

面向触觉通信的预测窗口和 计算卸载策略优化

Optimization of Prediction Window and Computing Offloading Strategy for Haptic Communication

吴岩/WU Yan, 吴丹/WU Dan, 王嵩/WANG Song

(陆军工程大学, 中国 南京 210000)
(Army Engineering University of PLA, Nanjing 210000, China)



摘要: 构建了联合预测和边缘计算的触觉通信框架,明确了时延和能耗之间的折中关系,并定义了发送者的预测效益。以总预测效益最大化为目的,构建了多发送者的预测窗口和计算卸载策略联合优化问题。为便于求解,将该优化问题转化为多发送者预测与计算卸载博弈,并提出了一种基于最优响应的预测与计算卸载联合优化算法以收敛纳什均衡解。仿真结果表明,所提算法可以获得近乎最优的预测窗口和计算卸载策略。

关键词: 触觉通信; 超低时延; 预测; 边缘计算; 博弈

Abstract: A joint prediction and edge computing framework for haptic communications is constructed. The tradeoff between delay and energy consumption is clarified, and the prediction benefit of the transmitter is defined. In order to maximize the sum prediction benefit, a joint optimization problem of multi-transmitter prediction window and computing offloading strategy is constructed. Then, the optimization problem is transformed into a multi-transmitter prediction and computing offloading game, and a joint optimization algorithm of prediction and computing offloading based on the best response is proposed to converge to the Nash equilibrium. Simulation results show that the proposed algorithm can achieve near-optimal performance.

Keywords: haptic communication; ultra-low latency; prediction; edge computing; game

DOI: 10.12142/ZTETJ.202106005

网络出版地址: <https://kns.cnki.net/kcms/detail/34.1228.TN.20211119.1936.004.html>

网络出版日期: 2021-11-22

收稿日期: 2021-11-06

无线通信、信号处理和多媒体通信技术的进步推动了触觉互联网的发展,使触觉互联网可以在传统视听信号的基础上实现触觉信息的实时传输。触觉通信的发展为用户带来了更具沉浸感的服务体验,也开启了远程操作、自动驾驶等多媒体应用的新时代^[1]。

基金项目:国家自然科学基金(61671474);江苏省杰出青年基金(BK20180028);江苏省优秀青年基金(BK20170089)

触觉通信一般包含主域、网络域和控制域3个部分。触觉表现需要依靠肤觉的即时性和力觉的反馈性,对时延有着极高的要求,否则会使得通信双方对环境认知出现偏差。为了满足这一要求,文献[2]从触觉设备信号采集、数据压缩、网络传输协议和编码、资源管理等方面展开了研究。但由于处理时延、传输时延等固有时延的存在,传统方法在降低触觉通信时延方面并不理想。

考虑到触觉信号在时间上的连

续性和关联性,通过引入预测思想,发送者可以根据预测窗口大小对未来动作进行预测并提前发送,以有效降低端到端时延。现有预测方法大致分为基于模型和基于数据的两种。前者较为简单,但过于依赖模型的选择和构建,因此适用场景有限;后者较为复杂,但可以通过机器学习等算法,通过挖掘历史数据中的潜在规律来预测未来趋势。特别地,由于神经网络具有时间序列预测的优势,因此基于神经网络的预测方法在网络流

量、车流量预测方面得到了广泛应用^[3-5]。然而,这种方法的性能优势建立在对大量历史数据进行训练的基础上,加大了发送者自身计算资源的损耗。特别是当发送者计算资源受限时,仅在本地进行计算卸载很可能会增加预测未来动作所需的时延。为此,尝试在预测的同时加入边缘计算,可以使得发送者有机会将预测任务卸载到边缘服务器上,以减少由预测带来的额外时延。

目前,已有一些研究将边缘计算与神经网络相结合,例如:文献[6]将边缘计算融入深度神经网络架构,以应对计算敏感型的处理任务;文献[7]利用边缘计算将深度学习过程从云服务器迁移到边缘节点,以减少工业物联网网络中的数据传输需求并缓解网络拥塞。

如此一来,在联合预测和边缘计算的触觉通信中,发送者根据本地计算资源和预测所需计算资源,既可以将预测任务进行本地卸载,也可以进行服务器卸载。值得注意的是,虽然边缘服务器比本地终端有着更为丰富的计算资源,但过多的发送者同时选择将预测任务卸载到服务器,会使得每个发送者分得的计算资源无法满足相应需求,反而会增加预测所需的时延。因此,在众多发送者之间合理规划计算卸载策略对于每个发送者而言至关重要。此外,值得注意的是,虽然引入预测和边缘计算有利于满足触觉通信的低时延要求,但是预测和计算卸载也会造成发送者能耗的增加。这对于能量受限的发送者而言是不可忽略的。实际上,发送者的能耗不仅与计算卸载策略有关,还与预测窗口的大小有关,即预测窗口越大,预测所需的计算资源越多,由此带来的能耗则越大。因此,为了保证发送者的预测所耗时延和能耗性

能,对预测窗口和计算卸载策略进行联合优化势在必行。

鉴于此,本文通过引入预测和边缘计算的思想,提出了预测窗口和计算卸载策略联合优化方案,以满足触觉通信超低时延和低能耗的双重要求。主要工作总结如下:

(1)构建了联合预测和边缘计算的触觉通信框架,其核心思想是根据优化的预测窗口大小,采用基于长短期记忆神经网络预测模型来预测发送者未来时刻的动作,同时引入边缘计算,激励发送者在本地和边缘服务器之间自主选择计算卸载策略,以避免本地卸载导致的预测所耗时延过高的问题。

(2)定量分析了预测窗口和计算卸载策略对预测所耗时延和发送者能耗的影响,明晰了时延和能耗之间的折衷关系,进而提出预测效益的概念,以定义发送者对于低时延和低能耗的双重要求。

(3)以总预测效益最大化为目标,建立了预测窗口和计算卸载策略联合优化问题。为便于求解,将该优化问题转化为多发送者预测与计算卸载博弈,并证明了纳什均衡的存在性,而后提出一种基于最优响应的预测与计算卸载联合优化算法,以分布

式、低复杂度的方式获得近乎最优的预测窗口和计算卸载策略。

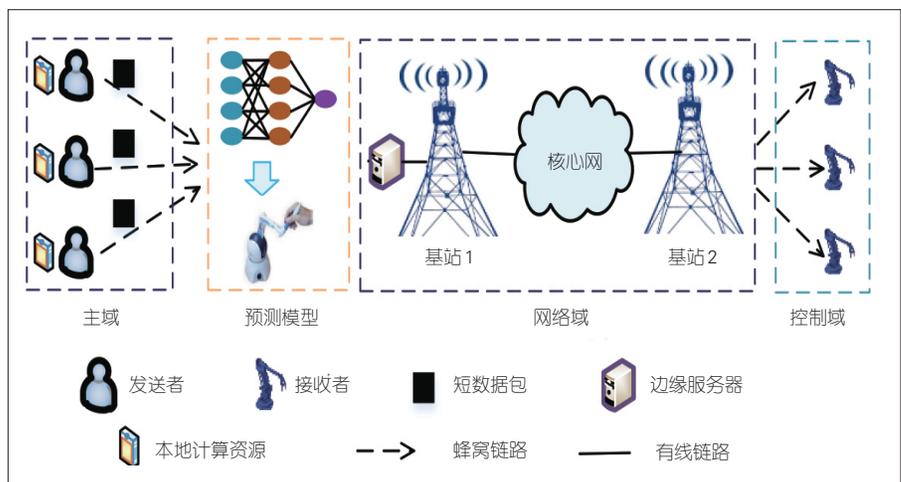
1 联合预测和边缘计算的触觉通信框架

图1展示了联合预测和边缘计算的触觉通信框架,包含主域、预测模型、网络域和控制域。位于主域的发送者通过网络域向位于控制域的接收者发送触觉信号,以对其进行实时操作。其中,触觉信号采用短数据包的形式进行传输。各部分的主要结构和作用概括描述如下。

- 主域:由发送者和人机接口组成,其中发送者为具备一定计算资源的终端设备,人机接口负责将发送者的动作通过编码转化为触觉信号。所有发送者构成集合 $\mathcal{N} = \{1, \dots, n, \dots, N\}$,其中 N 为发送者的数目,发送者 n 自身具备的计算资源表示为 V_n 。

- 预测模型:由于触觉信号在时间上的连续性和关联性,发送者根据优化获得的预测窗口大小,采用基于长短期记忆(LSTM)神经网络预测模型对未来时刻动作进行预测并提前发送,以满足触觉通信超低时延的要求。

- 网络域:由基站和核心网组成,

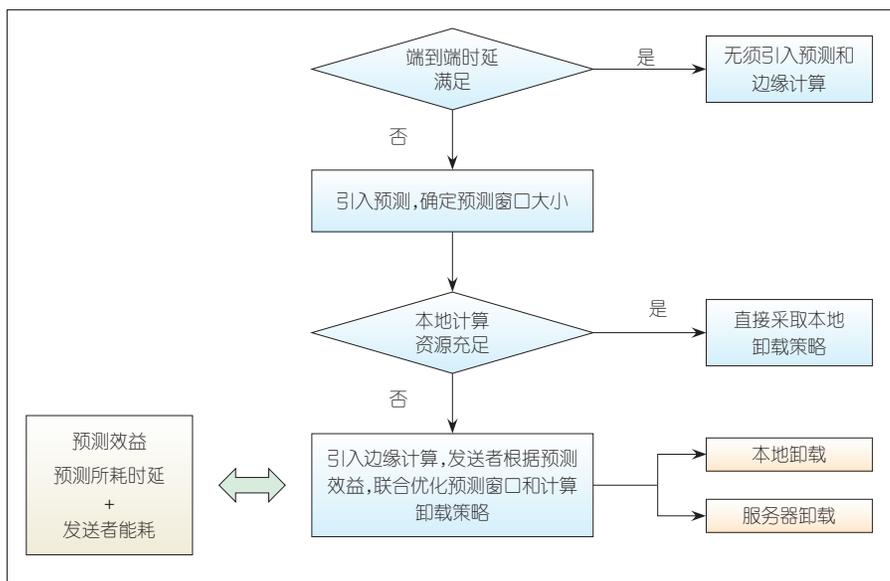


▲图1 联合预测和边缘计算的触觉通信框架

负责为触觉通信提供传输媒介。基站 1 配备有一个边缘服务器,可提供的计算资源总量为 V_B 。

• 控制域:由触觉信号接收者组成,可以和远程环境进行交互。

图 2 展示了联合预测和边缘计算的触觉通信流程。首先,发送者根据接收者的反馈判断端到端时延是否满足触觉通信超低时延要求。若满足,则无须引入预测和边缘计算,发送者可直接与接收者进行触觉通信;若不满足,则引入基于 LSTM 神经网络的触觉动作预测模型,并根据预测所耗时延和发送者的能耗确定预测窗口大小。随后,考虑到预测需要以计算资源为支撑,计算资源越多,预测所耗时延就越低。若此时发送者自身具备的计算资源能够满足预测所耗时延要求,则直接采取本地卸载策略;否则引入边缘计算,发送者根据预测效益,联合优化预测窗口和计算卸载策略。

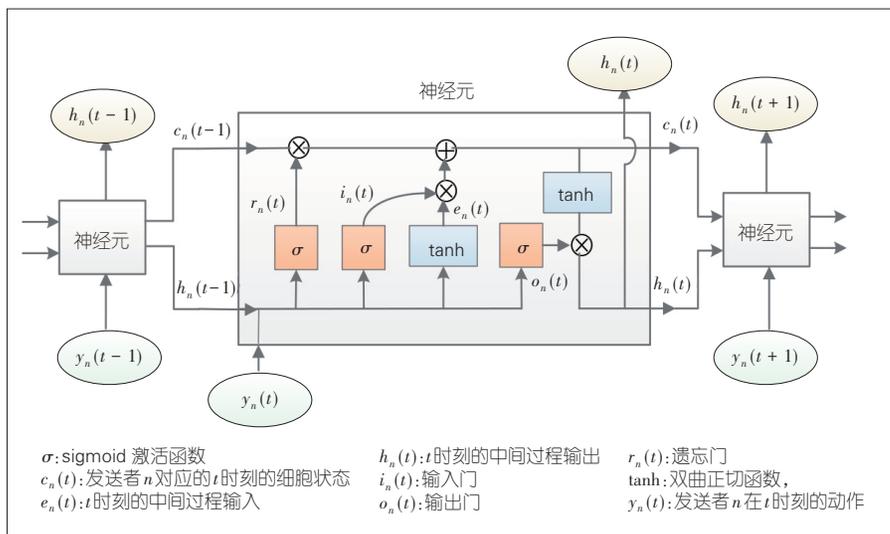


▲图 2 联合预测和边缘计算的触觉通信流程

1.1 基于 LSTM 神经网络的触觉动作预测模型

针对触觉动作所具有的时间序列特性,本文采用基于 LSTM 的神经网络预测方法。LSTM 神经网络不仅可以很好地解决时间序列的预测问题,而且可以通过在神经元中引入门结构,很好地协调历史信息和当前信息,从而有助于解决时间序列中的长期依赖问题。

图 3 展示了 LSTM 神经元结构,包含输入门 $i_n(t)$ 、输出门 $o_n(t)$ 和遗忘门 $r_n(t)$ 。其中,输入门用来处理当前序列位置的输入,输出门用来控制信息的输出,遗忘门用来控制是否遗忘细胞历史状态。相应的更新规则如下:



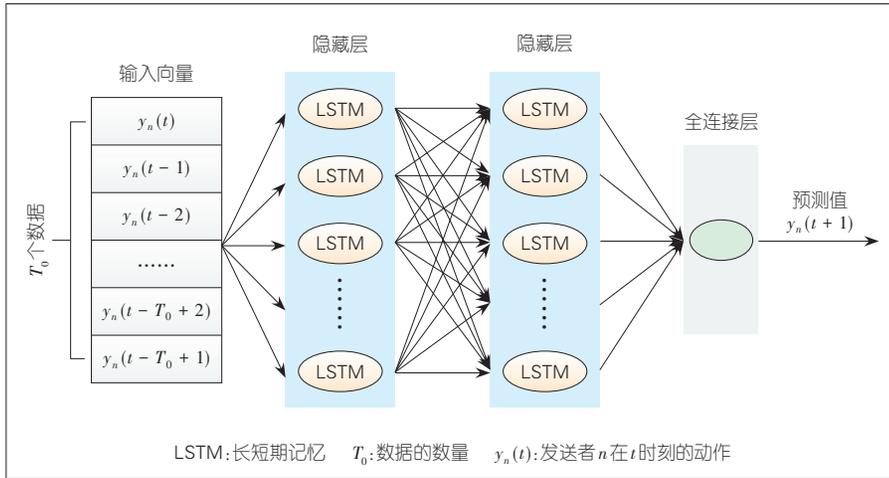
▲图 3 长短期记忆神经元结构

$$\begin{aligned}
 r_n(t) &= \sigma(Z_r \cdot h_n(t-1) + G_r \cdot y_n(t) + I_r) \\
 i_n(t) &= \sigma(Z_i \cdot h_n(t-1) + G_i \cdot y_n(t) + I_i) \\
 o_n(t) &= \sigma(Z_o \cdot h_n(t-1) + G_o \cdot y_n(t) + I_o) \\
 e_n(t) &= \tanh(Z_e \cdot h_n(t-1) + G_e \cdot y_n(t) + I_e) \\
 c_n(t) &= c_n(t-1) \otimes r_n(t) + i_n(t) \otimes e_n(t) \\
 h_n(t) &= o_n(t) \otimes \tanh(c_n(t))
 \end{aligned} \tag{1}$$

其中, $y_n(t-1)$ 、 $y_n(t)$ 和 $y_n(t+1)$ 分别表示发送者 n 在时刻 $t-1$ 、 t 和 $t+1$ 的动作, $c_n(t)$ 表示发送者 n 对应的 t 时刻的细胞状态, $e_n(t)$ 表示 t 时刻的中间过程输入, $h_n(t-1)$ 、 $h_n(t)$ 和 $h_n(t+$

1) 分别表示时刻 $t-1$ 、 t 和 $t+1$ 的中间过程输出, σ 为 sigmoid 激活函数, \tanh 表示双曲正切函数, \otimes 表示对应元素相乘。此外, Z_r 、 Z_i 、 Z_o 、 Z_e 、 G_r 、 G_i 、 G_o 、 G_e 、 I_r 、 I_i 、 I_o 、 I_e 均为线性关系的系数和偏倚。

结合图 3 所示的 LSTM 神经元结构,图 4 展示了基于 LSTM 神经网络的触觉动作预测模型。令 t 为当前时刻, T_0 为预测未来动作所需要的历史动作数据量, w_n 为预测窗口。触觉动作的预测采用迭代预测方式,即当预



▲图4 基于LSTM神经网络的触觉动作预测模型

测未来 $t + w_n$ 时刻动作时,先用 $t - T_0 + 1$ 到 t 时刻的连续 T_0 个数据作为输入向量,并经过两层 LSTM 隐藏层和全连接层,此时输出 $t + 1$ 时刻的预测动作;而后再用 $t - T_0 + 2$ 到 $t + 1$ 时刻的数据作为输入向量来预测 $t + 2$ 时刻的触觉动作,依次迭代进行,直至输出 $t + w_n$ 时刻预测动作。由此可见,LSTM 神经网络预测所需要的计算资源与预测窗口大小密切相关,即预测窗口越大,迭代预测的次数越多,所需要的计算资源也越多。

进一步地,本文采用均方根误差(RMSE)作为上述预测模型的预测误差指标。当预测窗口为 w_n 时,发送者 n 的预测差错概率为:

$$e_n^{\text{predict}} = \sqrt{\frac{1}{w_n} \sum_{i=1}^{w_n} (y_n(t+i) - \hat{y}_n(t+i))^2}, \quad (2)$$

其中, $y_n(t+i)$ 为发送者 n 在 $t+i$ 时刻实际采取的动作, $\hat{y}_n(t+i)$ 为发送者 n 在 $t+i$ 时刻预测的动作。

1.2 发送者预测效益定义

虽然引入预测和边缘计算有利于满足触觉通信超低时延要求,但是预测和计算卸载也会造成发送者能

耗的增加。这对于能量受限的发送者而言是不可忽略的。因此,本文通过明晰时延和能耗之间的折衷关系,定义预测效益这一性能指标。该指标的物理意义在于表征触觉通信低时延和低能耗的双重要求。

当采用本地卸载策略时,即 $x_n = 0$,发送者 n 的预测所耗时延取决于预测窗口和自身的计算资源,即:

$$t_n^{\text{predict}} = \frac{\mu w_n}{V_n}, \quad (3)$$

其中, w_n 为发送者 n 的预测窗口大小, μ 为预测一个传输间隔需要的计算资源, V_n 为发送者 n 自身具备的计算资源。迭代预测方法可以使预测所需的计算资源与预测窗口呈正相关关系。因此,这里采用线性计算方法,即预测窗口为 w_n 时需要的计算资源为 μw_n 。

根据文献[8],本地卸载策略下的能耗为:

$$E_n = \kappa \mu w_n V_n^2, \quad (4)$$

其中, κ 为芯片结构的能量系数。

结合公式(3)和(4),本地卸载策略下发送者 n 的预测效益为:

$$\delta_n = t_0 w_n - t_n^{\text{predict}} - \tau E_n, \quad (5)$$

其中, t_0 为数据包的传输间隔, $t_0 w_n - t_n^{\text{predict}}$ 表示本地卸载策略下触觉通信端到端时延的减少量, τ 为能耗的权重系数。在本地卸载策略下,考虑到发送者能量的有限性,为了避免发送者一味地增大预测窗口而造成过大的能耗,令 $\tau = \tau_0 \sqrt{w_n}$, 其中 τ_0 为常数。相应地,能耗的权重系数将随着预测窗口的增加而不断增加,以实现时延和能耗的折衷。

当采用服务器卸载策略时,即 $x_n = 1$,发送者 n 的预测所耗时延取决于预测窗口 w_n 和边缘服务器分配的计算资源,即:

$$t_n^{\text{predict}} = \frac{\mu w_n}{V_B^n}, \quad (6)$$

其中, V_B^n 为边缘服务器分配给发送者 n 的计算资源。为了满足计算资源分配的公平性原则,边缘服务器为采用服务器卸载策略的发送者等额分配计算资源,即:

$$V_B^n = \frac{V_B}{\sum_{i \in \mathcal{N}} x_i}, \quad (7)$$

其中, V_B 为服务器可提供的计算资源总量, $\sum_{i \in \mathcal{N}} x_i$ 表示所有采用服务器卸载策略的发送者数目。

由于边缘服务器为有源节点,其能耗相对于能量有限的发送者而言可以忽略不计,即 $E_n = 0$ 。因此,在服务器卸载策略下,发送者 n 的预测效益为:

$$\delta_n = t_0 w_n - t_n^{\text{predict}}, \quad (8)$$

其中, $t_0 w_n - t_n^{\text{predict}}$ 表示在服务器卸载策略下触觉通信端到端时延的减少量。需要注意的是,我们之所以没有考虑发送者上行传输的能耗,是因为在触觉通信中发送者本来就需要先向基站1发送触觉信号,而后才能向

核心网传送。这也从侧面体现了在触觉通信中引入边缘计算的优势,即降低能耗并减少回传时延。结合公式(5)和(8),发送者 n 的预测效益可以表示为:

$$\delta_n = \begin{cases} t_0 w_n - \frac{\mu w_n}{V_n} - \tau E_n & x_n = 0 \\ t_0 w_n - \frac{\mu w_n}{V_B^n} & x_n = 1 \end{cases} \quad (9)$$

1.3 触觉通信时延和可靠性约束

结合图1所示的触觉通信框架,发送者 n 的端到端时延可以表示为:

$$t_n = t_n^{\text{up}} + t_n^{\text{predict}} + t_n^{\text{core}} + t_n^{\text{down}} - t_0 w_n, \quad (10)$$

其中, t_n^{up} 为发送者 n 到基站1的传输时延, t_n^{predict} 为预测所耗时延, t_n^{core} 为基站1到基站2的传输时延, t_n^{down} 为基站2到相应接收者的传输时延。

令 t_{\max} 为触觉通信端到端时延约束,则有:

$$t_n \leq t_{\max} \quad (11)$$

发送者 n 的总传输差错概率可以表示为:

$$\varepsilon_n = 1 - (1 - \varepsilon_n^{\text{up}})(1 - \varepsilon_n^{\text{predict}})(1 - \varepsilon_n^{\text{core}})(1 - \varepsilon_n^{\text{down}}), \quad (12)$$

其中, $\varepsilon_n^{\text{up}}$ 为发送者 n 到基站1的传输差错概率, $\varepsilon_n^{\text{predict}}$ 为预测差错概率, $\varepsilon_n^{\text{core}}$ 为基站1到基站2的传输差错概率, $\varepsilon_n^{\text{down}}$ 为基站2到相应接收者的传输差错概率。

由于在高可靠传输下的差错概率一般为 10^{-4} ~ 10^{-5} ,因此公式(12)可以近似为 $\varepsilon_n = \varepsilon_n^{\text{up}} + \varepsilon_n^{\text{predict}} + \varepsilon_n^{\text{core}} + \varepsilon_n^{\text{down}}$ 。令 ε_{\max} 为触觉通信传输差错概率约束,则有:

$$\varepsilon_n \leq \varepsilon_{\max} \quad (13)$$

2 预测窗口和计算卸载策略联合优化

本节中,我们首先以总预测效益最大化为目标,建立预测窗口和计算卸载策略联合优化问题;随后,将该优化问题转化为多发送者预测与计算卸载博弈,通过定义博弈的势能函数证明纳什均衡的存在性;最后,提出一种基于最优响应的预测与计算卸载联合优化算法,并分析其收敛性和复杂度。

2.1 问题形成

由以上的分析可知,无论是卸载策略还是预测窗口,都对发送者的预测效益产生非常关键的影响。令 $a_n = \{x_n, w_n\}$ 为发送者 n 的联合卸载策略和预测窗口策略。本文旨在优化所有发送者的策略以最大化总预测效益。优化问题可以表示为:

$$\begin{aligned} Q: & \max_{a_n} \sum_{n \in \mathcal{N}} \delta_n \\ \text{s.t.} & C1: t_n \leq t_{\max} \\ & C2: \varepsilon_n \leq \varepsilon_{\max} \\ & C3: x_n \in \{0, 1\}, \end{aligned} \quad (14)$$

其中,约束条件C1和C2分别表示触觉通信的时延和可靠性约束,C3为卸载策略约束。对于C3, $x_n = 0$ 表示本地卸载策略, $x_n = 1$ 则表示服务器卸载策略。由公式(10)可知,预测窗口仅会影响 $t_0 w_n$ 和 t_n^{predict} 两项时延。根据公式(9),不管采取哪种卸载策略,预测窗口越大,端到端时延的减少量就越多,因此约束条件C1可以视为预测窗口 w_n 的下界约束。同理,由公式(12)可知,预测窗口仅会影响预测差错误差 $\varepsilon_n^{\text{predict}}$,并且预测窗口越大,预测差错误差就越大,因此约束条件C2可以视为预测窗口 w_n 的上界约束。

2.2 博弈模型

公式(14)中的优化问题为混合

整数非线性规划问题。集中式的解决方案将导致较高的复杂度。此外,发送者的卸载策略将影响其他发送者可分配的服务器计算资源,进而影响其他发送者的预测效益。考虑到不同发送者策略之间的交互关系,我们采用博弈论^[9-10]对优化问题进行求解。相应地,优化问题被建立为多发送者预测与计算卸载博弈 $\mathcal{G} = [\mathcal{N}, \mathbb{A}, \{u_n\}_{n \in \mathcal{N}}]$,其中 $\mathcal{N} = \{1, \dots, N\}$ 为发送者的集合, $\mathbb{A} = \mathcal{A}_1 \times \dots \times \mathcal{A}_N$ 为所有发送者的策略空间, $\mathbb{A}_n = a_n \otimes w_n$ 为发送者 n 的策略空间, u_n 为发送者 n 的效用函数。

本文中发送者 n 的效用函数被定义为:

$$u_n(a_n, a_{-n}) = \delta_n(a_n, a_{-n}) + \sum_{i \neq n} (\delta_i(a_i, a_{-i}) - \delta_i(a_i, a_{-i \setminus n})), \quad (15)$$

其中, a_{-n} 为除发送者 n 外其他发送者的策略集, $\delta_i(a_i, a_{-i \setminus n})$ 为不考虑发送者 n 策略时发送者 i 的预测效益。因此, $\delta_i(a_i, a_{-i}) - \delta_i(a_i, a_{-i \setminus n})$ 表示在发送者 n 采取策略前后,发送者 i 预测效益的变化量。公式(15)的第1项表示发送者 n 的预测效益,第2项表示发送者 n 的策略对其他发送者的影响。

2.3 纳什均衡的存在性

定义1(纳什均衡):当且仅当没有发送者可以单方面改变策略使得自身效用函数得到提升时, $a^* = (a_1^*, \dots, a_n^*, \dots, a_N^*)$ 被认为是所提多发送者预测与计算卸载博弈 \mathcal{G} 的纳什均衡,如公式(16)所示。

$$\begin{aligned} u_n(a_n^*, a_{-n}^*) & \geq \\ u_n(a_n, a_{-n}^*), & \forall n \in \mathcal{N}, a_n \in \mathcal{A}_n. \end{aligned} \quad (16)$$

定义2(精确势能博弈):若存在势能函数 $\phi(a_n, a_{-n})$ 使得公式(17)成

立,则所提多发送者预测与计算卸载博弈 \mathcal{G} 为精确势能博弈。

$$\begin{aligned} u_n(a_n^+, a_{-n}) - u_n(a_n, a_{-n}) &= \\ \phi(a_n^+, a_{-n}) - \phi(a_n, a_{-n}) & \\ \forall n \in \mathcal{N}, a_n^+ \in \mathcal{A}_n & \quad (17) \end{aligned}$$

公式(17)表示任意发送者策略变化引起的效用函数变化量等于势能函数变化量。

定理1:所提多发送者预测与计算卸载博弈 \mathcal{G} 为精确势能博弈,且最优的联合预测窗口和计算卸载策略为博弈 \mathcal{G} 的纯策略纳什均衡。

证明:定义势能函数为所有发送者的总预测效益,如公式(18)所示。

$$\phi(a_n, a_{-n}) = \sum_{n \in \mathcal{N}} \delta_n(a_n, a_{-n}) \quad (18)$$

当发送者 n 的策略从 a_n 改变为 a_n^+ 时,发送者 n 效用函数的变化量可以表示为:

$$\begin{aligned} u_n(a_n^+, a_{-n}) - u_n(a_n, a_{-n}) &= \\ \delta_n(a_n^+, a_{-n}) - \delta_n(a_n, a_{-n}) &+ \\ \sum_{i \neq n} (\delta_i(a_i, a_{-i}^+) - \delta_i(a_i, a_{-i})) &- \\ \sum_{i \neq n} (\delta_i(a_i, a_{-i}^+) - \delta_i(a_i, a_{-i})) & \quad (19) \end{aligned}$$

因为 $\delta_i(a_i, a_{-i}^+)$ 为不考虑发送者 n 策略时发送者 i 的预测效益,所以即使发送者 n 的策略从 a_n 改变为 a_n^+ , $\delta_i(a_i, a_{-i}^+) = \delta_i(a_i, a_{-i})$ 依然成立。公式(19)可以进一步表示为:

$$\begin{aligned} u_n(a_n^+, a_{-n}) - u_n(a_n, a_{-n}) &= \\ \delta_n(a_n^+, a_{-n}) + \sum_{i \neq n} \delta_i(a_i, a_{-i}^+) &- \\ \{\delta_n(a_n, a_{-n}) + \sum_{i \neq n} \delta_i(a_i, a_{-i})\} &= \\ \phi(a_n^+, a_{-n}) - \phi(a_n, a_{-n}) & \quad (20) \end{aligned}$$

可以看出,所提多发送者预测与计算卸载博弈 \mathcal{G} 为精确势能博弈。对于精确势能博弈,势能函数的最大值为博弈 \mathcal{G} 的纯策略纳什均衡^[1],

因此定理1得证。

2.4 基于最优响应的预测与计算卸载联合优化算法

如算法1所示,我们提出了一种基于最优响应^[12]的预测与计算卸载联合优化算法来获得所提博弈的纳什均衡解。具体地,在每次迭代中,只有一个发送者 n 被随机选择来更新其策略。在发送者 n 计算自身效用函数时,需要知道其他发送者的策略,这意味着策略的更新需要发送者之间的信息交互。一般而言,信息交互可以通过公共信道广播来实现。在每次算法迭代时,只有被随机选出的发送者更新策略,其他发送者将保持他们的策略不变。因此,在迭代过程中由信息交互导致的信令开销非常有限。

算法1 基于最优响应的预测与计算卸载联合优化算法

- 1:初始化 $t = 0$,根据公式(14)中约束条件 C1 和 C2 确定预测窗口的下界 w_n^{\min} 和上界 w_n^{\max} 。初始化每个发送者的策略 $a_n = \{x_n, w_n\}$, 其中 $x_n \in \{0, 1\}$, $w_n^{\min} \leq w_n \leq w_n^{\max}$ 。每个发送者在公共信道上广播其初始策略。
- 2:随机选择一个发送者,将其记为 n 。发送者 n 计算策略空间 A_n 中每一个策略对应的效用函数值,即 $u_n(a_n, a_{-n}), \forall a_n \in A_n$ 。其他发送者的策略保持不变。
- 3:在 $t + 1$ 时刻,发送者 n 选择策略空间中效用函数值最大的策略。
 $a_n(t + 1) = \arg \max_{a_n \in A_n} u_n(a_n, a_{-n}(t))$ (21)
 发送者 n 在公共信道上广播其更新后的策略。如果存在多个策略使得效用函数达到最大值,则从多个策略中随机选择一个策略。
- 4:如果运行到达了最大迭代次数,则

算法终止,否则返回步骤2。

定理2:算法1可以收敛到所提多发送者预测与计算卸载博弈的纳什均衡解。

证明:由定理1可知,所提多发送者预测与计算卸载博弈 \mathcal{G} 为精确势能博弈,因此发送者策略变化引起的效用函数变化量等于势能函数变化量。由于在算法每次迭代中,发送者的策略更新总是可以使其效用函数值得到增加,相应地,势能函数值也在不断增加。由于发送者的策略空间为有限空间,因此,算法1可以在有限的迭代次数中收敛到势能函数的局部最优解或者全局最优解,即所提多发送者预测与计算卸载博弈的纳什均衡解。

算法1的复杂度主要由发送者的效用函数计算过程决定。具体地,在每次迭代中,发送者需要计算策略空间 A_n 中每一个策略对应的效用函数值。由于 $x_n \in \{0, 1\}$, $w_n^{\min} \leq w_n \leq w_n^{\max}$, 因此每次迭代的复杂度为 $2(w_n^{\max} - w_n^{\min} + 1)$ 。令 T_{\max} 为最大的迭代次数,则算法1的复杂度为 $\mathcal{O}(T_{\max}(w_n^{\max} - w_n^{\min} + 1))$ 。

3 数值仿真结果

3.1 基于LSTM神经网络的触觉动作预测模型

本节首先对基于LSTM神经网络的触觉动作预测模型进行仿真分析。该模型采用两层LSTM隐藏层结构,每层神经元个数分别设置为80和100,预测所需要的历史数据量 T_0 为1000。图5给出了训练次数分别为10、20和30的预测误差曲线。随着预测窗口的增加,每条曲线的预测误差都不断增加。这是因为预测窗口越大,由LSTM所引发的预测误差传

播对后续的触觉动作预测影响就越大。此外,训练次数的增加并不一定会降低预测差错概率,这是因为训练次数过多可能导致过拟合的现象。因此,在后续仿真中,我们设置训练次数为20。

3.2 基于最优响应的预测与计算卸载联合优化算法

这里,我们对算法1的性能进行仿真分析。仿真参数设置如下:发送者数目 N 为12,预测一个传输间隔需要的计算资源 μ 为 10^6 转,边缘服务器计算资源 V_B 为 20×10^9 转/s,每个发送者的计算资源 V_n 服从随机分布 $[2,3] \times 10^9$ 转/s,传输间隔 t_0 为1 ms,能效权重系数 τ_0 为 0.12×10^{-9} 。由公式(14)中的约束条件C1和C2可知,触觉通信中的预测窗口下界 w_n^{\min} 和上界 w_n^{\max} 需要结合主域、核心网以及控制域的传输时延和传输差错概率共同求得。在仿真中,为便于算法1的仿真分析,我们设 w_n^{\min} 和 w_n^{\max} 分别为5和20,即 $w_n \in [5,20]$ 。

图6分析了算法1的收敛性。随着迭代次数的增加,系统总预测效益不断增加,并最终达到收敛。需要注意的是,所提算法只能收敛到局部最优解,并不能保证收敛到全局最优方案。算法1的优势在于复杂度较低,

且可以以较快的收敛速度达到接近最优方案的性能。

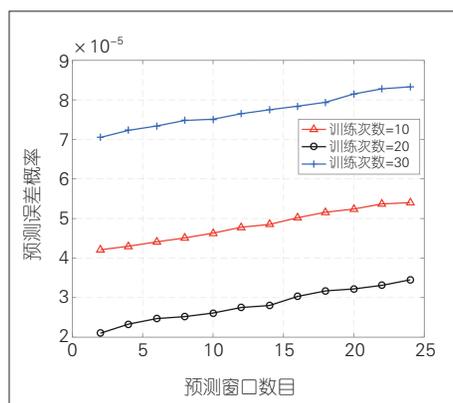
图7分析了系统总预测效益与发送者数目的关系。其中,“服务器卸载”是指所有发送者都采用服务器卸载策略,由公式(9)可知,此时每个发送者都采用最大预测窗口以使总预测效益最大;“本地卸载(最大窗口)”是指所有发送者都采用本地卸载策略,且预测窗口都采用最大值;“本地卸载(最优窗口)”是指所有发送者都采用本地卸载策略,且预测窗口都采用最优值;“随机卸载”是指每个发送者的卸载策略和预测窗口都随机分配。

首先,随着发送者数目的增加,所提算法的系统总预测效益不断增加,且优于其他方案的性能。这验证了所提算法的可行性和优越性。其次,当发送者数目较小时,服务器卸载方案性能优于本地卸载方案性能。这是因为:一方面,服务器的能耗可以忽略不计;另一方面,当发送者数目较小时,每个发送者从服务器获得的计算资源较多,从而预测所耗时延也就越低。然而,当发送者数目不断增加时,服务器卸载方案性能先增加而后逐渐降低,且性能劣于本地卸载方案。这是因为随着发送者数目的增加,每个发送者从服务器获得的计

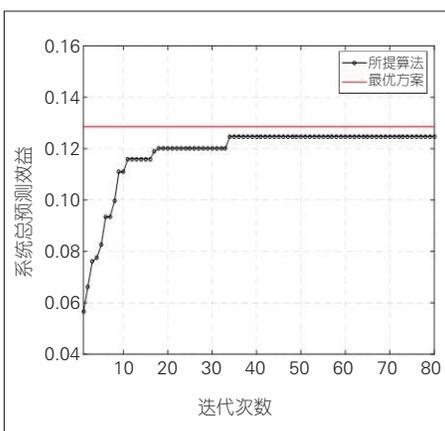
算资源逐渐减少,预测所需的时延也就越多,进而导致总体预测效益逐渐降低。最后,不管发送者数目是多少,本地卸载(最优窗口)方案的性能都优于本地卸载(最大窗口)方案的性能。这验证了优化预测窗口可以有效提升发送者的预测效益。

图8分析了系统总预测效益与能效权重系数的关系。可以看出,除服务器卸载方案外,其他方案的系统总预测效益都会随着能效权重系数的增加而不断降低。这是因为能效权重系数越大,预测效益就越低。而对于服务器卸载方案,其能效可以忽略不计,所以总预测效益不受能效权重系数的影响。此外,当能效权重系数较小时,本地卸载(最优窗口)方案与本地卸载(最大窗口)方案的性能相同,这说明此时最大预测窗口就是最优预测窗口。而随着能效权重系数的增加,本地卸载(最优窗口)方案逐渐优于本地卸载(最大窗口)方案的性能,且性能差距逐渐增大。

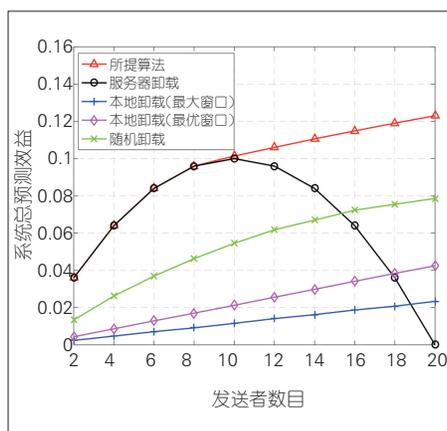
图9分析了系统总预测效益与服务器计算资源的关系。除本地卸载策略下,其他方案的总预测效益都随着服务器计算资源的增加而不断增加。这是因为当服务器计算资源不断增加时,发送者采用服务器卸载策略可以分配的计算资源就越多,预测



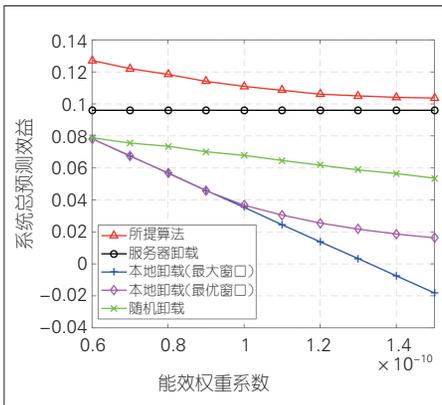
▲图5 基于长短期记忆神经网络的预测误差与预测窗口关系



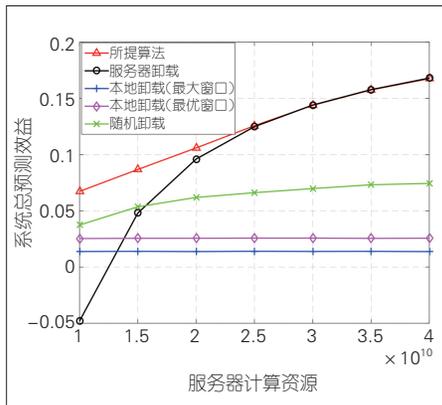
▲图6 算法1收敛性分析



▲图7 系统总预测效益与发送者数目的关系



▲图8 系统总预测效益与能效权重系数的关系



▲图9 系统总预测效益与服务器计算资源的关系

所耗时延会不断降低,预测效益就会不断增加。对于本地卸载方案,其总预测效益与服务器计算资源没有关系。当服务器计算资源较低时,本地卸载方案的性能优于服务器卸载方案。当服务器计算资源逐渐增加时,服务器卸载方案的性能逐渐超过本地卸载方案,且逐渐趋于所提算法。

4 结束语

本文构建了联合预测和边缘计算的触觉通信框架以满足触觉通信的超低时延要求,其核心思想是根据优化的预测窗口大小,采用基于LSTM神经网络预测模型来预测发送者未来时刻的动作,并通过引入边缘计算激励发送者在本地和边缘服务器之间自主选择计算卸载策略。此外,本文明晰了时延和能耗之间的折衷关系,并由此定义了发送者的预测效益;为便于求解,通过势能博弈对优化问题转化,并提出一种基于最优响应的预测与计算卸载联合优化算法,以分布式、低复杂度的方式获得近乎最优的预测窗口和计算卸载策略。

参考文献

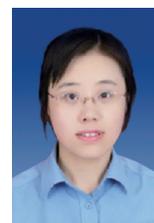
- [1] AIJAZ A, DOHLER M, AGHVAMI A H, et al. Realizing the tactile Internet: haptic communications over next generation 5G cellular networks [J]. IEEE wireless communications, 2017, 24(2): 82–89. DOI: 10.1109/MWC.2016.1500157RP
- [2] ANTONAKOGLU K, XU X, STEINBACH E, et al. Toward haptic communications over the 5G tactile Internet [J]. IEEE communications surveys & tutorials, 2018, 20(4): 3034–3059. DOI: 10.1109/COMST.2018.2851452
- [3] BI J, ZHANG X, YUAN H T, et al. A hybrid prediction method for realistic network traffic with temporal convolutional network and LSTM [J]. IEEE transactions on automation science and engineering, 2021, 19(1): 1–11. DOI: 10.1109/TASE.2021.3077537
- [4] MACKENZIE J, RODDICK J F, ZITO R. An evaluation of HTM and LSTM for short-term arterial traffic flow prediction [J]. IEEE transactions on intelligent transportation systems, 2019, 20(5): 1847–1857. DOI: 10.1109/TITS.2018.2843349
- [5] KANNAN S, YENGERA G, MUTTER D, et al. Future-state predicting LSTM for early surgery type recognition [J]. IEEE transactions on medical imaging, 2020, 39(3): 556–566. DOI: 10.1109/TMI.2019.2931158
- [6] LI E, ZENG L K, ZHOU Z, et al. Edge AI: on-demand accelerating deep neural network inference via edge computing [J]. IEEE transactions on wireless communications, 2020, 19(1): 447–457. DOI: 10.1109/TWC.2019.2946140
- [7] LIANG F, YU W, LIU X, et al. Toward edge-based deep learning in industrial Internet of Things [J]. IEEE Internet of Things journal, 2020, 7(5): 4329–4341. DOI: 10.1109/JIOT.2019.2963635
- [8] 吴学文, 廖婧贤. 云边协同系统中基于博弈论的资源分配与任务卸载方案 [J]. 系统仿真学报, 2021. DOI: 10.16182/j.issn1004731x.joss.21-0077

- [9] BACCI G, LASAULCE S, SAAD W, et al. Game theory for networks: a tutorial on game-theoretic tools for emerging signal processing applications [J]. IEEE signal processing magazine, 2016, 33(1): 94–119. DOI: 10.1109/MSP.2015.2451994
- [10] FANG T, YUAN F, AO L, et al. Joint task offloading, D2D pairing and resource allocation in device-enhanced MEC: a potential game approach [J]. IEEE Internet of Things journal, 2021, 8(1): 1–11. DOI: 10.1109/JIOT.2021.3097754
- [11] DU Y Q L, CHEW Y H, SOONG B H. Potential game theory applications in radio resource allocation [M]. Berlin: Springer International Publishing, 2016
- [12] XU Y H, WANG C G, CHEN J H, et al. Load-aware dynamic spectrum access for small-cell networks: a graphical game approach [J]. IEEE transactions on vehicular technology, 2016, 65(10): 8794–8800. DOI: 10.1109/TVT.2015.2508998

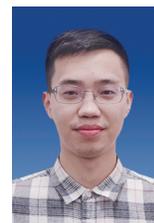
作者简介



吴岩, 陆军工程大学在读博士研究生; 主要研究领域为跨模态通信、D2D 内容共享; 发表论文4篇。



吴丹, 陆军工程大学副教授、国家优秀青年基金获得者; 主要研究领域为跨模态通信、D2D 内容共享、协同通信; 先后主持国家自然科学基金项目10余项; 获中国通信学会科学技术奖一等奖、教育部自然科学奖二等奖等多项科研奖励; 发表论文20余篇。



王嵩, 陆军工程大学在读硕士研究生; 主要研究领域为触觉通信、资源管理; 发表论文1篇。