

时空数据驱动的智能家居服务管控方法

陈佳雯^{1, 2, 3}, 陈金荣^{1, 2, 3}, 陈星^{1, 2, 3*}, 莫毓昌⁴

¹ (福州大学计算机与大数据学院, 福州 350116)

² (大数据智能教育部工程研究中心, 福州 350002)

³ (福州大学福建省网络计算与智能信息处理重点实验室, 福州 350116)

⁴ (华侨大学数学科学学院 计算科学福建省高校重点实验室, 泉州 362021)

摘要: 针对目前智能家居服务管控技术存在的标准缺失和用户需求多样化的问题, 该文提出了一种时空数据驱动的智能家居服务管控方法。该方法包括构建智能家居时序知识图谱和基于联邦学习的智能家居服务管控方法。通过记录智能家居场景中概念实例的状态, 时序知识图谱提供了环境变化和服务状态的时序数据支持。通过联邦学习算法, 结合不同家庭的模型参数, 实现个性化模型更新和预测智能家居服务状态。实验结果表明, 该方法能够有效地管控智能家居设备并准确满足用户需求, 具有高准确度和较快的收敛速度。

关键词 智能家居; 知识图谱; 运行时模型; 联邦学习; 物联网

中图分类号: TP311 文献标志码 A doi: 10.12146/j.issn.2095-3135.20230921001

A Spatio-Temporal Data-Driven Control Method for Smart Home Service

CHEN Jiawen^{1,2,3}, CHEN Jinrong^{1,2,3}, CHEN Xing^{1,2,3*}, MONG Yuchang⁴

¹ (College of Computer and Data Science, Fuzhou University, Fujian Fuzhou, 350108, China)

² (Engineering Research Center of Big Data Intelligence, Ministry of Education, Fuzhou, 350002, China)

³ (Fujian Key Laboratory of Network Computing and Intelligent Information Processing (Fuzhou University), Fuzhou, 350116, China)

⁴ (Fujian Province University Key Laboratory of Computational Science, School of Mathematical Sciences, Huaqiao University, Quanzhou, 362021, China)

Corresponding Author: Xing Chen. Computer and Data Science College of Fuzhou University, Fujian Fuzhou, 350108 China. Email: chenxing@fzu.edu.cn.

Abstract: The absence of unified standards among smart device brands hinders collaborative management, as it requires dealing with different interfaces and communication protocols of each device, thus complicating the implementation of smart home service management. Moreover, the personalized differences due to lifestyle habits, climate conditions, and other factors also make it difficult for pre-set management rules to meet various requirements. To address these challenges, a spatial-temporal data-driven method for smart home service management is studied in this work. The method involves constructing a temporal knowledge graph for smart homes and utilizing a federated learning-based approach for smart home service management. By recording the state of concept instances in smart home scenarios, the temporal knowledge graph provides temporal data for environmental changes and service statuses. Through federated learning algorithms that

来稿日期: 2023-09-21 修回日期: 2023-12-12

基金项目: 国家自然科学基金项目(62072108); 福厦泉国家自主创新示范区协同创新平台项目(2022FX5); 福建省财政厅科研专项经费(83021094); 福建省科技经济融合服务平台(2023XRH001); 福建省促进海洋与渔业产业高质量发展专项资金(FJHYF-ZH-2023-02)

作者简介: 陈佳雯, 硕士研究生, 研究方向为软件自适应、知识图谱; 陈金荣, 硕士研究生, 研究方向为智能家居、软件自适应; 陈星(通讯作者), 教授, 研究方向为软件自适应、软件工程、服务计算, E-mail: chenxing@fzu.edu.cn; 莫毓昌, 教授, 博士生导师, 研究方向为利用组合模型对复杂系统和网络进行可靠性分析。

incorporate model parameters from different households, personalized model updates and predictions of smart home service statuses are achieved. Experimental results showed that this method can effectively manage smart home devices, accurately meet user demands with satisfied accuracy and rate of convergence.

Key words: Smart Home; Knowledge Graph; Runtime Model; Federated Learning; Internet of Things

Funding: This project is supported by National Natural Science Foundation of China under Grant (62072108), Fuzhou-Xiamen-Quanzhou National Independent Innovation Demonstration Zone Collaborative Innovation Platform under Grant (2022FX5), the Funds for Scientific Research of Fujian Provincial Department of Finance under Grant (83021094), Fujian Province Technology and Economy Integration Service Platform under Grant (2023XRH001) and Special Funds for Promoting High-quality Development of Marine and Fishery Industries in Fujian Province under Grant (FJHYF-ZH-2023-02).

1 引言

随着基础设施的不断发展和各种智能家居设备的普及,智能设备逐渐融入人们的日常生活。智能家居通过提供多样化的服务为人们带来便利^[1]。然而,目前智能家居服务面临着两大挑战:缺乏统一标准和用户个性化需求。不同厂商的智能设备之间缺乏互通性,用户必须安装特定品牌的应用程序才能控制对应的智能设备^[2]。

在智能设备环绕的家居环境中生活,人们对智能家居服务的期望自然提升。在快速发展的技术时代,简单的设备控制已经失去竞争力,用户期望更智能、无感知、个性化的服务^[3]。然而,要实现更智能的服务,需要设备之间具备协同合作的能力。例如,当用户离开卧室进入客厅时,希望卧室的空调自动关闭并打开客厅的空调,这就需要卧室和客厅的空调与用户的定位设备进行联动。另外,为了满足不同场景下的复杂需求,需要对设备进行更高级别的抽象,并编写相应的服务程序。此外,不同用户有着个性化的需求,例如对温度接受程度不同,所需开启空调的临界温度也不同。为了满足用户的个性化需求,现有解决方案往往是让用户预先设定设备控制规则^[3]。

然而,现有的智能家居服务存在一些问题。首先,不同厂商和型号的智能家居设备往往无法协同工作,这主要是因为每个厂商都致力于构建自己的生态系统,缺乏互操作性,难以形成一体化的智能家居体验。此外,不同设备的异构特性对于开发者在设备互联和协同管理方面提出了巨大挑战^[4,5]。其次,现有设备的控制方式主要依赖用户通过终端设备远程操控或预先配置规则来提供服务。远程操控并没有真正实现智能化,仍需要用户手动发出指令。虽然预先配置规则在一定程度上实现了智能化,但僵化的规则无法适应复杂多变的环境。另外,大量的规则配置过程对用户使用智能家居带来一定门槛和学习成本,甚至部分智能家居系统需要用户投入大量时间和精力学习规则配置^[6]。最后,用户通常根据周围环境状态提出服务需求,这使得个性化的智能家居服务离不开对用户周围环境和其变化的感知。因此,建立智能家居与环境知识之间的联系以提供实时灵活的定制服务对于智能、无感知、个性化的智能家居服务至关重要。

然而仅有各个设备的信息,无法很好地表示用户周围的环境信息。前期工作通过引入知识图谱对设备进行建模^[7],将每个智能家居设备提供的功能抽象为多个具有单一功能的服务,并通过一系列的语义规则构造出用户可感知的环境。基于上述概念可以反映用户周边可感知的环境状态和设备状态,并通过运行时知识图谱实现设备的控制。通过现有的知识图谱模型可以实现一些基于固定规则的服务,然而正如前文所述,除了规则的配置十分繁琐外,预先配置的规则没有考虑到用户行为的上下文信息,往往无法很好的满足用户多变且复杂

的智能化、个性化需求。

为了应对上述挑战,本文提出一种时空数据驱动的智能家居服务管控方法。该方法利用智能家居时序知识图谱收集用户行为数据,并构建训练数据集。通过联邦平均算法^[7,8],交换不同家庭的模型参数构建出全局模型,并利用用户的本地数据对全局模型进行更新,得到个性化模型。进而,根据用户感知的环境状态和服务状态时序数据,借助时序知识图谱完成对应设备的控制,实现智能化、个性化的智能家居服务管控。仿真实验结果表明,本文的智能家居时序知识图谱能够高准确度地对智能家居设备进行管控,并根据不同家庭偏好实现个性化管控,服务管控准确度达到 90% 以上,同时能够加快新家庭加入时模型的收敛速度。

2 相关工作

智能家居是物联网系统的一个重要应用场景,如何实现更加智能的智能家居自动化系统一直受到学术界和工业界的广泛关注。智能家居系统在能源消耗、健康监护方面一直有较多的研究。Khan 等^[9]提出在智能家居系统中对传感器数据历史进行分析实现水泵负载的预测。Forbes 等^[10]提出将智能家居系统的和行为识别用于居家健康检测。

智能家居系统是建立各种传感器和提供智能家居服务的智能设备之上的,而如何解决异构设备间的通信问题,以及如何将具体设备和上层应用解耦,降低开发的复杂度是包括智能家居在内所有物联网应用无法避免的问题。目前解决该问题的普遍做法是加入中间件层^[11]。Hu 等人^[12]设计了一个开放的 IoT 系统架构,将物理设备抽象为软件,从而将物联网应用与具体物理设备进行解耦,实现了对设备资源的动态配置和优化。Filho 等^[13]提出了一种基于雾计算范例的智能决策系统,该系统通过加入一层基于 MQTT^[14]的消息队列层来处理异构设备的编程接口和连接方式的差异。

为了进一步支持智能家居应用的服务组装,一些研究提出将基于知识推理的方法应用到智能家居服务管控中,以提供语义化的物联网设备服务。Tao 等人^[15]设计了一个通用的智能家居领域本体模型,研究了基于本体的语义推理和特定的语义匹配规则。Xie 等人^[16]提出了一种基于知识图谱的多层物联网中间件,引入了一个中间层来解决具有不同通信协议的物联网设备之间的差异。但这些研究没有考虑用户需求与底层语义模型和物联网服务之间的联系,难以满足用户的个性化需求。

除了上述提到的异构性问题外,如何在智能家居系统中提供更加个性化、智能化、无感化的服务已经成为了新的研究热点^[6,17]。Jin 等^[18]提出了基于深度学习的个性化室内温度控制系统,但是其适用范围仅限于智能家居中的温度控制服务,无法用于其他智能家居设备和服务。Deephome^[19]基于深度学习,从用户的历史记录中学习行为习惯并预测用户行为,为用户自动执行设备操作。Deephome 较好的实现了智能化、无感化服务,但是其仅针对高度定制化的智能家居环境。Yu 等人^[20]提出从用户的上下文数据中学习智能家居访问控制规则以防范针对智能家居设备的攻击,并通过联邦学习解决数据量不足和设备多样性的问题。A v odji 等人^[21]提出了一种新的智能家居架构,专注于安全和隐私方面,但其专注于提供数据安全的智能家居框架,不能给用户提供个性化的智能家居服务管控。

以上基于深度学习、联邦学习等机器学习技术的方法虽然能够为用户提供个性化的控制,但是这些方法都依赖大量用户数据训练模型,没有考虑到单个家庭智能家居场景下会遇到的用户数据量不足的情况。

3 方法整体框架

为了实现更加智能化本文提出时空数据驱动的智能家居服务执行方法,图 1 给出该方法的整体框架。本方法是对前期工作^[22]的扩展,通过学习用户的历史行为记录,预测用户未来可能的行为,自动为用户操作智能家居设备。该方法包括两个部分:第一部分是智能家居时序知识图谱构造方法,通过将具体设备与上层管控逻辑解耦,以服务的形式统一管理智能

家居设备功能，并支持用户感知的环境变化和服务状态时序数据；第二部分是基于时序知识图谱的差异化、个性化智能家居服务管控，为不同用户提供个性化的智能家居服务。这两部分方法只需要基本情境知识、概念实例和智能设备关联关系以及少量用户行为数据，即可构建个性化的管控模型，提供智能化、个性化的智能家居服务管控。

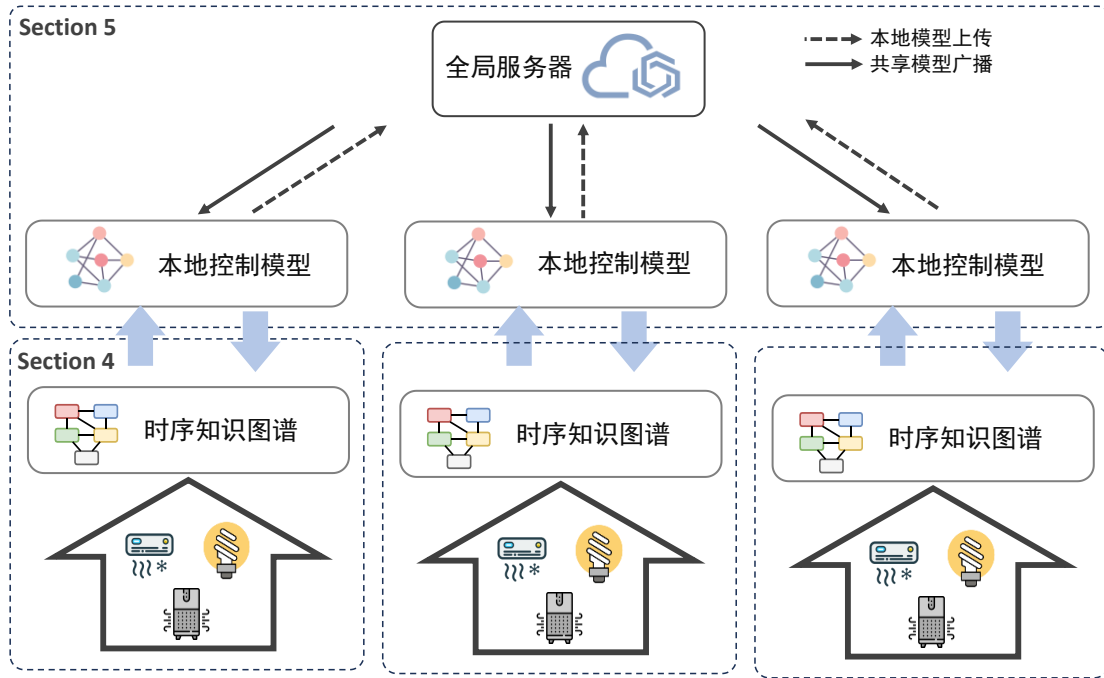


图 1 时空数据驱动的智能家居服务管控方法概览

Fig. 1 Overview of Spatio-Temporal Data-Driven Intelligent Home Service Control Method

3.1 智能家居时序知识图谱

首先，智能家居知识图谱概念模型是对智能家居场景中的用户、智能设备、环境状态和它们之间的关联关系等进行抽象建模。智能家居知识图谱概念模型定义了核心概念（“用户”、“位置”、“设备”、“服务”、“环境”）和概念之间的关系（“位于”、“感知”、“提高”、“降低”、“设值”、“监测”），将智能设备和家庭中的住户等实体表示为概念实例，以服务的形式表示智能家居设备功能。接着，提出通过智能家居知识图谱运行时建模方法，介绍如何基于面向场景的情境知识、概念实例与智能设备的映射关系和服务对象基本信息自动构建智能家居知识图谱实例模型。在场景状态发生变化时，利用运行时模型方法自动更新对应的智能家居知识图谱实例模型，并将对服务状态的改变转换为对应的智能设备状态改变，实现现实世界和概念模型之间的双向同步。通过对智能家居知识图谱概念模型中各实例状态的记录，将智能家居运行时知识图谱拓展到时间维度，提供用户感知的环境变化和服务状态的时序数据支持。

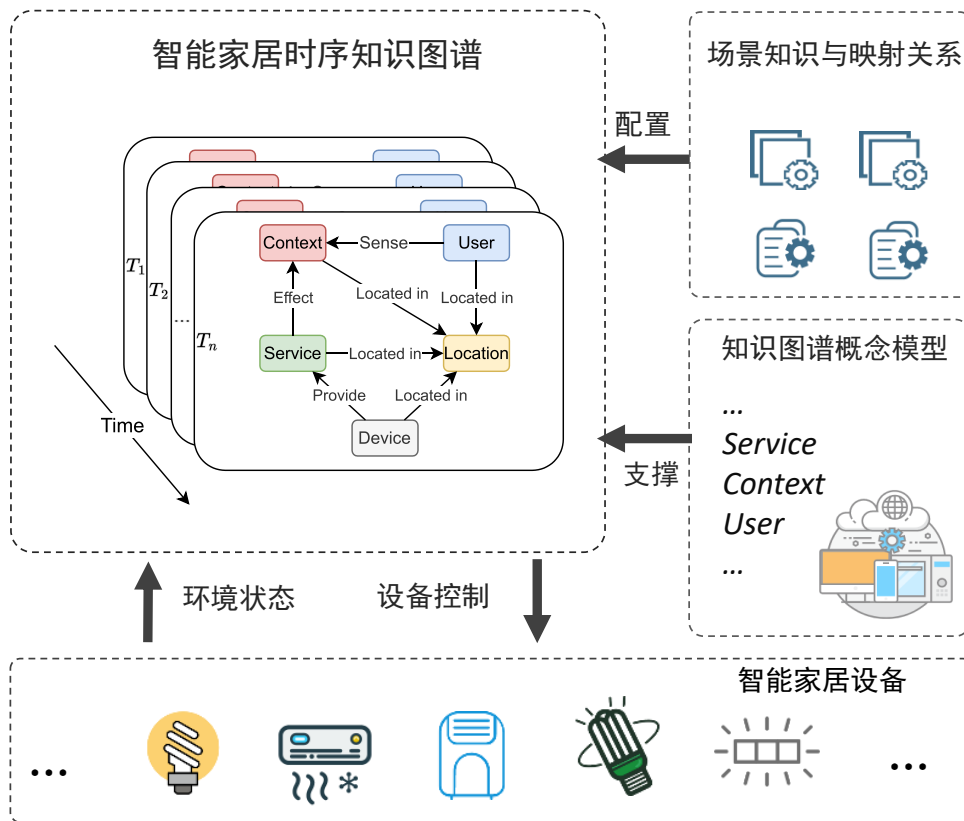


图 2 智能家居时序知识图谱构造方法

Fig. 2 Construction Method of Intelligent Home Temporal Knowledge Graph

3.2 基于联邦学习的智能家居服务管控方法

该方法通过一个全局服务器（Server）和多个本地家庭客户端（Client）构成。如图 3 所示，在联邦模型训练过程中，首先在服务器上初始化全局模型（Global Model），然后开始服务器和客户端之间的迭代训练流程，为多个家庭构建智能家居服务管控模型。迭代训练的步骤如下：（1）服务器将全局模型广播给各个客户端；（2）各个客户端使用用户行为数据对本地模型进行训练，并更新本地模型参数；（3）每个客户端将更新后的参数上传至服务器；（4）服务器收集各个客户端的参数并聚合，得到新的全局模型参数。通过迭代步骤（1）到步骤（4），得到面向所有家庭的泛化模型。最后，各个家庭根据自身的个性化需求，利用本地收集的行为数据对模型进行额外的参数更新。通过这一额外的本地模型更新步骤，得到的个性化模型可以更好地适应用户的差异化需求。完成个性化模型的训练后，可以借助时序知识图谱获取相应的用户感知数据，并根据智能家居时序知识图谱来决策相应的服务状态，并实现对智能家居设备的管控。

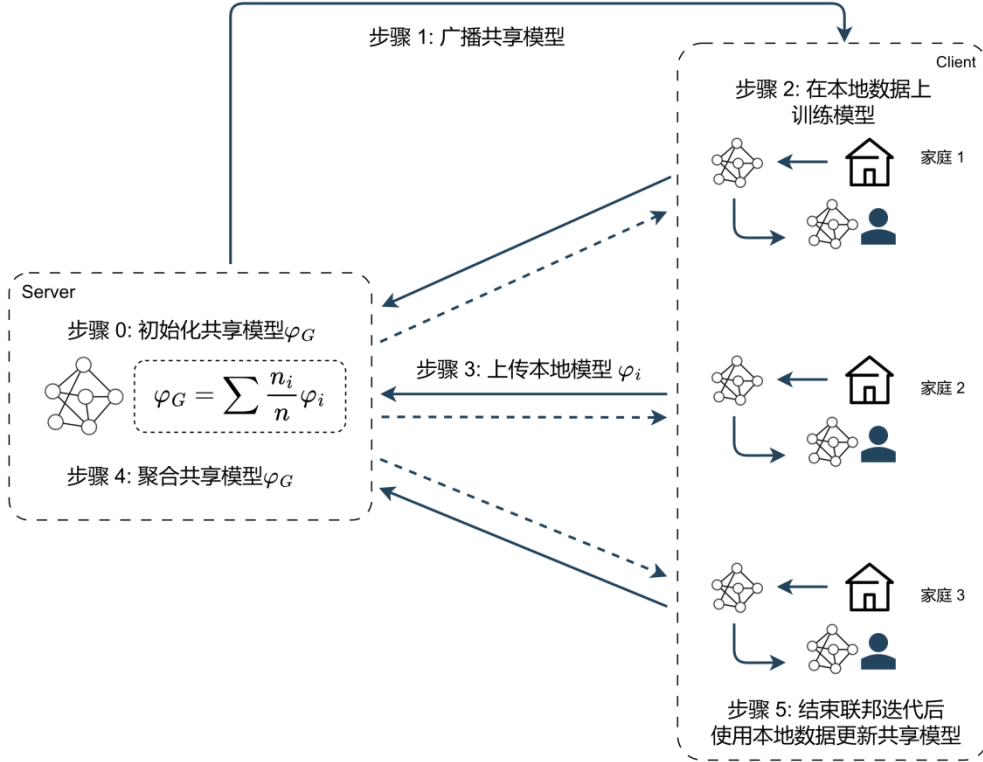


图 3 基于联邦学习的智能家居服务管控方法

Fig. 3 Federated Learning Based Intelligent Home Service Control Method

4 智能家居知识图谱运行时建模方法

4.1 智能家居情境感知时序知识图谱模型

智能家居情境感知运行时知识图谱是我们的先前工作^[18]，这里对运行时知识图谱的核心概念进行介绍。智能家居时序知识图谱模型如图 2 中的智能家居时序知识图谱模型模块所示。该模型在时间维度上对先前工作运行时知识图谱模型的拓展，除了描述智能家居个性化方案中涉及的概念和概念间的关系外，还能够表示在一定时间段内概念实例和关系的变化过程。

时序知识图谱可以被理解为具有时间标签的知识图谱流(KG Stream)，即知识图谱在给定时间段 $\{T_1, \dots, T_n\}$ 内时间间隔为 ΔT 的状态集合，每个时间点的数据包括该时间点的知识图谱状态 KG^k 和时间标签 T^k ，可以完整描述对应时刻的智能家居场景状态，包括用户的位置信息、用户可感知的环境状态信息、各个智能设备的状态信息等。

为构造上述时序知识图谱，首先需要将概念实例的状态拓展到时间维度，并定义符号 X_i^t 表示某个概念实例 X_i 在 t 时刻的状态， X^t 表示概念实例 X_i 在 t 时刻的状态集合，如 U^t 表示用户实例 U_i^t 在 t 时刻的状态集合， C^t 表示环境实例 C_j^t 在 t 时刻的状态集合， S^t 表示服务实例 S_k^t 在 t 时刻的状态集合， L^t 表示位置实例 L_l^t 在 t 时刻的状态集合， D^t 表示位置实例 D_m^t 在 t 时刻的状态集合。根据 t 时刻各类型状态实例集合定义，将其聚合在一起即可得到 t 时刻的所有概念实例状态集合 $CSet^t$ ，定义为：

$$CSet^t = \{U^t, L^t, S^t, C^t, D^t\} \quad (1)$$

Relation 代表概念之间的关系集合，在图 2 中表示为带标签的箭头，如“Locate”关系、“Sense”关系等。 $relation^t$ 表示 t 时刻下概念实例之间的关系。从而可以在概念实例集合基础上构造 t 时刻的关系实例集合 $RSet^t$ ，定义为：

$$RSet^t = \{X_i^t \xrightarrow{relation^t} Y_i^t \mid X_i^t \in CSet^t, Y_i^t \in CSet^t, relation^t \in Relation\} \quad (2)$$

基于上述时序定义， t 时刻的智能家居知识图谱状态可以通过 $CSet^t$ 和 $RSet^t$ 定义，记为 KG^t ：

$$KG^t = \langle CSet^t, RSet^t \rangle \quad (3)$$

最后得到时序知识图谱（Temporal Knowledge Graph, 简记 TKG）模型，定义为：

$$TKG = \langle KG^1, KG^2, \dots, KG^n \rangle \quad (4)$$

4.2 基于时序知识图谱的智能家居管控模型

为了能够更好的实现对智能家居服务的管控，需要将关注点仅放在用户所能感知的环境状态上。同时需要注意到，用户在智能家居环境中的位置会因用户的活动而不断变化，因此用户所能感知的环境状态必然是基于时间变化而不同。

在智能家居时序知识图谱模型中，要获得用户周围一段时间内的环境状态变化，首先需要获取用户 U_i 所在空间位置信息 $U_i.LocName$ ，需满足条件 $C_j.LocName = U_i.LocName$ 的

Context 实例 C_j ，记为用户敏感的环境 $C_j(U_i \xrightarrow{Sense} C_j)$ ，即为用户所能感知的环境。接着，

可以通过时序知识图谱获取 C_j 最近的历史状态数据，即为用户周围一段时间内的环境状态变化，将其定义为：

$$History(C_j, t, k) = \langle C_j^t, C_j^{t-1}, \dots, C_j^{t-k+1} \rangle \quad (5)$$

其中 t 为当前时间、 k 为时间窗口长度。

在智能家居时序知识图谱模型中，要调控用户感知到的环境状态，可通过控制智能家居设备功能，影响用户敏感的环境 C_j ，例如，想降低温度可通过调控空调的制冷功能，增加湿度则可通过操作加湿器的加湿功能。时序知识图谱模型将智能设备功能抽象为服务实例对象，操作通过改变服务状态完成。若存在关系 $S_k \xrightarrow{Effect} C_j$ ，则能够影响环境 C_j 的服务实例 S_k 。

智能设备状态 S_k^t 是服务实例 S_k 当前的状态，用户对智能设备功能的操作可以表示为服务 S_k^t 状态改变，即下一时刻的状态 S_k^{t+1} 。因此，本文将服务管控模型的输入包括用户敏感

环境状态的时序数据 $History(C_j, t, k)$ 和敏感服务实例当前状态 S_k^t ；输出为敏感服务实例 S_k

下一时刻的状态决策 S_k^{t+1} ，如图 4 所示。




图 4 服务管控模型定义

Fig. 4 Definition of Service Control Model

5 基于联邦学习的智能家居服务管控模型

本文采用的联邦模型训练方法基于联邦平均算法^[23] (FedAvg) 对基于 DNN 的管控模型进行训练, 并针对不同用户的个性化的需求做了一些改进。在本文方法中, 每个家庭有一个与全局模型有所不同的个性化服务管控模型, 该模型以通过联邦学习和其他家庭协作训练得到模型全局模型为基础, 进一步使用用户本地的数据进行更新, 以捕捉用户的个性化需求, 构建不同家庭与全局服务器之间协作训练模型。具体的模型训练过程如下所示。

算法: 基于联邦学习的智能家居服务管控模型构建过程

Input: 各个家庭的数据集 ($Dataset_1, Dataset_2, \dots, Dataset_n$)

Output: 共享模型 ϕ_G 和各个家庭的模型 $\phi = (\phi_1, \phi_2, \dots, \phi_n)$

- 1: 初始化全局服务器中各类型服务管控模型参数 ϕ_G
 - 2: 初始化各家庭本地服务管控模型参数: $\phi_i \leftarrow \phi_G$
 - 3: **for** communication episode = 1, Max communication episodes **do**
 - 4: **for** each home of all homes in parallel **do**
 - 5: 执行本地模型训练 LocalUpdate($Dataset_i, \phi_i$)
 - 6: **end**
 - 7: 各个家庭上传本地模型参数 ϕ_i 到全局服务器
 - 8: 保存各家庭模型参数到 $\phi \leftarrow (\phi_1, \phi_2, \dots, \phi_n)$
 - 9: 对各家庭模型参数进行聚合得到新的全局模型参数 $\phi_G' \leftarrow \sum_{i=1}^n \frac{N_i}{N} \phi_i$
 - 10: 用新的全局模型参数替换旧的全局模型参数 $\phi_G \leftarrow \phi_G'$
 - 11: 将新的全局模型参数广播到所有家庭
 - 12: 更新各个家庭的本地模型参数为全局模型参数: $\phi_i \leftarrow \phi_G$
 - 13: **end**
 - 14: **for** each home in all homes **do**
 - // 再次使用用户本地数据对模型进行更新
 - 15: $\phi_i \leftarrow local_update(\phi_i', Dataset_i)$
 - 16: **end**
-

算法首先对全局服务器中的全局模型 ϕ_G 进行随机初始化 (第 1 行), 并使用 ϕ_G 对各家庭的本地参数 ϕ_i 进行初始化 (第 2 行), 然后开始进行全局模型的协作训练 (第 3-14 行)。首先根据算法 5-1 使用家庭中本地的用户习惯数据为每个家庭执行本地模型训练(第 5 行), 接着将训练得到的本地模型参数 ϕ_i 上传到全局服务器 (第 7 行)。在服务器端, 根据对各家庭所包含的数据量对他们的模型参数进行模型聚合, 得到新的全局模型参数 (第 9-10 行), 并根据全局模型参数广播到各个家庭中 (第 11 行), 对各个家庭的本地模型进行更新 (第 12 行)。在结束全局模型的协作训练之后, 各个家庭将使用用户的本地数据集再对各自的模型 ϕ_i 进行个性化更新 (第 15 行), 以确保该模型能够符合用户的个性化需求。

基于上述算法可以完成对全局模型参数的初始化构建, 此后对于中途加入的新家庭, 在通过时序知识图谱收集到少量的用户行为数据后, 可以跳过全局模型的联邦构建过程, 直接获取现有全局模型参数 ϕ_G 作为初始模型参数对本地模型进行初始化, 再使用本地数据对模

型参数进行更新，即可直接投入智能家居服务管控中。本方法仅需收集较少量的本地数据，即可实现较高的服务管控准确率，并使得模型训练在较少的轮次内即可实现收敛，进而大幅减少新加入家庭所需等待的“冷启动”所需时间，降低用户使用智能家居服务管控的成本，可以轻松扩展更多家庭的环境。

6 实验与评估

6.1 实验设置

实验原型系统考虑五个家庭的五个用户，每个用户的偏好不同。本实验为用户构建的 Context 有温度、湿度和亮度三种典型类型。智能家居场景中的智能设备能够对相应的环境类型提供对应类型的服务，每个家庭所拥有的智能家居设备设置如表 1 所示。基于智能家居时序知识图谱的特性，将不同的智能家居设备的功能操作抽象为服务实例，以统一的方式对设备进行数据读写和功能调用。实验采用的神经网络结构包含一个输入层，一个输出层，和三个隐藏层，各层之间采用全连接网络连接，三个隐藏层的神经元个数分别为 32、64、32。模型训练过程中的批次大小 $M=32$ ，采用 Sigmoid 作为激活函数，Adam 作为优化算法，其对应的学习率 α 为 0.001， β_1 和 β_2 分别取 0.9、0.99， ε 取值为 10^{-7} 。

表 1 各家庭所拥有的智能设备情况

Table 1 Smart Device Inventory in Each Household

家庭	智能空调	智能灯	智能加湿器
家庭 1	✓	✓	✓
家庭 2	✓		✓
家庭 3		✓	✓
家庭 4	✓	✓	
家庭 5	✓	✓	✓

五个家庭模型部署后，每个家庭首先从全局服务器获取全局模型，通过本地的数据对模型进行更新。本实验的本地模型每迭代次数 $E=100$ ，在本地迭代次数 E 结束后将与全局服务器之间进行一次通信，交换模型参数。完成全局模型训练后再使用本地数据进行模型更新，得到符合用户个人习惯的个性化模型进行服务管控。

实验所使用的数据是基于真实环境数据^[24]分别为每个家庭的用户生成仿真数据，每个家庭根据自己的偏好生成对应的管控结果作为标签。每条数据的时间间隔为 10 分钟。实验数据基于对应数据样本的大小归一化到 $[0,1]$ 区间：

$$\mathbf{X}' = \frac{\mathbf{X} - \mathbf{X}_{\min}}{\mathbf{X}_{\max} - \mathbf{X}_{\min}} \quad (6)$$

本实验的实验代码基于 Python 3.9 版本下的深度学习代码框架 Tensorflow 2.10 编写，实验代码运行环境为一台服务器，其 CPU 为 Intel(R) Xeon(R) Silver 4114 @ 2.20GHz，运行内存为 64GB，安装有 Ubuntu 22.10 操作系统。

表 2 实验环境配置

Table 2 Experimental Environment Configuration

参数	配置
CPU	Intel(R) Xeon(R) Silver 4114 @ 2.20GHz
GPU	NVIDIA GeForce RTX 2080 SUPER
运行内存	64GB
操作系统	Ubuntu 22.10
编程语言	Python 3.9
深度学习框架	Tensorflow 2.10

6.2 服务管控实例

为了验证本文方法的有效性，本实验以家庭 1 为例展示时序知识图谱构造过程、服务管控模型构造过程和服务管控过程。家庭 1 的智能家居场景如图 5 所示，其被管控的区域为卧室 (L_1)。在该家庭中有一个住户 U_1 ，并拥有智能空调、智能加湿器和智能灯等设备。在该场景中本实验构造温度、相对湿度和灯光三个类型的 Context。场景中的各个智能设备能够为对应的 Context 提供 Monitor、Increase、Reduce 类型的环境调节服务。

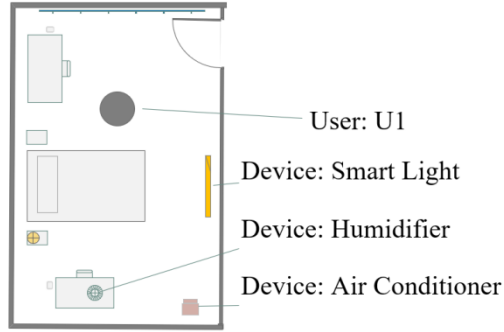


图 5 智能家居场景原型

Fig. 5 Smart Home Scenario Prototype

基于图 5 所示智能家居场景原型，构造对应的智能家居时序知识图谱模型。该场景中包含 1 个 User 实例，即用户 U_1 、1 个 Location 实例，即卧室、3 个 Device 实例、3 个 Context 实例、10 个 Service 实例。其次，根据 4.2.2 节的关系构造规则，构造出上述概念实例间对应的关系：17 个 Located in 关系、10 个 Provide 关系、3 个 Monitor 关系、2 个 Reduce 关系、3 个 Increase 关系、1 个 Assign 关系以及 3 个 Sense 关系。最后，构造得到的智能家居知识图谱快照如图 6 所示。智能家居时序知识图谱建立完成后，并以 10 分钟间隔生成当前知识图谱的“快照”并保存，为后续提供时序数据的基础。




图 6 智能家居时序知识图谱快照

Fig. 6 Snapshot of Intelligent Home Temporal Knowledge Graph

首先借助时序知识图谱获取前 200 个时间点对应的时序数据用于管控模型训练。模型训练过程如第 5 章所述，首先从全局服务器下载全局模型作为本地的初始模型，接着使用本地数据训练模型，每训练 100 个轮次与全局服务器交换模型参数，重复迭代多次完成全局模型

参数训练。在全局模型训练完毕后，再基于用户本地数据对模型进行针对性更新，得到可用的本地个性化模型。

通过上述步骤完成管控模型构建后，可以开始对智能家居设备进行管控。在管控智能家居设备的过程中，时序知识图谱会持续记录用户的行为数据。在收集到一定的增量数据后，可以启动后台进程对模型进行重新训练并将参数上传到全局服务器中，使管控模型能够持续适应用户习惯的变化，保持模型的高准确性。

6.3 对比方法与评价指标

为了验证服务管控准确率上表现，本文对所提出模型的与如下对比方法进行对比：

(1) 基于预设规则的管控模型 (Rule-based)：该方法通过统一设定的智能家居服务控制规则对智能家居服务进行管控，用于在模拟智能家居设备自带的预设规则下不同偏好家庭的智能家居服务管控准确率的表现。

(2) 基于本地数据训练的 DNN 管控模型 (Local-only)^[17]：该方法仅使用少量本地用户个人数据来训练本地 DNN 模型进行智能家居服务管控。本文方法相比，该方法与主要差异是缺少与其他家庭协作训练模型的过程，所有模型参数均由本地数据训练而来。该方法模拟数据不足情况下深度学习方法的表现，方法相关参数设置与本文方法相同。

(3) 基于联邦全局模型的 DNN 管控模型 (Global-only)：该方法直接使用基于其他家庭联邦协作训练得到的共享 DNN 模型，该方法与本文方法相比的主要差异在于缺少了使用本地数据对模型进行更新的过程，可以认为是不含用户个人数据训练得到的模型。该方法模拟统一的机器学习模型在不同偏好家庭下的表现，方法相关参数设置与本文方法设置相同。服务管控准确率定义参考文献^[16]，输出值与标签值进行归一化后计算误差平方和，其平方和小于 0.05 的情况认为值准确的一次预测，所有正确预测的数量占总样本数量的比值记为管控准确率。

6.4 实验结果

表 3 显示了不同偏好的家庭在温度相关服务管控准确率方面的情况。基于预设规则的管控模型表现平均准确率低，仅为 36.88%，无法满足用户需求。该方法在不同家庭上的性能差异较大，最好与最差情况的差距超过 20%。原因是该方法使用统一规则，无法适应不同家庭的差异化需求。本地数据训练的 DNN 管控模型平均准确率为 58.96%，由于仅依赖少量本地数据（200 条），模型容易欠拟合。联邦全局模型的 DNN 管控模型平均准确率为 71.40%，虽然具有一定泛化能力，但无法满足个性化需求，因为模型只能符合多家庭的“平均”习惯。

本文提出的方法平均准确率为 89.47%，在不同偏好的家庭上表现最佳。该方法利用联邦学习解决了单个家庭数据量不足的问题，并通过本地数据对模型进行更新，以有针对性地学习符合本地用户习惯的管控模型。与其他方法相比，该方法能够满足不同家庭的差异化管控需求。

表 3 温度场景下服务管控准确率 (%)

对比方法	Home1	Home2	Home4	Home5
Rule-based	46.88	22.42	17.02	49.21
Local-only	61.865	50.495	56.45	67.015
Global-only	67.954	78.685	64.15	74.85
Ours	85.745	91.045	89.31	91.78

表 4 显示了不同偏好的家庭在相对湿度相关服务管控准确率方面的情况。基于预设规则的管控模型平均准确率为 47.63%，略高于温度场景。但与本文方法相比仍存在较大差距。该方法在不同家庭上也表现出较大差异，无法满足湿度场景下不同家庭的需求。基于本地数据训练的 DNN 管控模型平均准确率为 61.37%，与本文方法相比有约 20%的差距。基于联

邦全局模型的 DNN 管控模型平均准确率为 74.23%，略高于基于本地数据训练的 DNN 管控模型，但与本文方法相比仍有约 15% 的差距。本文方法在湿度相关服务的平均准确率为 87.04%，在各个家庭上表现最佳，且不同家庭的准确率差异约为 5%。说明本方法能够满足不同家庭不同服务的管控需求。

表 4 温度场景下服务管控准确率 (%)

对比方法	Home1	Home2	Home4	Home5
Rule-based	56.87	45.52	40.53	47.59
Local-only	59.05	70.16	65.09	51.19
Global-only	77.25	64.49	74.94	80.25
Ours	89.23	84.55	86.43	87.93

表 5 展示了灯光场景下本文方法与对比方法在服务管控准确度的比较情况。在亮度场景下，基于规则的服务管控模型的平均准确率约为 67.24%，难以满足用户的需求。基于本地数据的 DNN 管控模型的平均准确率为 80.78%。基于联邦全局模型管控方法的平均准确率为 81.40%，与基于本地数据的 DNN 管控模型相差不大。本文方法的平均管控准确率约为 94.45%，对比方法中表现最好的方法相比准确率提升超过 10%。

表 5 灯光场景下服务管控准确率 (%)

对比方法	Home1	Home2	Home4	Home5
Rule-based	73.50	70.52	60.35	60.59
Local-only	80.56	76.17	80.68	85.69
Global-only	85.11	81.59	77.21	81.68
Ours	95.22	94.08	95.45	93.05

为了展示本方法在模型收敛速度上表现，评估联邦学习为新部署家庭带来的上的收益，本实验仿真了实际应用过程中新部署家庭加入已有的联邦集群的过程。在该过程中，家庭 1、家庭 2 和家庭 4 以每经过 100 个本地训练轮次 (epoch) 与全局服务器进行一次通信的频次协作训练全局模型。经过四轮与通信后，全局模型达到一个基本可用的状态。此时家庭 5 开始加入联邦协作训练，其对应的训练准确率变化曲线如图 8 和图 9 所示。

从图 7 中可以看到，与其他三个家庭从零开始协作训练需要 200 轮左右才能达到 80% 左右的准确率相比，新加入的家庭仅需约 10 个轮次即可达到接近相同的效果，在模型收敛速度上有大幅的提升。这说明联邦学习能够快速为新加入的模型找到最优的策略，具有扩展到更多家庭数量的能力。此外，从图中可以看到在模型刚加入协作训练时，其准确率与全局模型接近，不包含家庭 5 的习惯信息，故在家庭 5 上准确率表现较低，而经过家庭 5 的本地数据更新后，模型可以达到约 90% 左右的准确率。




图 7 新家庭加入联邦协作训练时模型准确率变化曲线

Fig. 7 Accuracy Variation Curve of the Model with the Addition of a New Family in Federated Collaborative Training

图 8 展示了温度场景下新加入家庭的模型收敛曲线变化。在刚开始训练的时候出现不同家庭之间模型聚合会导致本地损失函数增加的情况，到后面的轮次该现象逐渐消失，此时的模型中已经包含有各个家庭的个性化特征。与从头开始训练相比，新加入家庭的模型的收敛速度显著加快，约 10 个训练轮次即可追上其他模型的训练进度，且实现了更低的损失函数值。该结果说明本方法可以加快新加入模型训练过程中的收敛速度，降低模型训练开销。




图 8 新家庭加入联邦协作训练时模型损失函数值变化曲线

Fig. 8 Loss Variation Curve of the Model with the Addition of a New Family in Federated Collaborative Training

7 结论

为了应对智能家居应用开发中面临的设备异构性挑战，实现更加智能化、无感化、人性化的智能家居服务开发，提高智能家居的服务水平，本文提出了时空数据驱动的智能家居服务管控方法，首先，提出了智能家居时序知识图谱构造方法，完善并扩充了现有的

智能家居知识图谱模型。该方法通过概念、关系实例来表示情境知识，并记录了智能家居设备在不同时间点的状态，以提供时序数据支持。其次，基于联邦学习，提出了一种以用户为中心的多家庭智能家居服务管控方法。利用智能家居时序知识图谱和联邦平均算法，结合用户的本地数据与全局模型进行更新，从而实现个性化的智能家居服务预测和操作执行。这种方法可以根据用户偏好精确地进行智能家居服务管理，并具有 90% 的服务管控准确度和加速模型构建收敛速度的优势。

目前的研究并未考虑多用户需求冲突的情况，在未来研究中，将针对不同用户处在同一环境下的服务管控，引入多用户冲突解决方案。此外，还将对联邦模型的公平性问题进行进一步探究，实现更加智能化的预测算法。

参考文献

- [1] 刘景泰,张 森,孙 月.面向智能家居/智慧生活的服务机器人技术与系统 [J].集成技术,2016,5(3):38-46.
Liu JT, Zhang S, Sun Y. Technology and System of Service Robots for Smart Home and Intelligent Life[J]. Journal of Integration Technology,2016,5(3):38-46.
- [2] Behmann F, Wu K. Collaborative internet of things (C-IoT): For future smart connected life and business[M]. John Wiley & Sons, 2015.
- [3] Ghiani G, Manca M, Paternò F, et al. Personalization of context-dependent applications through trigger-action rules[J]. ACM Transactions on Computer-Human Interaction (TOCHI), 2017, 24(2): 1-33.
- [4] Taj S, Asad U, Azhar M, et al. Interoperability in IOT based smart home: A review[J]. Journal homepage: <http://iieta.org/Journals/RCES>, 2018, 5(3): 50-55.
- [5] Laghari A A, Wu K, Laghari R A, et al. A review and state of art of Internet of Things (IoT)[J]. Archives of Computational Methods in Engineering, 2021: 1-19.
- [6] Berg I A, Khorev O E, Matvevnina A I, et al. Machine learning in smart home control systems-Algorithms and new opportunities[C]//AIP Conference Proceedings. AIP Publishing, 2017, 1906(1).
- [7] 陈星, 黄志明, 叶心舒, 等. 智能家居情境感知服务的运行时建模与执行方法[J]. 软件学报, 2019, 30(11): 3297-3312.
Chen X, Huang ZM, Ye XS, et al. Runtime Modeling and Execution Method for Context-aware Services in Smart Homes [J]. Journal of Software, 2019, 30(11): 3297–3312.
- [8] Li D, Jayaweera S K. Reinforcement learning aided smart-home decision-making in an interactive smart grid[C]//2014 IEEE Green Energy and Systems Conference (IGESC). IEEE, 2014: 1-6.
- [9] Khan N S, Ghani S, Haider S. Real-time analysis of a sensor's data for automated decision making in an IoT-based smart home[J]. Sensors, 2018, 18(6): 1711.
- [10] Forbes G, Massie S, Craw S, et al. Representing temporal dependencies in smart home activity recognition for health monitoring[C]//2020 International Joint Conference on Neural Networks (IJCNN). IEEE, 2020: 1-8.
- [11] Zhang Y, Tian G, Zhang S, et al. A knowledge-based approach for multiagent collaboration in smart home: From activity recognition to guidance service[J]. IEEE Transactions on Instrumentation and Measurement, 2019, 69(2): 317-329.

-
- [12] Hu P, Ning H, Chen L, et al. An open internet of things system architecture based on software-defined device. *IEEE Internet Things J* 6 (2): 2583–2592[J]. 2019.
- [13] Rocha Filho G P, Meneguette R I, Maia G, et al. A fog-enabled smart home solution for decision-making using smart objects[J]. *Future Generation Computer Systems*, 2020, 103: 18-27.
- [14] Toldinas J, Lozinskis B, Baranauskas E, et al. MQTT quality of service versus energy consumption[C]//2019 23rd International Conference Electronics. IEEE, 2019: 1-4.
- [15] Tao M, Ota K, Dong M. Ontology-based data semantic management and application in IoT-and cloud-enabled smart homes[J]. *Future generation computer systems*, 2017, 76: 528-539.
- [16] Xie C, Yu B, Zeng Z, et al. Multilayer Internet-of-Things Middleware Based on Knowledge Graph[J]. *IEEE Internet of Things Journal*, 2021, 8(4): 2635-2648.
- [17] Geraldo Filho P R, Villas L A, Freitas H, et al. ResiDI: Towards a smarter smart home system for decision-making using wireless sensors and actuators[J]. *Computer Networks*, 2018, 135: 54-69.
- [18] Jin J, Shu S, Lin F. Personalized Control of Indoor Air Temperature Based on Deep Learning[C]//2019 Chinese Control And Decision Conference (CCDC). IEEE, 2019: 1354-1359.
- [19] Mao B, Xu K, Jin Y H, et al. DeepHome: A control model of smart home based on deep learning[J]. *Chinese Journal of Computers*, 2017, 40(8): 1-15.
- [20] Yu T, Li T, Sun Y, et al. Learning context-aware policies from multiple smart homes via federated multi-task learning[C]//2020 IEEE/ACM Fifth International Conference on Internet-of-Things Design and Implementation (IoTDI). IEEE, 2020: 104-115.
- [21] A ĩodji U M, Gambs S, Martin A. IOTFLA: A secured and privacy-preserving smart home architecture implementing federated learning[C]//2019 IEEE security and privacy workshops (SPW). IEEE, 2019: 175-180.
- [22] Chen J, Chen Z, Zheng L, et al. A Spatio-Temporal Data-Driven Automatic Control Method for Smart Home Services[C]//Companion Proceedings of the Web Conference 2022. 2022: 948-955.
- [23] McMahan B, Moore E, Ramage D, et al. Communication-efficient learning of deep networks from decentralized data[C]//Artificial intelligence and statistics. PMLR, 2017: 1273-1282.
- [24] Schneider G F, Rasmussen M H, Bonsma P, et al. Linked building data for modular building information modelling of a smart home[C]//11th European conference on product and process modelling. CRC Press. 2018: 407-414.