

基于非平稳排队模型的机场安检客流预测

张惠煜, 吴佳俊, 陈庆新, 毛宁

(广东工业大学机电工程学院, 广东 广州 510006)

摘要: 机场旅客到达过程存在一定的聚集性和随机性, 不平稳的到达过程很容易导致服务资源浪费。为了动态配置机场安检区的服务资源, 根据航班计划精准预测各个时间段的安检旅客流量。在安检过程中, 安检设备读取旅客证件信息, 旅客此刻已经完成了排队过程, 旅客实际到达安检区的时间早于安检时间。目前的安检流程无法记录每个旅客到达旅检区的时间。针对机场旅客量预测的研究中, 都是将旅客开始接受安检时刻替代为旅客到达安检区时刻, 忽略旅客等待安检的排队时间, 导致预测结果精确度降低。针对此问题, 提出一种基于非平稳排队模型的机场安检客流预测方法。首先, 建立具有一般分布、非平稳随机到达和服务过程的安检排队模型, 提出近似算法求解系统排队性能指标; 其次, 设计基于非平稳排队模型的启发式迭代算法, 迭代推算旅客到达时间; 最后, 基于分时段聚类-拟合方法, 建立航班旅客到达分布模型。实验结果表明, 相比现有的旅客到达时间处理方法, 推算到达时间的预测方法误差降低约 15.07%, 分时段聚类-拟合方法建立的航班旅客到达分布模型在多个算例中都具有良好的预测准确性和泛用性, 在处理节假日等特殊日期的数据时, 也能够得到较精确的预测结果, 且具有较好的过量预测效果, 便于后续的服务资源配置。基于非平稳排队模型的机场安检客流预测方法可为动态配置机场安检区服务资源提供数据基础。

关键词: 旅客量预测; 聚类分析; 分布拟合; 非平稳排队模型; 积压后移平稳近似方法

中图分类号: V351

文献标志码: A

DOI: 10.19678/j.issn.1000-3428.0070458

Prediction of Passenger Flow at Airport Security Checks Based on Non-stationary Queuing Model

ZHANG Huiyu, WU Jiajun, CHEN Qingxin, MAO Ning

(School of Electromechanical Engineering, Guangdong University of Technology, Guangzhou 510006, Guangdong, China)

【Abstract】 The arrival of passengers at airports exhibits certain aggregation and randomness, and an non-stationary arrival process can easily lead to wastage of service resources. To dynamically allocate service resources at airport security checks, accurate prediction of passenger flow at various times based on flight schedules is necessary. By the time the security equipment reads the passenger identification information, the passenger has already completed the queuing process, which implies that the actual arrival time at the security check is earlier than the recorded security check time. The current process of security checks cannot record the exact time at which each passenger arrives at the inspection area. Existing research on airport passenger flow forecasting has replaced the time at which passengers begin to undergo security checks with the time at which they arrive at the security check area, ignoring the queuing time for security checks, which leads to lower prediction accuracy. To address this issue, a method for forecasting passenger flow at airport security checks based on a non-stationary queuing model is proposed. First, a security check queuing model with a general distribution, non-stationary random arrival, and service processes is established, and an approximate algorithm is proposed to solve the system's queuing performance indicators. Second, a heuristic iterative algorithm based on a non-stationary queuing model is designed to iteratively calculate passenger arrival times. Finally, a passenger arrival distribution model is established based on a time-segmented clustering and fitting method. The analysis results show that, compared to existing methods of calculating passenger arrival times, the proposed method reduces the error by approximately 15.07%. The proposed model demonstrates good predictive accuracy and versatility in multiple case studies. It can also make relatively accurate predictions for specific dates such as holidays and has a good over-forecasting effect, facilitating the allocation of service resources. The forecasting method based on the non-stationary queuing model can provide a data-dependent foundation for the dynamic allocation of service resources at airport security checks.

【Key words】 passenger flow prediction; clustering analysis; distribution fitting; non-stationary queuing model; Stationary Backlog-Carryover(SBC) approximate method

基金项目: 广东省基础与应用基础研究基金(2022A1515011175); 广州市基础研究计划(2023A04J0406)。

作者简介: 张惠煜, 男, 讲师, 主研方向为随机生产与服务系统的建模与优化; 吴佳俊, 硕士研究生; 陈庆新, 教授、博士; 毛宁, 教授、博士。

收稿日期: 2024-10-10

修回日期: 2025-01-20

E-mail: hyzhang_henry@126.com

0 引言

机场安检区的旅客到达过程存在一定的聚集性和随机性,其到达流量主要受航班的起飞时间以及载客量影响。不平稳的到达过程很容易导致服务资源的浪费,因此管理人员需要对安检通道资源合理配置,配置不足会增加旅客排队时间,影响旅客满意度;配置过多会造成空闲,降低通道利用率。在对机场安检通道资源配置进行优化时,通常依赖于对安检旅客流量的预测。为了动态配置机场安检区的服务资源,需要根据航班计划精准预测各个时间段的旅客流量。目前,针对机场安检客流预测方法主要分为两类:一是建立航班旅客到达分布并基于航班计划预测机场各个时段的旅客流量;二是基于深度学习等智能算法细致分析历史安检数据特征,进而对机场旅检客流进行预测。经过对某大型枢纽机场进行实地调研和数据分析,机场安检旅客量会因为航班的延误和节假日等原因发生非常大的变化,而第二类方法则难以在特殊情况合理准确预测旅客流量。第一类方法根据航班计划和订票数据等可以及时对特殊情况进行反馈,得到较为准确的预测结果。然而,由于旅客到达安检区的时间难以获取,现有的安检旅客流量预测的方法都是在旅客到达时间已知的情况下,或者直接将安检时间当作到达时间进行预测。在实际情况中,机场安检区仅在安检过程中检验身份信息并记录安检时间,此时排队过程已经结束,无法得到旅客到达时间。若直接将安检时间作为到达时间进行预测,在高峰时期,较长的安检排队时间会减小旅客到达过程的聚集特性,导致到达分布不准确,影响预测精度。现有研究鲜有考虑和解决这一问题。为此,本文对单位时间段内(以 60 min 为单位时间段)的机场安检区旅客流量进行研究,以某大型机场春夏季安检信息数据为例,通过积压后移平稳(SBC)近似方法求解系统性能指标值,并结合启发式迭代算法推算旅客到达时间,并对实验结果进行验证,以期为机场安检区服务资源的合理分配及调度提供科学依据。

本文针对一般分布的到达间隔时间和服务时间、具有多个并行服务台的单阶段服务系统,建立了相应的非平稳排队模型,利用 SBC 方法求解系统性能指标值,并将其嵌入启发式迭代算法近似得到旅客到达时间并进行旅客到达分布预测。本文的主要创新点如下:

1)对机场安检旅客的到达时间与安检时间进行区分,并在此基础上推算旅客到达时间进行预测,通

过实验算例验证了推算旅客到达时间方法的有效性,降低了预测偏差率。

2)提出由非平稳排队理论的系统性能指标估算方法与启发式算法结合的优化方法,现有文献鲜有将平稳排队理论结合启发式算法对安检区旅客到达时间进行求解。

1 相关工作

国内外在机场安检客流预测方面开展了许多研究。王晴等^[1]采用分布拟合法拟合各组单航班离港旅客聚集行为,设计单航班赋权叠加公式并采用启发式算法求解权重系数,提出面向多航班耦合的离港旅客聚集模型。冯霞等^[2]提出了基于时间序列分析的航站楼安检客流预测方法,对安检客流时间序列进行了相空间重构,利用自相关函数法确定时间延迟,使用最近邻法确定嵌入维数,接着使用 Wolf 方法判断客流时间序列的混沌特性,并采用 BP 神经网络对混沌时间序列进行预测。钟翔等^[3]分析了时间段、能见度、后续航班数量和值机旅客流量等因素对机场安检旅客流量的影响,建立了基于 BP 神经网络的机场安检旅客流量预测模型,使用天津机场数据验证模型,预测了过安检的旅客流量并进行安检人员模拟派工,但依据安检口流量进行人员派工会造成信息传递滞后,导致派工不及时,基于到达安检区的流量预测进行的资源配置会更加及时和准确。XING 等^[4]提出一种基于航班计划和历史安检数据的流量预测方法,首先以二阶高斯混合分布拟合单次航班旅客到达概率密度分布曲线,构建 MRBF-GMM 模型预测同一安检区域内多航班旅客到达分布。WANG 等^[5]对离港旅客的行为模式进行研究,将值机后到安检前、安检后到登机前的时间间隔近似为双幂律分布和指数截断幂律分布。YAO 等^[6]研究了机场腹地航空旅客出行行为特征。YANG 等^[7]提出了一种基于深度学习的考虑气象因素的机场到达流量预测方法。MONMOUSSEAU 等^[8]采用长短期记忆(LSTM)神经网络,对巴黎戴高乐机场安检点旅客流量进行预测。

文献[9-11]提出一种基于深度学习框架的预测旅客流量模型。PEKEL 等^[12]提出了两种混合方法预测旅客数量,即协议优化算法-人工神经网络(POA-ANN)和智能水滴算法-ANN(IWD-ANN)。TSUI 等^[13]采用 SARIMA 和 ARIMAX 模型预测香港机场旅客吞吐量。上述文献几乎都是以安检时间作为旅客到达时间进行研究的,忽略了安检排队时间的影响。研究人员提出了一种改进的非全连接

神经网络模型,通过改进网络结构和误差传递函数来提高客流预测的准确性和可解释性。研究人员提出了混合深度学习模型,结合卷积神经网络^[14]、残差单元和门控循环单元^[15]来捕获流量数据的时空特征,并引入加权平方误差损失函数,以提高对交通客流量峰值的预测精度。针对非平稳排队模型方面也进行了许多研究。HE 等^[16]研究了非平稳到达的一般模型,提出 $G(t)/M/C(t)$ 模型,扩展了服务系统人员配置算法,使其能够应对非泊松到达过程,并提出量化非泊松到达对人员配置影响的方法,通过仿真实验验证了人员配置算法的有效性。姚加林等^[17]验证了旅客到达和离开过程均服从泊松分布后建立 $M/M/C$ 的排队系统模型,实现各时段安检设备的合理配置。分析安检区服务系统数据,几乎所有服务系统的旅客到达速率在一天中具有显著变化,到达过程分布和服务时间分布也不是接近指数分布,其对排队系统的性能指标存在重大影响,在计算系统性能指标时须考虑这些变化。当前非平稳排队模型的求解方法分为精确解法和近似法。精确解法^[18-19]可以求解部分系统稳态的精确解,但仅当到达率小于服务率时才有可能达到稳态,大部分服务系统都可能暂时超载^[20],精确解法不适用于安检排队系统。在近似法中,GREEN 等^[21]应用简单平稳

近似(SSA)在具有周期性时间依赖性输入参数的系统,在整个时间范围内对系统输入参数取平均,获得性能参数,但不能得出性能参数的变化趋势。GREEN 等^[22]应用逐期平稳独立近似,将整个时间范围分为等长的更小周期,可取每个周期系统参数值的最大值(或最小值)用于计算系统的性能参数,但近似效果较差。NEWELL^[23]提出逐点平稳近似(PSA),用瞬时系统输入参数值计算性能参数,但由于瞬态过程偏差和忽略周期间的联系,造成较大的性能误差。STOLLETZ^[24]引入积压后移平稳近似方法求解 $M(t)/M(t)/C(t)$ 系统^[20]、 $M(t)/G(t)/1$ 系统、 $M(t)/G/C(t)$ 系统^[25]以及 $G(t)/G/1/K$ 系统^[26]的系统性能。

2 问题描述

安检区安检流程如图 1 所示。机场安检中,当设备读取证件信息的时间作为安检时间时,旅客已经完成了排队过程,旅客到达安检区的时间早于安检时间。现有的安检流程没有办法准确记录每个旅客到达安检区的时间。本文通过计算旅客排队时间的方法反推出旅客的到达时间。旅客安检时间由机器读取,为已知数据,因此只需要计算出旅客的排队时间即可得到旅客的到达时间。




图 1 安检区安检流程示意图

Fig. 1 Schematic diagram of security check process in security check area

在安检区排队系统中,每个时段旅客到达量变化幅度大,具有非平稳性,且旅客的到达过程具有随机性(旅客到达间隔时间不确定),服务通道数量和服务速率为动态变化,具有非平稳性,需要建立一般分布的非平稳排队模型。根据机场排队方式,构建一个多 $G(t)/G(t)/1$ 并行的排队模型,如图 2 所示。对于每个服务系统,当旅客抵达系统时,如果服务台处于空闲状态,他们便可以直接接受服务。相反,如果服务台处于忙碌状态,旅客则需在一条队列中排队等候服务。该系统拥有无限的等候容量。到达过程服从一般分布,平均到达速率为 $\lambda(t)$,服务时间同样也服从平均服务速率为 $\mu(t)$ 的一般分布,服务台的服务规则为“先到先服务”。根据 Kendall 记法,该排队模型为 $G(t)/G(t)/1/\infty$ 模型。




图 2 多 $G(t)/G(t)/1$ 并行排队模型

Fig. 2 Multi $G(t)/G(t)/1$ parallel queuing model

3 基于非平稳排队模型的旅客到达时间推算方法

3.1 启发式迭代算法

将某旅客到达安检区的时间认定为其开始安检的时间减去其安检排队花费的时间。因此,只要得到旅客排队时间,即可反推出旅客到达安检区的时间。本文提出一种嵌入 SBC 近似方法的启发式迭代算法,近似得到旅客排队时间。

算法具体步骤如下:1)设定初始排队时间,根据服务速率的不同区间,为服务台设定一个初始的随机排队时间,通常情况下,服务速率越高,设定的初始排队时间越短;2)系统性能分析,计算旅客到达安检区的时间(某旅客到达安检区的时间认定为其开始安检的时间减去其安检排队花费的时间),通过非平稳排队模型分析系统性能,得到旅客排队结束的时间,即开始安检的时间;3)对比和调整,将步骤2)中开始安检时间与实际开始安检时间进行对比,计算两者误差,这一误差值用于调整步骤1)中的排队时间初始值,若排队模型计算的安检时间早于实际时间,则增加排队时间初始值,反之,则减少排队时间初始值;4)重复迭代,使用新的初始值重复步骤2)和步骤3),再次进行系统性能分析和对比迭代;5)误差阈值判断,当步骤3)中计算的误差小于某一设定的阈值时,迭代结束。此时的排队时间初始值被认为是较为准确的排队时间,可作为输出。启发式迭代算法的具体流程如图3所示。




图3 启发式迭代算法流程

Fig.3 Procedure of heuristic iterative algorithm

3.2 $G(t)/G(t)/1$ 排队时间近似求解方法

本节详细介绍了 SBC 近似方法在求解 $G(t)/G(t)/1$ 排队时间中的应用。在 SBC 近似方法

中^[18],整个时间间隔被分为 T 个时段,原来的到达率和服务率 $\lambda(t)$ 和 $\mu(t)$ 分别被分段常数函数 λ_i 和 μ_i 替代,如式(1)和式(2)所示:

$$\lambda_i = \frac{1}{t_i - t_{i-1}} \int_{t_{i-1}}^{t_i} \lambda(s) ds, i=1, 2, \dots, T \quad (1)$$

$$\mu_i = \frac{1}{t_i - t_{i-1}} \int_{t_{i-1}}^{t_i} \mu(s) ds, i=1, 2, \dots, T \quad (2)$$

第1个阶段:从第1个时段开始,都以平稳的 $G/G/1/1$ 损失制模型进行分析。为了考虑时段之间的联系,定义每个时段的人工积压量 b_{i-1} ,表示第 $i-1$ 时段因堵塞而离开 $G/G/1/1$ 损失制系统的作业稳态速率,如式(3)所示。其中, $P_{i-1}(B)$ 代表第 $i-1$ 时段堵塞的概率,本文应用爱尔朗损失概率替代,如式(4)所示。这些积压被转移到下一个时段,从而得到下一个时段 $\tilde{\lambda}_i$ 的人工到达率,如式(5)所示。同时得到下一个时段的系统期望利用率 $E(U_i)$,如式(6)所示。SBC 近似方法基本原理如图4所示(彩色效果见《计算机工程》官网 HTML 版,下同)。

$$b_{i-1} = \tilde{\lambda}_i \times P_{i-1}(B) \quad (3)$$

$$P_i(B) = \frac{\tilde{\lambda}_i / \mu_i}{1 + \tilde{\lambda}_i / \mu_i} = \frac{\tilde{\lambda}_i}{\mu_i + \tilde{\lambda}_i} \quad (4)$$

$$\tilde{\lambda}_i = \lambda_i + b_{i-1} \quad (5)$$

$$E(U_i) = \frac{\tilde{\lambda}_i (1 - P(B))}{\mu_i} = \frac{\tilde{\lambda}_i - b_i}{\mu_i} \quad (6)$$




图4 SBC 近似方法基本原理

Fig.4 Basic principles of SBC approximation method

第2个阶段:第1个阶段提出的损失制模型不能用于近似预期的队列长度或系统中的旅客数,所以需要采取1个修正的到达率对 $G/G/1$ 等待制系统近似相应的性能度量,最终的修正到达率 λ_i^{MAR} 如式(7)所示:

$$\lambda_i^{MAR} = E(U_i) \mu_i = \tilde{\lambda}_i (1 - P(B)) = \tilde{\lambda}_i - b_i \quad (7)$$

利用修正到达率 λ_i^{MAR} 结合 $G/G/1$ 等待制系统

的近似方法得到所需要的性能度量的近似值。本文采用了 KRAMER 等^[27]提出的 G/G/1 排队模型的近似方法。

KRAMER 等^[27]提出了 G/G/1 排队模型各性能度量的近似值,预期的等待时间如式(8)和式(9)所示:

$$E(W) \approx \frac{c_a^2 + c_s^2}{2} \frac{\rho}{1-\rho} \frac{1}{\mu} g(\rho, c_a^2, c_s^2) \quad (8)$$

$$g(\rho, c_a^2, c_s^2) = \begin{cases} \exp\left[-\frac{2(1-\rho)(1-c_a^2)}{3\rho(c_a^2 + c_s^2)}\right], & c_a^2 \leq 1 \\ \exp\left[-\frac{(1-\rho)(c_a^2 - 1)}{c_a^2 + 4c_s^2}\right], & c_a^2 > 1 \end{cases} \quad (9)$$

式中: ρ 为交通强度; c_a^2 和 c_s^2 分别为输入过程分布和服务过程分布的平方变异系数。

4 基于分时段聚类-拟合的航班旅客到达分布模型

4.1 考虑单航班旅客到达分布特性的航班时段聚类方法

在利用启发式算法确定旅客的到达时间之后,本文可以进一步构建航班旅客到达分布模型。在先前的研究中,航班起飞时间的分类通常基于主观判断,将其划分为上午、下午和晚上等时段。例如,王晴等^[1]在对航班起飞时间进行分类时,将其简化为两个主要类别:早高峰时段(09:00—12:00)和晚高峰时段(15:00—17:00)。然而对航班数据分析,相邻起飞时间的航班到达分布也有着较大的差异。因此,本文基于机器学习聚类算法,更加客观地对航班起飞时间进行分类。聚类算法是一类无监督学习算法,主要用于将一组数据分组为由相似性度量的多个类或簇。聚类算法的目标是使得同一个簇内的数据点尽可能相似,而不同簇的数据点尽可能不同。AGNES 算法是一种层次聚类算法,属于一种凝聚层次聚类方法。在凝聚层次聚类中,每个样本最初被视作一个单独的簇,然后算法逐步将最相似的簇合并在一起,直到所有样本都属于同一个簇,或者满足某个终止条件为止。

在 AGNES 算法中,样本集 $D = \{x_1, x_2, \dots, x_m\}$ 包含 m 个无标记样本,其中 $x_i = \{x_{i1}, x_{i2}, \dots, x_{in}\}$ 是一个 n 维特征向量,代表起飞时间为第 i 个时间段的航班旅客到达概率分布。AGNES 算法基本流程如图 5 所示。AGNES 算法的具体步骤如下。

1)初始化。将每个样本 x_i 视作一个单独的聚类簇 C_i 。




图 5 AGNES 算法流程

Fig.5 AGNES algorithm procedure

2)距离计算。每个簇是一个样本集合,集合之间的距离是通过特定的链接准则来计算的。聚类簇 C_i 与 C_j 的距离计算如式(10)~式(12)所示。样本之间的距离通常以欧氏距离计算,如式(13)所示。当聚类簇距离由 $d_{\min}$ 、 $d_{\max}$ 、 d_{avg} 计算时,AGNES 算法被相应称为“单链接”“全链接”或“均链接”算法。

$$d_{\min}(C_i, C_j) = \min_{y \in C_i, z \in C_j} \text{dist}(y, z) \quad (10)$$

$$d_{\max}(C_i, C_j) = \max_{y \in C_i, z \in C_j} \text{dist}(y, z) \quad (11)$$

$$d_{\text{avg}}(C_i, C_j) = \frac{1}{|C_i| + |C_j|} \max_{y \in C_i, z \in C_j} \text{dist}(y, z) \quad (12)$$

$$\text{dist}_{\text{ed}}(x_i, x_j) = \|x_i - x_j\|_2 =$$

$$\sqrt{\sum_{u=1}^n |x_{iu} - x_{ju}|^2} \quad (13)$$

3)合并簇。选择距离最近的聚类簇进行合并,形成新的聚类簇。

4)更新距离。重新计算合并后的聚类簇和其他聚类簇之间的距离。

5)重复步骤 3)和 4)至满足停止条件。上述过程不断重复,直到达到预设的聚类簇数。

通过聚类算法,本文可以更客观、精确地对不同起飞时间的航班旅客到达分布进行分类。接下来,本文将探讨如何对每个类别内的多个分布进行有效拟合。

4.2 考虑多航班耦合的分时段航班旅客到达分布拟合方法

针对每个类别内多个航班旅客到达分布的拟

合问题,本文采用梯度提升决策树(GBDT)算法^[28]对多个航班旅客到达分布的离散点进行拟合,拟合结果作为当前类别的航班旅客到达分布。GBDT 算法是一种基于决策树的集成学习算法,通过梯度下降对新的学习器进行迭代。GBDT 算法以决策树作为梯度提升机中的基础学习器,先构

造 1 个决策树,然后不断在已有模型和实际样本的输出残差上构造另一棵树,依次迭代,最后将所有决策树的结果作为输出,其基本原理如图 6 所示。在每次迭代中,GBDT 算法都会尝试最小化前一次迭代中模型的残差,并构建 1 个新的决策树来拟合这些残差。




图 6 GBDT 算法基本原理

Fig.6 Basic principles of GBDT algorithm

拟合优度是指回归直线对观测值的拟合程度。度量拟合优度的统计量是可决系数(也称确定系数) R^2 。 R^2 最大值为 1。 R^2 的值越接近 1,说明回归直线对观测值的拟合程度越好;反之, R^2 的值越小,说明回归直线对观测值的拟合程度越差。拟合优度的计算方法如式(14)所示:

$$R^2 = \frac{S_{SSR}}{S_{SST}} = 1 - \frac{\sum (y - \hat{y})^2}{\sum (y - \bar{y})^2} \quad (14)$$

式中: S_{SSR} 表示回归平方和,表示模型预测值与因变量均值之间差异的平方和; S_{SST} 表示离差平方和,表示因变量与其均值之间差异的平方和; y 为实际值; $\bar{y}$ 为平均值; $\hat{y}$ 为预测值。

5 算例分析

以某城市大型枢纽机场 2023 年 3 月—2023 年 8 月旅客安检信息为算例(5 410 559 条安检信息, 34 694 次航班)。

5.1 旅客到达时间处理方法对比

本文设计实验以验证推算旅客到达时间进行预测是否能提高预测精度。实验中,随机选取 14 日的数据,对比了两种预测方式:1)推算旅客到达时间进行预测;2)将旅客的安检时间作为到达时间进行预

测。通过比较两种方式的预测偏差率,评估推算旅客排队时间对提高预测精度的实际效果。偏差率是通过计算单位时间偏差人数的绝对值之和与实际值之比得到的。实验结果如表 1 所示。

表 1 推算到达时间与安检时间当作到达时间的预测偏差率对比

Table 1 Comparison of predicted deviation rates between estimated arrival time and security check time as arrival time

日期	预测偏差率/%	
	推算到达时间	安检时间当作到达时间
4 月 3 日	5.26	6.29
4 月 4 日	5.20	6.38
4 月 5 日	6.65	7.55
4 月 12 日	6.58	6.77
4 月 24 日	4.27	5.22
4 月 29 日	6.17	7.53
5 月 1 日	8.43	9.32
5 月 12 日	3.59	6.29
5 月 14 日	5.53	5.36
5 月 31 日	4.02	5.34
6 月 22 日	7.36	8.13
6 月 24 日	10.70	11.84
6 月 30 日	4.40	5.19
7 月 25 日	5.36	6.95

实验结果表明,采用推算到达时间的预测方法,其平均偏差率降低至 5.97%,相较于将安检时间作为到达时间的预测方法(平均偏差率为 6.87%),预测精度显著提升,偏差率降低了约 15.07%。特别地,在 5 月 1 日劳动节和 6 月 22 日端午节这两个高峰时段,通过推算到达时间的方法将预测偏差率降低了约 10.5%。推算到达时间的方法能够有效提高预测准确性。

5.2 旅客到达时间推测方法的有效性验证

在以往文献中^[20,29],已经有实验和数据证明了在到达率、服务率和变异系数的非平稳性情况下 SBC 近似方法的有效性。由于机场安检区旅客到达时间难以获取,因此本文以仿真实验对比验证 SBC 近似嵌入迭代算法计算到达时间方法的有效性。由于旅客到达安检区的时间难以获取,因此本文在 Siemens Tecnomatix Plant Simulation (eM-Plant) 仿真软件上建立离散事件仿真模型,验证嵌入拓展 SBC 近似的启发式迭代算法,近似得到旅客到达时间的准确性。

实验设计如下:首先,随机抽取 7 天的数据,将启发式迭代算法推算的到达时间作为物料生成时间,排队过程模拟为物料加工过程,得到的物料终结时间即是排队结束时间(安检时间);其次,以仿真得到的安检时间为数据,2 次采用启发式迭代算法推算到达时间;最后,对比 2 次到达时间的误差。

表 2 展示了 2023 年 6 月 3 日 2 次推算旅客到达时间结果对比。偏差时间(绝对值)的最大值为 00:10:33,平均值约为 00:03:20。与 2 次推算结果的到达安检区流量对比,以 10 min 为间隔,偏差率约为 3.31%。表 3 展示了随机 7 日 2 次推算旅客到达时间与到达安检区流量偏差,两次推算旅客到达时间的平均偏差时间约为 00:04:22,流量平均偏差率约 4.41%。实验结果表明,本文推算的旅客到达时间具有较好的准确性和有效性。

以随机抽取 1 周安检信息为算例,统计的每日安检人数以及算法运行时间如表 4 所示。在实际应用中,机场旅检部门通常根据次日航班计划进行客流预测,从而提前安排次日安检通道和员工所需数量。算例实验证明,本文提出的算法运行时间约为 8 min,能够满足离线预测的应用需求。图 7 展示了 $|\Delta t|$ 随迭代次数的变化趋势。 Δt 是各旅客基于非平稳排队模型分析得到开始安检时间与实际安检时间之间的偏差平均值。启发式迭代算法以当前解的安检时间与实际安检时间的差值作为迭代方向,每次迭代都可以使当前解更加接近最优解。随迭代次

数的增加,算法的 $|\Delta t|$ 逐渐减小,在 10 次迭代内可以基本接近收敛极限。

表 2 2 次部分推算旅客到达时间对比

Table 2 Comparison of two partially estimated passenger arrival times

首次推算到达时间	2 次推算到达时间	偏差时间
04:13:11	04:13:56	00:00:45
07:25:19	07:22:01	00:03:18
07:22:40	07:23:44	00:01:04
07:21:41	07:23:48	00:02:07
07:26:19	07:23:59	00:02:20
07:25:40	07:22:14	00:03:26
07:29:39	07:23:58	00:05:41
07:26:26	07:24:06	00:02:20
07:23:47	07:24:02	00:00:15
07:22:09	07:24:03	00:01:54
07:26:01	07:22:29	00:03:32
07:26:38	07:24:15	00:02:23
07:30:15	07:24:11	00:06:04
07:22:37	07:24:19	00:01:42
07:26:22	07:22:43	00:03:39
07:26:57	07:24:30	00:02:27
07:26:47	07:24:31	00:02:16
07:24:54	07:24:25	00:00:29
07:23:05	07:24:35	00:01:30
07:26:01	07:24:40	00:01:21
22:54:02	22:56:18	00:02:16

表 3 2 次推算旅客到达时间与到达安检区流量偏差


Table 3 Flow deviation between the two estimated passenger arrival times and the security checkpoint arrival

日期	平均偏差时间	流量偏差率/%
3 月 28 日	00:04:15	2.916 6
4 月 13 日	00:05:05	4.018 3
5 月 1 日	00:04:18	4.210 7
5 月 7 日	00:03:22	7.108 1
6 月 3 日	00:03:20	3.312 7
7 月 7 日	00:05:13	4.079 1
8 月 20 日	00:05:09	4.051 1

表 4 安检人数以及算法运行时间

Table 4 Number of security checks and algorithm running time

日期	安检人数/个	运行时间/s
3 月 26 日	34 825	451
3 月 27 日	33 672	461
3 月 28 日	34 423	399
3 月 29 日	31 186	440
3 月 30 日	40 756	461
3 月 31 日	41 576	491
4 月 1 日	39 400	485

图 7 $|\Delta t|$ 随迭代次数的变化趋势Fig.7 The change trend of $|\Delta t|$ with the number of iterations

5.3 航班旅客到达分布模型的有效性验证

5.3.1 航班时段聚类方法对比

将历史数据中的航班起飞时间按照半小时间隔进行分组,起始时间为 06:00,结束时间为 24:00,分为 36 组。部分起飞时间的航班到达分布如图 8 所示。从图 8 可以看出,不同起飞时间的航班到达分布差异较大。基于回归算法,将组内多个航班的旅客提前到达概率分布进行拟合,以达到聚类样本间维度统一的效果。对比多种聚类方法的聚类结果进行预测得到的偏差率如表 5 所示。本文选择偏差率最低的 AGNES 聚类算法(4 簇),聚类结果如表 6 所示。




图 8 部分起飞时间的航班到达分布

Fig.8 Distribution of flight arrivals for a subset of departure times

5.3.2 分时段到达分布拟合方法对比

在得到航班的聚类结果后,基于回归算法对 AGNES 聚类结果中每个类别内的多个航班旅客到达分布进行拟合,建立每个类别的航班旅客提前到达安检区的概率分布模型。在拟合结果中,本文使用拟合优度作为评估标准,以判断不同回归模型对到达分布的拟合程度。拟合优度指标通常用于衡量模型对数据的解释能力,其值越接近 1 表示模型拟合得越好。拟合结果如图 9 所示。实验结果表明,

表 5 多种聚类方法聚类结果的流量预测偏差率

Table 5 Deviation rate of traffic prediction based on clustering results using multiple clustering methods %

聚类方法	偏差率
k -means(2 簇)	6.878 7
AGNES(2 簇)	6.878 7
k -means(3 簇)	6.983 0
AGNES(3 簇)	5.119 9
k -means(4 簇)	7.249 5
AGNES(4 簇)	4.914 5
k -means(5 簇)	6.665 3
AGNES(5 簇)	4.955 9
Mean Shift(5 簇)	5.652 3

表 6 AGNES 聚类结果

Table 6 AGNES clustering results

簇编号	簇内样本
类别 1	06:00—07:00;08:30—09:00;10:00—10:30;11:00—11:30;12:00—12:30;13:30—15:00;15:30—17:00
类别 2	17:00—24:00
类别 3	07:00—08:00
类别 4	08:00—08:30;09:00—10:00;10:30—11:00;11:30—12:00;12:30—13:30;15:00—15:30

在 3 种回归模型中,梯度提升树回归模型在到达分布的拟合上表现最优,其拟合优度高于多层感知机回归模型和 k -最近邻回归模型。此外,多层感知机回归模型在训练过程中需要较大的数据量来减少过拟合现象,而 k -最近邻回归模型则对数据中的噪声较为敏感,容易受到异常值的影响。综合考虑模型的拟合性能以及泛用性,选择梯度提升树回归模型作为最终的模型,以建立航班旅客提前到达安检区的概率分布模型。

5.3.3 基于航班计划的分时段旅客量预测

根据航班旅客到达分布,结合当天的航班计划,即可计算出当天各时段旅客到达安检区的人数分布情况。2023 年 4 月 22 日旅客到达安检区流量预测结果如图 10 所示,偏差率为 3.439 4%。

对预测结果和实际值采用 t 检验方法检验是否具有显著性差异,检验统计量为:

$$t = \frac{\bar{x}_{\text{pred}} - \mu_{\text{actual}}}{s_{\text{pred}} / \sqrt{n}} \quad (15)$$

式中: $\bar{x}_{\text{pred}}$ 、 s_{pred} 分别为预测结果的样本均值和标准差; μ_{actual} 为实际值的总体均值; n 为预测结果的样本大小。 t 检验过程主要是:




图 9 旅客到达分布

Fig.9 Distribution of passenger arrivals




图 10 4 月 22 日安检区流量预测结果对比

Fig.10 Comparison of security checkpoint traffic forecast results on April 22nd

1) 提出假设 H_0 。预测值与实际值之间没有显著差异, 给定显著性水平 $\alpha = 0.05$ 。

2) 以 $\alpha = 0.05, n = 24$ 查 t 分布 α 分位数表^[30], $t_{0.975} = 2.069$, 拒绝域为 $\{|t| > 2.069\}$ 。

3) 检验统计量。 $t = 0.0094$, 没有落在拒绝域中, 因此在 $\alpha = 0.05$ 水平上接受原假设。

考虑到在实际运营管理中, 客流量预测值偏大导致资源过剩, 比预测值偏小造成的资源紧张更容易管理。为此, 本文设计了过量预测系数 (Score, S)

评价模型的过量预测效果, 如式 (16) 所示。过量预测系数越大, 代表过量预测效果越好。

$$S = \sum_1^n [e^{\left(\frac{d_1}{a_1}\right)} - 1] - \sum_1^m [e^{-\left(\frac{d_2}{a_2}\right)} - 1] \quad (16)$$

式中: n, m 分别为预测值偏大的样本量和预测值偏小的样本量; d_1 和 a_1 分别为预测值偏大的样本的偏差量和偏差量之和; d_2 和 a_2 分别为预测值偏小的样本的偏差量和偏差量之和。

为了评估本文所提预测模型的有效性, 随机选择 30 天、4 周和 1 个月不同跨度的时间段以及节假日及其前后两天数据作为测试集, 并分别应用了本文方法、文献[1, 5, 31]所提方法进行到达分布的预测并对偏差率进行对比。预测结果如表 7~表 11 所示。实验结果表明, 本文提出的预测模型在多个算例中都具有良好的预测准确性和泛用性, 在处理节假日等特殊日期的数据时, 也能够得到较精确的预测结果, 且具有较好的过量预测效果, 有益于服务资源配置和管理。相比之下, Transformer^[31]方法在实际运用中, 存在运行时间长、预测效果不稳定、准确度较低等问题, 难以应用于该场景。

表 7 随机 30 日算例应用不同方法预测偏差率对比

Table 7 Comparison of prediction deviation rates using different methods in random 30 days examples

日期	本文方法		文献[1]方法		文献[5]方法		文献[31]方法	
	偏差率/%	过量预测系数	偏差率/%	过量预测系数	偏差率/%	过量预测系数	偏差率/%	过量预测系数
4 月 11 日	5.22	0.000 3	10.17	0.050 9	9.10	0.032 6	15.85	-0.058 2
4 月 15 日	6.81	0.025 6	11.36	0.049 4	10.34	0.044 5	20.66	-0.138 3
4 月 18 日	5.17	0.015 9	8.23	0.043 2	7.90	-0.021 0	26.44	-0.250 6
4 月 21 日	4.92	0.038 7	9.71	0.065 0	7.57	0.030 1	25.01	-0.059 3
4 月 25 日	4.98	0.016 1	9.03	-0.088 0	9.94	-0.058 8	30.73	0.241 4
4 月 27 日	6.45	-0.006 2	11.84	0.040 2	10.68	0.022 8	16.37	0.083 0
4 月 28 日	6.03	0.007 7	10.56	0.030 8	8.97	-0.002 1	31.07	-0.205 5
5 月 9 日	6.37	0.007 3	10.76	0.027 6	11.22	0.008 0	27.16	0.399 3
5 月 10 日	4.82	0.005 2	8.81	0.009 9	8.68	-0.013 1	28.20	0.151 7
5 月 13 日	3.59	0.037 3	9.47	-0.018 6	9.48	-0.030 9	14.64	-0.117 5
5 月 16 日	4.87	0.017 0	7.87	-0.079 7	8.29	-0.067 6	16.26	-0.014 6
6 月 2 日	4.87	-0.017 3	8.14	-0.031 8	8.05	-0.055 7	17.58	-0.685 5
6 月 11 日	4.66	0.004 2	10.05	0.031 3	7.15	-0.026 3	21.65	0.095 2
6 月 12 日	4.05	0.015 9	11.09	0.025 7	9.36	-0.003 6	16.81	0.054 8
6 月 30 日	4.40	0.039 3	9.98	0.026 4	7.97	-0.026 1	24.73	0.686 9
7 月 5 日	6.38	0.029 1	9.58	-0.057 5	8.69	-0.091 9	29.49	-0.151 4
7 月 6 日	3.96	0.087 5	8.36	-0.036 2	8.91	-0.037 4	15.26	-0.053 0
7 月 11 日	5.32	0.011 1	8.47	-0.134 2	9.19	-0.072 8	15.77	-0.122 2
7 月 12 日	4.18	-0.010 8	7.91	-0.068 1	7.91	-0.093 1	24.67	-0.145 7
7 月 14 日	4.64	0.021 3	8.50	-0.051 9	8.02	-0.043 1	12.46	0.000 7
7 月 23 日	4.31	0.028 5	8.63	-0.114 6	8.94	-0.085 6	20.01	-0.477 5
7 月 24 日	4.09	-0.027 1	9.04	-0.022 6	7.77	-0.033 6	21.89	-0.133 2
7 月 25 日	5.36	0.102 0	8.30	-0.119 8	9.38	-0.078 0	16.96	0.024 5
7 月 26 日	4.02	0.003 4	10.21	-0.006 0	8.53	-0.061 2	10.95	0.038 3
8 月 6 日	3.40	0.098 7	9.79	-0.007 7	8.77	-0.022 1	27.18	-1.031 9
8 月 7 日	4.80	0.082 9	9.95	-0.018 5	9.41	-0.036 7	15.91	-0.141 3
8 月 8 日	4.77	0.015 0	8.68	-0.075 9	8.70	-0.065 2	31.15	-0.677 8
8 月 10 日	4.90	0.039 8	10.56	-0.015 8	9.54	-0.130 9	11.69	0.039 6
8 月 14 日	4.76	-0.003 9	9.77	-0.067 2	7.93	-0.178 1	10.06	-0.189 9
8 月 26 日	6.13	-0.006 1	12.49	-0.053 6	11.59	-0.098 1	37.11	-0.030 3

表 8 随机 4 周算例应用不同方法预测偏差率对比

Table 8 Comparison of prediction deviation rates using different methods in random 4 weeks examples

日期	本文方法		文献[1]方法		文献[5]方法		文献[31]方法	
	偏差率/%	过量预测系数	偏差率/%	过量预测系数	偏差率/%	过量预测系数	偏差率/%	过量预测系数
4 月 11 日	5.22	0.000 3	10.17	0.050 9	9.10	0.032 6	15.85	-0.058 2
4 月 12 日	6.58	-0.017 7	11.21	0.023 9	7.80	0.010 1	11.90	-0.077 2
4 月 13 日	5.47	-0.013 6	11.76	0.027 5	10.31	-0.011 1	14.64	-0.117 5
4 月 14 日	4.77	-0.034 2	10.50	0.022 0	8.38	-0.012 8	13.61	-0.006 4
4 月 15 日	6.81	0.025 6	11.36	0.049 4	10.34	0.044 5	20.66	-0.138 3
4 月 16 日	5.10	0.022 1	9.86	-0.000 8	7.17	-0.041 5	15.94	0.074 8
4 月 17 日	5.74	-0.008 9	9.67	0.029 0	9.18	0.009 7	23.19	0.624 4
5 月 8 日	7.84	0.022 8	13.47	0.039 0	11.35	0.003 3	23.54	-0.010 5
5 月 9 日	6.37	0.007 3	10.76	0.027 6	11.22	0.008 0	27.16	0.399 3
5 月 10 日	4.82	0.005 2	8.81	0.009 9	8.68	-0.013 1	15.72	-0.672 6

表 8(续)

日期	本文方法		文献[1]方法		文献[5]方法		文献[31]方法	
	偏差率/%	过量预测系数	偏差率/%	过量预测系数	偏差率/%	过量预测系数	偏差率/%	过量预测系数
5 月 11 日	5.60	0.086 7	10.63	0.035 0	9.42	0.006 7	28.62	0.193 9
5 月 12 日	6.39	0.085 3	8.52	0.024 0	7.29	-0.014 5	21.94	-0.285 1
5 月 13 日	3.59	0.037 3	9.47	0.018 6	9.48	-0.030 9	24.06	0.153 5
5 月 14 日	5.53	-0.008 8	10.97	-0.009 8	9.00	-0.044 6	21.89	-0.138 7
6 月 30 日	4.40	0.039 3	9.98	0.026 4	7.97	-0.026 1	24.73	0.686 9
7 月 1 日	6.35	0.039 6	11.71	0.081 0	9.78	0.047 8	24.86	-0.488 5
7 月 2 日	6.76	-0.009 9	13.91	0.042 4	11.07	0.004 7	20.82	-0.545 3
7 月 3 日	6.89	0.022 0	12.09	0.051 2	10.12	-0.009 2	17.07	0.047 1
7 月 4 日	7.07	0.064 0	10.77	-0.065 4	9.33	-0.101 5	16.07	-0.088 1
7 月 5 日	6.38	0.029 1	9.58	-0.057 5	8.69	-0.091 9	29.49	-0.151 4
7 月 6 日	3.96	0.087 5	8.36	-0.036 2	8.91	-0.037 4	15.26	-0.053 0
8 月 5 日	4.99	0.119 2	10.11	0.002 4	8.30	-0.039 9	21.53	0.064 3
8 月 6 日	3.40	0.098 7	9.79	-0.007 7	8.77	-0.022 1	27.18	-1.031 9
8 月 7 日	4.80	0.082 9	9.95	-0.018 5	9.41	-0.036 7	15.91	-0.141 3
8 月 8 日	4.77	0.015 0	8.68	-0.075 9	8.70	-0.065 2	31.15	-0.677 8
8 月 9 日	5.28	-0.000 4	10.88	-0.010 8	8.15	-0.041 4	11.86	-0.079 6
8 月 10 日	4.90	0.039 8	10.56	-0.015 8	9.54	-0.130 9	11.69	0.039 6
8 月 11 日	5.56	0.044 2	9.97	-0.011 4	8.16	-0.068 5	15.10	0.078 6

表 9 随机 1 个月算例应用不同方法预测偏差率对比

Table 9 Comparison of prediction deviation rates using different methods in random 1 month examples

日期	本文方法		文献[1]方法		文献[5]方法		文献[31]方法	
	偏差率/%	过量预测系数	偏差率/%	过量预测系数	偏差率/%	过量预测系数	偏差率/%	过量预测系数
7 月 1 日	6.35	0.039 6	11.71	0.081 0	9.78	0.047 8	16.67	0.091 7
7 月 2 日	6.76	-0.009 9	13.91	0.042 4	11.07	0.004 7	20.82	-0.545 3
7 月 3 日	6.89	0.022 0	12.09	0.051 2	10.12	-0.009 2	17.07	0.047 1
7 月 4 日	7.07	0.064 0	10.77	-0.065 4	9.33	-0.101 5	16.07	-0.088 1
7 月 5 日	6.38	0.029 1	9.58	-0.057 5	8.69	-0.091 9	29.49	-0.151 4
7 月 6 日	3.96	0.087 5	8.36	-0.036 2	8.91	-0.037 4	15.26	-0.053 0
7 月 7 日	7.56	-0.016 9	10.45	0.025 4	9.54	-0.018 6	15.92	0.124 9
7 月 8 日	6.66	0.013 9	12.11	0.042 2	10.38	0.018 3	22.61	0.286 9
7 月 9 日	5.64	0.044 5	10.61	0.026 0	9.23	0.014 1	10.43	0.055 7
7 月 11 日	5.32	0.011 1	8.47	-0.134 2	9.19	-0.072 8	15.77	-0.122 2
7 月 12 日	4.18	-0.010 8	7.91	-0.068 1	7.91	-0.093 1	24.67	-0.145 7
7 月 13 日	5.90	0.020 1	9.63	-0.030 6	8.88	-0.025 8	16.75	-0.169 4
7 月 14 日	4.64	0.021 3	8.50	-0.051 9	8.02	-0.043 1	12.46	0.000 7
7 月 17 日	7.16	0.006 9	10.99	-0.061 5	10.95	-0.073 0	30.20	-0.455 0
7 月 18 日	8.40	-0.000 4	12.51	-0.147 0	9.54	-0.266 8	17.65	0.015 9
7 月 19 日	6.90	0.015 2	10.42	-0.043 2	8.88	-0.081 4	25.13	-0.128 4
7 月 20 日	5.65	-0.010 5	8.71	-0.042 0	7.72	-0.099 8	30.55	-0.683 4
7 月 21 日	5.50	0.048 6	8.26	-0.089 8	6.58	-0.136 5	23.37	-0.011 8
7 月 22 日	5.83	0.028 3	10.10	-0.021 8	8.44	-0.016 3	29.82	-0.071 1
7 月 23 日	4.31	0.028 5	8.63	-0.114 6	8.94	-0.085 6	20.02	-0.477 5
7 月 24 日	4.09	-0.027 1	9.04	-0.022 6	7.77	-0.033 6	21.89	-0.133 2
7 月 25 日	5.36	0.102 0	8.30	-0.119 8	9.38	-0.078 0	16.96	0.024 5
7 月 26 日	4.02	0.003 4	10.21	-0.006 0	8.53	-0.061 2	10.95	0.038 3
7 月 27 日	5.01	0.001 9	7.72	-0.063 9	6.66	-0.065 0	20.40	0.060 6

表 9(续)

日期	本文方法		文献[1]方法		文献[5]方法		文献[31]方法	
	偏差率/%	过量预测系数	偏差率/%	过量预测系数	偏差率/%	过量预测系数	偏差率/%	过量预测系数
7 月 28 日	5.12	0.040 8	6.37	-0.311 2	8.55	-0.102 5	18.10	0.021 8
7 月 29 日	6.33	-0.022 5	8.93	-0.069 8	8.12	-0.073 9	21.74	0.676 1
7 月 30 日	7.59	0.031 2	10.56	-0.091 5	10.68	-0.055 7	18.17	-0.035 9
7 月 31 日	5.16	0.034 3	10.47	0.024 6	9.41	-0.038 3	20.95	0.072 2

表 10 节假日算例应用不同方法预测偏差率对比

Table 10 Comparison of prediction deviation rates using different methods in holiday examples

日期	本文方法		文献[1]方法		文献[5]方法		文献[31]方法	
	偏差率/%	过量预测系数	偏差率/%	过量预测系数	偏差率/%	过量预测系数	偏差率/%	过量预测系数
4 月 3 日	6.80	0.007 1	10.47	-0.095 1	10.37	-0.089 8	26.31	0.062 6
4 月 4 日	5.78	0.050 2	9.18	-0.127 7	8.83	-0.139 3	38.51	-0.330 1
4 月 5 日	6.70	-0.004 2	13.23	-0.045 7	12.03	-0.069 7	21.23	-0.076 3
4 月 6 日	6.23	0.038 9	9.81	-0.056 1	8.93	-0.105 1	23.99	0.046 5
4 月 7 日	7.64	0.027 7	13.95	0.010 3	11.60	-0.022 3	30.73	0.241 4
4 月 29 日	5.56	0.009 6	12.74	-0.052 9	11.23	-0.091 6	31.07	-0.205 5
4 月 30 日	5.62	-0.011 5	12.02	-0.071 3	10.92	-0.103 3	7.73	0.018 7
5 月 1 日	8.38	0.030 0	14.51	-0.161 4	14.59	-0.111 7	27.86	-0.106 8
5 月 2 日	7.95	-0.000 6	12.00	-0.098 6	12.05	-0.050 6	26.61	-0.471 2
5 月 3 日	5.73	-0.020 6	10.19	-0.004 0	9.22	-0.027 1	29.96	0.518 4
6 月 20 日	7.37	0.038 9	11.63	0.074 5	9.14	0.035 8	12.35	0.011 9
6 月 21 日	7.83	-0.001 5	12.89	0.046 8	8.39	0.013 2	18.12	0.181 9
6 月 22 日	7.36	-0.019 5	11.74	-0.070 5	10.54	-0.084 2	11.96	0.674 7
6 月 23 日	9.60	-0.036 1	15.00	-0.047 5	13.35	-0.039 5	33.87	-0.109 1
6 月 24 日	10.70	0.016 5	14.19	-0.045 1	12.39	-0.076 7	25.71	-0.071 7

表 11 不同算例的平均偏差率对比

Table 11 Comparison of average deviation rates for different examples

算例	本文方法		文献[1]方法		文献[5]方法		文献[31]方法	
	平均偏差率/%	平均过量预测系数	平均偏差率/%	平均过量预测系数	平均偏差率/%	平均过量预测系数	平均偏差率/%	平均过量预测系数
30 日	5.01	0.022 6	9.70	-0.022 2	9.04	-0.043 2	21.12	-0.095 6
4 周	5.55	0.031 4	10.48	0.008 9	9.13	-0.024 0	20.05	-0.085 6
1 月	5.85	0.022 2	9.83	-0.048 4	8.97	-0.059 9	19.99	-0.062 7
节假日	7.28	0.008 3	12.24	-0.049 6	10.90	-0.064 1	24.40	0.025 7

6 结束语

针对旅客到达时间未知的机场安检区到达分布预测问题,本文建立到达过程和服务过程服从一般分布的多 G/G/1 并行的非平稳排队模型,应用了 SBC 近似求解系统性能指标值,并结合启发式迭代算法建立模型推算旅客到达时间。通过仿真模型验证该优化算法的有效性。仿真实验结果表明,基于机器学习聚类算法和回归算法建立了相对于航班起飞时旅客提前到达安检区的时间概率分布。在不同算例下,与过去部分预测方法的结果相比,该预测方法具有较好的预测精度和过量预测效果,便于实际的管理运营。

本文建立的预测模型以不同的航班起飞时间进行聚类分析,而现实中航班的季节、目的地、节假日等因素对航班旅客到达概率分布也有着较大的影响,后续将针对多个因素对航班旅客到达分布的影响进行研究。

参考文献

[1] 王晴. 面向航班计划的离港旅客聚集特性研究[D]. 天津: 中国民航大学, 2022.
WANG Q. A study on the characteristics of departing passenger clustering for flight planning [D]. Tianjin: Civil Aviation University of China, 2022. (in Chinese)
[2] 冯霞, 赵立强. 以时间序列分析为基准的航站楼安检客流预测[J]. 现代电子技术, 2023, 46(6): 135-142.
FENG X, ZHAO L Q. Terminal building security check passenger flow prediction based on time series analysis [J].

- Modern Electronics Technique, 2023, 46(6): 135-142. (in Chinese)
- [3] 钟翔, 朱彩云, 韩旭. 基于 BP 神经网络的机场安检旅客流量预测模型[J]. 航空工程进展, 2019, 10(5): 655-663.
ZHONG X, ZHU C Y, HAN X. The prediction model based on BP neural network about airport security-check passenger flow[J]. Advances in Aeronautical Science and Engineering, 2019, 10(5): 655-663. (in Chinese)
- [4] XING Z W, LING R H, WANG C, et al. Prediction of passenger arrival distribution in security area based on MRBF-GMM model[C]//Proceedings of the 6th International Conference on Electromechanical Control Technology and Transportation (ICECTT 2021). Chongqing, China: SPIE, 2022: 7.
- [5] WANG Y J, LIU T D, HU M H, et al. Temporal patterns underlying domestic departure passengers behavior in the airport[J]. IEEE Access, 2020, 8: 127969-127980.
- [6] YAO H F, HUANG Y Y, LIU J S. Study on travel behavior characteristics of air passengers in an airport hinterland[J]. Journal of Air Transport Management, 2023, 112: 102440.
- [7] YANG Z, WANG Y F, LI J, et al. Airport arrival flow prediction considering meteorological factors based on deep-learning methods[J]. Complexity, 2020, 2020: 6309272.
- [8] MONMOUSSEAU P, JARRY G, BERTOSIO F, et al. Predicting passenger flow at Charles de Gaulle airport security checkpoints [C]//Proceedings of the International Conference on Artificial Intelligence and Data Analytics for Air Transportation (AIDA-AT). Washington D. C., USA: IEEE Press, 2020: 1-9.
- [9] YAN Z, YANG H Y, LI F, et al. A deep learning approach for short-term airport traffic flow prediction[J]. Aerospace, 2022, 9(1): 11.
- [10] POLSON N G, SOKOLOV V O. Deep learning for short-term traffic flow prediction[J]. Transportation Research Part C: Emerging Technologies, 2017, 79: 1-17.
- [11] LIU L J, CHEN R C. A novel passenger flow prediction model using deep learning methods [J]. Transportation Research Part C: Emerging Technologies, 2017, 84: 74-91.
- [12] PEKEL E, SONER KARA S. Passenger flow prediction based on newly adopted algorithms[J]. Applied Artificial Intelligence, 2017, 31(1): 64-79.
- [13] TSUI W H K, BALLI H O, GILBEY A, et al. Forecasting of Hong Kong airport's passenger throughput[J]. Tourism Management, 2014, 42(42): 62-76.
- [14] 王蕾, 党时鹏, 潘丰. 基于卷积神经网络的隐性旁路预测模型[J]. 计算机工程, 2024, 50(8): 40-49.
WANG L, DANG S P, PAN F. Model for predicting concealed accessory pathway based on convolutional neural network[J]. Computer Engineering, 2024, 50(8): 40-49. (in Chinese)
- [15] 郑晨俊, 曾艳, 袁俊峰, 等. 基于联邦学习的船舶 AIS 轨迹预测算法[J]. 计算机工程, 2024, 50(2): 298-307.
ZHENG C J, ZENG Y, YUAN J F, Z, et al. Ship AIS trajectory prediction algorithm based on federated learning [J]. Computer Engineering, 2024, 50(2): 298-307. (in Chinese)
- [16] HE B X, LIU Y N, WHITT W. Staffing a service system with non-Poisson non-stationary arrivals [J]. Probability in the Engineering and Informational Sciences, 2016, 30(4): 593-621.
- [17] 姚加林, 潘学成. 基于排队论的高铁车站安检设备运用优化研究[J]. 铁道科学与工程学报, 2020, 17(8): 1919-1925.
YAO J L, PAN X C. Research on application by optimization of security inspection equipment in high-speed railway station based on queuing theory[J]. Journal of Railway Science and Engineering, 2020, 17(8): 1919-1925. (in Chinese)
- [18] JACQUILLAT A, ODONI A R. Endogenous control of service rates in stochastic and dynamic queuing models of airport congestion [J]. Transportation Research Part E: Logistics and Transportation Review, 2015, 73: 133-151.
- [19] NASR W W, TAAFFE M R. Fitting the pht/Mt/s/c time-dependent departure process for use in tandem queueing networks [J]. INFORMS Journal on Computing, 2012, 25(4): 758-773.
- [20] STOLLETZ R. Approximation of the non-stationary M(t)/M(t)/c(t)-queue using stationary queueing models: the stationary backlog-carryover approach[J]. European Journal of Operational Research, 2008, 190(2): 478-493.
- [21] GREEN L, KOLESAR P. The pointwise stationary approximation for queues with nonstationary arrivals [J]. Management Science, 1991, 37(1): 84-97.
- [22] GREEN L V, KOLESAR P J, SOARES J. Improving the SIPP approach for staffing service systems that have cyclic demands[J]. Operations Research, 2001, 49(4): 549-564.
- [23] NEWELL G F. Airport capacity and delays [J]. Transportation Science, 1979, 13(3): 201-241.
- [24] STOLLETZ R. Non-stationary delay analysis of runway systems[J]. OR Spectrum, 2008, 30(1): 191-213.
- [25] STOLLETZ R. Analysis of passenger queues at airport terminals [J]. Research in Transportation Business & Management, 2011, 1(1): 144-149.
- [26] STOLLETZ R, LAGERSHAUSEN S. Time-dependent performance evaluation for loss-waiting queues with arbitrary distributions [J]. International Journal of Production Research, 2013, 51(5): 1366-1378.
- [27] KRAMER W, LANGENBACH M. Approximate formulae for the delay in the queueing system GI/G/1[C]//Proceedings of the 8th International Teletraffic Congress (ITC 8). Melbourne: Australia: [s.n], 1976: 1-8.
- [28] 黄桂灶, 马同鑫, 杨泽锋, 等. 基于 GBDT 算法的弓网动态匹配特性预测模型[J]. 振动与冲击, 2024, 43(16): 26-32, 50.
HUANG G Z, MA T X, YANG Z F, et al. A study on prediction model of dynamic matching characteristics of pantograph-catenary system based on the GBDT algorithm [J]. Journal of Vibration and Shock, 2024, 43(16): 26-32, 50. (in Chinese)
- [29] 张惠煜, 严李洲, 陈庆新, 等. 考虑非平稳随机过程的机场旅检通道服务资源配置优化[J]. 工业工程, 2024, 27(5): 11-22.
ZHANG H Y, YAN L Z, CHEN Q X, et al. Optimization of service resource allocation for airport security checkpoints considering non-stationary random processes[J]. Industrial Engineering Journal, 2024, 27(5): 11-22. (in Chinese)
- [30] 高春波, 景晓霞, 彭邦华. 分析化学分析方法的原理及应用研究[M]. 北京: 中国纺织出版社, 2018.
GAO C B, JING X X, PENG B H. Study on the principle and application of analytical chemistry analysis method[M]. Beijing: China Textile & Apparel Press, 2018. (in Chinese)
- [31] LIM B, ARIK S Ö, LOEFF N, et al. Temporal fusion Transformers for interpretable multi-horizon time series forecasting[J]. International Journal of Forecasting, 2021, 37(4): 1748-1764.

文字编辑 薛晋栋
栏目编辑 宋 圆