

时空分布动态感知的校园共享单车众包调度系统

沈如达¹, 何万源¹, 许艺凡²

(1. 东南大学信息科学与工程学院, 南京 211189; 2. 东南大学网络空间安全学院, 南京 211189)

摘要: 共享自行车系统(Bike sharing system, BSS)已成为实施城市智能交通系统的一个重要组成部分。本文提出了一种时空分布动态感知的校园共享单车资源调度系统。该系统为了解决共享自行车站点库存突发变化所导致的库存紧张的问题, 首先通过向量自回归滑动平均(Vector autoregressive moving average, VARMA)模型对自行车站点的动态变化情况进行建模, 实现对站点未来时刻库存水平的预测, 其次为了解决众包资源调度场景下自行车调度效用和开销的矛盾, 提出了基于二分最优匹配模型的调度任务分配方法, 并针对性优化了匈牙利算法实现任务分配决策的高效求解。仿真实验结果表明, 本文提出的方法能够有效提高共享单车调度的系统效用, 降低自行车站点因库存紧张导致的服务质量损失, 有效平衡自行车时空分布。

关键词: 共享单车; 众包; 时序预测; 二分图匹配

中图分类号: U491.225; TP18 **文献标志码:** A

Campus Bike-Sharing Crowdsourcing Scheduling System Based on Spatio-Temporal Distribution Dynamic Perception

SHEN Ruda¹, HE Wanyuan¹, XU Yifan²

(1. School of Information Science and Engineering, Southeast University, Nanjing 211189, China; 2. School of Cyber Science and Engineering, Southeast University, Nanjing 211189, China)

Abstract: The bike sharing system (BSS) has become a significant component of implementing urban intelligent transportation systems. This paper proposes a spatio-temporal distribution dynamic perception-based campus bike-sharing resource scheduling system. To address the issue of sudden inventory changes at shared bicycle stations leading to inventory shortages, the system first models the dynamic changes at bicycle stations using the vector autoregressive moving average (VARMA) model, achieving predictions of future inventory shortage events at stations. Secondly, to resolve the contradiction between bicycle scheduling utility and cost in crowdsourced resource scheduling scenarios, it introduces a task assignment method based on a binary optimal matching model and specifically optimizes the Hungarian algorithm for efficient decision-making in task assignment. Simulation results show that the proposed method can effectively improve the system utility of bike-sharing scheduling, reduce the service quality loss caused by inventory shortages at bike stations, and effectively balance the spatio-temporal distribution of bicycles.

Key words: bike sharing; crowdsourcing; time series prediction; bipartite graph matching

引言

在智能交通系统(Intelligent transportation systems, ITSs)中,公共自行车共享作为一种流行的短途交通方式已经发展成熟,其核心技术基于低成本的云计算、嵌入式传感器系统和实时大数据分析。一般来说,共享单车系统可以分为两类,即基于停靠站的系统和无桩系统。尽管近年来无桩共享单车系统蓬勃发展,但它们也引入了一些额外的问题,例如随机停车问题和系统的可持续性。同时,基于停靠站的系统由于操作和管理的便利性在全球范围内仍然普遍存在。这些系统中的关键问题是保证用户能够方便地租借或归还自行车。

为了缓解师生的校园出行困难,很多高校已经开始提供校内专用的无桩共享单车服务,如图1所示。校园内无桩共享单车的普及,为师生提供了便捷的出行方式,却也带来了许多管理上的挑战。首先,在校园的热点区域,尤其是在出行高峰期,常常出现单车短缺的情况,学生和教职工难以找到可用的单车。其次,由于高校校园内的公共区域和道路面积相对较小,共享单车的乱停放现象更为显著。造成这些问题的根本原因在于:校园出行的潮汐现象导致的无桩共享单车时空分布不均衡,即在特定时段内,某些地区单车需求远超供给,而车辆调度能力却跟不上这种需求变化。为解决这个问题,已有的研究工作采用的平衡策略可以大致分为静态平衡和动态平衡两种。从静态平衡的假设出发,Chemla等^[1]针对自行车调度问题的NP-Hard挑战,提出了结合剪枝和禁忌搜索算法的求解方法;Raviv等^[2]将单车平衡建模为两个混合整数线性规划问题;赵达等^[3]采用混合蚁群算法来求解调度模型;刘恒孜等^[4]针对共享单车骑行数据的周期性、非线性和随机性的特点,提出了季节性灰色 Markov 模型来预测共享单车需求量,在此基础上根据双层规划模型结果来制定调度优化方案。从动态平衡的假设出发,Ghosh等^[5]提出一个优化方案,通过使用车辆重新调配自行车,同时考虑车辆的路线和未来预期需求,提出了基于问题可分解性的两个求解方法;Li等^[6]通过聚类降低问题的复杂性,继而设计了一个多智能体时空强化学习模型,旨在长期内最小化顾客损失。

为了建立一个自我可持续的系统,有学者提出了如图2所示的众包驱动的自行车平衡方法,激励用户参与自行车的平衡任务。Pfrommer等^[7]考虑了智能重新调配决策和动态定价相结合的方式,利用基于模型的预测控制提供动态变化的奖励,并且提出了启发式方法重新计算重新调配员工应采取的路线。Singla等^[8]设计了一个完整的激励系统架构,该系统采用在线学习中的遗憾最小化方法来实现最优定价策略。Pan等^[9]基于深度确定性策略梯度提出了分层强化定价(Hierarchical reinforcement pricing, HRP),利用分割与支配结构和嵌入式局部模块捕捉了空间和时间依赖性。Gao等^[10]提出了预期行程距离(Estimated travel distance, ETD)和成功停车概率(Probability of successful parking, PSP)来评估路线,并为路线规划问题构建了行程树,提出了基于行程树的最优路径贪心算法(Greedy algorithm for the optimal route, GOR)和小任务优先(First-min, FM)方法。一些众包驱动的自行车平衡方案已经在真实系统中部署,如CitiBike在2016年5月启动了一个名为Bike Angels的计划^[11]。为了平衡系统,骑行自行车从拥挤的站点到空的站点的用户将得到奖励。奖励根据站点当前的填充水平和自行车的未来流动实时确定。为了创造可持续的激励,也提供了每月、每年和终身的奖励。然而,在Bike Angels计划中,用户随机选



图1 校园无桩共享单车

Fig.1 Station free sharing bikes on campus




图2 众包共享单车调度系统

Fig.2 Crowdsourcing sharing bike scheduling system

择他们的目标站点或根据地图上的分数选择。由于用户之间的非合作行为,现有系统可能面临两个问题,即:一些拥挤的站点因租借自行车的动机变空,一些空的站点因归还自行车的鼓励变得拥挤。实际上,如果认为激励措施足够合理,用户会积极主动地参与平衡任务^[12]。因此,共享单车运营商的关键任务是生成平衡任务并找出最优的分配,以从全局视角最大化系统效用。也有学者将卡车托运和众包调度相结合进行共享单车调度^[13-14]。

此外,出于对共享单车服务质量优化目标的考量,在进行自行车站点间调度前往往往会考虑各站点的使用量规律,根据以往各站点自行车借用和归还的历史数据来预测未来自行车库存的增减情况,从而优化单车调配效率。例如,基于数据驱动的思路,Wang等^[15]将无桩共享单车供需预测问题建模为一个矩阵补全问题,通过结合时空关联、兴趣点(Point of interest, PoI)分布以及用量约束来实现区域级别自行车使用需求预测。He等^[16]从流图的视角看待无桩共享单车的预测问题,提出了一个新的时空图胶囊神经网络来预测共享单车流量分布。类似地,Li等^[17]采用了时空记忆网络来预测短期共享单车使用情况。考虑到共享单车服务质量以及工况维护,Wang等^[18]提出了一个名为eShare+的框架,采用上下文长短期记忆网络(Long short-term memory, LSTM)预测未来自行车使用,并且更进一步地以自行车使用模型来驱动自行车选择策略优化。然而,相比于城市内大尺度共享单车系统,校园内小规模共享单车服务存在特殊性,不仅自行车和用户规模较小,停车点较为固定,而且用户使用自行车的时空规律同质程度较高,多样性较弱。因此,相比于基于深度学习的方法,使用其他传统且轻量的时序预测方法可以在使用更少运算资源的情况下,达到大致同等的预测效果。

针对共享单车的众包调度问题,已有的研究大多将系统进行简化,例如不考虑自行车分布受普通用户使用服务的影响,而只关注于静态的站点自行车数量缺失的补充过程,亦或没有考虑到众包志愿者完成一次自行车调度所需要的时间,而是将其建模为同一个瞬时完成的动作。因此,本文提出了一个新的时空分布动态感知的众包调度策略(Spatial temporal dynamic aware crowdsourcing scheduling strategy, STDCSS)。此系统结合动态时序预测和任务分配两个方面。一方面,动态时序预测机制根据已有的共享单车站点库存历史数据,从中分析出周期性和随机波动性特征,进而求得未来时刻共享单车站点的库存变化数据。另一方面,在预测时序数据的基础上,建立众包志愿者接受任务意愿和站点调度需求的匹配模型,根据实际调度操作对站点库存平衡情况的增益(效用)模型,以及调度自行车所需要花费的开销模型,设计了一个时隙内系统效用最优的任务分配方法,使得自行车站点库存的紧缺情况能够在最小调度开销下得到满足。

1 预备知识

向量时序预测^[19]是一种处理和预测多变量时间序列数据的方法。与单变量时间序列预测^[20]只关注一个时间序列的未来值不同,向量时序预测模型同时处理多个相关时间序列,能够捕捉不同时间序列间的动态关系和相互作用。向量自回归滑动平均(Vector autoregressive moving average, VARMA)模型^[21]方法是一种用于多变量时间序列预测的统计模型,结合了向量自回归(Vector autoregressive, VAR)和移动平均(Moving average, MA)模型的特点。这种模型适用于分析和预测多个时间序列数据,其中各个时间序列可能相互关联^[22],表达式为

$$Y_t = A_1 Y_{t-1} + A_2 Y_{t-2} + \dots + A_p Y_{t-p} + e_t + M_1 e_{t-1} + M_2 e_{t-2} + \dots + M_q e_{t-q} \quad (1)$$

式中: $Y_t \in \mathbb{R}^N$ 是在时间 t 的多变量时间序列向量; $A_k \in \mathbb{R}^{N \times N}$ 为自回归(Auto regression, AR)系数矩阵; $M_k \in \mathbb{R}^{N \times N}$ 为MA系数矩阵; $e_t \in \mathbb{R}^N$ 为误差项,假定为白噪声过程, p, q 分别为VAR和MA部分的阶数。

2 系统模型

为了解决校园内共享单车站点库存紧缺的众包调度决策问题,建立如下的优化问题模型。不失一

般地,假设系统中存在 m 个自行车站点(以下简称为站点)的集合为 $S = \{s_1, s_2, \dots, s_m\}$, 每个站点在时隙 t 内停放的共享单车的数量,即库存数量,记为 $f_s(t)$ 。假定在校园环境这一封闭场景内,系统记录每个时刻下所有站点的库存数据,以及每个时隙内所有站点新停放的自行车以及被骑走的自行车的数量,分别记为 $e_s^+(t)$ 和 $e_s^-(t)$,那么就可以得到实际范围 T 内站点库存时间模型为

$$f_s(t+1) = f_s(t) + e_s^+(t) - e_s^-(t) \quad t \in T \quad (2)$$

任何共享单车系统都存在一定的自行车流动时空模式,以校园为例,系统的潮汐特征一般表现为早晨大量的自行车从宿舍区骑至教学区、办公区、图书馆等,夜晚则会有大致等量的自行车呈现反方向的流动。因此同一个站点在一天之内的库存水平存在波动,而同一个站点在每天的某个特定的时刻往往呈现稳定的库存水平。将某个时刻的库存水平的期望记为 $\hat{f}_s(t) = E[f_s(t)]$ 。

一般而言,由于共享单车会向普通用户提供服务,库存随时间波动属于正常情况,因此仅仅针对绝对值的高低来衡量库存紧缺和充沛是不够确切的。本文考虑的是共享单车站点库存围绕期望值波动的情况。具体而言,将站点 s_i 在 t 时刻的库存波动情况建模为

$$\tilde{f}_i(s_i) = \hat{f}_i(s_i) - f_i(s_i) \quad (3)$$

当库存的期望值比实际值高,则取正值,说明需要向该站点调入自行车以满足可能的需求;当库存的期望比实际值低,则取负值,说明该站点库存能够满足当前时刻下可能到来的需求。需要注意的是,站点库存变化作为一个随机过程,其与期望的差值通常被认为是噪声值,但是在不同的时间尺度下,差值中往往包含一些更大时间粒度的趋势信息。例如,当 t 时刻被定义为一天之中的某个小时,那么库存波动 $\tilde{f}_i(s_i)$ 不仅包含随机噪声,也包含了工作日、月度和季度趋势,因此对于考虑自行车自由流动的实际情况,采用 $\tilde{f}_i(s_i)$ 来衡量站点需求是可行的。

假设系统中有 n 位参与众包任务的志愿者(下文简称为用户),组成的集合为 $W = \{u_1, u_2, \dots, u_n\}$ 。为了简化模型,本文假设所有用户在激励机制作用下都有充分的意愿接受分配给他的任务,并且对于任务的选择不带有差异性的偏好。

为了解决自行车站点的库存波动问题,求得众包自行车调度决策,本文将求解决策的过程形式化为一个优化问题。用时间段 T 内对站点的库存波动带来的需求满足(下文简称为收益)来衡量系统效用。具体而言,将用户 u_i 在 t 时刻分配给终点为 s_j 任务所带来的收益记为 $B(u_i, s_j, t)$,结合前文对库存波动的描述,收益可以通过式(4)得到。

$$B(u_i, s_j, t) = \begin{cases} \tilde{f}_i(s_j) & \tilde{f}_i(s_j) \geq 0 \\ 0 & \text{其他} \end{cases} \quad (4)$$

式中 t_j 表示用户到达 s_j 的时刻。

在满足站点波动性需求获得收益的同时,也需要给与众包用户激励,否则理性用户不会接受任何任务。对用户的激励即为系统付出的成本,本文引入代价函数 $C(u_i)$ 来表征用户 u_i 接受众包任务所需要的成本,并假设成本与任务的骑行距离成幂次关系,即 $C(u_i, s_j, t) = d(s_{u_i}, s_j)^\gamma$, 其中 γ 为成本与距离幂次之间的比例系数。综合考虑系统收益和成本之间的关系,可以将系统效用定义为

$$\hat{B}(u_i, s_j, t) = \frac{B(u_i, s_j, t)}{C(u_i, s_j, t)} = \frac{B(u_i, s_j, t)}{d(s_{u_i}, s_j)^\gamma} \quad (5)$$

效用函数 $\hat{B}(u_i, s_j, t)$ 可以解释为单位成本度量下的系统收益,当 γ 取 1 时,效用即简化为单位距离收益。此外,定义任务分配的决策变量 $\pi(u_i, s_j)$ 为一个 0-1 矩阵,矩阵第 i 行第 j 列元素取 1 时表示将任务 s_j 分配给用户 u_i , 否则取 0。

最终以系统效用为优化目标函数,结合针对用户、决策变量的约束条件,建立最优化问题模型为

$$\pi_{\text{opt}} = \operatorname{argmax}_{\pi \in \Pi} U(\pi) \quad (6)$$

$$\text{s.t. } U(\pi) = \sum_{u_i \in U} \sum_{s_j \in S} \pi(u_i, s_j) \hat{B}(u_i, s_j, t) \quad (7)$$

$$\hat{B}(u_i, s_j, t) = \frac{B(u_i, s_j, t)}{d(s_{u_i}, s_j)^\gamma} \quad u_i \in W \quad (8)$$

$$B(u_i, s_j, t) = \begin{cases} \tilde{f}_{s_j}(s_j) & \tilde{f}_{s_j}(s_j) \geq 0 \\ 0 & \text{其他} \end{cases} \quad (9)$$

$$\tilde{f}_{s_j}(s_j) = \hat{f}_{s_j}(s_j) - f_{s_j}(s_j) \quad t_j \in T, s_j \in S \quad (10)$$

$$\pi(u_i, s_j) \in \{0, 1\}, u_i \in W \quad (11)$$

式(6)表示最优决策 π_{opt} 为优化目标取到最大值时的策略;式(7)表示优化目标可以通过对所有任务参与的所有任务所得收益求和得到;式(8~10)表述了 t 时刻将众包任务 s_j 分配给用户 u_i 的效用度量;式(11)表示决策变量为一个对应于每一个用户是否参与任务的 0-1 向量。

3 时空动态分布感知的众包调度

为了求得最优任务分配策略,系统需要根据每个用户可能完成的任务所带来的系统效用增益的区别进行任务分配。对于一个可行的单车调度系统而言,它会收集当前自行车站点的库存信息,结合每个站点的历史库存数据,从用户集合中选择出能够最大化系统效用增益的一个或多个用户,将调度任务分配给他们。这些被分配了任务的用户会立刻从起点开始骑行,并在未来的某个时刻达到预定的终点站点,其骑行的自行车将补充终点站点的库存缺失。

考虑到共享单车骑行这一动作不能够瞬间完成,因此对于库存的补充在时间上存在滞后性。例如,对于一段行程 $\langle t_{\text{src}}, t_{\text{dst}}, s_{\text{src}}, s_{\text{dst}} \rangle$,若是在 t_{src} 将该任务行程分配,那么终点站点将在 t_{dst} 时刻收到这辆自行车。在实际系统运行中,在 t 时刻进行即时的任务分配只可能在将来满足站点需要,反过来说,若是要满足某个站点未来特定时刻的需要,则需要提前一段时间进行任务分配。要实现最优化的任务分配决策,需要解决两个问题:(1) 需要根据已有的历史库存数据预测未来时刻站点库存的变化,从而得到站点对自行车调度的准确需求;(2) 需要从满足时间(未来时刻)和空间(目的地)的用户集合中做出效用最优的任务分配决策。

针对这两个问题,本文提出了如算法 1 所示的两阶段子问题模型和求解算法。首先,通过变量回归模型实现站点未来时刻库存水平的预测,其次基于预测结果进行效用最优的任务分配。算法 1 给出了算法的伪代码。在每个时间片内 t 内,首先利用已有的历史库存数据,通过 FitPredictionModel 方法训练库存预测回归模型;其次,基于模型预测时间窗口内每个站点的库存变化情况,通过 FindOptimalAssignment 方法寻找可行用户集合与站点需求 f_{t+w} 之间的最优匹配,并输出匹配的用户集合。值得注意的是,在伪代码中,分配任务的用户集合是在 T 个时间片之后统一输出的,但是在实际系统运行过程中,在每个时间片之内,系统都可以输出当前求得的最优任务法分配决策 $u \cdot \pi$ 。

算法 1 两阶段任务最优分配算法

输入:时间段 T ,历史库存数据 f ,用户集合 W ,站点集合 S ,预测时间窗口 w

输出:分配任务用户集合 W_π

(1) $W_\pi \leftarrow \{\}$

(2) for $t \leftarrow 1$ to T do

(3) model \leftarrow FitPredictionModel(f_t)

- (4) $f_{i+w} \leftarrow \text{Predict}(\text{model}, t+w)$
- (5) $\pi \leftarrow \text{FindOptimalAssignment}(W, S, f_{i+w})$
- (6) append $W \cdot \pi$ to W_π
- (7) end

针对这 2 个子问题模型,本文为所提出的时空分布感知的自行车众包调度系统设计了对应的求解算法,其处理流程如图 3 所示。首先对于历史用户数据进行预处理,其次基于历史数据利用 VARMA 模型进行站点库存预测,然后通过二分图最优匹配算法求得用户和任务的匹配,最终产生任务分配决策。

3.1 基于向量自回归平滑模型的站点库存水平预测

校园作为一个典型的封闭场景,其中各个站点的共享单车库存分布存在着互相关联,而总的自行车保有量则保持相对稳定(假设校内外自行车不能流动),例如教学楼、宿舍、食堂等站点的不同时刻库存水平存在相关性,且能够与校园内师生的日常活动规律对应起来,基于对时间和空间相关性的观察,本文采用 VARMA 模型对多站点自行车库存水平进行建模。VARMA 模型分为自回归部分和滑动平均部分。自回归部分将预测值建模为过去一段时间内每个时刻取值的线性组合,历史值的加权求和即可得到预测值。具体而言,对于所有站点库存向量 f ,其 t 时刻的库存值可以表示为

$$f_t = A_1 f_{t-1} + A_2 f_{t-2} + \dots + A_p f_{t-p} + e_t + M_1 e_{t-1} + M_2 e_{t-2} + \dots + M_q e_{t-q} \quad (12)$$

式中: f_{t-k} 为当前时间 t 之前 k 个时刻所有站点库存值构成的 m 维向量; e_t 为 t 时刻所有站点库存值的噪声项,模拟了无法由其他变量解释的随机变化。超参数 p 和 q 分别为回归项和误差项向前追溯的时间步长,也称为模型的阶数, p, q 的大小也反映了未来值受历史值影响的窗口宽度。

在已有历史数据的情况下,可以根据站点库存数据求解出 VARMA 模型的系数 A, M 。由于 VARMA 已经是较为成熟的多元变量时序预测模型,且已有大量的研究工作和工程实践给出了求解其系数(即模型训练)的解决方案,例如极大似然估计(Maximum likelihood estimation, MLE)和 Yule Walker 方法。本文在这里不再重新设计模型训练算法,而是直接采用已有的 MLE 算法作为 FitPredictionModel。该算法输入站点库存历史数据,寻找使得似然函数在该数据上取得最小值的系数 A, M ,最终输出预测模型。当需要预测 t 时刻各站点库存时,只需要将前 p 天的历史数据代入模型中,就可以得到 t 时刻的预测值。

当需要估计 VARMA 模型在训练数据集上的参数值,以实现待测数据的最优预测时,可以采用最常用的极大似然估计方法,并通过梯度上升的方式在每个迭代步骤内更新参数的估计值,以最大化似然函数。在采用梯度上升的极大似然估计进行参数估计的情况下,对于 VARMA 模型,其似然函数包含自回归项和噪声项两部分,其中自回归项在计算损失函数的梯度时至少需要进行维度为 m 的向量数乘,并根据梯度更新 p 个自回归系数,因此所需要进行运算的复杂度为 $O(pm)$ 。假设噪声项 $e_t, e_{t-1}, \dots, e_{t-q}$ 为多元正态分布,采用基于最大期望(Expectation-maximization, EM)的方法对均值项、协方差矩阵以及噪声项系数同时进行估计。EM 算法由 E 步(Expectation step)和 M 步(Maximization step)交替组成。在 E 步,忽略求解多元正态函数的概率密度和对数运算的复杂度,对于 $q+1$ 个 m 维正态分布变量,计算其对数似然函数的梯度并进行参数更新的时间复杂度为 $O(qm)$;在 M 步,基于 E 步估计得到的概率值来最大化针对误差项系数 M_1, M_2, \dots, M_q 的似然函数,类似地,进行系数更新的时间复杂度为 $O(qm)$ 。假设完整算法的迭代步数为 k ,那么算法总体的时间复杂度即为 $O(km(p+q))$ 。

3.2 基于二分图最优匹配的任务分配决策

在时刻 t 可能最多存在 m 个需求不同、地点各异的任务,要将这些任务分配给 n 个可能会带来不等




图3 时空分布感知的自行车众包调度
Fig.3 Spatial-temporal aware crowd-sourcing bike scheduling

效用的用户,这个问题可以规约为1个组合优化问题。具体而言,将 n 个用户根据整数决策变量以多对一的模式分配给 m 个收益不同的调度任务,同时寻求最大的总和收益,这个问题显然是广义任务指派问题(General assignment problem, GAP)的一个实例。考虑只有1个任务的特殊情况,需要从所有用户中选出一部分用户完成此任务,每个用户只能选择二元决策。虽然本文的问题模型中并没有对任务可分配的用户数量做出限制,但是模型中任务分配的收益只与站点的库存缺失被满足的情况有关,因此可以规约为存在任务分配数量限制,此时原问题就等价于1个0-1背包问题,这个问题是经典的NP-Hard问题,无法确定是否存在多项式时间内的解法。近期的研究成果普遍采用强化学习^[23]、启发式搜索^[24]等方法来解决类似的组合优化问题,这些方法对计算资源要求较高,且求解过程存在随机性。本文将原任务分配问题转化为一个二分图最大匹配问题,并提出了1个基于匈牙利算法的匹配方法来求解最优任务分配决策^[25-26]。

(1) 重构二分图模型。定义1个二分图 $G=\langle W, S, \mathcal{E}^t \rangle$,其中 W 和 S 分别表示用户集合和站点集合在二分图上的节点, \mathcal{E}^t 为边二分图的边,表示在 t 时刻可能的任务分配方案。根据第2节给出的最优任务分配问题,1个自行车站点可能存在大于1的需求,即需要超过1个用户承担该站点的调度任务,这是1个典型的多对一匹配问题。为了能够在后续借助基于匈牙利算法的方法进行匹配的高效求解,需要对二分图进行重构,使得图中的两侧节点具有相同的个数。对于时刻 t 下的站点集合 S ,只考虑自行车库存需求大于0,即 $\tilde{f}_i(s_i)=\hat{f}_i(s_i)-f_t(s_i)>0$ 的站点,而不考虑存在库存盈余的站点,记为 $N^t=\{s|s\in S\cap\tilde{f}_i(s)>0\}$ 。对于 N^t 中的每个站点 s ,将其拆分为 $\text{ceil}(\tilde{f}_i(s))$ 个库存需求为1的伪节点,其中 ceil 为向上取整函数。例如,若是有某个站点的期望需求为1.5辆自行车,则将其拆分为2个伪节点,并将二分图中站点一侧的节点个数记为

$$|N^t|=\sum_{n\in N^t}\text{ceil}(\tilde{f}_i(n)) \quad (13)$$

对于二分图中的用户侧,同样添加足够数量的伪节点,使得用户侧节点集合 W' 的数量与站点侧节点数量相等,此时经过补足之后的二分图记为 $G'=\langle W', N^t, \mathcal{E}^t \rangle$,且满足 $|W'|=|N^t|$ 。二分图重构算法如算法2所示。

算法2 二分图重构算法

输入:当前时刻 t ,时间窗口 w ,用户集合 W ,站点集合 S ,站点预测需求 \hat{f}_i

输出:二分图 G'

- (1) $W' \leftarrow \{\}$
- (2) $N^t \leftarrow \{\}$
- (3) $\mathcal{E}^t \leftarrow \text{empty sparse matrix } \{\}$
- (4) for time $\leftarrow t$ to $t+w$ do
- (5) $N_{\text{demand}} \leftarrow \{n | \hat{f}_{\text{time}}(n) > 0\}$
- (6) for $n \leftarrow N_{\text{demand}}$ do
- (7) $N_{\text{dummy}} \leftarrow \text{ceil}(\hat{f}_{\text{time}}(n)) \text{ dummy nodes}$
- (8) append N_{dummy} to N^t
- (9) $W_{\text{dst}} = \{u | \text{destination of } u \text{ is } n\}$
- (10) for u to W_{dst} do
- (11) append $\mathcal{E}(u, n)$ to \mathcal{E}^t
- (12) end
- (13) end

- (14) append enough dummy users to W^t
 (15) construct G' with W^t, N^t, \mathcal{E}^t
 (16) end

图4给出了1个二分图重构的示例,有3个众包用户 u_1, u_2, u_3 和4个站点 s_1, s_2, s_3, s_4 。根据站点库存水平预测算法给出的结果, s_2 不存在库存调度需求, s_1 的库存需求为2, s_3, s_4 的需求为1, 因此需要将 s_1 拆分为2个伪节点, 同时在用户侧补充一个伪节点 u_4 , 最终形成1个在完全二分图上的一对一匹配问题。需要注意的是, 与伪节点的边的权重都记为0, 意味着选中这些边不会带来效用增益。因此, 初始决策问题可以转化为如下形式的二分图匹配问题




图4 二分图重构过程示例图

Fig.4 An example of bipartite graph reconstruction

需要注意的是, 与伪节点的边的权重都记为0, 意味着选中这些边不会带来效用增益。因此, 初始决策问题可以转化为如下形式的二分图匹配问题

$$\max_{\pi} \sum_{(u_i, n_j) \in \mathcal{E}^t} \hat{B}(u_i, n_j) \pi(u_i, n_j) \quad (14)$$

$$\text{s.t.} \quad \sum_{n_j} \pi(u_i, n_j) = 1 \quad u_i \in W^t, n_j \in N^t \quad (15)$$

$$\sum_{u_i} \pi(u_i, n_j) = 1, \quad u_i \in W^t, n_j \in N^t \quad (16)$$

$$\epsilon^t(u_i, n_j) = \begin{cases} \frac{1}{d(s_{u_i}, s_j)^{\gamma}} & u_i \notin \text{dummies}, s_{u_i} \in S, s_j \in S \\ 0 & \text{其他} \end{cases} \quad (17)$$

$$\pi(u_i, n_j) \in \{0, 1\} \quad u_i \in W^t, n_j \in N^t \quad (18)$$

式中 ϵ^t 表示经过二分图重构后边的权重, 若用户不为伪节点, 则边的权重平分初始决策问题中效用 $\hat{B}(u_i, s_j, t)$, 否则为0。

(2) 基于匈牙利算法的二分图匹配。对于带权二分图最大匹配问题, 匈牙利算法可以 $O(n^3)$ 的时间复杂度求解得到最大匹配结果^[27], 其中 n 是二分图一侧的节点数量。基于匈牙利算法的流程, 本文首先初始化1组可行顶标 l 和1个相等子图 G'_l 上的初始匹配 π_0 , 然后迭代地提升匹配权重来得到最优解, 最优匹配算法的伪代码如算法3所示。

算法3 二分图最优匹配算法

输入: 二分图 $G' = \langle W^t, N^t, \mathcal{E}^t \rangle$

输出: 最优匹配 π

- (1) Initialize π, l
- (2) while π is not perfect do
- (3) Pick an unmatched node $n \in N^t$
- (4) $X \leftarrow \{n\}; Y \leftarrow \emptyset; N(X) = \{m \mid \forall n \in X: (n, m) \in \mathcal{E}^t\}$
- (5) while True do
- (6) if $N(X) = Y$ then
- (7) Improve the labeling l to l'
- (8) $\delta = \min_{w_i \in X, n_j \in Y} \{l(w_i) + l(n_j) - \epsilon^t(w_i, n_j)\}$
- (9) $l'(v) \leftarrow l(v) + \delta$ for $v \in X$
- (10) $l'(v) \leftarrow l(v) - \delta$ for $v \in Y$

- (11) else
- (12) Pick a node $m \in N(X) \setminus Y$
- (13) if m is free then
- (14) Flip the augmenting path from n to m
- (15) Break the current loop
- (16) else
- (17) Assume m is matched with k
- (18) $X \leftarrow X \cup \{k\}$
- (19) $Y \leftarrow Y \cup \{m\}$
- (20) end
- (21) end
- (22) Update $N(X)$
- (23) end
- (24) end
- (25) return π

定义 1 可行顶标 对于 1 个二分图 G' , 其上的可行顶标满足: $\forall (u_i, n_j) \in \mathcal{E}'$, $l(u_i) + l(n_j) \geq \varepsilon'(u_i, n_j)$ 。

定义 2 相等子图 1 个相等子图 $G'_i = \langle W', N', \mathcal{E}'_i \rangle$ 是图 G' 的 1 个子图, 且满足 $\mathcal{E}'_i = \{(u_i, n_j) \in \mathcal{E}' | l(u_i) + l(n_j) = \varepsilon'(u_i, n_j)\}$ 。

最优匹配算法的主要流程分为如下 2 个步骤:

(1) 寻找增广路径。根据 Kuhn-Munkres 定理, 如果 1 个匹配 π 是相等子图 G'_i 上的完美匹配, 那么 π 就是 G' 上的一个最优匹配。因此, 从 1 个为匹配节点出发, 在相等子图 G'_i 上寻找增广路径, 如果找到了增广路径, 就翻转路径上所有边的匹配性。

(2) 更新可行顶标。如果无法找到增广路径, 那么寻找增广路径的 DFS 过程构成了 1 棵交错树, 减小给交错树左侧节点的顶标, 并等量增加右侧节点的顶标, 这样保持交错树内的边依然在相等子图内的同时, 可能会有新的边加入相等子图, 且新边能够成为增广路的一部分。不断地修改顶标就可以找到增广路。

当找到 G'_i 的完美匹配时, 说明已经找到了 G' 的 1 个最优匹配, 匹配结果 π 即为最优任务分配决策。

由算法 2 的过程易得知进行二分图重构所需操作的时间复杂度为 $O(\omega mu)$ 。算法 3 的主要流程是基于匈牙利算法进行的二分图最优匹配过程, 因此其时间复杂度为 $O(|N'|^3)$, 其中 $|N'|$ 为重构之后二分图的顶点数量。考虑到一般情况下用户数量 n 大于站点数量, 因此基于二分图匹配的任务分配决策算法的整体时间复杂度为 $O(n(n^2 + \omega m))$ 。结合基于向量自回归模型的时序预测算法的时间复杂度分析, 整个系统在每个时刻进行时序预测和任务分配操作的时间复杂度为 $O(km(p + q) + n(n^2 + \omega m))$ 。

4 实验分析

本文采用东南大学九龙湖校区共享单车系统收集的真实数据集进行实验评估。数据集包含了 2023 年 12 月 1 日至 12 月 28 日共 27 天九龙湖校区内所有共享单车的租借和归还记录, 总计约 40 万条。每条记录包含了脱敏之后的共享单车服务订单信息, 包括开始时间、结束时间、开始地点坐标、结束地点坐标和消费金额。

本文对数据集的预处理和实验分析过程均在自有服务器平台完成, CPU 为 Intel E5-2620 v4 @

2.10 GHz 16核 32线程,内存空间为 64 GB,代码编写采用 Python 3.11,在预处理、算法实现和实验评估过程借助了包括 Pandas、Matplotlib 等常用的开源第三方库。

4.1 数据预处理和实验设置

实验首先去除数据集中无关数据,仅保留每条共享单车订单(以下简称记录)的开始时间、结束时间、开始地点坐标和结束地点坐标。通过 GeoJson 格式定义东南大学九龙湖校区校园边界的多边形,并过滤掉起点或终点不在校园内的记录。由于校园共享单车采用无桩的运营模式,因此首先需要根据自行车的停靠地点空间聚集特征设置虚拟的自行车站点。本文采用 K-Means 算法对所有记录的起点和终点进行聚类,聚类簇的数量为 30,最大迭代次数为 1 000 次。在完成 30 个簇的聚类之后,根据每个簇类相关的记录条数进行排序,选择自行车流动性最强的前 20 个簇类作为自行车站点,最终得到的站点如图 5 所示。从图 5 中可以看出,共享单车的停放点在局部呈现聚集分布特性,且与功能区划高度相关,绝大部分自行车站点位于宿舍、图书馆、教学楼、实验楼、食堂、校门等场所附近。将记录中起点和终点均与设置的站点无关的记录去除,保留有关记录。以 5 min 为时间片粒度,对所有订单时间进行取整,以标识系统运行时间。根据第 2 节给出的库存模型估算每个站点在每个时刻的库存水平,并将每个站点的一天内的库存校准为正数。由于除了普通用户使用共享单车产生的流动之外,校园内日常还增派了多位工作人员不定时以货运三轮来调度自行车,因此仅仅依靠数据集并不能得到真实完整的站点库存数据,本文将此数据集推算出的库存数据作为真实数据的近似。




图 5 校园共享单车停靠点聚类结果

Fig.5 Clusters of sharing bike stations on campus

图 6 刻画了最后一周时间内两个站点自行车库存随时间变化的柱状图,其中每个条形覆盖 2 h。图 6(a) 站点位于梅园宿舍区门口,由于学生一般从早上 8 时开始上课,因此此处的自行车库存从 6~8 时开始持续减少,从 20~22 时开始增多。图 6(b) 站点位于图书馆门口,从 8 时起有学生陆续到达开始学习,因此从 8 时开始此处自行车库存持续增长,直到 20~22 时左右才开始显著下降。从图 6 可以看出,校园内自行车站点的库存数量随一天之内的时间变化呈现周期性,且不同区位站点的库存水平呈现的周期性和波动性也有显著区别,因此其中隐藏的变化模式规律具有提升共享单车调度的可能性。

由于 VARMA 回归模型包含超参数 p 和 q , 分别代表了 AR 部分和 MA 部分的阶数,在进行实验评估和实际运行过程中,不同的 p 和 q 的取值组合会直接影响 VARMA 模型对数据的拟合和预测效果。常




图 6 库存数量随时间变化

Fig.6 Changes of inventory with time

用的超参数 p 和 q 选择方法包含相关函数 (Auto correlation function, ACF) 和偏自相关函数 (Partial auto correlation function, PACF) 图、赤池信息量准则 (Akaike information criterion, AIC) 和贝叶斯信息准则 (Bayesian information criterion, BIC) 信息准则, 以及网格搜索等。本文在这里采用 AIC 信息准则进行超参数取值调优。具体而言, AIC 准则通过计算参数数量 k 和极大似然值 L 的关系, 即

$$AIC = 2k - 2 \ln L \quad (19)$$

实验中需要选择既能良好拟合数据又不过于复杂的模型。如果模型过于复杂 (即参数过多), 则可能会过拟合数据, 这在 AIC 中通过增加 $2k$ 的惩罚项来避免, 最终选择 AIC 值最小的模型。本文利用实际时序数据来计算 AIC 值, 从而初步选出最优的 p 、 q 取值。具体而言, 本文以 4 天作为库存时序数据回归的滑动窗口, 对 p 和 q 均取 1~5 内的值并将其组合, 建立针对所有站点库存水平的 VARMA 模型并进行回归, 从而计算出 AIC 值。表 1 给出了不同的参数 p 和 q 组合下 VARMA 模型对站点库存时间序列的回归时 AIC 指标。从表 1 中可以看出, 当 p 取 3 并且 q 取 5 时, AIC 取到最小值为 2 792.84, 说明此时似然值最大, 估计得到的模型参数能够更好地反映实际数据的变化规律。因此本文在实验中均采用 $p=3$ 、 $q=5$ 的 VARMA 模型。

表 1 VARMA 模型不同 p 、 q 选择下 AIC 值
Table 1 AIC value of different combinations of p and q in VARMA model

滑动平均 阶数 q	自回归阶数 p				
	1	2	3	4	5
1	2 819.36	2 794.06	2 795.31	2 795.10	2 797.20
2	2 812.36	2 795.55	2 794.80	2 794.05	2 793.43
3	2 805.08	2 793.79	2 793.39	2 794.34	2 794.99
4	2 801.74	2 796.80	2 794.27	2 793.88	2 798.27
5	2 800.61	2 795.87	2 792.84	2 794.06	2 795.00

为了全面客观地考察本文设计的算法在解决共享单车众包调度问题上的表现, 本文另外选取了 4 个对比方法作为对照组: (1) 随机分配 (Random)。对于每个存在调度需求为 k 的站点, 随机选择 k 位用户; (2) 最近用户优先 (Nearest worker first, NWF)。对于每个存在调度需求的站点, 选择 k 位距离最近的用户; (3) 最优二分图匹配 (Optimal bipartite graph matching, OBG M)^[28]。与本文所提出的 STDCSS 不同的是, OBG M 不在每个时间片内对站点未来的库存需求进行预测, 而是直接以当前时刻的需求作为未来需求的近似值, 在此基础上实现基于二分图匹配的决策算法; (4) 单车网络强化学习 (BikeNet reinforcement learning, BN-RL)^[29]。采用深度学习来预测共享单车的未来需求, 包括使用图卷积网络 (Graph convolutional neural network, GCN) 表征空间关联性、LSTM 表征时间特性以及自动编码器 (Auto encoder, AE) 来表征上下文因素, 然后通过深度强化学习来求解站点库存平衡的整数线性优化问题。

4.2 实验评估

本文首先评估了 5 种方法在用户数量发生变化时的系统效用的变化情况, 站点数量固定为 20。从图 7(a) 可以看出, 5 种方法中, 本文提出的 STDCSS 方法的效用水平较 OBG M、Random 和 NWF 这 3 种方法有显著优势, 并且其效用随着用户数量的增长呈现线性增长的趋势。STDCSS 方法在用户数量为 100 时的效用水平就超过了另外 3 种方法在 250 个用户时的情况。与之相对地, OBG M 方法的效用比其余的 2 种方法略高, 但远远低于 STDCSS 方法, 这说明后者额外的库存需求预测步骤能够有效预测未来时刻各站点的需求, 并为后续的最优匹配过程提供更接近于最优解的指导, 提升系统总体表现。此外, Random 方法作为基线, 其表现与 NWF 方法基本一致, 这说明在单个时间片内采用贪心的思路或许能够在当前时刻下较好地解决共享单车调度问题, 但是对于跨时间片的行程无法进行有效的任务分配。BN-RL 得益于深度学习神经网络对站点需求时空波动规律的精确感知, 以及深度强化学习对优化问题的精确规划, 其表现出了最高的系统效用水平。然而, 由于在校园范围内, 站点数量和用户数量相比于城区等大范围内的单车调度系统而言较少, 因此问题可行解所在的空间也较为局限, 导致 BN-RL

与STDCSS相比并没有产生理想的优势。当用户数量不超过150时,二者表现出的效用水平较为接近。当用户数量进一步增大时,BN-RL的效用优势逐渐增大。图7(b)展示了当用户数量固定为300、站点数量发生变化时5种方法的效用表现。在这种设置下,用户数量处于显著满足站点需求的水平,因此站点数量增多时系统效用也能够增加。同样地,STDCSS方法较除了BN-RL其他3种方法表现出显著的优势。具体而言,当站点数量为20时,STDCSS方法产生的任务分配策略所带来的系统效用为其他3种方法的2.5倍,这也与图7(a)中相同效用水平下STDCSS所需要的人数与其他方法的比例相一致。同样地,BN-RL的效用依然处于最高水平,且随着站点数量的增大,BN-RL的效用优势逐步扩大。

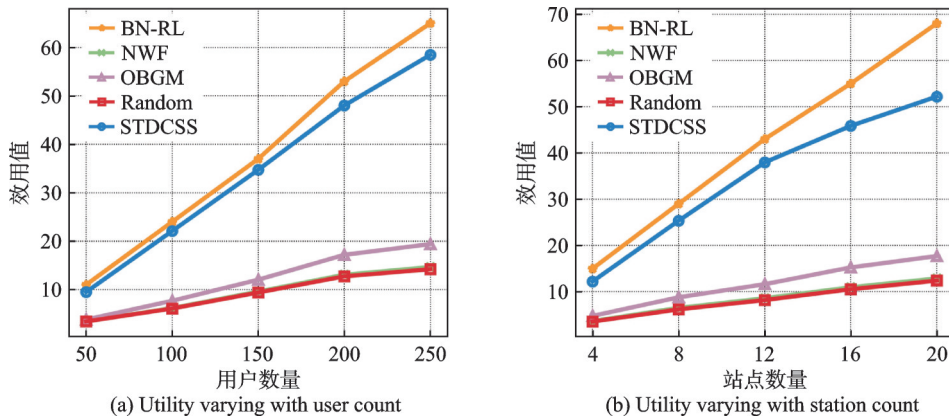


图7 系统效用随用户数量和站点数量变化
Fig.7 Changes of system utility with user count and station count

为了评估各个算法的运行效率,本文通过仿真实验测量了它们在各个参数下的运行时间。需要注意的是,虽然运行时间与具体的硬件配置和系统工况高度相关,但是不同的算法在相同参数设置下的运行时间之间的相对关系依然是有参考价值的。图8(a)和(b)给出了算法运行时间分别受用户数量和站点数量影响而产生的变化。显而易见的是,随着问题规模的扩大,BN-RL方法运行时间的增长趋势较其他算法更为明显,其次是STDCSS方法,与此二者相比,剩余3种方法的运行时间随实验参数的变化影响不大。STDCSS引入的预测算法虽然对于提升系统效用发挥了显著作用,但是其也需要进行更多更加复杂的运算操作。本文为了保证预算算法的效果,采用了在每个时间片对滑动窗口进行预测模型训练的模式,即每个时间片都会引入额外的时间开销,这部分时间开销明显超过了OBGM算法,成为

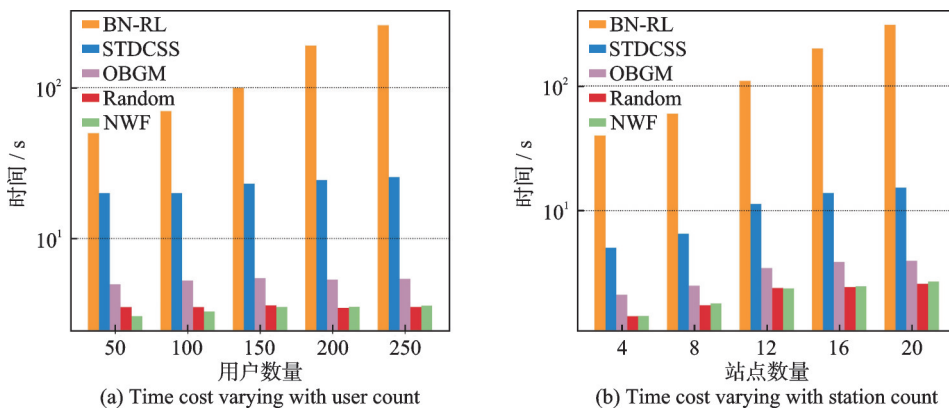


图8 运行时间随用户数量和站点数量变化
Fig.8 Changes of running time with user count and station count

影响系统运行时间的主要因素。STDCSS算法的运行时间受站点数量的影响较大,而其与用户规模的倍率关系并没有那么明显,因为站点数量是VARMA模型参数个数的决定性因素。而BN-RL方法所需要在训练数据集上对神经网络模型和强化学习模型进行训练,尽管校园共享单车数据集的规模并不大,但是与其他方法相比,对未来站点需求的准确拟合以及单车调度决策的优化目标,使得多轮次训练所花费时间开销仍然要高出一个数量级。因此,从系统可拓展性角度分析,在实际应用中需要适当控制节点个数,或者加配相当的计算资源,来满足每个时间片内的预测和匹配运算资源需求。

5 结束语

本文提出了一种校园共享单车资源调度系统,它能够动态感知时空分布,并解决库存紧张和资源调度效用之间的矛盾。该系统首先利用VARMA向量自回归滑动平均模型对自行车站点的动态变化进行建模,预测未来时刻站点库存紧缺情况,以应对突发变化。其次,为了解决众包资源调度场景下的自行车调度效用和开销之间的矛盾,提出了基于二分最优匹配模型的调度任务分配方法,并通过优化匈牙利算法来实现高效的任务分配决策。仿真实验结果表明,该方法能够有效提高共享单车调度的系统效用,减少因库存紧张导致的服务质量损失,并有效平衡自行车的时空分布。

参考文献:

- [1] CHEMLA D, MEUNIER F, CALVO R W. Bike sharing systems: Solving the static rebalancing problem[J]. *Discrete Optimization*, 2013, 10(2): 120-146.
- [2] RAVIV T, TZUR M, FORMA I A. Static repositioning in a bike sharing system: Models and solution approaches[J]. *EURO Journal on Transportation and Logistics*, 2013, 2(3): 187-229.
- [3] 赵达. 基于共享单车大数据的智能调度平台的研究与应用[D]. 北京: 北京工业大学, 2024.
ZHAO Da. Research and application of intelligent dispatching platform based on big data of shared bicycle[D]. Beijing: Beijing University of Technology, 2024.
- [4] 刘恒孜, 贺玉龙, 宋太龙, 等. 共享单车需求预测及调度优化[J]. *科学技术与工程*, 2021, 21(35): 15247-15254.
LIU Hengzi, HE Yulong, SONG Tailong, et al. Demand forecast and scheduling optimization of shared bicycles[J]. *Science Technology and Engineering*, 2021, 21(35): 15247-15254.
- [5] GHOSH S, VARAKANTHAM P, ADULYASAK Y, et al. Dynamic repositioning to reduce lost demand in bike sharing systems[J]. *Journal of Artificial Intelligence Research*, 2017, 58: 387-430.
- [6] LI Y, ZHENG Y, YANG Q. Dynamic bike reposition: A spatio-temporal reinforcement learning approach[C]//*Proceedings of ACM SIGKDD*. [S.l.]: ACM, 2018: 1724-1733.
- [7] PFROMMER J, WARRINGTON J, SCHILDBACH G, et al. Dynamic vehicle redistribution and online price incentives in shared mobility systems[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2014, 15(4): 1567-1578.
- [8] SINGLA A, SANTONI M, BARTOK G, et al. Incentivizing users for balancing bike sharing systems[C]//*Proceedings of the AAAI Conference on Artificial Intelligence*. Austin: AAAI, 2015: 723-729.
- [9] PAN L, CAI Q, FANG Z, et al. A deep reinforcement learning framework for rebalancing dockless bike sharing systems[EB/OL]. (2018-02-13)[2025-06-23]. <https://arxiv.org/abs/1802.04592>.
- [10] GAO Y, TAO J, XU Y, et al. Collaborative route plan for parking sites selection in bike-sharing systems[C]//*Proceedings of IEEE CSCWD*. [S.l.]: IEEE, 2018: 814-819.
- [11] Citibike. Bike angels[EB/OL]. (2019-06-19). <http://www.citibikenyc.com/bikeangels>.
- [12] GHOSH S, VARAKANTHAM P. Incentivizing the use of bike trailers for dynamic repositioning in bike sharing systems[C]//*Proceedings of ICAPS*. Pennsylvania, USA: [s.n.], 2017: 373-381.
- [13] 李连欣. 基于深度强化学习的共享单车调度策略研究[D]. 武汉: 武汉理工大学, 2023.
LI Lianxin. Research on bike-sharing dispatching strategy research on bike-sharing dispatching strategy[D]. Wuhan: Wuhan University of Technology, 2023.
- [14] 石兵, 黄茜子, 宋兆翔, 等. 基于用户激励的共享单车调度策略[J]. *计算机应用*, 2022, 42(11): 3395-3403.
SHI Bing, HUANG Xizi, SONG Zhaoxiang, et al. User incentive based bike-sharing dispatching strategy[J]. *Journal of*

- Computer Applications, 2022, 42(11): 3395-3403.
- [15] WANG S, CHEN H, CAO J, et al. Locally balanced inductive matrix completion for demand-supply inference in stationless bike-sharing systems[J]. IEEE Transactions on Knowledge and Data Engineering, 2020, 32(12): 2374-2388.
- [16] HE S, SHIN K G. Distribution prediction for reconfiguring urban dockless e-scooter sharing systems[J]. IEEE Transactions on Knowledge and Data Engineering, 2021, 34(12): 5722-5740.
- [17] LI X, XU Y, CHEN Q, L. et al. Short-term forecast of bicycle usage in bike sharing systems: A spatial-temporal memory network[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(8): 10923-10934.
- [18] WANG S, ZHU X, WANG G, et al. eShare+: A data-driven balancing mechanism for bike sharing systems considering both quality of service and maintenance[J]. IEEE Transactions on Knowledge and Data Engineering, 2023, 35(10): 10497-10513.
- [19] SAPANKEVYCH N I, SANKAR R. Time series prediction using support vector machines: A survey[J]. IEEE Computational Intelligence Magazine, 2009, 4(2): 24-38.
- [20] 张朝辉,罗炜,林康熙,等.基于时序分析的电网合并单元电平预测[J].数据采集与处理,2022,37(5):1169-1178.
ZHANG Zhaohui, LUO Wei, LIN Kangzhao, et al. Electrical level prediction of power grid merging unit based on time series analysis[J]. Journal of Data Acquisition and Processing, 2022, 37(5): 1169-1178.
- [21] NGUYEN Du. Vector autoregressive moving average model with scalar moving average[EB/OL]. (2019-09-01) [2025-06-23]. <https://arxiv.org/abs/1909.00386>.
- [22] 李家鑫,宋佳怡,李冠辰,等.基于多元时间序列预测的智能交通系统[J].现代信息技术,2019,3(12):104-105.
LI Jiabin, SONG Jiayi, LI Guanchen, et al. Intelligent transportation system based on multivariate time series prediction[J]. Modern Information Technology, 2019, 3(12): 104-105.
- [23] 王心一,陈志江,雷磊,等.多无人机网络边缘智能计算卸载算法[J].数据采集与处理,2023,38(6):1286-1298.
WANG Xinyi, CHEN Zhijiang, LEI Lei, et al. Computation offloading algorithm for multi-UAV network based on edge intelligence[J]. Journal of Data Acquisition and Processing, 2023, 38(6): 1286-1298.
- [24] 张玉琴,梁莉,张小洪,等.基于改进启发式优化算法的无线网络资源分配[J].数据采集与处理,2022,37(6):1288-1296.
ZHANG Yuqin, LIANG Li, ZHANG Xiaohong, et al. Resource allocation of wireless networks based on improved heuristic optimization algorithm[J]. Journal of Data Acquisition and Processing, 2022, 37(6): 1288-1296.
- [25] ZHAO B, DONG H, WANG Y, et al. A task allocation algorithm based on reinforcement learning in spatio-temporal crowdsourcing[J]. Applied Intelligence, 2023, 53: 13452-13469.
- [26] SHA Z, CHAUDHARI A M, PANCHAL J H. Modeling participation behaviors in design crowdsourcing using a bipartite network-based approach[J]. Journal of Computing and Information Science in Engineering, 2019, 19(3): 031010.
- [27] CHUZHONG J, SANJEEV K. A faster combinatorial algorithm for maximum bipartite matching[EB/OL]. (2023-12-19) [2025-06-23]. <https://arxiv.org/abs/2312.12584>.
- [28] SILVA M C M, ALOISE D, JENA S D. Data-driven prioritization strategies for inventory rebalancing in bike-sharing systems [J]. Omega, 2024, 129: 103141.
- [29] ZHU Hang, SHOU Tieqi, GUO Ruiying, et al. RedPacketBike: A graph-based demand modeling and crowd-driven station rebalancing framework for bike sharing systems[J]. IEEE Transactions on Mobile Computing, 2023, 22(7): 4236-4252.

作者简介:



沈如达(1990-),通信作者,男,研究实习员,研究方向:算法优化、智慧校园等,E-mail: shenruda@seu.edu.cn。



何万源(1996-),男,研究实习员,研究方向:信号处理、机器学习等。



许艺凡(1991-),男,博士,助理研究员,研究方向:资源调度、在线算法设计与分析等。

(编辑:刘彦东)