

基于联邦学习的车联网多维资源动态分配算法

吴贇寒, 白光伟, 沈航

引用本文

吴贇寒, 白光伟, 沈航. 基于联邦学习的车联网多维资源动态分配算法[J]. 计算机科学, 2022, 49(12): 59-65.

WU Yun-han, BAI Guang-wei, SHEN Hang. Multi-dimensional Resource Dynamic Allocation Algorithm for Internet of Vehicles Based on Federated Learning [J]. Computer Science, 2022, 49(12): 59-65.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[融合XGBoost与SHAP模型的足球运动员身价预测及特征分析方法](#)

Integrating XGBoost and SHAP Model for Football Player Value Prediction and Characteristic Analysis
计算机科学, 2022, 49(12): 195-204. <https://doi.org/10.11896/jsjcx.210600029>

[基于日志信息的不可重复构建原因分类](#)

Classification of Unreproducible Build Causes Based on Log Information
计算机科学, 2022, 49(12): 109-117. <https://doi.org/10.11896/jsjcx.220300227>

[开源社区众包任务的开发者推荐方法](#)

Developer Recommendation Method for Crowdsourcing Tasks in Open Source Community
计算机科学, 2022, 49(12): 99-108. <https://doi.org/10.11896/jsjcx.220400289>

[基于联邦学习的暖通空调系统故障检测与诊断](#)

Fault Detection and Diagnosis of HVAC System Based on Federated Learning
计算机科学, 2022, 49(12): 74-80. <https://doi.org/10.11896/jsjcx.220700280>

[基于联邦学习的Gamma回归算法](#)

FL-GRM:Gamma Regression Algorithm Based on Federated Learning
计算机科学, 2022, 49(12): 66-73. <https://doi.org/10.11896/jsjcx.220600034>

基于联邦学习的车联网多维资源动态分配算法

吴贇寒 白光伟 沈航

南京工业大学计算机科学与技术学院 南京 211816

(Wyh1130@outlook.com)

摘要 考虑到车联网系统中多维资源消耗会随时间波动的特性和用户对高效计算服务以及数据隐私安全的需求,提出了一种基于联邦学习的车联网多维资源分配方法。一方面,综合考虑计算、缓存和带宽资源分配,保证计算任务的完成率,避免多维资源的冗余分配,基于该目标设计了一种深度学习算法,通过边缘服务器收集的数据预测各项资源的消耗量,以此为依据分配多维资源;另一方面,考虑到用户的数据隐私安全需求造成的数据孤岛问题,采用联邦学习架构以获得泛化性较好的神经网络模型。该算法能随时间调整多维资源的分配量,满足随时间变动的资源需求,保证车联网系统中计算任务的高效完成。实验结果表明该算法具有收敛速度快、模型泛化性好等特点,能以较少的通信轮数完成联邦学习的聚合。

关键词: 车辆网络; 联邦学习; 多维资源分配; 计算迁移; 机器学习

中图法分类号 TP393

Multi-dimensional Resource Dynamic Allocation Algorithm for Internet of Vehicles Based on Federated Learning

WU Yun-han, BAI Guang-wei and SHEN Hang

College of Computer Science and Technology, Nanjing Tech University, Nanjing 211816, China

Abstract In consideration of the characteristics of multi-dimensional resource consumption fluctuating with time in the Internet of Vehicles system and users' demands for efficient computing services and data privacy and security, this paper proposes a method of multi-dimensional resource allocation for Internet of Vehicles based on federated learning. On the one hand, the allocation of computing, cache and bandwidth resources is considered comprehensively to ensure the completion rate of computing tasks and avoid the redundant allocation of multidimensional resources. For this purpose, a deep learning algorithm is designed to predict the consumption of various resources through the data collected by edge servers. On the other hand, considering the data island problem caused by users' data privacy and security requirements, federated learning architecture is adopted to obtain a neural network model with better generalization. The proposed algorithm can not only adjust the allocation of multi-dimensional resources over time, but also meet the resource requirements that change over time, and ensure the efficient completion of computing tasks in the Internet of Vehicles system. Experimental results show that the algorithm has the characteristics of fast convergence and good model generalization, and can complete the aggregation of federated learning with fewer communication rounds.

Keywords Vehicle networks, Federated learning, Multi-dimensional resource allocation, Computational migration, Machine learning

1 引言

车联网技术正受到学术界与工业界越来越多的关注。行驶中的车辆作为信息感知对象,借助新一代通信技术实现车与车、车与人、车与路、车与服务平台之间的网络连接。通过接入车联网,道路安全和交通效率得到提高,越来越多的车辆应用和数据服务得以启动。然而,有限的频谱资源、车载计算资

源和缓存资源使得对延迟敏感的应用和服务仍面临许多挑战。

传统的资源分配方式下,各项多维资源的分配是固定的,难以随时间灵活变动。但在车联网系统中,资源需求随时间波动明显,静态的分配方式将导致一些时段内大量资源闲置;另一方面,频繁出现突发的用户请求会导致资源紧缺的情况出现,这会极大地影响用户的使用体验。随着软件定义网络(Software Defined Network, SDN)和网络功能虚拟化技术

到稿日期:2021-10-18 返修日期:2022-03-23

基金项目:国家自然科学基金(61502230);江苏省自然科学基金(BK20201357)

This work was supported by the National Natural Science Foundation of China(61502230) and Natural Science Foundation of Jiangsu Province, China(BK20201357).

通信作者:白光伟(bai@njtech.edu.cn)

(Network Functions Virtualization, NFV) 的发展, 随时间动态分配资源的方式成为可能。在动态的管理方法下, 每经过一段较短的时间就对资源的分配进行调整, 以满足随时间变化的多维资源需求, 避免资源的冗余分配。

近年来, 在边缘计算场景下许多性能优越的资源分配方法被提出。文献[1-2]的研究方案基于精确算法或数学规划的近似算法来求解相应的最优化资源分配问题, 在大数据场景下求解复杂的组合优化问题显得较为困难, 且上述方案难以根据场景的动态变化作出自适应调整。为解决以上问题, 许多基于机器学习方法的资源分配方案被提出, 文献[3]考虑了无人机辅助场景下通过机器学习方法对频谱资源分配进行优化, 使车联网系统内的平均传输延迟最小化, 提高了频谱资源的利用率; 文献[4-7]考虑了网络切片间的带宽资源分配, 利用强化学习方法来提高资源利用率。以上文献仅处理单一资源的分配, 不能完全满足车联网系统中对高效计算服务的需求。文献[8-13]综合考量了多维资源的分配, 通过深度强化学习方法自适应调整多维资源的分配, 以满足各项资源随时间变化的动态需求并保证高效的计算服务。然而在实际应用场景中, 为保证用户数据隐私, 边缘服务器无法获得足以支撑良好机器学习训练的大量高精度数据, 因此文献[14-16]采用联邦学习架构, 在保护用户数据隐私^[17]的前提下进行多方合作训练, 得到一个泛化性良好的全局模型。

综上所述, 现有的研究多专注于车联网系统中某单一资源的最优分配, 少有综合考虑多维资源的统一最优分配; 而另外一些使用机器学习方法对多维资源进行分配的文献中, 单一的训练方为保证用户隐私安全难以获得足够的训练数据, 使最终的模型质量较差, 不适用于实际场景。因此, 本文提出基于联邦学习的多维资源分配算法, 综合考虑计算任务的完成率和多维资源随时间变动的动态需求, 基于长短时记忆神经网络模型(Long Short-Term Memory, LSTM)设计边缘服务器端的深度学习算法, 为车载网络随时间动态分配多维资源; 同时采用联邦学习方法对多个数据提供方的本地模型进行聚合, 以保护用户的数据隐私, 获得质量较好的神经网络模型。

本文第2节基于车联网计算任务的高效服务需求和多维资源的动态需求设计最小化问题; 第3节针对上述优化问题设计基于联邦学习的 LSTM 算法, 保证计算任务的高效完成, 并分配所需的各项多维资源; 第4节设计相关实验, 从多个角度验证本文算法的性能; 最后总结全文并展望未来。

2 问题建模

由于计算任务的异构性和车辆的高机动性^[18-20], 车辆对多维资源的要求随时间变化而变化。控制器需要动态地管理各小基站的可分配资源, 以保证卸载任务的完成率并防止资源的冗余分配。

考虑如图1所示的场景。一个小基站与其覆盖范围下的若干车辆组成一个车辆自组织网络, 若干个这样的车载网络由一个中心控制器连接。小型基站分布在双向道路两侧, 小基站覆盖路段上的车辆随机生成不同的计算任务, 并上传到小基站。

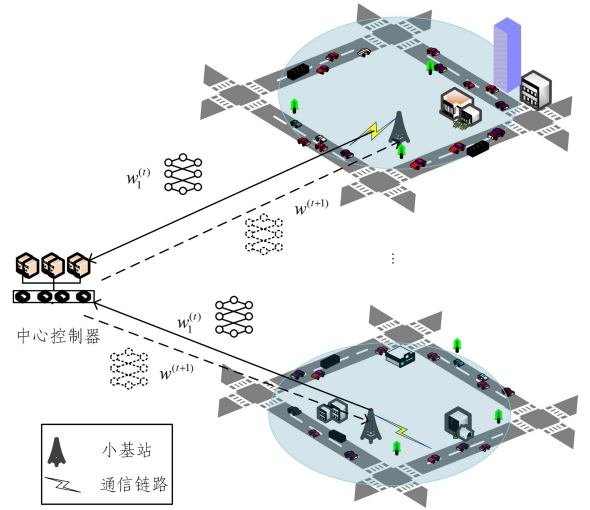


图1 场景模型

Fig. 1 Scenario model

小基站收集覆盖范围内的路况和车辆数据, 并使用这些数据在本地进行机器学习训练, 通过该模型对所需的各项资源量进行预测。由于车联网用户要求数据安全, 因此各小基站间不能交互用户数据, 本地数据不足以完成一个精准高效的模型。中心控制器作为联邦学习的中心节点接收各个本地模型, 聚合得到全局模型后下放到各个小基站。通过该全局模型, 小基站对该时隙内所需的各项多维资源进行预测, 并以此为依据分配多维资源。

将在 t 时隙内处于设想路段的车辆集合表示为 $\mathbb{N}(t)$, 其中共有 $N(t)$ 台车辆。小基站可分配的多维资源表示为 $\{C^{(ca)}, C^{(sp)}, C^{(co)}\}$, 控制器根据机器学习模型为小基站分配多维资源并表示为 $\{C_{m,i}^{(ca)}(t), C_{m,i}^{(sp)}(t), C_{m,i}^{(co)}(t)\}$ 。小基站 m 分配给车辆 i 的多维资源可表示为 $\{c_{m,i}^{(ca)}(t), c_{m,i}^{(sp)}(t), c_{m,i}^{(co)}(t)\}$ 。

设车辆 i 在时隙 t 生成的计算任务表示为 $M_i(t) = \{s_i(t), de_i(t), r_i(t)\}$, 其中 $s_i(t)$ 表示计算 $M_i(t)$ 所需输入的数据大小; $de_i(t)$ 表示完成该计算任务的最大允许时延; $r_i(t)$ 表示完成该计算任务所需的 CPU 周期数, 反映完成该任务所需的计算资源量。

对于每台车辆 i , 在接入小基站 m 时, 当分配给它的缓存资源 $c_{m,i}^{(ca)}(t) \geq s_i(t)$ 时, 该车辆的卸载任务可以完成, 反之则失败。

对于车辆和小基站间的上行链路, 考虑一个一般的路径损耗模型。假设车辆的发射功率固定为 P , 发射信号的功率衰减速度为 $\sqrt{d_{m,i}^2 + h_m^2}^{-\gamma}$, $d_{m,i}$ 为车辆和小基站间的水平距离, h_m 为小基站高度, γ 为路径损耗指数。小基站 m 分配至车辆 i 的带宽资源量为 $c_{m,i}^{(sp)}(t)$ 。根据香农公式, 车辆向小基站卸载任务时的上行传输速率为:

$$e_{m,i}(t) = c_{m,i}^{(sp)}(t) \log_2 \left(1 + \frac{PG_{m,i}(t)}{\sigma^2} \right) \quad (1)$$

其中, $G_{m,i}(t) = 10^{-\frac{\sqrt{d_{m,i}^2 + h_m^2} \gamma}{10}}$ 表示时隙 t 内车辆到小基站的上行通道增益, σ^2 为接收到的背景噪声。

根据式(3)可计算出卸载任务从车辆上传至小基站所用的时间为:

$$T_i^{up}(t) = \frac{s_i(t)}{e_{m,i}(t)} \quad (2)$$

在任务成功上传后,小基站为该计算任务分配相应的计算资源并开始进行计算。任务的计算时间为计算该任务所需的CPU周期数除以该任务在小基站处的CPU占比。卸载任务从上传到完成的时间记为 $T_i(t)$ 。 $T_i(t)$ 由3个部分构成,分别是任务的上传时间、在小基站处的计算时间和最终计算结果的回传时间。相较于前两者,计算结果的回传时间可忽略不计,故卸载任务的完成时间可表示为任务的上传时间与计算时间之和。

$$T_i(t) = T_i^{up}(t) + \frac{r_i(t)}{C_{m,i}^{(ca)}(t)} \quad (3)$$

当 $T_i(t) \leq de_i(t)$ 时,车辆 i 的卸载任务成功,反之失败。

设 λ 为在时隙 t 间的卸载任务完成率,其定义如下:

$$\lambda = \frac{\sum_{i \in \mathcal{N}(t)} H(C_{m,i}^{(ca)} - s_i(t)) H(de_i(t) - T_i(t))}{N(t)} \quad (4)$$

其中, $H(\cdot)$ 为跃阶函数,当变量大于0时,其值为1,否则为0。

控制器为小基站分配的多维资源应使卸载任务的完成率高于一定阈值 δ ,即:

$$\lambda \geq \delta \quad (5)$$

本文的优化目标为在保证卸载任务完成率的前提下,最小化小基站使用的各项多维资源,优化目标如下:

$$\min \alpha C_m^{(ca)}(t) + \beta C_m^{(sp)}(t) + \varphi C_m^{(co)}(t) \quad (6)$$

s. t. (5)

其中, α, β, φ 为常数,可根据小基站处多维资源的稀缺程度进行调整。 α, β, φ 可取一段时间内该小基站覆盖范围内因缓存、带宽和计算资源不足而未能完成的任务数分别除以总任务数的值。

目标优化问题的计算复杂度随覆盖区域内车辆数量的增多而提高,因此使用传统的优化方法求解上述问题较为困难。小基站处可收集大量的相关数据以及对应的所消耗的多维资源量数据,这就满足了使用机器学习技术的基本条件。使用小基站收集的相关数据进行神经网络模型的训练,当模型训练完成后,将 t 时隙的相关数据输入该模型即可得到该时隙所需的多维资源量。因此可对原优化问题作出如下转化:

设 $\bar{C}^{(ca)}, \bar{C}^{(sp)}, \bar{C}^{(co)}$ 为式(6)所使用的最小各项资源量,则式(6)可转换为以下问题:

$$\min \sqrt{\alpha (C_m^{(ca)} - \bar{C}^{(ca)})^2 + \beta (C_m^{(sp)} - \bar{C}^{(sp)})^2 + \varphi (C_m^{(co)} - \bar{C}^{(co)})^2} \quad (7)$$

$$\text{s. t. } C_m^{(ca)} \geq \bar{C}^{(ca)} \quad (8)$$

$$C_m^{(sp)} \geq \bar{C}^{(sp)} \quad (9)$$

$$C_m^{(co)} \geq \bar{C}^{(co)} \quad (10)$$

由于无法直接观测得到卸载任务的完成率,故将约束调整为式(8)~式(10)。

由于各项多维资源在数值表示上差异极大,故对式(7)作出如下转化:

$$\min \sqrt{\alpha \left(\frac{C_m^{(ca)} - \bar{C}^{(ca)}}{\bar{C}^{(ca)}} \right)^2 + \beta \left(\frac{C_m^{(sp)} - \bar{C}^{(sp)}}{\bar{C}^{(sp)}} \right)^2 + \varphi \left(\frac{C_m^{(co)} - \bar{C}^{(co)}}{\bar{C}^{(co)}} \right)^2} \quad (11)$$

s. t. (8)~(10)

针对以上优化问题,本文使用LSTM算法在小基站处训练各自的本地机器学习模型。机器学习模型的质量与训练数据的数量和质量正相关,当训练数据量不足时往往不能得到一个精确的模型。出于对用户数据隐私的保护,小基站收集的车辆相关数据不能直接上传到控制器。因此本文使用联邦学习方法,将控制器作为联邦学习的中心节点来收集小基站传输的模型数据进行聚合,从而获得性能良好的全局模型。小基站收到全局模型后收集本地车辆和任务数据作为输入,按模型输出结果对所需多维资源进行分配。

3 基于联邦学习的 LSTM 资源分配算法

本文使用的联邦学习架构为横向联邦学习架构,本质上是一种分布式机器学习架构,以实现样本的联合,其目标是在保证数据隐私安全的基础上实现多方共同建模。共同建模的参与方,在本文中即为各边缘服务器,其覆盖范围内的车辆用户数据保存在本地,相互间不进行数据交互,仅使用该范围内的数据进行本地模型的训练。在共同建模,即联邦学习的聚合过程中,参与方将训练完成的模型或梯度上传至中心节点,而非在传统机器学习下将原始数据上传至中心节点。通过上述方式,联邦学习的参与方规避了数据泄露的风险,并提升了模型质量。更进一步的,对于恶意攻击,参与方与中心节点可使用安全多方计算协议等方式进行防御。根据文献[21],联邦学习架构对常见的攻击方式,如生成式对抗网络攻击等都具有很好的防御效果。

本节首先设计小基站用于预测多维资源消耗量的本地神经网络模型,然后采用联邦平均算法作为聚合方式,提出基于联邦平均的LSTM算法(Federated Averaging LSTM),简称FAL算法。由于联邦平均方法存在随着参与方不断增多而收敛变慢、模型精度降低的问题,因此提出基于联邦匹配平均的LSTM算法(Federated LSTM with Matched Averaging),简称FML算法。FML算法的模型精度更高,且参与方的增多对该算法有正向影响,但聚合过程中频繁的匹配操作会消耗中心节点处大量的计算资源,当中心节点具有足够的处理能力时,为提高模型的精度,FML算法是更优的选择。

本文提出的算法在避免泄露用户数据的前提下使用多个隔离车载网络的数据,准确预测车载网络所需的多维资源量,小基站通过该模型为下一时刻分配各项资源,保证车辆计算任务的完成率并避免资源的冗余分配。

3.1 本地 LSTM 算法

由于车辆的高移动性以及计算任务的突发性,小基站对资源的需求随时间和空间波动较大,采集的数据和时间关联度较高,长短时记忆神经网络在处理此类学习任务时具有明显优势。本节简单介绍LSTM算法[22]。

LSTM是一种特殊的循环神经网络(Recurrent Neural Network, RNN),相比普通的RNN,它能有效解决训练过程中的长期依赖问题。LSTM的细胞结构如图2所示。LSTM有两个不同的传递状态, h_t 为当前节点的短时状态,经过映射矩阵后可得到当前时刻的输出,不同节点间往往区别较大; C_t 用于保存长时间信息,变化很慢。LSTM的细胞结构中有多

个门控单元和对应的神经网络,通过这些门控单元,LSTM将信息删除或添加到两个状态中。神经网络的输入 x 为车辆采集的各类信息以及小基站处收集的路况信息等归一化处理后的一维向量,其输出 y 是一个列向量,分别对应各项多维资源。




图2 LSTM结构

Fig. 2 LSTM structure

为避免多维资源数值上的差异对预测精度造成的影响,将每项数值都统一到(0,1)之间;为各项资源都设定一个标准值,记为 $\{C_0^{(ca)}, C_0^{(sp)}, C_0^{(co)}\}$;模型的输出 $y = \left(\frac{C_m^{(ca)}}{C_0^{(ca)}}, \frac{C_m^{(sp)}}{C_0^{(sp)}}, \frac{C_m^{(co)}}{C_0^{(co)}}\right)^T$,记 $\hat{y}^{(i)}$ 为模型在第 i 个输入上的输出, n 是训练样本的数目。模型的损失函数如下:

$$L(\theta) = \frac{1}{n} \sum_i \sqrt{(\hat{y}^{(i)} - y^{(i)})^2} \quad (12)$$

若数据集 $D = \bigcup_{m=1}^M D_m$ 控制器能全部获得,则可采用传统集中式机器学习方法进行训练。但在车联网系统中,出于对用户隐私安全的保护,各小基站的数据集 D_m 间相互独立,且控制器无法获得。因此,通过联邦学习框架,小基站各自训练本地模型 w_m ,而后将该模型上传至控制器进行聚合。

3.2 FAL 算法

联邦平均算法(FedAvg)因计算简单,性能损失较小而成为当前应用最广泛的联邦学习聚合方法。该算法在聚合阶段将参与方的本地模型根据数据集的大小进行简单加权平均后得到全局模型。本节使用 LSTM 算法作为本地训练算法,使用 FedAvg 作为聚合方式,提出 FAL 算法,以保护用户的数据隐私,获得性能更优秀的全局模型,其流程如算法 1 所示。

算法 1 FAL 算法

1. 控制器初始化全局模型 $\mathbf{W}^{(0)}$ 并下发至各小基站
2. for $1, 2, \dots, n$ do
3. for $1, 2, \dots, m$ do
4. 小基站 m 接收全局模型 $\mathbf{W}^{(n-1)}$
5. 更新本地模型,进行新一轮本地训练直到模型收敛 $\mathbf{W}_m^{(n)} = \mathbf{W}^{(n-1)} + \Delta \mathbf{W}_m^{(n)}$
6. end for
7. 控制器接收本地模型,更新全局模型 $\mathbf{W}^{(n)} = \frac{\sum_{m=1}^M D_m}{D} \mathbf{W}_m^{(n)}$,将更新后的本地模型参数发送给控制器方
8. end for

联邦平均算法聚合过程本质上是对相同位置的神经元权重进行合并。该方法在聚合过程中无法保证持续对全局模型施加正向影响,证明如下。

一个基础的两层全连接神经网络可表示为以下形式:

$$\hat{y} = \sigma(x \mathbf{W}_1) \mathbf{W}_2 \quad (13)$$

对式(13)进行拓展,得到式(14):

$$\hat{y} = \sum_{i=1}^L \mathbf{W}_{2,i} \cdot \sigma(\langle x, \mathbf{W}_{1,i} \rangle) \quad (14)$$

其中 $i \cdot$ 和 $\cdot i$ 分别表示行和列; L 为隐藏单元的个数,即神经元的个数。

求和是一种置换不变的运算,因此对于任意的 $\{\mathbf{W}_1, \mathbf{W}_2\}$, 都有 L 种等价的置换操作。因此,式(14)与式(15)是等价的。

$$\hat{y} = \sigma(x \mathbf{W}_1 \mathbf{\Pi} \mathbf{\Pi}^T \mathbf{W}_2) \quad (15)$$

其中, $\mathbf{\Pi}$ 是一个 $L \times L$ 的置换矩阵,当其在矩阵左侧时表示对行进行置换操作,在右侧时表示对列进行置换操作。

假设 $\{\mathbf{W}_1, \mathbf{W}_2\}$ 为某神经网络的最优权重,在两个同质数据集 X_i 和 X_j 上训练得到的权重分别为 $\{\mathbf{W}_1 \mathbf{\Pi}_i, \mathbf{\Pi}_i^T \mathbf{W}_2\}$ 和 $\{\mathbf{W}_1 \mathbf{\Pi}_j, \mathbf{\Pi}_j^T \mathbf{W}_2\}$ 。两种排列方式大概率上是不同的,即 $\mathbf{\Pi}_i \neq \mathbf{\Pi}_j$ 。若按 FedAvg 方法对两权重进行聚合,显然不存在 $\mathbf{\Pi}$ 使下式成立。

$$(\mathbf{W}_1 \mathbf{\Pi}_i + \mathbf{W}_1 \mathbf{\Pi}_j) = \mathbf{W}_1 \mathbf{\Pi} \quad (16)$$

随着聚合的不断进行,全局模型会逐步累积不可知的误差,偏离最优模型。由于该问题的存在,当系统内的参与方不断增加时,算法的性能将受到明显的影响。

3.3 FML 算法

为解决 FAL 算法中的问题,需要对聚合过程进行优化,以减少聚合过程中产生的误差。因此,本节通过联邦匹配平均方式进行模型的聚合,从而解决 FAL 算法中的问题,提出了基于联邦匹配平均的 LSTM 算法,简称 FML 算法。

联邦匹配平均是利用求和运算中神经元的置换不变性将神经网络重新排列,使聚合过程中的误差减少的一种聚合方式。接下来将对其进行简单的介绍。

在单隐藏层的神经网络中,FedMA 可表现为图 3 所示的形式。




图3 联邦匹配平均过程

Fig. 3 Federated matching average process

如图 3 所示,该方法将具有相似特征的神经元进行合并,减少了聚合过程中的性能损失。

将上述方法拓展到多隐藏层的神经网络中,对每个隐藏层的神经元进行重排列,使特征相近的神经元位于权重矩阵中的相同位置,然后进行加权平均后得到最终的全局模型。

通过上述方法得到的聚合方案即为联邦匹配平均算法(FedMA)。

将 LSTM 内部的深度神经网络中的相邻两层表示为式(13)所示的形式,逐层对所有本地模型进行排列并聚合。

设 $w_{m,l}$ 为在数据集 D_m 上训练得到的第 l 个神经元, θ_i 表示在全局模型中的第 i 个神经元, $c(\cdot, \cdot)$ 是一对神经元之间的相似函数。以下优化问题的解决方案即为匹配平均算法所需的排列:

$$\min_{(\pi_{li}^m)} \sum_{i=1}^l \sum_{m,l} \min \pi_{li}^m c(w_{m,l}, \theta_i) \quad (17)$$

$$\text{s. t. } \sum_i \pi_{li}^m = 1, \forall m, l \quad (18)$$

$$\sum_l \pi_{li}^m = 1, \forall m, i \quad (19)$$

对式(17)使用二分图匹配法进行求解^[18], 组合得到排列矩阵 $\Pi_{m,l}^T = \pi_{li}^m$ 。

LSTM 中有多个隐藏状态和对应的权重矩阵, 这导致每次聚合都会消耗大量的计算资源用于计算排列矩阵, 这在边缘计算场景下是不合理的。因此, 需要对聚合过程进行优化。设权重矩阵为一个共有 L 层的深度全连接神经网络, 每次聚合时, 对当前层神经元进行匹配平均, 获得全局模型的当前层神经元并将其固定后再下发到小基站, 小基站仅更新固定层之后的权重参数, 算法整体流程如算法 2 所示。

算法 2 FML 算法

1. 在控制器端执行:
2. 初始化全局堆叠权重矩阵, 并下发到小基站。
3. while $l \leq L$ do
4. if $l < L$ then
5. 求解式(13)得 $(\Pi_m)^M_{m=1}$, 对本地权重矩阵进行再排列。
6. 更新全局模型的第 l 层,
7. $W_l = \frac{1}{M} \sum_{m=1}^M \frac{D_m}{D} W_{m,l} \Pi_m^T$
8. if $l = L$
9. 按数据集大小进行加权平均, 更新最后一层权重参数, $W_l = \frac{1}{M} \sum_{m=1}^M \frac{D_m}{D} W_{m,l}$
10. end while
11. 在小基站处执行:
12. for $1, 2, \dots, M$ do
13. 为保证求和不变, 重排列下一层的权重矩阵 $W_{m,l+1} = \Pi_m W_{m,l+1}$
14. 本地固定 $W_{m,l}$, 训练 $\{W_{m,l+1}, \dots, W_{m,G}\}$ 直到训练周期完成或模型收敛
15. 本地训练完成后将权重矩阵发送至控制器
17. end for

该算法简化了联邦匹配平均的聚合过程, 将通信轮数限制为深度神经网络的层数, 提高了通信效率并减少了中心控制器处计算资源的消耗。尽管较原来的匹配平均过程更简单, 但与 FAL 算法相比, 该算法仍会消耗中心节点较多的计算资源。

4 仿真实验与性能分析

4.1 实验设计

本节通过一系列的仿真实验深入分析基于 FML/FAL 算法的资源分配算法的性能, 由于数据隐私安全问题不是本文研究的主要关注点, 因此我们没有在实验中对数据安全进行验证。模拟的车联网场景如图 1 所示, 并由此获得相应数据。在 $1 \text{ km} \times 1 \text{ km}$ 的场景中, 均匀分布共 20 个小基站, 每个

小基站的覆盖范围为 50 m^2 。车辆在该场景下匀速行驶, 并周期性地生成不同复杂程度的计算任务。下面介绍具体的实验参数并分析实验结果。表 1 列出了实验中的其他重要参数的取值。

表 1 仿真参数

Table 1 Experimental parameters	
参数	值
总可用带宽/MHz	40
小基站计算资源/(Gb/s)	6
小基站缓存资源/kbits	50
小基站覆盖范围/ m^2	50
背景噪声功率/dB	-174
车辆发射功率/W	1
计算任务所需的 CPU 周期数/M	[0,10]次
车辆上传信息大小/kbits	[0,10]
任务完成时延/ms	[10,50]

4.2 实验结果分析

4.2.1 通信轮次

为客观地评估所提算法的性能, 将其与集中式机器学习方式进行对比。集中式的机器学习算法无须频繁地与边缘服务器进行通信即可获得准确率较高的模型, 但由于车联网系统对用户隐私安全的保护, 集中式算法难以获取系统中不同小基站范围内的用户数据, 因此, 这里将集中式算法的性能作为本文提出的两种算法的性能对照指标。

在联邦学习架构中, 达到所需精度需要的通信轮次越少, 意味着全局模型收敛速度越快。另外, 在车联网系统的无线网络环境中, 通信轮次越多则消耗的通信资源越多, 且由于无线传输的不稳定性, 模型数据的丢失或缺损将导致全局模型的收敛变得困难。因此, 在车联网系统中, 以较少的通信轮次达成较高的预测准确率是系统性能优秀的表现。

本节实验对比了两种算法在不同通信轮次下的性能, 首先在测试集上测试模型的预测准确率, 然后在仿真环境下使用该模型为小基站分配资源, 测试系统中计算任务的完成率。实验结果如图 4 和图 5 所示。




图 4 模型性能对比

Fig. 4 Model performance comparison

图 4 中, 横坐标表示小基站与控制器之间的通信轮数, 纵坐标表示模型在测试集上预测的准确率。本文提出的两种算法中, 在一定的精度要求下 FML 算法所需的通信轮次更少。和传统集中式方法相比, 本文提出的两种算法在预测的准确率上有一定下降, 但随着通信轮次的增加, 两者间的差距可以忽略。

此外, 从图 4 中可知, 在联邦学习前期增加通信轮数可有效提升模型的性能, 但随着精度的提高, 增加通信轮数带来的

收益趋向于无,这种趋势在本文提出的算法中很明显。因此,为节约通信和计算资源,提升系统的整体性能,在达到一定精度后,中心控制器即可停止训练。

在仿真环境下按模型预测结果为小基站分配各项资源,测试一段时间内系统中计算任务的完成率。测试结果如图 5 所示。




图 5 不同通信轮次下计算任务完成率

Fig. 5 Completion rate of tasks at different communication rounds

图 5 中,横坐标为小基站与控制器之间的通信轮数,纵坐标为一段时间内系统中计算任务的完成率。从图中可以看出,不同通信轮次下系统的卸载任务完成率差别不大,都能满足任务完成率的需求,维持在较高水平。其原因是在模型的训练过程中将完成率作为一个重要约束,若不满足此条件则会施加一个较大的惩罚;另一方面,随着模型精度的提高,冗余的资源量减少,部分突发的任务请求难以被满足,导致任务完成率有一定下降。此问题可通过在更短的时间片上对用户分配的多维资源量进行调整来解决,这将作为更进一步的研究目标。

4.2.2 参与方数目

本节主要研究参与联邦学习的小基站数目对算法性能的影响。在本节实验中,将每个小基站的数据集划分为同样大小的若干份数据,被划分出的数据作为单独的参与方加入联邦学习的训练中。图 6 给出了随着参与方的增加各方法所训练模型的性能变化。




图 6 参与方数目对模型性能的影响

Fig. 6 Impact of different number of participants on model performance

图 6 中,横坐标为参与方的数目,纵坐标为模型在测试集上的准确率。从图中可以看到参与方数量的变化对传统机器学习未造成任何影响,因为无论如何划分全部的数据,最终都会集中到中心控制器进行训练;对于本文提出的 FML 算法,增加参与方的数量对模型的性能有稍许提升;而 FAL 算法在参与方较少的情况下,增加参与方数目能有效提高其性能,而过多地增加参与方数目对模型的影响则是负面的。

4.2.3 数据异构性

车联网系统中的计算任务数据是多变的,主要体现为

任务上传的数据量不同以及任务的完成时延要求不同,多个小基站覆盖范围下的计算任务数据特征不同,从而导致本地模型的泛化性能较差。本节实验主要研究数据异构性对系统性能的影响。选取多个小基站 M1, M2, M3 和 M4, M1 中车辆生成的计算任务上传数据总大小大部分在 (5, 10] kB 之间; M2 中车辆生成的计算任务上传数据总大小主要在 [0, 5] kB 之间; M3 中车辆生成的计算任务要求最大完成时延在 [10, 30] ms 之间; M4 中车辆生成的计算任务要求最大完成时延在 [30, 50] ms 之间,偏差较大的数据集大小基本一致。使用以上数据集分别独立训练模型,同时将其作为参与方分别训练 FML 算法和 FAL 算法下的模型,将所有模型放在一个随机测试集上进行测试。性能对比如图 7 所示。




图 7 数据异构性对模型的影响

Fig. 7 Impact of data heterogeneity on model

从图 7 可知,多个本地模型在测试集上表现较差,有限且同质化的本地数据所训练出的模型难以适用于一般场景,联邦学习算法能有效提高模型质量, FAL 和 FML 两者间的性能接近。在车联网系统中,不同时间和地域的数据偏差往往较大,因此,在聚合过程中减少数据异构性对系统性能非常重要。实验结果表明,本文提出的两种算法在数据集偏差较大的情况下依旧能保持良好的预测准确率,有效减少了数据异构性带来的影响。

结束语 本文提出了基于联邦学习的车联网多维资源分配算法,即 FAL 算法和 FML 算法,旨在在保证车联网用户数据安全的基础上解决多维资源分配问题。使用联邦学习架构使多个小基站协同训练得到的模型对小基站所需多维资源进行计算,预测所需的各项资源量,防止资源的冗余分配。FML 算法解决了 FAL 算法随参与方数目增多产生性能波动的问题,同时提高了模型训练时的通信效率。实验结果表明,和传统集中式机器学习方法相比,本文提出的算法虽有一定的性能损失但仍能将准确率维持在较高水准上。实验证明了 FML 算法相比 FAL 算法拥有更高的训练效率,在参与方数目增加时表现出更好的稳定性,而在参与方数目较少时,两种算法的性能接近。FAL 算法由于聚合方式简单,消耗中心节点的计算资源更少,因此更适用于参与方较少的场景。

本文提出的方案并没有具体考虑联邦学习在无线网络环境中进行模型交互的情形,仅通过模型训练的通信轮数来间接比较两种方法的通信效率。此外,本文没有比较模型训练所消耗的计算资源、通信资源以及相应的训练时长。以上问题将作为进一步的研究目标。

参考文献

[1] WANG C, LIANG C, YU F R, et al. Computation offloading and

- resource allocation in wireless cellular networks with mobile edge computing[J]. *IEEE Transactions on Wireless Communications*, 2017, 16(8): 4924-4938.
- [2] HABER E E, NGUYEN T M, ASSI C. Joint optimization of computational cost and devices energy for task offloading in multi-tier edge-clouds[J]. *IEEE Transactions on Communications*, 2019, 67(5): 3407-3421.
- [3] ZHANG T, WANG Y, LIU Y, et al. Cache-enabling UAV communications: Network deployment and resource allocation[J]. *IEEE Transactions on Wireless Communications*, 2020, 19(11): 7470-7483.
- [4] CHEN J, WU H, YANG P, et al. Cooperative Edge Caching With Location-Based and Popular Contents for Vehicular Networks[J]. *IEEE Transactions on Vehicular Technology*, 2020, 69(9): 10291-10305.
- [5] YAN M, FENG G, ZHOU J, et al. Intelligent resource scheduling for 5G radio access network slicing[J]. *IEEE Transactions on Vehicular Technology*, 2019, 68(8): 7691-7703.
- [6] CHEN J, YANG P, YE Q, et al. Learning-Based Proactive Resource Allocation for Delay-Sensitive Packet Transmission[J]. *IEEE Transactions on Cognitive Communications and Networking*, 2020, 7(2): 675-688.
- [7] PENG H, SHEN X. Multi-Agent Reinforcement Learning Based Resource Management in MEC-and UAV-Assisted Vehicular Networks[J]. *IEEE Journal on Selected Areas in Communications*, 2020, 39(1): 131-141.
- [8] LI R, WANG C, ZHAO Z, et al. The LSTM-based advantage actor-critic learning for resource management in network slicing with user mobility[J]. *IEEE Communications Letters*, 2020, 24(9): 2005-2009.
- [9] LIU C H, CHEN Z, TANG J, et al. Energy-efficient UAV control for effective and fair communication coverage: A deep reinforcement learning approach [J]. *IEEE Journal on Selected Areas in Communications*, 2018, 36(9): 2059-2070.
- [10] LI J, ZHOU Y, LAMONT L. Communication architectures and protocols for networking unmanned aerial vehicles[C] // 2013 IEEE Globecom Workshops (GC Wkshps). IEEE, 2013: 1415-1420.
- [11] SALLENTO O, PEREZ-ROMERO J, FERRUS R, et al. On radio access network slicing from a radio resource management perspective[J]. *IEEE Wireless Communications*, 2017, 24(5): 166-174.
- [12] PENG H, SHEN X. DDPG-based resource management for MEC/UAV-assisted vehicular networks[J]. *arXiv*, 2009. 03721, 2020.
- [13] WU H, CHEN J, XU W, et al. Delay-Minimized Edge Caching in Heterogeneous Vehicular Networks: A Matching-Based Approach[J]. *IEEE Transactions on Wireless Communications*, 2020, 19(10): 6409-6424.
- [14] SAMARAKOON S, BENNIS M, SAAD W, et al. Distributed federated learning for ultra-reliable low-latency vehicular communications[J]. *IEEE Transactions on Communications*, 2019, 68(2): 1146-1159.
- [15] DINH C, TRAN N H, NGUYEN M N H, et al. Federated learning over wireless networks: Convergence analysis and resource allocation[J]. *arXiv*:1910.13067, 2019.
- [16] WADU M M, SAMARAKOON S, BENNIS M. Federated learning under channel uncertainty: Joint client scheduling and resource allocation[C] // 2020 IEEE Wireless Communications and Networking Conference (WCNC). IEEE, 2020: 1-6.
- [17] CHEN M, YANG Z, SAAD W, et al. A joint learning and communications framework for federated learning over wireless networks[J]. *IEEE Transactions on Wireless Communications*, 2020, 20(1): 269-283.
- [18] FOTOUHI A, QIANG H, DING M, et al. Survey on UAV cellular communications: Practical aspects, standardization advancements, regulation, and security challenges[J]. *IEEE Communications Surveys & Tutorials*, 2019, 21(4): 3417-3442.
- [19] XIONG Z, ZHANG Y, NIYATO D, et al. Deep reinforcement learning for mobile 5G and beyond: Fundamentals, applications, and challenges[J]. *IEEE Vehicular Technology Magazine*, 2019, 14(2): 44-52.
- [20] SHI W, ZHOU H, LI J, et al. Drone assisted vehicular networks: Architecture, challenges and opportunities [J]. *IEEE Network*, 2018, 32(3): 130-137.
- [21] MOTHUKURI V, PARIZI R M, POURIYEH S, et al. A survey on security and privacy of federated learning[J]. *Future Generation Computer Systems*, 2021, 115(2): 619-640.
- [22] GREFF K, SRIVASTAVA R K, KOUTNÍK J, et al. LSTM: A search space odyssey[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2016, 28(10): 2222-2232.



WU Yun-han, born in 1996, master. His main research interests include Internet of vehicles and federated learning.



BAI Guang-wei, born in 1961, Ph. D, professor, doctoral supervisor, is a member of China Computer Federation. His main research interests include mobile Internet, Internet of vehicles, artificial intelligence and so on.