

移动边缘计算中基于信誉值的智能计算卸载模型研究

亓晋¹, 孙海蓉², 巩锬³, 许斌¹, 张顺颐¹, 孙雁飞¹

(1. 南京邮电大学物联网学院, 江苏 南京 210003; 2. 南京邮电大学自动化学院、人工智能学院, 江苏 南京 210003;
3. 南京邮电大学计算机学院, 江苏 南京 210003)

摘 要: 针对移动边缘计算环境下, 爆炸式增长的物联网智能移动终端处理计算密集型和时延敏感型新兴移动应用时, 面临的高时延、高能耗和低可靠性等问题, 提出综合考虑时延和能耗的卸载决策模型和基于信誉值的计算资源博弈分配模型, 并分别利用改进粒子群算法和拉格朗日乘数法求解。仿真结果表明, 所提方法可满足新兴智能应用对于低时延、低能耗和高可靠性的服务需求, 可有效实现计算卸载资源的整体优化配置。

关键词: 移动边缘计算; 信誉值; 博弈分配; 卸载决策; 资源配置

中图分类号: TP393

文献标识码: A

doi: 10.11959/j.issn.1000-436x.2020105

Research on intelligent computing offloading model based on reputation value in mobile edge computing

QI Jin¹, SUN Hairong², GONG Kun³, XU Bin¹, ZHANG Shunyi¹, SUN Yanfei¹

1. Internet of Things School, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

2. College of Automation & College of Artificial Intelligence, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

3. Computer School, Nanjing University of Posts and Telecommunications, Nanjing 210003, China

Abstract: Aiming at the problem of high-latency, high-energy-consumption, and low-reliability mobile caused by computing-intensive and delay-sensitive emerging mobile applications in the explosive growth of IoT smart mobile terminals in the mobile edge computing environment, an offload decision-making model where delay and energy consumption were comprehensively included, and a computing resource game allocation model based on reputation that took into account was proposed, then improved particle swarm algorithm and the method of Lagrange multipliers were used respectively to solve models. Simulation results show that the proposed method can meet the service requirements of emerging intelligent applications for low latency, low energy consumption and high reliability, and effectively implement the overall optimized allocation of computing offload resources.

Key words: mobile edge computing, reputation value, game allocation, offloading decision, resource allocation

1 引言

近年来, 随着“大智云移物”等新一代信息技术与产业的深度融合与发展, 智慧城市、无人驾驶、AR/VR (augmented reality / virtual reality)

和人脸识别等新兴物联网智能应用应运而生^[1-2]。但这些爆炸式增长的智能应用受智能移动终端自身的电池、计算及存储资源等诸多限制, 在处理计算密集型和时延敏感型新兴智能应用时面临性能方面的瓶颈问题, 这为新兴智能应用的实现带

收稿日期: 2020-02-03; 修回日期: 2020-04-16

基金项目: 国家自然科学基金资助项目 (No.61802208, No.61772286); 中国博士后基金资助项目 (No.2019M651923); 江苏省自然科学基金资助项目 (No.BK20191381); 江苏省重点研发计划基金资助项目 (No.BE2019742)

Foundation Items: The National Natural Science Foundation of China (No.61802208, No.61772286), The Postdoctoral Science Foundation of China (No.2019M651923), The Natural Science Foundation of Jiangsu Province (No.BK20191381), The Primary Research & Development Plan of Jiangsu Province (No.BE2019742)

来了前所未有的挑战。

为了应对这种挑战,国内外众多研究团队和学者致力于通过移动云计算(MCC, mobile cloud computing)方案来解决,旨在利用云计算强大的计算能力,将智能移动终端的计算任务卸载到云端执行。但这种方案存在两点不足:1)MCC有限的网络覆盖能力难以保证提供无所不在的服务;2)MCC环境下智能移动终端与云端交互易造成高时延、高能耗,这无法满足新兴智能应用对于低时延、低能耗和高可靠性服务的需求。为了摆脱这一局限,利用网络边缘智能终端来处理数据的移动边缘计算(MEC, mobile edge computing)模式应运而生^[3],该模式考虑将智能移动终端承担的计算任务卸载到边缘云中,克服了传统MCC在计算能力、存储性能及能效等方面存在的不足,并与MCC模式形成互补。MEC最关键的计算卸载技术可以为时延和能耗敏感的计算密集型智能移动终端提供低时延、低能耗、高可靠的服务质量(QoS, quality of service)保障。但是,智能移动终端卸载大量计算任务到MEC服务器的过程中,如何分配MEC服务器计算资源来保障智能移动终端的服务性能是亟需解决的问题。针对这个问题,可分两步解决:首先解决时延和能耗需求下是否卸载、何时卸载等卸载决策问题;其次解决计算资源恶性争抢产生的可靠卸载分配问题。因此,可以尝试从最大化智能移动终端效益出发,而不仅仅是从最大化服务提供商经济利益角度出发,基于智能移动终端信誉值来分配MEC服务器计算资源,阻止恶意行为发生,实现整体资源的最优化配置。

因此,本文旨在综合考虑MEC中计算和时延敏感型新兴智能应用计算卸载问题,根据不同的卸载任务需求与智能移动终端信誉值分配计算资源,以获得低时延、低能耗和高可靠的最优计算卸载方案。本文的主要贡献包括以下几点:1)提出一种MEC环境下面向多个智能移动终端的多任务场景下,综合考虑时延和能耗的MEC卸载决策模型,实现低时延、低能耗的最优卸载方案;2)提出一种基于智能移动终端信誉值的计算卸载任务动态分配博弈方法,通过拉格朗日乘数法实现信誉值可靠卸载任务分配;3)提出一种改进的粒子群优化(PSO, partical swarm optimization)算法求解所提出的模型,结果表明该算法可有效实现计算卸载资源整体优化配置。

2 相关工作

计算卸载作为MEC的关键技术,已受到学者的广泛关注并逐渐成为研究热点。研究内容包括卸载决策和资源分配2个问题,卸载决策研究移动智能终端是否卸载、卸载多少及卸载什么的问题,资源分配则是研究对申请计算卸载的任务如何分配资源及分配多少的问题^[4]。

在卸载决策方面,针对移动智能终端是否卸载、卸载多少及卸载什么已有大量研究成果。文献[5]提出了一种卸载高能耗计算任务到远端服务器的方法,满足智能移动终端执行时间来实现节能的动态卸载,但计算密集型任务远端交互易带来高时延问题。文献[6]通过对智能移动终端进行分类得到能耗优化的任务卸载机制,但并未结合实际考虑卸载时延。文献[7]利用拓扑排序算法选择最佳虚拟机卸载计算,虽满足智能移动终端的最低时延需求,但忽略了能耗、成本等影响因素。文献[8]提出了一种基于模糊控制的自适应边缘卸载机制,但未考虑响应时间的影响。以上文献在卸载决策建模过程中考虑的影响因素不够全面,影响了计算卸载策略的合理化执行。文献[9]通过时延约束解决小蜂窝网络中计算分流问题,旨在降低移动边缘的能耗。文献[10]提出了一种新颖的全多项式时间近似方案,将时延作为约束,优化卸载计算成本和能耗。以上文献虽将计算卸载过程中时延和能耗作为重要的组成因素,然而通过约束时延来降低能耗的方法使卸载策略欠缺通用性。因此,本文在总结前人研究工作中的不足的基础上,引入时延和能耗权衡因子,较全面地考虑智能移动终端计算卸载的时延和能耗。

目前,已有部分研究工作综合考虑卸载计算中的时延和能耗。文献[11-12]考虑时延和能耗均衡实现计算资源的部分卸载,但时延提升效果不显著。文献[13-14]基于李雅普诺夫(Lyapunov)优化在线学习策略实现计算资源的全部卸载,能耗与时延提升幅度较部分卸载策略明显,但效能的提升是以降低时延或能耗某一目标来实现的。因此,本文考虑到部分卸载对全局效能提升不明显,以最小化系统总消耗为目标,综合考虑智能移动终端计算卸载时延和能耗,引入时延和能耗权衡因子,实现多个智能移动终端的多任务计算资源的全部卸载。

在资源分配方面,针对计算卸载任务如何分配资源及分配多少的问题,当前的研究工作主要集中在

在 MEC 的资源分配策略设计上^[15-16]。文献[17]采用二分搜索法优化传输功率来降低传输时延和能耗，利用非合作博弈论解决多个智能移动终端卸载决策问题来降低系统开销，但忽略了卸载计算中重要资源的分配问题。文献[18]以最大化智能移动终端能耗为目标对资源进行分配以节省终端能量，但这并不利于整体的资源的优化配置，会导致低能耗需求的智能移动终端争抢资源的局面。文献[19]提出了一种基于连续凸逼近算法的计算和通信资源分配策略，最大化服务提供商的经济利益，但忽略了智能移动终端的实际需求，不利于资源分配的整体优化。文献[20-22]中，可用的系统带宽被平均分配给 MEC 用户，但平均资源分配方案的效率和可靠性难以满足用户的 QoS 需求。以上文献在 MEC 资源分配研究中取得了一定成果，但忽略了智能移动终端竞争资源这一问题，难以实现 MEC 系统计算资源的合理可靠配置。如果规范智能移动终端的恶意资源竞争行为，实现计算卸载资源的整体优化配置，则可以时延和能耗敏感型的智能移动终端提供低时延、低能耗、高可靠的 QoS 保障。因此，本文创新性地引入智能移动终端信誉值来分配 MEC 服务器中的计算资源，有效地实现计算资源的优化配置。

综上所述，针对 MEC 中卸载决策和资源分配方法存在的不足，本文构建了综合时延和能耗的 MEC 卸载决策模型，并同时考虑基于信誉值的计算卸载资源博弈分配模型，采用改进的 PSO 算法和拉格朗日乘数法解决所存在的问题，有效实现了计算卸载资源整体优化、合理可靠的配置。

3 问题描述

3.1 网络模型

MEC 环境下的移动智能终端计算卸载过程中，MEC 服务器根据不同计算任务需求与智能终端的

信誉值分配计算资源来执行不同的计算卸载。基于信誉值的移动边缘智能计算网络模型由智能移动终端（VR/AR、智能汽车、电子游戏机、PC 监视器、无人机、智能家居等）、MEC 服务器和可信机构组成，如图 1 所示。

3.1.1 智能移动终端

本文中计算密集型智能移动终端具有计算、GPS (global positioning system) 和无线通信等模块。计算模块执行计算任务，GPS 模块实时获取位置信息，无线通信模块实现数据传输。当智能移动终端需要运行增强现实、图像处理等新兴的应用程序时，计算模块难以完成相应的计算和存储任务，则通过无线通信模块发起计算卸载请求，并将计算任务发送至指定的 MEC 服务器。

3.1.2 MEC 服务器

分布式 MEC 服务器部署在智能移动终端的邻近位置，负责分配计算资源以执行不同的计算卸载任务，完成计算任务后把回传数据反馈给智能移动终端。智能移动终端对计算卸载有不同的信誉值要求，在部分卸载情况下，当卸载的计算任务较多时，设立小基站来存储排队等待任务，待宏基站空闲时将其存储的任务上传至宏基站。本文使用全部卸载决策，因此不考虑部署小基站情况，只考虑部署 MEC 服务器的宏基站，每个智能移动终端根据不同的需求选择不同的卸载方式。

3.1.3 可信机构

可信机构由权威机构承担，负责信誉值数据库的事件记录与信誉值更新。所有的智能移动终端都必须在可信机构进行合法身份注册，取得合法身份的智能移动终端具有有效的信誉值，并取得安全通信所需的公私钥对和证书等。可信机构通过智能移动终端在不同时刻的行为记录来实时更新其信誉值，并向服务提供商提供全网信誉值数据库的访问

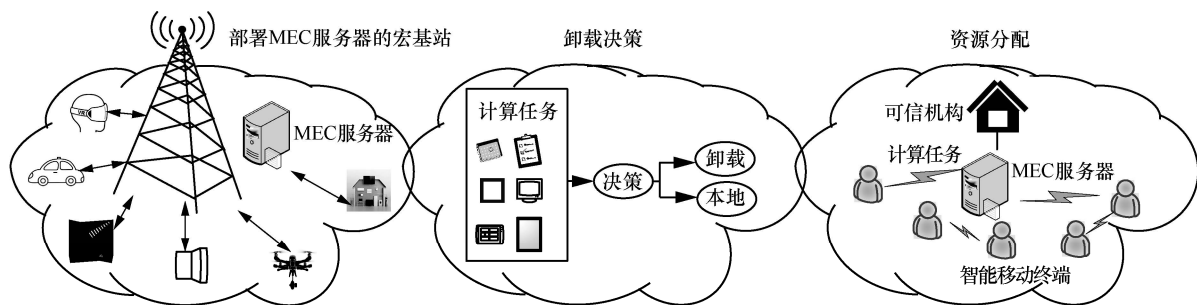


图 1 基于信誉值的移动边缘智能计算网络模型

权限。智能移动终端进行合法访问时，可信机构可实时获取其当前的信誉值。

3.2 数学模型

MCC 环境下智能移动终端有着不同的计算卸载需求，除了进行本地计算，还可以将计算任务卸载到部署 MEC 服务器的宏基站。在多个智能移动终端参与的场景下，是否卸载及任务卸载之后如何进行资源的有效分配，都是需要解决的问题。为了解决这些问题，本文提出了一种联合考虑时延和能耗的智能计算任务卸载方法，根据不同的智能移动终端的性能指标和智能移动终端用户的需求选择适合的卸载方式，实现低时延、低能耗的计算卸载决策；同时为实现计算资源的整体优化配置，以最大化智能移动终端效益为目标，基于智能移动终端的信誉值，高信誉值的智能移动终端在竞争 MEC 服务器计算资源时获得更高的决策因子，分配更多的计算资源，实现讨价还价博弈的可靠计算资源分配。

3.2.1 卸载决策模型

本文构建了一种拥有多个智能移动终端、部署 MEC 服务器的宏基站单蜂窝网络模型。假设 $N = \{1, 2, \dots, n\}$ 表示 n 个不同种类的智能移动终端。每个智能移动终端有一个计算密集型或时延敏感型的计算任务。计算任务表示为

$$O_i = \{D_i, C_i, t_i^{\max}\}, i \in N \quad (1)$$

其中， O_i 表示智能移动终端 i 所拥有的计算任务， D_i 表示计算任务的数据大小， C_i 表示完成计算任务所需的 CPU 周期数， t_i^{\max} 表示智能移动终端 i 为完成计算任务所能承受的最大时延。

针对智能移动终端用户需求不同，时延敏感型智能移动终端用户对时延需求较高，而能耗敏感型智能移动终端用户由于自身电量不足对节能需求较高，因此引入权衡机制，时间需求系数 φ_i^T 和能量需求系数 φ_i^E 分别表示智能移动终端对时延敏感及节能需求的偏重程度。对于每个智能移动终端的计算任务既可以选择卸载到 MEC 服务器，也可选择在本地执行完成，本文引入决策机制 $a_{i,j} = \{0, 1\}$ ，其中， $j = \{1, 2\}$ 表示决策方式， $j = 1$ 表示智能移动终端选择本地计算模型进行计算任务； $j = 2$ 表示智能移动终端选择卸载计算模型到宏基站执行计算任务。本文以多个智能移动终端参与的全局系统消耗为目标，构建卸载决策模型，如式(2)所示。

$$\min \sum_{i=1}^N \left\{ \varphi_i^T (a_{i,1} Z_1 + a_{i,2} Z_2) + \varphi_i^E (a_{i,1} E_1 + a_{i,2} E_2) \right\} \quad (2)$$

其中， Z_1 和 Z_2 分别表示本地计算和卸载到宏基站计算的总时延， E_1 和 E_2 分别表示本地计算和卸载到宏基站计算的总能耗。卸载决策过程如图 2 所示。

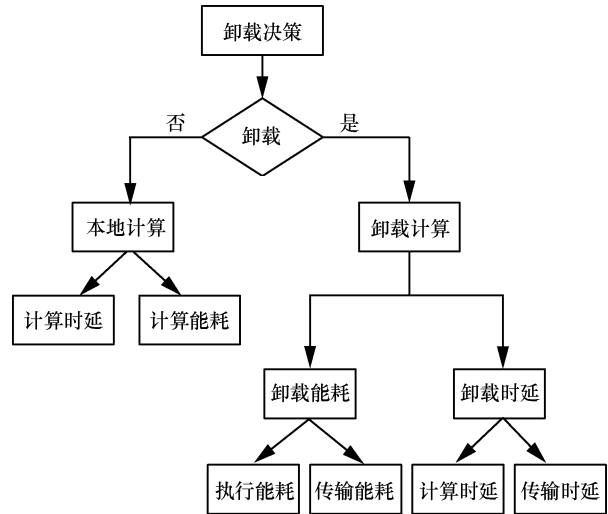


图 2 卸载决策过程

1) 本地计算模型

不同智能移动终端的本地计算能力不同，智能移动终端 i 的计算时延 $t_{i(z)}^L$ 和计算能耗 $e_{i(z)}^L$ 分别为

$$t_{i(z)}^L = \frac{C_i}{A_i^L} \quad (3)$$

$$e_{i(z)}^L = \frac{C_i}{B_i^L} \quad (4)$$

其中， A_i^L 表示智能移动终端 i 的本地计算能力， B_i^L 表示智能移动终端 i 在本地单个 CPU 周期内的能耗。对于本地计算模式，由于没有其他形式上的时间消耗和能量消耗，因此式(3)和式(4)分别表示智能移动终端 i 本地计算的总时延和总能耗。

2) 卸载计算模型

本文构建的 MEC 模型是一个正交频分复用的异构网络，接入同一基站的智能移动终端之间信道相互正交，只存在接入宏基站之间的干扰。因此，整个卸载计算过程中的时延包括传输时延和计算时延，能耗包括传输能耗和执行能耗。

① 卸载时延

智能移动终端 i 选择接入宏基站 b 的上行数据速率 $r_{i \rightarrow b}^M$ 为

$$r_{i \rightarrow b}^M = W \text{lb} \left(1 + \frac{P_i^b G_i^b}{D_i^b + k_0} \right) \quad (5)$$

其中, W 表示 i 向宏基站 b 发送上行计算请求的实际带宽, P_i^b 表示终端 i 与宏基站 b 之间的功率, G_i^b 表示终端 i 与宏基站 b 之间的增益, D_i^b 表示其他接入宏基站的智能移动终端与智能移动终端 i 之间存在的干扰, k_0 表示背景噪声功率。

智能移动终端 i 直接卸载计算任务到 MEC 服务器的传输时延 $t_{i \rightarrow b}^M$ 为

$$t_{i \rightarrow b}^M = \frac{D_i}{r_{i \rightarrow b}^M} \quad (6)$$

执行完成任务的计算时延 $t_{i(z)}^M$ 为

$$t_{i(z)}^M = \frac{C_i}{A_i^b} \quad (7)$$

其中, A_i^b 表示位于宏基站 b 的智能移动终端 i 的计算能力。

由于整个计算卸载过程中再无其他形式的时延, 智能移动终端 i 选择直接将计算任务卸载到宏基站的总时延 t_i^M 为

$$t_i^M = \frac{D_i}{r_{i \rightarrow b}^M} + \frac{C_i}{A_i^b} \quad (8)$$

将决策机制 $a_{i,j}$ 代入式(6)所示的宏基站的时延中可得到

$$t_{i \rightarrow b}^M = \frac{D_i}{W \text{lb} \left(1 + \frac{P_i^b G_i^b}{\sum_{l=1, l \neq i}^N a_{l,2} P_l^b G_l^b + k_0} \right)} \quad (9)$$

其中, l 表示接入宏基站的智能移动终端, P_l^b 表示宏基站 b 根据某些功率控制算法确定的 l 的传输功率, G_l^b 表示智能移动终端 l 与宏基站 b 之间的信道增益。

② 卸载能耗

智能移动终端 i 直接卸载计算任务到 MEC 服务器的能耗包括传输能耗 $e_{i \rightarrow b}^M$ 和执行能耗 $e_{i(z)}^M$ 两部分, 如式(10)和式(11)所示。

$$e_{i \rightarrow b}^M = \frac{P_i^b D_i}{t_{i \rightarrow b}^M} \quad (10)$$

$$e_{i(z)}^M = C_i B_i^b \quad (11)$$

其中, B_i^b 表示智能移动终端 i 在宏基站单个 CPU 周期内的能耗。

由于整个计算卸载过程中再无其他形式能耗, 智能移动终端 i 选择直接将计算任务卸载到宏基站的总能耗 e_i^M 为

$$e_i^M = \frac{P_i^b D_i}{t_{i \rightarrow b}^M} + C_i B_i^b \quad (12)$$

③ 卸载计算

联合考虑时延和能耗的 MEC 卸载计算模型为

$$\min \sum_{i=1}^N \left\{ \varphi_i^T \left[a_{i,1} \frac{C_i}{A_i^b} + a_{i,2} \left(\frac{D_i}{W \text{lb} \left(1 + \frac{P_i^b G_i^b}{\sum_{l=1, l \neq i}^N a_{l,1} P_l^b G_l^b + k_0} \right)} + \frac{C_i}{A_i^b} \right) \right] + \varphi_i^E \left[a_{i,1} C_i B_i^L + a_{i,2} \left(\frac{P_i^b D_i}{W \text{lb} \left(1 + \frac{P_i^b G_i^b}{\sum_{l=1, l \neq i}^N a_{l,2} P_l^b G_l^b + k_0} \right)} + C_i B_i^b \right) \right] \right\} \quad (13)$$

$$\text{s.t. } t_{i,z}^L \leq t_i^{\max} \quad (14)$$

$$t_i^M \leq t_i^{\max} \quad (15)$$

$$\varphi_i^T + \varphi_i^E = 1, \dots, \varphi_i^T, \varphi_i^E \in [0, 1] \quad (16)$$

$$a_{i,1} + a_{i,2} = 1, \dots, a_{i,1}, a_{i,2} \in [0, 1] \quad (17)$$

其中, 约束条件中给出了本地执行方式的时间时延 $t_{i(z)}^L$ 和直接卸载计算任务到 MEC 服务器的时间时延 t_i^M , 二者都要小于最大时延需求 t_i^{\max} ; 权衡机制中时间需求系数 φ_i^T 和能量需求系数 φ_i^E 取值范围均为 $[0, 1]$, 且两者之和为 1; 决策机制 $a_{i,1} = 1$ 、 $a_{i,2} = 0$ 表示智能移动终端 i 选择本地计算模型计算; $a_{i,1} = 0$ 、 $a_{i,2} = 1$ 表示智能移动终端 i 选择卸载计算模型到宏基站计算。

3.2.2 资源分配模型

考虑到不规范行为恶意竞争带来的资源的配置不合理问题, 本文尝试引入一种基于信誉值的讨价还价博弈模型来解决^[23], 以实现计算资源的整体优化配置。

假设 MEC 服务器计算资源满足所有需求, 一台 MEC 服务器在一个工作周期内收到 N 个智能移动终端的计算卸载任务, MEC 服务器的计算能力为每秒执行 L 个 CPU 周期。设 L_i 表示 MEC 服务器为相应的智能移动终端 i 所分配的计算资源, 每个智能移动终端通过讨价还价的博弈过程竞争

MEC 服务器上的计算资源, 且赋予信誉值高的更大的优先权, 则资源分配模型^[24]为

$$\max \prod (L_i - L_{i(\min)})^{P_i} \quad (18)$$

$$\text{s.t.} \sum_{i=1}^N L_i \leq L \quad (19)$$

其中, $L_{i(\min)}$ 表示 MEC 服务器分配给智能移动终端 i 的最小计算资源; P_i 表示智能移动终端对 MEC 服务器计算资源的决策权威因子, 与智能移动终端当前信誉值 M_i 相关, 如式(20)所示。

$$P_i = \frac{M_i}{\sum_{i=1}^N M_i} \quad (20)$$

资源分配模型也可以作为不同信誉值的效益函数模型, 信誉值越高, 则分配到的计算资源就越大。为了最大化的效益, 本文采用拉格朗日乘数法来求解 MEC 环境下基于信誉值的计算卸载资源分配博弈模型。对资源分配取对数并引入拉格朗日因子 λ , 构造拉格朗日函数, 如式(21)所示。

$$U = \left(\sum_{i=1}^N P_i \ln(L_i - L_{i(\min)}) \right) + \lambda \left(\sum_{i=1}^N L_i - L \right) \quad (21)$$

4 求解方法

第 3 节建立的 MEC 卸载决策模型包括卸载决策模型和资源分配模型, 分别对应卸载决策问题和资源分配问题。卸载决策问题在数学建模上属于 NP (non-deterministic polynomially) 问题, 且考虑寻找最优移动边缘计算卸载方案时, 还需适用于多竞争模式, 因此考虑采用搜索精度高和收敛速度快的 PSO 算法来求解本文提出的联合考虑时延和能耗的 MEC 卸载模型, 以实现低时延、低能耗的计算卸载决策。同时, 资源分配问题中每个服务器可获得的资源量是有界的, 定义域在 MEC 服务器的计算资源内, 根据有界定义域的函数的最大值理论, 如资源分配函数最大值存在, 只能在定义域内的极大值点或者在定义域的边界点上取得, 而拉格朗日乘数法是确定函数有无极大值点的有效方法。因此, 为了最大化不同信誉值的智能移动终端的效益函数, 本文采用拉格朗日乘数法求解卸载资源博弈论分配模型, 以实现合理可靠的最优资源配置。

4.1 基于改进的 PSO 算法的卸载决策求解

4.1.1 PSO 算法

PSO 算法是根据鸟群协作寻找食物的过程而

产生的一种基于群体的智能随机优化算法。PSO 算法在一个 D 维的搜索空间, 随机产生 V 个粒子构成一个种群 S , $S = \{X_1, X_2, \dots, X_V\}$, 每个粒子表示一个潜在解, 第 k 个粒子位置表示为向量 $X_k = \{x_{k1}, x_{k2}, \dots, x_{kD}\}$, 速度表示为向量 $V_k = \{v_{k1}, v_{k2}, \dots, v_{kD}\}$, 寻优过程中第 k 个粒子搜索到的最优位置表示为 $P_{\text{best}_k} = \{p_{\text{best}_{k1}}, p_{\text{best}_{k2}}, \dots, p_{\text{best}_{kD}}\}$, 全局搜索过程中粒子群搜索到的最优位置表示为 $G_{\text{best}} = \{g_{\text{best}_1}, g_{\text{best}_2}, \dots, g_{\text{best}_D}\}$, 第 k 个粒子的位置和速度更新的计算过程为

$$v_{kd}(t+1) = wv_{kd}(t) + c_1 \text{rand}() [p_{\text{best}_{kd}}(t) - x_{kd}(t)] + c_2 \text{rand}() [g_{\text{best}_d}(t) - x_{kd}(t)] \quad (22)$$

$$x_{kd}(t+1) = x_{kd}(t) + v_{kd}(t+1) \quad (23)$$

$$1 \leq k \leq V, 1 \leq d \leq D \quad (24)$$

其中, c_1 和 c_2 为加速因子, 分别表示粒子受个体认知和社会认知的影响程度; $\text{rand}()$ 表示 $[0,1]$ 的随机数; w 表示惯性权重; t 表示迭代次数。

4.1.2 改进的 PSO 算法

本文提出的 MEC 卸载决策模型求解是多方参与的 NP 问题, n 个智能移动终端选择不同的卸载方式所产生的系统消耗均不相同, 但考虑到消耗值没有太大差别, 采用不同的卸载方式组合产生的系统消耗总值变化幅度不大, 较稳定。本文采用收敛速度快的 PSO 算法求解, 容易造成多个智能移动终端参与高维状态下的系统消耗陷入局部最优, 因此分别从经济性和探索能力方面对该算法进行改进: 1) 经济性方面, 在寻优过程中自适应动态调整模型中的惯性权重, 提高算法的局部和全局寻优能力以获得更好的求解质量; 2) 探索能力方面, 从变异的角度出发, 对粒子群中的加速因子进行优化, 提高算法在解空间的探索能力。

1) 惯性权重改进

本文 MEC 卸载决策的模型是面向多个智能移动终端的多任务的决策过程, PSO 算法在求解多任务下的系统消耗高维函数时, 易陷入局部最优解的早熟收敛, 采用惯性权重保持恒定的值或线性递减的单一调整方法, 难以保证粒子每一维都同时趋向最优, 使同时搜索出多参与下系统消耗函数中的每一维最优解的概率非常小。因此, 本文采用自适应非线性的动态方式来寻优, 在前人研究的基础上引入余弦函数, 如式(25)所示。

$$W = \frac{w_{\max} + w_{\min}}{2} \cos\left(\frac{\pi t}{T_{\max}}\right) + \frac{w_{\max} - w_{\min}}{2} \quad (25)$$

其中, w_{\max} 表示惯性权重极大值, 一般取值为 0.7; w_{\min} 表示权重极小值, 一般取值为 0.1; T_{\max} 表示最大迭代次数。

惯性权重控制粒子历史位置对当前寻优状态的影响, 保持全局搜索与局部搜索之间的平衡, 能有效实现其数值的自适应非线性调整, 提高算法的效率和智能性。在算法初期需加大全局搜索, 因此惯性权重需有一个较大值; 在算法后期, 应保持一个合理的收敛速度, 以加大局部搜索能力, 故惯性权重应保持较小值。

2) 加速因子改进

由于粒子位置受个体极值和群体极值影响, 即认知部分和社会部分会大大影响粒子收敛方向和速度。PSO 算法中的加速因子 c_1 通常取值为 0.43, c_2 通常取值为 0.4, 但是在本文面向 MEC 卸载决策模型中, 当迭代次数不同时, 认知部分和社会部分的主导地位存在偏差; 当迭代次数较小时, c_1 项的认知部分占主导作用, c_2 项的社会部分占次要作用; 当迭代次数较大时, 社会知识积累不断增加, 恰好与之相反。本文 MEC 卸载决策中存在动态多本地计算和卸载计算选择问题, 为进一步提高 PSO 算法在解空间的探索能力, 从变异角度对加速因子进行改进, 采用如式(26)和式(27)所示的动态加速因子替代静态加速因子。

$$c_1 = \frac{\varepsilon}{h} \quad (26)$$

$$c_2 = \eta h^2 \quad (27)$$

其中, h 表示迭代次数; ε 表示个体认知影响因子, 本文场景下取值范围为 149~280; η 表示社会认知影响因子, 本文场景下取值范围为 0.000 13~0.000 205。

4.1.3 基于改进 PSO 算法的卸载决策方法

改进 PSO 算法的解空间与卸载决策问题的解空间的映射如表 1 所示。

表 1 改进 PSO 算法的解空间与卸载决策问题的解空间的映射

改进的 PSO 算法	卸载决策问题
空间维度	数量
种群	不同卸载决策的集合
粒子位置	不同的卸载决策
适应度值	系统总消耗

基于改进的 PSO 算法的卸载决策求解过程如算法 1 所示。

算法 1 基于改进的 PSO 算法的卸载决策求解过程

步骤 1 初始化。确定空间维度 $D=50$ 和种群规模 $V=100$; 惯性权重极值 w_{\max} 和 w_{\min} 分别设为 0.7 和 0.1; 初始位置和初始速度在搜索空间范围内随机产生。

步骤 2 求适应度值。根据式(13)所示的适应函数计算系统总消耗。

步骤 3 寻找个体极值 P_{best_k} 和群体极值 G_{best} 。寻找选择不同的卸载方式产生的系统消耗的极小值 P_{best_k} , 以及所有不同卸载方式组合下系统消耗的最优值 G_{best} 。

步骤 4 更新粒子位置和速度。根据式(22)~式(27)更新粒子速度和位置, 每个粒子都共享其与当前系统最优值的距离。粒子 k 选择到达系统最近的消耗目标值; 其他粒子将相对于粒子 k 的位置和自己曾离所求最小系统能耗目标值的最优位置进行矢量叠加。

步骤 5 更新个体极值 P_{best_k} 和群体极值 G_{best} 。将每个粒子的系统消耗值和 P_{best_k} 相比较, 如果目前的消耗值比 P_{best_k} 小, 就用目前位置替代 P_{best_k} , 然后把 P_{best_k} 中的系统消耗最小位置和 G_{best} 相比较, 如果 P_{best_k} 中的系统消耗值比 G_{best} 更小, 则替代 G_{best} 。

步骤 6 终止条件判断。终止条件根据最大迭代次数进行判断。如果满足算法终止条件, 退出循环, 返回最优搜索结果 G_{best} 。如果不满足算法终止条件, 则重复执行步骤 2~步骤 5, 直到满足算法终止条件。

步骤 7 输出最优解, 即系统消耗的最小值。

4.2 基于拉格朗日乘数法的卸载资源分配求解

资源分配模型针对的是不同信誉值的智能移动终端的效益函数, 而每个智能移动终端可获得的资源量小于或等于 MEC 服务器的计算资源, 为了最大化 MEC 资源的效益, 只在计算资源的有界范围内或边界点取得效益函数的极大值点, 而拉格朗日乘数法是确定效益函数有无计算资源极大值点的有效方法, 因此本文采用拉格朗日乘数法, 解决上述基于信誉值的卸载资源博弈分配模型。对资源分配模型取对数并引入拉格朗日因子 λ , 构造拉格朗日函数^[24], 如式(21)所示。

利用 U 对 λ 的一次偏导为 0, 一次偏导能判断

局部最优的可行解，得到式(28)。

$$\lambda = \frac{-1}{L - \sum_{i=1}^N L_{i(\min)}} \quad (28)$$

再对 λ 进行二次偏导，得到式(29)。

$$\frac{\partial^2 U}{\partial \lambda^2} = \frac{1}{\lambda^2} \quad (29)$$

由于 λ 的二次偏导大于 0，因此可确定效益函数存在最值解。

将式(28)代入式(21)，得到式(30)。

$$L_i = L_{i(\min)} + P_i \left(L - \sum_{i=1}^N L_{i(\min)} \right) \quad (30)$$

最终，MEC 服务器按照式(30)的结果分配计算资源，执行不同的计算卸载任务，并将计算结果反馈至智能移动终端。

基于拉格朗日乘数法的卸载资源分配求解过程如算法 2 所示。

算法 2 基于拉格朗日乘数法的卸载资源分配求解过程

步骤 1 对目标函数不同信誉值智能移动终端的效益函数取对数并引入拉格朗日因子 λ ，构造拉格朗日函数 U 。

步骤 2 对构造的效益函数 U 关于每个 MEC 服务器的计算资源需求 L_i 进行一次偏导，得到计算资源的局部最优的可行解，再进行二次偏导，若二次偏导不等于 0 则证明效益函数有最值解。

步骤 3 令效益函数 U 关于每个 MEC 服务器的计算资源需求 L_i 一次偏导的值等于 0，解得驻点 $L_i = L_{i(\min)}$ 。

步骤 4 对效益函数 U 关于拉格朗日因子 λ 求一次偏导。

$$\frac{\partial U}{\partial \lambda} = -\frac{1}{\lambda} + \sum_{i=1}^N L_{i(\min)} \quad (31)$$

步骤 5 由式(29)可知效益函数存在最值解，则令效益函数 U 关于拉格朗日因子 λ 的一次偏导的值等于 0，解得 λ 的值如式(28)所示。

步骤 6 将式(20)和式(28)代入计算资源分配式中，最终求得 L_i ，即分配资源的计算式，如式(32)所示。

$$L_i = L_{i(\min)} + \frac{M_i}{\sum_{i=1}^N M_i} \left(L - \sum_{i=1}^N L_{i(\min)} \right) \quad (32)$$

5 实验仿真

5.1 参数设置

在 MEC 网络模型场景中，假设网络有 50 个移动智能终端和一个部署 MEC 服务器的宏基站，小区蜂窝网络边长为 1 000 m。本文采用基于数值计算的理论评估来验证本文所提方法的效能，为该小区提供服务的 MEC 的计算能力 $F=10$ GHz，设智能移动终端自身的计算能力 L_i 、信誉值 R_i ，以及时间权衡因子为 φ_i^T 均在指定范围内服从均匀分布，如表 2 所示。其他实验参数设置参见文献[22-23]。

表 2 实验参数

实验参数	数值
移动智能终端自身计算能力 L_i /GHz	[0.5,1.0]
当前信誉值 R_i	[0,10]
时间权衡因子 φ_i^T	[0,1]
MEC 能力 F /GHz	10
功率 p /mW	100
终端与基站之间的增益 $g_{i,s}$	10^{-6}
背景噪声功率 N /dBm	-100
i 向宏基站发送上行计算请求的实际带宽/kHz	15
计算任务数据最大值 D_i^{\max} /KB	5 000
MEC 单个 CPU 能耗 δ /W	5
任务所需的 CPU 周期总数 C /兆周	1 000

5.2 结果与分析

本文利用 MATLAB 对卸载决策模型和资源分配模型进行仿真实验。本实验设置的智能移动终端数量为 1~50 个，MEC 服务器 CPU 计算能力为 5 GHz/s，智能移动终端 CPU 计算能力随机分配为 100~900 MHz/s。分别考虑低能耗卸载^[25]、随机分配卸载^[26]和本文联合时延和能耗的高效卸载 3 种不同方案对模型整体能耗的影响，并采用改进的 PSO 算法求解，得到了 3 种不同方案整体能耗的影响曲线，如图 3 所示。

从图 3 可以看出，随着智能移动终端数量的增加，3 种方案整体能耗逐渐增加。本文综合考虑时延和能耗高效卸载方案的总能耗最低，而随机分配的卸载模型总能耗最高，低能耗卸载方案的系统总能耗介于两者之间。当智能移动终端为 50 个时，本文高效卸载方案的系统总能耗比随机分配卸载方案提高了 64.05%，比低能耗卸载方案提高了 32.89%，可以看出，本文提出的综合时延和能耗高效卸载方案可有效实现低时延、低能耗的计算卸载。




图 3 3 种卸载方案的总能耗对比

由于同时存在对时延敏感和对能耗敏感的需求，考虑改变式(13)中的时间或能耗需求系数，则本文高效卸载方案对智能移动终端进行卸载决策的影响如图 4 所示。




图 4 需求系数的变化对卸载数量的影响

从图 4 可以看出，当智能移动终端对时延或能耗敏感度的需求越大，则选择将计算任务卸载到 MEC 服务器的数量越多，而此时选择本地计算的智能移动终端数量越少。由于传输时延相对于计算时延几乎可以忽略不计，而 MEC 服务器的计算速度远大于本地计算的速度，如果智能移动终端对时延或能耗敏感度需求很大，那么 MEC 服务器强大的计算能力可以有效满足终端快速处理计算任务的需求，那么在此需求下，卸载计算模型比本地计算模型效率更高。

考虑终端做出卸载决策在一定程度上与 MEC 服务器和本地终端的 CPU 的计算能力有关，静态固定 MEC 服务器的 CPU 工作能力情况下得到的实验结果不具备说服力。本文尝试动态改变 MEC 服务器的 CPU 计算能力，以 MEC 服务器 CPU 计算

能力为自变量，以不同智能移动终端选择卸载计算任务的数量为因变量，研究卸载计算和本地计算的卸载决策结果，如图 5 所示。




图 5 MEC 服务器 CPU 对智能移动终端数量的影响

从图 5 可以看出，由于 MEC 服务器进行计算的速度比智能移动终端计算的速度快，当 MEC 服务器 CPU 的计算能力持续增加，就会使智能移动终端选择将计算任务卸载到 MEC 服务器的数量也持续增加，且随着 CPU 计算能力越来越强，MEC 服务器和本地计算之间差距也越来越大。

为了验证基于改进 PSO 算法求解卸载决策模型的有效性，本文将 PSO 算法、人工蜂群算法、差分进化算法和本文改进 PSO 算法进行对比，以算法迭代次数为自变量，以系统消耗为因变量，得到了图 6 所示的变化曲线。




图 6 不同算法对模型的求解结果

从图 6 可以看出，随着迭代次数的增加，基于人工蜂群算法、本文改进的 PSO 算法和 PSO 算法求得的模型总消耗量曲线变化趋于稳定，而差分进化算法的稳健性较差，且得到的总能耗远高于其他 3 种算法。由人工蜂群算法、本文改进的 PSO 算法和 PSO 算法得到的模型总能耗可知，人工蜂群算法

和 PSO 算法模型总能耗大于本文改进的 PSO 算法, 本文改进的 PSO 算法得到的系统消耗值比 PSO 算法降低了 37.33%, 比人工蜂群算法降低了 73.14%, 比差分进化算法降低了 82.75%。因此, 本文改进的 PSO 算法在求解卸载决策模型时有效性较强。

最后, 本文在不同的 MEC 的 CPU 计算能力的情况下, 分析智能移动终端所得到的计算资源随不同信誉值变化的情况, 如图 7 所示。




图 7 不同信誉值对智能移动终端资源分配的影响

从图 7 可以看出, 随着 MEC 的计算能力 F 的增加, 智能移动终端相应地也可以得到更多的计算资源, 当信誉值为 6 时, $F=140$ GHz 比 $F=120$ GHz 的智能移动终端分配到的计算资源提高了 24%。当智能移动终端拥有更高的信誉值时, 其所分配到的计算资源也会相应地增加。当 $F=140$ GHz 时, 智能移动终端的信誉值从 1 增加到 10, 则分配到的计算资源增加了 129%。

6 结束语

本文提出了一种基于信誉值的移动边缘计算智能计算卸载模型, 该模型通过把 MEC 环境下的计算卸载分为卸载决策和资源分配 2 个过程, 解决了新兴移动应用计算卸载面临的高时延、高能耗和低可靠瓶颈问题。为了实现面向多个智能移动终端的多任务的计算卸载方案, 本文提出一个综合考虑时延和能耗的卸载决策模型, 并使用改进的 PSO 算法实现了低时延、低能耗的最优计算卸载方案; 考虑到不规范行为恶意竞争资源带来的资源分配不合理问题, 引入一种基于信誉值的讨价还价博弈模型, 采用拉格朗日乘数法求解以实现计算资源的可靠分配。实验结果表明, 本文所提出的计算卸载模型可满足新兴智能应用对于低时延、低能耗和高可

靠性的服务需求, 可有效实现计算卸载资源整体优化配置。但考虑到 MEC 分布式特点, 传统的基于信誉值的方法有一定局限性, 下一步工作的重点是尝试将区块链与 MEC 相结合, 实现更加有效可信的计算卸载。

参考文献:

- [1] ZHANG K, LENG S P, HE Y J, et al. Mobile edge computing and networking for green and low-latency Internet of things[J]. IEEE Communications Magazine, 2018, 56(5): 39-45.
- [2] TALEB T, DUTTA S, KSENTINI A, et al. Mobile edge computing potential in making cities smarter[J]. IEEE Communications Magazine, 2017, 55(3): 38-43.
- [3] PRIYA B, SRI R, NIMMAGADDA A, et al. Mobile edge communication an overview of MEC in 5G[C]//2019 5th International Conference on Advanced Computing & Communication Systems. Piscataway: IEEE Press, 2019: 271-276.
- [4] 谢人超, 廉晓飞, 贾庆民, 等. 移动边缘计算卸载技术综述[J]. 通信学报, 2018, 39(11):142-159.
XIE R C, LIAN X F, JIA Q M, et al. Survey on computation offloading in mobile edge computing [J]. Journal on Communications, 2018, 39(11): 142-159.
- [5] 朱新峰, 张智浩, 王彦凌. 移动边缘计算环境下的动态资源分配策略[J]. 计算机工程与科学, 2019, 41(7): 1184-1190.
ZHU X F, ZHANG Z H, WANG Y L. A dynamic resource allocation strategy in mobile edge computing environment[J]. Computer Engineering & Science, 2019, 41(7): 1184-1190.
- [6] ALAM M G R, HASSAN M M, UDDIN M Z, et al. Autonomic computation offloading in mobile edge for IoT applications[J]. Future Generations Computer Systems, 2019, 90(3): 149-157.
- [7] CHEN X, SHI Q, YANG L, et al. Thrifty edge: resource-efficient edge computing for intelligent IoT applications[J]. IEEE Network, 2018, 32(1): 61-65.
- [8] MENG Z Y, XU H L, HUANG L S, et al. Achieving energy efficiency through dynamic computing offloading in mobile edge-clouds[C]//2018 IEEE 15th International Conference on Mobile Ad Hoc and Sensor Systems. Piscataway: IEEE Press, 2018: 175-183.
- [9] YOU C S, ZENG Y, ZHANG R, et al. Asynchronous mobile-edge computation offloading: energy-efficient resource management[J]. IEEE Transactions on Wireless Communications, 2018, 17(11): 7590-7605.
- [10] KAO Y H, KRISHNAMACHARI B, RA M R, et al. Hermes: latency optimal task assignment for resource-constrained mobile computing[J]. IEEE Transactions on Mobile Computing, 2017, 16(11): 3056-3069.
- [11] LAGÉN S, PASCUAL-ISERTE A, MUÑOZ O, et al. Energy efficiency in latency-constrained application offloading from mobile clients to multiple virtual machines[J]. IEEE Transactions on Signal Processing, 2018, 66(4): 1065-1079.
- [12] YOU C, HUANG K, CHAE H, et al. Energy-efficient resource allocation for mobile-edge computation offloading[J]. IEEE Transactions on Wireless Communications, 2017, 16(3): 1397-1411.
- [13] NAN Y C, LI W, BAO W, et al. Adaptive energy-aware computation offloading for cloud of things systems[J]. IEEE Access, 2017(5):

- 23947-23957.
- [14] WEI F, CHEN S X, ZOU W X. A greedy algorithm for task offloading in mobile edge computing system[J]. China Communications, 2018, 15(11): 149-157.
- [15] 董思岐, 吴嘉慧, 李海龙, 等. 面向优先级业务的移动边缘计算资源分配策略[J]. 计算机工程, 2020, 3(46): 18-23.
DONG S Q, WU J H, LI H L, et al. Resource allocation method for priority task in mobile edge computing[J]. Computer Engineering, 2020, 3(46): 18-23.
- [16] PENG Q L, XIA Y N, FENG Z, et al. Mobility-aware and migration-enabled online edge user allocation in mobile edge computing[C]//2019 IEEE International Conference on Web Services. Piscataway: IEEE Press, 2019:91-98.
- [17] 周文晨, 方维维, 李阳阳, 等. 移动边缘计算中分布式的设备发射功率优化算法[J]. 西安交通大学学报, 2018, 52(12): 121-127.
ZHOU W C, FANG W W, LI Y Y, et al. A distributed algorithm for transmit power optimization in mobile edge computing[J]. Xi'an Jiaotong University Xuebao, 2018, 52(12): 121-127.
- [18] GUO J F, SONG Z Z, CUI Y, et al. Energy-efficient resource allocation for multi-user mobile edge computing[C]// 2017 IEEE Global Communications Conference. Piscataway: IEEE Press, 2017:1-7.
- [19] SARDELLITTI S, SCUTARI G, BARBAROSSA S. Joint optimization of radio and computational resources for multicell mobile-edge computing[J]. IEEE Transactions on Signal and Information Processing over Networks, 2015, 1(2):89-103.
- [20] GUO S T, LIU J D, YANG Y Y, et al. Energy-efficient dynamic computation offloading and cooperative task scheduling in mobile cloud computing[J]. IEEE Transactions on Mobile Computing, 2019,18(2): 319-333.
- [21] LYU X, TIAN H, ZHANG P, et al. Multi-user joint task offloading and resources optimization in proximate clouds[J]. IEEE Transactions on Vehicular Technology, 2017, 66(4): 3435-3447.
- [22] CHEN X, JIAO L, LI W, et al. Efficient multi-user computation offloading for mobile-edge cloud computing[J]. IEEE-ACM Transactions on Networking, 2016, 24(5): 2795-2808.
- [23] ZHANG H, ZHANG Q, DU X. Toward vehicle-assisted cloud computing for smartphones[J]. IEEE Transactions on Vehicular Technology, 2015, 64(12): 5610-5618.
- [24] 吴振铨, 黄旭民, 余荣, 等. 车载边缘计算中基于信誉值的计算卸载方法研究[J]. 计算机应用研究, 2018, 35(9): 138-141.
WU Z Q, HUANG X M, YU R, et al. Reputation-based approach for computation offloading in vehicular edge computing[J]. Application Research of Computers, 2018, 35(9): 138-141.
- [25] ZHANG H, GUO J, YANG L, et al. Computation offloading considering fronthaul and backhaul in small-cell networks integrated with MEC[C]//2017 IEEE Conference on Computer Communications Workshops. Piscataway: IEEE Press, 2017: 115-120.
- [26] 龙彦汕, 富勤学, 郭继斌. D2D 缓存网络中基于随机几何的成功卸

载概率分析[J]. 计算机应用, 2019, 39(8):2346-2353.

LONG Y S, FU Q X, GUO J B. Successful offloading probability analysis in device-to device caching network based on stochastic geometry[J]. Journal of Computer Applications, 2019, 39(8):2346-2353.

[作者简介]



元晋(1983-), 男, 山东莱芜人, 博士, 南京邮电大学副教授, 主要研究方向为人工智能在工业互联网、能源互联网、智慧供应链和智慧健康等领域的关键技术与应用。



孙海蓉(1994-), 女, 江苏泰州人, 南京邮电大学硕士生, 主要研究方向为边缘计算在工业互联网和智能制造等领域的应用。



巩锟(1999-), 女, 山东莱芜人, 南京邮电大学硕士生, 主要研究方向为边缘计算、机器学习在工业互联网领域的应用。



许斌(1981-), 男, 江苏张家港人, 博士, 南京邮电大学副教授, 主要研究方向为智能计算技术及其在工业互联网、能源互联网、复杂网络、智慧健康等领域的关键技术与应用。

张顺颐(1944-), 男, 江苏南京人, 南京邮电大学教授, 主要研究方向为移动互联网、网络管理与监控关键技术与产业应用。

孙雁飞(1976-), 男, 山东莱芜人, 博士, 南京邮电大学研究员, 主要研究方向为人工智能在工业互联网、能源互联网、智慧供应链和智慧健康等领域的关键技术与应用。