

基于联邦学习的自助取货机远程 下单数据共享方法

赵峻岭[†], 梁峰, 陈琳

(国网安徽省电力有限公司 淮北供电公司, 安徽 淮北 235000)

摘 要:研究了基于联邦学习的自助取货机远程下单数据共享方法。精准有效共享自助取货机各端口运营中的下单数据, 为有效分析各端口营销差异、保障其合理运营提供依据。运用自编码神经网络改进基础联邦学习模型, 获得半监督联邦学习模型, 结合增量加权训练该模型后, 运用训练后的半监督联邦学习模型共享各自助取货机端口的远程下单数据。结果显示, 该方法可有效共享各远程自助取货机端口的下单数据, 依据共享数据可有效分析出各端口不同时段畅销品类; 当共享中存在无标记数据端口, 且通信轮数较低时, 该方法的共享精度略受影响, 而通信轮数到达一定数量后, 该方法的共享精度稳定不受此因素干扰; 当共享中存在端口新增下单数据时, 新增的下单数据量对该方法的共享精度几乎无影响。

关键词:联邦学习; 自助取货机; 远程下单数据; 自编码; 半监督; 增量加权

中图分类号: TP309

文献标识码: A

Remote Order Data Sharing Method for Self-Service Cargo Machine Based on Federated Learning

ZHAO Junling[†], LIANG Feng, CHEN Lin

(Huaibei Power Supply Company, State Grid Anhui Electric Power Co., Ltd., Huaibei, Anhui 235000, China)

Abstract: This paper studies the remote order data sharing method of self-pick-up machine based on federal learning, accurately and effectively shares the order data of each port operation of self-pick-up machine, and provides a basis for effectively analyzing the marketing differences of each port and ensuring its reasonable operation. The self-coding neural network was used to improve the basic federated learning model, and the semi-supervised federated learning model was obtained. After the model was trained with incremental weighting, the semi-supervised federated learning model was used to share the remote order data of each assisted cargo plane port. The results show that the method can effectively share the order data of each remote self-pick-up machine port, and can effectively analyze the best-selling categories of each port in different periods according to the shared data. When there are unmarked data ports and the number of communication wheels is low, the sharing accuracy of the method is slightly affected. When the number of communication wheels reaches a certain number, the sharing accuracy of the method is stable without interference from this factor. When the newly added order data exists in the sharing, the newly added order data has almost no effect on the sharing accuracy of the method.

Key words: federated learning; self-service pickup machine; remote order data; self-coding; semi-supervision; incremental weighting

自助服务是通过交互的形式将采用手机或现金等方式得到的服务提供给用户,其主要特点是智能、高效、安全、便捷等,属于一种较为新颖的智能化服务^[1]。作为自助服务代表的自动收费机、自助检票机、自助挂号机以及自助取货机等自助服务设备,均属于高科技智能产品,常在医疗、交通、金融、娱乐以及公共服务等领域被大量运用^[2,3]。其中,自助取货机的应用范围更为广泛,其主要负责如饮品类、零食类、卫生用品类等商品的经营,其优点包括操作便捷、适用场景广泛、购物便利、品类多样等,不仅能够提升用户的购物乐趣,而且增强了用户购物的自主性^[4]。现实中投放者为了保障自助取货机的运营效果与销量,需依据其不同投放区域端口的实际销售数据及时调整在售商品品类,故而,自助取货机各端口远程下单数据的在线共享,成为当前自助取货机经营过程中的关键^[5,6]。当前已有的数据在线共享方法有武法提等人所研究的多源数据融合的教育数据共享模型,此模型先对多源异构教育数据实施融合处理,然后依据 xAPI 数据规范规范化分析融合后的教育数据,得到普适性强的数据交换格式,运用该格式创建融合后教育数据共享模型,该模型可实现在线多源异构教育数据的共享,便于实时分析教育模式与教育效果,但当存在大量新增教育数据时,该模型的数据共享精度明显下降,共享性能不够稳定^[7];由牛淑芬等人提出的基于区块链的电子病历数据共享方法,是通过运用区块链技术存储电子病历数据,并结合代理重加密算法,完成电子病历数据的在线共享,该方法不仅能够共享电子病历数据,而且可为数据加密,防止共享时泄露患者的隐私,但该方法在电子病历数据新增量高时,共享精度降低显著,共享性能的稳定性同样不够理想^[8]。

联邦学习(FL)属于一类较为新颖的人工智能技术,该技术以保证个人数据与边缘数据安全性为前提,实现若干参与方间的高效机器学习,其应用前景广阔应用价值较高,被广泛应用于计算机视觉、教育、医疗、金融及工业等领域内。在该技术的机器学习过程中,各参与方不用对初始数据实施共享,仅需对梯度与参数等模型信息实施交换即可实现联合建模,也就是无须将本地数据传出,即可实现联合训练学习,构建联邦共享的机器学习模型^[9,10]。自编码神经网络属于一类无监督学习算法,该算法的主要目标是极大限度地令其输出与输

入更为相似,即通过学习到的初始输入数据内的隐藏表示建立其输入数据,以此令最终的输出数据更加接近输入数据^[11]。

综合上述分析,本文结合联邦学习与自编码神经网络,构建一种针对自助取货机远程下单数据的共享模型,实现各自助取货机端口远程下单数据的精准在线共享,为准确分析各端口实际销售情况、合理投放在售商品品类提供可靠依据。

1 自助取货机远程下单数据共享方法

1.1 基础联邦学习模型框架设计

基础联邦学习模型主要由中心服务器与局部模型训练两部分构成^[12]。局部模型训练部分通过本地端口所储存的下单数据,向中心服务器传输局部模型参数 θ_i ,经聚合后将中心服务器内的全局模型参数得到。通常联邦学习的总体流程中包含数轮数据通信,其间可通过本地端口储存数据实现各端口局部模型的同步训练。基础联邦学习模型框架如图 1 所示。




图 1 基础联邦学习模型框架图

由于基础联邦学习模型只能够用在监督学习中,其将全部端口数据都认定成存在标签的标记数据^[13]。但因现实中,所存储的自助取货机远程下单数据中存在大量的无标记数据,仅通过基础联邦学习模型无法实现此部分远程下单数据的学习共享。因而,结合自编码神经网络对基础联邦学习模型实施优化改进,获得半监督联邦学习模型,令无标记数据端口也可加入联邦学习中,实现自助取货机有标记、无标记远程下单数据的联合共享。

1.2 基于自编码神经网络的半监督联邦学习模型

在基础联邦学习的基础上引入自编码神经网络获得半监督联邦学习模型,运用此模型实现自助取货机远程下单数据的有效共享。该半监督联邦学习模型由分类器与自编码神经网络两个关键部

分构成。其中,自编码神经网络部分属于一类尝试向恒等函数靠近的无监督学习算法,它的主要目标为最大限度地令输出数据与输入数据相似^[14]。为实现此目标,该部分通过学习初始输入的自助取货机远程下单数据内的隐藏表示,重新构建学习模型的输入数据。而分类器部分主要由编码器与解码器两个单元组成,其中编码器的任务为学习初始输入的自助取货机远程下单数据内的隐藏表示,解码器的任务为依据编码器所学习的隐藏表示,重新构建学习模型的输入数据。另外由编码器所学习的初始输入远程下单数据隐藏表示属于分类器的预测特征。基于自编码神经网络的半监督联邦学习模型结构见图 2。




图 2 半监督联邦学习模型结构图

其中,编码器与解码器分别通过函数 $f(\cdot)$ 与 $b(\cdot)$ 表示,以自助取货机各端口远程下单数据作为初始输入数据 X ,为了令 $b(\cdot)$ 重新构建的输入数据 $\tilde{X}$ 尽可能与初始输入数据 X 接近,需对重新构建输入数据的损失实施最小化。在此先运算出重新构建输入数据 $\tilde{X}$ 的均方差 K_{MSE} ,即:

$$\begin{aligned} \arg \min_v K_{MSE} &= \frac{1}{m} \sum_{i=1}^m k_1(X^{(i)}, v) = \\ &= \frac{1}{m} \sum_{i=1}^m \|\tilde{X}^{(i)} - X^{(i)}\|^2 = \\ &= \frac{1}{m} \sum_{i=1}^m \|b(f(X^{(i)})) - X^{(i)}\|^2 \end{aligned} \quad (1)$$

式中,各自助取货机端口的下单数据集中所包含的训练样本数据量通过 m 表示;在各自助取货机端口通信时,端口 A_l 的最小化目标函数为 $K(X, Y, v_L)$,其中, L 代表端口总数量, Y 代表输

出数据, v_L 代表端口梯度;第 i 个端口的初始输入数据与重新构建输入数据分别通过 $X^{(i)}$ 与 $\tilde{X}^{(i)}$ 表示;重新构建输入数据损失的最小化目标函数通过 $k_1(X^{(i)}, v)$ 表示。

通常深度学习模型包含 $g(\cdot)$ 、 $h(\cdot)$ 两个函数,二者的作用分别为提取特征与预估标记。基于自编码神经网络的半监督联邦学习模型作为一种深度学习模型,为实现其输出数据与输入数据的最大化接近目标,需以最小化数据分类损失作为目标函数^[15]。在此选用交叉熵损失函数作为数据分类损失函数,其运算式为:

$$\begin{aligned} \arg \min_v K_{CE} &= \frac{1}{m} \sum_{i=1}^m k_2(X^{(i)}, Y^{(i)}, v) = \\ &= -\frac{1}{m} \sum_{i=1}^m Y^{(i)} \log(h(g(X^{(i)}))) \end{aligned} \quad (2)$$

式中,最小化分类损失目标函数通过 $k_2(X^{(i)}, Y^{(i)}, v)$ 表示;数据分类损失通过 K_{CE} 表示。将编码器 $f(\cdot)$ 作为函数 $g(\cdot)$,并对函数 $h(\cdot)$ 实施设定,设定其为全连通网络,以此对其末层维度同标记维度的统一予以保障。故在此可将数据分类损失表示成:

$$K_{CE} = -\frac{1}{m} \sum_{i=1}^m Y^{(i)} \log(h(f(X^{(i)}))) \quad (3)$$

在此基础上,为实现分类损失与重新构建输入数据损失的最小化,可设定终极优化目标函数为:

$$K = \delta K_{MSE} + K_{CE} \quad (4)$$

式中,超参数通过 δ 表示。在所例远程下单数据集内,编码器内所提取到的编码即为初始输入数据的隐藏表示,同时通过其特征能够实现数据的分类。

1.3 基于半监督联邦学习模型的自助取货机远程下单数据共享

1.3.1 结合增量加权的半监督联邦学习模型训练

在运用所构建的半监督联邦学习模型共享自助取货机远程下单数据之前,需先对该模型实施训练。常规训练方法下,联邦学习模型可反复在本地数据内获取特征实施训练学习,但因自助取货机各端口下单数据的新增量高且数据量不等,导致训练学习过程中不能与各端口实时新增下单数据保持同步并自适应增量修正本地模型,造成整体训练耗时长、模型学习精度降低等问题。为解决此类问题,本文结合增量加权训练半监督联邦学习模型。经联邦增量学习算法将自助取货机各端口的增量

加权得出,以此高效融合各端口新增的下单数据与本地初始模型,有效解决自助取货机端口远程下单数据新增量高、各端口数据量不统一等问题,提升整体训练效率的同时,保证训练后模型的学习精度。

设在第 t 轮数据通信过程中,本地模型参数通过 θ_i 表示。自助取货机各端口新增下单数据样本数量占初始下单数据样本总量的比例即为对应端口的增量权值。第 i 个自助取货机端口的增量权值为:

$$\lambda_i = \frac{|\dot{m}_i|}{|m_i|} \quad (5)$$

式中,第 i 个自助取货机端口的初始下单数据样本总量通过 $|m_i|$ 表示;其新增下单数据样本数量通过 $|\dot{m}_i|$ 表示。在第 $t+1$ 轮数据通信过程中优化本地模型参数时,模型参数的深度值 ϑ_{t+1}^i 可表示为:

$$\vartheta_{t+1}^i = \vartheta_t^i - (\vartheta_t^i * \lambda_i) \quad (6)$$

式中,第 t 轮数据通信中本地模型参数的深度值通过 ϑ_t^i 表示。

参数的深度值会随着各端口下载与上传参数的期间内产生的全新训练数据实时修正。通过本地模型参数深度值能够呈现出在单次训练时自助取货机端口的本地数据集内新增下单数据影响模型性能的程度,以此反馈各端口的更新程度。在此将增量加权的衰减函数选取为反正切函数,以此令端口的参数加权值与参数深度值成反比关系,即深度值越高则端口的参数加权值越低,同时衰减幅度也越小。此反正切函数可表示成:

$$\varphi_{t+1}^i = \frac{2}{\pi} \arctan \vartheta_{t+1}^i \quad (7)$$

在半监督联邦学习模型框架下,为提升聚合操作的效能,每轮数据通信只对加入数据子集内的各端口实施修正,同时以端口模型的深度值为依据,将聚合操作内模型所发挥作用中可运用的历史信息确定,以此对本地模型的实际应用价值实施划分实现。为此,需进一步对本地模型的参数加权予以考量,在此基础上得到的优化聚合方程式为:

$$\theta_{t+1} \leftarrow \sum_{i=1}^L \theta_{t+1}^i \cdot \varphi_{t+1}^i \cdot \left(\frac{m_L}{m}\right) \quad (8)$$

式中,训练时 L 个端口的本地私有下单数据集的大小通过 m_L 表示。在半监督联邦学习模型训练过程中,各自助取货机端口所上传的模型参数需通过增量加权的调整,方可加入到本地模型优化

中。经增量加权调整之后的模型参数在本地端上按照详细的算法实现模型参数的优化,完成优化过程之后,各端口得到全新的本地模型参数,同时应用此类参数将本地参数覆盖,继而进入下一轮迭代训练。

1.3.2 基于半监督联邦学习模型的下单数据共享实现

在半监督联邦学习模型的远程下单数据集集合内,以数据集是否存在标记为依据,将自助取货机端口划分为无标记数据集端口与存在标记数据集端口,二者分别以 $\{A_d\}_{A_d=1}^L$ 与 $\{A_c\}_{A_c=1}^L$ 表示,其中,两种端口的数目分别通过 L_d 与 L_c 表示。运用经上文训练的半监督联邦学习模型构建自助取货机各端口间远程下单数据共享模型框架,此共享模型框架可通过联合数个自助取货机端口实现各端口远程下单数据的联邦学习共享。其中,联邦学习全局服务器的作用是对全局各端口模型实施协调,在此协调下,各端口模型同全局服务器实现联合训练后,开启各端口远程下单数据的联邦学习共享过程。自助取货机远程下单数据共享模型框架如图 3 所示。




图 3 自助取货机远程下单数据的半监督联邦学习共享模型框架

对存在标记数据集的端口 A_c 而言,运用公式(4)的优化目标函数 K 得到更优越的分类器即为它的目标。将编码器 $f(\cdot)$ 视作自助取货机各端口远程下单数据的特征提取器,通过此提取器联合优化重新构建输入数据损失 K_{MSE} 与分类损失 K_{CE} ;解码器 $b(\cdot)$ 完成了对联合优化后 K_{MSE} 的学习。在第 j 次数据通信迭代过程中,将各端口 A_c 由联邦学习全局服务器内所下载的当前模型视作本地

模型,并对此模型实施更新,更新方程式为:

$$v_c^{j+1} \leftarrow v_c^j - \mu \nabla_{v_c^j} K = v_c^j - \mu \left[\left(\frac{\partial \partial K_{MSE}}{\partial v_c^j} \right) + \left(\frac{\partial K_{CE}}{\partial v_c^j} \right) \right] \tag{9}$$

式中,学习效率通过 μ 表示。向联邦学习全局服务器返回更新后的 $v^{(j+1)}$ 。而对无标记数据集的各个端口 A_d 而言,其目标为运用联合优化后的 K_{MSE} 对自编码神经网络部分实施训练。端口 A_d 更新本地模型的方程式为:

$$v_d^{j+1} \leftarrow v_d^j - \mu \nabla_{v_d^j} K = v_d^j - \frac{\mu \partial K_{MSE}}{\partial v_d^j} \tag{10}$$

对上述过程实施迭代,直至完成全部自助取货机端口远程下单数据的联邦学习共享。

2 实验结果分析

以某城市中某品牌自助取货机为例,运用本文方法实现其不同端口远程下单数据的共享,通过共享实验中本文方法的各方面性能表现,检验本文方法的综合应用性能。该城市此品牌自助取货机的端口数量共计 116 个,实验中由其中随机抽取 12 个端口,所抽取端口的在售商品种类包括饮品类、零食类、方便食品类、水果类、卫生用品类、其他综合类。实验中涉及的关键参数详见表 1。

表 1 实验关键参数详情

端口编号	端口初始 下单数据 总量/个	端口训练 数据量/个	端口测试 数据量/个	端口数据 是否存在 标记
端口 1	5870	4109	1761	是
端口 2	6210	4347	1863	是
端口 3	6630	4641	1989	是
端口 4	5930	4151	1779	否
端口 5	5580	3906	1674	否
端口 6	6890	4823	2067	是
端口 7	7010	4907	2103	否
端口 8	6560	4592	1968	否
端口 9	6210	4347	1863	是
端口 10	6870	4809	2061	是
端口 11	7160	5012	2148	否
端口 12	6140	4298	1842	否
学习率 μ	5×10^{-5}	超参数 δ	1	

在上述实验条件下,运用本文方法共享各自助取货机端口的远程下单数据,以其中部分共享结果为例,呈现共享后同一日 09:00 - 10:00 相同时间段内各自助取货机端口饮品类数据中下单量最高饮品的远程下单共享数据效果,如表 2 所示。

由表 2 能够看出,在本文方法的应用下,所选取的 12 个自助取货机端口的远程下单数据实现了共享,由共享后各端口下单数据得知,该时间段内端口 1、2、5、6、7、12 的矿泉水类饮品下单量相对更高,其他端口的果味饮料类饮品下单量相对更高,其中端口 5 的下单量最高,端口 4 的下单量最低。

检验本文方法共享数据过程中,不同数量的无标记数据端口对整体数据共享效果的影响。实验中所选取的自助取货机端口中,端口 4、5、7、8、11、12 为无标记数据端口,其余 6 个端口为有标记数据端口。在 6 个有标记数据端口均参与的情况下,依次统计在本文方法的应用下,经过 500~6000 轮数据通信之后,0、2、4、6 个无标记数据端口参与下,本文方法的远程下单数据共享精度,进一步分析检验无标记数据端口量对本文方法数据共享性能的影响。所得统计结果如图 4 所示。

通过图 4 可得出,在没有无标记数据端口参与时,本文方法在经过 500 轮数据通信后,共享 6 个有标记数据端口远程下单数据的精度为 0.8863;当加入 2 个无标记数据端口时,同样轮数数据通信后,本文方法共享 8 个端口远程下单数据的精度为 0.8651;而当加入 4 个和 6 个无标记数据端口时,同样轮数数据通信后,本文方法共享 10 个和 12 个端口远程下单数据的精度分别为 0.8563 和 0.8375;随着通信轮数的升高,不同无标记数据端口量加入下的共享精度均有所上升,当通信轮数达到 4500 轮后,加入 2 个无标记数据端口的数据共享精度与没有无标记数据端口时的相吻合,而加入 4 个和 6 个无标记数据端口的数据共享精度分别在 5000 轮与 5500 轮通信后与没有无标记数据端口时的相吻合,当经过 6000 轮数据通信后,各种情况下的数据共享精度均可达到 0.9625。综上所述,当通信轮较低时,无标记数据端口量越低,本文方法的数据共享精度相对越高;当无标记数据端口量不变时,通信轮数越高,本文方法的数据共享精度越高;当达到一定的通信轮数后,本文方法的数据共享精度几乎不受无标记数据端口量的影响。

表 2 各自助取货机端口的远程下单共享数据

端口 编号	商品 编号	商品 名称	商品规 格/mL	商品单 价/元	下单 量/单
端口 1	848849	农夫山泉饮用天然水	550	2	15
端口 2	67130994	百岁山天然矿泉水	570	3	13
端口 3	100026055027	柠檬味雪碧	500	4	16
端口 4	100011936495	康师傅青梅绿茶	500	3.5	9
端口 5	848849	农夫山泉饮用天然水	550	2	21
端口 6	537547	怡宝饮用纯净水	555	2	16
端口 7	67130994	百岁山天然矿泉水	570	3	17
端口 8	100031571616	元气森林荔枝味苏打气泡水	480	6	10
端口 9	7535498	美年达橙味汽水	330	3	13
端口 10	156193	可口可乐	500	4	20
端口 11	100014339249	元气森林白桃味苏打气泡水	480	6	18
端口 12	848849	农夫山泉饮用天然水	550	2	19




图 4 不同无标记数据端口量下本文方法的数据共享精度

在本文方法对 12 个自助取货机端口远程下单数据实施共享过程中,为各端口分别新增 100 个、300 个、500 个下单数据样本,检验存在不同数量新增下单数据样本的情况下,本文方法的数据共享性能,所得检验结果见图 5。

分析图 5 得知,在本文方法的应用下,各端口远程下单数据共享过程中,端口新增下单数据量的高低对本文方法的数据共享精度影响不大,且无固定规律,原因是本文方法在半监督联邦学习模型的训练过程中运用了增量加权,通过运算得出的新增下单数据端口的增量加权值,达到对端口新增下单数据的高效融合,有效防止端口新增下单数据对模型的整体学习共享精度的影响,保证本文方法数据共享性能的稳定。




图 5 不同新增下单数据量下本文方法的数据共享精度

3 结 论

自助取货机端口可分布于各种区域,其运营过程中不同端口的畅销品类与时段均可能存在差异,为精准有效地分析此类差异,保障自助取货机的合理运营,需及时高效地共享不同端口的远程下单数据。为此,针对一种基于联邦学习的自助取货机远程下单数据共享方法展开研究。该方法是通过自编码神经网络改进基础联邦学习模型,构建半监督联邦学习模型,以此实现对存在无标记数据端口参与下远程下单数据的共享;另外,为了解决各端口运营过程中随时新增的下单数据的共享问题,在半监督联邦学习模型训练时引入了增量加权方法,以各新增下单数据端口的增量加权值为依据,将新增

下单数据融合到本地模型内,保证了训练后半监督联邦学习模型的数据学习共享精度。最后通过实际应用检验本文方法的性能。结果表明,本文方法可完成数个远程自助取货机端口下单数据的有效共享,且端口数据是否存在标记以及端口下单数据新增量对整体共享精度的影响不大,数据共享性能稳定可靠。

参考文献

[1] 姜晓丹,刘连臣,吴澄,等. 新一代信息技术环境下现代服务业的数字化和智能化演进[J]. 计算机集成制造系统, 2021, 27(11):3049-3056.

[2] 张威. 物流仓储系统中智能化机械设备的开发及应用[J]. 机械设计, 2021, 38(11):157-158.

[3] 万莉,程慧平. 基于元分析结构方程模型的科学数据共享行为因素研究[J]. 情报理论与实践, 2021, 44(7):125-130+158.

[4] 张伯钧,郭一晨,王子凯,等. 基于智能合约的数据共享激励机制研究[J]. 计算机工程, 2022, 48(8):37-44.

[5] 宋宇翔,杨丽. 基于数据中台的无线传感器网络数据共享系

统[J]. 计算机工程与设计, 2022, 43(11):3022-3029.

[6] 杨舒,苏放. 基于微服务的分布式数据安全整合应用系统[J]. 计算机工程与应用, 2021, 57(18):238-247.

[7] 武法提,黄石华. 基于多源数据融合的共享教育数据模型研究[J]. 电化教育研究, 2020, 41(5):59-65+103.

[8] 牛淑芬,陈俐霞,李文婷,等. 基于区块链的电子病历数据共享方案[J]. 自动化学报, 2022, 48(8):2028-2038.

[9] 莫慧凌,郑海峰,高敏,等. 基于联邦学习的多源异构数据融合算法[J]. 计算机研究与发展, 2022, 59(2):478-487.

[10] 刘晶,董志红,张喆语,等. 基于联邦增量学习的工业物联网数据共享方法[J]. 计算机应用, 2022, 42(4):1235-1243.

[11] 卫佳乐,丁正生. 新型稀疏自动编码器组合的深度学习方

[12] 陈乃月,金一,李滢东,等. 基于区块链的公平性联邦学习模型[J]. 计算机工程, 2022, 48(6):33-41.

[13] 郑楷洪,肖勇,王鑫,等. 一个面向电力计量系统的联邦学习框架[J]. 中国电机工程学报, 2020, 40(S1):122-133.

[14] 张驰,唐凤珍. 基于自适应编码的脉冲神经网络[J]. 计算机应用研究, 2022, 39(2):593-597.

[15] 侯坤池,王楠,张可佳,等. 基于自编码神经网络的半监督联邦学习模型[J]. 计算机应用研究, 2022, 39(4):1071-1074+1104.

(上接第 101 页)

参考文献

[4] XIAO L, PING W, NIYATO D, et al. Wireless charging technologies: fundamentals, standards, and network applications [C]// Proceedings of the IEEE Communications Surveys and Tutorials, 18(2), 1413-1452.

[5] DAI H P, WU X B, CHEN G H, et al. Minimizing the number of mobile chargers for large-scale wireless rechargeable sensor networks [J]. Computer Communications, 2014, 46(15):54-65.

[6] JIAN W, WU X. Sustaining a perpetual wireless sensor network by multiple on-demand mobile wireless chargers [C]// 2015 IEEE 12th International Conference on Networking, Sensing and Control. IEEE, 2015, 218(2):1-8.

[7] RAMANATHAN R, ROSALES-HAIN R. Topology control of multiple wireless networks using transmit power adjustment [C]// INFOCOM 2000. Nineteenth Annual Joint Conference of the IEEE Computer and Communications Societies. Proceedings. IEEE. IEEE, 2000, 227(5):37-45.

[8] FENG Y, GUO L, FU X D, et al. Efficient mobile energy replenishment scheme based on hybrid mode for wireless rechargeable sensor networks [J]. IEEE Sensors Journal, 2019(99):1-1.

[9] LI G, THOMAS M, SHERALI D, et al. Making sensor networks immortal: an energy-renewal approach with wireless power transfer [J]. IEEE and ACM Transactions on

Networking, 2012, 298(48):1-9.

[10] LIANG H, YU G, PAN J, et al. On-demand charging in wireless sensor networks: theories and applications [C]// IEEE International Conference on Mobile Ad-hoc and Sensor Systems. IEEE Computer Society, 2013, 71(31):34-39.

[11] XU W, LIANG W JIA X, et al. Maximizing sensor lifetime in a rechargeable sensor network via partial energy charging on sensors [C]// 2016 13th Annual IEEE International Conference on Sensing, Communication, and Networking (SECON). IEEE, 2016, 217(32):72-79.

[12] WANG K, LEI W, OBAIDAT M S, et al. Extending network lifetime for wireless rechargeable sensor network systems through partial charge [J]. IEEE systems journal, 2021(15-1):72-75.

[13] TIAN M Q, JIAN W G, LIU J M, et al. The charging strategy of mobile charging vehicles in wireless rechargeable sensor networks with heterogeneous sensors [J]. IEEE Access, 2020, (99):1-1.

[14] SHI Y, XIE L, HOU Y Q, et al. On renewable sensor networks with wireless energy transfer [C]// 2011 Proceedings IEEE Infocom. IEEE, 2011, (37):27-45.

[15] MA Y, LIANG W F, XU W Z, et al. Charging utility maximization in wireless rechargeable sensor networks by charging multiple sensors simultaneously [J]. IEEE and ACM Transactions on Networking, 2018, 23(15):34-41.