



面向语义通信网络的能效跨层优化

余开文, 樊仁和, 苟文龙, 俞传航, 武刚*

电子科技大学通信抗干扰全国重点实验室, 成都 611731

* 通信作者. E-mail: wugang99@uestc.edu.cn

收稿日期: 2023-09-30; 修回日期: 2023-12-28; 接受日期: 2024-02-01; 网络出版日期: 2024-04-10

中央高校基本科研业务费专项资金 (批准号: 2242022k60006) 资助项目

摘要 语义通信关注传输信息的内在含义, 通过语义提取可显著减少需要传输的数据量, 提高通信效率, 在未来智能设备通信场景中展现出巨大的潜力. 然而, 深度学习使能的语义编解码进一步加剧传统通信的能量消耗. 针对该问题, 本文提出一种联合跨层优化框架, 并设计了一种语义能效指标来评估用户的体验质量和全局系统的能量损耗. 将该优化过程建模为部分可观测的马尔可夫过程, 联合优化物理层中的功率控制和语义层中的语义压缩配置: 功率分配用于消除小区间干扰, 语义压缩等级配置用于优化语义传输效率. 仿真结果表明, 所提框架和算法能够有效解决语义层和物理层的联合优化问题.

关键词 资源分配, 语义通信, 语义感知网络, 能量效率, 多智能体强化学习

1 引言

自 Shannon 和 Weaver 提出语义通信概念以来^[1], 该领域经历了较长发展期. 近年来, 在深度学习的推动下, 语义通信取得了显著的研究成果, 再次成为学术界的研究焦点^[2~4]. 在未来无线网络驱动的智能场景中, 视频图像数据爆发式增长, 大量的视觉业务和沉浸式业务将带来巨大的资源压力, 语义通信由于其高效的传输能力, 成为国际电信联盟 (international telecommunication union, ITU) 规划的未来总体愿景与潜在关键技术之一. 语义通信关注如何准确传输信息内在的含义, 而不是准确传输每个符号^[5,6]. 与传统通信相比, 语义通信具有三大优势^[7]: (1) 进一步降低信息冗余^[8]. 随着通信规模的扩大, 通信数据海量增长, 语义通信先理解后传输的特点让信源和信宿能更好地理解所需传递的内容本身, 从源头上避免大量冗余传输; (2) 进一步提高智能设备间的通信效率^[9,10]. 未来具备智能处理能力的通信实体将占用大量通信资源. 智能体之间的通信主要以任务为导向. 语义通信能够更高效地使接收方理解传输的含义, 完成指示性和推理性任务; (3) 进一步提高安全性能^[7]. 语义通信依据收发智能体双方的知识库来进行语义推理, 非信宿智能体即使接收到信息, 也无法准确理解信息所携带的含义, 从而达到安全通信的目的.

引用格式: 余开文, 樊仁和, 苟文龙, 等. 面向语义通信网络的能效跨层优化. 中国科学: 信息科学, 2024, 54: 758–776, doi: 10.1360/SSI-2023-0283
Yu K W, Fan R H, Gou W L, et al. Cross-layer energy efficiency optimization for semantic communication networks (in Chinese). Sci Sin Inform, 2024, 54: 758–776, doi: 10.1360/SSI-2023-0283

1.1 语义通信研究现状

1.1.1 端到端语义通信

端到端语义通信系统按照信源模态类型可分为文本、语音和图像3种形式。

文本语义通信系统已有广泛研究,然而文本数据量有限,无法完全展示语义通信的优势。语义通信需要与新的通信场景结合,如远程医疗、全息网络、增强现实等,充分发挥其高效的信息压缩能力。得益于自然语言处理技术强大的分析和理解能力,文本语义通信可以分为两大类:基于Transformer模型^[11,12]和基于长短记忆网络(long short term memory, LSTM)模型^[13,14]。Xie等^[11]以Transformer为基础,提出了DeepSC框架,旨在以最小误差恢复文本语义信息。Transformer在联合信源信道编码方案上表现出巨大的潜力。通过对Transformer基础结构进行微调,语义编解码器能够适应信道环境,在低信噪比下仍然表现优异,具有良好的鲁棒性。Zhou等^[15]提出一种基于一般化Transformer的语义编解码结构,来适应每个传输语句中所蕴涵的语义信息差异。此外,将混合重传机制等传统通信技术应用到语义通信系统也引起了广泛兴趣,这种做法已被证明能有效提升通信效率^[16,17]。

不同于语义通信系统的文本传输,语音具有更复杂的表现特征,如语速、音量、声调、方言等,不同特征的语音可能表达相同的意思。一般的做法是将语音转化文本进行处理。然而,相同的文本信息用不同的语调表达会产生不同的意思。因此,语音语义传输更为复杂且更难处理^[18,19]。语音语义通信系统类似于文本语义通信系统,同样存在难以发挥语义通信优势的问题。传统通信中,语音信号传输已经十分成熟,语音语义通信系统的优势及应用场景仍然需要进一步明确。

图像语义通信架构与文本语义通信架构类似,主要差异在于所使用的神经网络类型不同。文本语义通信中常用的全连接层无法捕捉图像的空间结构,而卷积神经网络(convolutional neural networks, CNN)通过卷积和池化操作自动学习图像在各个层次上的特征。因此,CNN在图像语义通信系统中被广泛使用。Bourtsoulatzis等^[20]利用CNN首次提出联合信源信道编码(joint source-channel coding, JSCC)的端到端图像传输系统,与传统图像传输方法相比,所提算法能够实现更好的性能。Lu等^[21]重新审视了学习的过程,允许对任何用户定义的语义测量进行高效的学习,解决不可微语义优化问题。Huang等^[22]利用生成对抗网络(generative adversarial network, GAN)来进行语义编码,设计了一个分级细化的语义编码模型,获得了优于传统压缩算法的性能。Yu等^[23]首次考虑双向语义通信问题,利用GAN来模拟信道,并用于收发双方语义编解码的在线训练,用于解决双向语义通信的在线训练开销问题。

无论考虑哪种信源模态,语义编解码的能力都依赖于收发智能体双方的背景知识^[24,25]。背景知识库的设计以及在知识不对称情况下的语义通信系统是语义通信需要解决的关键问题之一。Zhang等^[26]考虑收发两端具有相似的背景知识库,发射端不知道接收端的具体任务的情景,提出以任务为导向的动态语义通信系统,在传统语义编码方案的前端集成数据自适应网络,用来解决收发双方的背景知识差异问题。收发两端的背景知识库相似度越高,其恢复的性能就越好,数据自适应网络的训练时间就越短。

1.1.2 多用户语义通信系统

为了满足实际通信需求,端到端语义通信系统需进一步考虑多用户场景。Hu等^[27]利用深度神经网络设计了一种一对多语义通信系统,利用不同用户的语义特征进行用户区分,在低信噪比下获得了良好的性能。Wang等^[28]以语义相似度为评价指标,将注意力机制融入特征提取,设计了一个基于强化学习的语义通信优化框架。该方法能够评估语义信息间的重要性,建立语义信息的重要性分布关系,

并通过动态调整学习率来增强模型收敛性能. Zhang 等^[29] 针对多用户语义通信系统的目标识别问题, 提出利用用户间的数据相关性来实现多用户协作的目标识别. 然而以上研究仍处于起步阶段, 语义通信系统中通信对象如何切换, 如何建立新的连接, 如何设计多对多的语义通信系统仍是值得研究的方向.

1.1.3 面向 IoT 设备的语义通信

语义通信能在少量资源开销下准确的传输高质量信息, 其特性符合人与机器、机器与机器之间通信的特点, 满足面向特定智能任务的智能场景下的通信需求. 在机器类通信中, 由于硬件设备的计算能力和存储能力受限, 无法部署复杂的神经网络, 而联邦学习能在云端收集数据并训练模型, 然后将训练好的模型下发给指定设备, 从而解决数据缓存和训练开销等难题. Xie 等^[30] 面向物联网场景, 利用云平台进行模型训练, 通过物联网设备进行数据收集和传输. 同时通过删除较低权重来压缩模型, 降低模型冗余, 减小模型占用空间, 使其更易部署在物联网设备中. Wu 等^[31] 提出通过语义信息来指导目标检测的训练过程, 利用迁移学习解决多任务间语义编码参数无法共享等问题. Pokhrel^[32] 针对工业 4.0 场景中的自动化需求, 设计了一种基于联邦学习和异步优势动作评价算法 (asynchronous advantage actor-critic, A3C) 网络的语义通信架构, 该架构可通过先前学习到的知识, 快速适应不断变化的环境和系统语义.

1.1.4 语义通信的资源分配

尽管端到端语义通信系统获得了大量的研究并取得了显著的进展, 但针对语义通信网络的资源分配问题仍然研究较少^[33,34]. Liu 等^[35] 考虑如何最优化压缩和传输语义信息来完成后续智能任务, 提出了一种联合语义压缩和资源分配算法来最大化终端任务完成概率. Zhang 等^[36] 针对以任务为导向的语义通信资源分配问题, 提出了基于深度确定性策略梯度 (deep deterministic policy gradient, DDPG) 的强化学习算法, 以系统的语义压缩率、功率和带宽为优化目标, 最大化系统的任务完成率. 并通过动态分配语义压缩率, 能够在保证完成任务的情况下减小数据传输消耗. Farshbafan 等^[37] 关注以任务为导向的语义通信系统, 成功建模并解决了在任务执行时间和传输成本最小的情况下, 如何选择能够完美描述观测结果的最小信念集优化问题. Yang 等^[38] 针对下行场景中如何能量高效地进行速率分割的问题, 以计算、时延和传输功率为约束, 提出了一种交替算法来最小化系统的能量损耗. Yan 等^[39] 重新思考了语义感知的资源分配问题, 以文本语义通信为研究对象, 首次定义了语义速率评价指标, 并根据信道状况和传输的语义符号数量来优化资源分配. 进一步地, 他们^[40] 引入多模态语义传输的资源分配场景, 提出了一种基于语义感知的资源优化算法来改善系统的用户体验质量 (quality of experience, QoE) 性能.

1.1.5 语义通信的功耗 – 安全折中问题

目前, 对于语义安全通信的能量效率问题还没有统一的标准进行评估. 如何平衡语义通信的安全性性能与功率损耗, 以及如何基于语义方案来降低功率损耗都是亟待解决的问题. 在现有的语义安全通信研究领域中, 学者们已经积极地探讨并关注到了功率损耗的问题^[41]. 随着无人机制造成本的降低, 其在物联网产业中的应用越来越广泛. 虽然无人机能够拓宽物联网的通信范围, 但这同样带来了电池能效的问题. 为了解决物联网中数据量过大、频谱效率低和安全性不足等问题, 语义通信提供了一种有效的解决方案. Gu 等^[42] 在语义互联网的框架下, 对无人机感知时间、飞行速度和覆盖范围等通信能效指标提出了优化算法, 并通过仿真展现了所提方案的卓越性能表现. Fensel 等^[43] 提出了一种基于

语义通信的智能家居系统,重点评估了面向消费者的节能终端系统的功耗和隐私安全性能. Park 等^[44]提出了一种节能、轻量级、低延迟的算法,用于构建在语义层面与观察到的现象保持一致性的隐形活动. 通过使用该隐形活动,可以灵活地控制虚假数据传输的数量,实现能量效率和隐私保护之间的权衡. 此外,该方法支持低延迟的真实数据传输,同时也能有效地抵抗无线侦听攻击,降低其成功概率. Yang 等^[38]研究了将私有消息和公共消息分开传输的节能语义安全通信框架,提出了一种功耗优化算法,该算法综合考虑了计算能量与传输能量,并用数值结果验证了该算法的有效性. 在无线传感器网络 (wireless sensor network, WSN) 中,能量效率同样也是一个重要的性能指标. Liu 等^[45]总结了目前已有的各种 WSN 功耗优化方案,针对 WSN 提出了一种基于语义的功耗降低策略. Bispo 等^[46]提出了一种基于中间件和本体复合方式来改善 WSN 功耗的方法. 该中间件能够处理数据和应用程序的异构性,为数据提供了一个形式化和明确的语义,不仅减少了发送消息的数量,还使用了占空比方案来节省能量开销,最终实现 30% 以上的节能效果.

1.2 语义通信 – 性能指标与优化策略探讨

尽管语义通信有上述优势,但仍然缺乏明确的性能评价指标. 传统优化指标,如系统整体的和速率、误码率等,无法反应语义通信中差异化通信的特点. 语义通信网络需要新的评价指标以评估整体性能. 主要可从以下两个方面来考虑:

其一,未来智能终端设备具有不同的通信需求,根据执行业务的不同,其所需的传输速率和传输精度也存在差异. 因此,可联合反应语义速率和语义精度的指标需要进一步被挖掘. 另一方面,语义通信更多地被期望于提高用户或智能终端的任务完成概率. 对用户来说,该任务可以是参加一场视频会议或开展一种增强现实/虚拟现实业务,从而将语义速率和语义准确度指标作为当前通信场景的评价指标. 对智能体来说,目标可以是执行某个动作或完成某项任务,从而将动作规范性和任务完成程度作为当前通信场景的评价指标. 可见,语义通信自然地与用户满意程度建立起联系,反应语义通信系统的用户 QoE 评价指标需要进一步被研究.

其二,能量损耗 (energy consumption, EC) 问题日益突出,基于深度学习的语义编解码需要大量数据用于训练,进一步加剧能源开销. 如何建立高能效的通信网络一直是通信领域研究中的重点问题. 首先,能源成本一直是运营商支出的重要组成部分,运营商致力于开发高效的通信网络以节省支出. 更重要的是,全球都致力于实现碳中和目标,期望以新技术来引领低碳发展的新格局. 考虑未来通信的可持续发展,信息与通信技术 (information and communications technology, ICT) 行业致力于实现绿色第六代移动通信系统 (the 6th generation mobile communication technology, 6G) 和更环保的第五代移动通信系统 (the 5th generation mobile communication technology, 5G). 因此,如何在保证网络性能的前提下降低功耗,如何对系统功耗建模,以及如何动态调整功率控制策略是当前迫切需要解决的问题.

综上所述,语义通信系统将给经典的通信体系带来全新的问题和挑战,绿色语义通信网络首要面临着以下 3 个问题:

- 问题一: 在哪些应用场景中,语义通信能发挥更大的潜力?
- 问题二: 引入深度学习的语义通信系统的能效指标应如何被定义?
- 问题三: 针对语义通信网络,如何构建性能 – 功耗兼顾的跨层优化框架?

为了回答上述 3 个问题,本文将阐述语义通信潜在的应用场景,分析面向语义通信系统的跨层资源优化框架,探讨从传统通信到语义通信的资源优化目标与方案. 同时,本文以优化物理层中的功率控制策略和语义层中的语义压缩等级配置为例,针对多用户语义通信系统,设计了一个基于多智能体强化学习 (multi-agent reinforcement learning, MARL) 的最大化能量效率 (energy efficiency, EE) 的鲁棒

资源分配方案来说明联合语义-物理资源优化的可行性及有效性. 对多用户语义通信下行传输场景, 考虑智能设备不同的最小语义速率、语义精度约束以及最大发射功率约束, 基于动态信道, 建立了一个联合功率分配和语义压缩的鲁棒高效资源分配模型, 该模型是一个多变量, 多维度优化问题. 同时, 本文提出一种新的可反应语义准确度、语义速率和能量损耗的评价指标, 为了解决上述优化问题, 本文将建模为部分可观测马尔可夫决策过程 (partially observable Markov decision process, POMDP), 并采用基于离线学习在线决策的分布式多智能体强化学习算法求解. 仿真结果表明, 所提策略具有良好的收敛性和鲁棒性.

2 语义通信网络

2.1 语义通信的应用场景

语义通信系统最重要的问题是明确其应用场景. 三大可能的应用场景如图 1 所示, 分别为智能物联网、智能车联网和智慧工厂场景.

语义通信在物联网场景下实时数据与控制信息的传输上展现出显著的应用潜力^[47]. 智能机器人、无人机以及 VR/AR 眼镜等^[48] 多种智能设备将赋予物联网更先进且多样化的功能. 在该场景中, 物联网设备将实时监控系统状态以及工作环境, 并将数据通过无线网络实时上传到移动边缘服务器用于计算和数据分析, 从而实现动态的智能化控制. 因此, 物联网设备需要实时压缩数据并传输到边缘服务器, 从而根据数据分析结果下发控制信息.

语义通信另一个应用场景是智能车联网中的动态环境感知和智能控制. 目前, 多个国家和地区将自动驾驶作为国家战略目标之一. 车用无线通信技术 (vehicle to everything, V2X) 等车联网技术在支撑自动驾驶方面发挥着至关重要的作用. 特别地, V2X 技术使得智能体间的信息传输成为可能. 在 V2X 场景中, 车辆可以感知当前环境并预测行驶轨迹、交通流量和网络拥堵情况. 车辆上搭载的多个无线传感器, 如毫米波雷达、红外雷达、高清摄像头等将实时观测周围环境信息, 同时也会产生大量的数据. 车辆可能需要将部分多模态数据上传到边缘服务器进行深入分析或优化处理. 多模态语义通信系统能够实现高效的数据传输和模态信息融合^[49], 赋能智能车联网的发展.

智慧工厂依赖大量的机器人和少量控制人员维持正常运行. 高效的人与机器, 以及机器与机器之间的通信显得至关重要. 在机器与机器的通信中, 中央服务器将实时采集机器的关键性能指标及环境数据, 如功耗、磨损情况、温度等, 并对其进行语义分析, 从而下发语义控制指令. 在人与机器的通信中, 人可以通过动作指引机器人的行动, 或通过语音下达相关命令, 机器人接收相关信息并提取其语义特征, 从而完成指定任务. 以任务为导向的语义通信系统能够有效提升智慧工厂的运行效率, 降低通信开销, 高效完成生产任务. 该部分内容对 1.2 小节中的问题一进行了回答.

2.2 语义通信评价指标

语义通信的核心是确保接收端能够对发射端传递的信息进行精确的含义解释, 相同的传输消息所蕴含的语义信息对不同的接收方具有差异性. 现有无线通信系统依据香农经典信息论, 将系统整体的速率、误码率等传统参数作为优化指标, 无法反映语义通信智能场景下的任务差异性和多样化的特点. 语义通信系统需要新的指标来评价整体性能.

关于语义精度评价问题, 针对不同的数据模态, 不同的精确度评价指标被用于语义通信系统^[5]. 在文本语义传输的通信系统中, 基于双语评估评价 (bilingual evaluation understudy, BLEU) 的性能度量指标被用于评价收发双方获得的文本信息差异. 基于相似度比较的方法通过测量发送端文本和接




图 1 语义通信网络的应用案例

Figure 1 Use cases of semantic communications

收端恢复文本之间的语义距离,从而评价接收端信息的质量情况,此方法能反映出语义通信的失真程度^[50,51]. 基于变换器的双向编码器表示技术 (bidirectional encoder representations from transformers, BERT) 评价被用于计算语句之间的相似性. BERT 模型是由数百万数据训练而成,具有较为完备的语义知识库,能够在不同语境下有效地生成多样的语义向量,从而更加准确地反映语句之间的差异. 图像语义通信系统的评价指标主要源自图像处理领域,包括峰值信噪比 (peak signal-to-noise ratio, PSNR)^[20]、结构相似性 (structure similarity index measure, SSIM)^[23] 和图像识别率^[52]. 评价语音语义通信的指标包括两种:源失真比 (source to distortion ratio, SDR) 和语音失真的知觉评价 (perceptual evaluation of speech quality, PESQ)^[53]. SDR 主要比较原始语音信号和恢复信号之间的误差. 另一方面,国际电信联盟则推荐 PESQ 作为语音的评价指标,这一方法侧重于测量接收方的感知质量,从而为语音语义通信评价提供了一个不同的考量维度.

2.3 语义能效度量指标

尽管 3GPP 协议中已经设计了大量的能量节省算法, 但现有无线通信系统的能量损耗仍存在压缩空间^[54], 为推进节能降碳工作, 我国已启动“东数西算”等工程并开始试点运行“零碳”5G 基站^[55]. 未来无线通信系统将需要更高的吞吐量和海量的智能设备连接来满足不同的应用需求, 进一步加剧能量损耗, 高效的节能方法需要被进一步研究. 与此同时, 现有语义通信的优越性来自基于深度学习的编解码技术, 高性能的语义编解码需要大量的历史数据用于训练. 由于训练数据和超参数的快速扩张, 人工智能的耗电量在 2012~2018 年期间增加了 300000 倍, 即每 3.4 个月电力消耗翻一番^[56]. 据统计, 2021 年国内数据中心的耗电量就已占到了全社会用电量的 2.6%^[55]. 因此, 语义通信系统的能效指标不仅要考虑传统通信系统中的硬件损耗和传输损耗, 同时要考虑语义通信网络的训练和计算开销. 语义能效指标可以被定义为

$$EE = \frac{T_s}{P_{BS} + P_{UT} + P_{AI}}, \quad (1)$$

其中 P_{BS} 表示基站的硬件功耗, P_{UT} 表示终端的硬件功耗, P_{AI} 表示用于语义编解码的训练和计算功耗. T_s 表示语义通信系统的传输性能, 对于端到端语义传输, 可以是语义传输准确度, 对于语义通信网络, 可以是语义传输速率, 也可以是用户满意程度. 该部分内容对 1.2 小节中的问题二进行了回答.

2.4 语义能效跨层优化框架

在语义通信系统中, 智能设备完成智能任务需要利用多维度的资源. 例如, 利用底层物理资源用于数据传输, 利用算力资源用于决策推理, 利用缓存资源用于语义编解码模型下载. 底层物理传输到顶层任务执行的每个维度的资源和环境状态都是动态变化的, 如何对传统通信层面和语义层面进行跨层优化设计, 以解决语义通信系统中的动态多维资源优化问题是一个重大挑战. 如图 2 所示, 本小节展示了所提出的语义通信系统的跨层优化结构, 主要分为底层环境和数据信息、物理层、语义层、网络层, 以及对应各层的功耗模型. 其中底层环境主要包括物理环境、网络环境和语义环境, 另外 3 层都依靠该层的信息进行决策优化. 物理环境主要包括无线信道衰落、多普勒 (Doppler) 频移、用户间干扰强度等, 主要反应无线通信的物理因素, 用于物理层的参数优化以改善无线环境的衰落等影响. 网络环境主要包括网络拥塞、网络吞吐量、用户满意度等, 主要反应智能网络的服务性能, 例如网络速率是否正常、用户体验满意度是否达标等, 用于另外 3 层的参数优化以改善整体网络环境. 而语义环境主要反应当前场景的语境信息, 相同的内容在不同的语境中具有不同的语义信息, 语义环境主要用于改善语义层的语义编解码能力. 另一方面, 数据信息主要包括模型的结构、超参数信息和历史训练数据, 数据信息涉及到通信网络整体的信息安全. 此外, 物理层的主要任务包括功率分配、波束赋形和关联节点等, 负责传输信息; 语义层的主要任务包括语义编解码、背景知识库匹配等, 负责语义提取; 网络层的主要任务包括任务卸载、缓存分配和算力分配等, 负责整个语义通信网络的资源分配. 在具体跨层优化框架中, 除考虑上述的优化目标外, 与之对应的, 还需额外考虑系统功耗所带来的影响, 具体包括网络层的路由功耗、语义层的训练功耗、物理层的传输功耗以及硬件功耗. 将该功耗指标与多维资源联合优化, 可实现性能-功耗兼顾的语义通信网络. 该部分内容对 1.2 小节中的问题三进行了回答.

3 系统模型及问题描述

考虑多小区干扰的下行语义通信场景, 通信系统中部署 M 个蜂窝小区, 假设每个蜂窝小区中有一个用户, 不同小区工作在相同的频段, 因此存在小区间干扰. 中央控制器用于信令交换, 定义基站集合




图 2 语义通信网络的跨层优化设计

Figure 2 Cross-layer optimization design for semantic communication networks

为 $\mathcal{M} = \{1, 2, \dots, M\}$, $\forall m \in \mathcal{M}$. 每个基站作为独立的智能体, 拥有一定的自我决策能力和信号处理能力. 本文考虑文本语义传输, 在各个基站和相应的终端用户侧分别部署 DeepSC 的语义编解码器^[11], 基站将待发送文本信息通过语义编码器 (semantic encoder, SE) 映射为语义信息, 而终端用户通过相应的语义解码器将接收到的语义信息还原为初始文本内容. 考虑不同小区间干扰, 第 m 小区中的终端下行传输的信干噪比 (signal-to-interference-and-noise ratio, SINR) 为

$$\gamma_m(t) = \frac{\left| \sqrt{p_m(t)} \mathbf{h}_{m,m}^\dagger(t) \right|^2}{\sum_{j \neq m} \left| \sqrt{p_j(t)} \mathbf{h}_{m,j}^\dagger(t) \right|^2 + \sigma^2}, \quad (2)$$

其中, $p_m(t)$ 表示在时间 t 时刻的基站传输功率, $\mathbf{h}_{j,m}^\dagger(t)$ 表示基站 m 到终端 j 之间的信道模型, σ 表示信道的物理噪声方差. 本文采用块衰落信道模型, 在 t 时刻基站 m 到终端 j 的信道响应可以表示为

$$\mathbf{h}_{j,m}(t) = \beta_{j,m} |\mathbf{g}_{j,m}(t)|^2, \quad (3)$$

其中 $\mathbf{g}_{j,m}(t)$ 表示基站 m 和终端 j 间的小尺度瑞利衰落因子, $\beta_{j,m}$ 表示基站 m 和终端 j 之间的大尺度衰落因子. 将小尺度瑞利衰落表示成一阶复数高斯马尔可夫 (Gauss-Markov) 过程:

$$\mathbf{g}_{j,m}(t+1) = \rho \mathbf{g}_{j,m}(t) + \sqrt{1 - \rho^2} \mathbf{e}_{j,m}(t), \quad (4)$$

其中 $\mathbf{e}_{j,m}(t)$, for $t = 0, 1, 2, \dots$ 是具有单位方差的独立同分布圆对称复高斯随机变量 (circularly symmetric complex Gaussian, CSCG), ρ 是相关因子.

基于 BERT 的语义相似性被用于语义精度评价^[11]. 语义精度主要由语义编解码的神经网络架构 c_m , 神经网络权重 w_m , 信道 SINR 和语义压缩率 k 决定, 其表示为

$$\xi_m = f_s(c_m, w_m, k_m, \gamma_m). \quad (5)$$

值得指出的是, 语义编解码的神经网络架构和权重主要以离线的方式进行设计和训练, 并利用训练好的语义编解码进行在线部署. 因此, 在线过程中语义编解码的神经网络架构 c_m 和网络权重 w_m 保持不变.

在特定模型和接收任务的条件下, 语义熵是固定的^[40]. Yan 等^[40] 在此前提下, 将语义速率最小单位定义为 “sub/s”. 受其启发, 本文将语义速率定义为

$$\varsigma_m = \frac{\tilde{H}}{Q_m^{\text{txt}} k_m} \cdot W, \quad (6)$$

其中 $\tilde{H}$ 表示语义熵, W 表示信道带宽, Q_m^{txt} 表示基站 m 待传输的文本信息. 在 t 时刻系统总的功率损耗可以被定义为

$$P_{\text{tot}}(t) = \sum_{m=1}^M \left\| \sqrt{p_m(t)} \right\|^2 + MP_{\text{BS}} + MP_{\text{AI}} + MP_{\text{UT}}, \quad (7)$$

由于终端所进行业务的差异, 不同终端用户对传输速率和传输精度有不同的需求. 因此, 本文考虑的终端 QoE 为^[40]

$$\text{QoE}_m = \omega_m f_r(\varsigma_m^{\text{req}} - \varsigma_m) + (1 - \omega_m) f_a(\xi_m^{\text{req}} - \xi_m), \quad (8)$$

其中 ξ_m^{req} 表示小区 m 中的用户的语义精度需求, ς_m^{req} 表示小区 m 中的用户的语义速率需求, ω_m 表示平衡因子, $f_r(x) = 1/(1 + e^{\alpha_m x})$ 和 $f_a(x) = 1/(1 + e^{\beta_m x})$ 是 logistic 函数. α_m 和 β_m 是增长因子.

为了确保蜂窝终端用户的体验质量, 本文考虑终端用户的最小语义速率要求, 最小语义精度要求和系统功率损耗, 基于系统总语义能效累计增益最大化的优化目标可以描述为

$$\max_{\pi} \mathbb{E} \left[\sum_{t=0}^T \sum_{m \in \mathcal{M}} \Delta \frac{\text{QoE}_m(t)}{P_{\text{tot}}(t)} \right], \quad (9)$$

$$\text{s.t. } [p_m(t), k_m(t)] \sim \pi, \forall m \in \mathcal{M}, \quad (9a)$$

$$p_{\min} \leq p_m(t) \leq p_{\max}, \forall m \in \mathcal{M}, \quad (9b)$$

$$0 \leq k_m(t) \leq 1, \forall m \in \mathcal{M}, \quad (9c)$$

$$\varsigma_m \geq \varsigma_m^{\text{req}}, \forall m \in \mathcal{M}, \quad (9d)$$

$$\xi_m \geq \xi_m^{\text{req}}, \forall m \in \mathcal{M}, \quad (9e)$$

其中 π 表示长期联合功率优化策略和语义压缩率优化策略. $\Delta \frac{\text{QoE}_m(t)}{P_{\text{tot}}(t)}$ 表示在 t 时刻的能效优化增益. 约束条件 (9b) 和 (9c) 分别限制了传输功率范围和语义压缩率配置比, 约束条件 (9d) 和 (9e) 分别表示在 t 时刻小区 m 中的用户的语义速率需求和语义准确度需求.

值得提出的是, 连续优化上述目标函数可能导致优化维度过高的问题, 从而影响优化效率. 假设功率分配的行动空间大小为 A_p , 语义压缩率行动空间大小为 A_s , 那么在时刻 t 集中式算法的优化空间维度将会膨胀为 $(A_p \times A_s)^M$, 显著增加了问题的复杂度, 传统的算法可能在效率上难以应对这一挑战. 因此, 迫切需要开发一种高效的分布式方法来解决该高维度多目标优化问题.

4 基于分布式多智能体强化学习的跨层优化算法

本节将阐述一个基于局部观测的分布式多智能体强化学习算法框架, 其中每个独立决策的智能体通过奖励函数来学习如何协作, 从而提升整体系统的性能. 由于智能体的全局信息观测将导致严重的信令开销, 本文假设当前智能体仅能获得本小区的系统状态. 本文采用分布式离线学习在线决策的方法策略. 为了便于扩展, 本文假设所有智能体拥有相同的观测空间和决策空间. 智能体根据当前时刻各自的观测状态, 做出独立的行动.

4.1 POMDP

为了解决优化问题 (9), 本文首先将决策过程建模为部分可观测的马尔可夫决策过程, 该过程可由元组 $(\mathcal{M}, \mathcal{S}, \mathcal{A}_x, \mathcal{P}, \mathcal{R}, \Omega_x, \gamma)$ 表示, 其中 $\gamma \in [0, 1]$ 表示折扣因子, $\mathcal{S}$ 表示环境的状态空间, $\mathcal{A}_x = \times_m \mathcal{A}_m$ 表示联合行动空间, $\Omega_x = \times_m \Omega_m$ 表示联合观测空间. 在每个时间步长, 每个智能体 m 能够选择一个行动 $a_m \in \mathcal{A}$, 因此联合行动 $\times_m a_m \in \mathcal{A}_x$, 无线环境以概率 $\mathcal{P}(s'|s, \times_m a_m)$ 转换到下一状态 $s' \in \mathcal{S}$. 所有智能体共享相同奖励函数 $r = \mathcal{R}(s, \times_m a_m, s')$. 在无线环境中, 由于无线信令的传输时延和信号处理时延, 本文假设每个基站仅能够获得本地小区的观测信息 $O_m \in \Omega_m$, 从整体系统来看, 这是一个部分可观测的过程. 基站 $m \in \mathcal{M}$ 拥有独立的局部观测行动历史 $\tau_m(t) = \{(O_m(0), a_m(0)), (O_m(1), a_m(1)), \dots, (O_m(t-1), a_m(t-1))\}$. 同时, 每个基站根据自身策略 π 独立进行决策.

4.2 训练算法

最优策略 $\pi^*(a|s)$ 可以视为从状态 s 到行动 a 的映射函数, 用于解决 POMDP 问题. $\pi^*(a|s)$ 是一个远视的优化策略, 其长期累计折扣奖励可以被定义为

$$R(t) = \sum_{\tau=0}^{\infty} \gamma^{\tau} \mathcal{R}(s(t+\tau+1), a(t+\tau+1)), \quad (10)$$

其中 $s(t+\tau+1)$ 和 $a(t+\tau+1)$ 分别表示在 $t+\tau+1$ 时刻涉及到的状态和行动. 动态规划问题可以利用准确环境信息来求解. 然而, 由于无线信道的动态变化, 获取该信息是不切实际的. 深度 Q 网络 (deep Q -network, DQN) 算法作为一种 Model-free 算法, 能够在没有动态无线环境知识的情况下探索最优策略. DQN 通过试错机制, 不断观察环境状态并试图做出响应来获取更高的奖励信息. 与策略 π 相对应的 Q 函数被定义为

$$Q_{\pi}(s, a) = \mathbb{E}[R(t)|s(t) = s, a(t) = a]. \quad (11)$$

上述 Q 函数可以通过贝尔曼 (Bellman) 等式优化:

$$Q_{\pi}(s, a) = \mathcal{R}(s, a) + \gamma \sum_{s' \in \mathcal{S}} \left(\mathcal{P}(s, a, s') \sum_{a' \in \mathcal{A}} Q_{\pi}(s', a') \right), \quad (12)$$

其中 $Q_{\pi}(s', a')$, $\forall (s', a') \in \mathcal{S} \times \mathcal{A}$ 表示状态 s' 时选择动作 a' 的概率, 其能够计算所有可能的状态行动对. $\mathcal{R}(s, a) = r$ 表示在状态 s 下执行行动 a 的中间奖励. 最优策略 π^* 所对应的 Q 值函数为

$$Q^{\pi^*}(s, a) = \mathcal{R}(s, a) + \gamma \sum_{s' \in \mathcal{S}} \mathcal{P}(s, a, s') \max_{a'} Q^{\pi^*}(s', a'). \quad (13)$$

本文采用基于 Q 值函数的方法进行驱动, 智能体在开始时刻会初始化一个 Q 值表, 利用贪婪策略不断尝试新动作, 根据获得的奖励信息作为反馈来指导下一次行动. 贪婪策略能有效避免算法陷入局部最优解. 在多次与环境交互后, 智能体根据以下公式来更新 Q 值表:

$$q(s, a) \leftarrow (1 - \alpha) q(s, a) + \alpha \left(r + \gamma \max_{a'} q(s', a') \right), \quad (14)$$

其中 $\alpha \in [0, 1]$ 表示智能体的学习率. 基于值函数的 DQN 算法能够解决 Q 值表的大空间问题, 其主要由目标网络和训练网络构成. 半静态的目标网络构造一个权重为 θ^- 的深度神经网络 (deep neural network, DNN) 网络, 用于输出目标值, 训练网络用于输出评估值. 与此同时, DQN 采用经验重放技术, 即利用状态-行动-奖励的历史经验信息 (s, a, r, s') 来训练网络权重. 在训练过程中, 智能体随机在缓存器 $\mathcal{B}$ 中抽取 $\mathcal{D}$ 组历史经验用于损失计算. 最小化损失函数以降低目标网络和训练网络之间的误差:

$$\mathcal{L}(\theta) = \sum_{(s, a, r, s') \in \mathcal{D}} \left(r + \gamma \max_{a'} q(s', a'; \theta^-) - q(s, a; \theta) \right)^2. \quad (15)$$

最后, 智能体根据以下公式来更新训练网络的权重:

$$\frac{\partial \mathcal{L}(\theta)}{\partial \theta} = \sum_{(s, a, r, s') \in \mathcal{D}} \left(r + \gamma \max_{a'} q(s', a'; \theta^-) - q(s, a; \theta) \right) \nabla q(s, a; \theta). \quad (16)$$

然而, 由于局部观测信息无法反应整体系统的状态, DQN 在估计 Q 值时会产生一定的误差, 最终导致无法获得最优的决策性能. 在 DQN 中嵌入 LSTM 的深度递归 Q 网络 (deep recurrent Q -network, DRQN) 能够利用循环神经网络的记忆性特点保留中间状态, 并且聚合一定时间的观测信息, 可进一步提高准确度, 本文采用 DRQN 来驱动智能体.

4.3 策略设计

如前文所述, 本文假设每个基站能够独立进行功率分配和语义压缩决策. 因此, 联合跨层优化问题可以建模成多智能体强化学习问题. 如图 3 所示, 在在线决策过程中, 基站 m 根据当前的局部观测信息 $O_m(t)$ 根据策略 $\pi_m(a|s)$ 采取行动 $a_m(t)$. 基站向中央控制器上报当前小区的能量效率值, 由中央控制器计算系统总能效后作为奖励信息 $R_m(t)$ 下发给各基站. 在离线训练过程中, 基站 m 从经验重放缓存器 $\mathcal{B}_m$ 中随机抽出 $\mathcal{D}$ 个历史经验用于网络训练, 智能体利用式 (16) 进行网络训练. 每隔 T_b 个时隙, 将训练网络的权重更新给目标网络. 因此, 观测空间、行动空间和奖励函数分别被定义如下.

观测空间. 观测信息被定义为当前小区和服务用户的状态:


$$O_m(t) = (p_m(t-1), \gamma_m(t), \text{QoE}_m(t), \mathbf{b}_m(t), \mathbf{i}_m(t)), \quad (17)$$

其中 $p_m(t-1)$ 表示 $t-1$ 时刻的功率分配信息. $\mathbf{b}_m(t)$ 和 $\mathbf{i}_m(t)$ 是在 t 时刻基站 m 等效信道增益和总的干扰加噪声功率集合, 其包含当前时刻和上一时刻信息, $\mathbf{b}_m(t) = \{b_m(t), b_m(t-1)\}$ 和 $\mathbf{i}_m(t) = \{i_m(t), i_m(t-1)\}$, 其中

$$b_m(t) = \left| \sqrt{p_m(t)} \mathbf{h}_{m,m}^\dagger(t) \right|^2, \quad (18)$$

$$i_m(t) = \sum_{j \neq m} \left| \sqrt{p_j(t)} \mathbf{h}_{m,j}^\dagger(t) \right|^2 + \sigma^2. \quad (19)$$

行动空间. 行动空间被定义为 $(A_p \times A_s)$, 为了降低决策复杂度, 本文选择离散决策空间, 并且定义功率码本为 $\mathcal{T}_p = \{0, \frac{p_{\max}}{Q_{\text{pow}}-1}, \frac{2p_{\max}}{Q_{\text{pow}}-1}, \dots, p_{\max}\}$. 每个智能体采取行动时, 选择对应功率码字的索引,

图 3 基站 m 的网络架构和处理流程Figure 3 Structure and processing flow in BS m

即 $\mathcal{T}_p(a) \in \mathcal{T}_p$. 定义语义压缩率码本为 $\mathcal{T}_k = \{\frac{1}{k_{\max}}, \frac{2}{k_{\max}}, \dots, \frac{k_{\max}-1}{k_{\max}}\}$, $k \in \mathcal{T}_k$, 其中 $k_{\max}$ 表示最大压缩等级.

奖励函数. 智能体 m 的奖励信息 $r_m(t)$ 被定义为时刻 t 决策时的系统能效增益, 即

$$r_m(t) = \sum_{m \in \mathcal{M}} \Delta \frac{\text{QoE}_m(t)}{P_{\text{tot}}(t)}. \quad (20)$$

所设计的语义能效最大化跨层优化策略如算法 1 所示.

5 实验参数设置与结果分析

5.1 系统参数设置

本文基于 Tensorflow 平台仿真验证所提出的基于分布式多智能体强化学习的联合功率分配和语义压缩资源优化方法. 本文考虑多小区网络, 基站位于小区中央, 终端设备随机分布在对应的小区内. 基站 m 和终端设备 j 之间的路径损耗为 $\beta_{m,j} = 120.9 + 37.6 \log_{10} d_{m,j}$, 其中 $d_{m,j}$ 表示基站 m 和终端设备 j 之间的距离. 主要仿真参数和网络模型超参数分别如表 1 和 2 所示.

5.2 对比算法介绍

本小节介绍后续实验中采用的对比算法. (1) 基于 DQN 的多智能体强化学习算法 (DQN-based

算法 1 基于分布式多智能体强化学习的高能效语义跨层优化算法

```

1: 初始化目标网络权重  $\theta_m^-$ , 训练网络权重  $\theta_m$ , 以及经验回放缓存器  $\mathcal{B}_m, \forall m \in \mathcal{M}$ .
2: 当时间  $t < T_b$  时, 每个智能体基于随机策略采取行动, 同时将经验信息  $(O_m(t), a_m(t), r_m(t), O_m(t+1))$  保存到经验回放缓存器  $\mathcal{B}_m$  中.
3: while  $t \geq T_b$  do
4:   for  $\forall m \in \mathcal{M}$  do
5:     基站  $m$  观测当前时刻的状态  $O_m(t)$ ;
6:     基站  $m$  以  $\epsilon$  概率根据随机策略选择行动, 以  $1 - \epsilon$  概率根据  $\arg \max_{a \in \mathcal{A}} q(s, a; \theta_m)$  选择行动;
7:     基站  $m$  计算中间奖励函数  $r_m$ ;
8:     基站  $m$  观测下一时刻状态信息  $O_m(t)$ , 并将新的状态行动奖励对  $(O_m(t), a_m(t), r_m(t), O_m(t+1))$  存储到经验回放缓存器  $\mathcal{B}_m$  中;
9:     基站  $m$  随机从经验回放缓存器  $\mathcal{B}_m$  抽取部分数据用于训练;
10:    训练网络权重, 并且每  $T_b$  时刻利用  $\theta_m$  来更新  $\theta_m^-$ ;
11:   end for
12: end while

```

表 1 多小区网络参数**Table 1** Multi-cell network parameter

Parameter	Value
Number of cell, M	7
Radius of each cell	200 m
Maximum transmitting power for each BS, $p_{\max}$	20 dBm
Total power dissipation for UTs, P_{UT}	10 dBm
Total power dissipation for semantic codec training and computing, P_{AI}	5 dBm
Hardware power dissipation for BSs, P_{BS}	9 dBW
Noise power spectral density, σ^2	114 dBm/Hz
Bandwidth of each channel, W	180 kHz
Correlation coefficient, ρ	0.64
Transmit power level, Q_{pow}	7
Maximum semantic compression level, $k_{\max}$	20
Requirement of semantic rate, ς_m	[0.8, 0.9]
Requirement of semantic accuracy, ξ_m	[80, 100]
Semantic entropy, $\tilde{H}$	4

MARL). 该算法采用与所提算法相同的框架. 不同的是, 每个基站部署一个基于 DQN 的决策网络. (2) 不考虑功率损耗的多智能体强化学习算法 (DQN-based MARL-w/o EC). 为了考察所考虑的系统功率损耗目标对整体系统能量效率的影响, 本小节设置不考虑功率损耗的策略作为基线算法, 该算法的网络结构和超参数与算法 1 相同. 但其仅将整体系统的用户 QoE 指标作为优化对象. (3) 基于贪婪策略的决策算法 (greedy-based algorithm). 在该算法中, 每个智能体在每个时隙选择最大的传输功率. (4) 基于两步随机策略的决策算法 (random-based algorithm). 由于联合决策的行动空间较大, 随机策略难以获得较为稳定的性能, 该算法将决策过程分为功率分配和语义压缩两个子问题, 每个智能体在每个时隙分别随机选择传输功率和语义压缩配置.

表 2 神经网络参数
Table 2 Neural network parameter

Parameter	Value
Depth	3
Number of kernels	6432
Size of the memory pool at each agent	500
Size of the mini-batch	32
Size of the memory step	8
Learning rate	0.0005
Learning rate decay factor	0.0001
Future discount	0.5
Adaptive greedy strategy	[0.1, 0.6]
The time of updating the target network	100
Activation function	ReLU




图 4 (a) 三小区时和 (b) 七小区时不同算法下系统 EE 与时间的关系

Figure 4 EE of system versus time under different algorithms when the number of cell is (a) 3 and (b) 7

5.3 实验结果与分析

图 4(a) 为三小区情况下所提算法和其他策略的 EE 性能对比. 从图中可以看出, 基于多智能体强化学习的算法性能随着时间的推移逐渐上升, 而非智能算法性能保持不变. 这是由于多智能体强化学习算法存在学习的过程. 通过与环境交互, 以奖励函数为指导, 通过离线学习在线更新的方式逐渐改善策略, 最终获得较好的性能. 其中, 基于 DQN 的算法波动较大, 这是由于智能体无法观测全局环境, 使其具有一定的不确定性; 而基于 DRQN 的算法波动较小, 在收敛后能够保持相对稳定的性能. 这是由于 DRQN 中的 LSTM 网络能够保存中间状态, 具有对抗环境不确定性的能力. 另一方面, 基于随机策略的算法性能最差, 基于贪婪策略的算法性能略优于随机算法. 这是由于虽然基于贪婪策略可选择最大功率作为传输, 但大功率传输只会优化本链路的性能, 会对其他链路产生较强的干扰, 因此并不能获得最优的结果, 验证了所提多智能体强化学习算法的有效性.




图 5 (a) 三小区时和 (b) 七小区时不同算法下系统 EE 的箱线图

Figure 5 Boxplot of system's EE under different algorithms when the number of cell is (a) 3 and (b) 7

图 4(b) 为七小区情况下所提算法和其他方法的 EE 性能对比。从图中可以看出, 所提算法性能优势较三小区时更为明显。这是由于在七小区环境中, 系统更加复杂, 智能体仅能观测当前小区的部分信息, 全局信息的模糊性更高, 更加缺乏对整体系统信息的掌握, 导致其他 3 种算法的性能有所损伤。而不考虑功率损耗的策略较三小区时性能损伤更大, 波动更为明显, 反应了所设计的能效优化结构能够考虑系统实时的功率损耗, 实现语义能效最大化的目标。

图 5(a) 和 (b) 分别为三小区和七小区情况下所提算法和其他方法的 EE 性能的箱线图对比。该图仅展示所有算法收敛后的决策性能统计, 反应了不同算法的稳定性差异。由于随机算法和贪婪算法的短视性, 其获得较差的性能, 但其波动较为稳定。所提基于 DRQN 的多智能体强化学习算法性能最优, 同时稳定性最好。不考虑系统功率损耗的算法在三小区情况下虽然峰值性能与所提算法相似, 但是在七小区情况下该算法波动较大, 性能损伤明显, 这是由于其没有考虑系统功率损耗, 智能体在决策过程中选择大功率时不会获得负面奖励, 因此最后的整体系统 EE 性能表现较差。基于 DQN 的多智能体强化学习策略算法的均值和性能波动均优于不考虑系统功率损耗的算法。该现象证明了所设计的算法框架能够达在保持系统性能的情况下实现节能的目的。

图 6 为三小区情况下不同策略在 10000 时隙内智能体选择传输功率的热力图统计。功率索引值越大代表智能体所采用的传输功率越大。单元格颜色越深表示在统计时间内选择该行动的次数越多。从图中可以看出, 考虑系统功率损耗的算法会优先选择较小的发射功率, 而不考虑系统功率损耗的算法优先选择较大的发射功率。因此, 在满足用户 QoE 指标的情况下, 所提算法能够最小化系统功耗, 从而实现能量效率最大化的目标。

6 结束语

本文考虑了语义通信网络的能效增益最大化问题。为了优化系统整体能效, 本文首先提出了一种跨层资源分配优化框架, 并提出一种考虑语义传输的用户 QoE 和系统功率损耗的语义能效评价指标, 设计了联合功率分配和语义压缩率分配的多智能体强化学习跨层优化算法, 通过将决策问题建模成分可观测的马尔可夫过程, 在每个基站内部部署决策网络, 仅依靠当前小区信息作为观测信息进行决策。仿真结果表明, 基于多智能体强化学习的跨层策略能够有效解决动态功率分配和语义压缩率决策




图6 不同策略下智能体的传输功率行动的热力图

Figure 6 Heatmap of transmitted power actions of agents under different schemes. (a) DQN-based MARL; (b) DQN-based MARL-w/o EC; (c) DRQN-based MARL

问题, 所提算法能够在降低功耗的情况下满足用户需求, 证明了所提算法的有效性.

参考文献

- Shannon C E. A mathematical theory of communication. Bell Syst Tech J, 1948, 27: 379–423
- Wenwei X, Gong Z, Bo B, et al. Ten key ICT challenges in the post-Shannon era. Sci Sin Math, 2021, 51: 1095–1138 [徐文伟, 张弓, 白铂, 等. 后香农时代 ICT 领域的十大挑战问题. 中国科学: 数学, 2021, 51: 1095–1138]
- Niu K, Dai J S, Zhang P, et al. 6G-oriented semantic communications. Mobile Commun, 2021, 45: 85–90 [牛凯, 戴金晟, 张平, 等. 面向 6G 的语义通信. 移动通信, 2021, 45: 85–90]
- Niu K, Zhang P. A mathematical theory of semantic communication. 2024. ArXiv:2401.13387
- Lyu S Y, Dai J S, Zhang P. New paradigm of joint source and channel processing: semantic communications. ZTE Commun, 2023, 29: 2–8 [吕守晔, 戴金晟, 张平. 信源信道联合的新范式: 语义通信. 中兴通讯技术, 2023, 29: 2–8]
- Zhang P, Niu K, Yao S S, et al. Semantic communications for future: basic principle and implementation methodology. J Commun, 2023, 44: 1–14 [张平, 牛凯, 姚圣时, 等. 面向未来的语义通信: 基本原理与实现方法. 通信学报, 2023, 44: 1–14]
- Zhang Y C, Zhang P, Wei J B, et al. Semantic communication for intelligent devices: architectures and a paradigm. Sci Sin Inform, 2022, 52: 907–921 [张亦弛, 张平, 魏急波, 等. 面向智能体的语义通信: 架构与范例. 中国科学: 信息科学, 2022, 52: 907–921]
- Bao J, Basu P, Dean M, et al. Towards a theory of semantic communication. In: Proceedings of the 1st International Workshop on Network Science, West Point, 2011. 110–117

- 9 Shi G M, Li Y Y, Xie X M. Semantic communications: outcome of the intelligence era. *Pattern Recogn Artif Intell*, 2018, 31: 91–99
- 10 Shi G M, Xiao Y, Li Y, et al. Semantic networking for the intelligence of everything. *Chinese J Int Thing*, 2021, 5: 1–11
- 11 Xie H, Qin Z, Li G Y, et al. Deep learning enabled semantic communication systems. *IEEE Trans Signal Process*, 2021, 69: 2663–2675
- 12 Zhou Q, Li R, Zhao Z, et al. Semantic communication with adaptive universal transformer. *IEEE Wireless Commun Lett*, 2022, 11: 453–457
- 13 Farsad N, Rao M, Goldsmith A. Deep learning for joint source-channel coding of text. In: *Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, 2018. 2326–2330
- 14 Rao M, Farsad N, Goldsmith A. Variable length joint source channel coding of text using deep neural networks. In: *Proceedings of the 19th International Workshop Signal Process Advanced Wireless Communications (SPAWC)*, Kalamata, 2018. 1–5
- 15 Zhou Q, Li R, Zhao Z, et al. Semantic communication with adaptive universal transformer. *IEEE Wireless Commun Lett*, 2022, 11: 453–457
- 16 Jiang P, Wen C K, Jin S, et al. Deep source-channel coding for sentence semantic transmission with HARQ. *IEEE Trans Commun*, 2022, 70: 5225–5240
- 17 Zhou Q, Li R, Zhao Z, et al. Adaptive bit rate control in semantic communication with incremental knowledge-based HARQ. *IEEE Open J Commun Soc*, 2022, 3: 1076–1089
- 18 Weng Z, Qin Z, Li G Y. Semantic communications for speech recognition. In: *Proceedings of the IEEE Global Communications Conference (GLOBECOM)*, 2021
- 19 Weng Z, Qin Z. Semantic communication systems for speech transmission. *IEEE J Sel Areas Commun*, 2021, 39: 2434–2444
- 20 Bourtsoulatz E, Kurka D B, Gunduz D. Deep joint source-channel coding for wireless image transmission. *IEEE Trans Cogn Commun Netw*, 2019, 5: 567–579
- 21 Lu K, Li R, Chen X, et al. Reinforcement learning-powered semantic communication via semantic similarity. 2022. ArXiv:2108.12121
- 22 Huang D, Tao X, Gao F, et al. Deep learning-based image semantic coding for semantic communications. In: *Proceedings of IEEE Global Communications Conference (GLOBECOM)*, 2021. 1–6
- 23 Yu K, He Q, Wu G. Two-way semantic communications without feedback. *IEEE Trans Veh Technol*, 2024. doi: 10.1109/TVT.2024.3352666
- 24 Sun Y P, Cui S G, Zhang P. Survey on semantic knowledge base for semantic communications. *ZTE Commun*, 2023, 29: 19–23 [孙亚萍, 崔曙光, 张平. 面向语义通信的语义知识库综述. *中兴通讯技术*, 2023, 29: 19–23]
- 25 Sun M Y, Xiong H C, Wang Y N, et al. Link design and key technologies of intellicise semantic communication system. *ZTE Commun*, 2023, 29: 40–45 [孙梦颖, 熊华超, 王怡宁, 等. 智简语义通信的链路设计及关键技术研究. *中兴通讯技术*, 2023, 29: 40–45]
- 26 Zhang H, Shao S, Tao M, et al. Deep learning-enabled semantic communication systems with task-unaware transmitter and dynamic data. *IEEE J Sel Areas Commun*, 2023, 41: 170–185
- 27 Hu H, Zhu X, Zhou F, et al. One-to-many semantic communication systems: design, implementation, performance evaluation. *IEEE Commun Lett*, 2022, 26: 2959–2963
- 28 Wang Y, Chen M, Luo T, et al. Performance optimization for semantic communications: an attention-based reinforcement learning approach. *IEEE J Sel Areas Commun*, 2022, 40: 2598–2613
- 29 Zhang Y, Xu W, Gao H, et al. Multi-user semantic communications for cooperative object identification. In: *Proceedings of the IEEE International Conference on Communications Workshops (ICC Workshops)*, Seoul, 2022. 157–162
- 30 Xie H, Qin Z. A lite distributed semantic communication system for Internet of Things. *IEEE J Sel Areas Commun*, 2021, 39: 142–153
- 31 Wu Q, Liu F, Xia H, et al. Semantic transfer between different tasks in the semantic communication system. In: *Proceedings of the IEEE Wireless Communications and Networking Conference (WCNC)*, Austin, 2022. 566–571
- 32 Pokhrel S R. Learning from data streams for automation and orchestration of 6G industrial IoT: toward a semantic

- communication framework. *Neural Comput Applic*, 2022, 34: 15197–15206
- 33 Chen J J, Guo C L, Feng C Y, et al. Resource allocation for the semantic communication in the intelligent networked environment. *Chin J Int Things*, 2022, 6: 47–57 [陈九九, 郭彩丽, 冯春燕, 等. 智能网联环境下面向语义通信的资源分配. *物联网学报*, 2022, 6: 47–57]
 - 34 Zhang P, Xu X, Dong C, et al. Model division multiple access for semantic communications. *Front Inform Technol Electron Eng*, 2023, 24: 801–812
 - 35 Liu C, Guo C, Yang Y, et al. Bandwidth and power allocation for task-oriented semantic communication. 2022. ArXiv:2201.10795
 - 36 Zhang H, Wang H, Li Y, et al. DRL-driven dynamic resource allocation for task-oriented semantic communication. *IEEE Trans Commun*, 2023, 71: 3992–4004
 - 37 Farshbafan M K, Saad W, Debbah M. Common language for goal-oriented semantic communications: a curriculum learning framework. In: *Proceedings of the IEEE International Conference on Communications*, 2022. 1710–1715
 - 38 Yang Z, Chen M, Zhang Z, et al. Energy efficient semantic communication over wireless networks with rate splitting. *IEEE J Sel Areas Commun*, 2023, 41: 1484–1495
 - 39 Yan L, Qin Z, Zhang R, et al. Resource allocation for text semantic communications. *IEEE Wireless Commun Lett*, 2022, 11: 1394–1398
 - 40 Yan L, Qin Z, Zhang R, et al. QoE-based semantic-aware resource allocation for multi-task networks. 2023. ArXiv:2305.06543
 - 41 Yang W, Du H, Liew Z Q, et al. Semantic communications for future internet: fundamentals, applications, and challenges. *IEEE Commun Surv Tut*, 2023, 25: 213–250
 - 42 Gu Y, Huang Y, Hu H, et al. Energy efficiency optimization of cognitive UAV-assisted edge communication for semantic Internet of things. *Wirel Commun Mob Com*, 2021, 2021: 1–12
 - 43 Fensel A, Tomic S, Kumar V, et al. SESAME-S: semantic smart home system for energy efficiency. *Informatik-Spektrum*, 2013, 36: 46–57
 - 44 Park H, Basaran C, Park T, et al. Energy-efficient privacy protection for smart home environments using behavioral semantics. *Sensors*, 2014, 14: 16235–16257
 - 45 Liu P, Hu Y F, Min G, et al. Semantization improves the energy efficiency of wireless sensor networks. In: *Proceedings of the IEEE Wireless Communication and Networking Conference (WCNC)*, Sydney, 2010. 1–6
 - 46 Bispo K A, Rosa N S, Cunha P R F. A semantic solution for saving energy in wireless sensor networks. In: *Proceedings of the IEEE Symposium on Computers and Communications (ISCC)*, 2012. 492–499
 - 47 Lu Y P, Dai J S, Niu K. Key technologies of semantic communication for industrial networks. *Mobile Commun*, 2023, 47: 18–24 [鲁延鹏, 戴金晟, 牛凯. 面向工业网络的语义通信关键技术. *移动通信*, 2023, 47: 18–24]
 - 48 Guo Y Y, Qin Z J, Tao X M. An overview of semantic communication systems for extended reality. *Mobile Commun*, 2023, 47: 22–26 [郭翼宇, 秦志金, 陶晓明. 面向扩展现实的语义通信系统综述. *移动通信*, 2023, 47: 22–26]
 - 49 Qin Z J, Zhao T T, Li F, et al. Survey of research on multimodal semantic communication. *J Commun*, 2023, 44: 28–41 [秦志金, 赵茱茱, 李凡, 等. 多模态语义通信研究综述. *通信学报*, 2023, 44: 28–41]
 - 50 Guler B, Yener A. Semantic index assignment. In: *Proceedings of the IEEE International Conference on Pervasive Computing and Communication Workshops (PERCOM WORKSHOPS)*, Budapest, 2014. 431–436
 - 51 Guler B, Yener A, Swami A. The semantic communication game. *IEEE Trans Cogn Commun Netw*, 2018, 4: 787–802
 - 52 Lee C H, Lin J W, Chen P H, et al. Deep learning-constructed joint transmission-recognition for Internet of Things. *IEEE Access*, 2019, 7: 76547–76561
 - 53 Rix A, Beerends J, Hollier M, et al. Perceptual evaluation of speech quality (PESQ) — a new method for speech quality assessment of telephone networks and codecs. In: *Proceedings of the IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP)*, Salt Lake City, 2001. 749–752
 - 54 3GPP. Management and orchestration; Energy efficiency of 5G. TS 28.310. 2021. <https://portal.3gpp.org/desktopmodules/Specifications/SpecificationDetails.aspx?specificationId=3550>
 - 55 Ministry of ecology and environment of the people's republic of China. China's Policies and Actions on Climate Change 2022 Annual Report. 2022 [中华人民共和国生态环境部. 中国应对气候变化的政策与行动 2022 年度报告. 2022] https://www.mee.gov.cn/ywgz/ycqhbh/syqhbh/202210/t20221027_998100.shtml
 - 56 Amodei D, Hernandez D. AI and compute. Heruntergeladen von, 2018. <https://blog.openai.com/ai-and-compute>

Cross-layer energy efficiency optimization for semantic communication networks

Kaiwen YU, Renhe FAN, Wenlong GOU, Chuanhang YU & Gang WU*

National Key Laboratory of Wireless Communications, University of Electronic Science and Technology of China, Chengdu 611731, China

* Corresponding author. E-mail: wugang99@uestc.edu.cn

Abstract Semantic communication focuses on the meaning of the transmitted information, which can significantly reduce the amount of data to be transmitted and improve the communication efficiency through semantic extraction, showing great potential in the future communication scenarios of smart devices. However, deep learning-enabled semantic codec further exacerbate the energy consumption of traditional communications. To address this problem, we propose a joint cross-layer optimization framework, and design a semantic energy efficiency metrics to evaluate the user's quality of experience and energy consumption of the global system. The optimization process is modeled as a partially observable Markov process. Jointly optimize power control in the physical layer and semantic compression allocation in the semantic layer: the power allocation is used to eliminate inter-cell interference, and the semantic compression level configuration is used to optimize the semantic transmission efficiency. Simulation results show that the proposed framework and algorithm can effectively solve the joint optimization problem of semantic and physical layers.

Keywords resource allocation, semantic communications, semantic-aware network, energy efficiency, multi-agent reinforcement learning