

# 面向边缘智能的空中计算

## Over-the-Air Computation for Edge Intelligence



曹晓雯/CAO Xiaowen<sup>1,2</sup>, 莫小鹏/MO Xiaopeng<sup>1,2</sup>, 许杰/XU Jie<sup>1</sup>

(1. 香港中文大学(深圳), 中国 深圳 440307;

2. 广东工业大学, 中国 广州 510006)

(1. The Chinese University of Hong Kong (Shenzhen), Shenzhen 440307, China;

2. Guangdong University of Technology, Guangzhou 510006, China)

**摘要:**边缘智能模型训练中的无线通信开销已成为系统性能瓶颈,空中计算是解决该问题的重要技术。利用无线多址接入信道的信号叠加特性,空中计算技术能够在多终端无线信号传输的同时,对参数汇总计算,从而实现通信计算一体化设计,降低无线通信开销,提高边缘智能系统性能。通过实例介绍了空中计算的基本原理及其在边缘智能中的应用,并展望了未来研究方向。

**关键词:**边缘智能;空中计算;分布式机器学习;多址接入信道

**Abstract:** The wireless communication overheads in the training of edge intelligence models have become the bottleneck of system performance. Over-the-air computation has emerged as a promising solution to address this issue. By exploiting the signal superposition property of wireless multiple access channels, over-the-air computation implements the aggregation of model parameters in a swift manner, during the concurrent transmission of multiple terminal devices. Via such an integrated communication and computation design, this technique can significantly reduce the wireless communication overhead and improve the AI training performance. Through case analysis, the basic principles of over-the-air computation and its application in edge intelligence are first introduced, and then the future research directions are presented.

**Keywords:** edge intelligence; over-the-air computation; distributed machine learning; multiple access channel

DOI: 10.12142/ZTETJ.202004007

网络出版地址: <https://kns.cnki.net/KCMS/detail/34.1228.TN.20200713.1123.002.html>

网络出版日期: 2020-07-13

收稿日期: 2020-06-08

## 1 边缘智能的概念

随着人工智能和物联网等技术的快速发展,信息技术与通信技术不断融合,通信网络已不再局限于提供数据传输服务,而正逐渐演变为

支撑下一代互联网、智能城市、自动驾驶、工业自动化的核心基础设施。近年来,通信网络支撑的终端设备数目和承载的业务量都急剧增加。据思科预测,到2023年,全球联网设备总数将达到293亿,而从2017—2022年,平均每年全球业务量增长将达到42%<sup>[1]</sup>;因此,未来通信网络需要支持海量设备节点的随时随地接入,并提供超可靠低时延的信息感知、传输、

处理、控制。

在通信网络中融入智能能力,是实现自动驾驶和工业自动化等新型应用的关键。未来的智能通信网络需要根据基站和终端设备所采集的海量数据进行学习和理解,进行智能的推理、规划和决策,并对物理世界进行反馈和执行控制。例如,在自动驾驶场景中,网络将汇总车辆的环境感知信息,并结合超高分辨率地图和实时交通信息,利用人工智能算法进

基金项目:广东省重点领域研发计划项目(2018B030338001)、国家重点研发计划项目(2018YFB1800800)、国家自然科学基金(61871137)、广东省普通高校省级科研项目(2018KZDXM028)、国家重点实验室开发研究基金项目(2019D08)

行智能推理和决策,辅助车辆进行导航路径规划和精准避障驾驶<sup>[2]</sup>。由于海量数据产生于无线网络边缘,为实现快速的智能信息处理和实时控制,人们需要将传统云服务器的计算、存储和智能能力下沉到网络边缘的基站和终端设备;因此,边缘网络智能(或边缘智能)成为大势所趋,并成为未来6G研究的一个重要方向<sup>[3-5]</sup>。与传统单机智能相比,边缘智能能够避免单个终端设备存储计算能力受限问题,打破设备间的数据孤岛;与传统云智能相比,边缘智能能够有效降低网络带宽需求,降低网络时延,保护数据隐私安全。

从技术上看,边缘智能主要包括在无线网络边缘对人工智能或机器学习模型进行分布式的智能训练和智能推理两个过程。其中,机器学习模型的智能训练对数据量和计算量有很高的要求,因此,本文中我们着重讨论机器学习模型的智能训练。在多种不同的分布式模型训练方法中,联邦学习<sup>[6]</sup>在保障用户隐私和数据安全方面具有独特的优势,因此获得了非常广泛的关注。在联邦学习中,海量终端设备利用各自的本地数据,在边缘服务器的协调下,联合训练共同的机器学习模型。联邦学习的训练过程可以基于分布式梯度下降法迭代进行:在每一次迭代中,不同终端设备根据各自的本地数据,更新局部模型参数,并通过无线信道将各自的局部模型参数上传至边缘服务器进行模型汇总,以更新全局模型参数。上述步骤迭代进行,直至全局模型参数收敛。联邦学习能够在终端设备不进行原始数据共享的情况下,充分挖掘边缘网络蕴藏的分布式计算存储能力,进行高效的模型训练。

虽然联邦学习在边缘智能中具

有独特的优势,但是其频繁的模式参数传输汇总过程也带来了技术上的挑战:终端设备和边缘服务器之间的无线通信过程正在成为联邦学习训练速度等性能的瓶颈<sup>[3]</sup>。已有研究工作从不同角度对该问题进行了研究,例如根据网络状态对上传的机器学习模型进行自适应压缩<sup>[7]</sup>、优化局部更新和全局汇总的次数<sup>[8]</sup>,都是降低通信开销的有效方法;然而,已有研究往往采用传统的多址接入方法(如正交频分复用等),需要对各个终端设备的上传的模型参数单独进行解码。当终端设备数目很大以及训练迭代次数很多时,将出现巨大的无线通信资源开销问题,因此,如何从信息理论和通信理论的角度,寻求适用于联邦学习的新型多址接入方式是一个重要的问题。

空中计算是解决上述问题的一种有效技术<sup>[9]</sup>。与传统多址接入方式对多用户数据单独解码、通信计算分离设计不同,空中计算技术可以利用无线链路上行多址接入信道的信号叠加特性,直接在空中进行计算,完成终端数据的快速汇总平均。空中计算技术通过通信和计算的一体化设计,可以有效降低分布式训练过程中的通信开销和时延,提高边缘智能网络和联邦学习的训练效率;因此,基于空中计算的联邦学习,已成为边缘智能的一个重要研究热点。

## 2 空中计算的基本原理

空中计算是指利用无线信号传输过程中的叠加特性,在空中实现对来自不同用户数据的函数计算。以下针对一个典型的多址接入信道,介绍空中计算的基本原理。如图1所示,系统包含 $K$ 个终端设备和一个基站(或边缘服务器),令 $\mathcal{K}$ 表示终端集合。假设每个终端设备 $k$ 的本地信息

为 $X_k$ ,而基站的目标是根据接收到的终端信号对 $\{X_k\}$ 进行计算。为简化讨论,设基站拟计算函数为 $\{X_k\}$ 的平均值,即:

$$\tilde{f} = \frac{1}{K} \left( \sum_{k \in \mathcal{K}} X_k \right)$$

在传统的多址接入方案中,基站对各个设备的数据 $X_k$ 进行分别解码,再汇总平均。与之不同的是,在空中计算中,每个终端设备首先进行归一化操作 $g_k(\cdot)$ ,得到处理后的本地信息为 $x_k \triangleq g_k(X_k)$ ,然后发送信息 $\alpha_k x_k$ ,其中, $\alpha_k$ 表示终端设备 $k$ 的发送系数。边缘服务器在接收到信号后,将直接检测以得到平均值 $f = \frac{1}{K} \sum_{k=1}^K x_k$ ,再通

过去归一化操作 $g_k^{-1}(\cdot)$ 获得有效信息 $\tilde{f} = g_k^{-1}(f)$ ;因此,这部分的难点在于如何有效恢复期望信号 $f$ 。具体而言,令 $h_k$ 表示终端设备 $k$ 到基站的信道参数,则基站接收到的信号为 $y = \sum_{k=1}^K h_k \alpha_k x_k + z$ ,其中 $z$ 为噪声。在接收到该信号后,基站通过降噪处理可以得到信息为 $\hat{f} = \frac{y}{K\sqrt{\eta}}$ ,其中 $\eta$ 为降噪因子。

在系统没有噪声存在的理想情况下,通过设置 $\alpha_k = \frac{h_k^\dagger}{|h_k|^2}$ 以及 $\eta = 1$ ,接收信号直接变为基站的期望信号,即 $\hat{f} = f$ ,其中, $\dagger$ 表示共轭运算;因此,在这种情况下,通过一次传输就可以实现 $K$ 个终端设备数据的平均计算,大大提高系统的频谱利用率,降低传输时延。

在实际的空中计算过程中,系统受到无线信道的衰落特性以及接收机噪声的影响,而终端设备的发送功率也往往有限;因此,如何在实际系统约束下,设计发送信号和接收机算法,是有效恢复期望信号 $f$ 的关键。在无线网络中,空中计算具体有两种实现方式:模拟和数字的空中计算。

对于模拟的空中计算,每个终端设备不需要对感知到的环境数据进行编码,只需要对原始数据进行预处理,紧接着通过无线信道发送到边缘服务器,并进行平均处理<sup>[10-11]</sup>。针对模拟空中计算,一般使用计算失真率作为主要衡量指标,以有效衡量空中计算的链路性能。例如,计算均方误差(MSE)是一种有效衡量空中计算失真的指标,其定义为  $MSE = \mathbb{E}[(\hat{f} - f)^2]$ 。针对单天线加性高斯白噪声信道,本地信息  $\{X_k\}$  独立的场景,计算均方误差可以表示为<sup>[11]</sup>:

$$MSE = \frac{1}{K^2} \mathbb{E} \left[ \left( \sum_{k \in \mathcal{K}} x_k \left( \frac{\sqrt{p_k} |h_k|}{\sqrt{\eta}} - 1 \right) + \frac{z}{\sqrt{\eta}} \right)^2 \right] = \frac{1}{K^2} \left( \sum_{k \in \mathcal{K}} \left( \frac{\sqrt{p_k} |h_k|}{\sqrt{\eta}} - 1 \right)^2 + \frac{\sigma^2}{\eta} \right), \quad (1)$$

公式(1)中,  $\sigma^2$  为噪声功率。在这种情况下,可以利用发送端的自适应功率分配,平衡信号的不对准以及

噪声的影响,有效降低系统均方误差<sup>[11]</sup>。除此之外,为进一步提高空中计算性能,文献[12-14]采用多天线技术,利用多天线的空间复用和阵列增益,联合设计发送端和接收端波束赋形,可以同时实现多模态传感信息的矢量值函数计算,最大程度地降低均方误差。

在实际情况下,噪声会严重损害模拟空中计算的性能,较低的信噪比将导致严重的计算失真。数字空中计算通过终端设备的信源编码,是一种有效抑制噪声的手段<sup>[15-16]</sup>。对于数字空中计算系统,计算速率是有效衡量链路性能的技术指标。计算速率  $R$  定义为当信号失真或解码误差趋向于无穷小情况下,每次信道实现系统能够计算的函数数量,即  $R = \frac{F}{n}$ ,其中,  $F$  为计算的函数数量,  $n$  为信道实现总次数。例如,针对采用格形编码的场景,在加性高斯白噪声信道下,系统的可达计算速率(比特每信道实

现)可以描述为<sup>[15]</sup>:

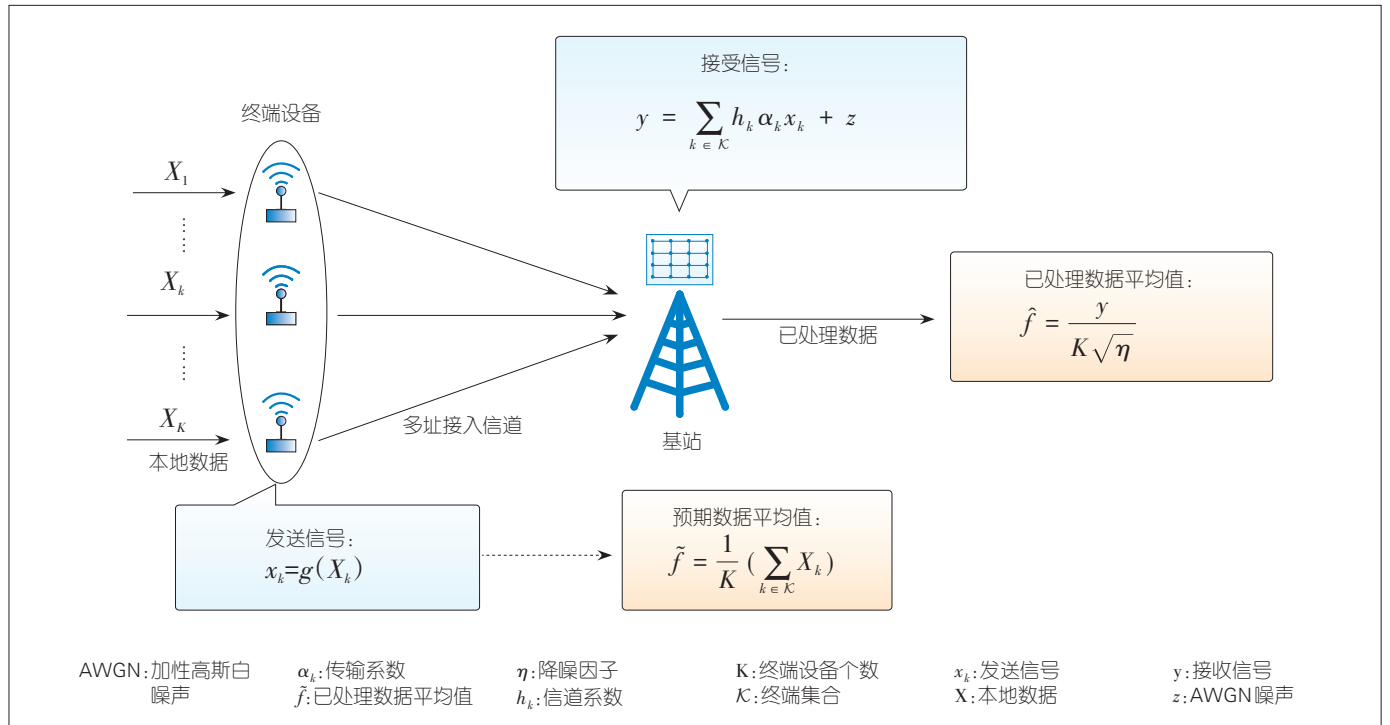
$$R = \left( \log \left( \frac{1}{K} + \min_{k \in \mathcal{K}} \frac{|h_k|^2 p_k}{\sigma^2} \right) \right)^+ \quad (2)$$

公式(2)中,  $(x)^+ = \max(x, 0)$ 。针对不同场景,功率分配、多天线、非正交多址接入技术<sup>[16]</sup>都是提高计算速率的有效手段。

### 3 空中计算驱动的边缘智能

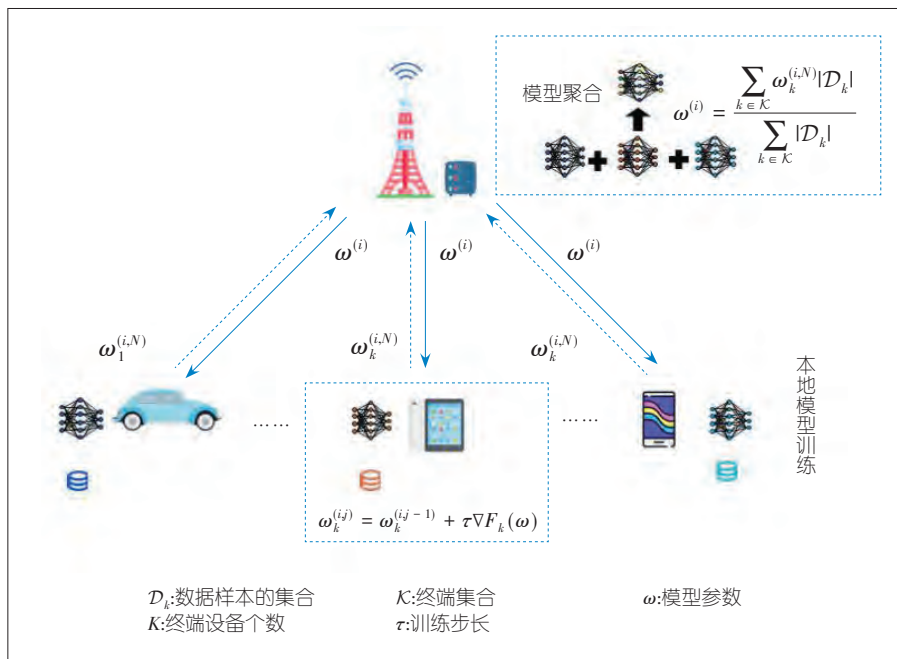
边缘智能是指通过挖掘基站和终端设备散布的数据和通信计算资源,在边缘网络中对人工智能或机器学习模型进行分布式的训练和推演。本节中我们主要关注联邦学习的分布式训练过程<sup>[6]</sup>。如图2所示,系统中的  $K$  个终端设备利用各自的本地数据,在边缘服务器的协调下,联合训练一个共同的机器学习模型。

在该系统中,拟训练的机器学习模型参数表示为  $\omega$ , 每个终端设备  $k \in \mathcal{K}$  的数据样本的集合表示为  $\mathcal{D}_k$ ,



▲图1 空中计算示意图





▲图2 联邦学习示意图

该数据集  $\mathcal{D}_k$  的大小表示为  $|\mathcal{D}_k|$ 。假设  $f_i(\omega)$  是数据样本  $i \in \mathcal{D}_k$  的损失函数。例如,对于线性回归而言,假设每个样本的输入为  $\mathbf{x}_i$ ,经过模型后输出为  $y_i$ ,则对应的损失函数为  $f_i(\omega) = \frac{1}{2} |y_i - \omega^T \mathbf{x}_i|^2$ 。对于支持向量机而言,每个样本的损失函数为  $f_i(\omega) = \frac{\lambda}{2} |\omega|^2 + \frac{1}{2} \max(0, 1 - y_i \omega^T \mathbf{x}_i)^2$ ,  $\lambda$  为常数。相应地,终端设备  $k \in \mathcal{K}$  的本地平均损失函数就可以写为  $F_k(\omega) \triangleq \frac{1}{|\mathcal{D}_k|} \sum_{i \in \mathcal{D}_k} f_i(\omega)$ 。所有  $K$  个终端设备的全球平均损失函数为  $F(\omega) = \frac{\sum_{k=1}^K |\mathcal{D}_k| F_k(\omega)}{\sum_{k=1}^K |\mathcal{D}_k|}$ 。联邦学习的目标是通过批量梯度下降或随机梯度下降等梯度下降<sup>[17]</sup>优化方法,找到期望的模型参数  $\omega$ ,以最小化全局平均损失函数  $F(\omega)$ 。

以分布式批量梯度下降算法为例,该训练过程将迭代进行。假设  $M$  代表边缘服务器的全局模型更新迭

代次数,  $N$  代表终端设备本地模型迭代更新次数。对边缘服务器,  $\omega^{(0)}$  表示的初始全局模型参数,  $\omega^{(i)}$  表示第  $i$  次全局模型更新后的参数;对终端设备  $k$ ,  $\omega_k^{(i,j)}$  表示第  $i$  次全局模型更新中第  $j$  次本地模型更新的本地模型参数。具体而言,第  $i$  次全局模型更新的训练过程按照如下方式进行:

步骤(1):边缘服务器将全局模型参数  $\omega^{(i-1)}$  广播下发至  $K$  个终端设备,同时终端设备的本地模型参数也相应同步设置为  $\omega^{(i-1)}$ ,即  $\omega_k^{(i,0)} = \omega^{(i-1)}$ ;

步骤(2):终端设备以迭代的方式,通过梯度下降的方法最小化本地平均损失函数  $F_k(\omega)$ ,以更新本地模型参数。假设  $\nabla F_k(\omega)$  为本地平均损失函数  $F_k(\omega)$  的梯度,则有  $\omega_k^{(i,j)} = \omega_k^{(i,j-1)} + \tau \nabla F_k(\omega)$ ,其中  $\tau$  为训练步长。该本地更新过程将迭代  $N$  次;

步骤(3):终端设备将更新后的本地模型参数  $\omega_1^{(i,N)}, \dots, \omega_k^{(i,N)}$  通过无线信道上传到边缘服务器;

步骤(4):边缘服务器根据接受

到的本地模型参数,通过加权平均来更新全局模型参数  $\omega^{(i)} = \frac{\sum_{k \in \mathcal{K}} \omega_k^{(i,N)} |\mathcal{D}_k|}{\sum_{k \in \mathcal{K}} |\mathcal{D}_k|}$ 。

经过  $M$  次全局模型迭代更新后,边缘服务器上的全局模型参数  $\omega^{(M)}$  可作为所需的最小化  $F(\omega)$  的解,即  $\omega^* \leftarrow \omega^{(M)}$ 。根据上述优化过程可知,基于传统的多址接入方式,边缘服务器在步骤(3)需要对不同终端的本地模型参数  $\omega_1^{(i,N)}, \dots, \omega_k^{(i,N)}$  进行分别解码,再进行步骤(4)的汇总平均。当终端数目很大的时候,步骤(3)的通信过程将成为系统性能的瓶颈。因此,利用第2节介绍的空中计算计算,将步骤(3)和步骤(4)的通信和计算过程进行一体化设计,将能够很好地提高模型训练的性能。

近年来,利用空中计算进行高效的模型参数传输聚合,已成为解决联邦学习的通信瓶颈的一个研究热门<sup>[18-22]</sup>。文献[18-22]研究了基于(模拟的)空中计算技术的边缘联邦学习,充分利用多址接入信道的信号叠加特性,提高联邦学习的收敛速度和准确度。由于在信息汇总过程中,信道较差的终端上传的模型参数将会产生较大的失真,影响网络整体的模型训练收敛速度。针对此问题,文献[18-22]分别从用户调度和功率控制的角度进行了研究。例如,文献[18]结合用户筛选和接收端波束赋形设计,在满足计算均方误差要求的情况下,最大化参与联邦学习的终端设备数目,以提高模型训练的性能;在功率控制方面,文献[19]针对一个宽带正交频分多址接入系统,提出一种截断功率控制方法,排除遭受深度衰落信道的终端设备,在学习性能和聚合误差之间取得良好的折衷;文献[20]研究了联邦学习中基于梯度统计信息的空中计算功率控制问题,关注衰

落信道下的最优功率控制问题,通过联合设计发射端的功率控制和接收端的降噪处理,最小化计算误差,进而提高收敛速度;此外,针对模拟空中计算中出现的噪声干扰问题,文献[21]研究了联邦学习中由于采用空中计算进行信息汇总出现的迭代噪声问题,依据子空间学习与跟踪技术解决了存在的传输数据缺失情况;文献[22]研究了基于空中计算的联邦学习出现的隐私保护问题,为了防止边缘服务器等聚合中心恶意揣测用户的隐私数据,通过对终端用户的功率进行控制,进而控制接收机接收到的注入到在聚合的全局模型中的噪声干扰,从而实现对保密级别和信噪比之间的最佳权衡。

#### 4 未来研究展望

空中计算驱动的边缘智能具有巨大的应用前景,但其研究还处于初始阶段。例如,如何将数字空中计算与边缘智能进行有效结合?如何建立准确的性能度量体系,刻画空中计算下分布式边缘智能网络的性能极限?这些都还需要研究。除此之外,本节中我们对空中计算驱动的边缘智能的几个未来研究方向进行展望。

##### 1) 分层网络的空中计算

已有工作主要研究单个边缘服务器和多个终端设备协作进行机器学习模型训练的场景。为充分挖掘边缘智能的潜力,需要利用大规模网络中海量终端设备的分布数据进行学习。在这种情况下,单个边缘服务器可能无法满足海量设备连接和计算能力的要求,因此,人们需要设计新的分层网络架构,通过依靠多个边缘服务器甚至云服务器,实现海量节点的分布式数据聚合和模型训练。针对分层网络,空中计算是提高分布式模型训练性能的一种有效手段。

以图3的三层网络为例,每个边缘服务器连接了不同的终端设备,而不同边缘服务器连接到上层服务器进行数据和模型的汇总更新。该三层网络可以通过两跳的空中计算实现大规模终端设备的模型汇总平均:在模型训练过程中,不同终端可以利用第一跳的空中计算,将更新后的局部模型参数上传至中间边缘服务器;边缘服务器则进行第二跳的空中计算,将其部分汇总的模型参数上传至上层服务器,进行全局模型汇总聚合。在这种情况下,如何确定中间边缘服务器的转发策略(基于模拟空中计算的放大转发或基于数字空中计算的解码转发)?如何确保两跳空中计算的时间同步?如何抑制或利用终端设备到不同中间边缘服务器的共道干扰?这些都是值得深入探索的问题。

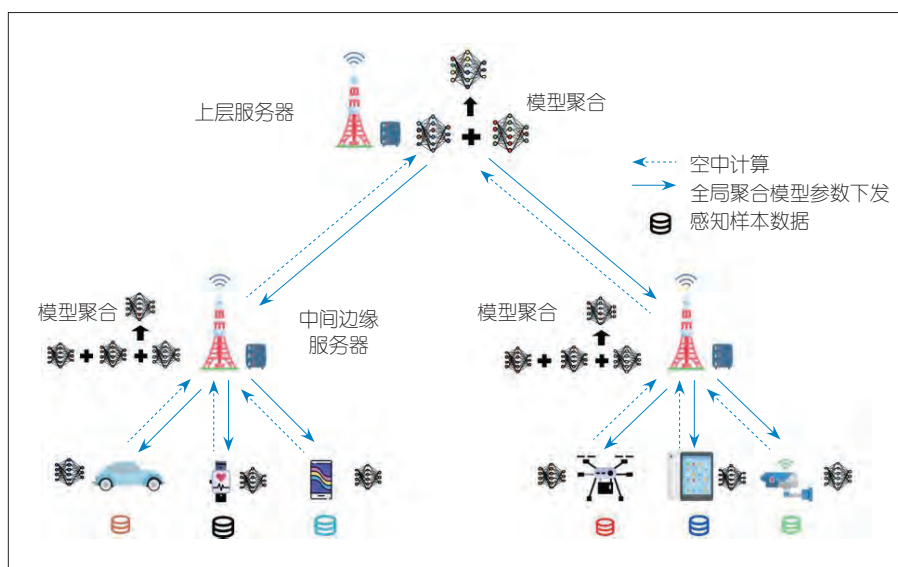
2) 设备间通信辅助的多跳空中计算

未来网络将存在海量终端设备,其中部分设备可能距离边缘服务器较远,这将大大影响空中计算和边缘智能的性能。为解决该问题,可以采用设备间通信技术,利用附近的一些闲置终端设备帮助偏远的设备终端

进行信息汇总。例如,通过在网络中将终端设备划分为多个簇,每个簇具有一个簇头和多个邻近的簇成员。由于相同簇中的终端设备之间距离很近,利用设备间通信能够保证较好的传输性能。如图4所示,簇成员通过将各自信息经由空中计算汇总到簇头端。所有簇头作为一个信息汇总中继节点,将接收到的信息通过空中计算汇总到边缘服务器。如何根据网络规模,设计分簇大小并选择适当的簇头节点?如何基于分簇情况,联合优化通信和计算资源,并设计设备间通信与空中计算技术的融合机制?这些都是未来重要的研究方向。此外,已有研究表明,通过在有限的信任簇群中通过设备间通信传输对数据进行共享,能有效改善分布式机器学习面临的数据非独立同分布问题<sup>[23]</sup>;因此,针对一些需要进行数据共享的边缘智能应用场景,如何有效结合设备间通信以及数据分布重塑增益,提升设备间通信辅助的空中计算性能,也是未来值得研究的方向。

##### 3) 隐私保护

在边缘智能网络中,移动终端训练的模型数据需要通过无线信道发



▲图3 三层网络下的空中计算

送到边缘服务器进行聚合汇总。尽管在联邦学习中,终端设备不需要将其私有数据公开,但其仍然面临隐私泄露的风险。这是由于终端设备上上传的模型参数仍然存在有用信息,边缘服务器(或环境中的窃听器)可以从接收到的每个终端设备发送的信息中恶意地推断出终端设备的私有信息(例如数据的标签等)。空中计算则可以利用无线信道的叠加特性避免这一方面的隐私泄露。当网络中的终端设备将信息发送到空中后,边缘服务器接收到的是所有信息的叠加信号,无法从中推断出具体某一个终端设备的信息,从而避免终端设备的隐私被恶意推测;因此,在这种情况下,如何通过配置最优无线资源分配实现保密性高的空中计算?如何刻画联邦学习训练的收敛性、无线资源优化和隐私保护之间的最优折衷关系?这些都是值得深入探讨的关键问题。

#### 4) 能量效率问题

在未来大规模物联网应用中,终端设备尤其是低功耗物联网节点的能量效率问题,显得至关重要。针对空中计算驱动的边缘智能网络,如何提高系统的能量效率是一个重要的问题。例如,联合优化终端的计算和通信资源分配是一个有效的方案。此外,也可以利用先进的能量技术(如能量采集和无线能量传输等),从能量供给侧提高边缘智能网络的能量效率和成本效益<sup>[24]</sup>。例如,图5给出了一个可持续边缘智能网络的示意图,其中,边缘服务器利用环境中的可再生能源(比如太阳能、风能等)进行供能,而终端设备则利用无线能量传输供能,或利用无线反射通信进行模型上传。由于可再生能源到达具有随机性和间歇性,而无线能量传输效率则取决于发射端的功率和距

离,因此,如何联合优化能量管理和空中计算的无线资源是一个值得深入研究的课题。

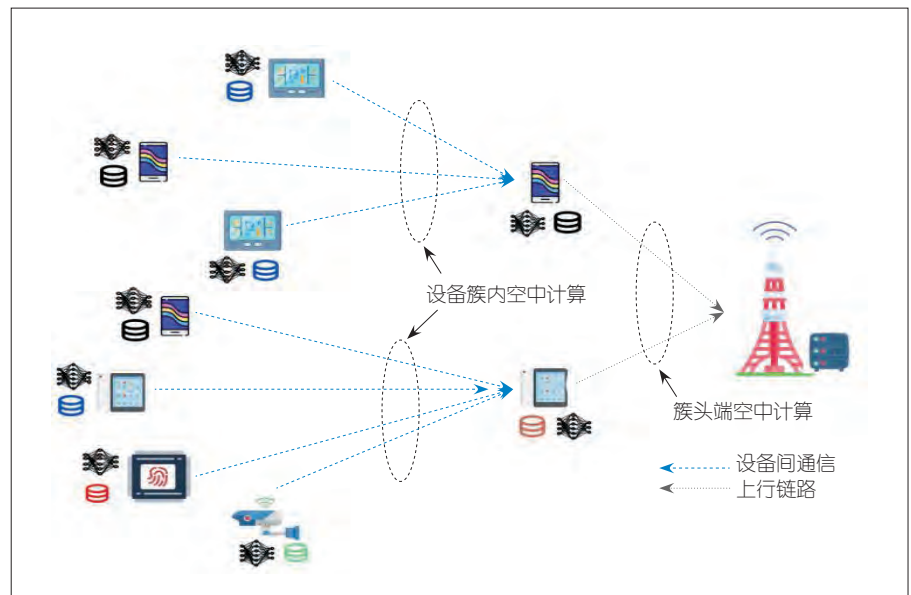
## 5 结束语

空中计算打破了传统无线网络通信计算分离的架构,实现“通信计算一体化”,能有效降低边缘智能网络的通信计算开销,进而提高训练性能。目前,针对空中计算驱动的边缘智能研究尚处于起步阶段。针对分

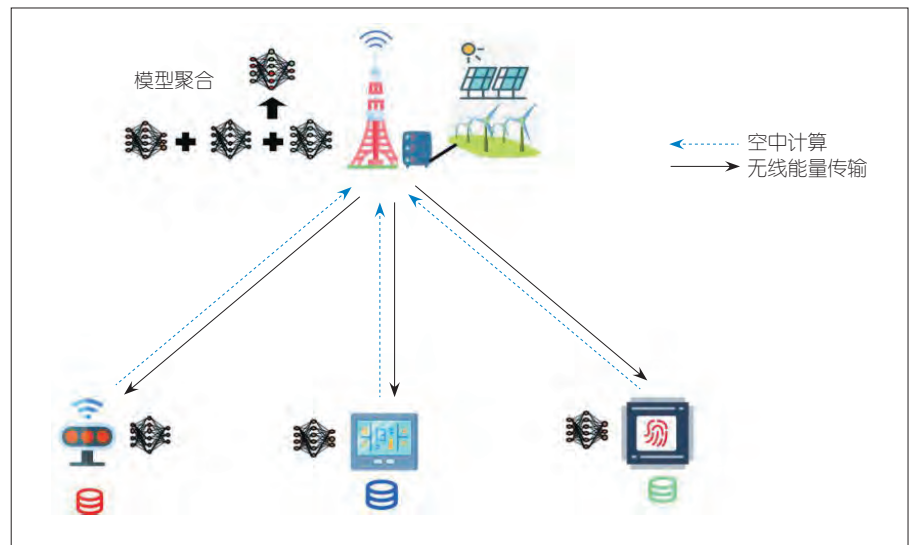
层网络和设备间通信等不同网络架构,考虑隐私保护和能量效率等实际因素,研究先进的空中计算方法,刻画边缘智能的性能极限,是未来研究亟待深入探讨的理论问题。这对推动空中计算走向6G应用具有重要的实际价值。

#### 参考文献

- [1] Cisco. Cisco global cloud index: forecast and methodology, 2016–2021, white paper [EB/OL]. [2020-06-28]. <https://www.cisco.com/c>



▲图4 设备间通信辅助的空中计算



▲图5 可持续边缘智能网络示意图



- en/us/solutions/collateral/service-provider/globalcloud-index-gci/white-paper-c11-738085.html
- [2] LI E, ZENG L K, ZHOU Z, et al. Edge AI: on-demand accelerating deep neural network inference via edge computing [J]. IEEE transaction on wireless communication, 2020, 19(1): 447-457. DOI: 10.1109/TWC.2019.2946140
- [3] ZHU G X, LIU D Z, DU Y Q, et al. Toward an intelligent edge: wireless communication meets machine learning [J]. IEEE communication magazine, 2020, 58(1): 19-25. DOI: 10.1109/MCOM.001.1900103
- [4] LETAIEF K B, CHEN W, SHI Y M, et al. The road-map to 6G: AI empowered wireless networks[J]. IEEE communication magazine, 2019, 57(8): 84-90. DOI: 10.1109/MCOM.2019.1900271
- [5] 未来移动通信论坛. 多视角绘6G蓝图 [EB/OL]. (2019-11)[2020-06-28]. <http://www.future-forum.org/dl/191120/08-%E5%A4%9A%E8%A7%86%E8%A7%92%E7%82%B9%E7%BB%98%E8%93%9D%E5%9B%BE.pdf>
- [6] YANG Q, LIU Y, CHEN T J, et al. Federated machine learning: concept and applications [J]. ACM transaction on intelligent systems, 2019, 10(2): 1-19. DOI: 10.1145/3298981
- [7] DU Y Q, YANG S, HUANG K B. High-dimensional stochastic gradient quantization for communication-efficient edge learning [J]. IEEE transactions on signal processing, 2020, 68: 2128-2142. DOI: 10.1109/TSP.2020.2983166
- [8] WANG S Q, TUOR T, SALONIDIS T, et al. Adaptive federated learning in resource constrained edge computing systems [J]. IEEE journal on selected areas in communications, 2019, 37(6): 1205-1221. DOI: 10.1109/JSAC.2019.2904348
- [9] 陈力, 卫国. 未来无线网络下的空中计算技术 [J]. 中兴通讯技术, 2019, 25(1): 29-34. DOI: 10.12142/ZTETJ.201901005
- [10] GASTPAR M. Uncoded transmission is exactly optimal for a simple Gaussian sensor network [J]. IEEE transaction on information theory, 2008, 54(11): 5247-5251. DOI: 10.1109/TIT.2008.929967
- [11] CAO X W, ZHU G X, XU J, et al. Optimal power control for over-the-air computation in fading channels [EB/OL]. (2010-06-17)[2020-06-28]. <https://arxiv.org/pdf/1906.06858.pdf>
- [12] ZHU G X, HUANG K B. MIMO over-the-air computation for high-mobility multi-modal sensing [J]. IEEE Internet of Things journal, 2019, 6(4): 6089-6103. DOI: 10.1109/JIOT.2018.2871070
- [13] CHEN L, ZHAO N, CHEN Y F, et al. Over-the-air computation for IoT networks: computing multiple functions with antenna arrays [J]. IEEE Internet of Things journal, 2018, 5(6): 5296-5306. DOI: 10.1109/JIOT.2018.2843321
- [14] ZHAI X F, CHEN X H, XU J, et al. Hybrid beamforming for massive MIMO over-the-air computation [EB/OL]. (2019-06-08)[2020-06-28]. <https://arxiv.org/abs/2006.04560>
- [15] JEON S W, JUNG B C. Opportunistic function computation for wireless sensor networks [J]. IEEE transactions on wireless communications, 2016, 15(6): 4045-4059. DOI: 10.1109/TWC.2016.2533379
- [16] WU F Z, CHEN L, ZHAO N, et al. Computation over wide-band multi-access channels: achievable rates through sub-function allocation [J]. IEEE transactions on wireless communications, 2019, 18(7): 3713-3725. DOI: 10.1109/TWC.2019.2918145
- [17] RUDER S. An overview of gradient descent optimization algorithm [EB/OL]. [2020-06-28]. <https://arxiv.org/abs/1609.04747>
- [18] YANG K, JIANG T, SHI Y M, et al. Federated learning via over-the-air computation [J]. IEEE transactions on wireless communications, 2020, 19(3): 2022-2035. DOI: 10.1109/TWC.2019.2961673
- [19] ZHU G X, WANG Y, HUANG K B. Broadband analog aggregation for low-latency federated edge learning [J]. IEEE transactions on wireless communications, 2020, 19(1): 491-506. DOI: 10.1109/TWC.2019.2946245
- [20] ZHANG N F, TAO M X. Gradient statistics aware power control for over-the-air federated learning [EB/OL]. (2020-05-08)[2020-06-28]. <https://arxiv.org/abs/2003.02089>
- [21] NARAYANAMURTHY P, VASWANI N, RAMAMOORTHY A. Federated over-the-air subspace learning from incomplete data [EB/OL]. (2020-06-14)[2020-06-28]. <https://arxiv.org/abs/2002.12873>
- [22] KODA Y, YAMAMOTO K, NISHIO T, et al. Differentially private AirComp federated learning with power adaptation harnessing receiver noise [EB/OL]. (2020-04-14)[2020-06-28]. <https://arxiv.org/abs/2004.06337>
- [23] CAI X R, MO X P, CHEN J Y, et al. D2D-enabled data sharing for distributed machine learning at wireless network edge [J]. IEEE wireless communication letters, 2020, (99): 1-1. DOI: 10.1109/LWC.2020.2993837
- [24] WANG F, XU J, WANG X, et al. Joint offloading and computing optimization in wireless powered mobile-edge computing systems [J]. IEEE transactions on wireless communications. 2018, 17(3): 1784-1797. DOI: 10.1109/TWC.2017.2785305

## 作者简介



曹晓雯, 香港中文大学(深圳)未来智能网络研究院访问学生、广东工业大学在读博士研究生; 主要研究领域为空中计算以及移动边缘计算; 发表期刊和会议论文6篇, 申请专利2项。



莫小鹏, 香港中文大学(深圳)未来智能网络研究院访问学生、广东工业大学在读硕士研究生; 主要研究领域为边缘人工智能以及无人机通信; 发表期刊和会议论文4篇, 申请专利2项。



许杰, 香港中文大学(深圳)理工学院副教授; 主要研究领域为无线能量传输、无人机通信、空中计算和边缘智能等; 先后主持和参加基金项目10余项; 已发表期刊和会议论文百余篇。