

分类号: TN929.5;TP18

单位代码: 10335

密 级: 公开

学 号: 22031085

浙江大学

硕士学位论文



中文论文题目: 无线边缘学习系统的
通信资源优化

英文论文题目: Communication Resource Optimization
for Wireless Edge Learning Systems

申请人姓名: 江智慧

指导教师: 余官定

专业名称: 信息与通信工程

研究方向: 通信与网络

所在学院: 信息与电子工程学院

论文提交日期 2023.3

无线边缘学习系统的
通信资源优化



论文作者签名： 江智慧

指导教师签名： 余官定

论文评阅人1: 匿名

评阅人2: 匿名

评阅人3: 匿名

评阅人4: _____

评阅人5: _____

答辩委员会主席: 王寿光 教授 浙江工商大学

委员1: 陈晓明 研究员 浙江大学

委员2: 殷锐 教授 浙大城市学院

委员3: 王彦波 高级工程师 国网浙江信通公司

委员4: _____

答辩日期: 2023.3

浙江大学研究生学位论文独创性声明

本人声明所呈交的学位论文是本人在导师指导下进行的研究工作及取得的研究成果。除了文中特别加以标注和致谢的地方外，论文中不包含其他人已经发表或撰写过的研究成果，也不包含为获得 浙江大学 或其他教育机构的学位或证书而使用过的材料。与我一同工作的同志对本研究所做的任何贡献均已在论文中作了明确的说明并表示谢意。

学位论文作者签名：

江智慧

签字日期：2023年3月10日

学位论文版权使用授权书

本学位论文作者完全了解 浙江大学 有权保留并向国家有关部门或机构送交本论文的复印件和磁盘，允许论文被查阅和借阅。本人授权浙江大学可以将学位论文的全部或部分内容编入有关数据库进行检索和传播，可以采用影印、缩印或扫描等复制手段保存、汇编学位论文。

（保密的学位论文在解密后适用本授权书）

学位论文作者签名：

江智慧

导师签名：

余官定

签字日期：2023年3月10日

签字日期：2023年3月10日

致 谢

时光如白驹过隙，转眼间两年半的硕士生涯即将画上句号。在求学的过程中，有痛苦与挫折，也有喜悦与收获。衷心感谢这一路上老师、同学、朋友以及家人们的关心、指导和帮助。

首先，我要由衷地感谢我的导师余官定教授。余老师是我科研道路上的启蒙老师，在我求学的各个阶段都给予了很大帮助。我的每一项研究工作都离不开余老师的悉心指导。不管是选题、问题建模还是论文写作，余老师都会耐心地跟我讨论，引导我思考，并给我提出许多宝贵意见，让我少走了很多弯路。余老师丰富的科研经验以及对待科研严谨的态度都潜移默化的影响着我的工作方法和生活态度。在科研之外，余老师也非常关心学生的身心健康，是一位良师益友。

同时，感谢上海科技大学文鼎柱教授给予我科研工作上的指导。文老师博闻多识、细致耐心、思路清晰、严谨治学。与文老师的每次讨论都能让我打开新思路，并且认识到当下研究工作中的不足之处。

感谢实验室的同学们。我的第一个科研工作是何映晖博士手把手带出来的。从问题建模到仿真再到论文的撰写，何映晖师兄都进行了细致的指导，并且告诉我很多经验和建议。每次有问题请教师兄，他也会非常耐心地和我讨论。刘胜利博士后也给予了我很多指导和帮助，为我的期刊论文以及硕士毕业论文的修改提出了许多宝贵意见。还要感谢王韵佳硕士、屈瑾硕士、张佳琪硕士、朱从亮硕士、王雅霖博士、李梦圆博士、胡棋昱博士、刘文亮博士、丁光耀博士、高惠国博士、杨经纬硕士、潘崇瑞硕士、万子煜硕士、侯秋硕博士、徐心怡硕士、刘翀赫硕士、何扬槊博士、王雕硕士、陈清炀硕士以及实验室其他诸位师弟师妹，和你们相处很温暖，你们的关心和帮助我都牢记在心。感谢我的室友施淑涵硕士、程鹏远硕士以及甘旭博士，你们的陪伴给我的硕士生涯增添了许多温馨和快乐。

感谢家人们一直以来对我的关心和付出，你们的支持和鼓励是我在求学过程中不断前进的动力。无论什么时候，你们都是我最坚强的后盾。最后，我真心地感谢所有帮助过我的人。

摘要

随着移动终端生成数据的爆炸性增长以及近年来人工智能（Artificial Intelligence, AI）领域取得的显著突破，AI被广泛地应用于无线通信领域中，并由此涌现和发展了许多新兴智能应用，如智慧物联网以及智慧医疗等。为了满足此类新兴智能应用的需求，无线边缘学习将成为赋能下一代移动通信（The 6th Generation, 6G）的关键技术之一。它可以快速访问分布式数据并利用各种边缘终端的计算资源，通过在网络边缘侧部署AI算法，为终端提供智能服务。然而，无线边缘学习技术将面临诸多挑战，主要包括：（1）由于无线通信资源以及终端的计算资源有限，训练过程中AI模型计算以及模型信息交互都会产生巨大的训练开销，需要设计通信和计算的优化方法以解决无线边缘学习的通信和计算瓶颈问题；（2）无线网络中的不可靠因素导致的传输错误等也会影响模型训练性能，需要设计复杂无线场景中的无线资源管理算法以提高模型训练性能。本论文针对上述问题展开了深入研究，从模型训练和无线通信资源优化两个角度设计高效的分布式资源优化方案，以提高无线边缘学习系统的性能，例如学习效率、训练准确率以及测试准确率等。

首先，针对联邦边缘学习系统，本文提出了一种基于数据重要性和信道状态信息（Channel State Information, CSI）的用户选择策略以及无线通信资源分配方案，以解决需要传输的模型参数数据量大导致的通信瓶颈问题。为了量化每个终端的数据重要性，首先分析了损失衰减与梯度的模的平方之间的关系。然后通过联合考虑用户选择和通信资源分配，建立了一个组合优化问题以最大化联邦边缘学习系统的学习效率。经过优化问题转换和松弛，推导出了最优用户选择策略和通信资源分配，并设计了一个多项式时间最优算法。最后，采用了两个常用的深度神经网络（Deep Neural Network, DNN）模型进行仿真。实验结果表明，与其他传统算法相比，本文提出的算法具有较强的泛化能力，并且可以提高联邦边缘学习系统的学习效率。

其次，针对模型分割边缘学习系统，本文基于时变无线信道提出了一种模型参数分配和带宽分配的联合优化算法，以最小化系统的训练时延。首先，分析了最小化系统总时延等同于分别最小化每轮时延，并基于此结论建立了每轮时延最小化问题。然后，为了解决时变信道场景中未来CSI未知的挑战，推导得出了等价的基于有限马尔可夫决策过程

(Markov Decision Progress, MDP) 的一轮时延最小化问题。在给定带宽分配下, 得出了最优模型参数分配算法, 并在给定模型参数分配下, 提出了针对时变信道的次优带宽分配算法, 该算法按顺序在每个相干时间内分配带宽。基于上述两个算法, 设计了联合模型参数分配和带宽分配的次优算法。最后, 实验结果表明, 本文提出的算法可以减少系统的训练时延, 提高模型的训练效率。

最后, 针对去中心化边缘学习系统, 本文提出了一种无线通信资源分配方案, 以减轻不可靠终端直通 (Device-to-Device, D2D) 通信导致的传输错误对模型训练性能的影响。为了提高模型训练的性能, 首先建立了一个优化问题, 即在给定训练时延下, 通过联合优化广播传输速率和带宽分配以最小化总模型偏差。然后, 推导得出了在高信噪比 (Signal-to-Noise Ratio, SNR) 场景、带宽充足场景以及大时延场景下广播传输速率的最优解, 该结果使得所有终端的一轮时延相等。接着, 提出了最优带宽分配算法以进一步提高系统的学习性能, 该算法使得所有终端的偏差减少速率相等。此外, 开发了一个协议用以实现去中心化边缘学习系统, 并提供了所提算法的收敛性分析。最后, 实验结果表明, 与基线算法相比, 本文提出的算法可以提高模型的收敛速率以及准确率。

本论文的探索和研究成果为无线边缘学习的应用提供了一定的理论和实践基础, 也为6G的发展提供了一定的理论支撑和有效思路。

关键词: 无线边缘学习; 人工智能; 联邦边缘学习; 模型分割边缘学习; 去中心化边缘学习; 数据重要性; 用户选择; 参数分配; D2D; 无线资源分配

Abstract

With the explosive growth of data generated by mobile devices and the remarkable breakthroughs made in artificial intelligence (AI) in recent years, AI has been widely applied in wireless communication, giving birth to many emerging intelligent applications, such as intelligent Internet of Things and intelligent medical care. To support such emerging intelligent applications, wireless edge learning has been regarded as one of the key technologies empowering the next generation communication. It can quickly access distributed data, utilize computing resources of various edge devices, and provide intelligent services for devices by deploying AI algorithms at the edge of the network. However, wireless edge learning still faces many challenges, mainly including: (1) Due to the limited wireless communication resources and computing resources of devices, AI model calculation and model information interaction will generate huge costs during the training process. To tackle the communication and computing bottlenecks of wireless edge learning, it is essential to design optimization methods of communication and computing. (2) Transmission errors caused by unreliable factors in wireless networks will also affect the model training performance. It is necessary to design wireless resource management algorithms in complex wireless scenarios to improve the learning performance. This thesis carries out in-depth research on the above issues, aiming to improve the learning performance (e.g., learning efficiency, training accuracy, and test accuracy) by designing efficient distributed resource optimization schemes from the perspective of model training and wireless communication resource optimization.

First, a user selection policy based on data importance and channel state information (CSI) and a wireless communication resource allocation scheme are proposed for federated edge learning system, which aim to tackle the communication bottleneck caused by the large amount of model parameters exchanged. To quantify the data importance of each device, the relationship between the loss decay and the squared norm of gradient is first analyzed. Then, by jointly considering user selection and communication resource allocation, a combinatorial optimization problem is formulated to maximize the learning efficiency of federated edge learning system. By problem transformation and relaxation, the optimal user selection policy and communication resource allocation are derived, and a polynomial-time optimal algorithm is developed. Finally, two common-used deep

neural network (DNN) models are deployed for simulation. The simulation results validate that the proposed algorithm has strong generalization ability and can attain higher learning efficiency as compared with other traditional algorithms.

Secondly, to minimize the training latency, a joint model parameter allocation and bandwidth allocation algorithm is proposed for partitioned edge learning system with time-varying channels. First, it is analyzed that minimizing the overall latency is equivalent to separately minimizing the latencies of all rounds. Based on this conclusion, the problem of one-round latency minimization is formulated. Then, to tackle the challenge of unknown future CSI, an equivalent Markov decision progress (MDP) based one-round latency minimization problem is derived. Given bandwidth allocation, the optimal model parameter allocation algorithm is proposed. Next, given model parameter allocation, the suboptimal bandwidth allocation algorithm is proposed for time-varying channels, where bandwidth is allocated sequentially in each coherence-time duration. Based on the above two algorithms, a joint model parameter allocation and bandwidth allocation algorithm is proposed. Finally, simulation results show that the proposed algorithms can reduce the training latency and improve the model training efficiency.

Finally, a wireless communication resource allocation scheme is proposed for decentralized edge learning system via unreliable device-to-device (D2D) communications, which aims to mitigate the impact of transmission errors on model training performance. To speed up the model training performance, an optimization problem to minimize the overall model deviation is formulated under given latency requirement by jointly optimizing the broadcast data rate and the bandwidth allocation. In the high signal-to-noise ratio (SNR), sufficient bandwidth, and large latency scenarios, the optimal broadcast data rate is firstly derived to equalize the one-round latency of devices. Then, an optimal bandwidth allocation algorithm is proposed to further improve the learning performance, where the deviation reduction rates of devices must be equivalent. Furthermore, a protocol to realize the decentralized edge learning system is developed, and the convergence analysis of the proposed algorithm is provided. Finally, simulation results verify that the proposed algorithm can improve both the convergence rate and learning accuracy as compared with the baseline algorithm.

These research results in this thesis can provide a theoretical basis for the application of the wireless edge learning system, as well as theoretical support and effective technical solutions for the further development of 6G.

Keywords: Wireless edge learning, artificial intelligence, federated edge learning, partitioned edge learning, decentralized edge learning, data importance, device selection, parameter allocation, D2D, wireless resource allocation.

插图

1-1	边缘学习技术场景分类.....	3
1-2	论文结构.....	11
2-1	联邦边缘学习系统模型.....	15
2-2	学习性能与通信回合数目的关系.....	24
2-3	不同算法测试准确率与训练时间的关系.....	24
2-4	所提算法的用户选择.....	25
2-5	所提算法的通信资源分配.....	25
2-6	相应的上行链路传输速率.....	26
2-7	不同终端数量时所提算法测试准确率与训练时间的关系.....	26
3-1	模型分割边缘学习系统模型.....	29
3-2	模型分割边缘学习系统的迭代过程.....	31
3-3	部分卸载场景中的三个阶段.....	40
3-4	全部卸载场景中的两个阶段.....	43
3-5	学习性能与时延的关系.....	47
3-6	不同系统带宽和不同组数下的时延性能比较.....	48
3-7	不同每组终端个数下的时延性能比较.....	48
4-1	去中心化边缘学习系统模型.....	51
4-2	去中心化边缘学习系统的迭代过程.....	53
4-3	实现去中心化边缘学习系统的协议.....	63
4-4	对于逻辑回归模型，不同系统带宽下学习性能与训练时间的关系.....	67
4-5	对于CNN模型，不同系统带宽下学习性能与训练时间的关系.....	68
4-6	对于逻辑回归模型，不同终端数下学习性能与训练时间的关系.....	69
4-7	对于CNN模型，不同终端数下学习性能与训练时间的关系.....	70

表 格

1-1	联邦边缘学习系统分布式训练机制.....	6
2-1	优化问题(2.16)的最优算法.....	22
2-2	第2章仿真参数.....	23
3-1	部分卸载场景下的最优带宽分配算法.....	42
3-2	时变信道场景中的顺序带宽分配算法.....	45
3-3	时变信道场景中模型参数分配和带宽分配的联合优化算法.....	45
3-4	第3章仿真参数.....	46
4-1	常用学习模型的损失函数.....	52
4-2	最优带宽分配算法.....	62
4-3	第4章仿真参数.....	65

缩写、符号清单、术语表

缩略词	英文全称	中文全称
5G	The 5th Generation	第五代移动通信
6G	The 6th Generation	第六代移动通信
AI	Artificial Intelligence	人工智能
AR	Augmented Reality	增强现实
BCD	Block Coordinate Descent	块坐标下降
CDMA	Code Division Multiple Access	码分多址
CNN	Convolutional Neural Network	卷积神经网络
CSI	Channel State Information	信道状态信息
D2D	Device-to-Device	终端直通
DNN	Deep Neural Network	深度神经网络
D-PSGD	Decentralized Parallel Stochastic Gradient Descent	去中心化并行随机梯度下降
eMBB	Enhanced Mobile Broadband	增强型移动带宽
FDMA	Frequency Division Multiple Access	频分多址
LUI	Learning Update Information	学习更新信息
MDP	Markov Decision Process	马尔可夫决策过程
MIMO	Multiple Input Multiple Output	大规模多输入多输出
mmWave	Millimeter Wave	毫米波
mMTC	Massive Machine Type Communications	大规模机器通信
Non-IID	Non-Independent Identically Distributed	非独立同分布
OFDMA	Orthogonal Frequency Division Multiple Access	正交频分多址
PS	Parameter Server	参数服务器
SGD	Stochastic Gradient Descent	随机梯度下降

缩略词	英文全称	中文全称
SGP	Stochastic Gradient Push	随机梯度推送
SNR	Signal-to-Noise Ratio	信噪比
TDMA	Time Division Multiple Access	时分多址
UDN	Ultra-Dense Network	超密集网络
URLLC	Ultra-Reliable Low Latency Communications	超可靠低时延通信
VR	Virtual Reality	虚拟现实

目 次

致谢	I
摘要	II
Abstract.....	IV
插图	VII
表格	VIII
缩写、符号清单、术语表.....	IX
目次	
1 绪论.....	1
1.1 无线边缘学习技术概述	2
1.1.1 边缘学习技术.....	2
1.1.2 无线边缘学习中的通信技术.....	4
1.1.3 无线边缘学习技术的主要挑战.....	4
1.2 无线边缘学习研究现状	5
1.2.1 联邦边缘学习系统.....	5
1.2.2 模型分割边缘学习系统.....	8
1.2.3 去中心化边缘学习系统.....	9
1.3 本论文主要创新点和内容安排	10
2 联邦边缘学习系统中用户选择与通信资源优化.....	13
2.1 系统模型	13
2.1.1 联邦边缘学习系统.....	14
2.1.2 DNN模型	15
2.1.3 通信模型.....	16
2.2 性能分析与问题建模	16
2.2.1 数据重要性分析.....	17
2.2.2 端到端时延分析.....	17

2.2.3	问题建模	18
2.3	算法设计	19
2.3.1	问题转换	19
2.3.2	最优用户选择策略	20
2.3.3	最优系统时延和通信资源分配	20
2.3.4	最优求解算法	21
2.4	仿真验证与性能分析	21
2.4.1	仿真设置	22
2.4.2	泛化能力测试	23
2.4.3	不同算法的性能比较	23
2.5	本章小结	26
3	模型分割边缘学习系统中模型参数分配与通信资源优化	28
3.1	系统模型	29
3.1.1	模型分割边缘学习系统	29
3.1.2	学习模型	30
3.1.3	通信模型	31
3.1.4	时延模型	32
3.2	问题建模	34
3.2.1	每轮时延最小化问题	34
3.2.2	基于MDP的一轮时延最小化问题	35
3.3	算法设计	37
3.3.1	模型参数分配优化算法	38
3.3.2	带宽分配优化算法	38
3.3.3	模型参数分配和带宽分配的联合优化算法	44
3.4	仿真验证与性能分析	45
3.4.1	仿真设置	45
3.4.2	学习性能	46
3.4.3	时延性能	47
3.5	本章小结	49
4	去中心化边缘学习系统中通信资源优化	50
4.1	系统模型	51
4.1.1	去中心化边缘学习系统	51

4.1.2 时延模型	54
4.2 问题建模	54
4.3 算法设计和协议设计	58
4.3.1 广播传输速率优化	59
4.3.2 带宽分配	60
4.3.3 实现去中心化边缘学习系统的协议	62
4.3.4 收敛性分析	63
4.4 仿真验证与性能分析	64
4.4.1 仿真设置	64
4.4.2 不同系统带宽下学习性能比较	66
4.4.3 不同终端数下学习性能比较	67
4.5 本章小结	69
5 总结与展望	71
参考文献	73
附录	79
A.1 第二章的相关证明	79
A.1.1 定理2.1的证明	79
A.1.2 定理2.2的证明	79
A.1.3 定理2.3的证明	80
A.2 第三章的相关证明	81
A.2.1 引理3.2的证明	81
A.2.2 引理3.3的证明	82
A.3 第四章的相关证明	83
A.3.1 引理4.1的证明	83
A.3.2 定理4.1的证明	83
A.3.3 引理4.2的证明	83
A.3.4 定理4.2的证明	84
A.3.5 定理4.3的证明	85
攻读硕士学位期间的科研成果	86

1 绪论

目前，第五代移动通信（The 5th Generation, 5G）正在全球范围内标准化和部署。实现5G的关键技术包括毫米波（Millimeter Wave, mmWave）蜂窝通信技术^[1,2]、大规模多输入多输出（Multiple Input Multiple Output, MIMO）^[3,4]以及超密集网络（Ultra-Dense Network, UDN）^[5,6]等。基于这些技术，5G网络具备高速率、低时延和广连接三大特性。因此，5G满足三大应用场景的需求，包括增强型移动带宽（Enhanced Mobile Broadband, eMBB）、大规模机器通信（Massive Machine Type Communications, mMTC）以及超可靠低时延通信（Ultra-Reliable Low Latency Communications, URLLC）^[7]。另一方面，随着近年来人工智能（Artificial Intelligence, AI）领域的不断发展以及计算机能力的不断提升，AI被广泛地应用于无线通信领域中。由此涌现和发展了许多新兴应用，例如智慧物联网、增强现实（Augmented Reality, AR）、扩展虚拟现实（Virtual Reality, VR）以及自动驾驶等。这些新兴应用的发展将导致未来移动通信量呈现爆炸式增长。可以预见，5G系统很难适应未来巨大的移动通信量。为了满足新兴应用对更高性能无线通信系统的需求，学术界和工业界开始了对下一代移动通信（The 6th Generation, 6G）技术的研究。

迄今为止，国内外已经有多个研究组对6G的关键技术以及潜在应用场景进行了展望^[8-12]。毫无疑问，6G系统将经历前所未有的变革。首先，6G系统将利用太赫兹和可见光波段的丰富频谱资源，以满足对更高系统容量和峰值数据速率的需求。其次，6G系统将会是空-地-海一体化网络，从而提供完整的全球覆盖。随着AI技术的不断发展，6G系统将会是一个万物互联的智能平台。在AI技术和无线通信技术的协同作用下，6G系统能够提供新兴智能服务并且实现资源和网络的高效传输、控制和管理。此外，6G系统将会是一个绿色、可持续和安全的系统。从6G的发展愿景中可以看出，新兴智能服务将会是6G的主要应用场景之一，这表明AI将会成为实现6G的关键技术之一。因此，在无线通信系统中实现AI成为了主流的研究方向之一，引领了通信和计算融合的趋势。其关键思想是利用大规模分布式终端的丰富数据来学习用于网络规划或优化的AI模型。由此，出现了一种新的计算范式，即无线边缘学习^[13,14]。它可以快速访问分布式数据并利用各种边缘终端的计算资源，通过在网络边缘侧部署AI算法，为终端提供智能服务。作为赋能6G网络的技术之一，

无线边缘学习将成为学术界和工业界的重点研究内容之一。

1.1 无线边缘学习技术概述

在无线网络中，训练数据由数亿个终端产生，并不均匀地分布在大量资源受限的终端上，而每个终端仅拥有一小部分数据^[15]。这使得在终端难以实现AI算法。为了利用丰富的数据并训练一个高质量的预测模型，无线边缘学习成为了重要的技术手段。基于移动边缘计算的创新架构，现在已经能够在网络边缘实现云计算能力并将学习任务从云中心迁移到边缘服务器^[16]。因此，无线边缘学习能够共同利用边缘终端和边缘服务器的计算资源，从而显著减少通信时延，大大节省移动能耗，有效缓解核心网络的拥塞，并且大大提高学习效率。本节将依次介绍边缘学习的类别、无线边缘学习中常用的通信技术以及无线边缘学习技术的主要挑战。

1.1.1 边缘学习技术

边缘学习技术主要有三种架构，包括联邦边缘学习、模型分割边缘学习以及去中心化边缘学习^[14, 17]，如图1-1所示。

- **联邦边缘学习**：随着数据隐私安全越来越受到重视，谷歌提出的联邦学习^[18, 19]被广泛研究。联邦学习是一种训练数据去中心化的机器学习解决方案。在联邦学习框架下，终端可以在本地保留所有训练数据的前提下协作训练一个共享的高质量预测模型，从而保障大数据交换时终端的信息安全和隐私安全。在无线网络中部署联邦学习被称为联邦边缘学习。联邦边缘学习系统由多个终端和一个参数服务器（Parameter Server, PS）组成，每个终端拥有一部分训练数据。为了充分利用终端本地的丰富数据，终端会定期将其模型参数或者梯度上传到PS，然后PS将其聚合以获得高质量的全局模型。边缘学习主要分为同步学习和异步学习两种。对于同步学习，PS需要等待所有终端的模型参数或者梯度上传完成后再进行聚合。而对于异步学习，PS则无需等待所有终端完成上传，在接收到部分终端的模型参数或者梯度后即可开始聚合。为了便于理论分析，本论文只考虑同步学习的情形。于是，联邦边缘学习一轮训练迭代的步骤描述如下。首先，每个终端利用本地数据集训练本地模型。接着，终端将本地计算得到的模型参数或者梯度上传至PS。PS在接收到所有终端的模型参数或者梯度之后进行平均聚合得到全局模型参数或梯度，并将其发送给各个终端。最后，各个终端在接收到全局模型参数或梯度后，更新其本地模型。循环执行以上步骤，直至全局模型收敛为止。由此，可以得到一个基于整个数据集的高质量全局模型。




图 1-1 边缘学习技术场景分类

- **模型分割边缘学习**：是指在无线网络中部署基于模型分割的分布式训练框架^[20, 21]。该分布式训练框架旨在通过模型分割将大规模学习任务分布在多个资源受限的终端上。与联邦边缘学习不同的是，模型分割边缘学习没有考虑数据隐私问题，它的设计目的是为了解决大规模模型训练问题。模型分割边缘学习系统由多个终端和一个PS组成，其中参与训练的终端被划分为多个组，每个组负责训练指定的模型参数块。在该系统中，每个终端拥有一部分训练数据并且每个组拥有完整的训练数据。PS将模型参数划分为参数块，并为每个组分配参数块。因此，每个终端只需训练模型的一部分，而不是像联邦边缘学习系统中那样训练整个模型，从而克服了终端的资源限制，降低了能耗。然后，PS从终端收集模型信息进行聚合，并更新相应的参数块。模型分割边缘学习一轮训练迭代的步骤描述如下。首先，PS将整个模型参数发送给所有终端，并为每个组分配模型参数块。接着，每个参数块的梯度或者近端梯度由一个组负责计算。每个终端利用其本地数据集计算所分配参数块的梯度或者近端梯度。最后，所有终端将其相应参数块的梯度或近端梯度上传至PS。PS在接收到所有

组的梯度或者近端梯度之后进行平均聚合，并更新相应的参数块。循环执行以上步骤，直至模型收敛。由此，可以得到一个高质量的大规模学习模型。

- 去中心化边缘学习：与上述两种架构不同，去中心化边缘学习不依赖于PS来收集模型信息，而是在终端之间传输模型信息以训练模型。每个终端需要在本地聚合模型。去中心化边缘学习一轮迭代的步骤描述如下。首先，每个终端利用其本地数据集更新其本地模型。接着，终端之间互相分享其本地模型。一方面，每个终端将其本地模型参数发送给其他终端。另一方面，每个终端接收其他终端分享的本地模型参数，经过平均聚合得到全局模型参数并更新其本地模型。循环执行以上步骤，直至全局模型收敛为止。由此，可以得到一个基于整个数据集的高质量全局模型。

1.1.2 无线边缘学习中的通信技术

在无线网络中部署不同的边缘学习技术，系统将采用不同的通信技术。对于联邦边缘学习系统和模型分割边缘学习系统，PS部署在基站侧。在每轮训练迭代中，移动终端通过时分多址（Time Division Multiple Access, TDMA）、码分多址（Code Division Multiple Access, CDMA）、频分多址（Frequency Division Multiple Access, FDMA）以及正交频分多址（Orthogonal Frequency Division Multiple Access, OFDMA）等多址方式将模型信息上传至基站。对于所有终端来说，全局模型是相同的。因此，在完成全局模型聚合之后，基站将全局模型信息广播给所有终端。对于去中心化边缘学习系统，基站侧不配有PS，并且不参与模型训练。终端之间可以通过终端直通（Device-to-Device, D2D）通信链路^[22, 23]进行模型信息的传输。具体地，终端可以采用广播、单播或者多播等通信模式^[24]发送模型信息给其他终端。

1.1.3 无线边缘学习技术的主要挑战

近年来，无线边缘学习技术被学术界和工业界广泛研究，并取得了一定的成果。但对无线边缘学习系统的分析和应用仍然面临着诸多挑战。

其一，无线边缘学习面临性能评估难的挑战。传统的机器学习方法要求将训练数据集集中在一台机器或者数据中心中进行学习。因此，系统的学习性能，包括模型的训练准确率以及收敛速率等，通常仅取决于训练的超参数。与集中式学习不同的是，无线边缘学习系统的学习性能会受到多个因素的影响，例如数据分布、模型聚合准确率以及无线通信资源的限制等。具体地，移动终端数据分布可能受到地理位置、用户的特定习惯以及使用频率等因素的影响。因此，在无线边缘学习系统中，终端数据分布往往是非独立同分布

(Non-Independent Identically Distributed, Non-IID) 且数量不均衡的, 这将在一定程度上影响系统的学习性能。除此之外, 在模型信息传输的过程中, 若部分终端的模型信息丢失会使得聚合所得全局模型与真实全局模型之间存在模型偏差, 从而影响系统的学习性能。在无线网络中, 由于通信资源是有限的且信道会受到干扰以及噪声等不可靠因素的影响, 系统的训练时延也会受到影响, 从而影响模型的收敛速率。因此, 需要研究边缘学习训练架构以及无线信道传输对无线边缘学习系统性能的影响机理。

其二, 无线边缘学习面临计算和通信瓶颈的挑战。传统的边缘学习系统往往旨在设计高效的学习算法以提高系统的学习性能。但对于无线边缘学习系统来说, 无线通信网络的容量以及终端的计算能力对于系统学习性能的影响不容忽视。一方面, 无线通信资源(如带宽等)是有限的。由于模型信息(如模型参数、梯度等)的数据量较大, 通过无线信道传输模型信息产生的通信时延是系统训练时延的决定因素之一。无线通信资源稀缺或者无线信道质量较差会导致通信时延增加, 从而降低系统的学习效率。另一方面, 终端的计算能力是有限的, 其取决于终端的硬件配置以及计算资源。由此, 本地模型计算产生的计算时延是系统训练时延的又一决定因素。同样地, 终端的计算能力较差会导致计算时延增加, 从而降低系统的学习效率。因此, 需要设计通信与计算的联合优化方法以解决无线边缘学习系统的计算和通信瓶颈。具体地, 为了提高无线边缘学习系统的学习性能, 需要综合考虑模型参数选择和分配、无线信道状态信息(Channel State Information, CSI)、用户调度以及资源分配等因素。对于联邦边缘学习系统, 由于模型参数的数据量较大且无线通信资源有限, 当传输模型参数的终端数量较多时容易引发网络拥塞, 从而严重影响系统的学习性能。此时, 需要选择性地传输模型参数, 比如可以根据数据重要性和CSI选择模型参数上传。对于模型分割边缘学习系统, 由于终端的算力有限, 当计算能力较差的终端分配到较多的模型参数时, 本地计算时延将大大增加。为了减小本地模型计算对系统学习性能的影响, 需要联合考虑模型参数分配和通信资源优化。因此, 综合考虑模型参数优化和通信资源优化将给无线边缘学习带来新的挑战。

1.2 无线边缘学习研究现状

近几年, 学术界和工业界对无线边缘学习系统开展了一系列研究。本小节将主要介绍联邦边缘学习系统、模型分割边缘学习系统以及去中心化边缘学习系统的相关工作。

1.2.1 联邦边缘学习系统

目前, 考虑到通信瓶颈以及本地计算瓶颈等问题, 学者提出了多种面向联邦边缘学习

系统的分布式训练机制，如表1-1所示。

表 1-1 联邦边缘学习系统分布式训练机制

切入点	方案	解决的问题	举例
无线通信	无线资源分配	通信瓶颈 无线信道影响	[25, 26]: 传统资源分配 [27, 28]: 噪声对收敛速率影响分析 [29, 30]: 考虑传输误差资源分配
	用户调度	通信瓶颈	[31]: 传统调度方案分析 [32–34]: 联合考虑模型优化和信道质量的用户调度策略
	新型空口设计	通信瓶颈	[35–38]: 空中计算
模型训练	传输参数压缩	通信瓶颈	[39–41]: 稀疏化 [42–44]: 量化
	本地计算量调整	计算瓶颈	[45, 46]: 模型剪枝 [47, 48]: 模型蒸馏 [49]: 学习批量大小调整

1.2.1.1 解决通信瓶颈的相关研究

在联邦边缘学习系统中，终端需要不断与PS进行交互以训练全局模型。由于需要传输的数据量非常大且无线通信资源有限，巨大的通信成本是影响系统学习性能的主要因素之一。目前的研究主要以无线通信和模型训练过程为切入点来解决这一问题。

由于无线通信的影响，一些研究工作通过无线资源分配^[25–30]、用户调度^[31–34]以及空中计算^[35–38]等技术减少通信开销，从而提升联邦边缘学习系统的学习性能。

无线资源分配：在联邦边缘学习系统中，优化无线资源分配，包括功率资源分配以及频谱资源分配等，有助于减少训练时延、能耗并提高模型的收敛速率。文献[25, 26]通过联合考虑功率资源分配、通信资源分配以及训练准确率实现了联邦边缘学习系统训练时延与能耗的折衷。由于无线信道会受到噪声及干扰等因素的影响，一些工作研究了这些不可靠因素对于联邦边缘学习系统学习性能的影响。文献[27, 28]分析了噪声对于模型收敛速率的影响。文献[29]联合考虑了传输功率分配、上行链路资源块分配以及用户选择以减小误码率对于系统学习性能的影响，并进一步在文献[30]中提出了概率用户选择和通信资源分配的联合优化方案以减少联邦边缘学习系统的训练时延。

用户调度：对于联邦边缘学习系统，用户调度是指在每一轮训练迭代中，只选择部分终端上传模型参数至PS参与全局模型聚合。考虑到上行链路的通信资源有限，当大量终端同时上传模型参数时，用户调度策略可以有效缓解通信资源紧张的问题，从而大大减少系统的训练时延。文献[31]比较了比例公平调度、随机调度以及轮询调度这三种传统调度策略对于模型收敛速率的影响。结果表明，对于联邦边缘学习系统，比例公平调度在高信干扰场景下的收敛性能最佳。然而，在联邦边缘学习系统中，用户调度策略的设计不仅要考虑对于训练时延的影响，还要考虑对于模型收敛速率的影响。为此，文献[32]提出了一种用户调度策略，可以基于终端的CSI尽可能多地选择终端参与训练以提高模型的收敛速率。文献[33]提出了联合考虑模型参数时效性和瞬时CSI的用户调度策略。针对具有不完全CSI的无线信道，文献[34]提出了通信资源分配、用户调度以及CSI反馈的联合优化方案，并定量分析了模型的收敛速率。

空中计算：与传统的多址接入技术不同，空中计算利用无线多址信道的叠加特性可以实现通信和计算的融合。基于此原理，文献[35]指出联邦边缘学习系统可以采用空中计算进行模型聚合，这使得全局模型可以在传输参数的同时完成聚合，从而极大地提高通信效率以及系统的学习效率。此外，该文献联合考虑了用户选择和波束成形设计，旨在满足模型聚合均方误差的要求下，最大化参与训练的终端个数。为了实现低时延的联邦边缘学习系统，文献[36]提出了一种利用空中计算的宽带模拟聚合方案，并得出了两种通信与学习的折衷方案。在此基础上，文献[37]设计了一种数字宽带空中聚合方案，以评估无线信道损失对模型收敛的影响。此外，对于采用模拟空中聚合的联邦边缘学习系统，文献[38]定量分析了该系统的收敛速率，并提出了一种能耗感知的动态用户调度策略，以提高系统的学习性能。

此外，由于需要传输的数据量非常大，一些研究工作以模型训练过程为切入点，通过稀疏化^[39-41]以及量化^[42-44]等方法压缩传输参数，从而减少联邦边缘学习系统的通信开销。具体地，文献[39]结合随机优化理论提出了一种稀疏随机梯度的方法，可以在保证模型训练准确率的前提下，减少随机梯度的编码长度，从而减少通信开销。文献[40]采用“Top- k ”稀疏化方法，通过只保留最大的 k 个梯度元素，大大降低了梯度向量的维度。基于“Top- k ”稀疏化方法，文献[41]提出了一种专为联邦边缘学习系统设计的稀疏三元压缩方法来压缩梯度，以减少上下行通信的成本。此外，文献[42, 43]通过量化模型参数或者梯度提高了通信效率，并且保证了模型的收敛性能。文献[44]提出了一种自适应调整传输比特数的量化策略，以进一步提升模型的收敛速率。

1.2.1.2 解决计算瓶颈的相关研究

由于终端的计算能力有限，本地模型计算产生的时延也是影响联邦边缘学习系统学习性能的一个重要因素。因此，一些工作从减少本地计算量的角度展开研究，以解决联邦边缘学习系统的计算瓶颈问题。随着深度学习的不断发展，深度神经网络（Deep Neural Network, DNN）的深度和宽度越来越大，以满足从大量数据样本中学习高级语义特征的需求。这导致模型参数的数目不断增加，部分模型参数变得冗余。为了剔除冗余参数以减少本地模型计算量，文献[45]在联邦边缘学习系统中引入模型剪枝技术，通过联合优化剪枝率、用户选择以及无线资源分配最大化模型的收敛速率。考虑到联邦边缘学习系统的统计异构性和系统异构性，文献[46]提出了一种自适应剪枝方案以减少计算开销，同时保证了模型的训练准确率。模型蒸馏技术旨在将大模型学习到的知识迁移到小模型上，并用以指导小模型的训练，从而减小模型规模。文献[47, 48]通过应用模型蒸馏技术提高了联邦边缘学习系统的训练速度。此外，为了动态调整本地计算量以提高联邦边缘学习系统的学习效率，文献[49]优化了学习批量大小以动态适应无线信道条件。

上述研究工作虽然提出了多种用户选择以及无线资源分配方案，但仍没有工作考虑基于数据重要性和CSI的用户选择以及无线资源分配方案。为了进一步提高联邦边缘学习系统的学习效率，如何设计基于数据重要性和CSI的用户选择以及无线资源分配方案是本文的第一个研究点。

1.2.2 模型分割边缘学习系统

尽管已经有许多研究工作致力于解决联邦边缘学习系统的通信瓶颈，但对于训练复杂的高维学习模型来说，该系统仍然会产生较大的通信开销。为了解决大规模模型训练问题，模型分割边缘学习系统开始受到关注。目前，关于模型分割边缘学习系统的研究仍处于起步阶段，已有工作大多致力于分析基于模型分割分布式训练框架的学习性能，仅有少数工作对模型分割边缘学习系统的关键问题——无线资源分配以及模型参数优化等进行分析。

文献[20, 21]提出了基于模型分割的分布式训练框架，旨在将大规模学习任务分布在多个资源受限的终端上。基于块坐标下降（Block Coordinate Descent, BCD）算法^[50]，该分布式训练框架可以用于训练具有可分解目标函数的学习模型，例如支持向量机、线性回归以及逻辑回归等。但对于更加复杂的卷积神经网络（Convolutional Neural Network, CNN）模型，由于其目标函数不具备可分解性，上述分布式训练框架的学习性能欠佳。为了解决这个问题，文献[51, 52]提出了将BCD算法扩展至训练CNN模型的方法。通过引入辅助变

量并对其进行适当调节,上述分布式训练框架可以在不同的训练迭代中单独训练CNN模型的各层。基于这种方法,上述分布式训练框架可以更高效地训练CNN模型。此外,还有一些研究工作旨在提升基于模型分割分布式训练框架的学习性能。在保证模型训练准确率的前提下,文献[53]提出终端可以利用过时的模型参数进行本地模型计算,以减少等待掉队终端的时间,从而提高模型的收敛速率。文献[54]采用优先级传输法,即允许先完成计算的终端上传模型参数,同时允许计算与通信重叠,从而大大减少训练时延。基于DNN模型的训练特性,文献[55]将下行通信与模型前向计算重叠,并将上行通信与模型反向计算重叠,以进一步减少训练时延。

对于模型分割边缘学习系统,现有的研究工作集中于通过减少训练时延来提高系统的学习性能^[56,57]。在快衰落信道和慢衰落信道下,文献[56]提出了模型参数分配和带宽分配的联合优化算法,以最小化系统的训练时延。针对宽带信道上的模型分割边缘学习系统,文献[57]为了提高系统的学习性能,提出了针对可分解学习模型的模型参数分配、子信道分配和传输功率分配的联合优化算法。此外,该文献还将所提算法扩展至适用于训练DNN模型的算法,以进一步提高系统对于大规模复杂模型的学习性能。

上述研究工作虽然针对模型分割边缘学习系统提出了模型参数分配和无线资源分配的联合优化方案,但这些工作都基于静态信道的假设。目前,还没有文献对时变无线信道场景中的模型分割边缘学习系统进行研究。因此,在更复杂的无线通信场景中,为了提高模型分割边缘学习系统的学习性能,如何设计模型参数分配和无线资源分配的联合优化方案是本文的第二个研究点。

1.2.3 去中心化边缘学习系统

与上述两种无线边缘学习系统不同,去中心化边缘学习系统不需要PS参与模型训练。终端之间可以利用D2D通信技术进行数据传输,以完成模型训练。目前,关于去中心化边缘学习系统的研究还比较少,已有工作大多致力于分析去中心化学习框架的学习性能,仅有部分工作分析了基于D2D通信的去中心化边缘学习系统的学习性能。

对于去中心化学习框架,由于训练过程中需要终端之间进行模型参数传输,网络拓扑结构会影响学习性能。因此,许多工作研究了不同网络拓扑下去中心化学习框架的学习性能^[58-63]。对于无向图,文献[58]提出了去中心化并行随机梯度下降(Decentralized Parallel Stochastic Gradient Descent, D-PSGD)算法,即每个终端仅与其相邻终端交换本地模型。该文证明了去中心化学习的性能优于集中式算法。然而,D-PSGD算法要求终端上的数据集差异不大。为了扩大应用范围,文献[59]提出了D-PSGD算法的扩展算法,以减小方差的

影响。该扩展算法对终端之间的大数据方差具有鲁棒性。文献[60]提出了一种基于梯度跟踪的随机去中心化学习算法，该算法可以有效地找到一阶驻点。为了进一步提高去中心化学习框架的学习性能，文献[61]提出了一种结合方差缩减和梯度跟踪的算法。对于时变图，文献[62]给出了去中心化学习算法的收敛速率分析。为了加速训练过程，文献[63]提出了随机梯度推送（Stochastic Gradient Push, SGP）算法。对于稀疏的有向时变图，该算法能够高效地训练学习模型。此外，文献[64, 65]提出可以通过模型压缩来减少去中心化学习框架的通信开销，以提高训练速度。

目前，只有少数工作研究了基于D2D通信的去中心化边缘学习系统^[66-69]。文献[66]在无线网络中部署了去中心化学习框架，并提出利用空中计算技术来减少通信时延。同时，该文献还提出了一种用户调度策略，以最小化无线信道中的干扰。基于数字和模拟传输方案，文献[67]实现了在无线D2D网络中部署去中心化学习框架，并且提出了基于图着色算法的调度策略，以减小无线干扰对系统学习性能的影响。基于此，文献[68]进一步分析了该去中心化边缘学习系统中模型的收敛速率。此外，文献[69]提出可以利用深度强化学习技术自适应地构造网络拓扑结构，从而有效提高去中心化边缘学习系统的训练效率。

上述研究工作虽然提出了用户调度等方法来提高去中心化边缘学习系统的学习性能，但仍没有工作考虑传输错误对于模型训练的影响。由于随机信道的衰落和噪声，无线D2D通信通常是不可靠的。由此导致的传输失败会影响终端之间的模型交换，从而降低系统的学习性能。因此，如何设计合适的优化目标以及无线资源分配方案，以减少不可靠传输并提高去中心化边缘学习系统的学习性能是本文的第三个研究点。

1.3 本论文主要创新点和内容安排

如前所述，关于无线边缘学习系统的关键技术挑战，仍然有许多问题需要研究。首先，对于联邦边缘学习系统，目前还没有相关工作设计基于数据重要性和CSI的用户选择以及无线资源分配方案，亟需一种新型用户选择方案，进一步提高系统的学习效率。其次，对于模型分割边缘学习系统，考虑到无线信道的时变特性，已有的模型参数分配以及无线资源分配方案不再适用。因此，在更复杂的无线通信场景中，需要重新设计模型参数分配以及无线资源分配方案，以提高模型的收敛速率。最后，对于去中心化边缘学习系统，目前没有相关工作考虑传输错误对于模型训练的影响。如何设计合适的优化目标以及无线资源分配方案，以减少不可靠传输需要进一步深入研究。针对这些问题，本论文将分别为上述三种无线边缘学习系统设计高效的分布式资源优化方案。

本论文的结构如图1-2所示。论文一共分为五章，其中第二章至第四章为主要研究内

容且均来源于作者已发表或在审稿中的论文。各章的内容安排及主要创新点如下所述：

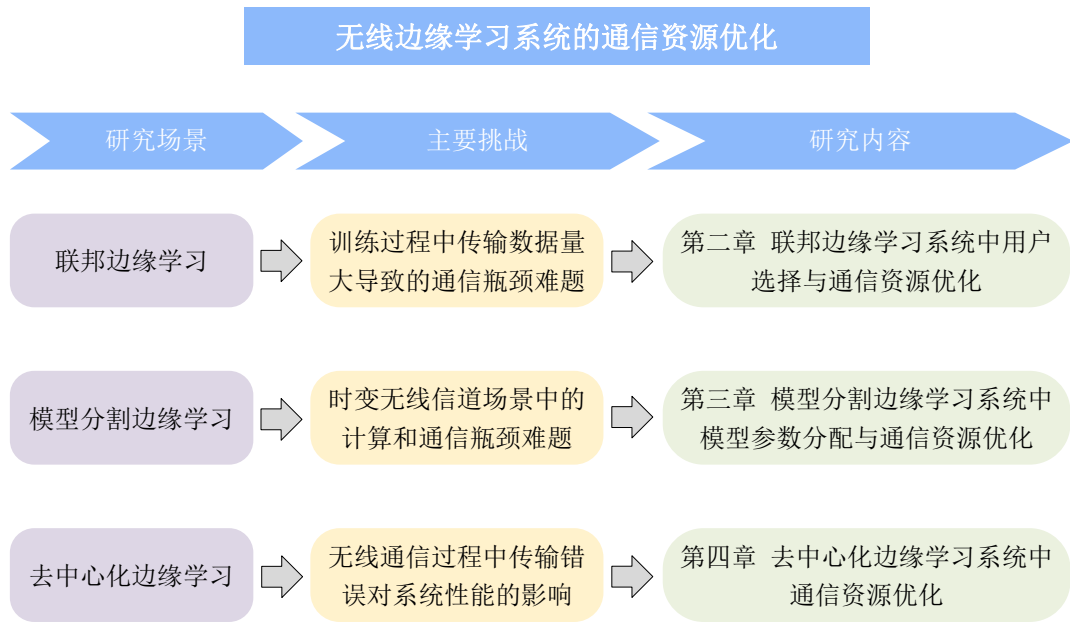


图 1-2 论文结构

第一章是绪论，介绍了无线边缘学习技术，分析了该技术的主要技术挑战，综述了无线边缘学习研究现状，并给出了论文的主要创新点和内容安排。

第二章针对联邦边缘学习系统，提出了一种基于数据重要性和CSI的用户选择策略以及无线资源分配方案，以解决需要传输的模型参数数据量大导致的通信瓶颈问题。具体而言，为了量化每个终端的数据重要性，首先分析了损失衰减与梯度的模的平方之间的关系。然后通过联合考虑用户选择和通信资源分配，建模了一个组合优化问题以最大化联邦边缘学习系统的学习效率。经过优化问题转换和松弛，得出了最优用户选择策略和通信资源分配，并设计了一个多项式时间最优算法。最后，采用了两个常用的DNN模型进行仿真。实验结果表明，本文提出的算法具有较强的泛化能力。同时，与其他传统算法相比，本文提出的算法可以提高系统的学习效率。

在第三章中，对于时变无线信道场景中的模型分割边缘学习系统，提出了一种模型参数分配和带宽分配的联合优化算法，以最小化系统的总时延。首先分析了最小化系统总时延等同于分别最小化每轮时延，并基于此结论建立了每轮时延最小化问题。然后，为了解决时变信道场景中未来CSI未知的挑战，推导得出了等价的一轮时延最小化问题。求解过程被分为两个步骤，一是在给定带宽分配下，得出了最优模型参数分配算法。二是在此基础上，提出了针对时变信道的次优带宽分配算法，该算法按顺序在每个相干时间内分配带宽。基于上述两个算法，设计了联合模型参数分配和带宽分配的次优算法。最后，通过仿

真验证了本文提出的算法可以减少系统的训练时延，提高模型的训练效率。

第四章针对去中心化边缘学习系统，提出了一种无线资源分配方案，以解决不可靠D2D通信导致的传输错误影响模型训练性能的问题。为了提高模型训练的性能，首先建立了一个优化问题，即在给定训练时延下，通过联合优化广播传输速率和带宽分配以最小化总模型偏差。接着，推导得出了在高信噪比（**Signal-to-Noise Ratio, SNR**）场景、带宽充足场景以及大时延场景下广播传输速率的最优解，该结果使得所有终端的一轮时延相等。然后提出了最优带宽分配算法以进一步提高系统的学习性能，该算法使得所有终端的偏差减少速率相等。此外，开发了一个协议用以实现去中心化边缘学习系统，并提供了所提算法的收敛性分析。最后，通过仿真验证了本文提出的算法可以提高模型的收敛速率以及准确率。

第五章是全文的总结与展望，总结了本论文的研究工作和主要贡献，并对未来的研究工作进行了展望。

2 联邦边缘学习系统中用户选择与通信资源优化

在联邦边缘学习系统中，终端与PS之间需要不断地传输模型参数或者梯度，以协作训练高质量的全局模型。由于模型参数或梯度的数据量非常大且无线通信资源有限，巨大的通信时延是阻碍系统学习性能提升的主要因素之一。为了解决联邦边缘学习系统的通信瓶颈问题，除了考虑优化无线通信资源分配之外，还可以考虑从模型训练的角度对系统进行优化，从而提高系统的学习效率。对于机器学习模型来说，并非所有数据对于模型训练的贡献都是同样重要的^[70]。由于训练数据不均匀地分布在大量资源受限的终端上，可以只选择具有重要数据的终端参与模型训练，从而减少需要传输的数据量。因此，本章考虑一种基于数据重要性的用户选择方案，旨在提高系统的学习效率。

然而，考虑基于数据重要性的用户选择方案存在两个关键问题。首先，由于地理位置以及用户特定习惯等因素的影响，终端拥有的数据是不同的，需要解决如何衡量终端数据重要性的问题。其次，如何基于数据重要性设计最优的用户选择方案？考虑到终端上传模型信息的通信时延受到无线信道质量的影响，选择具有重要数据但无线信道质量差的终端参与模型训练可能反而会降低系统的学习效率。基于上述两个问题，本章设计了一种基于数据重要性和CSI的用户选择策略以及通信资源分配方案，以提高联邦边缘学习系统的学习效率。

本章内容安排如下。2.1节介绍了联邦边缘学习系统模型。2.2节给出了数据重要性分析以及端到端时延分析，并建立了一个优化问题以最大化系统的学习效率。2.3节给出了基于数据重要性和CSI的最优用户选择策略以及最优通信资源分配并设计了相应的最优算法。2.4节给出了仿真结果并验证了所提算法的有效性。2.5节总结了本章内容。

2.1 系统模型

本节将首先介绍联邦边缘学习系统模型，然后依次介绍所涉及的DNN模型和通信模型。

2.1.1 联邦边缘学习系统

本章考虑如图2-1所示的一个联邦边缘学习系统，该系统包括一个基站和 K 个分布式终端，用集合 $\mathcal{K} = \{1, 2, \dots, K\}$ 表示。基站侧配有PS。每个终端利用本地数据集训练本地DNN模型。用 $\mathcal{D}_k = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_{N_k}, y_{N_k})\}$ 表示终端 k 的本地数据集，其中 \mathbf{x}_i 是训练样本， y_i 是相应的真实标签， N_k 是数据集的大小。在每个通信回合中，终端先将自己的梯度上传至PS。然后，PS收集所有终端的本地梯度并将其聚合为全局梯度。终端则利用由PS广播的全局梯度来更新其本地模型。最终，终端之间通过相互协作训练得到一个共享的全局模型。由于原始数据不会上传到PS，因此终端的隐私可以得到保护。

然而，由于无线通信资源的有限性，参加训练任务的终端数量受到限制。为了解决这个问题，本章通过共同考虑每个终端的学习更新信息（Learning Update Information, LUI）和CSI来提出一个用户选择策略。在每一个通信回合中，终端的数据都不是同等重要的。因此，本章仅根据数据重要性和信道传输速率选择部分终端上传其本地梯度。具体而言，以下七个步骤被定义为一个通信回合。

- 计算本地梯度：在第 n 个通信回合中，每个终端利用自己的本地数据集训练本地模型，其中 θ 表示DNN模型的参数集。本地梯度向量 $\mathbf{G}_k^\theta[n]$ 可以通过反向传播算法来计算。值得注意的是，因为不同的终端可能有不同的数据集，所以各个终端的本地模型和本地梯度可以不同。
- 上传本地梯度的模的平方：计算获得本地梯度向量 $\mathbf{G}_k^\theta[n]$ 后，每个终端计算其本地梯度的模的平方 $\|\mathbf{G}_k^\theta[n]\|_2^2$ ，并将其传输到PS。这里， $\|\cdot\|_2$ 表示 ℓ_2 范数。
- 选择终端：PS接收所有终端的本地梯度的模的平方。PS将依据数据重要性和信道传输速率来决定选择哪些终端参与训练任务。
- 上传被选择终端的本地梯度：在此步骤中，那些被选择的终端通过TDMA的方式将其本地梯度上传到PS。
- 聚合全局梯度：PS接收所有被选择终端的本地梯度，然后将其聚合为全局梯度，表示为：

$$\mathbf{G}^\theta[n] = \frac{1}{|\cup_k a_k \mathcal{D}_k|} \sum_{k=1}^K a_k |\mathcal{D}_k| \mathbf{G}_k^\theta[n], \quad (2.1)$$

其中， $a_k \in \{0, 1\}$ 表示终端 k 是否被选择，即 $a_k = 1$ 表示终端 k 被选择，否则 $a_k = 0$ 。

- 广播全局梯度：在完成全局梯度聚合之后，基站将全局梯度广播给所有终端。

- 更新本地模型：接收到全局梯度之后，每个终端更新其本地模型。从数学角度来说，本地DNN模型由以下式子更新，表示为：

$$\boldsymbol{\theta}[n+1] = \boldsymbol{\theta}[n] - \xi[n]\mathbf{G}^\theta[n], \quad (2.2)$$

其中， $\xi[n]$ 是第 n 个通信回合的学习率。

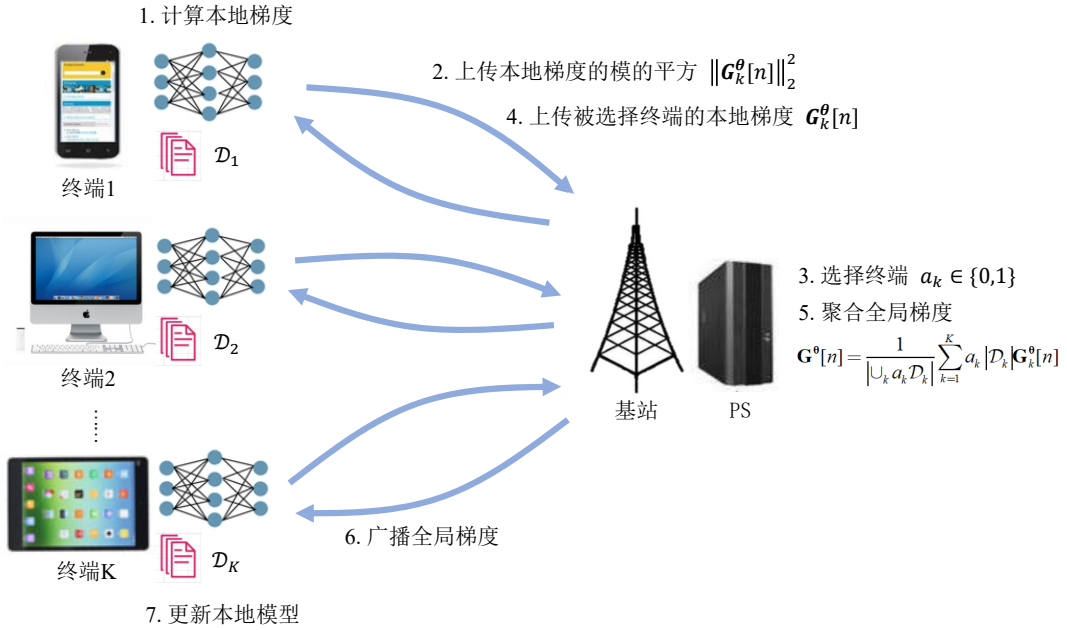


图 2-1 联邦边缘学习系统模型

循环执行以上七个步骤，直到全局模型收敛为止。在训练过程中，每个通信回合中终端的本地梯度和CSI都不尽相同。因此，在每个通信回合中，PS都应运行最优算法以选择终端。

2.1.2 DNN模型

在本章中，所有终端都采用相同的DNN模型进行训练。为了衡量学习输出与真实标签 y_i 之间的预测误差，定义样本损失函数为 $l(\boldsymbol{\theta}, \mathbf{x}_i, y_i)$ 。因此，终端 k 的本地损失函数和全局损失函数可以分别表示为：

$$L_k(\boldsymbol{\theta}, \mathcal{D}_k) = \frac{1}{|\mathcal{D}_k|} \sum_{(\mathbf{x}_i, y_i) \in \mathcal{D}_k} l(\boldsymbol{\theta}, \mathbf{x}_i, y_i), \quad (2.3)$$

$$L(\boldsymbol{\theta}) = \frac{1}{|\cup_k a_k \mathcal{D}_k|} \sum_{k=1}^K a_k |\mathcal{D}_k| L_k(\boldsymbol{\theta}, \mathcal{D}_k). \quad (2.4)$$

在训练过程中，全局损失函数 $L(\boldsymbol{\theta})$ 是要最小化的目标函数。本章旨在加速训练任务并训练一个高质量的全局模型。在不失一般性的前提下，本章用随机梯度下降（Stochastic Gradient Descent, SGD）作为优化算法。终端 k 的本地梯度向量表示为：

$$\mathbf{G}_k^\theta = \nabla L_k(\boldsymbol{\theta}, \mathcal{D}_k), \quad (2.5)$$

其中， ∇ 表示梯度算子。

2.1.3 通信模型

如上所述，在每个通信回合中，分布式终端和PS需要互相交换数据。本章采用了两种常用的数据传输方法，即TDMA和广播。

首先，被选择的终端通过TDMA的方式将本地梯度上传至PS。具体而言，一个时间帧被划分为 n 个时隙。每个终端在自己的时隙中传输数据。根据文献[71]可知，LTE标准中每个时间帧的长度为10ms。实际上，梯度的传输时延为秒级，其长度远远大于一个时间帧的长度^[72]。因此，本章用上行链路的平均信道容量来评估终端的传输速率^[73]，而不是瞬时信道容量，表示为：

$$R_k^U = W \mathbb{E}_h \left\{ \log_2 \left(1 + \frac{p_k^U |h_k^U|^2}{N_0} \right) \right\}, \quad (2.6)$$

其中， h_k^U 表示终端 k 的上行链路信道功率增益， p_k^U 表示相应的传输功率密度， \mathbb{E}_h 表示对上行链路信道功率增益的期望， W 是系统带宽， N_0 是噪声功率密度。

全局梯度聚合完成之后，基站将把全局梯度广播给所有终端。这样，所有终端能够同步接收到全局梯度。用 h_k^D 表示终端 k 的下行链路信道功率增益， p^D 表示所有终端的传输功率密度。因此，下行链路的传输速率可以表示为：

$$R^D = W \min_{k \in \mathcal{K}} \left\{ \mathbb{E}_h \left\{ \log_2 \left(1 + \frac{p^D |h_k^D|^2}{N_0} \right) \right\} \right\}. \quad (2.7)$$

值得注意的是，由于信道状态信息的时间尺度要远小于模型训练的时间尺度，为了减少资源分配的复杂度以及频繁地资源分配带来的开销，无线资源分配时采用与模型训练相同时间尺度范围内的平均信道状态信息来代替瞬时信道状态信息。

2.2 性能分析与问题建模

本节将首先提出一个指标用于衡量终端的数据重要性。然后，本节将分析每个通信回合中的端到端时延，并建立数学优化问题以最大化系统学习效率的下界。

2.2.1 数据重要性分析

在每个通信回合中，由于无线通信资源的有限性，只有部分终端被选择参与训练任务。根据文献[70]可知，不同的训练样本对模型训练的贡献不同。因此，本章根据数据重要性和信道传输速率来选择终端。为了量化数据重要性，本章定义损失衰减函数为：

$$\Delta L[n] = L(\boldsymbol{\theta}[n-1]) - L(\boldsymbol{\theta}[n]). \quad (2.8)$$

损失衰减函数 $\Delta L[n]$ 表示损失函数在第 n 个通信回合中的衰减量。从式(2.8)可知，在相同时间内，损失函数的衰减量越大，训练速度越快。换句话说，损失函数衰减量在某种程度上反映了数据的重要性。

根据文献[74]可知，损失函数衰减量与梯度的模的平方成正比。因此，在第 n 个通信回合中，损失函数衰减量的下界由下式给出^[74]：

$$\Delta L[n] \geq \beta \|\mathbf{G}^\theta[n]\|_2^2, \quad (2.9)$$

其中， β 为一常数，其值由学习率和模型本身的特性决定。因此，可以进一步将数据重要性与梯度向量的模的平方联系起来。基于以上讨论，本章利用终端本地梯度的模的平方来量化其数据重要性，表示为：

$$\rho_k = \beta \|\mathbf{G}_k^\theta[n]\|_2^2, \quad \forall k \in \mathcal{K}. \quad (2.10)$$

因此，在一个通信回合中，全局损失函数衰减量的下界可以表示为：

$$\Delta L = \sum_{k=1}^K a_k \rho_k. \quad (2.11)$$

2.2.2 端到端时延分析

如前所述，本章的目标是提高联邦边缘学习系统的学习效率。因此，一个通信回合的端到端时延应该被优化。一个通信回合的端到端时延的详细分析如下：

- 计算本地梯度：终端 k 的本地训练时延表示为 T_k^L 。
- 上传被选择终端的本地梯度：如前所述，只有那些被选择的终端将通过TDMA的方式把本地梯度上传到PS。所以，终端 k 的平均传输时延可以表示为：

$$T_k^T = a_k \frac{V}{\tau_k R_k^U}, \quad \forall k \in \mathcal{K}, \quad (2.12)$$

其中， τ_k 为终端 k 的时隙在一个时间帧中所占的比例， V 是梯度的数据量，该量对所有终端来说都是常数。

- 广播全局梯度：对于所有终端，下载全局梯度的时延为：

$$T^D = \frac{V}{R^D}. \quad (2.13)$$

- 更新本地模型：终端 k 更新本地模型的时延表示为 T_k^U 。

由于本地梯度的模的平方和 a_k 是标量，其传输所需的比特数足够小，相应的传输时延可以忽略不计。此外，PS通常具有强大的计算能力。因此，聚合全局梯度的时延也可以忽略不计。

然后，本章通过进一步分析获得一个通信回合内的总时延。值得注意的是，所有终端同步接收到全局梯度后开始更新本地模型。然而，由于终端可能具有不同的计算能力，其模型更新及训练的时延也会有所不同。因此，当所有终端都完成了模型更新和训练后，终端才被允许上传本地梯度的模的平方到PS。此外，当所有被选择终端都完成本地梯度的传输后，PS才开始聚合全局梯度。基于以上分析，该联邦边缘学习系统一个通信回合内的端到端总时延为：

$$T = \max_{k \in \mathcal{K}} \{T_k^U + T_k^L\} + \max_{k \in \mathcal{K}} T_k^T + T^D. \quad (2.14)$$

2.2.3 问题建模

本章旨在通过共同考虑用户选择和通信资源分配来提高联邦边缘学习系统的学习效率。根据文献[49]，本章采用以下准则来评估联邦边缘学习系统的学习性能。

定义 2.1. 联邦边缘学习系统的学习效率定义为：

$$E = \frac{\Delta L}{T}. \quad (2.15)$$

学习效率定义为给定时间 T 内全局损失函数的衰减速率，学习效率的提升意味着训练任务的加速。因此，用学习效率来评估联邦边缘学习系统的学习性能是合理的。本章的目标是减少每个通信回合的通信时延。此外，本章将系统学习效率的下界最大化。因此，本章的方案在一定程度上可以提高联邦边缘学习系统的学习效率。

基于以上分析，优化问题可以建模为：

$$\max_{\{a_k, \tau_k, T\}} E = \frac{\Delta L}{T} = \frac{\sum_{k=1}^K a_k \rho_k}{T}, \quad (2.16)$$

限制条件为：

$$\max_{k \in \mathcal{K}} \{T_k^U + T_k^L\} + T_k^T + T^D \leq T, \forall k \in \mathcal{K}, \quad (2.16a)$$

$$\sum_{k=1}^K \tau_k \leq 1, \quad (2.16b)$$

$$a_k \in \{0, 1\}, \forall k \in \mathcal{K}, \quad (2.16c)$$

$$\tau_k, T \geq 0, \forall k \in \mathcal{K}, \quad (2.16d)$$

其中，式(2.16a)表示在一个通信回合中，每个终端的端到端总时延均小于等于联邦边缘学习系统的端到端总时延，式(2.16b)表示上行链路的通信资源限制。为了便于描述，本章后面的小节中将 $\max_{k \in \mathcal{K}} \{T_k^U + T_k^L\} + T^D$ 重写为 T^C 。

2.3 算法设计

2.3.1 问题转换

显然，优化问题(2.16)是一个混合整数优化问题。由于优化问题(2.16)的目标函数非凸，直接求解该优化问题相当困难。结合式(2.12)与式(2.16a)，可以得出 T 与 a_k 和 τ_k 有关。当 a_k 和 τ_k 固定时，必须最小化变量 T 以最大化学习效率。因此，当式(2.16a)取等号时，即 $\tau_k = a_k \frac{V}{R_k^U(T - T^C)}$ ，所得解一定是优化问题(2.16)的最优解。

然而，整数约束，即式(2.16c)，使得优化问题(2.16)仍然难以求解。所以，将整数约束 $a_k \in \{0, 1\}$ 松弛为实值约束 $a_k \in [0, 1]$ 。因此，优化问题(2.16)可以被松弛为优化问题(2.17)，如下所示：

$$\max_{\{a_k, T\}} \frac{\sum_{k=1}^K a_k \rho_k}{T}, \quad (2.17)$$

限制条件为：

$$\sum_{k=1}^K \frac{a_k V}{R_k^U} \leq T - T^C, \quad (2.17a)$$

$$a_k \in [0, 1], \forall k \in \mathcal{K}, \quad (2.17b)$$

$$T \geq 0. \quad (2.17c)$$

下面的小节将先获得固定 T 时优化问题(2.17)的最优解。然后，当 T 变化时，继续求解优化问题(2.17)。最后求得了优化问题(2.16)的最优解。

2.3.2 最优用户选择策略

本节继续求解优化问题(2.17)。当 T 给定时，因为目标函数为凹且所有约束均为凸，所以优化问题(2.17)可以转换为一个标准的凸优化问题。因此，可以得出固定 T 时优化问题(2.17)的最优解，如下所示。

定理 2.1. 固定 T 时优化问题(2.17)的最优解如下：

- 当 $\rho_k R_k^U < \lambda^*$ 时， $a_k^* = 0$ ；
- 当 $\rho_k R_k^U > \lambda^*$ 时， $a_k^* = 1$ ；
- 当 $\rho_k R_k^U = \lambda^*$ 时， $0 \leq a_k^* \leq 1$ ，

其中， λ^* 是满足式(2.17a)的拉格朗日乘子的最优值。特别地，当 $\rho_k R_k^U = \lambda^*$ 时，实数 a_k^* 的值取决于(2.17a)。

证明：见附录A.1.1. □

根据定理2.1， λ^* 可以被视为终端的选择阈值。此外，终端 k 的选择优先级取决于其数据重要性 ρ_k 和上行链路传输速率 R_k^U 的乘积。一方面，具有更重要数据的终端对全局模型训练的贡献更大。另一方面，选择具有较大上行链路传输速率的终端可以缩短传输时延。因此，系统倾向于选择 $\rho_k R_k^U$ 乘积值较大的终端。这样做可以提高联邦边缘学习系统的学习效率。

2.3.3 最优系统时延和通信资源分配

本节将继续求解最优系统时延，并得到最优的通信资源分配，从而进一步提高联邦边缘学习系统的学习效率。到目前为止，已经得出了系统时延不变时的最优用户选择策略。基于此，最优系统时延一定是在式(2.17a)取等号时得到，即 $T = \sum_{k=1}^K \frac{a_k V}{R_k^U} + T^C$ 。为了得到 T 和 τ_k 的最优值，介绍以下定理。

定理 2.2. 优化问题(2.17)的最优解也是优化问题(2.16)的最优解。

证明：见附录A.1.2. □

定理2.2指出优化问题(2.17)取得最优解时, a_k 一定是整数解。基于此, 可以大大减少优化问题(2.17)的可行解范围。因此, 只需要比较当选择终端的总数变化时联邦边缘学习系统的学习效率即可。这里用上文所述的最优用户选择策略来选择系统中的终端。所以, 达到最大学习效率的 T^* 既是优化问题(2.17)的最优系统时延, 也是优化问题(2.16)的最优系统时延, 其表达式为:

$$T^* = \sum_{k=1}^K \frac{a_k^* V}{R_k^U} + T^C. \quad (2.18)$$

如前所述, 当式(2.16a)取等号时, 所得解一定是优化问题(2.16)的最优解。因此, 通过简单的数学计算, 可以得到最优通信资源分配, 其表达式为:

$$\tau_k^* = a_k^* \frac{V}{R_k^U (T^* - T^C)}. \quad (2.19)$$

从式(2.19)可以看出, 上行链路传输速率越大的终端分配的时隙越少。

2.3.4 最优求解算法

到目前为止, 本章已经得到了优化问题(2.16)的最优解。本节将基于上文的分析设计优化问题(2.16)的最优算法。如前所述, 需要比较所有选择方案的学习效率以得到优化问题(2.16)的最优解。然而, 随着终端数目的增加, 这将变得非常耗时。所以需要设计一个具有低计算复杂度的算法。当 M 个终端被选择时, 定义 E_M , $M \in \{1, 2, \dots, K\}$ 为联邦边缘学习系统的学习效率。为了更好地适应实际系统, 得出以下定理。

定理 2.3. 随着 M 的增加, E_M 先增后减。

证明: 见附录A.1.3. □

定理2.3表明学习效率 E_M 有且仅有一个全局最优值。因此, 可以根据最优用户选择策略依次选择终端参与训练任务, 直到联邦边缘学习系统的学习效率开始下降为止。这样就能够找到优化问题(2.16)的最优值。根据上述分析, 优化问题(2.16)的最优算法如表2-1所示。显而易见地, 该算法的计算复杂度是由排序操作决定的。因此, 该算法的计算复杂度为 $\mathcal{O}(K \log K)$ 。对于混合整数规划问题来说, 用具有多项式时间复杂度的算法求得最优解是可以接受的。这表明该算法可以应用于实际系统中。

2.4 仿真验证与性能分析

本节将通过仿真测试所提算法的性能, 并且将该算法与其他传统算法比较以验证其对

表 2-1 优化问题(2.16)的最优算法

Algorithm 2.1 优化问题(2.16)的最优算法

-
- 1: 计算 $\rho_k R_k^U, \forall k \in \mathcal{K}$ 。
 - 2: 降序排列 $\rho_k R_k^U$ 。
 - 3: 根据 $\rho_k R_k^U$ 依次选择终端, 并计算联邦边缘学习系统的学习效率 E_M 。
 - 4: **for** $M = 1 : K$ **do**
 - 5: **if** $M = 1$ **then**
 - 6: $E_{\max} = E_M$ 。
 - 7: **else**
 - 8: **if** $E_M < E_{\max}$ **then**
 - 9: 终止退出。
 - 10: **else**
 - 11: $E_{\max} = E_M$ 。
 - 12: **end if**
 - 13: **end if**
 - 14: **end for**
 - 15: 计算 E_{\max} 对应的 $\{a_k^*, T^*, \tau_k^{U*}\}$ 。
 - 16: 输出最优解 $\{a_k^*, T^*, \tau_k^{U*}\}$ 。
-

系统性能的提升。

2.4.1 仿真设置

在联邦边缘学习系统中, K 个终端随机分布在基站的覆盖范围内。基站的覆盖区域是半径为 500m 的圆。所有终端都通过无线信道与基站连接。信道增益均按照路径损耗模型生成, 即 $128.1 + 37.6 \log_{10}(d)$, 其中 d 表示基站和终端之间的距离, 小尺度衰落服从瑞利分布且具有均匀方差。噪声功率谱密度为 -174dBm/Hz , 系统带宽为 5MHz 。上行链路和下行链路的传输功率均为 24dBm 。仿真验证中使用到的主要系统参数见表 2-2。

本章用 CIFAR-10 数据集作为所有终端的本地数据集来训练模型。该数据集由 10 个类别的 60,000 张 32×32 的彩色图像组成, 其中包括 50,000 张训练图像和 10,000 张测试图像。先将所有训练样本打乱, 并把它们平均分成 K 个部分, 然后分别分发给所有终端。两个常见的 DNN 模型, MobileNetV2 和 ResNet18, 被用于图像分类。由于从头开始训练很耗时, 本章使用预先训练的模型以减少模型收敛时间。

表 2-2 第2章仿真参数

参数	数值
路径损耗模型	$128.1 + 37.6 \log_{10}(d)$
基站覆盖范围	500m
上行链路传输功率	24dBm
下行链路传输功率	24dBm
噪声功率谱密度	-174dBm/Hz
用户数目	14
系统带宽	5MHz

2.4.2 泛化能力测试

泛化能力是指算法对不同DNN模型的适应性。为了测试本章所提算法的泛化能力，使用该算法训练上述两种DNN模型。此时，设定联邦边缘学习系统中一共有 $K = 14$ 个终端。同时，将所提算法与基线算法的性能进行了比较。在基线算法中，所有终端都被选择且均匀分配通信资源。测试准确率和全局训练损失的仿真结果分别如图2.2(a)和图2.2(b)所示。从图中可以看出，对于不同的DNN模型，本章所提算法都可以达到较高的学习准确率和较快的收敛速率。仿真结果表明，所提算法具有较好的泛化能力，并且可以在实际系统中广泛应用。注意到图2.2(a)和图2.2(b)的横坐标是通信回合而不是训练时间。此时，所提算法的性能与基线算法相似。这是合理的，因为所提算法旨在减少每个通信回合的通信时延，而不是减少通信回合的数量。此外，该仿真结果表明，本章所提算法只需要在联邦边缘学习系统中选择部分终端参与训练任务即可达到与基线算法相似的训练速度。

2.4.3 不同算法的性能比较

本节将所提算法与其他常规算法的性能进行比较，以验证其优越性。两种常规算法描述如下。

- 基线算法：在每个通信回合中，联邦边缘学习系统中的所有终端都参与训练任务，并且均匀分配通信资源，即 $\tau_k = \frac{1}{K}$, $\forall k \in \mathcal{K}$ 。
- 全选算法：在每个通信回合中，联邦边缘学习系统中的所有终端都参与训练任务，并且根据式(2.19)进行最优通信资源分配。

这里使用经过预训练的ResNet18模型测试这三种算法的性能。设定系统中一共

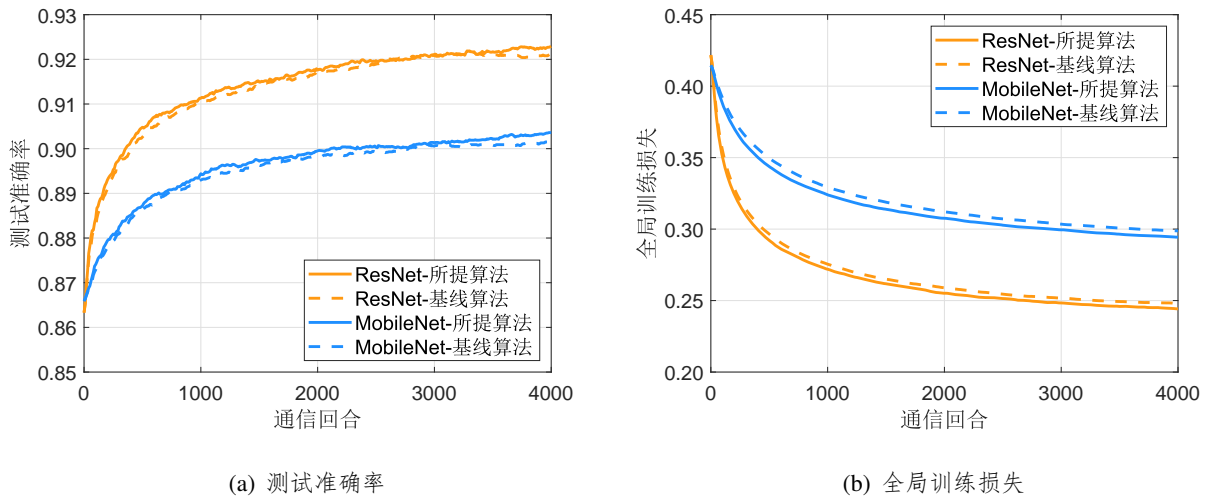


图 2-2 学习性能与通信回合数目的关系

有 $K = 14$ 个终端。不同算法的测试准确率与训练时间的关系如图2-3所示。从图中可以看出，本章所提算法达到的测试准确率是所有算法中最高的。这是因为所提算法不仅基于数据重要性选择终端参与训练任务，而且进行了最优通信资源分配。这样一来，只有具有更重要数据和更快上行链路传输速率的终端才能参与训练任务。因此，减少了通信时延，增加了全局损失函数衰减率。由此，系统的学习效率最终得以提升。全选算法相较于基线算法的增益来自于最优通信资源分配。所提算法相较于全选算法的增益来自于最优用户选择。总而言之，本章所提算法共同考虑了用户选择和通信资源分配，从而加速了训练任务并提高了联邦边缘学习系统的学习效率。

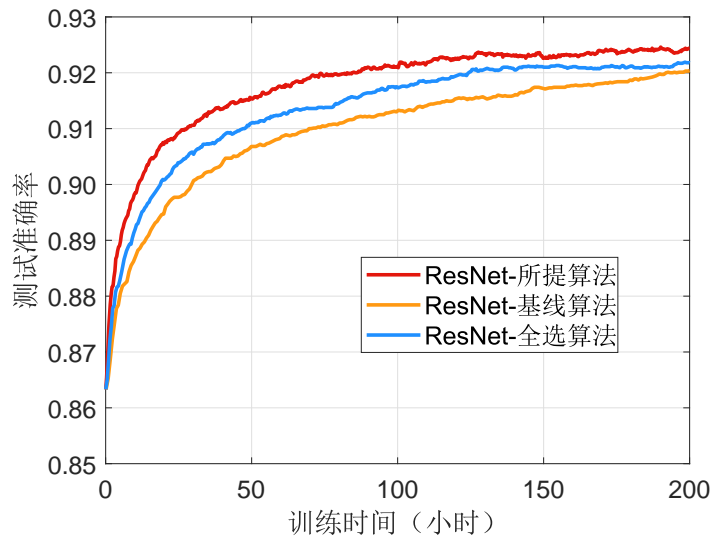


图 2-3 不同算法测试准确率与训练时间的关系

为了进一步验证所提算法的适用性和有效性，随机选择了一个通信回合以获得更深入




图 2-4 所提算法的用户选择

的仿真结果。在这一通信回合中，本章所提算法得到的用户选择及通信资源分配的结果分别如图2-4和图2-5所示。从图2-4中可以看出，只有当终端 k 的数据重要性与上行链路传输速率的乘积，即 $\rho_k R_k^U$ ，大于等于阈值时，该终端才会被选择。这一点与定理2.1一致。值得注意的是，根据定理2.1可知，终端的选择阈值是满足式(2.17a)的拉格朗日乘子的最优值。此外，为了清楚地展示通信资源分配和上行链路传输速率之间的关系，图2-6中绘制了所有终端对应的上行链路传输速率。结合图2-5和图2-6可以看到，在被选择的终端中，上行链路传输速率较快的终端分配的通信资源较少，这一点与式(2.19)一致。




图 2-5 所提算法的通信资源分配

最后进一步研究终端数量对联邦边缘学习系统训练性能的影响。不同终端数量下测试准确率与训练时间的关系如图2-7所示。从图中可以看出，当终端数目 $K = 6$ 时，系统的学




图 2-6 相应的上行链路传输速率

习效率最高。原因如下所示。当终端数目较少时，被选择终端分配到的时隙较多。因此，在这种情况下，通信时延大大减少了，联邦边缘学习系统的学习效率也大大提高了。此外，当终端数量太大时，单个终端所分配的无线通信资源得到下降。因此，当终端数量太多时，联邦边缘学习系统的学习效率不会随着终端数量的增加而提高。

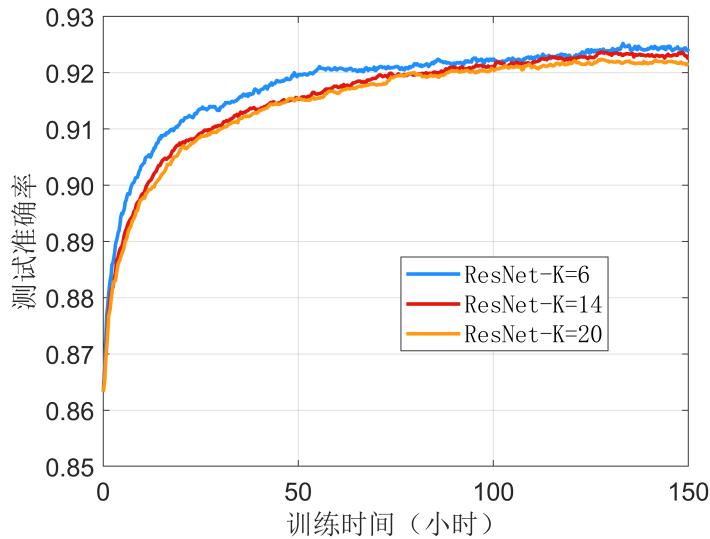


图 2-7 不同终端数量时所提算法测试准确率与训练时间的关系

2.5 本章小结

本章提出了联邦边缘学习系统中一种基于数据重要性和CSI的最优用户选择策略，从而加速训练任务并提高联邦边缘学习系统的学习效率。在分析了终端的数据重要性和联邦

边缘学习系统的端到端时延之后，本章建立了一个优化问题以最大化联邦边缘学习系统的学习效率。对原优化问题进行转换和松弛之后，推导得出了最优用户选择策略以及最优通信资源分配的闭式解，设计了一个多项式时间算法求解该混合整数规划问题并证明了其最优性。最后，仿真结果表明，本章所提算法具有很强的泛化能力，可以显著提高联邦边缘学习系统的学习效率。

3 模型分割边缘学习系统中模型参数分配与通信资源优化

在上一章所研究的联邦边缘学习系统中，终端需要将整个模型参数上传至基站侧部署的PS，以训练高质量的全局模型。但对于训练复杂的高维学习模型来说，终端和PS之间频繁地传输整个模型参数会产生较大的通信开销，这是限制模型训练性能的重要原因之一。为了解决大规模模型训练问题，模型分割边缘学习系统开始受到关注，该系统旨在通过模型分割将大规模学习任务分布在多个资源受限的终端上。在模型分割边缘学习系统中，每个终端只需要训练模型的一部分，并且只需将所负责训练部分的模型信息上传至PS，从而克服了终端的资源限制，降低了模型的训练开销。

在模型分割边缘学习系统中，模型参数由PS进行分割，并分配给系统中的终端。然而，由于终端的计算能力有限且无线资源有限，模型参数分配以及无线通信资源分配等都会影响系统的学习性能。一方面，考虑到终端之间计算能力的差异，不合理的模型参数分配方案将会产生较大的计算时延，从而降低模型的收敛速率。另一方面，由于无线通信资源有限，不合理的通信资源分配方案将会产生较大的通信时延，从而增加系统的训练开销。此外，已有研究工作大多基于静态信道的假设，即在一轮训练迭代期间无线信道状态不变。考虑到无线信道的时变特性，即在一轮训练迭代期间信道状态变化，已有的通信资源分配方案不再适用。因此，有必要为时变无线信道场景中的模型分割边缘学习系统设计模型参数分配与通信资源分配方案，以减少系统的训练开销，并提高模型训练的性能。

对于时变无线信道场景中的模型分割边缘学习系统，模型参数分配与通信资源分配方案的设计存在两个关键问题。首先是如何设计最优的模型参数分配方案？在模型分割边缘学习系统中，模型参数分配不仅会影响终端的本地计算时延，也会影响终端需要传输给PS的数据量大小，从而影响通信时延。为了提高模型训练的性能，PS需要根据终端的计算能力以及终端与基站之间的无线信道质量合理地分配模型参数。其次，如何针对时变信道重新设计通信资源分配方案，减少模型训练的开销？考虑到无线信道是不断变化的，未来CSI的不确定性给通信资源分配方案的设计带来了新的挑战。本章将致力于解决上述两个问题，设计一种模型参数分配和通信资源分配的联合优化方案，以减少模型分割边缘学习系统的训练开销，并提高模型训练的性能。

本章内容安排如下。3.1节介绍了模型分割边缘学习系统模型。3.2节建立了最小化一轮训练时延的优化问题。3.3节设计了联合模型参数分配和带宽分配的优化算法。3.4节给出了仿真结果并验证了所提算法的有效性。3.5节总结了本章内容。

3.1 系统模型

本节将首先介绍模型分割边缘学习系统，然后依次介绍学习模型、通信模型和时延模型。

3.1.1 模型分割边缘学习系统

本章考虑一个模型分割边缘学习系统，如图3-1所示，该系统由多个终端和一个基站组成，基站侧配有PS。参与训练的终端被均匀划分为 K 个组，表示为 $\{\mathcal{G}_1, \dots, \mathcal{G}_k, \dots, \mathcal{G}_K\}$ ，每个组负责训练指定的模型参数块。组 \mathcal{G}_k 中的第 n 个终端表示为 (k, n) 。在该系统中，每个终端通过下行链路信道^[56, 57]从基站加载一部分数据，或者通过D2D链路^[75]由其他终端共享。每个组将加载整个数据集。模型分割边缘学习系统可以利用终端的计算资源高效地训练高维学习模型。在每个训练迭代中，或者称为一个通信回合中，PS将模型参数划分为 K 个不相交的参数块，表示为 $\omega = \{\omega_1, \dots, \omega_k, \dots, \omega_K\}$ ，并将第 k 个参数块 ω_k 分配给组 \mathcal{G}_k 负责训练。在这种设置下，每个终端只需计算和传输参数块的梯度或近端梯度，而不是整个模型参数向量，从而提高计算和通信效率，并减少训练时延^[56]。

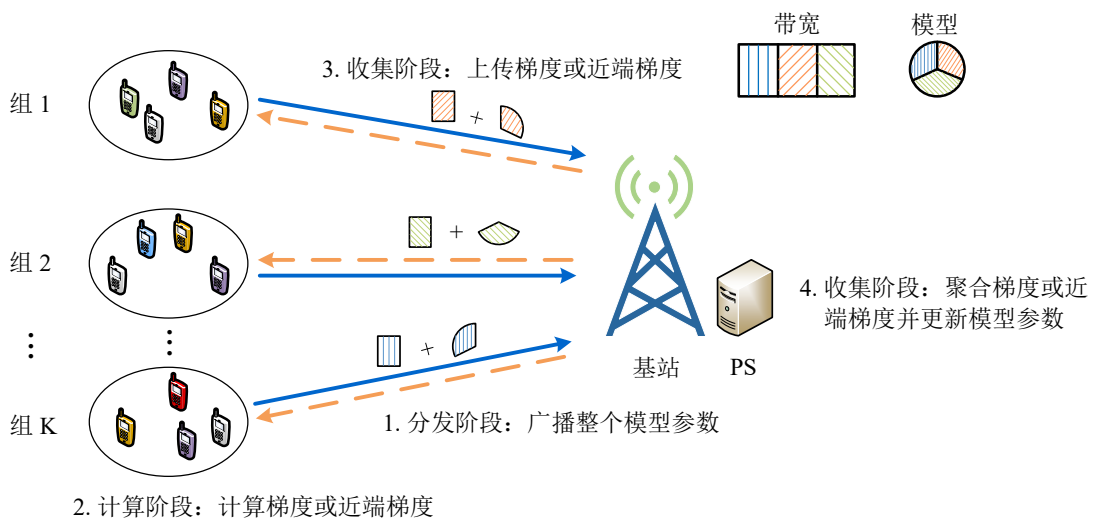


图 3-1 模型分割边缘学习系统模型

3.1.2 学习模型

基于BCD算法的模型分割边缘学习系统是针对大规模学习任务而设计的。对于支持向量和逻辑回归等可分解学习模型，可以直接应用块梯度坐标下降算法^[50]。对于具有嵌套结构的DNN模型，可以应用辅助变量法将其等效地转换为具有可分解结构的模型，从而使其可以在模型分割边缘学习系统中训练^[51, 57, 76]。根据文献[50]，可分解目标函数可以表示为：

$$\mathcal{L}(\boldsymbol{\omega}) = \mathcal{F}(\boldsymbol{\omega}) + \mathcal{R}(\boldsymbol{\omega}), \quad (3.1)$$

其中， $\boldsymbol{\omega} = \{\boldsymbol{\omega}_1, \dots, \boldsymbol{\omega}_{n_p}, \dots, \boldsymbol{\omega}_{N_p}\}^T$ 表示学习模型的参数向量， N_p 表示参数总数目， $\mathcal{F}(\boldsymbol{\omega})$ 表示损失函数， $\mathcal{R}(\boldsymbol{\omega})$ 表示正则化函数，例如 l_1 正则化和 l_2 正则化。具体地，损失函数可以表示为：

$$\mathcal{F}(\boldsymbol{\omega}) = \frac{1}{M} \sum_{m=1}^M \phi(\boldsymbol{\omega}; \mathbf{x}_m), \quad (3.2)$$

其中， $\mathcal{X} = \{\mathbf{x}_m\}$ 是数据集， M 是数据集的大小， $\phi(\cdot)$ 是平滑函数。块可分解正则化函数可以表示为：

$$\mathcal{R}(\boldsymbol{\omega}) = \sum_{i=1}^{N_p} \psi(\boldsymbol{\omega}_i), \quad (3.3)$$

其中， $\boldsymbol{\omega}_i$ 是 $\boldsymbol{\omega}$ 的第 i 个元素， $\psi(\cdot)$ 是 l_1 或 l_2 范数。在训练期间，更新学习模型的方法由 $\mathcal{R}(\cdot)$ 的平滑性质决定。当 $\mathcal{R}(\cdot)$ 平滑时，采用梯度下降算法更新学习模型。否则，采用近端梯度下降算法^[77]更新学习模型。

如图3-1所示，在本章考虑的模型分割边缘学习系统中，全局模型分三个阶段进行训练，如下所述。

- 分发阶段：基站向所有终端广播整个模型参数 $\boldsymbol{\omega}$ 。
- 计算阶段：在此阶段，每个参数块的梯度或近端梯度由一个组计算。每个终端基于其本地数据集计算所分配参数块的梯度或近端梯度。
- 收集阶段：所有终端将其相应参数块的梯度或近端梯度上传至基站。基站聚合来自所有组的梯度或近端梯度，并更新相应的参数块。

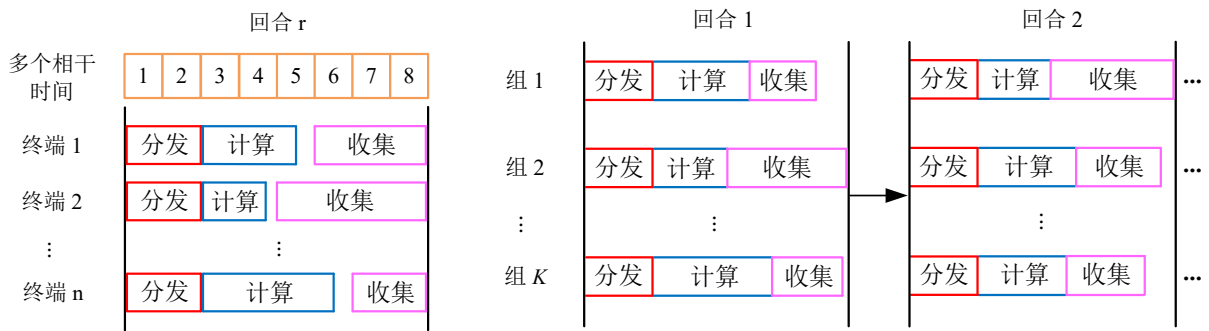
循环执行上述三个阶段，直至全局模型收敛。

3.1.3 通信模型

在模型分割边缘学习系统中，终端通过无线链路连接到基站。本章考虑了时变无线信道，一轮训练迭代的时延包括多个相干时间¹。无线信道的相干时间表示为 T_C 。假设当前相干时间中所有链路的CSI是已知的。对于未来相干时间中的链路增益，由于信道的时变特性，只假设其分布是已知的。此外，本章假设采用频率非选择性衰落信道。对于任意终端 (k, n) ，将其下行链路和上行链路信道增益的随机过程分别表示为 $\{\hat{H}_{k,n,q}\}$ 和 $\{\tilde{H}_{k,n,q}\}$ ，其中， q 表示第 q 个相干时间。

假设 3.1 (信道动态性). 下行链路和上行链路信道增益的随机过程，即 $\{\hat{H}_{k,n,q}\}$ 和 $\{\tilde{H}_{k,n,q}\}$ ，是无限状态平稳马尔可夫链。具体地， $\hat{h}_{k,n,q} \in \hat{\mathcal{H}} = \mathbb{R}^+$ 以及 $\tilde{h}_{k,n,q} \in \tilde{\mathcal{H}} = \mathbb{R}^+$ 。

基于上述假设，模型分割边缘学习系统的迭代过程如图3-2所示。在时变信道场景中，任意一轮迭代的详细过程如图3.2(a)所示。从图中可以看到，终端在接收整个模型参数之后同步开始计算梯度或近端梯度。然而，由于终端之间计算能力的差异，每个终端的计算时延不同。因此，各个终端在不同的相干时间开始上传梯度或近端梯度。注意到由于不断会有终端开始上传梯度，需要在每个相干时间内重新分配通信资源。系统中所有组的迭代学习过程如图3.2(b)所示。从图中可以看出，该系统采用了同步更新。也就是说，直到所有终端完成传输，基站才被允许聚合梯度和更新模型参数。因此，一轮中每组的时延取决于该组中最慢的终端，而一个通信回合的时延取决于系统中最慢的组。



(a) 时变信道下任意一轮迭代的详细过程

(b) 迭代学习过程

图 3-2 模型分割边缘学习系统的迭代过程

¹对于静态信道的设计已经在文献[56]中提出。

3.1.4 时延模型

本节将定义一个通信回合的总时延。考虑任意一个通信回合 r 和任意一个终端 (k, n) ，其一轮时延包括三个部分，分别对应于分发阶段、计算阶段和收集阶段。每个阶段的时延如下所述。

- 分发时延。基站向所有终端广播整个模型参数向量 ω 的分发时延为：

$$T_d^{(r)} = Q_d^{(r)} T_C, \quad (3.4)$$

其中， $Q_d^{(r)}$ 表示广播所需的相干时间数量，其值满足：

$$\sum_{q=1}^{Q_d^{(r)}} \min_{\{(k,n)\}} \left\{ B \hat{\gamma}_{k,n,q}^{(r)} T_C \right\} = A_p N_p, \quad (3.5)$$

其中， B 表示系统总带宽， A_p 表示每个模型参数的位数， N_p 表示模型参数的总数， $\hat{\gamma}_{k,n,q}^{(r)}$ 表示终端 (k, n) 在第 q 个广播相干时间内的下行链路频谱效率。下行链路频谱效率可以表示为：

$$\hat{\gamma}_{k,n,q}^{(r)} = \log_2 \left(1 + \frac{P_b \hat{h}_{k,n,q}^{(r)}}{N_0} \right), \quad (3.6)$$

其中， P_b 是基站的传输功率密度， $\hat{h}_{k,n,q}^{(r)}$ 是第 q 个广播相干时间内的下行链路信道增益， N_0 是噪声功率密度。注意，在每一个通信回合中，所有终端的分发时延都是相等的，对系统设计没有影响。因此，分发时延可以被视为一个常数。

- 计算时延。终端 (k, n) 的计算时延可以表示为：

$$t_{k,n}^{c,(r)} = \frac{b_k^{(r)} D_{k,n} O}{f_{k,n}^c}, \quad (3.7)$$

其中， $b_k^{(r)}$ 表示该通信回合中分配给组 \mathcal{G}_k 的参数块的长度， $D_{k,n}$ 表示终端 (k, n) 本地数据集的大小， O 表示用于计算一个样本的一个参数梯度的操作数， $f_{k,n}^c$ 表示终端 (k, n) 的处理器频率。然后，计算梯度所需的相干时间数量可以表示为：

$$Q_{k,n}^{c,(r)} = \left\lceil \frac{t_{k,n}^{c,(r)}}{T_C} \right\rceil, \quad (3.8)$$

其中， $\lceil \cdot \rceil$ 是向上取整函数。

- 收集时延。收集时延分为两个部分。一个是终端 (k, n) 将梯度上传到基站的时延，记为 $t_{k,n}^{u,(r)}$ 。另一个是基站更新模型参数的时延，记为 $T_s^{(r)}$ 。因此，收集时延可以表示为：

$$t_{k,n}^{cl,(r)} = t_{k,n}^{u,(r)} + T_s^{(r)}. \quad (3.9)$$

所有终端的更新时延 $T_s^{(r)}$ 都是相等的。上传时延 $t_{k,n}^{u,(r)}$ 可以表示为：

$$t_{k,n}^{u,(r)} = Q_{k,n}^{u,(r)} T_C, \quad (3.10)$$

其中， $Q_{k,n}^{u,(r)}$ 是终端 (k,n) 上传梯度所需的相干时间数量，其值满足：

$$\sum_{q=1}^{Q_{k,n}^{u,(r)}} B_{k,n,q}^{(r)} \tilde{\gamma}_{k,n,q}^{(r)} T_C = A_g b_k^{(r)}, \quad (3.11)$$

其中， A_g 是一个梯度元素的大小， $B_{k,n,q}^{(r)}$ 和 $\tilde{\gamma}_{k,n,q}^{(r)}$ 分别表示第 q 个上传相干时间内分配给终端 (k,n) 的上行链路带宽和终端 (k,n) 的上行链路频谱效率。第 q 个上传相干时间内上行链路的频谱效率可以表示为：

$$\tilde{\gamma}_{k,n,q}^{(r)} = \log_2 \left(1 + \frac{P_u \tilde{h}_{k,n,q}^{(r)}}{N_0} \right), \quad (3.12)$$

其中， P_u 是上行链路传输功率密度， $\tilde{h}_{k,n,q}^{(r)}$ 是第 q 个上传相干时间内的上行链路信道增益。

然后，记终端 (k,n) 的一轮时延为 $t_{k,n}^{(r)}$ 。通过结合式(3.4)，式(3.7)和式(3.9)，终端 (k,n) 的一轮时延可以表示为：

$$t_{k,n}^{(r)} = Q_{k,n}^{(r)} T_C + T_s^{(r)}, \quad (3.13)$$

其中， $Q_{k,n}^{(r)}$ 是广播模型参数、计算梯度以及上传梯度所需的相干时间总数，可以表示为：

$$Q_{k,n}^{(r)} = Q_d^{(r)} + Q_{k,n}^{c,(r)} + Q_{k,n}^{u,(r)}, \quad (3.14)$$

其中， $Q_d^{(r)}$ ， $Q_{k,n}^{c,(r)}$ 和 $Q_{k,n}^{u,(r)}$ 分别表示广播模型参数、计算梯度和上传梯度所需的相干时间数量，分别在式(3.5)、式(3.8)和式(3.11)中定义。

接着，定义第 r 个通信回合中每个组的时延。如上所述，由于同步更新，一轮迭代中每个组的时延取决于该组中最慢的终端。因此，组 \mathcal{G}_k 的一轮时延可以表示为：

$$t_k^{(r)} = \max_{n \in \mathcal{G}_k} t_{k,n}^{(r)}, \quad (3.15)$$

其中， $t_{k,n}^{(r)}$ 在式(3.13)中定义。

同样地，第 r 个通信回合的总时延取决于系统中最慢的组，可以表示为：

$$t^{(r)} = \max_k t_k^{(r)}. \quad (3.16)$$

因此，第 r 个通信回合所需的相干时间总数可以表示为：

$$Q^{(r)} = \left\lceil \frac{t^{(r)}}{T_C} \right\rceil. \quad (3.17)$$

3.2 问题建模

3.2.1 每轮时延最小化问题

本章的目标是最小化模型分割边缘学习系统的总训练时延，该时延的定义是直到模型收敛为止所有通信回合的总时延。基于该定义，总训练时延由每轮时延和模型收敛所需通信回合的数目决定。文献[56]证明了最小化总训练时延等同于分别最小化每轮时延。本章也可以应用此结论，如以下引理所述。

引理 3.1. 最小化直到模型收敛为止的总训练时延等同于分别最小化每轮时延^[56]。

引理3.1的解释如下。对于模型分割边缘学习系统，所采用的分布式学习算法的收敛速率等同于相应的集中式算法^[77]。其收敛速率可以通过所需的通信回合数目来衡量。更准确地说，对于分布式学习，模型收敛所需的轮数和每轮中计算的梯度值与本章考虑的模型参数分配和带宽分配无关。

基于引理3.1，本章的目标是通过考虑任意一个通信回合来分别最小化每轮时延。为此，为了简单起见，省略符号 (r) 。一轮时延在式(3.16)中定义，它取决于两个因素。一个是分配给各个组的参数块的长度，另一个是分配给终端的带宽。由于训练需要，分配给各个组的参数块的长度应该在每个通信回合开始时确定。而分配给终端的带宽应该根据无线信道的变化在每个相干时间内进行调整。基于以上两个原因，本章将一轮时延最小化问题建模为模型参数分配和带宽分配问题，如下所述。

- 模型参数分配的约束：每个模型参数的梯度应该在每一轮计算并上传，可以表示为：

$$\begin{cases} \sum_{k=1}^K b_k = N_p, \\ b_k \in \mathbb{Z}^+, 1 \leq k \leq K. \end{cases} \quad (3.18)$$

- 带宽分配的约束：在每一轮中，由于信道的变化，需要在每个相干时间内重新分配带宽。在每个上传相干时间内，总上行链路带宽应不超过系统总带宽，因此有以下约束：

$$\sum_{k=1}^K \sum_{n \in \mathcal{G}_k} B_{k,n,q} = B, \forall q. \quad (3.19)$$

因此，最小化一轮时延问题可以建模为以下联合模型参数分配和带宽分配问题：

$$\min_{\{b_k\}, \{B_{k,n,q}\}} t, \quad (3.20)$$

限制条件为(3.18)-(3.19)。

3.2.2 基于MDP的一轮时延最小化问题

由于信道是时变的，需要在每个相干时间内重新分配无线通信资源，以最小化一轮时延。然而，考虑到未来相干时间的CSI未知，优化问题(3.20)无法直接求解。基于假设3.1，本章考虑的模型分割边缘学习系统具有马尔可夫性。此外，优化问题(3.20)的本质是一个顺序决策优化问题，即需要按顺序在每个相干时间内做出最优决策。因此，可以采用马尔可夫决策过程（Markov Decision Progress, MDP）^[78]这一经典方法对本章考虑的复杂系统进行建模。由此，本节推导得出了一个与优化问题(3.20)等价的有限MDP问题。

一轮时延在式(3.16)中定义。如上所述，分发时延 T_d 和更新时延 T_s 都是常数。因此，为了最小化一轮时延，需要考虑三个因素，即每个终端的计算时延、上行链路频谱效率和梯度的大小，如下所述。

- 计算时延：考虑任意终端 (k, n) ，计算时延取决于被分配的模型参数块的长度 $\{b_k\}$ ，并由式(3.7)和式(3.8)确定。然后，上传在第一个终端完成计算之后开始，例如从第 $(Q_{\min}^c + 1)$ 个相干时间开始，其中， Q_{\min}^c 是第一个终端完成计算所需的相干时间数量，由下式给出：

$$Q_{\min}^c = Q_d + \min_{(k,n)} \{Q_{k,n}^c\}, \quad (3.21)$$

其中， Q_d 是分发阶段所需的相干时间数量，由式(3.8)定义的 $Q_{k,n}^c$ 是终端 (k, n) 计算阶段所需的相干时间数量。此外，在最后一个终端完成计算之后，所有终端都被允许上传，例如在第 Q_{\max}^c 个相干时间之后，其中， Q_{\max}^c 由下式给出：

$$Q_{\max}^c = Q_d + \max_{(k,n)} \{Q_{k,n}^c\}. \quad (3.22)$$

- 上行链路频谱效率：对于终端 (k, n) ，第 q 个相干时间内的上行链路频谱效率由式(3.12)定义，其中假设上行链路信道增益的随机过程为无限状态平稳马尔可夫链。因此，上行链路频谱效率 $\{\tilde{\gamma}_{k,n,q}\}$ 也是无限状态平稳马尔可夫链，即 $\tilde{\gamma}_{k,n,q} \in \tilde{\mathcal{R}} = \mathbb{R}^+$ 。
- 梯度的大小：对于终端 (k, n) ，将第 q 个相干时间开始时剩余未上传梯度的大小表示为 $L_{k,n,q}$ 。原始需上传梯度的大小取决于分配给该终端的参数块的长度 b_k^* ，由下式给出：

$$L_{k,n,q} = b_k^* A_g, \quad \forall q \leq Q_d + Q_{k,n}^c + 1, \quad (3.23)$$

其中，终端 (k, n) 在第 $(Q_d + Q_{k,n}^c + 1)$ 个相干时间开始上传。然后， $L_{k,n,q}$ 满足下式：

$$L_{k,n,(q+1)} = \max\{L_{k,n,q} - B_{k,n,q}\tilde{\gamma}_{k,n,q}T_C, 0\}, \forall q \geq Q_d + Q_{k,n}^c + 1, \quad (3.24)$$

其中， $B_{k,n,q}\tilde{\gamma}_{k,n,q}T_C$ 表示第 q 个相干时间内上传的位数。

联合考虑上述三个因素，优化问题(3.20)可以等效地建模为多智能体有限MDP问题，该问题有以下组成部分。

- 系统状态：记 $s_{k,n,q} = \{\tilde{\gamma}_{k,n,q}, L_{k,n,q}\}$ 为终端 (k, n) 在第 q 个相干时间的状态，其中 $\tilde{\gamma}_{k,n,q}$ 和 $L_{k,n,q}$ 分别表示频谱效率状态和剩余未上传梯度大小状态。第 q 个相干时间的系统状态是所有终端的组合，表示为 $\mathbf{S}_q = \{s_{k,n,q}, \forall (k, n)\}$ 。由于频谱效率过程 $\{\tilde{\gamma}_{k,n,q}\}$ 是无限的，因此系统的状态空间是无限的。
- 系统动作：对于任意终端 (k, n) ，第 q 个相干时间内的动作是分配的带宽 $B_{k,n,q}$ 。然后，在第 q 个相干时间内，系统动作是所有终端动作的组合，表示为 $\mathbf{A}_q = \{B_{k,n,q}, \forall (k, n)\}$ 。
- 层次约束：该系统有两个约束。一个是模型参数分配的约束。由于分配给每个组的模型参数应在一次训练迭代期间固定，因此分配给每个组的模型参数应该在一个通信回合开始时确定，并在该通信回合中保持不变。因此，模型参数分配的约束与式(3.18)相同。另一个是带宽分配约束。由于无线信道的变化，应该在每个相干时间内重新分配带宽。在时变信道的场景中，带宽分配约束包括两个方面。一个是带宽限制，即需要保证在上传过程中总带宽不超过系统带宽，表示为：

$$\sum_{k=1}^K \sum_{n \in \mathcal{G}_k} B_{k,n,q} \leq B, \forall q \in [Q_{\min}^c + 1, Q]. \quad (3.25)$$

另一个是上传约束。所有终端在完成计算之前不会上传梯度。因此，在完成计算之前不应分配带宽，表示为：

$$B_{k,n,q} = 0, \text{ 若 } q \leq Q_d + Q_{k,n}^c, \forall (k, n), \quad (3.26)$$

其中， $q \leq Q_d + Q_{k,n}^c$ 表示终端 (k, n) 尚未开始上传。

- 状态转移概率：对于任意终端 (k, n) ，给定当前状态 $s_{k,n,q}$ 和动作 $a_{k,n,q}$ ，转移概率是指该终端在第 $(q+1)$ 个相干时间处于状态 $s_{k,n,(q+1)}$ 的概率。终端 (k, n) 的转移概率可以表示为：

$$\Pr(s_{k,n,(q+1)} | s_{k,n,q}, a_{k,n,q}) = \Pr_{\tilde{\mathcal{R}}}(\tilde{\gamma}_{k,n,(q+1)} | \tilde{\gamma}_{k,n,q}) = \Pr_{\tilde{\mathcal{H}}}(\tilde{h}_{k,n,(q+1)} | \tilde{h}_{k,n,q}), \forall (k, n), \quad (3.27)$$

其中, $\tilde{\mathcal{R}}$ 和 $\tilde{\mathcal{H}}$ 分别是频谱效率和信道增益的状态空间。然后, 系统转移概率可以表示为:

$$\Pr(\mathbf{S}_{(q+1)}|\mathbf{S}_q, \mathbf{A}_q) = \prod_{(k,n)} \Pr(s_{k,n,(q+1)}|s_{k,n,q}, a_{k,n,q}). \quad (3.28)$$

- 成本函数、控制规则和策略: 首先, 定义 q_t 为终止相干时间。此时, 所有终端完成梯度的上传, q_t 满足:

$$\forall(k,n), L_{k,n,q_t} = 0 \text{ 且 } \exists(k,n), L_{k,n,(q_t-1)} \neq 0, \quad (3.29)$$

其中, 式(3.24)中定义的 L_{k,n,q_t} 表示第 q_t 个相干时间开始时剩余未上传梯度的大小。本章的目标是最小化一轮时延, 即相干时间总数。因此, 成本函数定义如下:

- 在过程终止之前, 即 $q < q_t$ 时, 一个相干时间内任何状态的成本为 T_C , 即一个相干时间。
- 在终止步骤中, 即 $q = q_t$ 时, 用负成本 -1 表示终止。
- 终止后, 即 $q > q_t$ 时, 所有状态的成本定义为 0 。

因此, 每个状态的成本函数可以表示为:

$$C(\mathbf{S}_q, \mathbf{A}_q) = \begin{cases} T_C, & \text{若 } q < q_t \\ -1, & \text{若 } q = q_t \\ 0, & \text{若 } q > q_t \end{cases}. \quad (3.30)$$

定义函数 π_q 为将状态 \mathbf{S}_q 映射到动作 $\mathbf{A}_q = \pi_q(\mathbf{S}_q)$ 的控制规则。可容许策略是每个相干时间内的一系列控制规则, 记为 $\boldsymbol{\pi} = \{\pi_1, \dots, \pi_Q\}$ 。所有可容许策略的集合表示为 $\boldsymbol{\Pi}$ 。

然后, 给定初始状态 \mathbf{S}_1 , 最小化一轮时延的优化问题(3.20)等价于以下MDP问题, 表示为:

$$\min_{\{\boldsymbol{\pi} \in \boldsymbol{\Pi}\}} \sum_{q=1}^Q \mathbb{E}_{\{\mathbf{S}_q | \forall q\}} [C(\mathbf{S}_q, \pi_q(\mathbf{S}_q)) | \mathbf{S}_1], \quad (3.31)$$

限制条件为(3.18)以及(3.25)-(3.26)。

3.3 算法设计

本节首先提出了给定带宽分配下的最优模型参数分配算法, 该算法中分配给每个组的模型参数与该组中最慢的终端计算和上传一个梯度的总时延成反比。然后, 在给定模型参

数分配下, 针对时变信道提出了次优带宽分配算法, 该算法按顺序在每个相干时间内分配带宽, 从而最小化期望时延。最后, 提出了模型参数分配和带宽分配的联合优化算法。

3.3.1 模型参数分配优化算法

文献[56]针对静态信道提出了最优模型参数分配算法。然后, 用期望频谱效率代替瞬时频谱效率, 可以将结果扩展到时变信道的场景。如上文所述, 模型参数分配应该在一个通信回合开始时确定。由于未来相干时间内的瞬时上行链路频谱效率未知, 因此使用期望上行链路频谱效率, 可以表示为:

$$\bar{\gamma}_{k,n}^u = \int_0^{+\infty} \log_2 \left(1 + \frac{P_u h_{k,n}^u}{N_0} \right) p(h_{k,n}^u) dh_{k,n}^u, \quad \forall (k, n), \quad (3.32)$$

其中, $h_{k,n}^u$ 表示终端 (k, n) 的随机上行链路信道增益, $p(h_{k,n}^u)$ 表示相应的概率密度函数。然后, 在给定带宽分配下, 时变信道的模型参数分配算法与文献[56]中的算法1相同。

3.3.2 带宽分配优化算法

给定模型参数分配下, 本小节首先对基于MDP的带宽分配问题进行近似处理, 以最小化每个相干时间内的期望时延。然后, 求解该问题并提出了次优带宽分配算法。

给定模型参数分配 $\{b_k^*\}$ 并记当前上传相干时间为 Q_{now} , 优化问题(3.31)中的带宽分配问题可以等价转换为以下问题:

$$\min_{\{\pi \in \Pi\}} \sum_{q=Q_{\text{now}}}^Q \mathbb{E}_{\{S_q | \forall q\}} [C(S_q, \pi_q(S_q)) | S_{Q_{\text{now}}}], \quad (3.33)$$

限制条件为(3.25)-(3.26)。

注 3.1. 求解优化问题(3.33)有两个主要挑战。一个挑战是 $\{S_q\}$ 的状态空间是无限的。另一个挑战是相干时间总数 Q 是一个随机变量, 且在每个相干时间内都应满足带宽约束^[79]。

为了解决这些挑战并求解优化问题(3.33), 接下来首先简化了目标函数, 然后将优化问题(3.33)近似为一系列带宽分配问题, 其中每个问题对应一个即将到来相干时间内的带宽分配问题, 以最小化期望时延。

首先, 根据式(3.30), 当过程未终止, 即 $q < Q$ 时, 其成本 $[C(S_q, \pi_q(S_q)) | S_1]$ 为 T_C 。在终止相干时间内, 其成本为 -1 。因此, 优化问题(3.33)的目标函数可以表示为:

$$\sum_{q=Q_{\text{now}}}^Q \mathbb{E}_{\{S_q | \forall q\}} [C(S_q, \pi_q(S_q)) | S_{Q_{\text{now}}}] = \sum_{q=Q_{\text{now}}}^{Q-1} T_C - 1 = (Q - Q_{\text{now}})T_C - 1. \quad (3.34)$$

从式(3.34)中可以看出, 优化问题(3.33)的目标函数为最小化成本, 并且等价于最小化完成上传所需的相干时间数量, 即所有终端完成上传的时延。记 T^u 为系统时延, $t_{k,n}^u$ 为终端 (k, n) 自当前相干时间到完成上传的时延。显然地, 可以得到:

$$(Q - Q_{\text{now}} + 1) = \left\lceil \frac{T^u}{T_C} \right\rceil = \left\lceil \frac{\max_{(k,n)} \{t_{k,n}^u\}}{T_C} \right\rceil. \quad (3.35)$$

将式(3.34)和式(3.35)代入目标函数, 优化问题(3.33)等价于以下问题:

$$\min_{\{B_{k,n,q}\}} \max_{(k,n)} t_{k,n}^u, \quad (3.36)$$

限制条件为(3.25)-(3.26)。

接着, 为了解决系统状态空间无限和相干时间总数随机的挑战, 进行了两个近似处理。其一, 是用期望频谱效率进行近似处理, 以解决系统状态空间无限的挑战。对于任意终端 (k, n) , 用期望频谱效率 $\bar{\gamma}_{k,n}^u$ 替换所有上传相干时间的瞬时频谱效率 $\{\tilde{\gamma}_{k,n,q}\}$ 。相应地, 系统的期望时延以及终端 (k, n) 的期望时延分别记为 \bar{T}^u 和 $\bar{T}_{k,n}^u$ 。其二, 是通过合并步骤进行近似处理, 以解决相干时间总数随机的挑战。具体地, 当所有终端都完成计算时, 在此之后的所有相干时间可以合并为一个步骤, 这是因为在这些相干时间内, 正在上传梯度的终端数量及其期望频谱效率不会改变。

通过上述两个近似处理, 可以按顺序在每个相干时间内求解优化问题(3.36), 以最小化期望时延。在当前相干时间内, 系统可能处于部分卸载场景或者全部卸载场景。具体地, 在部分卸载场景中, 只有部分终端在当前相干时间内上传梯度; 在全部卸载场景中, 所有终端都已完成计算并开始上传梯度。在上述两种场景中求解优化问题(3.36)的具体过程如下所述。

3.3.2.1 部分卸载场景

在当前相干时间内, 若系统处于部分卸载场景, 即只有部分终端在上传梯度, 则 Q_{now} 满足:

$$Q_{\text{now}} \in [Q_{\min}^c + 1, Q_{\max}^c]. \quad (3.37)$$

此时, 自当前相干时间至终止相干时间可以划分为三个阶段, 如图3-3所示。

- **阶段1:** 瞬时上行链路频谱效率已知的当前相干时间段。在该相干时间内, 只有部分终端在上传梯度。

- 阶段2: 期望上行链路频谱效率已知的未来相干时间段。在这些相干时间内, 只有部分终端在上传梯度。
- 阶段3: 期望上行链路频谱效率已知的未来相干时间段。在这些相干时间内, 所有终端都在上传梯度。




图 3-3 部分卸载场景中的三个阶段

注意, 阶段3通过合并步骤进行了近似处理, 即指将第 Q_{\max}^c 个相干时间之后的所有相干时间合并为一个步骤。显然地, 总期望时延可以表示为:

$$\bar{T} = \max_{(k,n)} \{\bar{T}_{k,n}^u\} = (Q_{\max}^c - Q_{\text{now}} + 1)T_C + \max_{(k,n)} \{\hat{T}_{k,n}\}, \quad (3.38)$$

其中, $\bar{T}_{k,n}^u$ 是终端 (k,n) 自当前相干时间到完成上传的期望时延, $(Q_{\max}^c - Q_{\text{now}} + 1)T_C$ 是所有终端阶段1和阶段2的时延, $\hat{T}_{k,n}$ 是终端 (k,n) 在阶段3上传剩余梯度的时延, 满足:

$$\hat{T}_{k,n} \hat{B}_{k,n} \tilde{\gamma}_{k,n}^u = \hat{L}_{k,n}, \quad (3.39)$$

其中, $\hat{B}_{k,n}$ 和 $\hat{L}_{k,n}$ 分别表示终端 (k,n) 在阶段3分配到的带宽和剩余未上传梯度的大小。此外, 剩余未上传梯度的大小 $\hat{L}_{k,n}$ 等于当前相干时间内未上传梯度的大小减去阶段1和阶段2上传的梯度的大小, 可以表示为:

$$\hat{L}_{k,n} = \max \left\{ L_{k,n,Q_{\text{now}}} - B_{k,n,Q_{\text{now}}} \tilde{\gamma}_{k,n,Q_{\text{now}}} T_C - \sum_{q=Q_{\text{now}}+1}^{Q_{\max}^c} B_{k,n,q} \tilde{\gamma}_{k,n}^u T_C, 0 \right\}, \quad (3.40)$$

其中, $B_{k,n,Q_{\text{now}}} \tilde{\gamma}_{k,n,Q_{\text{now}}} T_C$ 和 $\sum_{q=Q_{\text{now}}+1}^{Q_{\max}^c} B_{k,n,q} \tilde{\gamma}_{k,n}^u T_C$ 分别表示阶段1和阶段2上传的梯度的大小, $\{B_{k,n,q}, q \in [Q_{\text{now}}, Q_{\max}^c]\}$ 表示第 q 个相干时间内的带宽分配。通过代入式(3.38),

式(3.39)和式(3.40)，优化问题(3.36)可以等价表示为：

$$\min_{\{B_{k,n,q}\}, \{\hat{B}_{k,n}\}} \max_{(k,n)} \hat{T}_{k,n}, \quad (3.41)$$

限制条件为(3.26)和

$$\sum_{k=1}^K \sum_{n \in \mathcal{G}_k} B_{k,n,q} \leq B, \forall q \in [Q_{\text{now}}, Q_{\text{max}}^c], \quad (3.41a)$$

$$\sum_{k=1}^K \sum_{n \in \mathcal{G}_k} \hat{B}_{k,n} \leq B, \quad (3.41b)$$

$$\hat{T}_{k,n} \hat{B}_{k,n} \bar{\gamma}_{k,n}^u = \hat{L}_{k,n}, \forall (k, n). \quad (3.41c)$$

记 $\hat{T} = \max_{(k,n)} \{\hat{T}_{k,n}\}$ 为阶段3中所有终端的最大时延，并将其代入优化问题(3.41)。然后，优化问题(3.41)可以表示为：

$$\min_{\{B_{k,n,q}\}, \{\hat{B}_{k,n}\}, \hat{T}} \hat{T}, \quad (3.42)$$

限制条件为(3.26)，(3.41a)-(3.41b)和

$$\hat{T} \hat{B}_{k,n} \bar{\gamma}_{k,n}^u \geq \hat{L}_{k,n}, \forall (k, n). \quad (3.42a)$$

很容易得出优化问题(3.42)是非凸的。为了推导得出优化问题(3.42)的有效解，将优化问题(3.42)与以下引入的带宽最小化凸问题联系起来。

给定阶段3中所有终端的最大时延 \hat{T} ，记 $B^*(\hat{T})$ 为可利用的最小带宽。然后， $B^*(\hat{T})$ 解决了以下带宽最小化问题：

$$B^*(\hat{T}) = \min_{\{B_{k,n,q}\}, \{\hat{B}_{k,n}\}} \sum_{k=1}^K \sum_{n \in \mathcal{G}_k} \hat{B}_{k,n}, \quad (3.43)$$

限制条件为(3.26)，(3.41a)和(3.42a)。注意，给定阶段3中所有终端的最大时延 \hat{T} ，当且仅当优化问题(3.43)的解满足 $B^*(\hat{T}) \leq B$ 时，优化问题(3.42)是可行的，因为满足其所有约束。这里 B 是用于带宽分配的目标系统带宽。

下面给出关联优化问题(3.42)和优化问题(3.43)的两个有用引理。

引理 3.2. 最小带宽 $B^*(\hat{T})$ 是关于阶段3中所有终端的最大时延 \hat{T} 的单调递减函数。

证明：见附录A.2.1. □

根据引理3.2可以得出, 优化问题(3.42)的解是 \hat{T}^* 的最小值, 且 $B^*(\hat{T}^*)$ 不大于目标系统带宽 B 。这表明优化问题(3.42)的解可以通过搜索 \hat{T}^* 得到, 搜索的准则为 $B^*(\hat{T}^*) \leq B$, 如下所述。

这就需求解优化问题(3.43)以计算函数 $B^*(\hat{T}^*)$ 。为此, 引入以下引理。

引理 3.3. 给定 \hat{T} , 优化问题(3.43)是凸问题。

证明: 见附录A.2.2. □

基于以上分析, 可以通过嵌套对于 \hat{T} 的一维搜索和优化问题(3.43)的解来得出优化问题(3.42)的解。基于引理3.2中给出的单调性, 可以使用二分法对 \hat{T} 实现搜索, 并且给定 \hat{T} 时, 可以使用CVX工具箱^[80]求解优化问题(3.43)。由此, 可以得出部分卸载场景下的最优带宽分配算法, 如表3-1所示。

表 3-1 部分卸载场景下的最优带宽分配算法

Algorithm 3.1 部分卸载场景下的最优带宽分配算法

输入: $B, Q_{\text{now}}, Q_{\text{max}}^c, Q_d, T_C, \{Q_{k,n}^c\}, \{L_{k,n,Q_{\text{now}}}\}, \{\tilde{\gamma}_{k,n,Q_{\text{now}}}\}$ 和 $\{\tilde{\gamma}_{k,n}^u\}$ 。

- 1: 选择 $\hat{T}^u = T^u$, 令 $\hat{T} = \hat{T}^u$, 使得优化问题(3.43)中定义的 $B^*(\hat{T}^u)$ 小于 B 。
- 2: 选择 $\hat{T}^l = T^l$, 令 $\hat{T} = \hat{T}^l$, 使得 $B^*(\hat{T}^l) > B$ 。
- 3: **while** $\hat{T}^u \neq \hat{T}^l$ **do**
- 4: 令 $\hat{T}^m = (\hat{T}^u + \hat{T}^l)/2$, 并将 $\hat{T} = \hat{T}^m$ 代入优化问题(3.43)。
- 5: 利用CVX工具箱求解优化问题(3.43), 得到 $B^*(\hat{T}^m), \{B_{k,n,q}^*\}$ 和 $\{\hat{B}_{k,n}^*\}$ 。
- 6: **if** $B^*(\hat{T}^m) \leq B$ **then**
- 7: $\hat{T}^u = \hat{T}^m$ 。
- 8: **else**
- 9: $\hat{T}^l = \hat{T}^m$ 。
- 10: **end if**
- 11: **end while**
- 12: $\hat{T}^* = \hat{T}^m$ 。

输出: $\hat{T}^*, \{B_{k,n,q}^*\}$ 和 $\{\hat{B}_{k,n}^*\}$ 。

算法3.1的计算复杂度由两个部分决定。一个是求解优化问题(3.43)的内循环，其复杂度为 $\mathcal{O}(K^3)$ ，其中 K 是系统中组的数目。另一个是二分搜索的外循环，其复杂度为 $\mathcal{O}(\log(1/\epsilon))$ ，其中 ϵ 是收敛公差。因此，算法3.1的计算复杂度为 $\mathcal{O}[\log(1/\epsilon)K^3]$ 。

3.3.2.2 全部卸载场景

在当前相干时间内，若系统处于全部卸载场景，即所有终端都已完成计算并开始上传梯度，则 $Q_{\text{now}} > Q_{\text{max}}^c$ 。此时，自当前相干时间至终止相干时间可以划分为两个阶段，如图3-4所示。

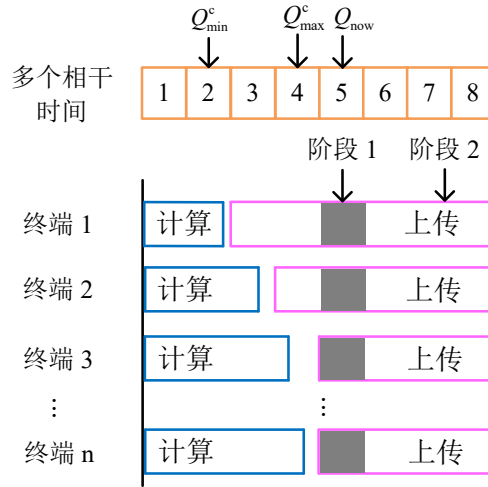


图 3-4 全部卸载场景中的两个阶段

- 阶段1：瞬时上行链路频谱效率已知的当前相干时间段。在该相干时间内，所有终端都在上传梯度。
- 阶段2：期望上行链路频谱效率已知的未来相干时间段。在这些相干时间内，所有终端都在上传梯度。

注意，阶段2通过合并步骤进行了近似处理，即指将第 Q_{now} 个相干时间之后的所有相干时间合并为一个步骤。显然地，总期望时延可以表示为：

$$\bar{T} = \max_{(k,n)} \{\bar{T}_{k,n}^u\} = T_C + \max_{(k,n)} \{\tilde{T}_{k,n}\}, \quad (3.44)$$

其中， $\bar{T}_{k,n}^u$ 是终端 (k,n) 自当前相干时间到完成上传的期望时延， T_C 是所有终端阶段1的时延， $\tilde{T}_{k,n}$ 是终端 (k,n) 在阶段2上传剩余梯度的时延，满足：

$$\tilde{T}_{k,n} \tilde{B}_{k,n} \tilde{\gamma}_{k,n}^u = \tilde{L}_{k,n}, \quad (3.45)$$

其中, $\tilde{B}_{k,n}$ 和 $\tilde{L}_{k,n}$ 分别表示终端 (k, n) 在阶段2分配到的带宽和剩余未上传梯度的大小。此外, 剩余未上传梯度的大小 $\tilde{L}_{k,n}$ 等于当前相干时间内未上传梯度的大小减去阶段1上传的梯度的大小, 可以表示为:

$$\tilde{L}_{k,n} = \max\{L_{k,n,Q_{\text{now}}} - B_{k,n,Q_{\text{now}}} \tilde{\gamma}_{k,n,Q_{\text{now}}} T_C, 0\}, \quad (3.46)$$

其中, $B_{k,n,Q_{\text{now}}} \tilde{\gamma}_{k,n,Q_{\text{now}}} T_C$ 是阶段1上传的梯度的大小。通过代入式(3.44), 式(3.45)和式(3.46), 优化问题(3.36)可以等价表示为:

$$\min_{\{B_{k,n,Q_{\text{now}}}\}, \{\tilde{B}_{k,n}\}} \max_{(k,n)} \{\tilde{T}_{k,n}^u\}, \quad (3.47)$$

限制条件为:

$$\sum_{k=1}^K \sum_{n \in \mathcal{G}_k} B_{k,n,Q_{\text{now}}} \leq B, \quad (3.47a)$$

$$\sum_{k=1}^K \sum_{n \in \mathcal{G}_k} \tilde{B}_{k,n} \leq B, \quad (3.47b)$$

$$\tilde{T}_{k,n} \tilde{B}_{k,n} \tilde{\gamma}_{k,n}^u = \tilde{L}_{k,n}, \quad \forall (k, n). \quad (3.47c)$$

注意到优化问题(3.47)与优化问题(3.41)有相同的结构和性质, 因此可以使用与算法3.1相同的方法来求解优化问题(3.47)。

3.3.2.3 总带宽分配

在本章考虑的系统, 需要按顺序在每个相干时间内确定带宽分配方案。具体地, 需要根据当前相干时间内系统是处于部分卸载场景还是全部卸载场景, 使用相应的带宽分配算法。当所有终端完成上传时, 该过程结束。总带宽分配算法的设计如表3-2所示。

3.3.3 模型参数分配和带宽分配的联合优化算法

本小节提出了模型参数分配和带宽分配的联合优化算法。在时变信道场景中, 由于缺少未来信道的相关信息, 提出了一种次优算法, 包括两个步骤。首先, 模型参数分配方案由文献[56]中针对静态信道的最优模型参数分配算法确定, 其中, 瞬时频谱效率用由式(3.32)定义的期望频谱效率 $\{\bar{\gamma}_{k,n}^u\}$ 代替。然后, 使用算法3.2来确定时变信道场景中的顺序带宽分配算法。联合模型参数分配和带宽分配的次优算法如表3-3所示。

表 3-2 时变信道场景中的顺序带宽分配算法

Algorithm 3.2 时变信道场景中的顺序带宽分配算法

输入: $\{b_k^*\}$, Q_{\min}^c , Q_{\max}^c , $\{L_{k,n,q}\}$ 和 $\{\bar{\gamma}_{k,n}^u\}$ 。

- 1: 初始化 $Q_{\text{now}} = Q_{\min}^c + 1$ 。
 - 2: **while** $\exists(k, n), L_{k,n,Q_{\text{now}}} \neq 0$ **do**
 - 3: 输入 $\{\tilde{\gamma}_{k,n,Q_{\text{now}}}\}$ 。
 - 4: **if** $Q_{\text{now}} \in [Q_{\min}^c + 1, Q_{\max}^c]$ **then**
 - 5: 求解部分卸载场景中的优化问题(3.41), 得到 $\{B_{k,n,Q_{\text{now}}}\}$ 。
 - 6: **else**
 - 7: 求解全部卸载场景中的优化问题(3.47), 得到 $\{B_{k,n,Q_{\text{now}}}\}$ 。
 - 8: **end if**
 - 9: $Q_{\text{now}} = Q_{\text{now}} + 1$ 。
 - 10: **end while**
 - 11: $T^* = Q_{\text{now}} * T_C$ 。
- 输出: T^* and $\{B_{k,n,q}, \forall q\}$ 。

表 3-3 时变信道场景中模型参数分配和带宽分配的联合优化算法

Algorithm 3.3 时变信道场景中模型参数分配和带宽分配的联合优化算法

输入: $\{\bar{\gamma}_{k,n}^u\}$ 。

- 1: 使用 $\{\bar{\gamma}_{k,n}^u\}$ 代替瞬时频谱效率, 然后根据文献[56]中的算法1获得模型参数分配方案 $\{b_k^*\}$ 。
 - 2: 确定 $\{Q_{k,n}^c\}$, Q_{\min}^c , Q_{\max}^c 和 $\{L_{k,n,q}\}$ 。
 - 3: 得到时延 T^* 并使用算法3.2得到带宽分配方案 $\{B_{k,n,q}^*, \forall q\}$ 。
- 输出: T^* , $\{b_k^*\}$ 和 $\{B_{k,n,q}^*, \forall q\}$ 。

3.4 仿真验证与性能分析

3.4.1 仿真设置

在仿真验证中, 考虑系统中有一个基站和 $K = 15$ 个组, 每组有 $N = 15$ 个终端。基站的覆盖范围为半径150m的圆, 系统中的各个组随机分布在基站的覆盖范围内。终端的计算能力在集合 $\{0.1, 0.2, \dots, 1.0\}$ GHz中随机选择。在时变信道场景中, 一个通信回合的时延具有多个相干时间。相干时间设置为0.1s。总带宽为100MHz。终端和基站之间的路径损耗模型为 $128.1 + 37.6 \log_{10}(d)$, 其中 d 表示基站和终端之间的距离。假设小尺度衰落满足瑞利分布。

基站和终端的传输功率分别为46dBm和24dBm。噪声功率谱密度为-174dBm/Hz。在仿真验证中使用 ℓ_1 正则化逻辑回归模型作为训练任务，并使用文献[81]中收集的News20数据集。该模型具有1,241,220个参数。训练数据集包含15,935个样本，测试数据集包含3,993个样本。对于每个组，训练数据集被均匀划分为 N 个子集。每个子集由组中的一个终端下载。表3-4中给出了仿真中用到的主要参数。

表 3-4 第3章仿真参数

参数	数值
路径损耗模型	$128.1 + 37.6 \log_{10}(d)$
基站覆盖范围	150m
基站传输功率	46dBm
终端传输功率	24dBm
噪声功率谱密度	-174dBm/Hz
终端组数	15
每组终端个数	15
系统总带宽	100MHz
相干时间	0.1s

为了进行比较，在仿真验证中考虑以下四种算法。

- 基线算法：平均分配模型参数和带宽。
- 模型参数分配算法：首先平均分配带宽，然后使用时变信道场景中的模型参数分配算法对模型参数进行分配。该算法如文献[56]中的算法1所示，并用期望频谱效率代替瞬时频谱效率。
- 带宽分配算法：首先平均分配模型参数，然后使用算法3.2对带宽进行分配。
- 联合优化算法：使用算法3.3对模型参数分配和带宽分配进行联合优化。

3.4.2 学习性能

为了验证本章所提算法的优越性，图3-5展示了训练准确率和测试准确率与时延的关系曲线。从图中可以看出，模型参数分配算法、带宽分配算法和联合优化算法在收敛速度方面都优于基线算法。具体地，给定200秒的时延，本章提出的联合优化算法、带宽分配算法和模型参数分配算法的训练准确率分别为（77.18%、74.39%、73.3%），测试

准确率分别为 (79.75%、79.26%、79.06%)。而基线算法的训练准确率和测试准确率分别为70.5%和78.35%。相比于基线算法，模型参数分配算法和带宽分配算法的性能增益分别来自模型参数分配优化和带宽分配优化。此外，在联合考虑模型参数分配和带宽分配的情况下，联合优化算法的性能增益更大。具体来说，为计算速度慢（或者信道状况较差）的终端分配额外的带宽（或者更少的模型参数），可以减少每轮时延并加快收敛速度。




图 3-5 学习性能与时延的关系

3.4.3 时延性能

对于基线算法和本章提出的三种算法，不同系统带宽和不同组数下的时延性能比较如图3-6所示。首先，从图3.6(a)中可以看出，所有算法的一轮时延随着系统带宽的增加而减少，其中系统带宽增加意味着有更多的通信资源。当系统带宽较大时，一轮时延主要由计算时延决定。类似地，从图3.6(b)中可以看出，所有算法的一轮时延随着组数的增加而减少，其中组数的增加意味着有更多的计算资源。当组数较多时，一轮时延主要由通信时延决定。其次，本章所提算法的一轮时延与基线算法相比显著减少。具体地，当系统带宽为70MHz时，联合优化算法、带宽分配算法和模型参数分配算法的时延与基线算法相比分别减少了 (25.51%、17.41%、9.71%)。当组数为18时，联合优化算法、带宽分配算法和模型参数分配算法的时延与基线算法相比分别减少了 (23.34%、16.18%、10.28%)。此外，联合优化算法的性能优于其他两种所提算法。比较模型参数分配算法和带宽分配算法的时延性能可以得出，带宽分配算法的性能更好。原因如下。带宽分配算法可以处理所有终端的信道异质性，而模型参数分配算法只能处理组级别的计算能力异构性。

此外，本小节还测试了当每组终端个数变化时所有算法的时延性能。图3-7展示了一




图 3-6 不同系统带宽和不同组数下的时延性能比较

轮时延与每组终端个数的关系曲线。从图中可以看出，一轮时延随着每组终端个数的增加而增加。这是两个因素共同作用的结果。一方面，每个终端分配到的模型参数随着每组终端个数的增加而减少，从而减少了计算时延。另一方面，随着共享固定系统带宽的终端数目增加，每个终端分配到的带宽随之减少。因此，通信时延增加，这对时延性能有不利影响。随着每组终端个数的增加，后一因素对一轮时延的影响更大，从而导致一轮时延增加。




图 3-7 不同每组终端个数下的时延性能比较

上述仿真结果表明，本章提出的联合优化算法的性能最佳，并且验证了第3.3节中的分析。

3.5 本章小结

本章主要研究了时变无线信道场景中的模型分割边缘学习系统，该系统用于在无线网络中执行大规模学习任务。本章旨在联合优化模型参数分配和带宽分配以最小化模型分割边缘学习系统的总时延。首先，分析了最小化系统总时延等价于分别最小化每轮时延，并基于此结论建模了每轮时延最小化问题。接着，为了解决时变信道场景中未来CSI未知的挑战，推导得出了与原优化问题等价的基于MDP的一轮时延最小化问题。基于此，先在给定带宽分配下得出了最优模型参数分配算法。然后，针对时变信道场景，提出了次优带宽分配算法，该算法按顺序在每个相干时间内分配带宽。基于上述两个算法，本章提出了联合模型参数分配和带宽分配的次优算法。最后，通过仿真验证了所提算法的性能。

4 去中心化边缘学习系统中通信资源优化

前两章所研究的无线边缘学习系统都依赖于基站侧部署的PS来收集模型参数或者梯度，但这种架构可能会导致中心节点处的拥塞。在一些场景中，出于对实施效率以及容错等因素的考虑，传统的无线边缘学习架构并不总是适用。因此，需要研究去中心化边缘学习系统，以满足不同场景的需求。

在去中心化边缘学习系统中，终端之间通过D2D链路互相交换模型参数，并在本地进行模型聚合，从而实现与系统中其他终端的协作训练。然而，由于无线资源有限，不可靠D2D通信导致的传输错误以及无线通信资源分配等都会影响系统的学习性能。一方面，由于随机信道衰落和噪声，无线D2D通信通常是不可靠的。不可靠传输会影响终端之间的模型交换。具体来说，部分终端的模型参数在传输过程中丢失会使得聚合所得的全局模型与真实全局模型之间存在模型偏差，从而降低模型训练的性能。另一方面，不合理的通信资源分配会导致系统中不可靠传输的比例增大，从而降低模型的收敛性能，并且会增大系统的训练时延。因此，本章考虑一个基于不可靠D2D通信的去中心化边缘学习系统，并设计了一种通信资源分配方案，以减少不可靠传输并提高系统的学习性能。

对于基于不可靠D2D通信的去中心化边缘学习系统，通信资源分配方案的设计存在两个关键问题。首先是如何评估由不可靠D2D通信导致的传输错误对于模型训练性能的影响？现有的关于去中心化边缘学习系统的研究工作大多基于所有传输可靠的假设，而忽略了系统中存在传输错误的情况及其对于模型训练性能的影响。其次，如何设计最优通信资源分配方案，以减少不可靠传输以及系统的训练时延？在去中心化边缘学习系统中，通信资源分配方案的设计不仅要考虑终端之间的无线信道质量，还要考虑在交换过程中，模型参数丢失对于模型训练性能的影响。基于上述两个问题，本章设计了一种通信资源分配方案，以减少不可靠传输并提高去中心化边缘学习系统的学习性能。

本章内容安排如下。4.1节介绍了去中心化边缘学习系统模型。4.2节建立了一个优化问题以最小化总模型偏差，并简化了原始问题。4.3节给出了最优广播传输速率和带宽分配。4.4节给出了仿真结果并验证了所提算法的有效性。4.5节总结了本章内容。

4.1 系统模型

4.1.1 去中心化边缘学习系统

本章采用的系统模型如图4-1所示。考虑一个旨在协同训练学习模型的去中心化边缘学习系统，该系统具有一个基站和 K 个终端。不同于前几章传统的边缘学习系统，本章考虑的系统中的基站侧不配有PS。基站不需要从终端收集模型参数或梯度以聚合全局模型，它只帮助终端进行网络协调，如信道估计等，并实现优化算法。由于基站需要收集的信息量非常少，所以可以降低通信成本和网络拥塞。为了利用终端的邻近性并减少系统中的数据流量，终端之间通过D2D链路进行数据传输。终端向相邻终端广播本地模型，并从其他终端接收本地模型以聚合全局模型。本章假设D2D链路的信道在一次训练迭代中是不变的，并且在不同的迭代中是变化的。此外，假设采用频率非选择性衰落信道。系统带宽记为 B 。由于D2D信道估计的信令开销昂贵，因此假设所有D2D链路的瞬时CSI是未知的。然而，由于路径损耗主要取决于位置等稳定信息，并且变化缓慢，因此假设已知所有链路的路径损耗。此外，假设所有链路的信道功率增益均为瑞利衰落。从终端 i 到终端 j 链路的信道功率增益表示为 $H_{i,j}$ 。




图 4-1 去中心化边缘学习系统模型

数据并行是去中心化边缘学习系统中常用的提高学习效率的方法，它是指每个终端利用其本地数据集训练整个学习模型。具体描述如下。首先，学习模型的训练目标函数可以

表示为：

$$\mathcal{L}(\boldsymbol{\omega}) = \frac{1}{K} \sum_{k=1}^K F_k(\boldsymbol{\omega}_k; \mathcal{D}_k), \quad (4.1)$$

s.t. $\boldsymbol{\omega}_1 = \boldsymbol{\omega}_2 = \cdots = \boldsymbol{\omega}_K = \boldsymbol{\omega},$

其中， $\boldsymbol{\omega}$ 表示全局模型参数向量， $\boldsymbol{\omega}_k$ 表示终端 k 的本地模型参数向量， \mathcal{D}_k 表示终端 k 的本地数据集， $\mathcal{D} \triangleq \{\mathcal{D}_1, \cdots, \mathcal{D}_k, \cdots, \mathcal{D}_K\}$ 表示总数据集， $F_k(\boldsymbol{\omega}_k; \mathcal{D}_k)$ 表示终端 k 训练的本地目标函数。具体地，本地目标函数可以进一步表示为：

$$F_k(\boldsymbol{\omega}_k; \mathcal{D}_k) = \frac{1}{|\mathcal{D}_k|} \sum_{(\mathbf{x}_i, y_i) \in \mathcal{D}_k} f(\boldsymbol{\omega}_k, \mathbf{x}_i, y_i), \quad (4.2)$$

其中， $|\mathcal{D}_k|$ 表示数据集 \mathcal{D}_k 的数据样本个数， \mathbf{x}_i 表示终端 k 的第 i 个数据样本， y_i 表示相应的数据标签， $f(\boldsymbol{\omega}_k, \mathbf{x}_i, y_i)$ 是损失函数，用于衡量模型 $\boldsymbol{\omega}_k$ 在数据样本 (\mathbf{x}_i, y_i) 处的损失。具体地，表4-1列出了几种常用学习模型的损失函数。为了便于描述，本章后面的小节中将 $F_k(\boldsymbol{\omega}_k; \mathcal{D}_k)$ 重写为 $F_k(\boldsymbol{\omega}_k)$ 。

表 4-1 常用学习模型的损失函数

学习模型	损失函数 $f(\boldsymbol{\omega}, \mathbf{x}, y)$
支持向量机	$\frac{1}{2} \max\{0, 1 - \boldsymbol{\omega}^\top \mathbf{x}\}^2$ ，其中， \top 是转置运算符
线性回归	$\frac{1}{2} \ \boldsymbol{y} - \boldsymbol{\omega}^\top \mathbf{x}\ ^2$
逻辑回归	$-y \log(h(\boldsymbol{\omega}^\top \mathbf{x})) - (1 - y) \log(1 - h(\boldsymbol{\omega}^\top \mathbf{x}))$ ，其中， $h(\cdot)$ 是sigmoid函数
神经网络	$\frac{1}{2} \ \boldsymbol{y} - \boldsymbol{s}(\mathbf{x}; \boldsymbol{\omega})\ ^2$ ，其中， $\boldsymbol{s}(\mathbf{x}; \boldsymbol{\omega}) = s_M(\cdots s_2(s_1(\mathbf{x}; \boldsymbol{\omega}_1); \boldsymbol{\omega}_2) \cdots; \boldsymbol{\omega}_M)$ 是学习输出， M 是层数， $s_i(\cdot)$ 是第 i 层的函数

本章考虑的去中心化边缘学习系统的迭代过程如图4-2所示。在该去中心化边缘学习系统中，模型训练分两个阶段进行。一个是计算阶段，每个终端利用本地数据集更新本地模型。另一个是通信阶段，每个终端将其本地模型广播给所有相邻终端。详细过程如下所述。

- 计算阶段：每个终端采用梯度下降法，利用本地数据集更新其本地模型，可以表示为：

$$\hat{\boldsymbol{\omega}}_k^{(l)} = \boldsymbol{\omega}_k^{(l-1)} - \eta^{(l-1)} \mathbf{g}_k(\boldsymbol{\omega}_k^{(l-1)}), \quad \forall k, \quad (4.3)$$

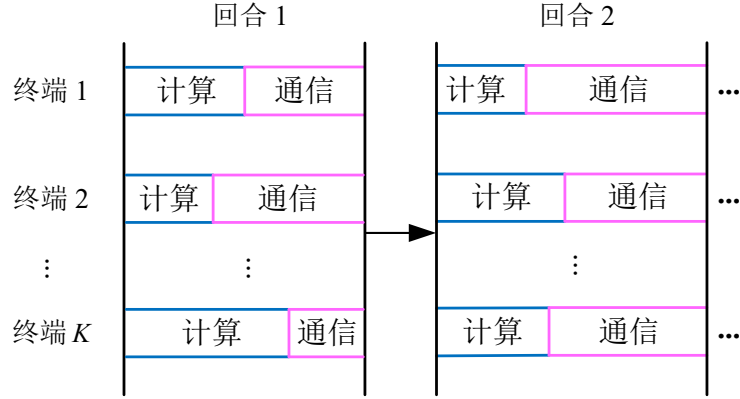


图 4-2 去中心化边缘学习系统的迭代过程

其中, $\hat{\omega}_k^{(l)}$ 表示第 l 个通信回合更新的本地模型, $\omega_k^{(l-1)}$ 表示第 $(l-1)$ 个通信回合的本地模型, $\eta^{(l-1)}$ 表示第 $(l-1)$ 个通信回合的学习率, $\mathbf{g}_k(\omega_k^{(l-1)}) = \nabla F_k(\omega_k^{(l-1)})$ 表示梯度向量。

- 通信阶段: 本地模型在此阶段共享。一方面, 每个终端将其本地学习模型广播给所有相邻终端。另一方面, 每个终端接收其他终端共享的本地模型, 用以估计全局模型。然而, 对于任意终端, 比如终端 k , 由于缺少瞬时 CSI 导致的不可靠传输, 估计全局模型 $\omega_k^{(l)}$ 可能与真实全局模型 $\omega^{(l)}$ 不同。具体地, 真实全局模型^[58] 可以表示为:

$$\omega^{(l)} = \frac{1}{K} \sum_{k=1}^K \hat{\omega}_k^{(l)}, \quad (4.4)$$

其中, 式(4.3)中定义的 $\hat{\omega}_k^{(l)}$ 是终端 k 在这个通信回合中更新后的本地模型。终端 i 的估计全局模型可以表示为:

$$\omega_i^{(l)} = \frac{\sum_{k=1}^K \alpha_{k,i} \hat{\omega}_k^{(l)}}{\sum_{k=1}^K \alpha_{k,i}}, \quad \forall i, \quad (4.5)$$

其中, $\alpha_{k,i} \in \{0, 1\}$ 。如果终端 k 的本地模型成功共享给终端 i , 则 $\alpha_{k,i} = 1$; 否则, $\alpha_{k,i} = 0$ 。值得注意的是, 本章采用平均法来估计全局模型, 其中权重取决于终端的入度。由于随机信道衰落和噪声, 无线 D2D 通信通常是不可靠的, 因此权重取决于终端出度的方法不适用于本章。

如图 4-2 所示, 在下一个通信回合的计算阶段之前, 所有终端都应共享其本地模型, 用以估计全局模型。这使得每个通信回合需要进行同步更新。这两个阶段不断迭代, 直至模型收敛。

4.1.2 时延模型

考虑任意一个通信回合（如第 l 个通信回合）和任意终端（如终端 k ），一个通信回合的时延由计算时延和通信时延决定。

- 计算时延：终端 k 的计算时延表示为：

$$T_k^{\text{cmp}} = \frac{|\mathcal{D}_k|}{f_k}, \quad \forall k, \quad (4.6)$$

其中， f_k 表示终端 k 的计算速度，根据每秒处理的样本数量测量得到，它取决于终端 k 的CPU频率和训练模型的大小。每个终端的 f_k 值是先验已知的常数。值得注意的是，每个终端的计算时延 $\{T_k^{\text{cmp}}\}$ 是不同的，且是常量值。

- 通信时延：终端 k 的通信时延表示为：

$$T_k^{\text{com}} = \frac{S}{\hat{R}_k}, \quad \forall k, \quad (4.7)$$

其中， S 表示模型大小， \hat{R}_k 表示终端 k 的广播传输速率。如上文所述，从终端 k 到终端 i 的传输可能是不可靠的。具体地，当且仅当从终端 k 到终端 i 的瞬时信道容量 $R_{k,i}$ 不小于广播传输速率 \hat{R}_k 时，才能实现成功传输，即

$$\alpha_{k,i} = \begin{cases} 1, & \text{若 } R_{k,i} \geq \hat{R}_k \\ 0, & \text{若 } R_{k,i} < \hat{R}_k \end{cases}. \quad (4.8)$$

瞬时信道容量 $R_{k,i}$ 可以表示为：

$$R_{k,i} = B_k \log_2 \left(1 + \frac{P_k H_{k,i}}{N_0} \right), \quad \forall k, i, k \neq i, \quad (4.9)$$

其中， B_k 表示分配给终端 k 用于广播的带宽， P_k 表示终端 k 的传输功率密度， N_0 表示噪声功率密度。本章假设终端用于广播的频带是正交的，因此没有考虑相互干扰。

4.2 问题建模

本章的目标是在任意一个通信回合结束时，即第 $(l+1)$ 个通信回合结束时，最小化本地估计全局模型与真实全局模型之间的总偏差。由不可靠传输导致的模型偏差会导致平均损失减少量的下降，从而导致学习性能下降。因此，通过总模型偏差来评估去中心化边缘学习系统的学习性能是合理的。

在一个通信回合结束时，终端*i*的本地估计全局模型和真实全局模型之间的偏差可以表示为：

$$\delta_i = \left\| \boldsymbol{\omega}^{(l+1)} - \boldsymbol{\omega}_i^{(l+1)} \right\|^2, \quad \forall i, \quad (4.10)$$

其中， $\boldsymbol{\omega}^{(l+1)}$ 表示式(4.4)中定义的真实全局模型， $\boldsymbol{\omega}_i^{(l+1)}$ 表示式(4.5)中定义的本地估计全局模型。总偏差定义为所有终端本地偏差的平均值，表示为：

$$\delta = \frac{1}{K} \sum_{i=1}^K \delta_i. \quad (4.11)$$

最小化总偏差有两个约束条件。一个约束条件是无线系统的总带宽是有限的，即

$$\sum_{k=1}^K B_k \leq B, \quad (4.12)$$

其中， B_k 表示分配给终端*k*用于广播其本地模型的带宽， B 表示系统总带宽。另一个约束条件是任一终端一个通信回合的时延应不超过给定的阈值，即

$$T_k^{\text{cmp}} + T_k^{\text{com}} \leq T, \quad \forall k, \quad (4.13)$$

其中， T_k^{cmp} 表示终端*k*的计算时延， T_k^{com} 表示终端*k*的通信时延， T 表示一个通信回合允许的最大时延。注意到在约束(4.12)和约束(4.13)下，可以通过联合优化广播传输速率和带宽分配来增加成功传输的比例，从而减少模型总偏差，提高学习性能。

综上所述，总偏差最小化问题可以建模为：

$$\min_{\{R_k, B_k\}} \mathbb{E}\{\delta\} = \mathbb{E} \left\{ \frac{1}{K} \sum_{i=1}^K \delta_i \right\}, \quad (4.14)$$

限制条件为(4.12)-(4.13)。其中，对随机信道系数取期望值。本章旨在通过开发资源管理方案来最小化每一个通信回合的模型偏差。为此，本章假设每一轮训练中偏差的权重是相等的。基于此，本章获得了一些关于资源分配和速率适应的有意义的结论。如果每个通信回合都考虑权重和资源管理方案的优化，虽然可以进一步提高收敛性能，但会非常复杂，无法得到直接且有意义的结论。尽管如此，这个问题值得在未来的工作中进一步研究。

为了得到问题的解，下面对优化问题(4.14)的目标函数进行化简。为了最小化一个通信回合的总偏差，基站需要从终端获得一些反馈信息，比如本地估计全局模型和真实全局模型之间的偏差。然而，所有终端都无法获得真实全局模型，使得本地模型偏差无法直接计算得到。因此，优化问题(4.14)无法直接求解。为了解决该问题，本章首先将优化问题(4.14)的目标函数进行化简。将式(4.10)中定义的本地偏差代入到式(4.11)中定义的总偏差，可以得到：

$$\delta = \frac{1}{K} \sum_{i=1}^K \left\| \boldsymbol{\omega}^{(l+1)} - \boldsymbol{\omega}_i^{(l+1)} \right\|^2. \quad (4.15)$$

将式(4.4)中定义的真实全局模型 $\omega^{(l+1)}$ 和式(4.5)中定义的本地估计全局模型 $\omega_i^{(l+1)}$ 代入式(4.15), 可以进一步得到:

$$\begin{aligned} \delta &= \frac{1}{K} \sum_{i=1}^K \left\| \frac{1}{K} \sum_{k=1}^K \hat{\omega}_k^{(l+1)} - \frac{\sum_{k=1}^K \alpha_{k,i} \hat{\omega}_k^{(l+1)}}{\sum_{k=1}^K \alpha_{k,i}} \right\|^2 \\ &\leq \frac{1}{K} \sum_{i=1}^K \left\| \frac{1}{K} \sum_{k=1}^K \hat{\omega}_k^{(l+1)} - \frac{1}{K} \sum_{k=1}^K \alpha_{k,i} \hat{\omega}_k^{(l+1)} \right\|^2 \\ &= \frac{1}{K} \sum_{i=1}^K \left\| \frac{1}{K} \sum_{k=1}^K (1 - \alpha_{k,i}) \hat{\omega}_k^{(l+1)} \right\|^2, \end{aligned} \quad (4.16)$$

其中, 使用了不等式 $\sum_{k=1}^K \alpha_{k,i} \leq K$, 当且仅当 $\alpha_{k,i} = 1, \forall k, i$, 即所有传输都可靠时, 等号成立。

根据詹森不等式, 式(4.16)可以进一步近似为:

$$\delta \leq \frac{1}{K^2} \sum_{i=1}^K \sum_{k=1}^K (1 - \alpha_{k,i})^2 \left\| \hat{\omega}_k^{(l+1)} \right\|^2, \quad (4.17)$$

当 $\alpha_{k,i} = 1, \forall k, i$, 即所有传输都可靠时, 等号成立。然后, 根据式(4.3), 式(4.17)中的项 $\left\| \hat{\omega}_k^{(l+1)} \right\|^2$ 可以表示为:

$$\begin{aligned} \left\| \hat{\omega}_k^{(l+1)} \right\|^2 &= \left\| \omega_k^{(l)} - \eta^{(l)} \mathbf{g}_k(\omega_k^{(l)}) \right\|^2 \\ &= \left\| \omega_k^{(l)} \right\|^2 - 2\eta^{(l)} \mathbf{g}_k(\omega_k^{(l)})^\top \omega_k^{(l)} + (\eta^{(l)})^2 \left\| \mathbf{g}_k(\omega_k^{(l)}) \right\|^2. \end{aligned} \quad (4.18)$$

为了进一步简化上式, 引入以下不等式。本章考虑常用的具有凸损失函数的学习模型, 例如表4-1中的支持向量机、线性回归和逻辑回归。由于 $F_k(\cdot)$ 是凸函数, 可以根据零附近的一阶泰勒展开式获得以下不等式:

$$F_k(\mathbf{0}) \geq F_k(\omega_k^{(l)}) - \mathbf{g}_k(\omega_k^{(l)})^\top \omega_k^{(l)}, \quad \forall k. \quad (4.19)$$

经过简单的数学计算, 可以得到以下不等式:

$$-\mathbf{g}_k(\omega_k^{(l)})^\top \omega_k^{(l)} \leq F_k(\mathbf{0}) - F_k(\omega_k^{(l)}), \quad \forall k, \quad (4.20)$$

当 $\omega_k^{(l)} = \mathbf{0}$ 时, 等号成立。从式(4.20)可以看出, 当本地模型趋于零时, $-\mathbf{g}_k(\omega_k^{(l)})^\top \omega_k^{(l)}$ 的上界是紧的。本地模型参数的值与模型的稀疏性相关。稀疏性使得模型参数的值更小, 因此 $-\mathbf{g}_k(\omega_k^{(l)})^\top \omega_k^{(l)}$ 的上界更紧。根据文献[82], 正则化常用于机器学习中, 这使得模型稀疏并趋于零。因此, $-\mathbf{g}_k(\omega_k^{(l)})^\top \omega_k^{(l)}$ 的上界是紧的。

此外，为了使终端在完成计算阶段之后可以直接进入通信阶段，避免等待其他终端完成本地计算，基站在每个通信回合开始时从终端获得反馈信息。然而，在第 l 个通信回合开始时，这个通信回合中的梯度向量是未知的。因此，第 l 个通信回合中梯度向量的模需要用第 $(l-1)$ 个通信回合中梯度向量的模来估计。由于 $\mathbf{g}_k(\cdot)$ 是凸函数且是利普希茨连续的，所以对于任意 \mathbf{u} 和 \mathbf{v} ，以下不等式成立：

$$\|\mathbf{g}_k(\mathbf{u}) - \mathbf{g}_k(\mathbf{v})\| \leq L \|\mathbf{u} - \mathbf{v}\|, \quad (4.21)$$

其中， L 是利普希茨常数。因此，第 l 个通信回合的梯度向量的模满足以下不等式：

$$\begin{aligned} \left\| \mathbf{g}_k(\boldsymbol{\omega}_k^{(l)}) \right\|^2 &= \left\| \mathbf{g}_k(\boldsymbol{\omega}_k^{(l)}) - \mathbf{g}_k(\boldsymbol{\omega}_k^{(l-1)}) + \mathbf{g}_k(\boldsymbol{\omega}_k^{(l-1)}) \right\|^2 \\ &\leq \left(\left\| \mathbf{g}_k(\boldsymbol{\omega}_k^{(l)}) - \mathbf{g}_k(\boldsymbol{\omega}_k^{(l-1)}) \right\| + \left\| \mathbf{g}_k(\boldsymbol{\omega}_k^{(l-1)}) \right\| \right)^2 \\ &\leq \left(L \left\| \boldsymbol{\omega}_k^{(l)} - \boldsymbol{\omega}_k^{(l-1)} \right\| + \left\| \mathbf{g}_k(\boldsymbol{\omega}_k^{(l-1)}) \right\| \right)^2, \end{aligned} \quad (4.22)$$

其中，第一个不等式采用了 $\|\mathbf{u} + \mathbf{v}\| \leq \|\mathbf{u}\| + \|\mathbf{v}\|$ ， $\forall \mathbf{u}, \mathbf{v}$ ，第二个不等式采用了式(4.21)。

结合式(4.17)、式(4.18)、式(4.20)和式(4.22)，总偏差可以表示为：

$$\begin{aligned} \delta &\leq \frac{1}{K^2} \sum_{i=1}^K \sum_{k=1}^K (1 - \alpha_{k,i})^2 \left\{ \left\| \boldsymbol{\omega}_k^{(l)} \right\|^2 + 2\eta^{(l)} \left[F_k(\mathbf{0}) - F_k(\boldsymbol{\omega}_k^{(l)}) \right] \right. \\ &\quad \left. + (\eta^{(l)})^2 \left(L \left\| \boldsymbol{\omega}_k^{(l)} - \boldsymbol{\omega}_k^{(l-1)} \right\| + \left\| \mathbf{g}_k(\boldsymbol{\omega}_k^{(l-1)}) \right\| \right)^2 \right\} \\ &\triangleq \frac{1}{K^2} \sum_{i=1}^K \sum_{k=1}^K (1 - \alpha_{k,i})^2 A_k. \end{aligned} \quad (4.23)$$

根据式(4.23)，可以得到 A_k 与终端 k 的一些本地信息有关，比如第 l 个通信回合的本地模型的模、第 l 个通信回合与第 $(l-1)$ 个通信回合的模型差的模、第 $(l-1)$ 个通信回合的梯度的模、以及从 $\boldsymbol{\omega}_k^{(l)}$ 到 $\mathbf{0}$ 的本地损失减少量。由于这些信息量足够小，所以基站很容易从终端 k 获取 A_k 。

因此，总偏差最小化问题可以简化为：

$$\min_{\{\hat{R}_k, B_k\}} \mathbb{E} \left\{ \frac{1}{K^2} \sum_{i=1}^K \sum_{k=1}^K (1 - \alpha_{k,i})^2 A_k \right\}, \quad (4.24)$$

限制条件为(4.12)-(4.13)。

为了求解优化问题(4.24)，将进行进一步化简。记 $(1 - \alpha_{k,i})^2$ 为 $\gamma_{k,i}$ 。根据式(4.8)， $\gamma_{k,i}$ 可以表示为：

$$\gamma_{k,i} = \begin{cases} 1, & \text{若 } R_{k,i} < \hat{R}_k \\ 0, & \text{若 } R_{k,i} \geq \hat{R}_k \end{cases}. \quad (4.25)$$

然后，总偏差可以近似表示为：

$$\delta \leq \frac{1}{K^2} \sum_{i=1}^K \sum_{k=1}^K \gamma_{k,i} A_k. \quad (4.26)$$

因此，可以最小化总偏差的上界，其目标函数可以表示为：

$$\mathbb{E} \left\{ \frac{1}{K^2} \sum_{i=1}^K \sum_{k=1}^K \gamma_{k,i} A_k \right\} = \frac{1}{K^2} \sum_{i=1}^K \sum_{k=1}^K A_k \Pr(R_{k,i} < \hat{R}_k). \quad (4.27)$$

本章考虑的去中心化边缘学习系统中，假设所有链路的信道功率增益为瑞利衰落，即 $H_{k,i}$ 呈指数分布，其概率密度函数可以表示为：

$$f_{\text{PDF}}(x) = \frac{1}{\sigma_{k,i}^2} \exp\left(-\frac{x}{\sigma_{k,i}^2}\right), \quad x \geq 0, \quad (4.28)$$

其中， $\sigma_{k,i}$ 表示方差。然后，可以得出下式：

$$\Pr(R_{k,i} < \hat{R}_k) = 1 - \exp\left(-\frac{N_0}{\sigma_{k,i}^2 P_k} \left(2^{\frac{\hat{R}_k}{B_k}} - 1\right)\right). \quad (4.29)$$

基于以上分析，总模型偏差的上界可以表示为：

$$\mathbb{E} \left\{ \frac{1}{K^2} \sum_{i=1}^K \sum_{k=1}^K \gamma_{k,i} A_k \right\} = \frac{1}{K^2} \sum_{i=1}^K \sum_{k=1}^K A_k \left[1 - \exp\left(-\frac{N_0}{\sigma_{k,i}^2 P_k} \left(2^{\frac{\hat{R}_k}{B_k}} - 1\right)\right) \right]. \quad (4.30)$$

推论 4.1. 由终端 k 到终端 i 的不可靠传输导致的终端 i 的本地模型偏差可以定义为：

$$\Delta_{k,i} = \frac{A_k}{K^2} \left[1 - \exp\left(-\frac{N_0}{\sigma_{k,i}^2 P_k} \left(2^{\frac{\hat{R}_k}{B_k}} - 1\right)\right) \right]. \quad (4.31)$$

根据推论4.1，优化问题(4.24)可以简化为：

$$\min_{\{\hat{R}_k, B_k\}} \sum_{i=1}^K \sum_{k=1}^K \Delta_{k,i}, \quad (4.32)$$

限制条件为(4.12)-(4.13)。尽管上界不能准确评估总模型偏差，但是基于上界的结论可以为无线网络中的去中心化边缘学习系统提供一定的理论指导。

4.3 算法设计和协议设计

本节提出了用于解决优化问题(4.32)的算法，并提出了一种实现去中心化边缘学习系统的工作协议。

4.3.1 广播传输速率优化

首先分析在给定带宽分配时，每个终端的最优广播传输速率。分析可得，最优广播传输速率使得每个终端的一轮时延相等。具体地，给定带宽分配 $\{B_k^*\}$ ，优化问题(4.32)可以表示为：

$$\min_{\{\hat{R}_k\}} \sum_{i=1}^K \sum_{k=1}^K \Delta_{k,i}, \quad (4.33)$$

限制条件为：

$$T_k^{\text{cmp}} + \frac{S}{\hat{R}_k} \leq T, \quad \forall k. \quad (4.33a)$$

为了求解优化问题(4.33)，首先引入以下引理来讨论优化问题(4.33)的凸性。

引理 4.1. 当 \hat{R}_k 满足以下不等式时，优化问题(4.33)是凸问题：

$$\hat{R}_k \leq B_k \log_2 \frac{\sigma_{k,i}^2 P_k}{N_0}. \quad (4.34)$$

证明：见附录A.3.1。 □

注 4.1. 基于引理4.1，可以看出 \hat{R}_k 在以下场景中可以满足式(4.34)。

- 场景1：（高SNR场景）从终端 k 到终端 i 的链路SNR可以表示为：

$$\text{SNR}_{k,i} = \frac{P_k H_{k,i}}{N_0}. \quad (4.35)$$

由于 $H_{k,i}$ 呈指数分布（其概率密度函数如式(4.28)所示），从终端 k 到终端 i 的链路的SNR期望值可以表示为：

$$\overline{\text{SNR}}_{k,i} = \mathbb{E}(\text{SNR}_{k,i}) = \frac{\sigma_{k,i}^2 P_k}{N_0}. \quad (4.36)$$

显然地，对于任意终端 i ，当 $\overline{\text{SNR}}_{k,i}$ 足够高时， \hat{R}_k 满足式(4.34)。此外，对于D2D链路，高SNR场景是常见且合理的。

- 场景2：（带宽充足场景）当系统总带宽充足时， \hat{R}_k 很容易满足式(4.34)。此外，当系统总带宽越大时，成功传输的比例会增加，因此总模型偏差会越小。

在上述两种场景中，优化问题(4.33)是凸问题。最优广播传输速率如以下定理所示。

定理 4.1. 当式(4.34)成立时, 优化问题(4.33)的最优解表示为:

$$\hat{R}_k^* = \frac{S}{T - T_k^{\text{cmp}}}, \quad \forall k. \quad (4.37)$$

证明: 见附录A.3.2. □

注 4.2. 从定理4.1可以得出两个结论。首先, 很容易得出, 当所有终端的一轮时延相等时, 可以得到最优广播传输速率。其次, 当式(4.34)成立时, 优化问题(4.32)的最优广播传输速率与优化问题(4.33)相同。

4.3.2 带宽分配

目前为止, 已经得出了最优广播传输速率。本节将继续求解得到最优带宽分配。给定最优广播传输速率, 可以通过求解优化问题(4.32)来得到带宽分配。具体地, 给定广播传输速率 $\{\hat{R}_k^*\}$ 时, $\Delta_{k,i}$ 可以表示为:

$$\Delta_{k,i} = \frac{A_k}{K^2} \left[1 - \exp \left(-\frac{N_0}{\sigma_{k,i}^2 P_k} \left(2^{\frac{S}{(T - T_k^{\text{cmp})} B_k}} - 1 \right) \right) \right]. \quad (4.38)$$

然后, 优化问题(4.32)可以化简为:

$$\min_{\{B_k\}} \sum_{i=1}^K \sum_{k=1}^K \Delta_{k,i}, \quad (4.39)$$

限制条件为:

$$\sum_{k=1}^K B_k \leq B. \quad (4.39a)$$

为了求解优化问题(4.39), 首先引入以下引理来讨论优化问题(4.39)的凸性。

引理 4.2. 当 B_k 满足以下不等式时, 优化问题(4.39)是凸问题:

$$2^{\frac{S}{(T - T_k^{\text{cmp})} B_k}} \leq \frac{2\sigma_{k,i}^2 P_k (T - T_k^{\text{cmp}})}{\ln 2 N_0 S} B_k + \frac{\sigma_{k,i}^2 P_k}{N_0}, \quad (4.40)$$

$$B_k \geq \frac{S}{(T - T_k^{\text{cmp}}) \log_2 \frac{\sigma_{k,i}^2 P_k}{N_0}}. \quad (4.41)$$

证明: 见附录A.3.3. □

注 4.3. 基于引理4.2, 可以看出 B_k 在以下场景中可以满足式(4.40)和式(4.41)。

- 场景1: (高SNR场景) 注4.1中已经详细说明了这种场景。
- 场景2: (大时延场景) 当给定的一轮时延阈值较大时, B_k 很容易满足式(4.40)和式(4.41)。此外, 当一轮时延越大时, 总模型偏差越小。

在上述两个场景下, 式(4.40)和式(4.41)成立, 此时优化问题(4.39)是凸问题。然后, 可以用拉格朗日法求解优化问题(4.39), 并得出最优带宽分配的一个重要性质。为此, 首先定义偏差减少速率 $\left| \sum_{i=1}^K \frac{\partial \Delta_{k,i}}{\partial B_k} \right|$ 为每增加单位带宽, 所有终端的模型偏差减少量, 这是由来自终端 k 的不可靠传输引起的。从偏差减少速率的定义和式(4.38)中可以观察到, 随着分配带宽的增加, 偏差减少速率随之增加, 从而使得模型偏差减少。这是因为分配更多的带宽可以提高成功传输的比例, 从而减少模型偏差, 使得偏差减少的速率得以提升。基于以上分析, 引入以下定理介绍最优带宽分配的重要性质。

定理 4.2. 给定正常数 C , 在带宽分配的约束条件 $\sum_{k=1}^K B_k = B$ 下, 优化问题(4.39)最优解的充分必要条件为:

$$\left| \sum_{i=1}^K \frac{\partial \Delta_{k,i}}{\partial B_k} \right| = C, \quad \forall k. \quad (4.42)$$

证明: 见附录A.3.4。 □

注 4.4. 根据定理4.2, 最优带宽分配要求所有终端的偏差减少速率相同。

根据附录A.3.4中的式(A.28)和式(A.29), 可以看出优化问题(4.39)没有闭式解。由于优化问题(4.39)是凸问题, 可以用原始对偶法来求解该问题。一些必要的符号表示如下。记 η_λ 和 $\{\eta_{B_k}\}$ 为梯度下降算法的步长。拉格朗日函数的定义如附录A.3.4中式(A.27)所示。应用原始对偶法得到用于求解优化问题(4.39)的算法如表4-2所示, 其中, 式(4.39a)成立。表4-2中算法的计算复杂度为 $\mathcal{O}(K^3)$ 。

到目前为止, 本章已经在一些场景中得到了最优解, 比如高SNR场景、带宽充足场景、大时延场景, 这些场景通常都存在。在其他一般场景下, 优化问题(4.33)和(4.39)是凹问题, 其最优解一定在可行区域的边界处获得。因此, 本章所提算法也可以在一般场景下求解上述优化问题。根据文献[83], 所提算法可以保证收敛到优化问题的稳定点。在没有

表 4-2 最优带宽分配算法

Algorithm 4.1 最优带宽分配算法

输入: $\{A_k, P_k, \sigma_{k,i}, T_k^{\text{cmp}}\}, N_0, S$ 和 T 。

1: 初始化 $\lambda^{(0)}$ 以及 $l = 0$ 。

2: **repeat**

3: $\lambda^{(l+1)} = \max \left\{ \lambda^{(l)} + \eta_\lambda \frac{\partial L_2(\{B_k\}, \lambda)}{\partial \lambda}, 0 \right\}$ 。

4: 初始化 $\{B_k^{(0)}\}$ 以及 $i = 0$ 。

5: **repeat**

6: $B_k^{(i+1)} = B_k^{(i)} - \eta_{B_k} \left(\sum_{i=1}^K \frac{\partial \Delta_{k,i}}{\partial B_k} + \lambda^{(l+1)} \right), \forall k$ 。

7: $i = i + 1$ 。

8: **until** 收敛

9: $\{B_k^* = B_k^{i-1}, \forall k\}$ 且 $l = l + 1$ 。

10: **until** 收敛

输出: $\{B_k^*\}$ 。

更好替代方案的情况下, 所提算法是目前解决上述优化问题的最佳选择。由于上述优化问题是NP难问题, 似乎无法对最优解与本章所提算法之间的性能差距进行定量分析。

4.3.3 实现去中心化边缘学习系统的协议

本小节将介绍所提出的协议, 用以实现基于上述算法的去中心化边缘学习系统。一次迭代的详细过程如下所述。

- **步骤1: 网络协调。** 基站帮助终端进行网络协调, 如信道估计等。为了减少D2D信道估计的信令开销, 基站获取长时间尺度信息, 例如终端之间的距离, 而不是所有D2D链路的瞬时CSI。
- **步骤2: 本地模型相关信息反馈。** 终端需要将一些本地信息反馈给基站, 包括当前迭代本地模型的模 $\|\omega_k^{(l)}\|^2$, 当前迭代本地模型与上一轮迭代本地模型之差的模 $\|\omega_k^{(l)} - \omega_k^{(l-1)}\|$, 上一轮迭代梯度的模 $\|g_k(\omega_k^{(l-1)})\|$ 以及本地损失减少量 $\{F_k(\mathbf{0}) - F_k(\omega_k^{(l)})\}$ 。由于需要反馈的本地信息量足够小, 反馈的时延可以忽略不计。
- **步骤3: 所提算法实现。** 基站在接收到所有信息之后, 开始执行表4-2中的算法以获得带宽分配。
- **步骤4: 本地计算。** 每个终端利用其本地数据集更新其本地模型。

- **步骤5：广播模型。**当模型更新完成之后，每个终端通过广播与其相邻终端共享其本地模型，并从其他终端接收本地模型以估计全局模型。此外，广播传输速率根据式(4.37)计算得到，其值取决于模型大小、一个通信回合的时延以及计算时延。

循环执行以上步骤直至模型收敛。图4-3描述了在去中心化边缘学习系统的迭代过程中终端和基站之间的交互。

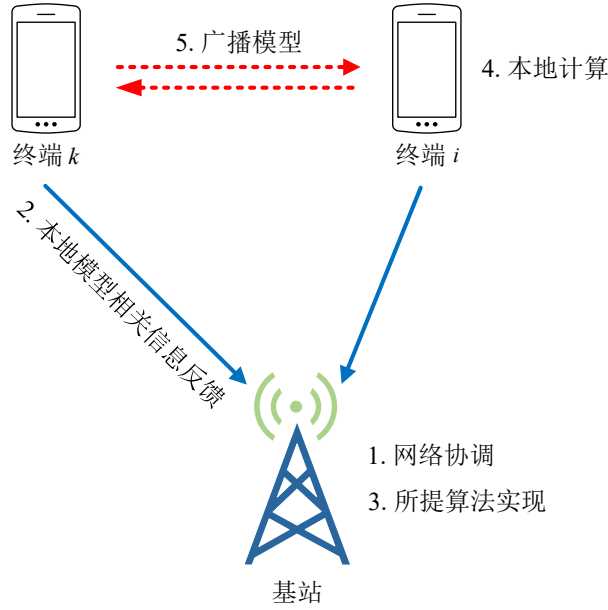


图 4-3 实现去中心化边缘学习系统的协议

4.3.4 收敛性分析

本小节分析了所提算法的收敛性能。首先，对本地目标函数进行以下假设。

假设 4.1. 本地目标函数 $F_k(\omega_k)$, $\forall k$ 是关于参数 μ 的强凸函数，即对于任意 \mathbf{u} 和 \mathbf{v} ，以下不等式成立：

$$F_k(\mathbf{u}) \geq F_k(\mathbf{v}) + \mathbf{g}_k(\mathbf{v})^\top (\mathbf{u} - \mathbf{v}) + \frac{\mu}{2} \|\mathbf{u} - \mathbf{v}\|^2, \quad (4.43)$$

其中， $\mu > 0$ 是强凸常数。

假设 4.2. 本地目标函数 $F_k(\omega_k)$, $\forall k$ 是利普希茨连续的，即对于任意 \mathbf{u} 和 \mathbf{v} ，以下不等式成立：

$$F_k(\mathbf{u}) \leq F_k(\mathbf{v}) + \mathbf{g}_k(\mathbf{v})^\top (\mathbf{u} - \mathbf{v}) + \frac{L}{2} \|\mathbf{u} - \mathbf{v}\|^2. \quad (4.44)$$

许多常用的学习模型，例如支持向量机、线性回归和逻辑回归等，都满足上述一般假设。本章第4.4节将通过仿真来验证所提算法也适用于CNN模型，尽管其损失函数不满足上述假设。此外，对于终端 k ，大多数来自其他终端的本地模型可以被正确接收。因此，可以进行以下假设。

假设 4.3. 终端 k 的估计全局模型可以表示为：

$$\omega_k^{(l)} = \omega^{(l)} + \xi_k^{(l)} \approx \omega^{(l)}, \quad (4.45)$$

其中， $\xi_k^{(l)}$ 表示估计全局模型和真实全局模型之间的偏差。注意到 $\xi_k^{(l)}$ 通常很小，这是因为对于大多数终端来说 $\alpha_{i,k} = 1$ 。

基于上述假设，对于终端 k ，可以得到每个通信回合的收敛上界，如以下定理所示。

定理 4.3. (收敛上界) 对于终端 k ，本章所提算法在第 l 个通信回合的收敛上界可以表示为：

$$\begin{aligned} \mathbb{E} \left\{ F_k(\omega_k^{(l+1)}) - F_k(\omega_k^*) \right\} &\leq \prod_{m=1}^l (1 - \mu\eta^{(m)}) \mathbb{E} \left\{ F_k(\omega_k^{(1)}) - F_k(\omega_k^*) \right\} \\ &+ \frac{1}{2} \sum_{m=1}^l \chi^{(m)} [L(\eta^{(m)})^2 - \eta^{(m)}] \mathbb{E} \left\{ \left\| \frac{1}{K} \sum_{i=1}^K \mathbf{g}_i(\omega_i^{(l)}) \right\|^2 \right\}, \end{aligned} \quad (4.46)$$

其中， $\chi^{(m)} = \prod_{j=m+1}^l (1 - \mu\eta^{(j)})$ 是权重系数。

证明：见附录A.3.5。 □

定理4.3表明最优性差距的上界由式(4.46)右边的两项之和决定。随着训练轮数 l 的增加，当学习率满足 $0 < \eta^{(m)} < \frac{1}{\mu}$ ， $\forall m$ 时，前一项将收敛到零。由于权重系数 $\chi^{(m)}$ 的减小，后一项也将收敛到零。一般来说，借助于本章所提算法，本地模型将收敛到最优。

4.4 仿真验证与性能分析

本节将通过仿真测试所提算法的学习性能，并验证了所提算法与基线算法相比的性能提升。

4.4.1 仿真设置

在仿真验证中，考虑去中心化边缘学习系统中有一个基站和 $K = 10$ 个终端。基站覆

盖范围的半径为150m。终端之间通过D2D链路进行数据传输。记 d 为终端之间的距离。如果 $d < 0.05\text{km}$ ，则终端之间的路径损耗模型为 $98.45 + 20 \log_{10}(d)$ ；否则，终端之间的路径损耗模型为 $175.78 + 40 \log_{10}(d)$ 。小尺度衰落满足瑞利分布。每个终端的传输功率设置为24dBm，噪声功率谱密度为 $1.1 \times 10^{-18}\text{W/Hz}$ 。系统总带宽设置为50MHz，所有终端的一轮时延设置为1s。表4-3给出了仿真中用到的主要参数。

表 4-3 第4章仿真参数

参数	数值
路径损耗模型, 若 $d < 0.05 \text{ km}$	$98.45 + 20 \log_{10}(d)$
路径损耗模型, 若 $d \geq 0.05 \text{ km}$	$175.78 + 40 \log_{10}(d)$
基站覆盖范围	150m
终端传输功率	24dBm
噪声功率谱密度	$1.1 \times 10^{-18}\text{W/Hz}$
终端个数	10
系统总带宽	50MHz
一轮时延	1s
训练逻辑回归模型的学习率	0.001
训练CNN模型的学习率	0.01

本章采用 ℓ_1 正则化逻辑回归模型和常用的CNN模型ResNet作为训练任务。对于逻辑回归模型，本章采用文献[81]中收集的News20数据集。该数据集包含20个类别的数据样本，包括15,935个训练样本和3,993个测试样本。对于CNN模型，本章采用CIFAR-10数据集。该数据集包含10个类别的数据样本，包括50,000个训练样本和10,000个测试样本。由于移动终端数据分布可能受到许多因素的影响，例如地理位置、用户的特定习惯等，因此在仿真中考虑了更具一般性的Non-IID的数据划分方式。所有训练数据样本首先按其标签排序。然后将它们平均分成 K 份，并分别分配给所有终端。这样一来，每个终端只获得了几个类别的训练样本，从而使得终端的数据分布为Non-IID。此外，逻辑回归模型和CNN模型的学习率分别设置为 $\eta_{\text{LR}} = 0.001$ 和 $\eta_{\text{CNN}} = 0.01$ 。

为了比较不同算法的学习性能，在仿真中还实现了基线算法。该算法的广播传输速率与本章所提算法相同，但是带宽平均分配给所有终端。

4.4.2 不同系统带宽下学习性能比较


基于本章的理论分析，本章所提算法可以最小化由不可靠传输导致的总模型偏差，从而加速模型收敛。由于每个终端的本地模型不同，本章采用平均训练准确率和平均测试准确率来评估终端的学习性能。此外，本章绘制了关于训练时间的曲线，以比较所提算法与基线算法在给定训练时间下的学习性能。

4.4.2.1 逻辑回归模型下性能比较


对于逻辑回归模型，不同系统总带宽下平均测试准确率和平均训练准确率与训练时间的关系如图4-4所示。从图中可以看出，本章所提算法在收敛速度方面优于基线算法。具体地，在系统总带宽为80MHz时，给定100分钟的训练时间，所提算法的平均训练准确率和平均测试准确率分别为86.15%和79.29%，而基线算法的平均训练准确率和平均测试准确率分别为80.35%和75.92%。同样地，当系统总带宽为50MHz时，所提算法的平均测试准确率为73.53%，而基线算法仅为67.23%。值得注意的是，基线算法的平均训练准确率在系统总带宽为50MHz时较高。原因如下所述。由于带宽资源稀缺，一些终端可能无法成功接收其他终端的本地模型。此外，由于训练数据量较小，部分本地模型过拟合，导致训练准确率较高，但测试准确率较低。与基线算法相比，本章所提算法的性能增益来自于最佳带宽分配。这样一来，终端能够成功接收更多其他终端的本地模型，并且可以提高收敛速度。此外，带宽资源越稀缺，性能增益越大。当带宽资源足够时，无论使用何种算法，终端都可以成功接收大多数其他终端的本地模型。换句话说，在带宽资源有限的情况下，本章所提算法性能优势明显。

4.4.2.2 CNN模型下性能比较

对于CNN模型，不同系统总带宽下，平均测试准确率和平均训练准确率与训练时间的关系如图4-5所示。此时，系统中有15个终端。可以观察到与逻辑回归模型类似的结果。从图4.5(a)中可以看出，本章所提算法的学习性能优于基线算法，这表明本章所提算法也适用于非凸学习模型。具体地，给定50分钟的训练时间，所提算法在50MHz总带宽和80MHz总带宽下的平均测试准确率分别为68.36%和79.89%，而基线算法的平均测试准确率分别为63.98%和76.31%。然而，平均训练准确率的增益很小。这是因为CNN模型建立了一个复杂的非线性映射，相比逻辑回归模型，CNN模型能够更好地拟合其本地数据样本。因此，所有终端都有较高的训练准确率，这使得不同算法的平均训练准确率非常接近。



(a) 平均测试准确率




(b) 平均训练准确率


图 4-4 对于逻辑回归模型, 不同系统带宽下学习性能与训练时间的关系

4.4.3 不同终端数下学习性能比较

本小节测试了不同终端数下所提算法的学习性能。系统总带宽设置为80MHz。对于逻辑回归模型, 不同终端数下平均测试准确率和平均训练准确率与训练时间的关系如图4-6所示。对于CNN模型, 相应的仿真结果如图4-7所示。正如预期的那样, 本章所提算法比基线算法收敛更快, 学习准确率更高。具体地, 对于逻辑回归模型, 给定100分钟的训练时间, 当终端数量为10时, 所提算法的平均测试准确率和平均训练准确率分别比基线算法高3.37%和5.8%。同样地, 当终端数量为15时, 所提算法的平均测试准确率



(a) 平均测试准确率

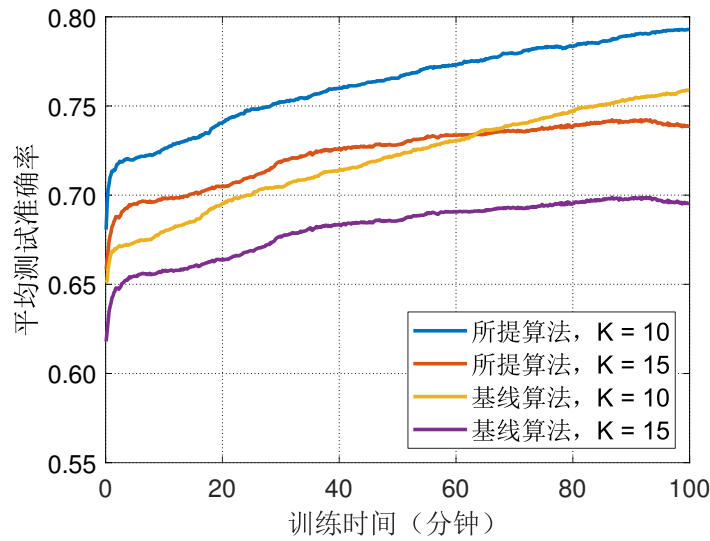


(b) 平均训练准确率


图 4-5 对于CNN模型，不同系统带宽下学习性能与训练时间的关系

比基线算法高4.33%。在这种情况下，由于模型过拟合，基线算法的平均训练准确率较高。第4.4.2节中详细阐述了原因。对于CNN模型，给定50分钟的训练时间，当终端数量为15和20时，所提算法的平均测试准确率分别提高了3.58%和3.35%。由于CNN模型的特性，平均训练准确率的增益很小，原因已经在第4.4.2节中详细阐述。

此外，从图中还能观察到，学习性能随着终端数量的增加而变差。这是两个因素共同作用的结果。一方面，每个终端的本地数据集的大小随着终端数量的增加而减小，这使得终端传输错误对模型收敛的影响减小。另一方面，随着终端数量的增加，每个终端分配到的带宽随之减少。因此，不可靠传输的概率增加，这使得学习性能下降。随着终端数量的



(a) 平均测试准确率



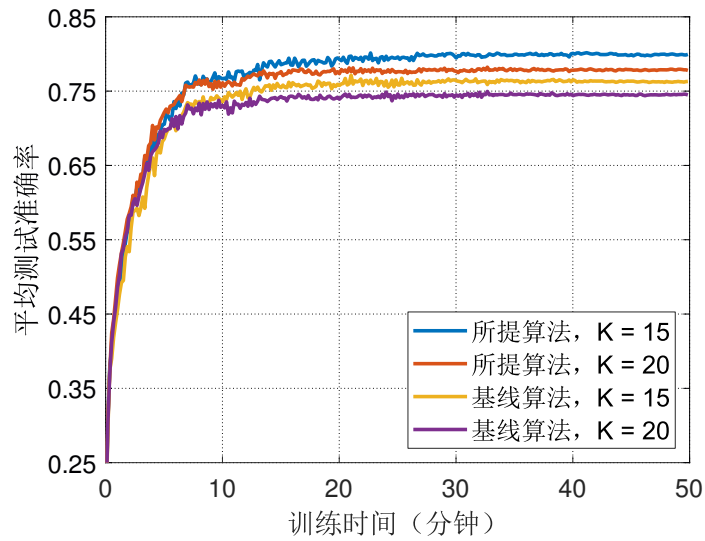
(b) 平均训练准确率

图 4-6 对于逻辑回归模型，不同终端数下学习性能与训练时间的关系


增加，后一因素对模型训练的影响更大，从而使得学习性能下降。

4.5 本章小结

本章主要研究了无线网络中的去中心化边缘学习系统，该系统避免了传统边缘学习系统中可能发生的中心拥塞。本章提出了一种基于不可靠D2D通信的去中心化边缘学习系统，该系统中不可靠传输对学习性能有不利影响。为了加快模型收敛并提高学习效率，在给定时延下，通过联合优化广播传输速率和带宽分配最小化由不可靠传输导致的总模型偏



(a) 平均测试准确率



(b) 平均训练准确率

图 4-7 对于CNN模型，不同终端数下学习性能与训练时间的关系

差。在高SNR场景、带宽充足场景以及大时延场景下，首先导出了最佳广播传输速率，使得所有终端的一轮时延相等。然后，提出了最优带宽分配方案以进一步提高学习性能，该方案使得所有终端的偏差减少速率相等。此外，本章开发了一个协议来实现去中心化边缘学习系统，并提供了所提算法的收敛性分析。最后，通过仿真验证了所提算法与基线算法相比的性能提升。

5 总结与展望

本论文以无线边缘学习为主要研究背景，针对系统的计算和通信瓶颈问题，展开了若干研究，包括联邦边缘学习系统中用户选择和通信资源优化，模型分割边缘学习系统中联合模型参数分配和通信资源分配优化，以及去中心化边缘学习系统中通信资源优化。本论文的主要贡献包括：

1. 针对联邦边缘学习系统中需要传输的模型信息数据量大导致的通信瓶颈问题，本论文提出了一种基于数据重要性和CSI的用户选择策略以及通信资源分配方案。首先，论文分析了损失衰减与模型更新信息之间的关系，并得出了量化数据重要性的指标。为了提高系统的学习性能，论文建立了最大化系统学习效率的目标优化问题，推导出基于数据重要性和CSI的最优用户选择策略以及最优通信资源分配闭式解，并设计了联合用户选择和通信资源分配的多项式时间算法。分析表明，与传统蜂窝网络不同，需要根据终端的数据重要性以及无线信道质量进行用户选择。仿真结果表明，通过该方法可以提高联邦边缘学习系统的学习效率。
2. 针对时变无线信道场景中的模型分割边缘学习系统，本论文提出了一种模型参数分配和带宽分配的联合优化算法。首先，论文分析了最小化系统总时延与分别最小化每轮时延之间的等价性，并基于此建立了最小化每轮时延的目标优化问题。为了解决时变信道场景中未来CSI未知的挑战，推导出了等价的基于MDP的一轮时延最小化问题，并分别设计了给定带宽分配下的最优模型参数分配算法、给定模型参数分配下的次优带宽分配算法以及联合模型参数分配和带宽分配的次优算法。仿真结果表明，在相同准确率需求下，所提算法可以有效减少系统的训练时延。相比已有算法，所提模型参数分配和带宽分配的联合优化算法有较好的性能提升。
3. 针对去中心化边缘学习系统中不可靠D2D通信导致的传输错误影响模型训练性能的问题，本论文提出了一种通信资源分配方案。首先，论文分析了由不可靠传输导致的估计全局模型与真实全局模型之间的模型偏差。为了减弱模型偏差对于模型收敛速率的不利影响，论文建立了给定时延约束下最小化总模型偏差的目标优化问题，

推导出高SNR、大带宽和大时延场景下最优广播传输速率的闭式解以及最优带宽分配的一些有用结论，并基于此设计了最优带宽分配算法。分析结果表明，当所有终端的一轮时延相等时，可以得到最优广播传输速率，最优带宽分配则要求所有终端的偏差减少速率相同。此外，论文开发了一个用于实现去中心化边缘学习系统的协议，并提供了所提算法的收敛性分析。仿真结果表明，所提算法可以有效提高模型的收敛速率以及准确率。

目前，学术界和工业界对于无线边缘学习的研究正如火如荼地开展着，但相关研究尚不完善。本论文选取了几个有代表性的核心技术问题进行了研究，并取得了一些研究成果。然而，随着未来应用需求以及新技术的不断涌现，本论文所涉及的无线边缘学习的其他研究问题仍有待进一步的深化和完善。今后的研究工作主要包括以下几个方面：

1. 更精确的收敛性分析。对于无线边缘学习系统，无线不可靠因素对于系统学习性能的影响可以通过收敛性分析来量化，并基于此优化无线资源分配。大部分已有工作的收敛性分析都基于机器学习模型的损失函数是强凸且利普希茨连续的假设，并且只给出了收敛边界。然而，在实际无线边缘学习系统中，模型的损失函数可能不满足这些假设，比如常用的CNN模型以及其他更复杂的高维模型等，其损失函数往往是非凸的。因此，如何分析具有非凸损失函数模型的收敛性能，并给出精确的收敛值（如模型收敛所需的训练迭代次数等）是具有实际意义的研究课题。
2. 更复杂无线场景中的无线资源分配。尽管很多研究工作已经针对无线边缘学习系统提出了一些创新性的无线资源分配方案，但大多工作都只考虑了比较简单的无线场景，如单小区蜂窝网络、传输可靠以及终端移动性低等。然而，未来的6G系统将会是万物互联的智能平台，这意味着终端具有高移动性，并对系统的时延、传输可靠性以及学习性能都提出了更高的要求。因此，考虑更加实际的无线场景，如多小区系统、终端具有高移动性以及存在区间干扰等，针对无线边缘学习系统设计高效的无线资源分配方案并提高模型的训练性能是值得深入研究的问题。
3. 更全面的机器学习算法应用。目前关于无线边缘学习的研究工作大多基于监督学习算法，比如支持向量机、逻辑回归、神经网络等。随着AI技术的不断发展，强化学习算法的应用范围越来越广，它可以应对动态环境并实现长期利益最大化。这种特性使得强化学习算法非常适用于复杂多变的无线边缘学习系统。因此，针对基于强化学习算法的无线边缘学习系统进行性能分析，并设计相应的无线资源分配方案也是一个值得探索的研究方向。

参考文献

- [1] T. S. Rappaport et al. Millimeter wave mobile communications for 5G cellular: It will work![J]. *IEEE Access*, May 2013. 1:335–349.
- [2] S. Rangan, T. S. Rappaport, E. Erkip. Millimeter-wave cellular wireless networks: Potentials and challenges[J]. *Proceedings of the IEEE*, Mar. 2014. 102(3):366–385.
- [3] E. G. Larsson, O. Edfors, F. Tufvesson, T. L. Marzetta. Massive MIMO for next generation wireless systems[J]. *IEEE Communications Magazine*, Feb. 2014. 52(2):186–195.
- [4] V. Jungnickel, K. Manolakis, W. Zirwas, B. Panzner, V. Braun, M. Lossow, M. Sternad, R. Apelfröjd, T. Svensson. The role of small cells, coordinated multipoint, and massive MIMO in 5G[J]. *IEEE Communications Magazine*, May 2014. 52(5):44–51.
- [5] M. Kamel, W. Hamouda, A. Youssef. Ultra-dense networks: A survey[J]. *IEEE Communications Surveys & Tutorials*, May 2016. 18(4):2522–2545.
- [6] S. Chen, F. Qin, B. Hu, X. Li, Z. Chen. User-centric ultra-dense networks for 5G: Challenges, methodologies, and directions[J]. *IEEE Wireless Communications*, Apr. 2016. 23(2):78–85.
- [7] M. Shafi, A. F. Molisch, P. J. Smith, T. Haustein, P. Zhu, P. D. Silva, F. Tufvesson, A. Benjebbour, G. Wunder. 5G: A tutorial overview of standards, trials, challenges, deployment, and practice[J]. *IEEE Journal on Selected Areas in Communications*, Jun. 2017. 35(6):1201–1221.
- [8] W. Saad, M. Bennis, M. Chen. A vision of 6G wireless systems: Applications, trends, technologies, and open research problems[J]. *IEEE Network*, May 2020. 34(3):134–142.
- [9] IMT-2030推进组. 6G总体愿景与潜在关键技术白皮书[R]. 2021.
- [10] 闫实, 彭木根, 王文博. 通信-感知-计算融合: 6G愿景与关键技术[J]. *北京邮电大学学报*, 2021. 44(4):1–11.
- [11] M. Giordani, M. Polese, M. Mezzavilla, S. Rangan, M. Zorzi. Toward 6G networks: Use cases and technologies[J]. *IEEE Communications Magazine*, Mar. 2020. 58(3):55–61.
- [12] W. Jiang, B. Han, M. A. Habibi, H. D. Schotten. The road towards 6G: A comprehensive survey[J]. *IEEE Open Journal of the Communications Society*, Feb. 2021. 2:334–366.
- [13] G. Zhu, D. Liu, Y. Du, C. You, J. Zhang, K. Huang. Toward an intelligent edge: Wireless communication meets machine learning[J]. *IEEE Communications Magazine*, Jan. 2020. 58(1):19–25.

- [14] K. B. Letaief, Y. Shi, J. Lu, J. Lu. Edge artificial intelligence for 6G: Vision, enabling technologies, and applications[J]. *IEEE Journal on Selected Areas in Communications*, Jan. 2022. 40(1):5–36.
- [15] J. Park, S. Samarakoon, M. Bennis, M. Debbah. Wireless network intelligence at the edge[J]. *Proceedings of the IEEE*, Nov. 2019. 107(11):2204–2239.
- [16] Y. Mao, C. You, J. Zhang, K. Huang, K. B. Letaief. A survey on mobile edge computing: The communication perspective[J]. *IEEE Communications Surveys & Tutorials*, Aug. 2017. 19(4):2322–2358.
- [17] 王志勤, 江甲沫, 刘沛西, 曹晓雯, 李阳, 韩凯峰, 杜滢, 朱光旭. 6G联邦边缘学习新范式: 基于任务导向的资源管理策略[J]. *通信学报*, 2022. 43(6):16–27.
- [18] J. Konečný et al. Federated learning: Strategies for improving communication efficiency[J]. *arXiv preprint arXiv:1610.05492*, 2016.
- [19] B. McMahan, E. Moore, D. Ramage, S. Hampson, B. A. y Arcas. Communication-efficient learning of deep networks from decentralized data[C]//*International Conference on Artificial Intelligence and Statistics*. Apr. 2017:1273–1282.
- [20] M. Li, L. Zhou, Z. Yang, A. Li, F. Xia, D. G. Andersen, A. Smola. Parameter server for distributed machine learning[C]//*Big Learning NIPS Workshop*. Dec. 2013:1–10.
- [21] M. Li, D. G. Andersen, A. J. Smola, K. Yu. Communication efficient distributed machine learning with the parameter server[C]//*Advances in Neural Information Processing Systems*. Dec. 2014:1–9.
- [22] G. Fodor, E. Dahlman, G. Mildh, S. Parkvall, N. Reider, G. Miklós, Z. Turányi. Design aspects of network assisted device-to-device communications[J]. *IEEE Communications Magazine*, Mar. 2012. 50(3):170–177.
- [23] A. Asadi, Q. Wang, V. Mancuso. A survey on device-to-device communication in cellular networks[J]. *IEEE Communications Surveys & Tutorials*, Apr. 2014. 16(4):1801–1819.
- [24] F. Jameel, Z. Hamid, F. Jabeen, S. Zeadally, M. A. Javed. A survey of device-to-device communications: Research issues and challenges[J]. *IEEE Communications Surveys & Tutorials*, Apr. 2018. 20(3):2133–2168.
- [25] N. H. Tran, W. Bao, A. Zomaya, M. N. H. Nguyen, C. S. Hong. Federated learning over wireless networks: Optimization model design and analysis[C]//*IEEE INFOCOM 2019-IEEE Conference on Computer Communications*. Apr. 2019:1387–1395.
- [26] C. T. Dinh, N. H. Tran, M. N. H. Nguyen, C. S. Hong, W. Bao, A. Y. Zomaya, V. Gramoli. Federated learning over wireless networks: Convergence analysis and resource allocation[J]. *IEEE/ACM Transactions on Networking*, Feb. 2021. 29(1):398–409.
- [27] M. M. Amiri, D. Gündüz, S. R. Kulkarni, H. V. Poor. Convergence of federated learning over a noisy downlink[J]. *IEEE Transactions on Wireless Communications*, Mar. 2022. 21(3):1422–1437.
- [28] X. Wei, C. Shen. Federated learning over noisy channels: Convergence analysis and design examples[J].

- IEEE Transactions on Cognitive Communications and Networking, Jun. 2022. 8(2):1253–1268.
- [29] M. Chen, Z. Yang, W. Saad, C. Yin, H. V. Poor, S. Cui. A joint learning and communications framework for federated learning over wireless networks[J]. IEEE Transactions on Wireless Communications, Jan. 2021. 20(1):269–283.
- [30] M. Chen, H. V. Poor, W. Saad, S. Cui. Convergence time optimization for federated learning over wireless networks[J]. IEEE Transactions on Wireless Communications, Apr. 2021. 20(4):2457–2471.
- [31] H. H. Yang, Z. Liu, T. Q. S. Quek, H. V. Poor. Scheduling policies for federated learning in wireless networks[J]. IEEE Transactions on Communications, Jan. 2020. 68(1):317–333.
- [32] T. Nishio, R. Yonetani. Client selection for federated learning with heterogeneous resources in mobile edge[C]//ICC 2019-2019 IEEE International Conference on Communications (ICC). May 2019:1–7.
- [33] H. H. Yang, A. Arafa, T. Q. S. Quek, H. V. Poor. Age-based scheduling policy for federated learning in mobile edge networks[C]//ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Apr. 2020:8743–8747.
- [34] M. M. Wadu, S. Samarakoon, M. Bennis. Joint client scheduling and resource allocation under channel uncertainty in federated learning[J]. IEEE Transactions on Communications, Sep. 2021. 69(9):5962–5974.
- [35] K. Yang, T. Jiang, Y. Shi, Z. Ding. Federated learning via over-the-air computation[J]. IEEE Transactions on Wireless Communications, Mar. 2020. 19(3):2022–2035.
- [36] G. Zhu, Y. Wang, K. Huang. Broadband analog aggregation for low-latency federated edge learning[J]. IEEE Transactions on Wireless Communications, Jan. 2020. 19(1):491–506.
- [37] G. Zhu, Y. Du, D. Gündüz, K. Huang. One-bit over-the-air aggregation for communication-efficient federated edge learning: Design and convergence analysis[J]. IEEE Transactions on Wireless Communications, Mar. 2021. 20(3):2120–2135.
- [38] Y. Sun, S. Zhou, Z. Niu, D. Gündüz. Dynamic scheduling for over-the-air federated edge learning with energy constraints[J]. IEEE Journal on Selected Areas in Communications, Jan. 2022. 40(1):227–242.
- [39] J. Wangni, J. Wang, J. Liu, T. Zhang. Gradient sparsification for communication-efficient distributed optimization[C]//Advances in Neural Information Processing Systems. Dec. 2018:1–11.
- [40] S. Shi et al. A convergence analysis of distributed SGD with communication-efficient gradient sparsification[C]//Proceedings of the 27th International Joint Conference on Artificial Intelligence. Aug. 2019:3411–3417.
- [41] F. Sattler, S. Wiedemann, K. R. Müller, W. Samek. Robust and communication-efficient federated learning from non-iid data[J]. IEEE Transactions on Neural Networks and Learning Systems, Sep. 2020. 31(9):3400–3413.
- [42] D. Alistarh, D. Grubic, J. Li, R. Tomioka, M. Vojnovic. QSGD: Communication-efficient SGD via gradient quantization and encoding[C]//Advances in Neural Information Processing Systems. Dec. 2017:1–12.

- [43] A. Reisizadeh, A. Mokhtari, H. Hassani, A. Jadbabaie, R. Pedarsani. Fedpaq: A communication-efficient federated learning method with periodic averaging and quantization[C]//International Conference on Artificial Intelligence and Statistics. Jul. 2020:2021–2031.
- [44] D. Jhunjhunwala, A. Gadhikar, G. Joshi, Y. C. Eldar. Adaptive quantization of model updates for communication-efficient federated learning[C]//ICASSP 2021-2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Jun. 2021:3110–3114.
- [45] S. Liu, G. Yu, R. Yin, J. Yuan, L. Shen, C. Liu. Joint model pruning and device selection for communication-efficient federated edge learning[J]. IEEE Transactions on Communications, Jan. 2022. 70(1):231–244.
- [46] Y. Jiang, S. Wang, V. Valls, B. J. Ko, W. H. Lee, K. K. Leung, L. Tassiulas. Model pruning enables efficient federated learning on edge devices[J]. IEEE Transactions on Neural Networks and Learning Systems, Apr. 2022:1–13.
- [47] T. Lin, L. Kong, S. U. Stich, M. Jaggi. Ensemble distillation for robust model fusion in federated learning[C]//Advances in Neural Information Processing Systems. Dec. 2020:1–13.
- [48] J. H. Ahn, O. Simeone, J. Kang. Wireless federated distillation for distributed edge learning with heterogeneous data[C]//2019 IEEE 30th Annual International Symposium on Personal, Indoor and Mobile Radio Communications (PIMRC). Sep. 2019:1–6.
- [49] J. Ren, G. Yu, G. Ding. Accelerating DNN training in wireless federated edge learning systems[J]. IEEE Journal on Selected Areas in Communications, Jan. 2021. 39(1):219–232.
- [50] S. J. Wright. Coordinate descent algorithms[J]. Mathematical Programming, Mar. 2015. 151(1):3–34.
- [51] M. Carreira-Perpinan, W. Wang. Distributed optimization of deeply nested systems[C]//Artificial Intelligence and Statistics. Apr. 2014:10–19.
- [52] Z. Zhang, Y. Chen, V. Saligrama. Efficient training of very deep neural networks for supervised hashing[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Jun. 2016:1487–1495.
- [53] Q. Ho, J. Cipar, H. Cui, S. Lee, J. K. Kim, P. B. Gibbons, G. A. Gibson, G. Ganger, E. P. Xing. More effective distributed ml via a stale synchronous parallel parameter server[C]//Advances in Neural Information Processing Systems. Dec. 2013:1–9.
- [54] J. Geng, D. Li, S. Wang. Accelerating distributed machine learning by smart parameter server[C]//Proceedings of the 3rd Asia-Pacific Workshop on Networking 2019. Aug. 2019:92–98.
- [55] S. Wang, A. Pi, X. Zhou, J. Wang, C. Z. Xu. Overlapping communication with computation in parameter server for scalable dl training[J]. IEEE Transactions on Parallel and Distributed Systems, Sep. 2021. 32(9):2144–2159.
- [56] D. Wen, M. Bennis, K. Huang. Joint parameter-and-bandwidth allocation for improving the efficiency of partitioned edge learning[J]. IEEE Transactions on Wireless Communications, Dec. 2020. 19(12):8272–

- 8286.
- [57] D. Wen, K. J. Jeon, M. Bennis, K. Huang. Adaptive subcarrier, parameter, and power allocation for partitioned edge learning over broadband channels[J]. *IEEE Transactions on Wireless Communications*, Dec. 2021. 20(12):8348–8361.
- [58] X. Lian, C. Zhang, H. Zhang, C. Hsieh, W. Zhang, J. Liu. Can decentralized algorithms outperform centralized algorithms? A case study for decentralized parallel stochastic gradient descent[C]//*Advances in Neural Information Processing Systems*. Dec. 2017:1–11.
- [59] H. Tang, X. Lian, M. Yan, C. Zhang, J. Liu. D^2 : Decentralized training over decentralized data[C]//*International Conference on Machine Learning*. Jul. 2018:4848–4856.
- [60] S. Lu, X. Zhang, H. Sun, M. Hong. GNSD: A gradient-tracking based nonconvex stochastic algorithm for decentralized optimization[C]//*2019 IEEE Data Science Workshop (DSW)*. Jun. 2019:315–321.
- [61] R. Xin, S. Kar, U. A. Khan. Gradient tracking and variance reduction for decentralized optimization and machine learning[J]. *arXiv preprint arXiv:2002.05373*, 2020.
- [62] A. Koloskova, N. Loizou, S. Boreiri, M. Jaggi, S. Stich. A unified theory of decentralized sgd with changing topology and local updates[C]//*International Conference on Machine Learning*. Nov. 2020:5381–5393.
- [63] M. Assran, N. Loizou, N. Ballas, M. Rabbat. Stochastic gradient push for distributed deep learning[C]//*International Conference on Machine Learning*. May 2019:344–353.
- [64] A. Koloskova, S. Stich, M. Jaggi. Decentralized stochastic optimization and gossip algorithms with compressed communication[C]//*International Conference on Machine Learning*. Jun. 2019:3478–3487.
- [65] N. Singh, D. Data, J. George, S. Diggavi. Sparq-sgd: Event-triggered and compressed communication in decentralized optimization[J]. *IEEE Transactions on Automatic Control*, Jan. 2022:1–8.
- [66] E. Ozfatura, S. Rini, D. Gündüz. Decentralized SGD with over-the-air computation[C]//*GLOBECOM 2020-2020 IEEE Global Communications Conference*. Dec. 2020:1–6.
- [67] H. Xing, O. Simeone, S. Bi. Decentralized federated learning via SGD over wireless D2D networks[C]//*2020 IEEE 21st International Workshop on Signal Processing Advances in Wireless Communications (SPAWC)*. May 2020:1–5.
- [68] H. Xing, O. Simeone, S. Bi. Federated learning over wireless device-to-device networks: Algorithms and convergence analysis[J]. *IEEE Journal on Selected Areas in Communications*, Dec. 2021. 39(12):3723–3741.
- [69] H. Xu, M. Chen, Z. Meng, Y. Xu, L. Wang, C. Qiao. Decentralized machine learning through experience-driven method in edge networks[J]. *IEEE Journal on Selected Areas in Communications*, Feb. 2022. 40(2):515–531.
- [70] A. Katharopoulos, F. Fleuret. Not all samples are created equal: Deep learning with importance sampling[C]//*International Conference on Machine Learning*. Jul. 2018:2525–2534.

- [71] E. U. T. R. Access. Physical channels and modulation, 3GPP TS 36.211[J]. V10, Jul. 2009. 2.
- [72] Y. Lin, S. Han, H. Mao, Y. Wang, W. J. Dally. Deep gradient compression: Reducing the communication bandwidth for distributed training[J]. arXiv preprint arXiv:1712.01887, 2017.
- [73] J. Ren, G. Yu, Y. Cai, Y. He. Latency optimization for resource allocation in mobile-edge computation offloading[J]. IEEE Transactions on Wireless Communications, Aug. 2018. 17(8):5506–5519.
- [74] T. Chen, G. Giannakis, T. Sun, W. Yin. LAG: Lazily aggregated gradient for communication-efficient distributed learning[C]//Advances in Neural Information Processing Systems. Dec. 2018:1–11.
- [75] M. S. Al-Abiad, M. Obeed, M. Hossain, A. Chaaban, et al. Decentralized aggregation for energy-efficient federated learning via overlapped clustering and D2D communications[J]. arXiv preprint arXiv:2206.02981, 2022.
- [76] A. Choromanska, B. Cowen, S. Kumaravel, R. Luss, M. Rigotti, I. Rish, P. Diachille, V. Gurev, B. Kingsbury, R. Tejwani, et al. Beyond backprop: Online alternating minimization with auxiliary variables[C]//International Conference on Machine Learning. May 2019:1193–1202.
- [77] N. Parikh, S. Boyd, et al. Proximal algorithms[J]. Foundations and Trends® in Optimization, Jan. 2014. 1(3):127–239.
- [78] M. L. Puterman. Markov decision processes[J]. Handbooks in Operations Research and Management Science, 1990. 2:331–434.
- [79] B. Lv, L. Huang, R. Wang. Joint downlink scheduling for file placement and delivery in cache-assisted wireless networks with finite file lifetime[J]. IEEE Transactions on Communications, Jun. 2019. 67(6):4177–4192.
- [80] M. Grant, S. Boyd. CVX: Matlab software for disciplined convex programming, version 2.1, Mar. 2014.
- [81] K. Lang. Newsweeder: Learning to filter netnews. //Machine Learning Proceedings 1995. Elsevier, 1995. 331–339.
- [82] Y. LeCun, Y. Bengio, G. Hinton. Deep learning[J]. Nature, May 2015. 521(7553):436–444.
- [83] D. P. Bertsekas. Nonlinear programming[J]. Journal of the Operational Research Society, Jan. 1997. 48(3):334–334.

附录

A.1 第二章的相关证明

A.1.1 定理2.1的证明

因为固定 T 时优化问题(2.17)是一个凸优化问题，所以可以用拉格朗日方法求得其最优解。拉格朗日函数定义为：

$$L = -\frac{\sum_{k=1}^K a_k \rho_k}{T} + \lambda \left(\sum_{k=1}^K \frac{a_k V}{R_k^U} - T + T^C \right), \quad (\text{A.1})$$

其中， λ 是与式(2.17a)相关的拉格朗日乘子。利用KKT条件和简单的数学计算，可以得到以下充分必要条件：

$$\frac{\partial L}{\partial a_k^*} = -\frac{\rho_k}{T} + \lambda^* \frac{V}{R_k^U} \begin{cases} \geq 0, & a_k^* = 0 \\ = 0, & 0 \leq a_k^* \leq 1, \forall k \in \mathcal{K}, \\ \leq 0, & a_k^* = 1 \end{cases} \quad (\text{A.2})$$

$$\lambda^* \left(\sum_{k=1}^K \frac{V a_k^*}{R_k^U} + T^C - T \right) = 0, \lambda^* \geq 0. \quad (\text{A.3})$$

通过简单的数学计算，可以得到最优用户选择策略，如定理2.1所示。证明完毕。

A.1.2 定理2.2的证明

根据定理2.1，终端按照 $\rho_k R_k^U$ 的降序依次被选择。因此，可以假设当 $k = 1, 2, \dots, M$ 时， $a_k = 1$ ；当 $k = M + 2, M + 3, \dots, K$ 时， $a_k = 0$ ；当 $k = M + 1$ 时， $a_k \in [0, 1]$ 。然后，可以用 $E^{(1)}$ 来表示优化问题(2.17)的目标函数，即

$$E^{(1)} = \frac{\sum_{k=1}^M \rho_k + a_{M+1} \rho_{M+1}}{\sum_{k=1}^M \frac{V}{R_k^U} + a_{M+1} \frac{V}{R_{M+1}^U} + T^C}. \quad (\text{A.4})$$

所以, $E^{(1)}$ 关于 a_{M+1} 求导可得下式:

$$\frac{\partial E^{(1)}}{\partial a_{M+1}} = \frac{\rho_{M+1} \left(\sum_{k=1}^M \frac{V}{R_k^U} + T^C \right) - \frac{V}{R_{M+1}^U} \sum_{k=1}^M \rho_k}{\left(\sum_{k=1}^M \frac{V}{R_k^U} + a_{M+1} \frac{V}{R_{M+1}^U} + T^C \right)^2}. \quad (\text{A.5})$$

可见, 导数的符号与式(A.5)分子的符号一致。然而, 式(A.5)分子的取值与 a_{M+1} 无关。因此, 当 $a_{M+1} \in [0, 1]$ 时, $E^{(1)}$ 是单调的。也就是说, $E^{(1)}$ 的最大值一定在 $a_{M+1} = 0$ 或者 $a_{M+1} = 1$ 处取到。总而言之, 优化问题(2.17)取得最优解时, a_k 一定是整数解。因此, 优化问题(2.17)的最优解一定也是优化问题(2.16)的可行解。又因为松弛之后目标函数的最大值不减, 所以优化问题(2.17)的最优解也是优化问题(2.16)的最优解。证明完毕。

A.1.3 定理2.3的证明

根据定理2.2可知, 优化问题(2.17)的最优解也是优化问题(2.16)的最优解。因此, 这里只需要考虑 a_k 为整数解的情况。当没有终端被选择时, 学习效率显然为零。随着被选择终端数目的增加, 学习效率必然会先增加。换句话说, 在该系统中至少有一个终端被选择。接着, 继续考虑以下情况。

当 M 个终端被选择时, 系统时延表示为 $T_M = \sum_{k=1}^M \frac{V}{R_k^U} + T^C$, $M \in \{1, 2, \dots, K\}$ 。假设以下公式成立:

$$E_M - E_{M-1} = \frac{\rho_M \sum_{k=1}^{M-1} \frac{V}{R_k^U} + T^C \rho_M - \frac{V}{R_M^U} \sum_{k=1}^{M-1} \rho_k}{\left(\sum_{k=1}^M \frac{V}{R_k^U} + T^C \right) \left(\sum_{k=1}^{M-1} \frac{V}{R_k^U} + T^C \right)} > 0, \quad (\text{A.6})$$

$$E_{M+1} - E_M = \frac{\rho_{M+1} \sum_{k=1}^M \frac{V}{R_k^U} + T^C \rho_{M+1} - \frac{V}{R_{M+1}^U} \sum_{k=1}^M \rho_k}{\left(\sum_{k=1}^{M+1} \frac{V}{R_k^U} + T^C \right) \left(\sum_{k=1}^M \frac{V}{R_k^U} + T^C \right)} < 0. \quad (\text{A.7})$$

根据式(A.6)和式(A.7), 可以得到以下不等式:

$$\rho_M R_M^U \left(\sum_{k=1}^{M-1} \frac{V}{R_k^U} + T^C \right) > V \sum_{k=1}^{M-1} \rho_k, \quad (\text{A.8})$$

$$\rho_{M+1} R_{M+1}^U \left(\sum_{k=1}^M \frac{V}{R_k^U} + T^C \right) < V \sum_{k=1}^M \rho_k. \quad (\text{A.9})$$

根据式(A.8), 可以得到以下递推公式:

$$\begin{aligned}
& \rho_{M-1} R_{M-1}^U \left(\sum_{k=1}^{M-2} \frac{V}{R_k^U} + T^C \right) - V \sum_{k=1}^{M-2} \rho_k \\
&= \rho_{M-1} R_{M-1}^U \left(\sum_{k=1}^{M-1} \frac{V}{R_k^U} + T^C \right) - V \sum_{k=1}^{M-1} \rho_k \\
&> \rho_M R_M^U \left(\sum_{k=1}^{M-1} \frac{V}{R_k^U} + T^C \right) - V \sum_{k=1}^{M-1} \rho_k > 0,
\end{aligned} \tag{A.10}$$

即 $E_{M-2} < E_{M-1}$ 。然后可以递推得到:

$$E_1 < E_2 < \cdots < E_M. \tag{A.11}$$

与上述分析类似地, 可以得到以下结论:

$$E_1 < E_2 < \cdots < E_M > E_{M+1} > E_{M+2} > \cdots > E_K. \tag{A.12}$$

基于以上分析可知, E_M 随着 M 的增加先增后减。证明完毕。

A.2 第三章的相关证明

A.2.1 引理3.2的证明

首先, 定义 $\delta_{k,n} = \frac{\hat{L}_{k,n}}{\hat{T} \hat{B}_{k,n} \bar{\gamma}_{k,n}^u}$ 。然后, 约束(3.42a)可以表示为:

$$\delta_{k,n} \left(B_{k,n,q}, \hat{B}_{k,n}, \hat{T} \right) \leq 1, \forall (k, n). \tag{A.13}$$

下面列出两个有用的事实。

- 事实1: $\delta_{k,n} \left(B_{k,n,q}, \hat{B}_{k,n}, \hat{T} \right)$ 是关于阶段3中所有终端的最大时延 \hat{T} 的单调递减函数。
- 事实2: 对于所有终端, $\delta_{k,n} \left(B_{k,n,q}, \hat{B}_{k,n}, \hat{T} \right)$ 是关于阶段3中带宽分配 $\hat{B}_{k,n}$ 的单调递减函数。

基于事实2和式(A.13), 为了最小化可行带宽, 约束(3.42a)应为:

$$\delta_{k,n} \left(B_{k,n,q}, \hat{B}_{k,n}, \hat{T} \right) = 1, \forall (k, n). \tag{A.14}$$

因此, 可以得到以下式子:

$$\sum_{k=1}^K \sum_{n \in \mathcal{G}_k} \delta_{k,n} \left(B_{k,n,q}, \hat{B}_{k,n}, \hat{T} \right) = KN. \tag{A.15}$$

对于 $\hat{T} = T_1$ ，记优化问题(3.43)的最优解为 $\{B_{k,n,q}^{(1)*}\}$ 和 $\{\hat{B}_{k,n,1}^*\}$ 。相应的最小可行带宽为 $B^*(T_1) = \sum_{k=1}^K \sum_{n \in \mathcal{G}_k} \hat{B}_{k,n,1}^*$ 。

接着，对于任意 $T_2 > T_1$ ，根据事实1，可以得到对于所有终端有 $\delta_{k,n} \left(B_{k,n,q}^{(1)*}, \hat{B}_{k,n,1}^*, T_2 \right) < \delta_{k,n}^* \left(B_{k,n,q}^{(1)*}, \hat{B}_{k,n,1}^*, T_1 \right)$ ，并可以进一步得到：

$$\sum_{k=1}^K \sum_{n \in \mathcal{G}_k} \delta_{k,n} \left(B_{k,n,q}^{(1)*}, \hat{B}_{k,n,1}^*, T_2 \right) < \sum_{k=1}^K \sum_{n \in \mathcal{G}_k} \delta_{k,n}^* \left(B_{k,n,q}^{(1)*}, \hat{B}_{k,n,1}^*, T_1 \right) = KN. \quad (\text{A.16})$$

此外，令

$$B_{k,n,q}^{(2)} = B_{k,n,q}^{(1)*}, \quad k = 1, 2, \dots, K, \quad (\text{A.17})$$

$$\hat{B}_{k,n,2} = \hat{B}_{k,n,1}^*, \quad k = 2, 3, \dots, K. \quad (\text{A.18})$$

对于组 \mathcal{G}_1 ，可以得出：

$$\begin{aligned} \sum_{n \in \mathcal{G}_1} \delta_{k,n} \left(B_{1,n,q}^{(2)}, \hat{B}_{1,n,2} \right) &= KN - \sum_{k=2}^K \sum_{n \in \mathcal{G}_k} \delta_{k,n} \left(B_{k,n,q}^{(2)}, \hat{B}_{k,n,2} \right) \\ &> KN - \sum_{k=2}^K \sum_{n \in \mathcal{G}_k} \delta_{k,n}^* \left(B_{k,n,q}^{(1)*}, \hat{B}_{k,n,1}^*, T_1 \right) \\ &= \sum_{n \in \mathcal{G}_1} \delta_{k,n}^* \left(B_{1,n,q}^{(1)*}, \hat{B}_{1,n,1}^*, T_1 \right), \end{aligned} \quad (\text{A.19})$$

其中，两个等式是由式(A.15)得出的，不等式是由式(A.16)，式(A.17)和式(A.18)得出的。根据事实2和式(A.19)，可以得出 $\hat{B}_{1,n,2} < \hat{B}_{1,n,1}^*$ ，从而可以得到 $\sum_{k=1}^K \sum_{n \in \mathcal{G}_k} \hat{B}_{k,n,2} < \sum_{k=1}^K \sum_{n \in \mathcal{G}_k} \hat{B}_{k,n,1}^* = B^*(T_1)$ 。此外，对于 $\hat{T} = T_2$ ，最小可行带宽满足 $B^*(T_2) \leq \sum_{k=1}^K \sum_{n \in \mathcal{G}_k} \hat{B}_{k,n,2}$ 。因此，可以得出：

$$B^*(T_2) < B^*(T_1). \quad (\text{A.20})$$

证明完毕。

A.2.2 引理3.3的证明

优化问题(3.43)的目标函数是凸的。此外，约束(3.41a)是凸的且约束(3.26)是凸集。然后，给定 $\hat{T} = T$ ，根据式(3.40)，约束(3.42a)可以表示为：

$$T \hat{B}_{k,n} \bar{\gamma}_{k,n}^u \geq \max \left\{ L_{k,n,Q_{\text{now}}} - B_{k,n,Q_{\text{now}}} \tilde{\gamma}_{k,n,Q_{\text{now}}} T_C - \sum_{q=Q_{\text{now}}+1}^{Q_{\text{max}}^c} B_{k,n,q} \bar{\gamma}_{k,n}^u T_C, 0 \right\}, \quad \forall (k, n). \quad (\text{A.21})$$

因为求最大值的操作保持凸性，所以式(A.21)是凸的。证明完毕。

A.3 第四章的相关证明

A.3.1 引理4.1的证明

如果优化问题(4.33)的目标函数是凸的, 则优化问题(4.33)是凸问题, 因为式(4.33a)显然是凸集。由于 $\Delta_{k,i}$, 即从终端 k 到终端 i 的不可靠传输导致的终端 i 的模型偏差, 是关于广播传输速率的一元函数, 所以可以通过二阶导数验证其凸性。因为加常数和乘常数的操作不影响凸性, 所以可以只考虑 $\varphi(\hat{R}_k) = -\exp\left(-\frac{N_0}{\sigma_{k,i}^2 P_k} \left(2^{\frac{\hat{R}_k}{B_k}} - 1\right)\right)$ 的二阶导数, 表示为:

$$\frac{d^2\varphi(\hat{R}_k)}{d\hat{R}_k^2} = \frac{(\ln 2)^2 N_0 2^{\frac{\hat{R}_k}{B_k}}}{\sigma_{k,i}^2 P_k B_k^2} \left(\frac{N_0 2^{\frac{\hat{R}_k}{B_k}}}{\sigma_{k,i}^2 P_k} - 1 \right) \varphi(\hat{R}_k). \quad (\text{A.22})$$

根据式(A.22)可以得到, 当 $\frac{d^2\varphi(\hat{R}_k)}{d\hat{R}_k^2} \geq 0$, 即 \hat{R}_k 满足式(4.34)时, $\varphi(\hat{R}_k)$ 是凸函数。在这个条件下, 由于求和操作不影响凸性, 优化问题(4.33)的目标函数也是凸函数。证明完毕。

A.3.2 定理4.1的证明

因为优化问题(4.33)是凸问题, 可以用拉格朗日法来求最优解。拉格朗日函数定义为:

$$L_1 = \frac{1}{K^2} \sum_{i=1}^K \sum_{k=1}^K A_k \left[1 - \exp\left(-\frac{N_0}{\sigma_{k,i}^2 P_k} \left(2^{\frac{\hat{R}_k}{B_k}} - 1\right)\right) \right] + \sum_{k=1}^K \mu_k \left(T_k^{\text{cmp}} + \frac{S}{\hat{R}_k} - T \right), \quad (\text{A.23})$$

其中, μ_k 是与式(4.33a)相关的拉格朗日乘子。利用KKT条件和简单的数学计算, 可以得到以下充分必要条件:

$$\frac{\partial L_1}{\partial \hat{R}_k^*} = \frac{1}{K^2} \sum_{i=1}^K \frac{\ln 2 A_k N_0}{P_k B_k \sigma_{k,i}^2} 2^{\frac{\hat{R}_k^*}{B_k}} \exp\left(-\frac{N_0}{\sigma_{k,i}^2 P_k} \left(2^{\frac{\hat{R}_k^*}{B_k}} - 1\right)\right) - \frac{\mu_k^* S}{(\hat{R}_k^*)^2} = 0, \quad (\text{A.24})$$

$$\mu_k^* \left(T_k^{\text{cmp}} + \frac{S}{\hat{R}_k^*} - T \right) = 0, \quad \mu_k^* \geq 0. \quad (\text{A.25})$$

根据式(A.24), 很容易得到 $\mu_k^* \neq 0$ 。因此, 结合式(A.24)和式(A.25), 可以得到 $T_k^{\text{cmp}} + S/\hat{R}_k^* = T$, 这意味着所有终端的一轮时延必须相等。然后, 可以得到最优广播传输速率如式(4.37)所示。证明完毕。

A.3.3 引理4.2的证明

如果优化问题(4.39)的目标函数是凸的, 则优化问题(4.39)是凸问题, 因为式(4.39a)显然是线性集。由于 $\Delta_{k,i}$ 是关于 B_k 的一元函数, 所以可以通过二阶导数验证其凸性。

记 $\phi(B_k) = -\exp\left(-\frac{N_0}{\sigma_{k,i}^2 P_k} \left(2^{\frac{S}{(T-T_k^{\text{cmp})} B_k}} - 1\right)\right)$ 。因为加常数和乘常数的操作不影响凸性，所以可以只考虑 $\phi(B_k)$ 的二阶导数，表示为：

$$\begin{aligned} \frac{d^2\phi(B_k)}{dB_k^2} &= -\frac{\ln 2 \sigma_{k,i}^2 P_k N_0 S [\ln 2S + 2(T - T_k^{\text{cmp}}) B_k] - (\ln 2)^2 N_0^2 S^2 2^{\frac{S}{(T-T_k^{\text{cmp})} B_k}}}{(T - T_k^{\text{cmp}})^2 \sigma_{k,i}^4 P_k^2 B_k^4} \\ &\quad \times 2^{\frac{S}{(T-T_k^{\text{cmp})} B_k}} \phi(B_k). \end{aligned} \quad (\text{A.26})$$

然后，可以得到当 $\frac{d^2\phi(B_k)}{dB_k^2} \geq 0$ ，即 B_k 满足式(4.40)时， $\phi(B_k)$ 是凸函数。在这个条件下，由于求和操作不影响凸性，优化问题(4.39)的目标函数也是凸函数。

此外，优化问题(4.39)在给定广播传输速率 $\{\hat{R}_k^*\}$ 时得出。结合式(4.34)和式(4.37)，可以得到 B_k 也应该满足式(4.41)。证明完毕。

A.3.4 定理4.2的证明

利用优化问题(4.39)的KKT条件得到定理4.2中的充分必要条件。首先，拉格朗日函数定义为：

$$L_2 = \sum_{i=1}^K \sum_{k=1}^K \Delta_{k,i} + \lambda \left(\sum_{k=1}^K B_k - B \right), \quad (\text{A.27})$$

其中， λ 表示与式(4.39a)相关的拉格朗日乘子。利用KKT条件，可以得到以下充分必要条件：

$$\begin{aligned} \frac{\partial L_2}{\partial B_k} &= \sum_{i=1}^K \frac{\partial \Delta_{k,i}}{\partial B_k} + \lambda \\ &= \lambda - \frac{1}{K^2} \sum_{i=1}^K \frac{\ln 2 A_k N_0 S 2^{\frac{S}{(T-T_k^{\text{cmp})} B_k}}}{P_k (T - T_k^{\text{cmp}}) \sigma_{k,i}^2 B_k^2} \exp\left(-\frac{N_0}{\sigma_{k,i}^2 P_k} \left(2^{\frac{S}{(T-T_k^{\text{cmp})} B_k}} - 1\right)\right) \\ &= 0, \end{aligned} \quad (\text{A.28})$$

$$\lambda \left(\sum_{k=1}^K B_k - B \right) = 0, \quad \lambda \geq 0. \quad (\text{A.29})$$

从式(A.28)可以得出：

$$\begin{cases} \lambda \neq 0, \\ \left| \sum_{i=1}^K \frac{\partial \Delta_{k,i}}{\partial B_k} \right| = C, \quad \forall k, \end{cases} \quad (\text{A.30})$$

其中， $C = \lambda$ 。因为 $\lambda \neq 0$ ，从式(A.29)中可以得出：

$$\sum_{k=1}^K B_k = B. \quad (\text{A.31})$$

基于以上分析，可以得出定理4.2。证明完毕。

A.3.5 定理4.3的证明

本地目标函数是 μ -强凸的，所以以下不等式成立：

$$F_k(\boldsymbol{\omega}_k^{(l+1)}) \geq F_k(\boldsymbol{\omega}_k^{(l)}) + \mathbf{g}_k(\boldsymbol{\omega}_k^{(l)})^\top (\boldsymbol{\omega}_k^{(l+1)} - \boldsymbol{\omega}_k^{(l)}) + \frac{\mu}{2} \left\| \boldsymbol{\omega}_k^{(l+1)} - \boldsymbol{\omega}_k^{(l)} \right\|^2. \quad (\text{A.32})$$

关于 $\boldsymbol{\omega}_k^{(l+1)}$ 最小化式(A.32)的左右两边，可以得到：

$$\min_{\boldsymbol{\omega}_k^{(l+1)}} F_k(\boldsymbol{\omega}_k^{(l+1)}) \geq \min_{\boldsymbol{\omega}_k^{(l+1)}} \left[F_k(\boldsymbol{\omega}_k^{(l)}) + \mathbf{g}_k(\boldsymbol{\omega}_k^{(l)})^\top (\boldsymbol{\omega}_k^{(l+1)} - \boldsymbol{\omega}_k^{(l)}) + \frac{\mu}{2} \left\| \boldsymbol{\omega}_k^{(l+1)} - \boldsymbol{\omega}_k^{(l)} \right\|^2 \right]. \quad (\text{A.33})$$

当 $\boldsymbol{\omega}_k^{(l+1)} = \boldsymbol{\omega}_k^*$ 时，式(A.33)的左边取得最小值。基于假设4.3，可以得到当满足以下公式时⁰，式(A.33)的右边取得最小值：

$$\boldsymbol{\omega}_k^{(l+1)} = \boldsymbol{\omega}_k^{(l)} - \frac{1}{\mu K} \sum_{i=1}^K \mathbf{g}_i(\boldsymbol{\omega}_i^{(l)}). \quad (\text{A.34})$$

因此，可以得到以下不等式：

$$\mu \left(F_k(\boldsymbol{\omega}_k^{(l)}) - F_k(\boldsymbol{\omega}_k^*) \right) \leq \frac{1}{K} \sum_{i=1}^K \mathbf{g}_k(\boldsymbol{\omega}_k^{(l)})^\top \mathbf{g}_i(\boldsymbol{\omega}_i^{(l)}) - \frac{1}{2} \left\| \frac{1}{K} \sum_{i=1}^K \mathbf{g}_i(\boldsymbol{\omega}_i^{(l)}) \right\|^2. \quad (\text{A.35})$$

此外，本地目标函数是利普希茨连续的，所以以下不等式成立：

$$F_k(\boldsymbol{\omega}_k^{(l+1)}) \leq F_k(\boldsymbol{\omega}_k^{(l)}) + \mathbf{g}_k(\boldsymbol{\omega}_k^{(l)})^\top (\boldsymbol{\omega}_k^{(l+1)} - \boldsymbol{\omega}_k^{(l)}) + \frac{L}{2} \left\| \boldsymbol{\omega}_k^{(l+1)} - \boldsymbol{\omega}_k^{(l)} \right\|^2. \quad (\text{A.36})$$

结合式(A.36)和式(A.35)并对公式两边求期望，可以得到：

$$\begin{aligned} & \mathbb{E} \left\{ F_k(\boldsymbol{\omega}_k^{(l+1)}) - F_k(\boldsymbol{\omega}_k^*) \right\} \\ & \leq (1 - \mu\eta^{(l)}) \mathbb{E} \left\{ F_k(\boldsymbol{\omega}_k^{(l)}) - F_k(\boldsymbol{\omega}_k^*) \right\} + \frac{L(\eta^{(l)})^2 - \eta^{(l)}}{2} \mathbb{E} \left\{ \left\| \frac{1}{K} \sum_{i=1}^K \mathbf{g}_i(\boldsymbol{\omega}_i^{(l)}) \right\|^2 \right\} \\ & \stackrel{\text{recursively}}{\leq} \prod_{m=1}^l (1 - \mu\eta^{(m)}) \mathbb{E} \left\{ F_k(\boldsymbol{\omega}_k^{(1)}) - F_k(\boldsymbol{\omega}_k^*) \right\} \\ & \quad + \frac{1}{2} \sum_{m=1}^l \chi^{(m)} [L(\eta^{(m)})^2 - \eta^{(m)}] \mathbb{E} \left\{ \left\| \frac{1}{K} \sum_{i=1}^K \mathbf{g}_i(\boldsymbol{\omega}_i^{(l)}) \right\|^2 \right\}, \end{aligned} \quad (\text{A.37})$$

其中， $\chi^{(m)} = \prod_{j=m+1}^l (1 - \mu\eta^{(j)})$ 。证明完毕。

攻读硕士学位期间的科研成果

已发表/投稿的期刊论文：

- [1] **Z. Jiang**, G. Yu, Y. Cai, Y. Jiang, “Decentralized Edge Learning via Unreliable Device-to-Device Communications,” **IEEE Transactions on Wireless Communications**, vol. 21, no. 11, pp. 9041-9055, Nov. 2022. (对应论文第四章)
- [2] **Z. Jiang**, Y. He, G. Yu, “Joint User Selection and Resource Allocation for Fast Federated Edge Learning,” **ZTE Communications**, vol. 18, no. 2, pp. 20-30, Jun. 2020. (对应论文第二章)
- [3] **Z. Jiang**, D. Wen, S. Liu, G. Zhu, G. Yu, “Adaptive Loading Balancing and Bandwidth Allocation for Partitioned Edge Learning over Fast Fading Channels,” **IEEE Transactions on Communications**, under review, 2022. (对应论文第三章)

已授权的发明专利：

- [1] 江智慧, 余官定, 袁建涛, 刘胜利, 一种面向工业互联网的分布式边缘学习系统和方法：中国, ZL202111240693.8, 2022-08-09. (已授权, 对应论文第四章)