

车联网中视频语义驱动的资源分配算法

陈九九, 冯春燕, 郭彩丽, 杨洋, 孙启政, 朱美逸

(北京邮电大学北京先进信息网络实验室, 北京 100876)

摘 要: 针对车联网中视频语义理解等智能计算业务需求下传统资源分配方式不再适用的问题, 研究了视频语义驱动的资源分配算法。首先, 以目标检测任务为例, 提出视频语义驱动的资源分配指导模型并给出模型参数的求解算法; 其次, 构建了车联网场景中视频语义驱动的资源分配优化问题, 将该问题转化成凸问题并利用凸优化算法求解; 进一步, 为降低凸优化算法的复杂度, 提出了基于强化 Q 学习的资源分配算法; 最后, 仿真验证了所提资源分配算法的性能优势。

关键词: 资源分配; 车联网; 视频语义; 目标检测; 强化学习

中图分类号: TN929.5

文献标识码: A

DOI: 10.11959/j.issn.1000-436x.2021080

Video semantics-driven resource allocation algorithm in Internet of vehicles

CHEN Jiujiu, FENG Chunyan, GUO Caili, YANG Yang, SUN Qizheng, ZHU Meiyi

Beijing Laboratory of Advanced Information Networks, Beijing University of Posts and Telecommunications, Beijing 100876, China

Abstract: Aiming at the problem that traditional resource allocation methods will no longer be applicable, with the demand of intelligent computing services such as video semantic understanding in Internet of vehicles, the video semantic driven resource allocation algorithm was studied. First of all, taking the object detection task as an example, a semantic driven resource allocation guidance model for video was proposed and an algorithm for solving model parameters was given. Secondly, an optimization problem of resource allocation driven by video semantics in Internet of vehicles was constructed, which was transformed into a convex problem and solved by convex optimization algorithm. Furthermore, in order to reduce the complexity of the convex optimization algorithm, a resource allocation algorithm based on reinforcement Q learning was proposed. Finally, the performance advantages of the proposed algorithm are verified by simulations.

Keywords: resources allocation, Internet of vehicles, video semantics, object detection, reinforcement learning

1 引言

当前, 在车联网场景中, 车辆端通常配备或部署多个高清摄像头, 据数据统计, 90%以上的行车环境信息可以通过摄像头采集和获取^[1]。同时, 计

算机视觉技术采用智能算法, 以深度学习为代表的人工智能技术对摄像头采集到的大量视频数据的语义进行充分理解和分析, 从而完成自动驾驶中安全类、信息类、交通效率类等各种业务的智能决策处理^[2]。这些基于视频语义理解的大量任务, 比如

收稿日期: 2020-11-03; 修回日期: 2021-02-01

基金项目: 中央高校基本科研业务费专项资金资助项目 (No.2021XD-A01-1); 国家自然科学基金重大研究计划重点资助项目 (No.92067202); 北京市自然科学基金资助项目 (No.4202049); 北京邮电大学 (济南) 工业互联网研究院项目 (No.201915001)

Foundation Items: The Fundamental Research Funds for the Central Universities (No.2021XD-A01-1), The Key Program of National Natural Science Foundation of China (No.92067202), The Beijing Natural Science Foundation (No.4202049), The Industrial Internet Research Institute (Jinan) of Beijing University of Posts and Telecommunications (No.201915001)

目标检测等,对车辆端的计算能力带来极大挑战,目前的解决方案是车辆仅对视频做一些简单计算后借助车联网将视频语义理解任务卸载到计算资源丰富的移动边缘计算服务器(通常部署在路边单元侧)进行协同计算^[3],以支持车联网中辅助驾驶等多种不同业务的需求。

车辆端到边缘服务器端的大量计算任务卸载需求,给车辆端到边缘服务器端的通信资源带来了巨大的压力,亟须研究高效的资源分配方式来提高车联网中的资源利用率,更好地服务于视频语义理解任务,促进车联网系统中通信传输与智能计算过程的融合。

车联网中传统的资源分配方式主要分为两类:基于服务质量(QoS, quality of service)的资源分配方法^[4-5]和基于用户体验质量(QoE, quality of experience)的资源分配方法^[6-7]。基于QoS的资源分配方法主要通过合理地分配带宽、功率、时延等通信资源,以优化网络的吞吐量、传输速率、时延、抖动等网络效率指标,面向的主体是通信系统的物理层或网络层;基于QoE的资源分配方法主要是通过分配通信资源以提升传输视频的流畅度、清晰度、用户满意度等指标,满足接收用户的各种主观需求。

传统的资源分配方法面向的主体是传输网络或人类用户,不考虑所传输的视频内容或语义信息。当视频传输的接收端是作为机器的智能体,传输后的视频用于目标检测等语义理解任务时,它追求的目标不再是网络效率或者用户体验,而是视频理解或分析的准确率,因此传统的QoS或QoE资源分配方法不再是最优的,有必要针对视频语义研究更高效的资源分配方法^[8]。

文献[8]提出了视频内容质量(QoC, quality of content)的概念,以最大化平均目标检测精度为目标,给出了视频编码资源分配方案。但文献[8]没有给出具体的视频内容质量量化模型,未从视频语义角度出发考虑不同视频的语义差异,且未考虑车联网非稳态信道条件下的资源分配。

视频传输的接收端是作为机器的智能体,它追求的目标是接收端在资源受限、视频有损传输的条件下最多最准确地理解视频语义。以目标检测为例,视频语义是指待检测的目标类别(如行人、汽车、信号灯)、目标数量、目标位置等。从视频语义理解任务出发,通过视频语义区分不同视频并合

理地分配通信资源,使接收端最大程度地理解视频语义,本文称之为视频语义驱动的资源分配指导方式。基于以上分析,应对视频语义理解需求和车联网中通信资源紧缺的挑战,根源在于如何设计合理的资源分配指导模型和资源分配优化方法,本文主要工作如下。

1) 以目标检测任务为例,提出了语义驱动的资源分配指导模型,并给出了基于回归分析的模型参数求解算法。

2) 基于资源分配指导模型,构建了车联网场景中视频语义驱动的资源分配优化问题,将该问题转化为凸问题并利用凸优化算法求解。

3) 为降低凸优化算法的求解复杂度,提出了基于强化Q学习的资源分配算法。

2 系统模型及资源分配指导模型

2.1 车联网系统模型

车联网场景下,边缘服务器负责分配通信资源以及完成视频语义理解任务,车辆端负责视频预处理的任務,如视频压缩等。一个典型的车联网边缘计算场景下的视频传输系统模型如图1所示。




图1 车联网边缘计算场景视频传输系统模型

该系统由多辆装有摄像头的智能网联车辆和边缘服务器组成,车辆行驶在边缘服务器的覆盖区域。车辆通过摄像头感知周围环境,感知内容包括交通场景(如交通信号)以及运动物体(如行人和其他车辆),这些车辆视频感知到的环境信息构成了视频语义信息。车辆行驶过程中通过摄像头采集到大量待分析的视频供车辆做出辅助行驶决策,如车辆转向、减速、变道等。考虑到采集视频的数据量极大以及车辆的计算能力有限,视频数据通过无线信道传输至边缘服务器完成视频语义的理解和分析,因此需要在资源受限的情况下最大限度地准确理解视频语义。

假设系统完成一次视频传输的总时长为 T ，本文定义一次视频传输过程为车辆发起一个视频传输请求到传输停止。整个系统的通信和计算过程如下。

步骤 1 车辆发起视频传输请求，对所采集的视频进行预处理，获取视频信息并将其上传到边缘服务器，同时边缘服务器获取信道状态信息 (CSI, channel state information) [9-10]。该部分处理时间为 t_1 。

步骤 2 边缘服务器获取全部信息 (包括所有视频信息和 CSI)，根据视频语义驱动的资源分配算法得到最优资源分配结果。该过程处理时间为 t_2 。因此，在视频传输之前，总的处理时间为 $\Delta t = t_1 + t_2$ 。

步骤 3 车辆根据资源分配的结果完成视频的编码压缩，通过无线信道传输到边缘服务器，该过程遵循无线视频传输协议 [11]。

步骤 4 边缘服务器将接收到的视频进行解码，对视频进行语义理解并将结果反馈给各车辆端，同时边缘服务器可将视频存储或用于其他任务，如道路交通情况分析等 [12]。

2.2 研究问题描述和定义

根据 2.1 节所述的系统模型，本文研究的关键是系统通信计算的步骤 2，即如何构建视频语义驱动的资源分配优化问题，并设计相应算法求取最优资源分配解。在本文所提的系统模型中，视频传输的接收端边缘服务器是智能体，它追求的目标是最准确地理解视频语义，因此资源分配的最优化目标为使用最少的通信资源代价尽可能获得最高的视频语义理解准确率。该资源优化问题可以形式化描述为

$$\begin{aligned} P1: \max_x F(x) \\ \text{s.t. } g(x) \leq x_{\max} \end{aligned} \quad (1)$$

其中， x 表示带宽资源； $F(x)$ 表示资源分配指导函数，即视频语义理解准确率； $g(x) \leq x_{\max}$ 表示资源限制条件， $g(x)$ 为约束函数； x_{\max} 为总资源最大值。

上述语义驱动的资源优化模型从理论上给出了资源分配算法的优化方向。在不同场景中，优化模型需要根据具体场景特点和视频语义理解任务类型。在实际的语义理解任务中，如车联网中应用极广泛的目标检测任务，视频语义包括待检测的目标类别、目标数量等，视频语义理解准确率即目标检测准确率。在目标检测任务中，各评价指标如下

$$\text{目标检测准确率} = \frac{\text{正确检测的样本数}}{\text{总样本数}} \quad (2)$$

$$\text{正确检测目标数} = \text{目标数} \times \text{检测准确率} \quad (3)$$

其中，目标检测准确率一般用来评估模型和算法的全局准确程度，正确检测目标数用来反映正确检测的数量程度。

2.3 视频语义驱动的资源分配指导模型

在实际的视频语义驱动的资源分配过程中，需要考虑具体的语义理解任务和通信资源限制带来的影响，研究如何引入视频语义理解准确率的评价指标来指导资源分配。本文以视频语义理解的基础任务、目标检测为例，阐述具体的视频语义理解准确率的建模方法，详细的建模过程如图 2 所示。

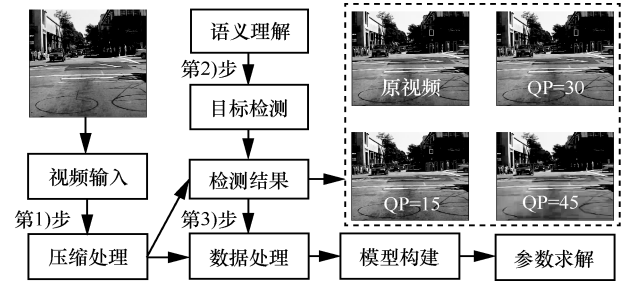


图 2 语义理解准确率建模过程

1) 考虑到视频传输受通信资源的限制，需要对视频进行处理。以带宽资源为例，由于视频传输的码率必须小于或等于带宽限制下的传输速率，因此需要对视频进行压缩处理以满足带宽资源约束条件。本文采用 HEVC (high efficiency video coding) 编码方案 [13] (即 H.265 视频编码压缩标准) 对视频数据进行压缩编码处理，压缩编码过程中不同的视频量化参数 (QP, quantitative parameter) 值对应不同压缩步长，QP 值越小压缩步长越小，视频码率越接近原始视频码率，传输所需的带宽越大。

2) 为探讨带宽限制下不同的压缩处理对视频语义理解准确率的影响，本文利用具有代表性的 Faster-RCNN (region convolutional neural network) 算法 [14] 对不同压缩程度的视频进行目标检测，目标类型主要包括行人、车辆和交通信号灯等。本文数据集来自交通场景目标检测应用最广泛和最新的 Caltech 数据集 [15] 和 Waymo 数据集 [16]。所选的 2 个数据集中，20% 的视频数据用于测试，80% 的视频数据用于训练。在不同 QP 值的压缩视频下统计目标检测的准确率，一些可视化的结果如图 2 所示。从图 2 可以看出，随着 QP 的增大，检测准确率有所下降。

3) 统计上述步骤中 QP 值对应的检测准确率的实验数据, 并根据数据结果选择适合的关系模型。指数关系模型为

$$P(q) = \alpha_1 (q)^{\alpha_2} + \alpha_3 \quad (4)$$

其中, q 表示视频量化参数 QP 值, P 表示检测精度, α 为模型参数。利用回归方法求解模型参数, 并引入均方误差 (MSE, mean square error) 作为损失函数。目标检测准确率与 QP 关系模型参数求解算法如算法 1 所示。

算法 1 目标检测准确率与 QP 关系模型参数求解算法

输入 N 个真实值数据样本 $(q^{(n)}, P^{(n)})$

输出 最优模型参数 $\alpha^* = (\alpha_1^*, \alpha_2^*, \alpha_3^*)$

1) 初始化模型参数: $\alpha = (\alpha_1, \alpha_2, \alpha_3)$

2) 构建损失函数: $L(\alpha) = \frac{1}{N} \sum_{n=1}^N (P(q^{(n)}) - P^{(n)})^2$

3) 令 $\frac{\partial L(\alpha)}{\partial \alpha} \rightarrow 0$, 求解 α^*

4) 利用梯度下降法迭代求解直至收敛

基于 Caltech 和 Waymo 数据集的实验, 目标检测准确率与 QP 关系模型如图 3 所示, 可以看出, 模型在不同类别的检测中均呈现较好的结果。根据算法 1 得到的目标检测准确率与 QP 关系模型最优参数如表 1 所示。




图 3 目标检测准确率与 QP 关系模型

不同 QP 值下视频的码率不同, 而码率的大小决定了传输过程中的带宽资源配置, 基于文献[8]的实验结果, 本文得到 QP 值与视频码率的关系模型为

$$q = \beta_1 \exp(\beta_2 R_m) \quad (5)$$

其中, R_m 为第 m 辆车所采集视频的码率, β_1, β_2 为模型参数。QP 值与视频码率的关系模型参数求解算法如算法 2 所示。

表 1 目标检测准确率与 QP 关系模型的最优参数

模型参数	视频语义检测类别		
	行人	车辆	交通灯
α_1	-2.214×10^{-12}	-3.82×10^{-13}	-8.405×10^{-8}
α_2	6.741	7.256	4.158
α_3	0.694	0.695 8	0.725
MSE	0.002 08	0.014 03	0.026 03

算法 2 QP 值与视频码率的关系模型参数求解算法

输入 M 段视频对应的 QP 值和视频码率值数据组 $(R_m, q^{(m)})$

输出 最优模型参数 $\beta^* = (\beta_1^*, \beta_2^*)$

1) 初始化模型参数: $\beta = (\beta_1, \beta_2)$

2) 计算 $L(\beta) = \frac{1}{M} \sum_{m=1}^M (q(R_m) - q^{(m)})^2$

3) 令 $\frac{\partial L(\beta)}{\partial \beta} \rightarrow 0$, 求解 β^*

4) 利用梯度下降法迭代求解直至收敛

采用 H.265 视频编码压缩标准, 通过车辆端采集的视频数据集, 基于算法 2 本文得到 QP 值与视频码率关系模型的最优参数结果如表 2 所示。在 H.265 标准下, 视频输出码率越大, 则视频 QP 值越小, 即视频被压缩的程度低, 因此 QP 值与视频码率呈负相关关系, 则在模型中 $\beta_2 < 0$ 是恒成立的。

表 2 QP 值与视频码率的关系模型的最优参数

模型参数	视频采集场景		
	目标密集	目标中等	目标稀疏
β_1	46.27	45.96	45.22
β_2	-7.086×10^{-5}	-8.648×10^{-5}	-1.052×10^{-4}
MSE	0.001 98	0.002 95	0.004 05

联合式(4)和式(5), 可得到检测准确率与码率的关系模型为

$$P(q) = \alpha_1 (\beta_1 \exp(\beta_2 R_m))^{\alpha_2} + \alpha_3 \quad (6)$$

码率的大小与传输过程中的带宽资源有关, 至此, 本文得到了面向视频语义理解准确率 (即目标检测任务中的检测准确率) 的带宽资源分配指导模型。

基于上述分析和研究可知，实际中针对视频语义理解任务，资源分配优化准则为视频语义理解准确率最大化，即资源分配的最优化目标为使用最少的通信资源代价尽可能获得最佳的视频语义的理解结果。上述目标检测准确率与码率的关系模型给出了语义驱动的资源分配算法的优化方向。

3 车联网场景下的资源分配优化问题

在车联网场景下，由于无线视频传输会消耗带宽，而整体带宽资源有限，因此设计一个高效的带宽分配算法很重要，以在带宽限制下，最大化正确理解的视频语义。

首先，传输视频的码率受到每辆车的传输速率限制，即 $R_m \leq R_m^T(t)$ 。考虑车联网场景下信道状态信息的时变特性，在时隙 t 时，每辆车的传输速率为

$$R_m^T(t) = B_m \text{lb} \left(1 + \frac{S_m h_m(t)}{\sigma_m^2} \right) \quad (7)$$

其中， B_m 是为每个车辆分配的带宽， S_m 、 h_m 和 σ_m^2 分别表示发射功率、信道增益和噪声功率。

为了简化分析，假设发送端可以获取接近完美的信道状态信息^[10]。将信道增益 h_m 建模为独立随机变量，既考虑了大尺度衰落效应 h_m^L （包含路径损耗 h_{pl} 和阴影衰落 h_{sd} ），也考虑了小尺度衰落效应 h_m^S 。由于信道的大尺度衰落通常是由车辆位置决定的，而车辆位置在一个很短的传输时隙中变化极小^[9]，这里路径损耗建模为 $h_{pl} = 148.1 + 37.6 \lg d_m$ ，单位为 dB。其中， d_m 为车辆 m 与边缘服务器之间的距离。阴影模型设为标准差为 8 dB、均值为 0 的对数正态分布模型^[9]。然而，小尺度衰落分量是时变的。本文把小尺度衰落系数表示为遵循单位方差、均值为 0 的瑞利分布。考虑到车联网中小尺度衰落的动态特性，本文将时变瑞利系数建模为独立的一阶自回归过程^[10]，表示为

$$h_m^S(t) = \rho_m(t_c) h_m^S(t - t_c) + e_n \quad (8)$$

其中， t_c 为信道保持稳定状态的时间间隔， e_n 为由 $\mathcal{CN}(0, 1 - \rho_m^2(t_c))$ 分布推导出的处理噪声， $\rho_m(t_c) = J_0(2\pi v_m t_c / \lambda_c)$ 为信道自相关函数， $J_0(\cdot)$ 为第一类零阶贝塞尔函数， λ_c 为中心载波波长， v_m 为车辆 m 的行驶速度。

因此，本文提出的资源分配的目标是在约束条件下最优地分配每辆车的带宽资源，从而最大化正

确理解的视频语义，则优化问题可以表示为

$$\begin{aligned} \text{P2: } \max_{B_m, l} & \frac{1}{M} \sum_{m=1}^M \sum_{n=1}^N \delta_n I_{m,n} P_n(q_m(R_m)) \\ \text{s.t.} & \\ \text{C1: } & R_m \leq R_m^T(t), \forall m \\ \text{C2: } & \sum_{m=1}^M B_m \leq B_{\max} \\ \text{C3: } & B_m \geq B_{\min}, \forall m \\ \text{C4: } & P_n \geq P_{\min}, \forall n \\ \text{C5: } & \Delta t + (l-1)t_c \leq t \leq \Delta t + lt_c \\ \text{C6: } & 1 \leq l \leq L, L = \frac{T - \Delta t}{t_c} \end{aligned} \quad (9)$$

其中， M 为车辆总数； N 为目标类别总数； δ_n 为不同检测类别的权重，不同类别的检测目标（如人、车、交通灯）在语义分析任务中可能具有不同的重要性； $I_{m,n}$ 为原视频中待检测的目标数量（密度）， $I_{m,n} P_n$ 为正确检测到的目标数量，即可正确理解的视频语义； B_m 为车辆分配的带宽； l 为传输时隙序号。

优化问题 P2 中各约束条件的实际意义如下。约束条件 C1 表示视频码率不大于信道传输速率，这是基于信息传输理论的。约束条件 C2 和 C3 表示车联网系统中带宽资源的限制条件，所有车辆所分配的带宽之和不大于总带宽资源 B_{\max} ，同时分配给每辆车的带宽资源不小于传输带宽门限值 B_{\min} ，即带宽分配的最小值。约束条件 C4 表示目标检测精度的取值范围，在实际中，检测精度应该大于任务需求的阈值 P_{\min} 。C5 表示车联网中一段视频的稳定传输时间范围。C6 表示整个视频传输过程的时隙跨度， L 表示最大的时隙数。

4 基于凸优化的资源分配算法

首先，从优化问题 P2 中可以看出，当 $t \in (\Delta t, T)$ 时，CSI 随时间变化，问题 P2 是非凸的。但是在时间间隔 t_c 内，可以将信道状态视为稳定状态，因此可以将原问题分解为 L 个子问题，其中 $L = (T - \Delta t) / t_c$ 。根据第 2 节中的分析， $\alpha_1 < 0$ ， $\alpha_2 > 1$ 且 $\beta_2 < 0$ ，又因为 $\partial P / \partial q > 0$ （ ∂ 是求导运算符），函数 $P(q(R_m))$ 在定义域中单调增加，当 $R_m = R_m^T(t)$ 时取最大值。因此，在第一个传输时间间隔 t_c 中，资源分配问题 P2 可以转换为

$$\text{P3: } \max_{B_m} \frac{1}{M} \sum_{m=1}^M \sum_{n=1}^N \delta_n I_{m,n} P_n(q_m(R_m^T(B_m, t)))$$

$$\begin{aligned}
\text{s.t. C1: } & \sum_{m=1}^M B_m \leq B_{\max} \\
\text{C2: } & B_m \geq B_{\min}, \forall m \\
\text{C3: } & P_n \geq P_{\min}, \forall n \\
\text{C4: } & \Delta t \leq t \leq \Delta t + t_c
\end{aligned} \quad (10)$$

定理 1 结合式(4)~式(7), 根据复合函数的规则, 问题 P3 是凸优化问题。

证明 对于第 3 节中信道模型的定义, 已知接近完美的 CSI, 并且式(8)中定义的小尺度衰落在持续时间 t_c 上是恒定的。在时间 $t \in (\Delta t, \Delta t + t_c)$ 范围内, 信道增益 h_m 恒定且不随时间变化。

1) 根据式(7), 传输速率 $R_m^T(B_m) = B_m \ln\left(1 + \frac{S_m h_m}{\sigma^2}\right)$ 是一个仿射函数, 该函数是线性递增的, 自变量为 B_m 。

2) 根据式(5), $q(\cdot)$ 是凸且递减的, 因此函数 $q(R_m^T(B_m))$ 是凸且递减的。

3) 根据式(4), $P(\cdot)$ 是一个凹且递减的函数, 因此复合函数 $P(q(R_m^T(B_m)))$ 是凹的。此外, 根据模型参数求解算法的结果, 即表 1 和表 2 的数值结果,

$\alpha_1 < 0$, $\alpha_2 > 1$ 且 $\beta_2 < 0$, 所以 $\frac{\partial P(q(R_m^T(B_m)))}{\partial B_m} > 0$ 。

4) 由于 δ_n 和 $I_{m,n}$ 是已知常数, M 和 N 是有限的正整数, 根据复合函数的规则, P3 的目标函数是凹函数和递增函数的非负和。

因为 P3 中目标函数是凹的, 并且由 P3 中所有约束 (C1~C4) 确定的可行集是凸的, 所以 P3 中的优化问题是凸的, 证毕。

因此, 优化问题可以用常规的凸优化算法来解决, 例如基于凸优化工具箱 (CVX, convex programming)^[17] 的凸优化算法, 具体算法过程如算法 3 所示, 在基于凸优化的资源分配算法中, 分配的结果在每个传输时间间隔内更新。

算法 3 基于凸优化的资源分配算法

输入 系统参数

输出 最优解 \mathbf{B}^* , 最优解对应的目标函数值

1) 初始化变量 $\mathbf{B} = (B_1, B_2, \dots, B_M)$

2) 确定优化目标函数及约束条件, 构建凸优化问题

3) 利用 CVX 工具箱迭代求解优化问题

4) 输出最优解 \mathbf{B}^*

5) 根据最优解计算目标函数的值并输出

算法 3 中利用 CVX 工具箱求最优解主要是基

于内点法^[17], 属于多项式时间算法, 因此算法 3 的计算时间复杂度为 $O(L^2)$, 其中 L 表示输入长度。

5 基于强化学习的资源分配算法

根据前述分析, 基于凸优化的资源分配时间复杂度为 $O(L^2)$, 属于多项式计算时间复杂度, 随着输入的增大, 算法的计算量会快速增长, 因此对边缘服务器的实时计算能力提出了极大挑战。为降低资源分配的复杂度, 本文考虑借鉴强化学习中的 Q-learning 算法^[18], 线下训练 Q 值表, 决策时只需要进行查询 Q 值表即可, 其训练复杂度为 $O(L^2)$, 决策复杂度为 $O(1)$, 因此可极大地降低复杂度, 提高资源分配的效率。

要采用强化 Q 学习算法, 通过训练模型学习到带宽资源分配的最优值, 需首先设计强化 Q 学习关键的 3 个要素, 具体如下。

1) 状态空间, 为 M 个车辆分配的带宽 $S = \{s | s = (B_1, B_2, \dots, B_m, \dots, B_M), B_m \in (B_{\min}, B_{\max})\}$ 。

2) 动作空间, 为 M 个车辆分配的带宽变化。为简化模型中的 Q 值表, 假设带宽变化的最小步长 ΔB 为总带宽的 1%。当 $M=3$ 时, 每个动作对应只有 2 个车辆的带宽对应增减, 因此整个动作空间一共有 6 种动作组合的方式, 可表示为

$$A = \{a | a \in \{(1, 2), (1, 3), (2, 1), (2, 3), (3, 1), (3, 2)\}\}$$

其中, (i, j) 表示 $(B_i + \Delta B, B_j - \Delta B), i, j = 1, 2, 3$ 。

3) 环境反馈, 为下一状态和当前状态的 F 的差值 $\Delta F = F' - F$ 。由于训练目标是 F 取得最优值, 因此希望 F 往不断增大的方向优化。当 F 减小时, 反馈函数为负值, 获得惩罚; 当 F 增大时, 反馈函数为正值, 获得奖励; 在选择回合结束点时, 需考虑本模型的特殊性, 与强化 Q 学习算法一般适用的场景不同, 训练 F 取得最优值并不像游戏问题有明确的终点, 相反地, F 的最优值是未知的, 因此将边界条件 $B_m < B_{\min}$ 作为回合结束点, 也可以设定最大步数值结束回合。

本文中强化 Q 学习 3 个要素之间的关系如图 4 所示。首先, 智能体 (边缘服务器) 根据状态空间中的当前状态 s , 在动作空间中选择相应的动作 a ; 其次, 智能体执行动作之后, 观测环境的变化; 最后, 智能体从环境中获得反馈的奖励值 ΔF , 并进入下一状态 s' , 循环执行上述操作。

除此之外, 强化 Q 算法训练的效果和它的主要

参数有较强的相关性，经过多次尝试实验，本文模型的主要参数设定如下：学习速率 $\alpha=0.1$ ，让算法保留历史训练结果的 90%，更注重过往经验；折扣因子 $\gamma=0.9$ ，让算法考虑下一步效益的 90%，更重视长远利益； ϵ -greedy 策略中的 $\epsilon=0.8$ ，让算法有 20% 的尝试空间，避免陷入局部最优。具体步骤如算法 4 所示。




图 4 强化 Q 学习的要素关系

算法 4 基于强化 Q 学习的资源分配算法

输入 动作空间，状态空间，学习速率 α ，折扣因子， ϵ -greedy 策略参数 ϵ ，系统参数

输出 Q 值表

- 1) 对于每回合循环
- 2) 设置初始状态 B_m
- 3) 对于每步循环
- 4) 基于贪婪策略的动作选择：生成随机数，若大于 ϵ ，执行步骤 6)；若小于 ϵ ，根据 Q 值表选择 Q 值最大的动作 a

5) 执行 a ，观测下一带宽分配状态 s' 和反馈的 F 值，计算得到变化量 ΔF

6) 更新 Q 值表

$$Q(s,a) \leftarrow Q(s,a) + \alpha [\Delta F + \gamma \max_{a'} Q(s',a') - Q(s,a)]$$

7) 迭代 $s \leftarrow s'$

8) 返回步骤 3)，直到 $B_m < B_{\min}$ ，结束当前回合

6 仿真分析

6.1 仿真参数设置

为符合现实车联网环境，本节基于 SUMO 交通仿真器，MATLAB R2019a，Pycharm 2019.1.1 平台完成了仿真系统的构建。1) 构建的车联网仿真环境是基于 SUMO (simulation of urban mobility) 生成的城市十字路口场景，每条道路包括 4 条宽 3.5 m 的双向车道，车辆的初始相对位置随机生成。2) 为符合车联网中真实的信道条件，路损模型使用 3GPP

TR 36.885 标准中的 Winner 模型^[19]，如第 3 节所述，同时考虑车联网中由于车辆移动和建筑等造成的小尺度衰落，采用如式(8)所示的时变小尺度衰落模型，具体的系统仿真参数设置均基于 3GPP TR 36.885，仿真数值汇总于表 3。3) 考虑到实际中车联网的时变非稳态特性，仿真中每次实验采用 200 次独立的蒙特卡罗仿真取平均值，以消除异常数据带来的误差。

表 3 系统仿真参数设置

仿真参数	值
边缘服务器覆盖范围/km	0.5
配置摄像头的车辆数目 M	3~18
检测对象的类别数 N	3
检测对象类别权重 δ_n	1
车辆行驶速度 $v_m / (\text{km}\cdot\text{h}^{-1})$	0~120
车辆发射功率 S_m / dBm	23
噪声功率谱密度 / $(\text{dBm}\cdot\text{Hz}^{-1})$	-174
中心载波频率 / GHz	2
视频预处理时延 $\Delta t / \text{ms}$	200
小尺度衰落的时间间隔 t_c / ms	50
总带宽资源 B_{\max} / MHz	0.2~2
最小带宽约束 B_{\min}	$0.1 B_{\max}$
最小检测正确率约束 P_{\min}	0.3

为符合实际中车辆和服务器的运算能力，视频处理和目标检测仿真实验设置如下。1) GPU 型号为 Tesla M40，视频检测器为 Faster-RCNN，训练和测试环境为 Windows 10 + CUDA 8.0+ Tensorflow 2.1。2) 视频编解码器使用 H.265，视频帧率为 30 帧/秒，帧组大小为 4 帧（包括一个 I 帧和 3 个 P 帧），每段传输视频大小为 300 帧。3) 测试视频来自使用较广泛的真实数据集 Caltech 交通视频数据集，表 4 中具体展示了不同车辆采集到的视频的具体信息，3 段视频的分辨率相同，其中视频 1 中待检测平均目标密度最高，视频 2 中目标密度中等，视频 3 中目标密度最低。

表 4 测试视频信息

视频序号	视频分辨率	视频帧率 / $(\text{帧}\cdot\text{s}^{-1})$	待检测目标密度 I (行人/车辆/信号灯)
1	640 像素×480 像素	30	11.1/1.6/1.5
2	640 像素×480 像素	30	1.0/8.5/1.5
3	640 像素×480 像素	30	0.0/1.9/0.0

6.2 对比分析

6.2.1 资源分配算法对比分析

本节仿真验证了本文所提的基于强化 Q 学习的资源分配算法的收敛性，并对比了凸优化算法、强化 Q 学习算法以及粒子群算法的性能差异。各算法介绍如下：1) 凸优化算法如算法 3 所示，利用 CVX 工具箱求最优资源分配的解；2) 强化 Q 学习算法如算法 4 所示，根据动作选择和环境反馈迭代学习来获得最优资源分配的解；3) 粒子群算法是一种应用广泛的启发式算法^[20]，将带宽资源的分配初始化为 M 个随机粒子（随机解），然后通过搜索空间中迭代获取最优解，在每一次的迭代中，粒子通过跟踪最优值来更新自己的速度和位置。

图 5 展示了强化 Q 学习算法的奖励函数的收敛过程。大约在 1 300 次迭代后，强化 Q 学习算法的解趋于稳定，这证明了本文所提的基于强化 Q 学习资源分配算法的收敛性，在线下训练中能通过有限次迭代得到稳定 Q 值表。




图 5 强化 Q 学习的迭代收敛仿真

图 6 展示了不同资源分配算法的性能对比。随着总带宽的增加，最大平均正确检测目标数量增加并最后趋于稳定，这是因为资源饱和造成收益减小。另外，强化 Q 学习算法的性能与凸优化算法的性能几乎一致，证明强化 Q 学习在降低复杂度的同时可获得较好性能。本文所提的算法均优于粒子群算法，这是因为粒子群算法在信道不稳定的条件下容易陷入局部最优解。

6.2.2 资源分配方案对比分析

本节仿真对比了不同资源指导方案下的性能差异，对比方案如下：1) 本文所提的视频语义驱动

的资源分配方案，通过所构建语义驱动的资源分配指导模型合理地分配通信资源，使边缘服务器端最大程度地理解视频语义；2) 文献[8]中基于 QoC 的资源分配方案，即边缘服务器端平均目标检测精度驱动的资源分配方案；3) 文献[6]中基于 QoE 的资源分配方案，即传输视频的用户体验质量驱动的资源分配方案；4) 文献[5]中基于 QoS 的资源分配方案，即车辆到边缘服务器的链路传输效率驱动的资源分配方案。




图 6 不同资源分配算法性能对比

图 7 展示了不同资源分配方案下随着总带宽的增加，每帧视频最大正确检测目标的数量。这里使用检测目标的数量来表示视频的语义，如优化问题 P2 中所定义的。显然，本文所提出的方案可以提高正确检测目标的数量。也就是说，该方案保证了视频传输结束后，能够在边缘服务器上正确检测到更多的目标，能更好地完成视频语义理解任务。从图 7 可知，基于 QoS 的资源分配方案性能最差，这是因为基于 QoS 的方案不考虑视频的语义信息，仅考虑网络效率，因此会给冗余视频（目标数量极少的视频）分配较多的带宽，而本文所提方案考虑了视频的语义信息，会倾向于给目标数量更多的视频分配更多的带宽资源，具体给每辆车的带宽分配结果如图 8 所示。结合图 7 和图 8 可知，有效的资源分配有助于在传输过程中保留更多的视频语义信息，因此可以在边缘服务器上更准确地理解视频语义。

图 9 和图 10 分别展示了不同方案下的正确检测概率和错误检测概率的性能曲线，随着带宽资源的增加，所有方案的性能均有所提升，这是因为带

宽资源的增加保证了视频的传输质量，所以边缘服务器端能接收到更高质量的视频，从而带来了目标检测任务的性能提升。可以看出，本文所提的方案的正确检测概率和错误检测概率的性能均是最优的，这是由于在优化问题的构建中，本文考虑了将正确检测概率作为目标函数的乘积项，因此在资源分配的过程中会使资源分配向提升正确检测概率性能的方向迭代。




图 7 不同资源分配方案的最大正确检测目标数量

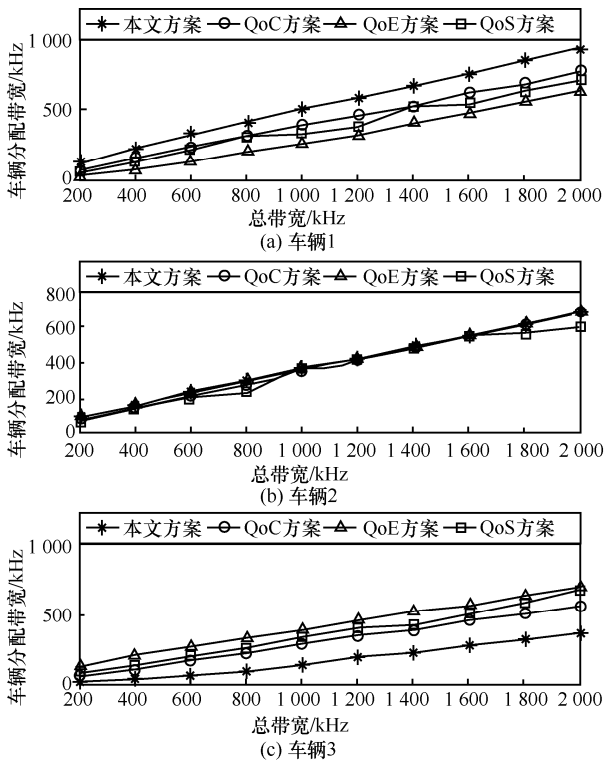


图 8 不同方案的带宽资源分配结果

另外，目标正确检测率和错检率的性能优势显示语义驱动的资源分配方案更适合于视频语义理

解任务，高正确检测概率和低错误检测概率对辅助驾驶或自动驾驶业务具有重要的意义，更准确的检测能优化驾驶决策。




图 9 不同资源分配方案的正确检测概率




图 10 不同资源分配方案的错检或漏检概率

6.2.3 车联网场景下影响参数分析

本节仿真分析了车联网场景中常见的 2 个指标（接入车辆数目和车辆行驶速度）对资源分配方案的性能影响。

不同方案下，最大正确检测目标数随着车辆数目的变化如图 11 所示。可以看出，随着接入边缘服务器车辆数目的增多，整体性能都呈下降趋势，这是因为车辆的增多造成了车辆对资源的竞争更激烈，可分给每辆车的平均带宽资源减少。但是，随着车辆数目的增加，本文所提的视频语义驱动的资源分配方法仍然保持性能最优，证明了本文方案在车辆数目较多场景下或者资源紧缺条件下的性能优势。




图 11 最大正确检测目标数随着车辆数目变化

随车辆速度变化不同方案的性能变化如图 12 所示。实验设置总带宽为 1 MHz。随着车辆行驶速度的增大，信号的传输过程产生多普勒频移，造成干扰，导致传输速率下降。因此，随着速度的增加，所有方案的性能均有所损失。从图 12 可以看出，本文方案在速度变化的条件下，依然保持最大的可正确检测的目标数量，这是因为第 3 节中考虑了信道条件随速度的变化特性，本文所提资源分配方案能适应车联网中信道快速变快的特性。




图 12 随车辆速度变化不同方案的性能变化

7 结束语

为实现车联网环境下对视频语义的高效传输和准确理解，以满足辅助驾驶等业务的需求，本文研究了视频语义驱动的资源分配问题。本文提出了视频语义驱动的资源分配指导模型，以及在该模型指导下车联网场景中的通信资源资源分配算法。实验结果验证了本文所提算法的性能优势，本文所提的资源

分配方案更适用于以视频语义理解任务为主的智能环境。顺应通信技术与人工智能紧密结合的大趋势，本文所提方案为以视频语义理解为主要手段的智能驾驶时代存在的交通环境复杂、汽车通行效率低、道路安全问题突出等难点问题提供了一条新的解决途径。

参考文献:

- [1] ZHANG J P, WANG F Y, WANG K F, et al. Data-driven intelligent transportation systems: a survey[J]. IEEE Transactions on Intelligent Transportation Systems, 2011, 12(4): 1624-1639.
- [2] ZHU L, YU F R, WANG Y G, et al. Big data analytics in intelligent transportation systems: a survey[J]. IEEE Transactions on Intelligent Transportation Systems, 2019, 20(1): 383-398.
- [3] ZHOU Z, CHEN X, LI E, et al. Edge intelligence: paving the last mile of artificial intelligence with edge computing[J]. Proceedings of the IEEE, 2019, 107(8): 1738-1762.
- [4] LI G Y, BOUKHATEM L, WU J S. Adaptive quality-of-service-based routing for vehicular ad hoc networks with ant colony optimization[J]. IEEE Transactions on Vehicular Technology, 2017, 66(4): 3249-3264.
- [5] SUN L, SHAN H G, HUANG A P, et al. Channel allocation for adaptive video streaming in vehicular networks[J]. IEEE Transactions on Vehicular Technology, 2017, 66(1): 734-747.
- [6] TAO X M, DUAN Y P, XU M, et al. Learning QoE of mobile video transmission with deep neural network: a data-driven approach[J]. IEEE Journal on Selected Areas in Communications, 2019, 37(6): 1337-1348.
- [7] LIANG H B, ZHANG X H, HONG X T, et al. Reinforcement learning enabled dynamic resource allocation in the Internet of vehicles[J]. IEEE Transactions on Industrial Informatics, 2021, 17(7): 4957-4967.
- [8] CHEN X, HWANG J N, MENG D, et al. A quality-of-content-based joint source and channel coding for human detections in a mobile surveillance cloud[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2017, 27(1): 19-31.
- [9] GUO C T, LIANG L, LI G Y. Resource allocation for vehicular communications with low latency and high reliability[J]. IEEE Transactions on Wireless Communications, 2019, 18(8): 3887-3902.
- [10] SHI J F, YANG Z H, XU H, et al. Dynamic resource allocation for LTE-based vehicle-to-infrastructure networks[J]. IEEE Transactions on Vehicular Technology, 2019, 68(5): 5017-5030.
- [11] WU J Y, YUEN C, CHENG B, et al. Bandwidth-efficient multipath transport protocol for quality-guaranteed real-time video over heterogeneous wireless networks[J]. IEEE Transactions on Communications, 2016, 64(6): 2477-2493.
- [12] LIU C H, HUYNH D Q, SUN Y C, et al. A vision-based pipeline for vehicle counting, speed estimation, and classification[J]. IEEE Transactions on Intelligent Transportation Systems, 2016, PP(99): 1-14.
- [13] SULLIVAN G J, OHM J R, HAN W J, et al. Overview of the high efficiency video coding (HEVC) standard[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2012, 22(12): 1649-1668.
- [14] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [15] DOLLAR P, WOJEK C, SCHIELE B, et al. Pedestrian detection: an

evaluation of the state of the art[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34(4): 743-761.

- [16] SUN P, KRETZSCHMAR H, DOTIWALLA X, et al. Scalability in perception for autonomous driving: Waymo open dataset[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE Press, 2020: 2443-2451.
- [17] BUBECK S. Convex optimization: algorithms and complexity[J]. Foundations and Trends in Machine Learning, 2015, 8(3-4): 231-357.
- [18] JANG B, KIM M, HARERIMANA G, et al. Q-learning algorithms: a comprehensive classification and applications[J]. IEEE Access, 2019, 7: 133653-133667.
- [19] Technical Specification Group Radio Access Network. Study on LTE-based V2X Services (Release 14)[R]. 3GPP TR 36.885 V14.0.0, 2016.
- [20] GONG Y J, ZHANG J, CHUNG H S H, et al. An efficient resource allocation scheme using particle swarm optimization[J]. IEEE Transactions on Evolutionary Computation, 2012, 16(6): 801-816.



郭彩丽（1977-），女，山西太原人，博士，北京邮电大学教授、博士生导师，主要研究方向为语义通信、无线移动通信技术、认知无线电、信号检测与估值、车联网、可见光通信，视觉智能计算，社交跨媒体数据挖掘与分析等。



杨洋（1991-），男，湖南娄底人，博士，北京邮电大学讲师，主要研究方向为可见光通信、室内定位技术、车联网技术、语义编码等。

[作者简介]




陈九九（1994-），男，湖南平江人，北京邮电大学博士生，主要研究方向为车联网资源分配、语义通信、强化学习算法等。



孙启政（1997-），女，河南安阳人，北京邮电大学博士生，主要研究方向为语义通信、视觉内容理解、深度学习算法等。



冯春燕（1963-），女，北京人，博士，北京邮电大学教授、博士生导师，主要研究方向为无线通信信息传输与处理、宽带通信网络理论与技术、社交网络分析和信息检索、电信大数据分析挖掘等。



朱美逸（1999-），女，湖北襄阳人，北京邮电大学硕士生，主要研究方向为车联网通信、强化学习算法等。