多区域协同感知中的面向时效性的调度与资源分配

Mengmeng Zhu，*IEEE*学生会员，Yuxuan Sun，*IEEE*会员，Yukuan Jia，Wei Chen，*IEEE*高级会员，Bo Ai，*IEEE*会士，以及Sheng Zhou，*IEEE*高级会员

arXiv:2601.04542v1 [cs.LG] 8 Jan 2026

摘要——**协同感知（CP）是自动驾驶和智慧城市等应用中的一项关键技术。它通过传感器之间共享和融合信息，克服单个传感器感知能力的局限，例如盲区和范围限制。然而，CP面临两项主要挑战。首先，由于环境具有动态性，所传输信息的时效性对感知性能至关重要。其次，传感器的计算能力有限，且无线带宽受限，因此必须谨慎设计通信量，以确保特征表示既有效又充分。本文研究多区域协同感知场景中的动态调度问题，并提出一种时效性感知多区域优先级（TAMP）调度算法，以权衡感知准确率与通信资源使用量。时效性体现了信息效用随时间推移而衰减的特性，这一特性在CP任务中表现为感知性能。我们提出一种经验惩罚函数，将信息年龄（AoI）和通信量的综合影响映射到感知性能。为长期最小化这一面向时效性的惩罚，并考虑到调度决策会对后续系统状态产生累积影响，我们提出了TAMP调度算法。TAMP是一种基于李雅普诺夫的优化策略，它将长期平均目标分解为时隙级优先级分配问题，在调度价值与资源成本之间取得平衡。我们使用真实世界的路侧协同感知（RCooper）数据集，在交叉路口和走廊场景中验证了该算法。大量仿真结果表明，TAMP优于表现最佳的基线方法，在不同配置下，平均精度（AP）最高提升27%。**

索引词—**信息年龄、协同感知、资源分配、在线调度、自动驾驶**

I. 引言

全面智能感知的新范式在自动驾驶和城市交通监控等应用中至关重要 [1]。智能车辆和路侧单元利用摄像头和激光雷达等传感器感知周围环境。然而，单个传感器的效能往往受限于视场狭窄、感知范围有限以及易受遮挡影响 [2]。为克服这些局限，协同感知（ CP ）应运而生，成为一项关键解决方案 [3]。在协同感知中，多个传感器共享通过无线信道传输的感知信息，旨在扩大集体感知范围，并减轻遮挡和视场受限所导致的性能下降。

然而，现有的协同感知方法主要关注单个区域内的协作，并将每个区域视为独立实体。这种设计未考虑不同区域可能会竞争共享的通信和计算资源。因此，单个区域的协同感知系统无法满足跨多个交叉路口和道路路段进行交通监控等应用的需求 [4]。因此，我们需要考虑多区域协同感知系统，该系统通常由两级架构组成。在区域间层级，中心基站（BS）负责协调各项操作，并在不同区域之间分配资源。在区域内层级，每个区域内的传感器执行协同感知，以互补各自的视场并覆盖彼此的盲区。为实现协同感知，我们采用特征级融合 [5]–[8]。这种广泛使用的范式在两种极端方案之间实现了平衡：原始数据级融合在不损失信息的情况下传输原始传感器数据，但会产生高昂的带宽开销 [9], ；目标级融合虽然具有较高的带宽效率，但可能会丢失关键细节 [10]。

多区域协同感知系统的主要目标是确保所有受监测区域的信息及时性。时效性指感知信息的价值，该价值会因动态环境而迅速降低 [11]。信息年龄（AoI）是一种广泛采用的指标，用于量化信息的新鲜程度，即衡量自最近接收的信息生成以来所经过的时间 [11]–[13]。例如，当协作传感器检测到一辆经过的车辆时，由于车辆的移动，延迟的感知信息会导致对目标位置的不准确估计。这种信息滞后会导致感知性能下降。

为了优化多区域CP的性能，一个关键问题随之而来：在通信和计算资源受限的情况下，基站如何高效管理来自多个区域的大量数据流？这一问题可分解为两个关键挑战。1）在区域内层级，特征粒度与时效性之间存在根本性的权衡。较大的通信量能够提供更丰富的信息，但会增加传输和计算时延，从而降低数据新鲜度。挑战在于确定每个区域的最优通信量，以平衡粒度与时效性之间的权衡。2）在区域间层级，挑战在于复杂的区域选择问题。由于带宽和服务器处理能力有限，只能同时为部分区域提供服务。一些区域近期已被调度，而另一些区域则

Mengmeng Zhu、Yuxuan Sun（通信作者）、Wei Chen 和 Bo Ai 就职于北京交通大学电子与信息工程学院，北京100044，中国。（电子邮箱：{mengmengzhu、yxsun、weich、boai}@bjtu.edu.cn）Yukuan Jia 和 Sheng Zhou 就职于清华大学北京信息科学与技术国家研究中心电子工程系，北京100084，中国。（电子邮箱：jyk20@mails.tsinghua.edu.cn、sheng.zhou@tsinghua.edu.cn）

长期未被调度。因此，它们的调度紧迫度各不相同。这就需要一种指标来量化每个区域的实时调度优先级。此外，系统的信道状态和目标高度动态，因此需要一种有效的随机优化策略，在无需完全了解未来系统状态的情况下做出长期决策。

对于区域内CP，现有研究首先致力于管理通信开销。特征级融合 [5]–[8]已成为主流范式。该范式的一个重点是仅传输最显著的信息，以减少数据载荷。为此，研究人员开发了多种技术。研究者提出了任务自适应码本 [14]，以确保只传输协作者执行下游任务所严格必需的信息。信道自适应压缩方案 [11]通过适应实时无线通信约束，提取最有价值的语义信息。信息瓶颈原理 [15] 也被用于一种编码方法，该方法根据内容的任务相关性调整视频压缩率，从而平衡准确性与通信成本。

与此同时，信息年龄（AoI）已被广泛用于量化信息新鲜度 [11]–[13]。这一线性指标衡量自最近接收的信息生成以来经过的时间。早期研究侧重于尽量降低实时监测和控制系统中的信息年龄 [16]–[18]。然而，AoI的线性特性往往不足以刻画任务性能随时延以非线性方式下降的情况。为此，研究者提出了非线性指标。例如，信息紧迫度（UoI） [19]根据状态更新的上下文，衡量其随时间变化的非线性重要性。使用信息年龄（AoUI） [20]则共同反映物联网系统中相关数据的新鲜度与可用性。针对多智能体感知的特定需求，感知目标年龄（AoPT） [15] 刻画多个流视角观测同一目标所形成的整体数据时效性。然而，如何应对这些因素固有的权衡，仍是一个关键问题。现有框架缺乏一种机制，来描述每个传感器的时效性要求，同时考虑其重要性差异和数据相关性，因而无法优化各自的通信量，提升CP任务的整体时效性与准确性。

对于跨区域 调度，现有研究可以从两个角度来看：设计优先级指标和调度算法。首先，区域调度优先级的定义经历了显著演变。处理信息年龄（AoPI） [21] 被引入作为一种优先级指标，它将识别准确率与传输和计算效率结合起来，超越了单纯的时效性考量。研究者制定了可定制、针对特定任务的信息年龄惩罚函数，以此定义优先级 [13], ，使系统能够根据具体应用需求权衡新鲜度与通信和计算时延。此外，研究者还基于传感器对任务的直接“感知增益”、动态移动环境中传感器数据的重要性和互补性，以及旨在最小化执行时延 [22]–[24]。

其次，为了基于给定的优先级指标寻找最优算法，研究者探索了各种调度模型。早期研究采用基于模型的优化方法，包括马尔可夫决策过程（MDP）。在这一范式下，研究者将调度问题建模为无限时域MDP，以最小化信息年龄，并证明最优策略通常具有简单的、基于阈值的结构 [17], [25], [26]。然而，为了应对现实环境的复杂性和动态性，该领域已采用深度强化学习（DRL）等数据驱动技术。基于DRL的方法能够有效处理高维状态空间和动作空间，最终在无需系统模型的情况下学习近乎最优的策略 [18], [27], [28]。然而，多区域CP调度仍存在两个方面的不足。首先，CP缺少实用、有效且考虑时效性的优先级指标。由于CP对传输和计算的需求很高，从调度某一区域到其数据完成处理和融合之间存在显著延迟。现有指标往往未能考虑这一时延，因此难以准确预测未来性能。其次，当前转向DRL等复杂数据驱动方案的趋势，带来了较高的训练开销和计算需求，却忽视了对更实用、轻量级调度策略的需求；这类策略更适用于实时、资源受限的环境。

在多区域CP的背景下，本文提出了一种面向时效性的调度框架，通过动态选择区域并分配资源，最大化全局感知性能。主要贡献如下：

- 我们提出了一种面向多区域CP的新型调度框架。针对CP任务设计了一种新颖的惩罚函数，通过联合考虑感知信息的时效性和通信量，对感知性能的非线性退化进行建模。
- 我们将多区域调度问题表述为随机优化问题。利用KKT条件，我们推导出一种调度优先级指标，用于刻画决策的持续影响。在资源约束和系统不确定性的条件下，我们设计了时效性感知的多区域优先级（TAMP）调度算法，用于区域调度和资源分配。
- 我们使用真实世界路侧数据集RCooper [29]验证了所提出的调度算法。通过在交叉路口和走廊场景中开展实证研究，我们根据从这些场景获得的推理数据拟合惩罚函数，并探索所提算法的实际性能。这证明了我们的算法在真实环境中的可行性。
- 我们进行了大量仿真，以评估所提出算法在不同场景设置和速率分布下的性能。结果表明，与基线方法相比，所提出的算法可将平均精度（AP）提高至多 27%。

II. 系统模型

A. 系统概述

如图1所示，我们考虑一个由与边缘服务器共址的基站（BS）以及一

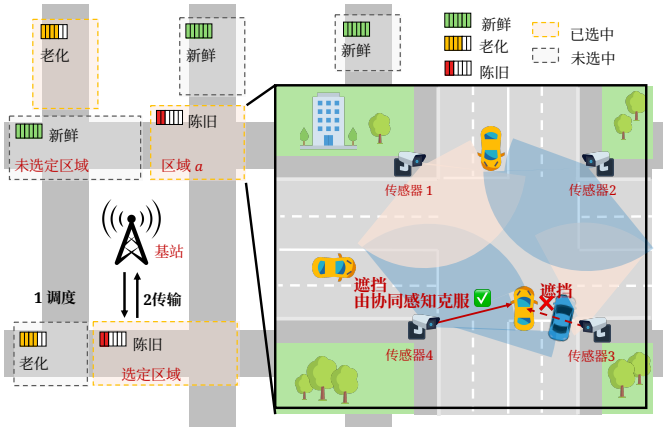

图1. 系统架构示意图，其中一个基站管理多个CP区域。

组待监测区域构成的系统，记为 $\mathcal{A}$。每个区域$a \in \mathcal{A}$配备一组传感器（例如摄像头、激光雷达），记为 $\mathcal{N}_a$。所有传感器的集合记为 $\mathcal{N} = \cup_{a\in\mathcal{A}}\mathcal{N}_a$。为克服单视角感知的局限性，每个区域内的传感器都会进行协同感知（CP）。随后，它们将处理后的感知数据传输至基站，以进行特征级融合和目标检测。每当一项 CP 任务完成时，基站便会获得该区域的最新信息，而这些信息会逐渐变得陈旧。由于通信和计算资源有限，基站每次只会调度有限数量的区域进行协同感知。我们的目标是设计一种调度算法，以最大化整体感知性能。

该系统以离散时隙运行，时隙编号为 k，整个流程由基站统筹。系统工作流程可分为三个依次进行的阶段：1）区域选择与特征提取，2）带宽分配与特征传输，以及3）特征融合与检测。

在第一阶段，基站执行区域选择。基站从空闲区域 $\mathcal{A}_{\text{idle},k}$ 中选择区域 $\mathcal{A}_{\text{selected},k}$ 进行调度，并将其加入活动区域集合，记为 $\mathcal{A}_k \subseteq \mathcal{A}$。如果某区域的 CP 任务已启动但尚未完成，则该区域处于活动状态。因此，$\mathcal{A}_k = (\mathcal{A}\setminus\mathcal{A}_{\text{idle},k}) \cup \mathcal{A}_{\text{selected},k}$。根据调度决策，选定区域 $a \in \mathcal{A}_{\text{selected},k}$中的传感器开始从环境中采集原始感知数据并提取特征。在第二阶段，对于活动区域 $a \in \mathcal{A}_k$中的每个传感器，基站执行资源分配，将带宽 $B_{n,k}$ 分配给传感器 n用于数据传输。随后，传感器对特征进行压缩，以适应分配的带宽，并通过无线信道将其传输至基站。在第三阶段，基站对每个选定区域内所有传感器传来的特征进行融合。融合结果随后用于下游任务，例如目标检测和跟踪。

B. 特征提取模型

当基站在时隙 k 调度区域 a 时，我们假设向该区域内所有传感器广播控制消息的时延可以忽略不计。收到控制消息后，每个传感器 $n \in \mathcal{N}_a$ 处理其原始感知数据，生成一个提取特征，记为 $\mathcal{F}_n^{\text{ext}}$。为管理每个区域消耗的传输和计算资源，我们对每个区域 a 的通信量施加长期平均约束：

$$\limsup_{K\to\infty} \frac{1}{K}\sum_{k=1}^{K} \mathbb{E}\left[b_{a,k}\right] \le \Gamma_a, \quad \forall a \in \mathcal{A}, \tag{1}$$

其中，Γ_a 是区域 a的预定义通信量预算。值得注意的是，基站根据信道条件和区域 a的当前状态，为每个区域 a 分配通信量$b_{a,\,k}$。来自传感器 $n \in \mathcal{N}_a$ 的提取特征 $\mathcal{F}_n^{\text{ext}}$ 按需压缩为传输表特征 $\mathcal{F}_n^{\text{tr}}$，使其与分配的通信量$b_{a,\,k}$相匹配。设 $|\cdot|$ 表示特征的数据大小。因此，$\sum_{n\in\mathcal{N}_a} |\mathcal{F}_n^{\text{tr}}| = b_{a,\,k}$。第 III 节详细介绍了每个区域内传感器的通信量分配和特征压缩方法。

单个传感器 n的特征提取延迟记为 $d_{n,\,k}^{\text{ext}}$，建模为服从平移指数分布 [30]–[32]的随机变量。后续的压缩时延可忽略不计。由于所有传感器并行运行，区域 a的整体阶段时延由最后完成的传感器决定。因此，其表达式为：

$$d_{a,k}^{\text{ext}} = \max_{n\in\mathcal{N}_a} \left\{ d_{n,k}^{\text{ext}} \right\}. \tag{2}$$

C. 特征传输模型

提取后，特征将传输至基站。传感器 n 在时隙 k 的可达传输速率记为 $r_{n,\,k}$，受频谱效率 η_k（单位：b/s/Hz）限制，其表达式为：

$$r_{n,k} = B_{n,k} \cdot \eta_k, \tag{3}$$

其中，$B_{n,\,k}$ 是分配给传感器 n 的带宽。频谱效率 η_k 是由信道状态决定的变量，我们假设其在每个任务内保持恒定。

给定总无线带宽 B_{total}，我们需要在活动区域 $\mathcal{A}_k$ 的传感器之间高效分配带宽。我们联合确定传感器 n 的通信量 $b_{n,\,k}$ 和带宽 $B_{n,\,k}$。这一决策基于传感器数据的重要性及其相关性。该分配的具体算法详见第三节。分配的带宽总和必须满足：

$$\sum_{a\in\mathcal{A}_k}\sum_{n\in\mathcal{N}_a} B_{n,k} \le B_{\text{total}}. \tag{4}$$

区域 a 的传输时延记为 $d_{a,\,k}^{\text{tr}}$，由最慢的传感器决定，其表达式为：

$$d_{a,k}^{\text{tr}} = \max_{n\in\mathcal{N}_a} \left\{ \frac{b_{n,k}}{r_{n,k}} \right\}. \tag{5}$$

D. 特征检测模型

特征成功上传后，BS会执行特征融合与处理。首先，BS融合从区域 a内所有活动传感器接收到的特征。设$\mathcal{F}_{n,\,k}^{\text{tr}}$为传感器 $n \in \mathcal{N}_a$的特征集。融合过程

将这些独立的特征集合并为一个完整的区域特征集，$\mathcal{F}^{\mathrm{tr}}_{a,\,k} = \bigcup_{n\in\mathcal{N}_a} \mathcal{F}^{\mathrm{tr}}_{n,\,k}$。随后，该融合后的特征集将用于下游任务，例如目标检测。区域 a在时隙k开始的任务的特征处理时延记为$d^{\mathrm{det}}_{a,\,k}$，并建模为服从平移指数分布 [30]–[32]的随机变量。然而，BS受其计算资源（例如GPU容量）的限制，因此可同时处于活动状态的CP任务数量有限。由于 $\mathcal{A}_k$ 是在时隙 k中有正在进行任务的活动区域集合，其大小上限为 M。由此得到以下系统约束：

$$|\mathcal{A}_k| \le M, \quad \forall k. \tag{6}$$

在时刻 k于区域 a 启动的CP任务，其物理时延记为 $d^{\mathrm{sec}}_{a,k}$ （单位：秒），定义为三个连续阶段（提取、传输和检测）的组成时延之和：

$$d^{\mathrm{sec}}_{a,k} \triangleq d^{\mathrm{ext}}_{a,k} + d^{\mathrm{tr}}_{a,k} + d^{\mathrm{det}}_{a,k}. \tag{7}$$

设 τ为时隙长度。为确保与离散时隙模型一致，最终任务时延$d_{a,\,k}$ （单位：时隙）通过将物理时延向上取整至最接近的整数来计算：

$$d_{a,k} = \left\lceil \frac{d^{\mathrm{sec}}_{a,k}}{\tau} \right\rceil. \tag{8}$$

*E. CP*及时性指标

及时性指标受区域信息新鲜度和各传感器通信量的共同影响。区域a 在时隙 k的信息新鲜度记为$h_{a,k}$，表示上一次成功完成的CP任务所用数据自生成以来经过的时间。图2展示了信息新鲜度的演变过程。如果区域 a 在时隙 $k = k'_m$完成一项CP任务，则信息新鲜度$h_{a,k}$ 将重置为任务总时延d_{a,k_m}。信息新鲜度按以下动态规律演变：

$$h_{a,k} = \begin{cases} d_{a,k_m}, & \text{if } k = k'_m, \\ h_{a,k-1} + 1, & \text{otherwise.} \end{cases} \tag{9}$$

令 $\boldsymbol{b}_{a,\,k} = \{b_{n,k} \mid n \in \mathcal{N}_a\}$ 表示在时隙 k为区域 a 中的传感器分配的通信量。我们引入惩罚函数 $f_a(h_{a,\,k}, \boldsymbol{b}_{a,\,k})$ 作为时效性指标。该惩罚函数的动态变化如图2所示。我们将第 m 次调度定义为在时隙 k_m 启动 CP 任务并在时隙 k'_m完成的调度。我们将第 m 个间隔定义为两个连续任务完成之间的时段，即从时隙 k'_m 到时隙 k'_{m+1}。由于为任务分配的通信量只有在该任务完成后才会影响感知性能，因此第 m 个间隔的性能受第 m 次调度时分配的通信量 $\boldsymbol{b}_{k_m}$ 影响。函数 $f(h,\ \boldsymbol{b})$ 将基于真实道路侧CP数据集进行拟合

在第IV节中，该惩罚函数具有两个特性。首先，它是信息年龄 h 的非递减函数。这表明，信息越陈旧，产生的惩罚越高。其次，它是通信量 $\boldsymbol{b}$ 的非递增函数。这意味着，传输更大的数据量通常会带来更高的感知质量，从而产生更低的

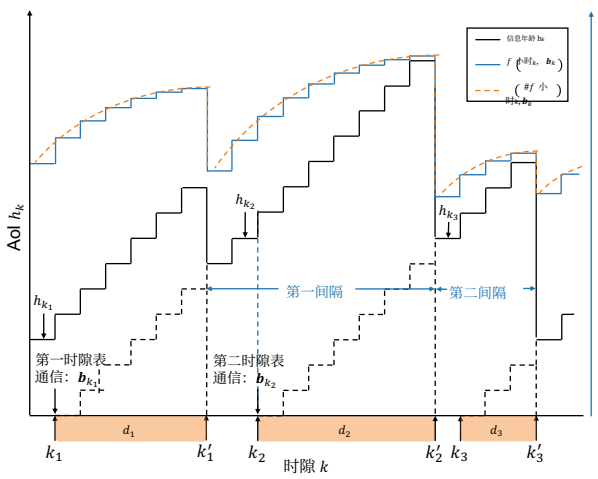

图2. 区域内结合信息年龄与通信量的面向时效性的惩罚函数。信息年龄 h_k 随时间呈阶梯状增长，仅在CP任务完成时重置。第 m 次调度从时隙 k_m 开始，分配的通信量（通信）为 $\boldsymbol{b}_{k_m}$，任务于时隙 k'_m 完成。第 m 个间隔定义为两个任务完成时间之间的持续时长，即从 k'_m 到 k'_{m+1}。注意， h_{k_m} 表示第 m 次调度时的信息年龄。

惩罚。该惩罚函数形式化地体现了一个基本权衡。一方面，使用大数据量进行频繁更新可以降低惩罚。另一方面，这种方法会消耗大量通信和计算资源，进而导致时延增加。因此，目标是设计一种调度算法，管理这一权衡，以最小化长期平均惩罚。

F. 问题表述

我们的目标是设计一种调度算法，使所有区域的长期平均惩罚最小化。回顾一下，调度决策在每个时隙开始时作出，而 CP 任务的时延可能跨越一个或多个时隙。我们定义每个时隙中的三个调度决策变量 k。第一个是区域调度向量，$\boldsymbol{u}(k) \triangleq [u_{1,k}, \ldots, u_{A,k}]$，其中 $u_{a,k} \in \{0,1\}$ 是一个二元指示变量；若区域 a 在时隙 k 被调度，则其值为 1，否则为 0。第二个是带宽分配矩阵，$\boldsymbol{B}(k) \triangleq [\boldsymbol{B}_{1,k}, \ldots, \boldsymbol{B}_{A,k}]^T$，其中 $\boldsymbol{B}_{a,k} = \{B_{n,k} \mid n \in \mathcal{N}_a\}$ 表示分配给区域 a 中传感器的带宽。第三个是通信量分配矩阵，$\boldsymbol{b}(k) \triangleq [\boldsymbol{b}_{1,k}, \ldots, \boldsymbol{b}_{A,k}]^T$。回顾一下，$\boldsymbol{b}_{a,k} = \{b_{n,k} \mid n \in \mathcal{N}_a\}$ 是区域 a 中传感器的通信量，而 $b_{n,k} \in [b_{\min}, b_{\max}]$，其中 $b_{\min}$ 和 $b_{\max}$ 分别表示最小值和最大值。令 $b_{a,k}$ 表示区域 a 在时隙 k 的通信量，即 $b_{a,k} = \sum_{n\in\mathcal{N}_a} b_{n,k}$。令 $\bar{b}_a$ 表示长期平均通信量：

$$\bar{b}_a \triangleq \limsup_{K\to\infty} \frac{1}{K} \mathbb{E}\left[\sum_{k=1}^{K} b_{a,k}\right]. \tag{10}$$

令 $\bar{f}_a$ 表示区域 a的长期平均惩罚：

$$\bar{f}_a \triangleq \limsup_{K\to\infty} \frac{1}{K} \mathbb{E}\left[\sum_{k=1}^{K} f_a(h_{a,k}, \boldsymbol{b}_{a,k})\right]. \tag{11}$$

使用此记号，可将问题表示为 $\mathcal{P}1$。目标函数 (12a) 是最小化所有区域的长期平均惩罚之和。约束 (12b) 对每个区域 a施加长期平均通信量预算 Γ_a 。约束 (12c) 和 (12d) 基于状态，分别限制瞬时带宽使用量以及状态集合 $\mathcal{A}_k$中当前活动区域的总数。决策$u_{a,\ k} = 1$ 会启动一项新的 CP 任务，随后将区域 a 添加到集合 $\mathcal{A}_k$中，并在其中保留直至任务完成。最后，约束 (12e) 和 (12f) 定义了调度变量和通信量分配变量的二元域和连续域。

$$\mathcal{P}1: \min_{\{\boldsymbol{u}(k),\boldsymbol{b}(k),\boldsymbol{B}(k)\}} \sum_{a\in\mathcal{A}} \bar{f}_a \tag{12a}$$

$$\text{s.t.} \quad \bar{b}_a \le \Gamma_a, \forall a \in \mathcal{A}, \tag{12b}$$

$$\sum_{a\in\mathcal{A}_k}\sum_{n\in\mathcal{N}_a} B_{n,k} \le B_{\text{total}}, \forall k, \tag{12c}$$

$$|\mathcal{A}_k| \le M, \forall k, \tag{12d}$$

$$u_{a,k} \in \{0,1\}, \forall a \in \mathcal{A}, \forall k, \tag{12e}$$

$$b_{n,k} \in [b_{\min}, b_{\max}], \forall n \in \mathcal{N}, \forall k. \tag{12f}$$

求解问题 $\mathcal{P}1$颇具挑战，因为其中存在若干相互交织的难点。首先，该问题具有随机性，且涉及长期平均目标和约束，因此需要在不了解未来系统状态（例如信道条件）的情况下进行在线决策。要通过逐时隙决策满足这些要求，本身就很困难。其次，调度的影响具有滞后性和累积性。更新的收益会随时间累积，因此瞬时性能并不能很好地反映长期质量。第三，区域选择决策具有组合性。由于同一时间只能服务有限数量的区域，可能的组合数量众多，因此需要一种简洁的方法来选出最优子集。因此，我们利用李雅普诺夫优化理论，将这一难以处理的随机问题转化为一系列易于处理的确定性问题，并在每个时隙求解，从而能够设计调度指标，以确定区域调度策略的优先顺序。

III. 时效性感知多区域优先调度算法

本节首先从预言机视角对长期平均惩罚进行理论分析，据此得出策略的设计原则。随后，我们利用李雅普诺夫优化框架推导出可执行的优先级指标，在调度价值与资源成本之间进行权衡。最后，我们对完整的 TAMP 调度算法进行形式化描述，详细说明竞争性选择和资源分配流程。

A. 平均惩罚分析

我们从基于预言机的视角分析系统的基本性能权衡。我们考虑一个预言机，它掌握系统中所有随机过程的统计特性（例如，信道条件的概率分布）。基于这些统计信息，可以推导出最优调度算法。为简单起见，我们聚焦于单个区域，并省略下标a 。为了进行长期惩罚分析，我们将累积惩罚函数定义为 $F(h,\ \boldsymbol{b})$，即截至信息年龄为 h时的瞬时惩罚之和：

$$F(h,\boldsymbol{b}) \triangleq \sum_{x=0}^{h} f(x,\boldsymbol{b}). \tag{13}$$

由于瞬时惩罚函数 $f(h,\boldsymbol{b})$ 仅在离散域上定义，我们构造其连续˜ ˜插值，记为 $\tilde{f}(x,\boldsymbol{b})$，使得对于 x 的所有整数值，均有 $\tilde{f}(x,\boldsymbol{b}) = f(x,\boldsymbol{b})$。鉴于 $\tilde{f}(x,\boldsymbol{b})$ 非负，且 $\tilde{f}(x,\boldsymbol{b})$ 关于 x 单调不减，该积分的上界为右黎曼和。因此，我们有：

$$\sum_{x=0}^{h} f(x,\boldsymbol{b}) \ge \int_0^h \tilde{f}(x,\boldsymbol{b})dx. \tag{14}$$

˜将连续累积惩罚记为 $\tilde{F}(h,\boldsymbol{b})$ $\int_0^h \tilde{f}\ x\ \boldsymbol{b}\ dx$ $\tilde{F}\ h\ \boldsymbol{b}\ \ge$ (.), 由此可得 (.) (.)。

我们考虑一种能够达到平稳状态的调度策略 π 。在该策略下，令 h 和 d 分别表示调度时的信息年龄以及对应任务的¯ ¯时延这两个随机变量，其均值分别为 $h = \mathbb{E}[h]$ 和 $d = \mathbb{E}[d]$。以下引理首先给出 $\mathcal{P}1$ 的等价长期平均惩罚表达式。随后，引理通过近似阶梯惩罚并应用詹森不等式，建立了一种便于处理的近似形式，该形式将作为后续优化的目标。间隔定义为两个连续任务的完成时间之差，如图2所示。令 M_K 表示截至时隙 K 的间隔数。

引理1。 给定调度策略 π，单个区域的长期平均惩罚为：

$$\limsup_{K\to\infty} \frac{1}{K}\mathbb{E}_\pi\left[\sum_{k=0}^{K} f(h_k,\boldsymbol{b}_k)\right] \tag{15}$$

$$= \limsup_{K\to\infty} \frac{M_K}{K}\mathbb{E}_\pi[F(h+d,\boldsymbol{b}) - F(d,\boldsymbol{b})] \tag{16}$$

$$\ge \frac{1}{\bar{h}} \cdot \left[\tilde{F}(\bar{h}+\bar{d},\boldsymbol{b}) - \mathbb{E}_\pi[F(d,\boldsymbol{b})]\right]. \tag{17}$$

证明。 见附录A。 □

虽然引理1为长期平均惩罚提供了一个易于处理的近似，但我们的在线算法需要实用的逐时隙决策。该决策过程分为两个步骤。第一步中，基站假设将在时隙 k 进行一次调度，并根据当前信息年龄 h_k 和信道条件，确定最优通信量 $\boldsymbol{b}_k^*$ 。这一结果通过求解以下由（17）引导的逐时隙惩罚最小化问题获得：

$$\boldsymbol{b}_k^* = \arg\min_{\boldsymbol{b}\ge 0} \frac{1}{h_k}\left[\tilde{F}(h_k+d_k,\boldsymbol{b}) - F(d_k,\boldsymbol{b})\right]. \tag{18}$$

在第二步中，给定候选通信量 $\boldsymbol{b}_k^*$，基站必须决定是否调度该区域在时隙 k。为确立这一决策的标准，我们分析式 (17) 的性质，以刻画最优调度的属性

时刻。具体而言，为了求得长期最优调度阈值，对于候选通信量 $\boldsymbol{b}$，我们通过平均时延 d优化信息年龄 h：

$$\mathcal{P}2: \quad \min_{h>0} \quad \frac{1}{h}\left(\tilde{F}(h+\bar{d},\boldsymbol{b})-\mathbb{E}[F(d,\boldsymbol{b})]\right) \tag{19}$$

备注1。第一步表示基于当前状态 h_k 和 d_k的瞬时最优决策，而第二步旨在推导长期策略的调度指导，因此采用平均值 d来刻画策略属性。

引理2。 $\mathcal{P}2$是一个拟凸优化问题。

证明。见附录B。 □

对于拟凸问题，Karush-Kuhn-Tucker（KKT）条件是全局最优性的充分条件。通过分析 $\mathcal{P}2$的KKT条件，我们推导出一个能够反映调度紧迫度的指标。驻点条件要求目标函数在 $\mathcal{P}2$中关于h 的导数为零：

$$\frac{1}{h^2}\cdot\left[h\tilde{f}(h+\bar{d},\boldsymbol{b})-(\tilde{F}(h+\bar{d},\boldsymbol{b})-\mathbb{E}[F(d,\boldsymbol{b})])\right]=0. \tag{20}$$

受最优性条件的启发，我们定义指标$U(h,\ b)$来量化调度效用，其定义为式(20)左侧的表达式：

$$U(h,\boldsymbol{b})\triangleq\frac{1}{h^2}\left[h\tilde{f}(h+\bar{d},\boldsymbol{b})-\left(\tilde{F}(h+\bar{d},\boldsymbol{b})-\mathbb{E}[F(d,\boldsymbol{b})]\right)\right]. \tag{21}$$

对于典型的惩罚函数，$U(h,\ \boldsymbol{b})$是信息年龄 h的非递减函数，这符合这样的直觉：随着信息变得越来越陈旧，调度更新的紧迫度也应随之增加。该指标还揭示了通信量 $\boldsymbol{b}$方面的基本权衡：增加 $\boldsymbol{b}$ 会降低惩罚 $f(h,\ \boldsymbol{b})$，但会增加时延 d。该效用指标构成了多区域调度算法优先级指标的基础。

B. 调度优先级

上一小节介绍了调度效用指标 $U_a(h_a,\ \boldsymbol{b}_a)$，用于量化每个区域的调度效用。现在，我们提出一个指标，用于平衡该效用与长期通信约束。第 IV 节在 Where2comm 框架下的实证分析 [33]表明，协同感知性能对每个区域分配的通信总量十分敏感；该框架会根据各传感器视野的重要性，动态地在传感器之间分配通信量。因此，我们为每个区域 $a\in\mathcal{A}$分配一个允许的长期平均通信量上限 Γ_a。为满足这一预算，我们为每个区域引入一个虚拟队列 $Q_{a,\ k}$。该队列跟踪区域 a的“通信欠额”，并按如下方式演化：

$$Q_{a,k+1}=\max\left\{Q_{a,k}+b_{a,k}-\Gamma_a,0\right\}, \tag{22}$$

其中，$b_{a,\ k}$ 是在时隙 k分配给区域a 的通信量。请注意，如果区域 a 未在时隙 k 中被调度，则 $b_{a,\ k}=0$。直观而言，如果通信使用量$b_{a,\ k}$ 超过预算 Γ_a，队列$Q_{a,\ k}$ 就会增长，这表明系统已超出预算。较大的$Q_{a,\ k}$ 表示后续时隙中需要强力节约通信资源。稳定的虚拟队列可确保长期通信预算 Γ_a得到遵守。

算法 1TAMP调度算法

输入： 最多调度区域数 M，带宽 B_{total}，通信预算 $\boldsymbol{\Gamma}$，控制参数 $\boldsymbol{V}$。
初始化： $Q_{a,0}\leftarrow 0$, $h_{a,0}\leftarrow 1$, $\mathcal{A}_{\text{idle},0}\leftarrow\mathcal{A}$。
对于每个时隙 $k=1,\ 2,\ \ldots\ldots$**执行**
  初始化 $\mathcal{C}\leftarrow\emptyset$。 ▷ 候选评估
  对于所有空闲区域 $a\in\mathcal{A}_{\text{idle},\ k}$ **执行**
    计算最优体积 $b^*_{a,k}$ 使用（18）。
    $\Pi_{a,k}\leftarrow U_a\left(h_{a,k},\ b^*_{a,k}\right)-V_aQ_{a,\ k}b^*_{a,k}$.
    如果 $\Pi_{a,k}\geq 0$ **然后**
      将 $(a,\ \Pi_{a,\ k})$ 添加到 $\mathcal{C}$。
    结束 if
  结束 for
  $M_{\text{rem}}\leftarrow M-|\mathcal{A}\setminus\mathcal{A}_{\text{idle},\ k}|$。 ▷ 竞争性选择
  按 $\mathcal{C}$ 和$\Pi_{a,\ k}$ 降序排序。
  $\mathcal{A}_{\text{selected},k}\leftarrow\text{Top}(\mathcal{C},\min(M_{\text{rem}},|\mathcal{C}|))$.
  $\mathcal{A}_k\leftarrow(\mathcal{A}\setminus\mathcal{A}_{\text{idle},k})\cup\mathcal{A}_{\text{selected},k}$.
  对所有区域 $a\in\mathcal{A}$ **执行** ▷资源分配
    如果 $a\in\mathcal{A}_{\text{selected},k}$ **则**
      $u_{a,k}\leftarrow 1,\quad b_{a,k}\leftarrow b^*_{a,k}$.
      $\{b_{n,k}\mid n\in\mathcal{N}_a\}\leftarrow$ 拆分$(b_{a,\ k})$。
    else
      $u_{a,\ k}\leftarrow 0,\quad b_{a,k}\leftarrow 0$。
    结束条件判断
    如果 $a\in\mathcal{A}_k$ **then**
      $B_{a,\ k}\leftarrow B_{\text{total}}/M$。
    结束条件判断
  结束循环
  对所有区域 $a\in\mathcal{A}$ **执行** ▷ 系统状态更新
    更新虚拟队列$Q_{a,\ k+1}$ 使用（22）。
    更新信息年龄$h_{a,\ k+1}$ 使用（9）。
  结束循环
  更新空闲区域集合 $\mathcal{A}_{\text{idle},\ k+1}$。
结束循环

我们提出的在线策略基于李雅普诺夫优化框架，其核心是漂移加惩罚原则 [34]。目标是在每个时隙内最大化调度效用，同时推动虚拟队列趋近于零。定义二次李雅普诺夫函数 $L(Q_{a,\ k})=\frac{1}{2}Q^2_{a,\ k}$，单时隙条件漂移为：

$$\Delta(Q_{a,k})=\mathbb{E}[L(Q_{a,k+1})-L(Q_{a,k})\mid Q_{a,k}]. \tag{23}$$

漂移加惩罚表达式为：

$$\Delta(Q_{a,k})-V_a\,\mathbb{E}[U_a(h_{a,k},b^*_{a,k})\,u_{a,k}\mid Q_{a,k}], \tag{24}$$

其中，V_a 是一个非负参数，用于控制漂移与惩罚之间的权衡。为确保问题易于处理，我们最小化漂移加惩罚表达式的一个上界。这将长期问题转化为一个确定性的逐时隙问题，具体形式如下定理 1 所述。

定理 1。通过最小化漂移加惩罚表达式的上界，调度算法被转化为

一个确定性的逐时隙问题，即选择调度动作 $u_{a,k} \in \{0,1\}$ 在每个时隙 k求解以下最大化问题：

$$\max_{u_{a,k}\in\{0,1\}} \quad \left[U_a(h_{a,k}, b^*_{a,k}) - V_a \cdot Q_{a,k} \cdot b^*_{a,k}\right] u_{a,k}. \tag{25}$$

证明。 见附录 C。 □

目标函数 (25) 启发我们为每个区域 a 在时隙 k 定义最终的调度优先级分数 $\Pi_{a,k}$:

$$\Pi_{a,k} = U_a(h_{a,k}, b^*_{a,k}) - V_a \cdot Q_{a,k} \cdot b^*_{a,k}. \tag{26}$$

这里，$b^*_{a,k}$ 是区域 a 在时隙 k 的最优通信量，该值通过求解 (18) 确定。

注 2。 优先级分数 $\Pi_{a,k}$ 巧妙地权衡了调度效用与通信成本。第一项 $U_a(\cdot)$ 表示调度价值，由我们的惩罚分析得出。第二项 $V_a Q_{a,k} b^*_{a,k}$ 表示调度成本，用于惩罚过高的通信成本。

C. 时效性感知多区域优先级调度

在调度优先级分数 $\Pi_{a,k}$ 的基础上，我们现提出用于 CP 的时效性感知多区域优先级（TAMP）调度算法。其核心思想是竞争性选择过程：在每个时隙中，评估所有空闲区域的调度优先级。随后，TAMP算法调度最值得调度的区域，使活动区域总数不超过系统容量 M。完整流程形式化地描述于算法 1 中。

给定最大调度区域数 M、总带宽 B_{total}、通信预算 $\mathbf{\Gamma} = \{\Gamma_a \mid a \in \mathcal{A}\}$ 和控制参数 $\boldsymbol{V} = \{V_a \mid a \in \mathcal{A}\}$，该算法在每个时隙内分四个阶段展开：

1) 候选评估： 基站通过计算每个空闲区域的最优通信量 $b^*_{a,k}$ 及相应的优先级分数 $\Pi_{a,k}$来进行评估。分数为非负的区域将被加入候选集 $\mathcal{C}$。

2) 竞争性选择： 这些候选区域按照优先级分数降序排列。可用的调度容量记为 M_{rem}，其计算方式为基站容量 M 减去当前活动区域数量$|\mathcal{A} \setminus \mathcal{A}_{\text{idle},k}|$。随后，基站选择排名前 $\min(M_{\text{rem}}, |\mathcal{C}|)$ 的区域以启动新任务，并将其与现有活动区域合并，形成最终活动集 $\mathcal{A}_k$。

3) 资源分配： 对于新选定的区域 $a \in \mathcal{A}_{\text{selected},k}$，将调度变量 $u_{a,k}$ 设置为 1。将分配的区域数据量 $b_{a,k}$ 通过 Split(·) 函数分配给传感器，如图 3 所示。该函数利用空间置信掩码 [33], 并动态调整一个置信度阈值 θ 通过二分搜索确定，从而为每个传感器视角分配通信量，以捕捉最显著的目标特征。具体而言， θ 会迭代降低（以纳入更多特征）或提高（以压缩数据），直到中间传感器数据量之和$\sum_{n\in\mathcal{N}_a} b'_n$与预算$b_{a,k}$ 在容差 ξ 范围内一致。随后，最终活动集合 $\mathcal{A}_k$ 中的每个区域都会获得总带宽 B_{total}/M的等额份额。

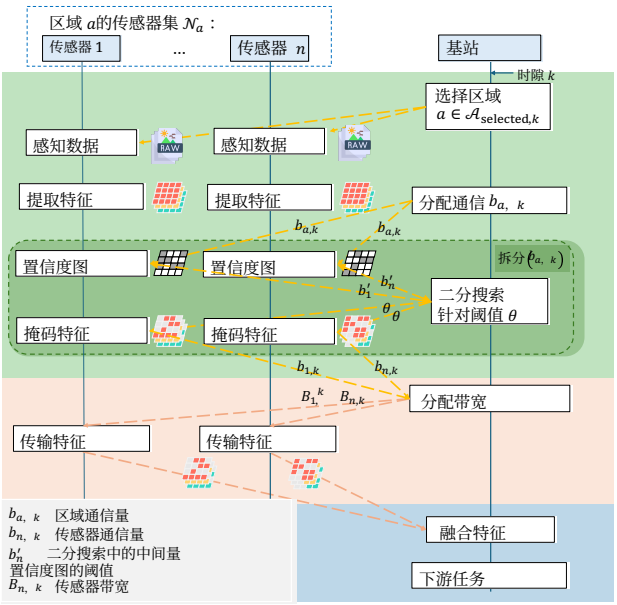

图 3。多区域 CP 系统的工作流程。

4) 系统状态更新：最后，根据各区域的动态更新所有区域的信息年龄和虚拟队列。刚完成任务的区域会被放回空闲集合 $\mathcal{A}_{\text{idle}}$，以供下一个时隙使用。

TAMP调度算法在第 II 节所述的三阶段工作流程中执行，如图 3 所示。算法的四个阶段与物理系统的映射如下：

- 特征提取：基站执行候选评估和竞争性选择，确定时隙 k 中的已选中区域 $\mathcal{A}_{\text{已选中}\,k}$。在资源分配的第一部分，基站为区域分配通信量 $b^*_{a,k}$。随后，传感器根据其空间置信度图生成通信量为 $b_{n,k}$ 的压缩特征。

- 特征传输：在资源分配的第二部分，基站为活动区域 $\mathcal{A}_k$ 分配带宽 $B_{a,k}$，并为每个传感器分配 $B_{n,k}$，以均衡区域内所有传感器之间的传输时延。随后，传感器将压缩特征传输至基站。
- 特征融合与检测：基站融合接收到的特征并执行下游任务。随后，基站执行系统状态更新，在任务完成后刷新信息年龄、虚拟队列和空闲区域集合。

IV. 经验惩罚函数

本节基于RCooper数据集建立经验惩罚函数，以衔接理论调度框架与现实世界中的协同感知（CP）性能。我们对不同场景下平均精度（AP）、信息年龄（AoI）和通信量之间的关系进行建模，并推导出用于指导TAMP算法的效用度量。

A. 实验设置

为了通过实证建立惩罚函数模型，我们在真实世界的RCooper数据集上进行了实验 [29], ， 该数据集

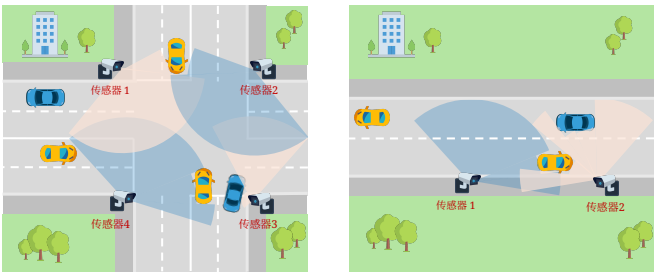

(a) 交叉路口场景　　(b) 走廊场景

图 4. RCooper数据集中的两种典型路侧CP场景 [29]。

包含两种路侧协同感知场景：交叉路口和走廊，如图4所示。每个交叉路口配备四个传感器，包括两组多线激光雷达（一组为80线，另一组为32线）和两台微机电系统激光雷达。每条走廊配备两组多线激光雷达（一组为80线，另一组为32线）。该数据集包含来自走廊场景的246个序列和来自交叉路口场景的34个序列。每个15秒的序列以3 Hz采集，约包含45帧点云。我们的方法基于Where2Comm协同感知框架 [33]。我们使用平均精度（AP）评估目标检测性能，并根据交并比（IoU）将检测结果与真实目标进行匹配。我们在IoU阈值为0.3、0.5和0.7时评估AP。我们系统地控制影响惩罚函数的两个变量：

- 信息年龄（AoI）：我们通过在点云帧与其真实标注之间引入时间偏移来模拟信息陈旧度。例如，将检测结果帧与其 0.2 秒前的标注进行评估，即可生成 0.2 秒的信息年龄。
- 通信量：我们使用空间置信度感知通信机制[33]来调节数据量。系统会生成空间置信度图，并对该图应用阈值，仅选择高置信度区域（例如，可能包含物体的区域）中的特征进行传输，从而控制每个区域的总通信量。

B. 性能建模与惩罚函数

图5中的实验数据展示了信息年龄和通信量对交叉路口场景中平均精度的共同影响。平均精度最初会随着信息年龄增加而下降。随后，下降趋势逐渐趋缓，并趋近于稳定的平均精度值。该稳定基线被视为静态背景物体的检测精度，这类物体基本不受信息陈旧的影响。另一方面，增加通信量通常能通过揭示关键的遮挡物体，带来显著的初始性能提升，但这种提升会逐渐趋于平缓。我们采用双指数模型对两者的综合影响进行建模，平均精度 ρ_1 由图5中的拟合曲面给出，表达式如下：

$$\rho_1(h_\mathrm{s}, b_\mathrm{log}) = \alpha \cdot e^{-\beta \cdot h_\mathrm{s}} - \gamma \cdot e^{-\delta \cdot b_\mathrm{log}} + \epsilon, \tag{27}$$

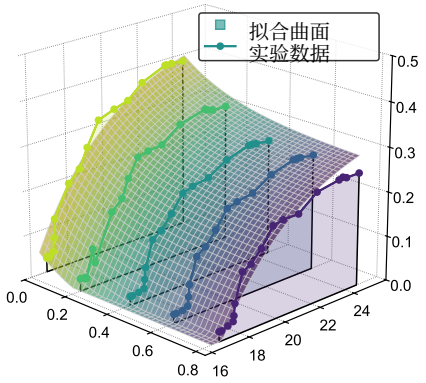

图5. 交叉路口场景下的性能拟合，展示了信息年龄和通信量（以 $\log_2$(字节) 为单位）对 AP@0.5 的联合影响。

其中， h_s 表示以秒为单位的信息年龄， b_log 表示传感器的总通信量，以 $\log_2$(字节) 为单位； $\alpha, \beta, \gamma, \delta$ 和 ϵ 为非负模型参数。

现在我们定义连续惩罚函数，$f(h, b)$ 这函数由我们的调度算法使用，表示 $\tilde{}$AP 相对于理想基准的损失。首先，我们定义理想性能基准，记为 ρ_max。该值表示在信息年龄为零且通信量最大时可达到的最高 AP，即 $f(0, b_\mathrm{max}) = 0$。惩罚函数定义为基准与拟合经验函数所建模的性能之差：

$$\tilde{f}(h, b) = \rho_\mathrm{max} - \rho_1(h_\mathrm{s}, b_\mathrm{log}). \tag{28}$$

拟合模型中使用的物理变量按如下方式映射自算法中的决策变量：

$$h_\mathrm{s} = h \cdot \tau, \quad b_\mathrm{log} = \log_2\left(\frac{b \cdot 10^6}{8}\right). \tag{29}$$

这里， τ 是单个时隙的时长，信息年龄 h以时隙为单位测量，通信量 b以兆比特（Mb）为单位测量。将上述变量变换代入（28），得到惩罚函数：

$$\tilde{f}(h, b) = -\alpha \cdot e^{\beta h \tau} + \gamma \left(\frac{b \cdot 10^6}{8}\right)^{-\delta/\ln 2} - \epsilon_0, \tag{30}$$

其中 $\epsilon_0 = \rho_\mathrm{max} - \epsilon$。此外，我们有：

$$\tilde{F}(h, b) = -\frac{\alpha}{\beta\tau}(1 - e^{-\beta\tau h}) + h \cdot \left[\gamma \left(\frac{b \cdot 10^6}{8}\right)^{-\delta/\ln 2} + \epsilon_0\right].$$

将该惩罚函数应用于 III-A小节中定义的调度效用指标$U(h, b)$，得到算法所使用的效用度量：

$$U(h, b) = -\frac{\alpha}{h} e^{-\beta h \tau} - \frac{\alpha}{\beta \tau h^2} e^{-\beta \tau \bar{d}} \left(e^{-\beta h \tau} - 1\right), \tag{31}$$

$\bar{}$其中 d 是此场景下的期望时延。该推导出的表达式直接指导了第三节所述算法中的竞争性调度决策。

在走廊场景中，图6a显示，与交叉路口场景相比，平均精度会随着信息年龄的增加而下降得更快，这是因为走廊场景中的车辆速度通常更高

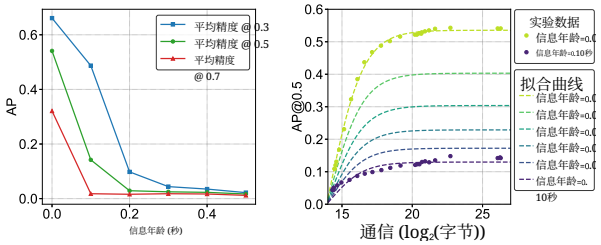

(a) (b)

图6。走廊场景中的惩罚函数拟合。（a）展示了信息年龄对平均精度的影响，（b）描绘了不同信息年龄下通信量（以 $\log_2$(字节) 为单位）对 AP@0.5 的影响。

。这种快速的性能下降可通过指数衰减函数进行数学建模。图6b中的实验数据展示了不同信息年龄下通信量对平均精度的影响。我们观察到一种饱和效应：随着通信量最初增加，性能迅速提升；但当物体得到清晰识别后，性能便趋于稳定。Sigmoid函数刻画了这种收益递减关系。平均精度 ρ_2 采用 Sigmoid-指数衰减函数建模，其表达式为：

$$\rho_2(h_{\mathrm{s}}, b_{\log})) = \left(\kappa \cdot \frac{1}{1+e^{-\lambda(b_{\log}-\lambda_0)}} - \mu\right) \cdot e^{-\nu \cdot h_{\mathrm{s}}}, \quad (32)$$

其中，κ，λ，λ_0，ν和 μ为非负模型参数。不同信息年龄水平下的拟合曲线如图6b所示。定义惩罚函数并推导调度效用指标 $U(h,\ b)$所采用的方法与交叉路口场景中使用的方法相同。

注释 3。现有 CP 系统通常会采用机制来补偿延迟，从而提升异步环境下的性能 [35]–[37]。为确保根据实测数据得出的惩罚函数能够反映这一实际情况，我们对信息年龄最初的 100 毫秒进行线性性能补偿，将初始性能下降限制在仅 0.02 平均精度。我们将简化的补偿机制直接整合到仿真过程中。

V. 数值实验

本节评估所提出的 CP TAMP 调度算法的性能。评估采用基于 RCooper数据集拟合的经验惩罚函数，详情见第IV节。

A. 实验设置

我们通过系统地评估调度算法在多种环境场景和不同关键系统参数下的目标检测精度（以 AP@0.5 衡量），来评估其性能。关键系统参数包括传输速率、通信预算、传感器侧计算能力和基站调度容量。为测试 TAMP算法的鲁棒性，我们采用两种环境配置。均质配置确保所有区域具有相同的特征；在本实验中，这被建模为仅由走廊场景构成的系统。相反，异构设置包含多种场景类型的组合；具体而言，在我们的实验中，走廊场景和路口场景各占一半。这检验了算法同时处理不同惩罚模型的能力。

默认仿真参数汇总于表 I。为反映典型的基站覆盖区域 [38]，我们将区域数量设为 A=20。调度容量设为 M =5，以适应并行处理能力有限的情况。按照实时网络标准，时隙持续时间为 $\tau = 10$毫秒 [39]。通信预算设为 $\Gamma_a = 2$ 兆比特/时隙，定义于 $32\times$ 传输压缩 [40]之前的掩码特征上。信道速率遵循 $\mathcal{U}(1,\ 20)$ 兆比特每秒，符合 IEEE 802.11p [41]。最后，处理时延采用平移指数分布建模，其位移为$\psi = 2$，尺度为 $\sigma = 8$，得到 10 毫秒的期望时延。除非另有说明，均采用这些参数。

表 I 默认仿真参数

参数	值
区域数量 (A)	20
调度容量 (M)	5
时隙长度 (τ)	10 毫秒
通信量预算（Γ_a）	2 兆比特/时隙
速率分布	$\mathcal{U}(1,\ 20)$ 兆比特每秒
提取延迟（d^{ext}）	移位指数分布 ($\psi = 2,\ \sigma = 8$)毫秒
检测延迟 (d^{det})	移位指数分布 ($\psi = 2,\ \sigma = 8$)毫秒
控制参数 (V_a)	10^{-3}
仿真时域	5000 个时隙

B. 性能比较

我们将 TAMP 算法与四种基线方法进行比较：

- **年龄优先级：** 根据当前信息年龄的高低，对前 M 个空闲区域进行调度，优先选择信息最陈旧的区域。
- **Rate-Prio：** 根据可用传输速率的高低，对前 M 个空闲区域进行调度，优先考虑即时通信效率。
- **GEA（贪心交换算法） [42]：** 该算法将当前时隙的预期信息新鲜度降低量作为调度指标，定义为区域保持空闲与被调度时的预测信息年龄之差：

$$\Pi^{\mathrm{GEA}}_{a,k} = (h_{a,k} + \tau) - \mathbb{E}[d_{a,k}], \quad (33)$$

其中时隙持续时间为 τ，期望时延为 $\mathbb{E}[d_{a,k}]$。

- **最大权重 [13]：** 一种基于李雅普诺夫的算法，通过考虑决策的长期累积影响的指标来定义调度优先级：

$$\Pi^{\mathrm{MW}}_{a,k} = \frac{W(h_{a,k})}{\bar{d}_a} - VQ_{a,k}b_{a,k}, \quad (34)$$

其中，$W(h_{a,\ k})$ 是仅取决于信息年龄的权重函数，在 [13] 中推导得出，用于刻画调度价值。

1）传输速率的影响：在本实验中，我们评估算法适应不同信道质量的能力。我们将均匀分布 $\mathcal{U}(1,\ x)$ 的最大可用速率 x 从 5 兆比特每秒调整至 60 兆比特每秒。所有其他参数均采用表 I 中列出的默认值。

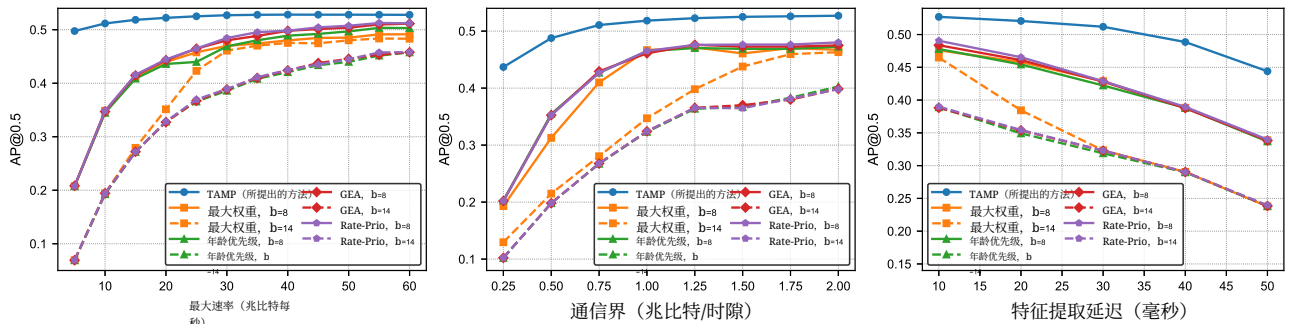

(a) (b) (c)

图 7. 在同质（20 条走廊）场景中，针对三个关键参数的性能比较：(a) 传输速率，(b) 长期通信界限，以及 (c) 传感器端特征提取延迟的期望值。

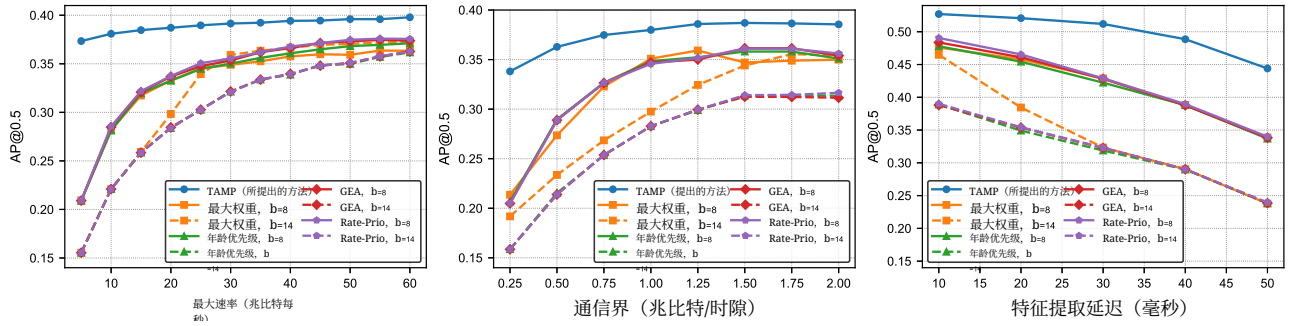

(a) (b) (c)

图 8. 在异质场景（10 条走廊 + 10 个交叉路口）场景中，针对三个关键参数的性能比较：(a) 传输速率，(b) 长期通信界限，以及 (c) 传感器端特征提取延迟的期望由传感器端特征提取延迟构成。

同质场景的结果如图 7a 所示，异质场景的结果如图 8a 所示。在这两种场景中，我们提出的算法 TAMP 始终显著优于所有基线方法。在低至中等速率区间，性能差距最为明显。例如，在同质场景中，当最大速率为 20 兆比特每秒时，与表现最佳的基线方法相比，TAMP 的平均精度提高了 15% 以上。这是因为基线算法采用非自适应策略，为每项任务使用固定的通信量；在我们的实验中，该数值设为 8 Mb 或 14 Mb。相比之下，TAMP 会根据各区域的瞬时状态，自适应地协同设计调度决策和通信量，从而更有效地利用资源。当系统受到信息年龄的限制时，所有算法的性能都会在极高速率下趋于饱和，而 TAMP 的自适应能力使其始终保持最高性能。

2）通信界的影响：在此，我们通过将长期通信预算 Γ_a 从 0.25 调整至 2.0 兆比特/时隙，研究其影响。需要特别指出的是，该预算是根据空间置信度掩码处理后的特征大小设计的，但位于紧接传输之前执行的 $32\times$ 压缩之前。所有其他参数均按照表 I 中的规定设置为默认值。图 7b 和图 8b 所示结果表明，TAMP 始终优于所有基线方法。尽管所有算法的性能都会随着预算增加而提升，并在约 $\Gamma = 1.25$ 兆比特/时隙附近达到平台期，但 TAMP 的优势在资源稀缺时最为明显。具体而言，在 $\Gamma = 0.75$ 兆比特/时隙的紧张预算下，TAMP 相较于性能最佳的基线方法实现了近 21% 的相对性能提升。这凸显了 TAMP 的基于李雅普诺夫的算法的有效性。该算法旨在智能管理长期约束，而相比之下，目光短浅的贪心基线方法在严格的预算限制下难以应对。

3) 传感器计算能力的影响：为评估算法在传感器侧计算能力变化时的鲁棒性，我们将随机特征提取延迟的均值从 10 毫秒调整至 50 毫秒。其他参数保持表 I 所示的默认设置。图 7c 和图 8c 所示结果表明，尽管所有算法的性能都随延迟增加而下降，TAMP算法始终保持最高的平均精度，而且随着处理延迟增大，其优势更加明显。例如，在 30 毫秒至 50 毫秒的较高延迟范围内，TAMP 相较于表现最佳的基线算法，性能提升了 18% 至 29%。

4）基站调度容量的影响：本实验测试了算法在基站并发调度容量方面的可扩展性，M。我们将 M 从 1 逐步增加到 10，其他参数均采用表 I 中的默认配置。图 10 所示结果表明，当 M从 2 增加到 4 时，TAMP 的性能始终优于所有基线方法，形成性能上界

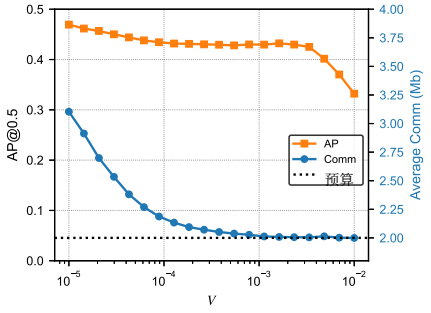

图9. 权衡参数 V 的影响。

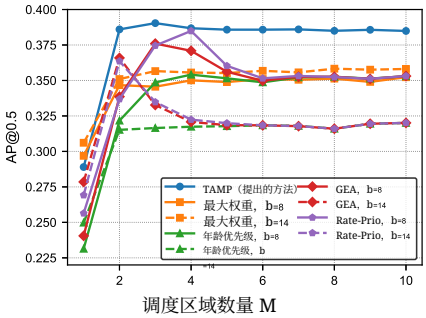

图 10. 基站容量 M 的影响。

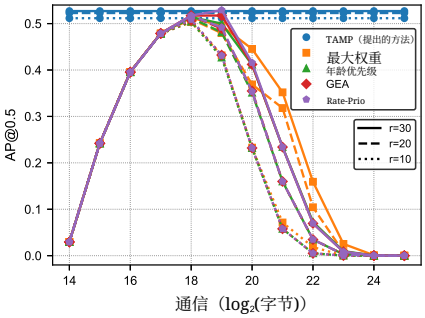

图11. 预设通信量 b 的影响。

。在 $M > 5$的平台区间内，TAMP 相较于表现最佳的基线方法，始终保持约 9.5% 的稳定性能增益。这表明，TAMP 能够通过智能选择最有价值的区域，有效利用额外的调度容量。

C. 调度权衡分析

1）权衡参数的影响 V：我们分析权衡参数 V 的作用。该参数用于平衡长期感知准确率（平均精度）与通信预算。如图9所示，较小的 V值会带来更高的稳态感知准确率，因为它较少关注即时通信成本。相反，较大的 V 值会使系统更快地收敛到通信预算。

2）自适应通信量分配的优势：我们展示了 TAMP 在自适应分配通信量方面的显著优势。在本实验中，基线方法被要求在每次传输中使用固定的通信量，并沿 x 轴改变该通信量。结果如图11所示。速率分布设置为均匀分布 $\mathcal{U}(1, x)$ 兆比特每秒。基线方法的性能对预设通信量高度敏感。随着通信量增大，更多特征得以传输，其性能曲线先上升；但当通信量过大导致任务时延增加时，性能曲线随之下降。这表明，任何固定通信量都只在有限的条件范围内最优。相比之下，我们的 TAMP算法在图中呈现为顶部近乎水平的曲线，表明其性能始终保持较高水平。这是因为它会在每个时隙自适应地计算并采用最优通信量，而非受限于预设值。

VI. 结论

本文探讨了CP中感知准确率与通信资源利用率之间的基本权衡。我们指出，准确建模这一权衡并制定智能调度策略，对于实现高效、可靠的性能至关重要。本文的主要贡献是提出了一个用于协同设计通信与感知的系统化框架。我们首先通过对真实世界数据集进行实证分析，刻画了平均精度、信息年龄与走廊和交叉路口场景中的通信量之间的非线性关系。基于此分析，我们推导出一个用于量化性能下降的通用惩罚函数。利用该函数，我们提出了时效性感知多区域优先级（TAMP）调度算法，该算法通过同时考虑实时信道条件和信息新鲜度，自适应地分配通信资源。大量数值实验验证了所提方法的优越性。结果表明，在各种配置下，TAMP始终优于年龄优先级、Rate-Prio、GEA和最大权重等基线方法，平均精度最高提升27%。此外，我们的分析凸显了TAMP自适应、高效分配通信资源，在检测准确率与通信开销之间实现平衡的能力。总之，本研究为CP系统中通信与感知的联合设计提供了一个具有坚实理论依据的框架。我们提出的惩罚函数和调度算法为实现高性能、高资源效率的CP提供了实用方案，为从自动驾驶到大规模智慧城市监测等更安全、更智能的应用铺平了道路。

附录A 引理1的证明

$\mathcal{P}1$ 的长期平均惩罚为：

$$\limsup_{K\to\infty} \frac{1}{K}\mathbb{E}_{\pi}\left[\sum_{k=0}^{K} f(h_k, \boldsymbol{b}_k)\right]. \tag{35}$$

我们将长期平均惩罚分解为各个间隔的总和。间隔定义为两个后续任务完成时间之间的时段。例如，第m个间隔是从时隙 k'_m 到 k'_{m+1}。因此，由式（35）可得：

$$\limsup_{K\to\infty} \frac{M_K}{K}\mathbb{E}_{\pi}\left[\sum_{k=k'_m}^{k'_{m+1}} f(h_k, \boldsymbol{b}_k)\right]. \tag{36}$$

第 m个间隔的长度为 T_m。设 h_{k_m} 为调度时隙 k_m处的信息年龄。设 $\boldsymbol{b}_{k_m}$ 为分配的通信量，在第 m个间隔内保持不变。设 d_{k_m}为从时隙 k_m开始的该任务的总时延。根据惩罚函数的几何图形，如

图2所示，式（36）中第 m个间隔内的累积惩罚可表示为：

$$\sum_{k=k'_m}^{k'_{m+1}} f(h_k, \boldsymbol{b}_k) = F(h_{k_{m+1}} + d_{k_{m+1}} + 1, \boldsymbol{b}_{k_m}) - F(d_{k_m}, \boldsymbol{b}_{k_m}), \tag{37}$$

该间隔的期望长度为：

$$T_m = h_{k_{m+1}} + d_{k_{m+1}} + 1 - d_{k_m}. \tag{38}$$

考虑长期平均性能时，稳态条件下的期望间隔时长为

$$\mathbb{E}_\pi[T] = \bar{h} + \bar{d} + 1 - \bar{d} = \bar{h} + 1. \tag{39}$$

根据基本更新理论，可得：

$$\lim_{K\to\infty} \frac{M_K}{K} = \frac{1}{\mathbb{E}_\pi[T]} = \frac{1}{\bar{h}+1}. \tag{40}$$

为了对离散累积惩罚建立一个易于处理的下界，我们利用 f 的积分，并且有以下不等式成立：

$$\sum_{x=0}^{h} f(x, \boldsymbol{b}) \geq \int_0^h \tilde{f}(x, \boldsymbol{b}) dx, \tag{41}$$

瞬时惩罚 $f(x, \boldsymbol{b})$ 是信息年龄 x 的非递减函数，因为信息越陈旧，产生的惩罚越大。因此，$F'(x, \boldsymbol{b}) = f(x, \boldsymbol{b}) \geq 0$。因此，$F(h, \boldsymbol{b})$ 是 h 的凸函数。

注意，$\boldsymbol{b}_{k_m}$ 独立于 $h_{k_{m+1}}$ 和 $d_{k_{m+1}}$。对长期平均值取期望，并将詹森不等式应用于 (37)，可得：

$$\begin{aligned}&\mathbb{E}_\pi[F(h_{k_{m+1}} + d_{k_{m+1}+1}, \boldsymbol{b}_{k_m})] - \mathbb{E}_\pi[F(d_{k_m}, \boldsymbol{b}_{k_m})] \\ &\geq \tilde{F}(\bar{h} + \bar{d} + 1, \boldsymbol{b}_{k_m}) - \mathbb{E}_\pi[F(d_{k_m}, \boldsymbol{b}_{k_m})].\end{aligned} \tag{42}$$

在平稳条件下，随机变量 h、d 和 $\boldsymbol{b}$ 在不同间隔 m 上同分布，因此我们省略下标 k_m。将 (40) 和 (42) 代入 (36)，可得长期平均惩罚的最终下界：

$$\bar{f} \geq \frac{\tilde{F}(\bar{h} + \bar{d} + 1, \boldsymbol{b}) - \mathbb{E}_\pi[F(d, \boldsymbol{b})]}{\bar{h} + 1}. \tag{43}$$

□

附录B 引理2的证明

问题 $\mathcal{P}2$ 的目标函数（其中 h 为优化变量）为：

$$\frac{1}{h}\left(\tilde{F}(h + \bar{d}, \boldsymbol{b}) - \mathbb{E}[F(d, \boldsymbol{b})]\right). \tag{44}$$

对于固定参数 $\boldsymbol{b}$ 和 d，$\mathbb{E}[F(d, \boldsymbol{b})]$ 被视为常数项。我们将证明以下函数的拟凸性：

$$y(h) = \frac{1}{h}\left(\tilde{F}(h + \bar{d}) - C\right), \quad h > 0, \tag{45}$$

其中 C 为常数。

根据瞬时惩罚的物理含义，信息价值损失会随着时间推移而增加，因此 $f(t)$是 t的非递减函数。这意味着累积惩罚 $\tilde{F}(h) = \int_0^h \tilde{f}(t)dt$ 满足：

$$\tilde{F}''(h) = \tilde{f}'(h) \geq 0. \tag{46}$$

因此，$F(h)$ 是凸函数。由仿射函数 $\tilde{}$ $\bar{}$ 复合定义的 $F(h + d)$ 也是凸函数。

函数 $y(h)$ 是拟凸函数，当且仅当对于每个 $\gamma \in \mathbb{R}$，其次水平集 $S_\gamma = \{h | y(h) \leq \gamma\}$ 都是凸集。对于给定的 γ，次水平集 S_γ 由以下不等式定义：

$$\frac{\tilde{F}(h + \bar{d}) - C}{h} \leq \gamma. \tag{47}$$

由于 $h > 0$，我们有：

$$\tilde{F}(h + \bar{d}) - \gamma h \leq C. \tag{48}$$

$\tilde{}$ $\bar{}$我们定义函数 $H(h) = F(h + d) - \gamma h$。第一项 $\tilde{}$ $\bar{}$term $F(h + d)$ 已被证明是凸函数。第二项 $-\gamma h$是线性函数，因此也是凸函数。

由于两个凸函数之和仍为凸函数，因此 $H(h)$ 是凸函数。次水平集 $S_\gamma = \{h | H(h) \leq C\}$ 是凸函数的次水平集。任何凸函数的次水平集始终是凸集。因此，$y(h)$ 是拟凸函数，$\mathcal{P}2$ 是一个拟凸优化问题。

□

附录 C 定理 1 的证明

为简化起见，我们省略下标 a。令 $L(Q_k) \triangleq \frac{1}{2}Q_k^2$ 为式 (22) 中定义的虚拟队列Q_k 的二次李雅普诺夫函数。首先通过分析队列长度平方的变化，可以对漂移进行界定：

$$\begin{aligned}Q_{k+1}^2 - Q_k^2 &= \left(\max\{Q_k + b_k - \Gamma, 0\}\right)^2 - Q_k^2 \\ &\leq (b_k - \Gamma)^2 + 2Q_k(b_k - \Gamma),\end{aligned} \tag{49}$$

其中，不等式由性质 $(\max\{x, 0\})^2 \leq x^2$ 得出。

对 $\frac{1}{2}(Q_{k+1}^2 - Q_k^2)$ 在给定Q_k 条件下取条件期望，可得漂移上界：

$$\Delta(Q_k) \leq \frac{1}{2}\mathbb{E}\left[(b_k - \Gamma)^2 \mid Q_k\right] + Q_k\,\mathbb{E}\left[b_k - \Gamma \mid Q_k\right]. \tag{50}$$

代入控制决策 $b_k = u_k b_k^*$ 并重新整理各项，可得：

$$\Delta(Q_k) \leq \underbrace{\frac{1}{2}\mathbb{E}\left[(u_k b_k^* - \Gamma)^2 \,\middle|\, Q_k\right]}_{\text{bounded by a constant } C} + Q_k\mathbb{E}[u_k b_k^* \mid Q_k] - Q_k\Gamma.$$

现在，在两边加上惩罚项，可得漂移加惩罚表达式的上界：

$$\begin{aligned}&\Delta(Q_k) - V\,\mathbb{E}[U(h_k, b_k^*)\,u_k \mid Q_k] \\ &\leq C + Q_k\mathbb{E}[u_k b_k^* \mid Q_k] - Q_k\Gamma - V\,\mathbb{E}[U(h_k, b_k^*)\,u_k \mid Q_k].\end{aligned}$$

为使每个时隙中的这一上界最小化，算法必须选择 u_k，以使不等式右侧最小化。相对于优化变量 u_k，项 C 和 $-Q_k\Gamma$ 为常数，因此可以将其去掉，从而得到式（25）中的所需结果。

□

参考文献

[1] W. Jiang、B. Han、M. A. Habibi 和 H. D. Schotten，“迈向6G之路：一项全面综述”，IEEE开放通信学会期刊，第2卷，第334–366页，2021年。[2] Z. Xiao、J. Shu、H. Jiang、G. Min、H. Chen 和 Z. Han，“克服遮挡：网联自动驾驶车辆中的感知任务导向信息共享”，IEEE Netw.，第37卷，229，2023 4，224 no. pp. – 。[3] Y. Han、H. Zhang、H. Li、Y. Jin、C. Lang 和 Y. Li，“自动驾驶中的协同感知：方法、数据集与挑战”，IEEE Intell. Transp. Syst. Mag.，第15卷，第6期，第131–151页，2023年。[4] L. Wang、J. Sun、Y. Sun、S. Zhou、Z. Niu、M. Jiang 和 L. Geng，“相关信息年龄约束下的基于分组的循环调度”，IEEE Trans. Inf. Theory，第71卷，2244，2025 3，2218 no. pp. – 。[5] T.-H. Wang、S. Manivasagam、M. Liang、B. Yang、W. Zeng 和 R. Urtasun，“V2VNet：用于联合感知与预测的车对车通信”，载于《欧洲计算机视觉会议》（ECCV）。Springer，2020年，第605–621页。[6] R. Xu、C.-J. Chen、Z. Tu 和 M.-H. Yang，“V2X-ViTv2：改进用于车联网协同感知的视觉变换器”，IEEE Trans. Pattern Anal. Mach. Intell.，第47卷，662，2025 1，650 no. pp. – 。[7] Y. Xie、R. Xu、T. He、J.-J. Hwang、K. Luo、J. Ji、H. Lin、L. Chen、Y. Lu、Z. Leng 等，“S4-Driver：具有时空视觉表征的可扩展自监督驾驶多模态大语言模型”，载于《IEEE计算机视觉与模式识别会议论文集》（CVPR），2025年，第1622–1632页。[8] X. Gao、R. Xu、J. Li、Z. Wang、Z. Fan 和 Z. Tu，“STAMP：可扩展的任务与模型无关的协同感知”，载于《国际学习表征会议论文集》（ICLR），2025年。 [在线]。可访问：https://openreview.net/forum?id=8NdNniulYE [9] Q. Chen、S. Tang、Q. Yang 和 S. Fu，“Cooper：基于三维点云的网联自动驾驶车辆协同感知”，载于《IEEE分布式计算系统国际会议论文集》（ICDCS）。IEEE，2019年，第514–524页。[10] E. Arnold、M. Dianati、R. De Temple 和 S. Fallah，“利用基础设施传感器在驾驶场景中进行三维目标检测的协同感知”，IEEE Trans. Intell. Transp. Syst.，第23卷，1864，2020 3，1852no. pp. – 。[11] S. Zhou、Y. Jia、R. Mao、Z. Nan、Y. Sun 和 Z. Niu，“面向智能无人系统协同感知的任务导向无线通信”，IEEE Netw.，第38卷，第6期，第21–28页，2024年。[12] S. Kaul、R. Yates 和 M. Gruteser，“实时状态：应多久更新一次？”，载于《IEEE计算机通信会议论文集》（INFOCOM）。IEEE，2012年，第2731–2735页。[13] J. Sun、L. Wang、Z. Nan、Y. Sun、S. Zhou 和 Z. Niu，“利用边缘辅助调度优化状态更新的任务特定时效性”，IEEE J. Sel. Areas Inf. Theory，第4卷，第624–638页，2023年。[14] Y. Hu、X. Pang、X. Qin、Y. C. Eldar、S. Chen、P. Zhang 和 W. Zhang，“多智能体协同感知中的务实通信”，arXiv预印本 arXiv:2401.12694，2024年。[15] Z. Fang、J. Wang、Y. Ma、Y. Tao、Y. Deng、X. Chen 和 Y. Fang，“R-ACP：利用鲁棒任务导向通信实现实时自适应协同感知”，IEEE J. Sel. Areas Commun.，第1 1页，2025 – 。[16] X. Qin、Y. Li、X. Song、N. Ma、C. Huang 和 P. Zhang，“任务导向通信中计算密集型状态更新的信息及时性”，IEEE J. Sel. Areas Commun.，第41卷，第3期，第623–638页，2022年。[17] A. E. Kalør 和 P. Popovski，“利用多个无线传感器的观测对动态源进行及时监测”，IEEE/ACM Trans. Netw.，第31卷，第3期，第1263–1276页，2022年。[18] X. Qin、Y. Li、N. Ma、Y. Zhang、K. Han、L. Meng 和 P. Zhang，“无人机边缘计算系统中的面向及时性的异步任务卸载”，IEEE Trans. Netw. Sci. Eng.，第11卷，第1期，第900–912页，2023年。[19] X. Zheng、S. Zhou 和 Z. Niu，“远程控制系统中用于上下文感知及时状态更新的信息紧迫度”，IEEE Trans. Wireless Commun.，第19卷，第11期，第7237–7250页，2020年。[20] X. Xie 和 H. Wang，“在边缘计算赋能的物联网系统中，最小化使用信息年龄，以刻画相关数据的新鲜度与可用性”，IEEE Trans. Mobile Comput.，第23卷，第5期，第5644–5659页

，2023年。

[21] X. Li ，S. Zh ang, Y. H$_{uang,}$ X. Ma, Z. W$^{ang, an}$ d H. L uo，“Toward s 在网络边缘提供及时视频分析服务，”IEEE移动计算汇刊，2024年。[22] J. Hou、P. Yang、X. Dai、T. Qin 和 F. Lyu，“提升车载边缘网络中基于激光雷达的协同感知准确率，”IEEE Trans. Intell. Transp. Syst.，2025年。[23] Y. Jia、Y. Sun、R. Mao、Z. Nan、S. Zhou 和 Z. Niu，“C-MASS：采用二阶拓扑近似的协同感知组合式移动性感知传感器调度，”IEEE Trans. Veh. Technol.，pp. 1–17, 2025年。[24] Z. Xiao、J. Shu、H. Jiang、G. Min、H. Chen 和 Z. Han，“面向自动驾驶的协同计算感知任务卸载，”IEEE J. Sel. Areas Commun.，vol. 41, no. 2, pp. 457–473, 2022年。[25] B. Zhou 和 W. Saad，“具有非均匀状态数据包大小的物联网中的最小信息年龄，”IEEE Trans. Wireless Commun.，vol. 19, no. 3, pp. 1933–1947, 2019年。[26] H. Tang、J. Wang、L. Song 和 J. Song，“功率约束下的信息年龄最小化：多状态时变信道中的多用户机会调度，”IEEE J. Sel. Areas Commun.，vol. 38, no. 5, pp. 854–868, 2020年。[27] X. Xie、H. Wang 和 M. Weng，“用于优化计算年龄赋能物联网的强化学习方法，”IEEE Internet Things J.，vol. 9, no. 4, pp. 2778–2786, 2021年。[28] M. Sun、X. Xu、X. Qin 和 P. Zhang，“面向物联网网络的AoI与能耗感知无人机辅助数据采集：一种深度强化学习方法，”IEEE Internet Things J.，vol. 8, 17 289, 2021 24, 17 275 no. pp. – 。[29] R. Hao、S. Fan、Y. Dai、Z. Zhang、C. Li、Y. Wang、H. Yu、W. Yang、J. Yuan 和 Z. Nie，“RCooper：用于路侧协同感知的真实世界大规模数据集，”发表于 IEEE/CVF计算机视觉与模式识别会议（CVPR）论文集，2024年，pp. 22 347–22 357。[30] F. Wu 和 L. Chen，“无线传输导致拖尾的编码计算延迟优化，”IEEE Wireless Commun. Lett.，vol. 9, no. 7, pp. 1124–1128, 2020年。[31] F. Zhang、Y. Sun 和 S. Zhou，“具有随机任务到达的异构工作节点上的编码计算，”IEEE Commun. Lett.，vol. 25, no. 7, pp. 2338–2342, 2021年。[32] Y. Sun、F. Zhang、J. Zhao、S. Zhou、Z. Niu 和 D. G¨und¨uz，“共享异构工作节点上的编码计算及通信时延，”IEEE Trans. Signal Process.，vol. 70, pp. 3371–3385, 2022年。[33] Y. Hu、S. Fang、Z. Lei、Y. Zhong 和 S. Chen，“Where2comm：通过空间置信度图实现通信高效协同感知，”发表于神经信息处理系统进展大会（NeurIPS）论文集，第35卷，2022年，pp. 4874–4886。[34] M. Neely，《随机网络优化及其在通信与排队系统中的应用》。Morgan & Claypool Publishers，2010年。[35] S. Wei、Y. Wei、Y. Hu、Y. Lu、Y. Zhong、S. Chen 和 Y. Zhang，“通过鸟瞰视图流实现异步鲁棒协同感知，”发表于神经信息处理系统进展大会（NeurIPS）论文集，第36卷，2023年，pp. 28 462–28 477。[36] J. Wang 和 T. Nordstr¨om，“利用异步特征融合实现时延鲁棒的协同感知，”发表于 IEEE/CVF冬季计算机视觉应用会议（WACV）论文集。IEEE，2025年，pp. 1–10。[37] D. Yu、J. You、X. Pei、A. Qu、D. Wang 和 S. Jia，“Which2comm：面向三维目标检测的高效协同感知框架，”arXiv预印本 arXiv:2503.17175，2025年。[38] F. Granda、L. Azpilicueta、M. Celaya-Echarri、P. Lopez-Iturri、C. Vargas-Rosales 和 F. Falcone，“城市环境中的空间V2X交通密度信道特征分析，”IEEE Trans. Intell. Transp. Syst.，vol. 22, no. 5, pp. 2761–2774, 2021年。[39] T. Zhang、T. Gong、M. Lyu、N. Guan、S. Han 和 X. S. Hu，“通过时隙共享实现实时无线网络中的可靠动态数据包调度，”IEEE移动计算汇刊，vol. 22, no. 11, pp. 6723–6741, 2023年。[40] Q. Shu、J. Chen、Y. Lu、Y. Zhang 和 Y. Wang，“CoRange：面向多智能体感知的协同距离感知自适应融合，”IEEE Trans. Intell. Veh.，vol. 10, no. 8, pp. 4316–4329, 2025年。[41] F. Arena 和 G. Pau，“车载通信概述，”Future Internet，vol. 11, no. 2, 2019年。 [在线]。可访问：https: // www.mdpi.com/ 1999 5903 11 2 27 - / / / Z. Qin、Z. [42] Wei、Y. Qu、F. Zhou、H. Wang、D. W. K. Ng 和 C.-B. Chae，“面向空地协同移动边缘计算的信息年龄感知调度，”IEEE Trans. Wireless Commun.，vol. 22, no. 5, pp. 2989–3005, 2022年。