

2-16-2023

Machine Learning-based Simulation Research of On-line Subway Pedestrian Flow Control

Jiajie Shi

1. *Tianjin University of Technology, Tianjin 300000, China;* 815425329@qq.com

Peng Yang

1. *Tianjin University of Technology, Tianjin 300000, China;* 29139475@qq.com

Yannan Pi

2. *Metro Operation Technology R&D Center, Beijing Metro Operation Co. , Ltd. , Beijing 100082, China;*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Simulation Platform / System Technology is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Machine Learning-based Simulation Research of On-line Subway Pedestrian Flow Control

Abstract

Abstract: In recent years, a large number of digital experiments have been carried out in the field of space launch, such as digital design verification, digital joint training and simulation training, and rocket-ground joint simulation evaluation, all of which involve the space launch information visualization. Through virtual reality technology, system simulation technology, data visualization technology, etc., *on the basis of multi-thread, multi-module architecture design idea, and message queue system interaction mode, the space launch visual simulation analysis technology platform with functions of data management, scenario management, calculation management, and script management is constructed. The application cases of visual simulation analysis for multi-satellite hazard, special operation test launch process, fairing opening and test launch flow status are studied.*

Keywords

space launch informatization, digital experiment, 3D visualization, virtual simulation, simulation and evaluation

Recommended Citation

Jiajie Shi, Peng Yang, Yannan Pi. Machine Learning-based Simulation Research of On-line Subway Pedestrian Flow Control[J]. Journal of System Simulation, 2023, 35(2): 386-395.

基于机器学习的地铁行人流在线优化控制研究

史佳洁¹, 杨鹏^{1*}, 皮雁南²

(1. 天津理工大学, 天津 300000; 2. 北京市地铁运营有限公司 地铁运营技术研发中心, 北京 100082)

摘要: 为了实现高峰期地铁站行人流管控的在线优化, 设计了基于机器学习的地铁站行人流管控算法框架。以某地铁车站早高峰的行人流管控流程为研究对象, 利用 Agent 技术搭建地铁站行人流管控仿真模型。多次运行仿真模型可以获得深度学习网络的训练数据。通过对网络进行充分训练, 得到优化调度策略。将网络接入地铁站行人流实时运行数据, 实现实时优化管控。仿真实验表明: 引入的深度强化学习框架可以实现在线优化, 调度结果优于传统方法。

关键词: 深度强化学习; 行人流管控; 地铁站调度策略; 在线仿真; 实时优化

中图分类号: TP391.9

文献标志码: A

文章编号: 1004-731X(2023)02-0386-10

DOI: 10.16182/j.issn1004731x.joss.21-0835

引用格式: 史佳洁, 杨鹏, 皮雁南. 基于机器学习的地铁行人流在线优化控制研究[J]. 系统仿真学报, 2023, 35(2): 386-395.

Reference format: Shi Jiajie, Yang Peng, Pi Yannan. Machine Learning-based Simulation Research of On-line Subway Pedestrian Flow Control[J]. Journal of System Simulation, 2023, 35(2): 386-395.

Machine Learning-based Simulation Research of On-line Subway Pedestrian Flow Control

Shi Jiajie¹, Yang Peng^{1*}, Pi Yannan²

(1. Tianjin University of Technology, Tianjin 300000, China;

2. Metro Operation Technology R&D Center, Beijing Metro Operation Co., Ltd., Beijing 100082, China)

Abstract: For the online optimization of pedestrian flow control in subway station, an algorithm frame for pedestrian flow control in subway station based on machine learning is designed. The pedestrian flow control process of a subway station during morning rush hour is selected, and the agent-based model is built to simulate the control process. The training data is collected through the multiple runs of the model, which is used as the input of deep reinforcement learning network, and the mature net is obtained through adequate training to provide the optimizing scheduling policy. Linking the actual data with the mature net to realize the real-time schedule optimization of subway pedestrian flow control. Simulation experiments show that the framework of the deep reinforcement learning can realize the on-line optimization and the performance is better than traditional algorithm.

Keywords: deep reinforcement learning; pedestrian flow control; scheduling strategy in subway station; online simulation; real-time optimization

0 引言

随着我国城市化进程的飞速发展, 地铁枢纽交通以其准时、快捷和运量大等特点在城市公共交通中所占的比重逐年提高。各城市的地铁线路

长度翻倍增长, 2020 年中国内地客流总量达到 175.27 亿人次, 北京地铁总客运量超 20 亿人次。其快速发展使得地铁运营中的问题也随之暴露, 地铁拥堵现象频繁发生, 存在一定的安全隐患,

收稿日期: 2021-08-18 修回日期: 2021-11-15

基金项目: 中央高校基本科研业务费(2019JBM032)

第一作者: 史佳洁(1997-), 女, 硕士生, 研究方向为复杂系统仿真。E-mail: 815425329@qq.com

通讯作者: 杨鹏(1977-), 男, 副教授, 博士, 研究方向为复杂系统仿真。E-mail: 29139475@qq.com

在一定程度上影响着地铁枢纽站点的发展。

由于地铁行人系统复杂度极高,且影响因素众多,难以建立精准的数学模型,因此国内外的学者多采用系统仿真的方法对其进行建模研究。王媛媛^[1]基于行人动力学模型,利用仿真技术建立了南京某地铁站进出站行人流模型,为研究地铁站乘客的疏导问题提供借鉴;李建华等^[2]利用仿真模型比较了不同布局方案对地铁站行人流过站时间的影响;鲁晨等^[3]运用仿真技术优化综合交通换乘枢纽的设计方案,提升了换乘服务水平;杨天阳等^[4]对非遗博览园站布局方式进行仿真模拟分析,对该地铁站的设施规模站内布局以及运营中应该注意的人流聚集点提出修改意见;Ciro Caliendo等^[5]对博物馆起火时的行人流疏散进行了模拟,并利用疏散仿真的模拟结果优化了博物馆的布局方案。

上述行人流仿真研究都是应用于场馆布局方案规划阶段的离线仿真研究,这种离线仿真模型不接收系统的实时数据输入,虽然可以用于场馆人流规划方案的评估,却无法对行人流管控的调度决策提供实时决策支撑。地铁高峰期的到达人流具有显著的波动性,现场管控需要根据现场状况动态调整限流和疏导方案。仿真模型虽然可以接收行人到达、站内负荷情况以及管控措施的输入,得到管控措施效果的预测结果,但无法得到最优管控策略。通过机器学习对充足的仿真输入、结果数据进行学习,则能够实现输入与最优管控策略的映射关系。

机器学习现已广泛应用于人脸识别、搜索引擎、交通^[6]、医学诊断^[7-8]、军队兵力优化^[9]等领域,在行业内积累了大量样本数据可以用于训练机器学习网络。张伟罡等^[10]搭建燃烧控制仿真模型,运用机器学习优化实现工业炉炉温智能控制;李增有^[11]运用机器学习不断检测与更新滤波信号,优化跟踪器,实现长时间稳定跟踪目标。

本文以北方某地铁站为研究对象,研究如何实现优化决策地铁站行人流管控的问题。最终目

的是为了实现地铁站服务流程的优化并提高设备的利用率。

1 地铁行人流管控目标及变量

1.1 管控目标的确定

对于优化地铁枢纽站点的运营业务,总目标是要提高它的整体性能,达到各方面的负载均衡,将利益大化、成本小化。提高运营稳定性、服务水平、设备利用率是实现这个总目标的重要因素,如图1所示。

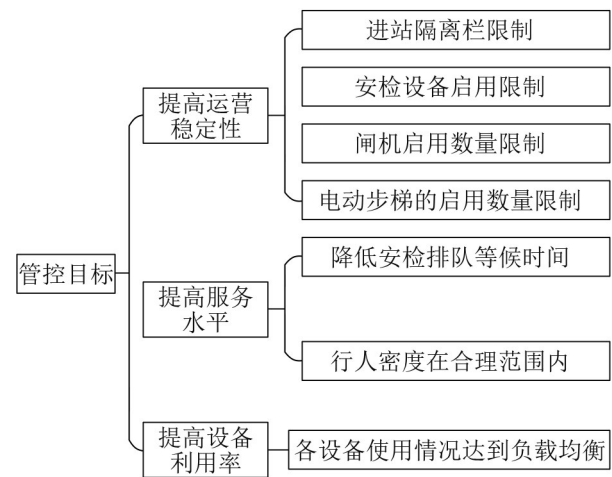


图1 管控目标

Fig. 1 Control objectives

1.2 控制变量分析

高峰时期,行人进站可以采用的管控措施主要包括以下几个方面。

1、设置进站隔离栏

高峰时期进站行人较多的情况下,设置一定数量的可开闭的隔离栏,缓解站内行人流压力,实现对站内行人流量的调整。

2、安检设备数量以及人工安检数量

高峰时期进站行人较多的情况下,可以不通过安检设备选择人工安检完成进站,实现分流。

3、进出站闸机开启的数量

根据当前情况下进出站行人的比例,相应改变闸机的进出方向,调整进出站闸机数量。

4、电动扶梯是否启用

若在行人拥挤的情况下，相应开启电动扶梯，加快通行进程。

1.3 观测变量分析

可以通过摄像机、物联网传感器实时采集高峰时期地铁站在当前工作人员调控之后站外限行区、站内以及站台等区域的行人数量。

1、站外限行区行人数量

站外排队的行人数量分为 2 个等级：0~100 人、100 人以上。

2、站内关键区行人数量

站内主要包括闸机、安检区、大厅 3 个区域，这 3 个区域的行人数量分为 4 个等级：100 人以内、100~200 人、200~300 人、300~400 人。

3、站台限行区行人数量

站台区域的行人数量分为 4 个等级：100 人以内、100~150 人、150~200 人、200~250 人。

2 基于机器学习的地铁行人流量管控

深度强化学习将深度学习的感知力和强化学习的决策力相结合，在面对复杂环境时可以做出更优决策^[12]，深度 Q 网络(deep Q network, DQN)作为其典型代表，将卷积神经网络与 Q-learning 相结合^[13]，完成决策优化。

在地铁行人流量管控仿真模型中引入 DQN，仿真系统为学习主体，把当前时刻各区域的行人流量密度以及上一时刻的隔离栏设置、安检通道数量、人工安检通道数量、闸机数量、电动扶梯开启数量作为系统状态；预设好 DQN 的网络参数，通过观察系统状态变化实时调整管控措施，管控措施包括隔离栏设置长度的增减、安检通道数量的增减、人工安检通道数量的增减、闸机数量的增减、电动扶梯开启数量的增减；对每一次决策给予奖励，以便于系统判断下次遇到这种情况调整管控措施，优化策略。DQN 算法与仿真模型的结合主要体现在 6 个方面，如图 2 所示。

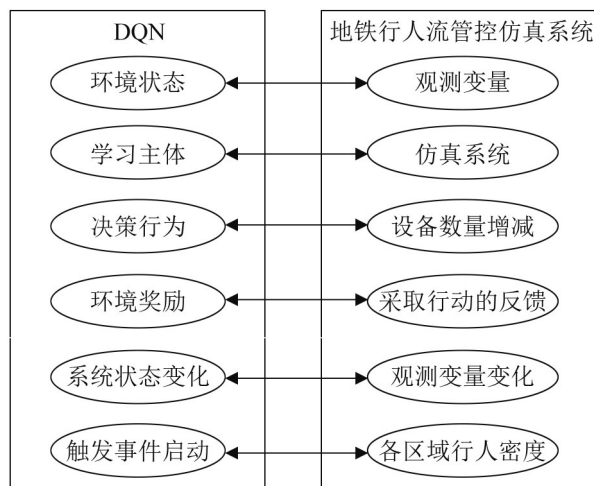


图 2 DQN 与地铁行人流量管控仿真模型结合点
Fig. 2 Combining of DQN and simulation model of pedestrian flow control in subway station

3 地铁行人流量管控模型的搭建

3.1 模型介绍

地铁行人流量管控仿真模型的开发是基于 Agent 的封装建模，根据地铁枢纽站点运营流程划分为不同的 Agent 类，用来描述行人进站、安检、过闸机、等候上车，以及排队等流程。

Main 类负责实现地铁行人流量管控业务的所有流程，完成所有 Agent 之间的沟通。在 Main 智能体中根据地铁站提供的进站时刻表设置进站地铁信息。调用行人智能体进站情况，通过摄像机、物联网传感器获得各区域的行人流量密度状态，由 Main 类分别向站外、安检、大厅，以及站台智能体发出限流服务请求。

3.2 模型输入

该模型的输入数据为早高峰时每 5 min 进站总人数以及早高峰地铁到达时刻表。

新到达进站总人数通过高峰时段在各进站口布控调研人员以 5 min 为时间间隔统计得到，在工作日和休息日的早高峰时间段均进行了调研，即 07:00—10:00。该地铁站每 5 min 早高峰时段进站人数统计如图 3 所示。




图3 每5 min进站总人数统计

Fig. 3 Statistics of total number of people entering the station of every 5 min

早高峰地铁到达时刻表由地铁站工作人员提供, 如表1所示。

表1 早高峰地铁到达时刻表

Table 1 Subway arrival schedule during morning rush hour

时段	该时段首发时间	时间间隔
07:00—08:00	07:01	每4 min一趟
08:00—09:00	08:00	每3 min一趟
09:00—10:00	09:01	每3 min一趟

通过对上述客流调研数据整理以及与专业工作人员的沟通, 汇总整理得到模型输入数据。

3.3 模型参数设置

该模型根据 Agent 将参数设置分为2个部分。

1、设备相关参数

设备相关参数在 Main Agent 中设置, 以实地调研结果作为参数设置依据。这些参数同时也是影响管控结果的重要因素, 将其作为模型的初始参数配置, 便于后期调整, 如表2所示。

表2 设备相关参数设置

Table 2 Device parameters setting

参数	初值
安检通道数量/个	16
人工安检数量/个	4
闸机数量/个	84
隔离栏长度/m	20
电梯数量/个	24

2、可变参数

该部分参数在 Person Agent 中设置, 由于安检

速度、行人行走步速这2个因素在一定程度上也会对系统运行结果产生影响, 且会受到个人差异及环境因素的影响, 存在一定的不确定性。因此, 模型也将其作为参数设定, 根据对大量人流的调研以及对数据的拟合处理, 确定了一个可以涵盖多数情况的参数数值, 如表3所示。

表3 可变参数设置

Table 3 Variable parameters setting

参数	初值
安检速度/(个/m)	Triangular(2.5, 5.5, 2.5)
行人行走速度/(m/s)	Triangular(0.8, 1.6, 0.8)

3.4 模型确认

本文使用 T 检验方法对仿真模型进行校验, 因本文最终目的是优化管控目标, 且提高运营稳定性中各项作为模型输入, 故不适合用于模型确认; 提高设备利用率相较于提高服务水平而言是一个次要影响因素, 因此不将其作为模型确认依据; 提高服务水平中的因素可用于模型确认, 但由于行人流密度的历史数据提供具有一定难度, 故选取管控目标中的安检排队时间作为假设检验的测量值, 将模型输出的测量值与历史数据中安检平均排队时间做对比, 进行假设检验。模型经过多次运行输出的数据呈现正态分布, T 检验参数检验方法适用于独立同分布的正态数据的一致性分析。检验步骤如下:

1、建立假设:

$$H: \mu_0 = 10.56 \quad (1)$$

本文指的是由地铁工作人员提供的历史安检排队时间平均值。

2、选择显著性水平:

$$\alpha = 0.05 \quad (2)$$

3、计算检验统计量:

$$t = \frac{\bar{X} - \mu_0}{S / \sqrt{n}} \quad (3)$$

式中: \bar{X} 为样本均值; μ_0 为总体均值, 此处为大量统计得到的历史数据值; S 为样本标准差; n 为样本容量, 本文指的是仿真实验运行次数。

在参数设置页面输入表 1~3 中参数数据，进行 20 次仿真实验，即 $n=20$ ，输出的安检排队时间样本平均值 $\bar{X}=11.25$ ，样本标准差 $S=3.4$ ，计算得到 $t=0.91$ ，查 T 检验临界值表得 $t_{0.05(19)}=1.729$ ，由于 $t < t_{0.05(19)}$ ，即模型还原度高于 95%，因此在 95% 置信度下模型可以被接受使用。

4 地铁行人流管控业务的优化

4.1 管控目标的量化

由于地铁站行人流管控优化调度过程中需要考虑众多因素的影响，提高运营的稳定性与服务水平都比较重要，最终要达到二者的均衡。控制变量与观测变量均是影响因素。根据地铁站的站外、安检、站厅，以及站台 4 个区域的行人数量与行人流密度之间的关系，以此为标准来设计地铁站行人流管控优化调度的多目标优化函数。

站外行人流密度与到达地铁站人数呈线性相关：

$$f_1(x) = \beta_1 \cdot \gamma \tag{4}$$

式中： γ 为站外人数。

安检区和站厅行人流密度与到达地铁站人数呈对数相关：

$$f_2(x) = \beta_2 \cdot \ln(\lambda) \tag{5}$$

$$f_3(x) = \beta_3 \cdot \ln(\mu) \tag{6}$$

式中： λ 和 μ 为安检区和站厅人数。

由于站台区域的特殊性，当站台区域的行人流密度达到某个峰值 k_1 时，这时站台区域达到了最大负荷，站台区域禁止行人继续进入；当站台区域的行人流密度小于某个极小值 k_0 时，行人可以正常通行；当站台区域的行人流密度介于二者之间时，采取相应措施进行合理控制：

$$f_4(x) = \beta_4 \cdot \psi \begin{cases} \beta_4 = +\infty, & \psi > k_1 \\ \beta_4 = -1, & \psi < k_0 \\ \beta_4 = 1, & k_0 < \psi < k_1 \end{cases} \tag{7}$$

式中： ψ 为站台人数。

为了后期方便根据不同情况对管控目标量化

进行调整，在模型中预留了 β_1 、 β_2 、 β_3 、 β_4 4 个参数，方便日后调整管控目标函数的量化关系， β_4 取值已在公式中给出，本文中其他 3 个参数的取值为 $\beta_1=1$ 、 $\beta_2=1$ 、 $\beta_3=1$ 。

采用线性加权系数法，将多目标函数求取最优解问题转化为单目标函数求取最值，该优化函数分为 4 个目标函数，依据不同目标函数的不同权重，分别乘以一组权重系数，彼此相加得到单目标函数：

$$F_{\min}(x) = \left(\sum_{i=1}^4 \alpha_i \cdot f_i(x) \right) \tag{8}$$

式中： $F_{\min}(x)$ 为求出函数中的最小值，通过调整 α_1 、 α_2 、 α_3 、 α_4 对站外、安检区、站厅，以及站台的行人流密度进行趋向性优化设计， $\alpha_4 > \alpha_2 > \alpha_3 > \alpha_1$ 。

本次各因素之间的权重通过层次分析法 (analytic hierarchy process, AHP) 软件计算得出，如表 4 所示。

权重系数	通过一致性检验的权重
α_1	0.1
α_2	0.3
α_3	0.2
α_4	0.4

4.2 基于 DQN 的地铁行人流管控策略优化

目前，实时获取各区域的行人流密度状态已经可以通过摄像机等设备来实现。为实现实时决策优化夯实了基础。本文中以实时行人流密度以及管控措施作为状态，地铁行人流管控优化与深度强化学习 (deep reinforcement learning, DRL) 模型的结合整体流程主要分为 3 步，如图 4 所示。

step 1: 随机调整模型参数并多次运行仿真模型，共计运行 2 000 余次，得到 2 000 组观测变量值和相应的控制变量值，得到充足的样本数据。

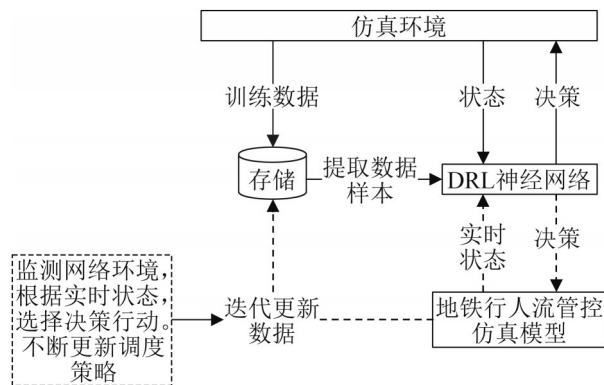


图4 地铁行人流管控与DRL模型的结合

Fig. 4 Combination of subway flow control and DRL mode

step 2: 搭建DRL神经网络, 将模型当前时刻的观测变量值、上一时刻的控制变量值作为输入, 将下一时刻的控制变量值作为输出, 利用step 1的样本数据作为初始训练数据进行迭代训练学习, 直到损失函数收敛于平稳状态, 网络训练成熟, 如图5所示。




图5 损失函数变化趋势

Fig. 5 Change trend of loss function

损失函数如式(9)所示, 为目标和预测值之间的方差, DQN在Q_Learning的基础上, 采用函数拟合更新Q值, 通过更新参数 θ 使Q函数逼近最优Q值。

$$L(\theta) = E[(\text{target } Q - Q(s, a; \theta))^2] \quad (9)$$

式中: s 为当前状态, 即当前时刻的观测变量值、上一时刻的控制变量值; a 为执行动作, 即安检通道、人工安检通道、闸机, 以及电动步梯数量的增减; θ 为网络参数, 即均方误差损失。

$$\text{target } Q = r + \gamma \max_a Q(s', a'; \theta) \quad (10)$$

式中: s' 为下一时刻状态, 即下一时刻的观测变

量值、控制变量值; a' 为下一时刻要执行动作; r 为奖励值; γ 为学习衰减率, 越接近1代表将后续状态的价值考虑程度越高。

step 3: 将训练成熟的网络与本文中的研究对象北京某地铁行人流管控系统连接, 实时获取观测变量和控制变量数据。由于获取数据需要一定时间, 因此根据当前情况, 得到当前最优管控策略并输出, 每次输出之后, 持续5 min, 然后再继续判断。将这些实时数据与最优调度策略输入到仿真模型中, 运行仿真模型, 观察评估该最优调度策略下的管控效果, 各区域行人流密度是否符合标准。

优化地铁行人流管控策略的DQN算法网络模型结构如图6所示, 输入层为当前时刻观测变量取值和上一时刻控制变量取值, 如表5所示。观测变量主要包括当前时刻的站外限行区行人流密度、安检区行人流密度、闸机通行行人流密度、站台行人流密度, 以及上一时刻的安检通道数量、人工安检通道数量、闸机数量以及电动步梯数量; 隐藏层有多层, 各层的激活函数均为relu函数; 输出层为在当前情况下的最优管控策略, 即下一时刻控制变量取值, 如表6所示。包括安检通道、人工安检通道、闸机以及电动步梯数量的增减。

4.3 基于OptQuest的地铁行人流管控策略优化

Optimization优化实验中调用的是OptQuest优化包, 它可以自主引导自定义和参数设置的过程、自主查找模型中与某些约束相关的最佳参数, 并以浅显易懂的图形显示结果, 是寻找模型参数最优解的最优搜索引擎^[14]。

该实验中综合考虑了进站通道数量、安检通道数量、闸机开放数量3个重要影响因素。该优化实验在每次模型开始运行时改变可控参数, 通过重复运行具有不同参数的模型, 找到可以达到最优结果的最佳参数配置并输出。依据实际情况, 优化参数设置范围如表7所示。




图 6 DQN 算法网络结构

Fig. 6 DQN algorithm network structure

表 5 DQN 模型输入数据
Table 5 DQN model input data

输入	变量取值
当前时刻观测变量	站外限行区行人流密度
	安检区行人流密度
	闸机通行行人流密度
	站台行人流密度
上一时刻控制变量	安检通道数量
	人工安检通道数量
	闸机数量
	电动扶梯数量

表 6 DQN 模型输出数据
Table 6 DQN model output data

输出	变量取值
下一时刻控制变量	安检通道数量
	人工安检通道数量
	闸机数量
	电动扶梯数量

表 7 优化参数范围
Table 7 Optimization parameters range

优化参数	最小值	最大值	步长	初值
安检通道数量	1	16	1	8
闸机开放数量	1	84	1	50
电动扶梯数量	0	24	1	10

通过 Optimization 实验优化之后，得到最优的参数配置方案如表 8 所示。

表 8 Optimization 优化实验参数最优取值
Table 8 Best parameters value of optimization

优化参数	最优值
安检通道数量	14
闸机开放数量	72
电动扶梯数量	18

4.4 两种优化方法的对比分析

从优化方式来看，基于 OptQuest 优化引擎的 Optimization 优化属于离线优化方式，即优化参数配置方案是在实际运营之前就得到的，运营过程中不能针对实际运营情况及时修改参数配置方案；DQN 则可以根据当前实际运营情况及时动态调整实时优化参数配置，实现在线决策。

以高峰时段内到达地铁站的总人数为基准，比较 DQN 与 Optimization 优化目标函数值的变化情况，如图 7 所示。DQN 优化目标函数最优值为 99.75，而 Optimization 实验目标函数最优值为 97.25，在进站人数过多的情况下，两种优化方式

的优化效果都有所下降, 但总体而言, DQN 优化效果更好。




图7 目标函数值优化对比

Fig. 7 Comparison of optimize objective function value

除了对比分析目标函数值的优化效果之外, 下面在高峰时段相同平均到达人数的情况下, 对比分析 DQN 优化与 Optimization 优化站外排队时间、安检口排队时间以及站台行人流密度的变化情况。

图8分析了经过2种优化方式后, 站外排队时间时长的情况, 可以看出, 经过DQN优化, 站外排队时间超过50%都被控制在5 min之内, 而Optimization优化只能达到40%。因此, 经过DQN优化, 站外排队时间更短, 优化效果更好。




图8 站外排队时间对比

Fig. 8 Comparison of queue time for outside station

图9分析了经过2种优化方式后, 安检排队时间时长情况, 可以看出经过DQN优化, 安检排队时间超过60%都被控制在5 min之内, 而Optimization优化只能达到不到50%。因此经过DQN优化, 安检排队时间更短, 优化效果更好。

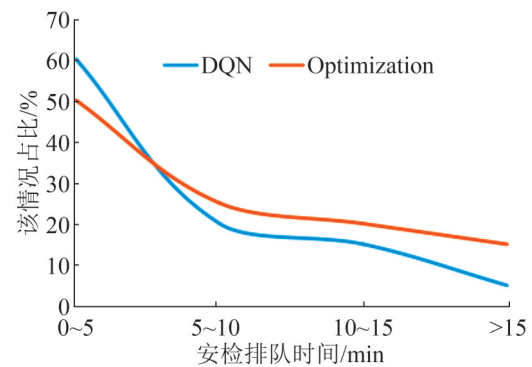


图9 安检排队时间对比

Fig. 9 Comparison of queue time for security

图10分析了经过2种优化方式后, 站台行人流密度情况, 可以看出DQN优化后超过50%的情况下站台行人流密度都可以控制在50%左右, 避免站台出现大量拥挤的情况, 因此, 经过DQN优化, 站台行人流密度可以被更好的控制, 优化效果更好。

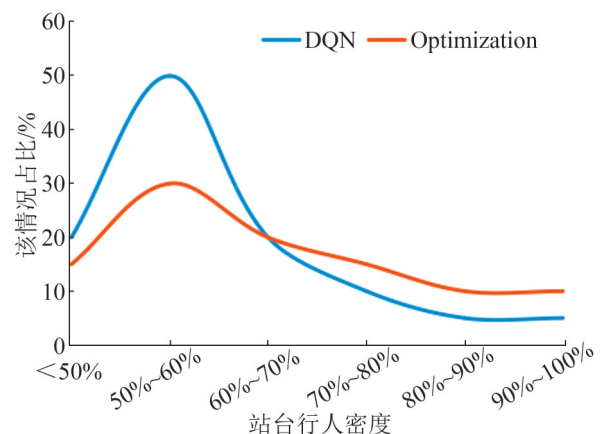


图10 站台行人密度对比

Fig. 10 Comparison of pedestrian density for platform

根据对比分析图以及数据, 2种优化实验在人流流量都不多的情况下DQN优化的优势并不明显, 当人流流量逐渐增多, DQN优化的优势显现, 当人流流量趋于地铁站承受能力时, 2种优化方式的优化能力都有所下降, 但是DQN优化的下降趋势较为缓慢, 而Optimization优化的下降较快。总体分析, DQN优化能力强于Optimization。

5 结论

本文针对优化地铁行人流管控方式,提出了基于机器学习的地铁行人流管控优化。将复杂问题量化为明确的目标函数,通过训练网络得到地铁行人流管控流程资源配置的最佳动态配置策略,为地铁行人流管控措施提供在线决策支持。

因影响地铁行人流管控流程的因素众多,虽然本文提出的优化框架有效提高了管控效率,但仍有许多工作有待进一步完善。下一步也计划将采用其他机器学习算法对地铁行人流管控进行优化。

关于优化地铁行人流管控流程的研究属于探索性研究,虽然仿真模型通过了检验与评估,但与现实仍存在一定程度上的不同。下一步可以将机场OA系统与物联网相连接,完善数据之前的转换,提高数据同步效果;另一方面,下一步可以搭建一个分析大量仿真数据的管理系统,将其与地铁数据中心的数据进行分析对比,既可以验证仿真系统的可靠性,也可以为优化地铁行人流管控提供更好的数据支持。除此以外,可以将地铁站中的方方面面都列入优化范畴,进一步完善优化方案。

参考文献:

- [1] 王媛媛. 基于行人动力学的地铁车站客流仿真模型[J]. 电子测试, 2018(12): 49-50, 48.
Wang Yuanyuan. Passenger Flow Simulation Model for Metro Station Based on Pedestrian Dynamics[J]. Electrical Test, 2018(12): 49-50, 48.
- [2] 李建华, 陈伟, 陈祥儒. 基于AnyLogic的人流增多地铁站系统再优化[J]. 科学技术与工程, 2020, 20(33): 13847-13851.
Li Jianhua, Chen Wei, Chen Xiangru. Simulation and Optimization of Metro Station System Based on AnyLogic[J]. Science Technology and Engineering, 2020, 20(33): 13847-13851.
- [3] 鲁晨, 孙健, 杨涛. 综合交通枢纽客流行人换乘组织优化及仿真[J]. 系统工程, 2020, 38(3): 84-91.
Lu Chen, Sun Jian, Yang Tao. Optimum Design and Simulation of Pedestrian Passenger Transfer Operation in Integrated Transportation Hub[J]. Systems Engineering, 2020, 38(3): 84-91.
- [4] 杨天阳, 朱志国. 基于AnyLogic的地铁车站通道设施设备规模与布局分析[J]. 交通运输工程与信息学报, 2017, 15(1): 115-121.
Yang Tianyang, Zhu Zhiguo. Scale and Layout Analyses of Subway Station Facilities Based on AnyLogic Software[J]. Journal of Transportation Engineering and Information, 2017, 15(1): 115-121.
- [5] Ciro Caliendo, Paolo Ciambelli, Rossella Del Regno, et al. Modelling and Numerical Simulation of Pedestrian Flow Evacuation from a Multi-Storey Historical Building in the Event of Fire Applying Safety Engineering Tools[J]. Journal of Cultural Heritage(S1296-2074), 2020, 41: 188-199.
- [6] 龙顺忠, 王志建, 刘皓. 网联环境下基于深度强化学习的单路口交通信号控制优化[J]. 工业控制计算机, 2020, 33(10): 16-19, 22.
Long Shunzhong, Wang Zhijian, Liu Hao. Based on Deep Reinforcement Learning Optimization of Traffic Signal Control at Single Intersection[J]. Industrial Control Computer, 2020, 33(10): 16-19, 22.
- [7] Huang Yicai, Chen Jiayuan, Duan Qiannan, et al. A Fast Antibiotic Detection Method for Simplified Pretreatment Through Spectra-Based Machine Learning[J]. Frontiers of Environmental Science & Engineering(S2095-2201), 2022, 16(3): 135-146.
- [8] Hassaine Abdelaali, Salimi Khorshidi Gholamreza, Canoy Dexter, et al. Untangling the Complexity of Multimorbidity with Machine Learning[J]. Mechanisms of Ageing and Development(S0047-6374), 2020, 190: 111325.
- [9] 张琪, 曾俊杰, 许凯, 等. 基于机器学习的计算机生成兵力行为建模研究综述[J]. 系统仿真学报, 2021, 33(2): 280-287.
Zhang Qi, Zeng Junjie, Xu Kai, et al. Behavior Modeling for Computer Gederated Forces Based on Machine Learning[J]. Journal of System Simulation, 2021, 33(2): 280-287.
- [10] 张伟罡, 龚希武. 基于机器学习的工业炉智能控制与实现[J]. 工业炉, 2020, 42(3): 45-49.
Zhang Weigang, Gong Xiwu. Intelligent Control and Implementation of Industrial Furnace Based on Machine Learning[J]. Industrial Furnace, 2020, 42(3): 45-49.
- [11] 李增有. 基于机器学习的雷达目标跟踪算法研究[J]. 信息技术与信息化, 2020(8): 217-219.
Li Zengyou. Research on Radar Target Tracking Algorithm Based on Machine Learning[J]. Information Technology and Informatization, 2020(8): 217-219.

- [12] 张荣霞, 武长旭, 孙同超, 等. 深度强化学习及在路径规划中的研究进展[J]. 计算机工程与应用, 2021, 57(19): 44-56.
Zhang Rongxia, Wu Changxu, Sun Tongchao, et al. Progress on Deep Reinforcement Learning in Path Planning[J]. Computer Engineering and Applications, 2021, 57(19): 44-56.
- [13] Wang Haonan, Liu Ning, Zhang Yiyun, et al. Deep Reinforcement Learning: a Survey[J]. Frontiers of Information Technology & Electronic Engineering (S2095-9184), 2020, 21(12): 1726-1744.
- [14] Neeraj R R, Nithin R P, Niranjhan P, et al. Modelling and Simulation of Discrete Manufacturing Industry[J]. Materials Today: Proceedings(S2214-7853), 2018, 5(11): 24971-24983.