑采用深度强化学习算法对上述优化问题进行近似和迭代求解。首先，将优化目标转换为马尔科夫决策过程（Markov Decision Processes，MDP）模型，MDP由五元组$<S, A, P, R, \gamma>$组成，其中S表示有限的状态集合，A表示有限的动作集合，P为状态转移矩阵，R为奖励函数，γ表示折扣因子[13]。

端到端网络切片控制器作为智能体观测当前的状态，在时隙t观测到的状态集合为：

$$S(t)=\{\omega_s(t), C_s(t), B_s(t), s(t)\} \tag{18}$$

式中，$\omega_s(t)$表示基站在t时刻观测到的可用RB资源，$C_s(t), B_s(t)$分别是时隙t节点剩余计算资源和链路剩余带宽资源；$s(t)=\{D, A, r_m^{\min}, R\}$决定业务的最大时延要求、最大数据新鲜度要求、最低速率和最低可靠性要求。

切片控制器根据观测到的状态选择动作，动作集合为：

$$A(t)=\{\omega(t), C(t), B(t)\} \tag{19}$$

式中，$\omega(t), C(t), B(t)$分别表示节点和链路为各业务分配的RB资源、计算资源、带宽资源。

智能体切片控制器的最终目标是在时隙系统的约束条件下实现性能评价函数的最大化。在采取资源分配动作后，智能体可以立即获得奖励。通过设计奖励机制，可以使智能体不断改进策略，以实现性能评价函数的最大化。将奖励定义为：

$$R=\begin{cases}\bar{Q}, & \text{满足约束条件}\\ \text{惩罚}, & \text{其他}\end{cases} \tag{20}$$

其中，惩罚项为负常数，如果采取的动作不满足约束条件，则在奖励中进行惩罚。

2.2　基于SAC的确定性业务资源分配算法

基于5G电力虚拟专网端到端的确定性网络服务切片架构，本研究提出一种基于柔性演员-评论家（Soft Actor-Critic，SAC）的确定性业务资源分配算法，如图2所示。

SAC算法是基于连续动作空间且面向最大熵RL框架的离线策略算法，该方法的最优策略是最大化熵正则化奖励，使得算法更加稳定[14]。SAC算法目标函数除了学习策略使累计奖励的期望最大，还要求每次策略输出的动作熵最大：

$$J(\pi)=\sum_{t=0}^{T}E_{(s_t,a_t)\sim\rho_\pi}\left\{r(s_t,a_t)+\alpha H\left[\pi(\cdot|s_t)\right]\right\} \tag{21}$$

为自动更新温度系数α，优化的损失函数为：

$$J(\lambda)=E_{a_t\sim\pi_t}\left[-\alpha\log\pi_t(a_t|\pi_t)-\alpha H_0\right] \tag{22}$$

该算法的值函数与策略各通过一个由参数控制的神经网络拟合，根据最小化KL散度更新actor网络，使用两个Q网络并且每次选择Q值较小的作为目标Q值来保证训练的快速稳定，通过最小化贝尔曼误

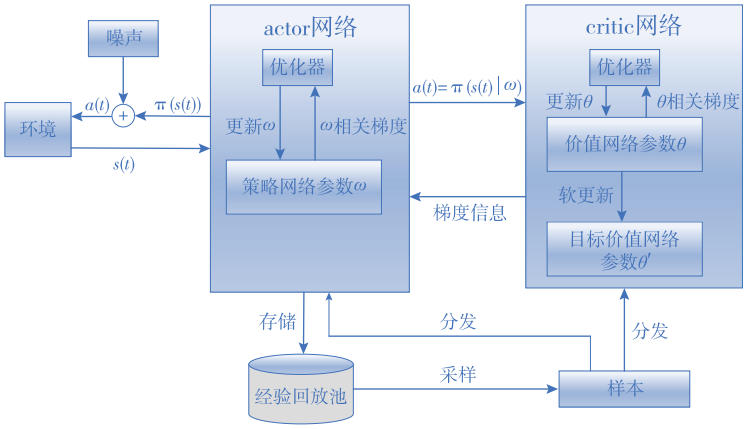


图2 基于SAC的确定性业务资源分配算法

差对critic网络更新。5G电力虚拟专网中基于SAC的确定性业务资源分配算法的具体流程如表1所示。

表1 端到端切片控制器确定性业务资源分配算法

输入：环境
输出：训练好的切片控制器SAC网络
1 初始化：经验回放池D，切片控制器SAC主网络和目标网络参数；
2 for 回合 = 1, 2, …, M, do；
3 初始化环境并获得观测状态s_0；
4 for 时间步 = 1, 2, …, T, do；
5 切片控制器通过ε−贪心策略选择动作a_t；
6 切片控制器执行切片动作a_t，获得奖励r_t并进入下一个状态s_{t+1}，同时切片控制器将该分配动作结果下发给用户终端所处的多智能体环境；
7 将经验(s_t, a_t, r_t, s_{t+1})存入经验回放池D；
8 从经验回放池随机采样小批量经验样本；
9 计算时间差分目标：

$$y_j = r_j + \gamma \max_{a} Q(s_{j+1}, a, \theta')$$

10 使用梯度下降法最小化损失函数，进而更新SAC主网络参数θ；
11 将SAC主网络参数θ复制给目标网络参数θ'。
12 end for
13 end for

3 仿真结果与分析

本节将通过Python 3.10和Pytorch平台进行仿真验证，评估网络切片在不同网络场景下的性能。相关仿真参数具体设置如表2所示。在仿真环境中，将所提算法与DDPG和DQN算法进行比较，评估所提方案在延迟、时效性等指标约束下切片性能的变化。

不同算法的奖励如图3所示，可以看出，在初始阶段，算法的奖励值在迭代过程中迅速增长，并在较短时间内趋于稳定。所提算法的最终收敛值高于基线算法，说明本算法在相同资源分配情况下，能够获得较高的奖励值，表现优于其他算法。这是由于所提算法引入了熵正则化策略，在最大化奖励的同时也增加了决策的探索性，鼓励算法在训练初期进行更广泛的探索。这种设计使算法可以避免过早陷入局部最优解，从而在迭代过程中获得更高的奖励值。

表2 仿真参数设置

仿真参数	取值
业务数量	6
节点数量	12
链路数量	15
业务最大时延限制	200 ms
物理节点CPU资源容量	100 GHz
物理链路带宽资源	10 Gbps
噪声功率谱密度	−174 dBm/Hz
子载波带宽	180 kHz
路径损耗系数	3
折扣因子	0.9
噪声类型	OU噪声
演员和评论家学习率	0.000 01/0.000 05

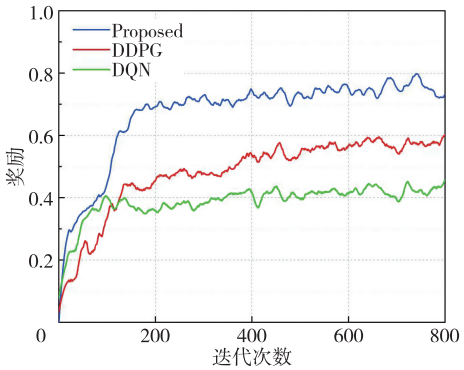


图3 算法奖励对比

图4所示为当电力切片任务数据大小变化时三种算法的端到端平均延迟。可以看出，所提算法的端到端平均时延小于其他算法，并且随着数据量的增加，时延增长的幅度相对较小。这表明所提算法在处理大数据量任务时，能够保持相对较低的时

延，即该算法在资源分配和调度上更为高效，能更好地应对高数据量的任务需求。DDPG 算法的时延随着任务数据量的增加逐渐上升，但相比所提算法，时延值整体较高，尤其是在任务数据量较大的情况下，其增长趋势更加明显，表明该算法的资源分配效率相对较低。DQN 算法的端到端时延在所有数据量范围内均为最高，且随着任务数据的增加，时延迅速上升，表明 DQN 在处理大任务数据时性能较差，无法有效控制时延。

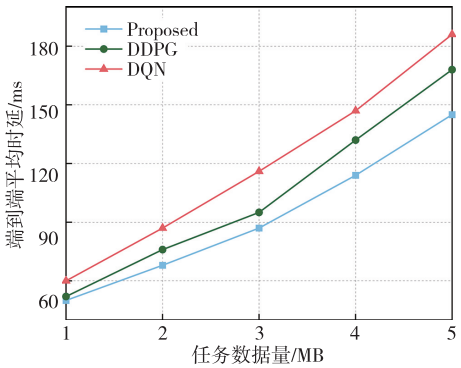


图 4　任务数据大小变化端到端平均延迟对比

图 5 展示了在不同算法中，不同切片类型与平均 AoI 的关系。根据用户的业务需求将切片划分为切片 1 和切片 2，其中划分到切片 1 的用户对于速率有更高的需求。可以看出，在所提算法中，切片 1 和切片 2 的平均 AoI 都低于其他两种算法，表明本算法能够在更短的时间内更新信息，确保数据的新鲜度。在确定性网络传输中，所提算法具有较好的时效性和数据更新能力。DQN 算法的 AoI 值最高，说明在信息新鲜度上，该算法的处理能力有限，时效性最差。

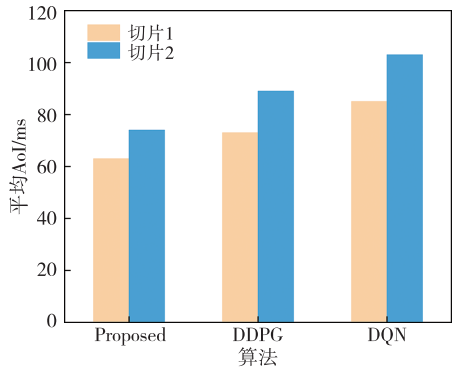


图 5　不同切片的平均 AoI 对比

图 6 展示了不同数据速率下三种算法的业务满意度对比。所提算法在所有数据速率下的业务满意度均高于其他算法，且接近 0.8，说明本算法能够有效满足业务需求，即使在不同的数据速率下都能保持较高的满意度。随着业务上行传输数据速率的增加，业务满意度相应增加。这是因为在数据速率较低时，系统资源尚未被完全利用，网络的带宽和计算资源能够有效处理更大的数据量，业务的吞吐量增加，满意度也随之提升。

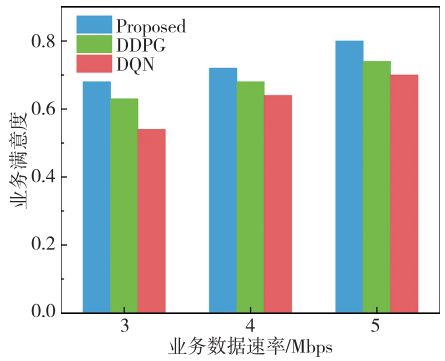


图 6　不同数据速率下的业务满意度

图 7 展示了不同业务请求数量下的业务满意度，随着业务请求数量的增加，业务满意度逐渐下降。这是由于处理较多业务请求时的资源分配效率有所下降，业务需求不能完全满足。尽管所提算法的业务满意度呈现出逐渐下降的趋势，但与基线算法相比，整体下降幅度较小，表现出较强的稳定性。这是因为所提算法使用双 Q 网络来估算值函数，从而减少了训练过程中因过高估计 Q 值所带来的不稳定性。因此，在面对业务请求数量不断增加的情况下，SAC 能够保持收敛的稳定性，减少波动，使得业务满意度的下降幅度较小。

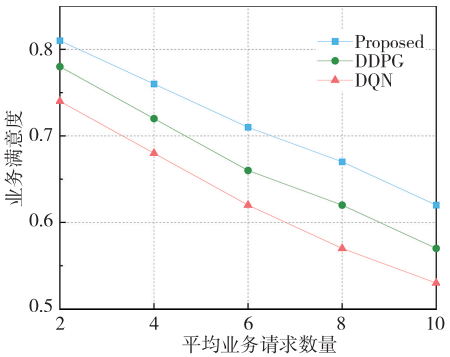


图 7　不同业务请求数量下的业务满意度

图 8 展示了不同计算资源下的业务满意度，随着计算资源的增加，各算法的业务满意度逐步提升。在所有计算资源情况下，DQN 算法的业务满意度的增长幅度和整体水平最低，表明其在资源利用和业务需求满足方面较弱。DDPG 算法同样随着计算资源的增加，业务满意度稳步提升，但与所提算法相比，业务

满意度整体水平稍低。所提算法在不同计算资源下表现出更高的业务满意度,这得益于其更高效的资源调度和优化机制,能够更有效地分配和利用计算资源,从而在资源充足的情况下提升业务满意度。

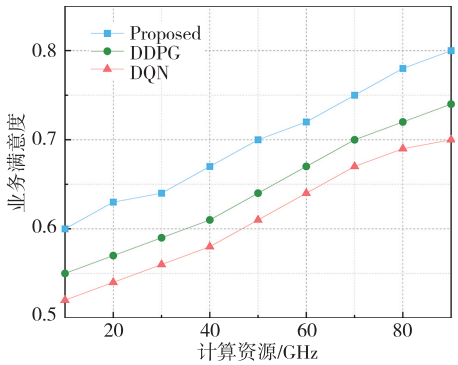


图8 不同计算资源的业务满意度

4 结论

面向5G电力确定性网络发展趋势,本文研究了5G电力虚拟专网的端到端确定性切片编排策略。首先基于网络切片技术建立端到端的切片模型,根据电力确定性业务的特征,将业务传输映射到网络资源需求,建立包含可靠性和时效性的切片性能满意度模型。为了最大化切片满意度,设计并提出了一种基于SAC的确定性业务资源分配算法来动态调整确定性切片编排策略,以满足不同业务的需求。仿真结果表明,所提出的算法在时延、AoI等关键性能指标上均优于基线算法。

参 考 文 献:

[1] 张桂玉, 马 睿, 白露莹, 等. 确定性网络相关技术及其在电力行业的应用研究[J]. 邮电设计技术, 2023(9): 15-20.
Zhang Guiyu, Ma Rui, Bai Luying, et al. Research on deterministic network related technology and its application in power industry[J]. Designing Techniques of Posts and Telecommunications, 2023(9): 15-20.

[2] Lv Y, Xiang H, Chen J, et al. Research on deterministic service quality guarantee for 5G network slice in power grid[C]//2023 IEEE 6th Information Technology, Networking, Electronic and Automation Control Conference, 2023: 820-823.

[3] 朱仕银, 杨 坚, 孔 磊. 5G确定性网络关键技术研究和应用[J]. 电信科学, 2024, 40(8): 172-182.
Zhu Shiyin, Yang Jian, Kong Lei. 5G deterministic network key technology research and application[J]. Telecommunications Science, 2024, 40(8): 172-182.

[4] Sharma G P, Patel D, Sachs J, et al. Toward deterministic communications in 6G networks: state of the art, open challenges and the way forward[J]. IEEE Access, 2023, 11: 106898-106923.

[5] Abedin S F, Mahmood A, Tran N H, et al. Elastic O-RAN slicing for industrial monitoring and control: a distributed matching game and deep reinforcement learning approach[J]. IEEE Transactions on Vehicular Technology, 2022, 71(10): 10808-10822.

[6] Han B, Wu J, Shu X, et al. Slice deployment method for deterministic latency broadband services for virtual power plant[C]//2022 IEEE International Symposium on Broadband Multimedia Systems and Broadcasting, 2022: 1-4.

[7] Bai H, Zhang Y, Zhang Z, et al. Latency equalization policy of end-to-end network slicing based on reinforcement learning[J]. IEEE Transactions on Network and Service Management, 2023, 20(1): 88-103.

[8] Gharehgoli A, Nouruzi A, Mokari N, et al. AI-based resource allocation in end-to-end network slicing under demand and CSI uncertainties[J]. IEEE Transactions on Network and Service Management, 2023, 20(3): 3630-3651.

[9] Fan W, Li J, Zhang M. ESRDO: an efficient E2E SFC resource dynamic orchestration framework and approach[C]//2024 IEEE Wireless Communications and Networking Conference, 2024: 1-6.

[10] Wang Y, Zhang L, Yu P, et al. Reliability-oriented and resource-efficient service function chain construction and backup[J]. IEEE Transactions on Network and Service Management, 2021, 18(1): 240-257.

[11] Kong X, Yang L, Huang Q, et al. A dynamic integrated network slicing strategy for future networks[C]//2022 4th International Conference on Advances in Computer Technology, Information Science and Communications, 2022: 1-7.

[12] Fu X, Yu F R, Wang J, et al. Dynamic service function chain embedding for NFV-enabled IoT: a deep reinforcement learning approach[J]. IEEE Transactions on Wireless Communications, 2020, 19(1): 507-519.

[13] 董 豪, 丁子涵, 仇尚航, 等. 深度强化学习——基础、研究与应用[M]. 北京: 电子工业出版社, 2021.
Dong Hao, Ding Zihan, Zhang Shanghang, et al. Deep Reinforcement Learning[M]. Beijing: Publishing House of Electronics Industry, 2021.

[14] Haarnoja T, Zhou A, Abbeel P, et al. Soft actor-critic: off-policy maximum entropy deep reinforcement learning with a stochastic actor[J]. ArXiv e-Prints, 2018: arXiv: 1801.01290.

作者简介:

唐元春(1973—),男,正高级工程师,主要从事电力通信规划设计及电力物联网建设研究;

夏炳森(1981—),男,工程师,主要从事电力通信规划设计及电力物联网建设研究。