

DOI: 10.19650/j.cnki.cjsi.J2312159

# 基于扩展卡尔曼滤波的疏散行人密度预测算法研究

高凤强<sup>1,2</sup>, 王若宇<sup>1</sup>, 曹光求<sup>2</sup>, 刘瞰东<sup>1</sup>

(1. 厦门大学萨本栋微米纳米科学技术研究院 厦门 361102; 2. 厦门大学嘉庚学院 漳州 363105)

**摘要:**疏散效率的提升是疏散系统研究的核心关注点。由于疏散系统通常呈现局部可观测性,而异常的局部观测信息会降低疏散效率,因此需对观测信息进行预测校正。为此,提出一种基于扩展卡尔曼滤波的人员密度信息预测校正算法。该算法采用神经网络拟合方法对扩展卡尔曼滤波算法中状态函数和观测函数的参数进行辨识,完成非线性疏散系统的近似线性化,提高了建模的精度;同时算法通过误差协方差矩阵的迭代更新机制实现疏散人员密度的快速预测和校正。在此基础上,还结合密度控制算法构建异常疏散场景下的行人疏散控制策略。为验证所提算法的有效性,在设计和构建异常疏散场景仿真模型的基础上进行了对比仿真和真人疏散可控实验。结果表明,相较无数据校正的疏散控制策略,算法在异常疏散仿真和真人可控场景中分别获得最高38.9%和23.26%的效率提升,为异常疏散场景中的控制策略提供了有效的解决思路。

**关键词:** 行人疏散; 系统辨识; 扩展卡尔曼滤波; 行人流密度预测; 疏散仿真

**中图分类号:** TH39 TP29 **文献标识码:** A **国家标准学科分类代码:** 510.80

## Research on the evacuation pedestrian density prediction algorithm based on extended Kalman filter

Gao Fengqiang<sup>1,2</sup>, Wang Ruoyu<sup>1</sup>, Cao Guangqiu<sup>2</sup>, Liu Tundong<sup>1</sup>

(1. Pen-Tung Sah Institute of Micro-Nano Science and Technology, Xiamen University, Xiamen 361102, China;

2. Xiamen University Tan Kah Kee College, Zhangzhou 363105, China)

**Abstract:** Enhancing evacuation efficiency is of paramount importance in the field of evacuation systems research. Evacuation systems often present observability limitations, and any abnormal observation of pedestrian density at the exits can diminish the effectiveness of evacuation control. Therefore, correcting the abnormal observation information at exits becomes imperative for improving evacuation performance. To address this issue, an algorithm based on the extended Kalman filter is proposed to predict pedestrian density, and a correlation mapping between normal and abnormal pedestrian densities is established. The algorithm incorporates a neural network fitting method to identify the parameters of the state and observation functions in the extended Kalman filter algorithm, enhancing the accuracy of system modeling by approximating nonlinearity. Moreover, an iterative update mechanism utilizing the error covariance matrix allows for fast prediction and correction of pedestrian density. Additionally, the algorithm incorporates a density control algorithm to formulate a pedestrian flow evacuation control strategy for abnormal evacuation scenarios. Comparative simulations are conducted by using the evacuation model in abnormal evacuation scenarios to evaluate the effectiveness of the proposed algorithm. The results show that, compared to the evacuation control strategy without data correction, the proposed algorithm achieves efficiency improvements of up to 38.9% and 23.26% in abnormal evacuation simulation and human-controllable scenarios, respectively, which provides an effective solution approach for control strategies in abnormal evacuation scenarios.

**Keywords:** pedestrian evacuation; system identification; extended Kalman filter; pedestrian flow density prediction; evacuation simulation

## 0 引言

提高疏散效率对于减少由事故造成的伤亡和财产损失具有重要意义<sup>[1]</sup>。疏散仿真通过计算机技术能有效评估在不同场景下的疏散控制策略,从而辅助决策者优化疏散计划、路径和资源调度,进而提高疏散效率<sup>[2]</sup>。早期研究主要集中在建立模拟人群动力学的各种模型<sup>[3-4]</sup>,并基于模型探索提高疏散效率的方法,如合理设置疏散设施<sup>[5]</sup>、路径规划<sup>[6]</sup>和引导人员<sup>[7]</sup>等。但此类研究主要关注预定计划的优化,难以适应实际疏散场景中状态信息的实时变化<sup>[8]</sup>。为解决该问题,研究人员提出了一种基于动态消息通知机制的实时人群疏散引导方法。Lopez-Carmona 等<sup>[9]</sup>通过手持设备让疏散人员实时接收不同出口的状态信息,以便引导疏散人员并优化疏散过程。Gorbil 等<sup>[10]</sup>通过特定的终端向疏散人员实时发送最优疏散路径的通知,以提高疏散效率。Qiu 等<sup>[11]</sup>通过智能手机上传位置信息并获得最短的安全路线,实现高效的人员疏散。但此类方法需要疏散人员佩戴特定设备以接收引导信息,在实际应用中存在一定的局限性。

为了克服疏散人员需要特殊佩戴设备的局限性,部分研究人员利用人群检测技术实现对疏散区域内人员分布的检测,为免佩戴设备的实时人群引导方法提供技术支持。在此基础上,一种基于局部观测信息的疏散人员实时引导方法被提出<sup>[12]</sup>。该方法通过采集出口人员密度信息,实现出口信号指示灯的动态控制,具有实现简单且引导信号易于理解的优点。Gao 等<sup>[13]</sup>在正确采集局部观测信息(即出口人员密度)的前提下,证实了该方法可以提高疏散效率。然而,在实际的紧急疏散过程中,观测信息常常会因疏散环境变化或观测设备异常而出现错误,进而导致疏散效率下降。因此,实现对异常观测信息的预测和校正是提高动态疏散环境下高效人员引导的有效途径。

目前,实现信息预测和校正的方法包括统计方法<sup>[14]</sup>、滤波器方法<sup>[15]</sup>、机器学习方法<sup>[16]</sup>和物理模型方法<sup>[17]</sup>等方法。针对疏散系统观测信息实时更新的要求,扩展卡尔曼滤波(extended Kalman filter, EKF)作为一种计算量较小的滤波器方法<sup>[18]</sup>,可通过误差协方差矩阵的迭代更新实现疏散人员密度的快速预测和校正。但疏散系统的动态性和非线性特点会导致 EKF 中状态矩阵和观测矩阵的动态变化,进而对 EKF 的性能和预测的准确性产生影响<sup>[19]</sup>。为准确建模和预测非线性系统的行为,研究人员通常采用手动调整法、数据驱动法、最小二乘法和期望最大化法等方法对状态矩阵和观测矩阵进行辨识<sup>[20]</sup>。反向传播(back propagation, BP)神经网络辨识方法作为一种简易的数据驱动方法,具有强大的非线性

建模能力,在系统辨识中得到了广泛应用<sup>[21]</sup>。同时,BP神经网络的实现相对简单且计算成本较低,可满足系统对实时性的要求。

因此,本文首先分析了异常人流密度信息对疏散人员实时引导系统的影响,并针对性地提出了一种基于 EKF 的人流密度预测算法。该算法采用 BP 神经网络对 EKF 算法的状态矩阵和观测矩阵进行辨识,实现了非线性疏散系统的近似线性化,并对局部出口人流密度进行预测校正。此外,将该算法与密度控制算法结合,实现了异常疏散场景下的人流控制策略。

## 1 系统描述与问题定义

### 1.1 系统描述

本文研究的疏散系统  $\Pi$  由多个疏散人员、疏散出口、引导人员和疏散空间组成。疏散人员通过观测的信息(如出口位置周围的疏散人员数量)实时调整自身位置,以安全快速地离开疏散空间。先前研究表明,引导人员的引导可以显著提高疏散效率<sup>[22]</sup>。因此,本文研究了具有  $\varepsilon \in N_+$  个疏散引导人员的疏散引导系统  $\mathcal{S}$ 。在该系统中,每个引导人员对应一个疏散出口,并通过引导信号引导疏散者到相应出口。本文假设疏散引导人员根据实时疏散信息动态调整引导信号,从而影响疏散进程。实时疏散信息指疏散引导人员通过计算机辅助技术获取的部分疏散人员位置等局部信息,例如,引导人员通过每个出口上的观测摄像机实时观测和统计出口附近的疏散人员密度  $\rho_i$ ,并根据观测的信息动态调整引导信号强度。

以前的研究已经证明<sup>[12-13]</sup>,通过观测局部信息(如出口周围的行人密度)并主动调整引导信号强度,可以有效提高多出口场景下的疏散效率。然而,该调整方式的有效性取决于引导人员获取信息的准确性。在实际疏散场景中,摄像机故障或火灾过程中烟雾遮挡都会导致错误观测信息的产生。因此,在个别观测信息错误的情况下,如何进行引导信号的主动调整以确保高效的疏散成为一个具有现实意义的问题。

为解决该问题,本文提出了针对疏散引导的信息校正框架,如图 1 所示。该系统框架应用力驱动的元胞自动机(cellular automaton, CA)构建疏散模型,并通过 EKF 对引导系统  $\mathcal{S}$  的密度控制器进行信息的预测校正,从而实现在错误信息条件下的有效疏散控制。

### 1.2 社会力驱动元胞自动机疏散模型

本文研究的是二维 Moore 型元胞网格场景的疏散引导,并设计了一种力驱动的 CA 疏散模型。该模型核心内容包括社会力的定义和 CA 模型的演化规则。每个元胞网格有 8 个可移动方向,并且只能被一个疏散人员占

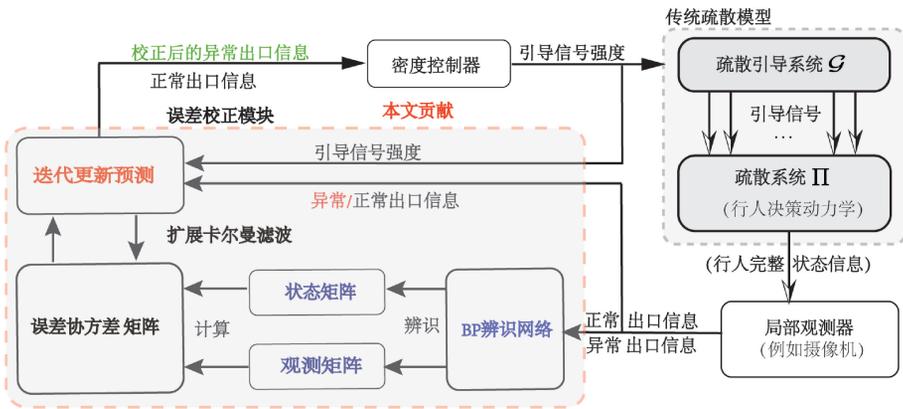


图 1 基于信息校正的疏散引导辅助系统结构

Fig. 1 Structure diagram of evacuation guidance assistance system based on information correction

据,如图 2(a)所示。同时,本文考虑的是一个  $N \times N$  个元胞网络的正方形疏散空间,  $N = 21$  为的示意图如图 2(b)所示。图 2(b)还给出了行人视野的长度  $w$ 、观测行人密度的区域和大小  $d$  的示意。在该模型中,假定疏散空间中的人员根据社会力的演化规则实时更新位置,并通过出口离开疏散空间。当疏散空间中的人员数量为 0 时,表示疏散过程结束。

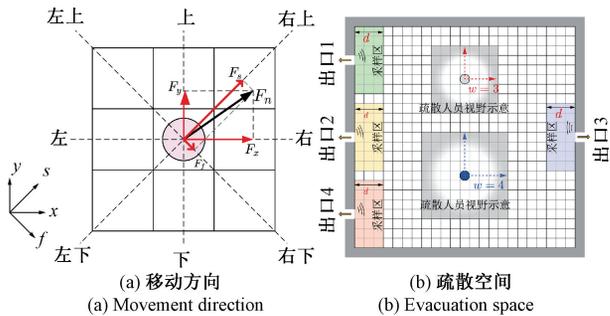


图 2 移动方向和疏散空间示意图

Fig. 2 Diagram of movement direction and evacuation space

### 1) CA 疏散模型的社会力定义

本文的 CA 疏散模型中应用了社会合力的概念,如图 2(a)所示。行人  $n$  受到的作用力  $F_n$  为引导力  $F_{guide}^n$ 、行人间作用力  $F_{mutual}^{n,m}$  和可见出口吸引力  $F_{exit}^{n,i}$  的合力,即:

$$F_n = w_1 F_{guide}^n + w_2 \sum_{m \in \mathbb{V}_n^p} F_{mutual}^{n,m} + w_3 \sum_{m \in \mathbb{V}_n^e} F_{exit}^{n,i} \quad (1)$$

式中:  $w_1, w_2$  和  $w_3 \in \mathbb{R}_+$  分别是引导力、可见出口吸引力和行人间作用力的权重因子。  $\mathbb{V}_n^p$  表示在行人  $n$  视野范围内的行人集合,  $\mathbb{V}_n^e$  表示在行人  $n$  视野范围内的出口集合。引导力  $F_{guide}^n$ 、行人间作用力  $F_{mutual}^{n,m}$  和可见出口吸引力  $F_{exit}^{n,i}$  的定义可以参考文献[13-14]。

### 2) 社会力驱动的演化规则

本文应用的基于社会力驱动 CA 疏散模型的演化规

则总结如下,其中  $\mathbb{R}\mathbb{M}(t)$  表示  $t$  步序时疏散空间中剩余的疏散人员集。

(1) 初始化。初始化步序  $t = 1$  时的疏散空间,包括疏散空间中的初始人员数量和位置分布,出口的位置等。

(2) 目标元胞网格更新。计算  $t$  步序时每个行人  $n \in \mathbb{R}\mathbb{M}(t)$  的合力  $F_n$ 。定义  $P_n = [P_n^1, P_n^2, P_n^3, P_n^4]$  为下一步移动目标元胞网格序列,其中  $P_n^i$  表示第  $i$  个目标元胞网格地址且  $i \in [1, 4]$ 。最后根据  $F_n$  在  $x, y, s$  和  $f$  轴分解力(图 2(a))的大小确定  $P_n$ 。

(3) 行人位置更新。由于存在多个行人具有相同目标元胞网格的情况,所以行人之间需要进行目标元胞网格竞争。本文设定每个行人都有 4 次机会进行目标元胞的竞争。如果行人  $n$  在第  $i \in [1, 4]$  次竞争获胜,则其  $t + 1$  步序位置更新为  $P_n^i$ 。如果其 4 次竞争都失败,则保持原地不动。

(4) 剩余行人集合更新。根据最新的行人位置,判断是否有到达出口的行人。如果某个行人已经到达出口,则将其从状态空间删除并更新  $\mathbb{R}\mathbb{M}(t)$ 。

(5) 疏散结束判断。如果  $\mathbb{R}\mathbb{M}(t)$  为空,则停止疏散仿真。否则,设置  $t = t + 1$ ,并跳转到步骤(2)继续进行仿真。

### 1.3 密度控制算法描述

#### 1) 出口人员密度定义和异常

图 2 中,4 个出口周围的彩色区域表示采样(观测)区,引导人员可以获得此区域的人员密度,并且可见半径为  $d$ 。本文每个元胞网格只能容纳一个疏散人员,且安置在每个出口的摄像机可获取对应观测区域中的疏散者数量  $n_i^{obs}$ ,因此出口  $i$  周围的疏散人员密度  $\rho_i^{obs}$  定义如下:

$$\rho_i^{obs} = \frac{n_i^{obs}}{n_i^{cap}}, 0 \leq \rho_i \leq 1 \quad (2)$$

其中,  $n_i^{cap}$  表示观测区可容纳行人数量,定义为:

$$n_i^{cap} = d \times (2 \times d + 1) \quad (3)$$

当出口*i*配置的摄像机工作异常时,摄像机获取到的观测区内的人数*n<sub>i</sub><sup>obs</sup>*和实际行人数量*n<sub>i</sub><sup>rt</sup>*就会发生偏离,导致获取到的人员密度*ρ<sub>i</sub><sup>obs</sup>*发生错误。

2) 密度控制算法定义

本文采用一种基于棒棒控制的密度控制算法作为疏散引导系统的反馈控制,用于调整出口*i*的引导信号强度*u<sub>i</sub>(t)*,从而影响疏散效率。所有的引导人员仅能观察到各自观测区的人员密度*ρ<sub>i</sub><sup>obs</sup>(t)*,当*ρ<sub>i</sub><sup>obs</sup>(t)*大于或小于目标密度*ρ<sub>i</sub><sup>aim</sup>*时,关闭或打开引导信号*u<sub>i</sub>(t)*,其中*i* ∈ *N<sub>EA</sub>*(引导人员的集合)。本文采用的密度控制算法如下:

$$u_i(t) = \begin{cases} 1, & \rho_i^{obs}(t) \leq \rho_i^{aim} \\ 0, & \rho_i^{obs}(t) > \rho_i^{aim} \end{cases} \quad (4)$$

$$i \in \{1, 2, 3, 4\}$$

式中:*ρ<sub>i</sub><sup>aim</sup>*表示由疏散引导人员*i*设定的目标密度;*ρ<sub>i</sub><sup>obs</sup>(t)*表示*t*时刻出口*i*的疏散人员密度。

1.4 疏散人员密度误差对密度控制的影响

摄像机故障或遮挡会导致获取的行人密度数据出现错误。为了研究密度错误对控制效果的影响,本文进行了3组不同出口故障的对比实验。该实验设定了数值跳动范围*v* = 0.4,即故障摄像机获取的出口人员密度在0~0.4随机跳动。本文将由此产生的错误密度定义为:

$$\rho_i^{error} = rand(0, v), 0 \leq v \leq 1 \quad (5)$$

式中:函数*rand(0, v)*用于生成一个介于0和*v*之间的随机数。当出口*i*的摄像机发生异常时,*ρ<sub>i</sub><sup>obs</sup>* = *ρ<sub>i</sub><sup>error</sup>*。

本文实验的响应曲线如图3所示,其中标记为“正常”的曲线代表所有出口正常工作时的疏散效果。曲线位于黑色失效线上方表示控制无效。从图3可以观察到,错误的密度数据导致控制几乎无效。为了更详细地观察异常观测数据对疏散过程的影响,出口3故障以及正常数据下的典型实时人员分布如图4所示。在正常条件下,疏散过程中各个出口的人员分布相对均匀,没有明显的人员拥堵情况,如图4(b)所示。然而,在异常数据条件下,疏散引导控制反而会导致异常出口出现人员拥堵情况,并且随着拥堵情况进一步加剧甚至出现非故障出口人员为空的情况,如图4(a)所示。该问题降低了各个出口的利用率,从而导致引导控制失效。

综上所述,异常密度数据对疏散过程的控制策略会产生负面影响。图4进一步证明了异常数据导致人员拥堵和引导控制失效的情况。该情况说明了研究数据异常情况下的人员疏散引导控制具有实际意义。因此,本文研究的重点是在单个出口出现异常密度数据的条件下如何提高疏散效率、减少异常数据对控制算法的不良影响。

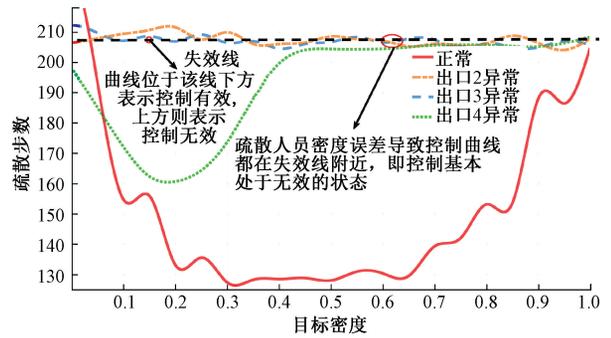


图3 不同出口故障和数据波动范围*v* = 0.4的响应曲线

Fig. 3 Response curve of different exit faults and data fluctuation range *v* = 0.4

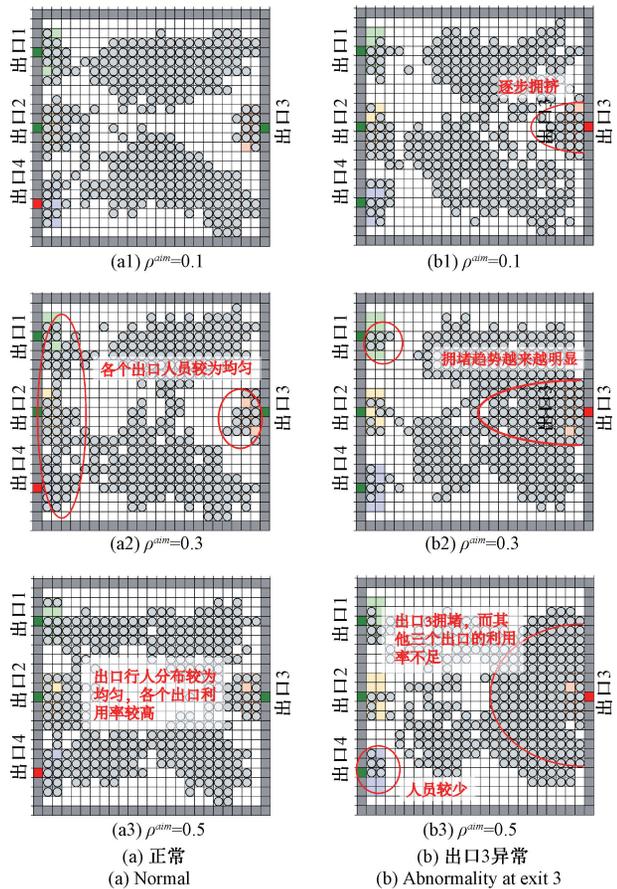


图4 正常和异常数据条件下的疏散人员实时分布

Fig. 4 Real-time distribution of evacuees under normal and abnormal data conditions

2 融合BP辨识和EKF的预测校正算法

为解决异常密度数据导致控制策略失效的问题,本文提出了一种基于EKF的疏散人员密度预测校正算法。该算法核心流程包括疏散系统建模、系统辨识和疏散人员密度预测。疏散系统建模实现对疏散系统的疏散人员

密度演化规则的模拟,构建了应用于 EKF 的疏散系统状态函数  $f(\cdot)$  和观测函数  $h(\cdot)$ 。状态函数  $f(\cdot)$  描述了相邻时序的正常出口疏散人员密度和信号引导强度的状态迭代关系,即  $k$  时刻正常出口疏散人员密度  $\mathbf{X}_k$ 、引导信号强度  $\mathbf{U}_k$  和  $k+1$  时刻正常出口疏散人员密度  $\mathbf{X}_{k+1}$  的迭代关系。观测函数  $h(\cdot)$  描述了正常出口疏散人员密度同异常出口疏散人员密度的映射关系,即  $k$  时刻正常出口

疏散人员密度  $\mathbf{X}_k$  和异常出口疏散人员密度  $\mathbf{Z}_k$  的映射关系。由于系统的状态函数  $f(\cdot)$  和观测函数  $h(\cdot)$  是非线性,且不能直接求解,因此本文采用 BP 神经网络对系统进行辨识,并通过辨识网络的权重计算  $f(\cdot)$  和  $h(\cdot)$  的具体表达式。在获得  $f(\cdot)$  数和  $h(\cdot)$  的具体表达式的基础上,本文采用扩展卡尔曼滤波对疏散人员密度进行预测校正,流程如图 5 所示。

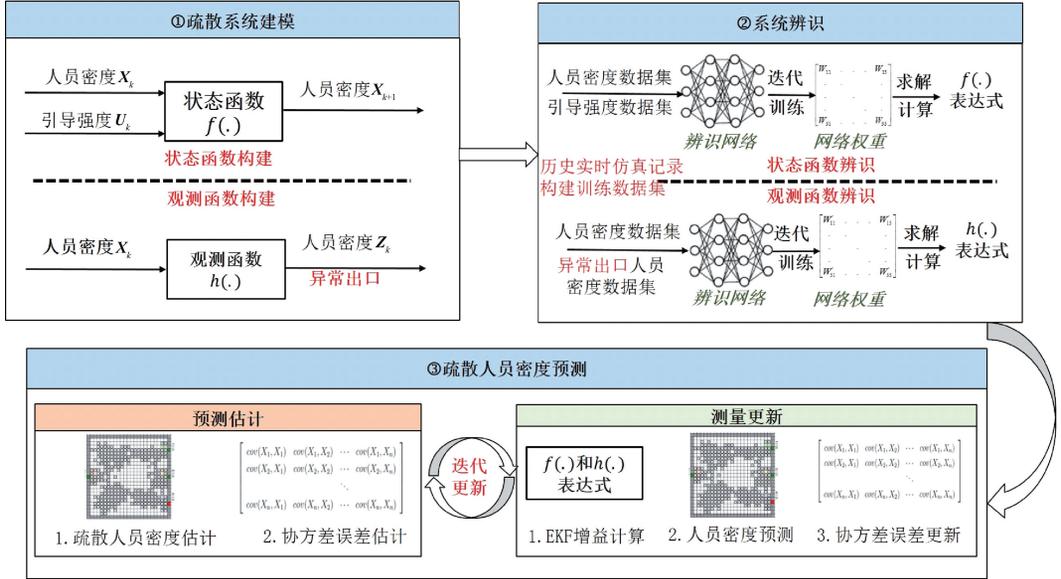


图 5 基于 EKF 的疏散人员密度预测流程示意图

Fig. 5 Diagram of the evacuees density prediction process based on EKF

### 2.1 疏散系统建模

考虑到疏散系统中疏散人员密度和引导信号强度之间关系为非线性,本文构建的疏散系统的状态函数和观测函数如下:

$$\mathbf{X}_k = f(\mathbf{X}_{k-1}, \mathbf{U}_{k-1}) + \mathbf{Q}_{k-1} \quad (6)$$

$$\mathbf{Z}_k = h(\mathbf{X}_k) + \mathbf{R}_k \quad (7)$$

式中:  $\mathbf{X}_k$  表示  $k$  时刻的系统状态变量;  $\mathbf{Z}_k$  表示  $k$  时刻的系统观测矩阵;  $\mathbf{U}_{k-1}$  表示  $k-1$  时刻的系统输入,即引导信号强度;  $f(\cdot)$  表示非线性状态函数;  $h(\cdot)$  表示非线性观测函数;  $\mathbf{Q}_{k-1}$  表示过程噪声;  $\mathbf{R}_k$  表示测量噪声;  $\mathbf{Q}_{k-1}$  和  $\mathbf{R}_k$  相互独立,且均值为 0。当图 2(b) 中的第 4 个出口存在故障导致采集到的出口疏散人员密度存在异常,则  $k$  时刻第 4 个出口的摄像机检测出的疏散人员密度对应系统观测变量  $\mathbf{Z}_k$ , 另外 3 个出口的摄像机检测出的  $k$  时刻疏散人员密度和引导信号强度则分别对应着系统状态变量  $\mathbf{X}_k$  和  $\mathbf{U}_k$ :

$$\mathbf{X}_k = \begin{bmatrix} \rho_1^{obs}(k) \\ \rho_2^{obs}(k) \\ \rho_3^{obs}(k) \end{bmatrix} \quad (8)$$

$$\mathbf{U}_k = \begin{bmatrix} u_1(k) \\ u_2(k) \\ u_3(k) \end{bmatrix} \quad (9)$$

$$\mathbf{Z}_k = [\rho_4^{obs}(k)] \quad (10)$$

其中,  $\rho_i^{obs}(k), i \in [1, 4]$  表示  $k$  时刻出口  $i$  的疏散人员密度,  $u_i(k), i \in [1, 3]$  表示  $k$  时刻出口  $i$  的引导强度。

### 2.2 状态函数和观测函数辨识

由于疏散系统的状态函数  $f(\cdot)$  和观测函数  $h(\cdot)$  不能直接求解,本文采用 BP 网络进行系统辨识,进而获得  $f(\cdot)$  和  $h(\cdot)$  的具体表达式。辨识的过程主要包括辨识 BP 网络的构建、辨识 BP 网络的迭代训练和函数的求解,具体流程如图 5 所示。

#### 1) 辨识 BP 网络的构建

根据式(6)和(7)可知两个函数的输入和输出类型不一致,当图 2(b) 中的第 4 个出口的存在故障的情况,根据式(8)~(10)可得系统状态变量  $\mathbf{X}_k \in \mathbb{R}^{3 \times 1}$ 、系统输入量  $\mathbf{U}_k \in \mathbb{R}^{3 \times 1}$  和观测值  $\mathbf{Z}_k \in \mathbb{R}^{1 \times 1}$ 。因此本文构建了两个 BP 神经网络分别用于辨识状态函数  $f(\cdot)$  和观测函数

$h(\cdot)$ 。用于观测函数  $f(\cdot)$  辨识的网络结构如图 6 所示, 该网络的输入为  $\mathbf{X}_{k-1}$  和  $\mathbf{U}_{k-1}$ 、输出为  $\mathbf{X}_k$ 、激活函数为 Sigmoid 函数。用于观察函数  $h(\cdot)$  辨识的网络结构如图 7 所示, 该网络的输入为  $\mathbf{X}_k$ , 输出为  $\mathbf{Z}_k$ , 激活函数为 Sigmoid 函数。

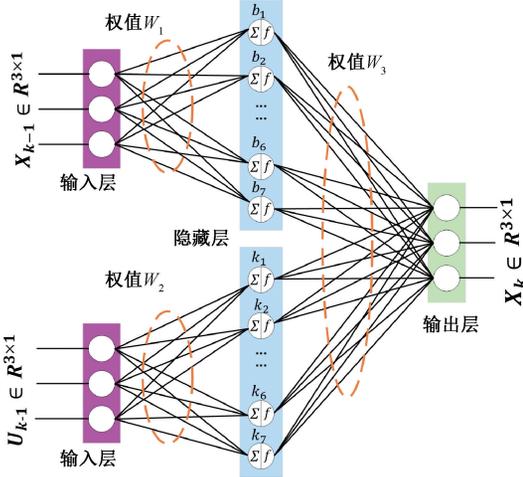


图 6 辨识状态函数  $f(\cdot)$  的 BP 网络结构

Fig. 6 BP neural network structure for identifying state function

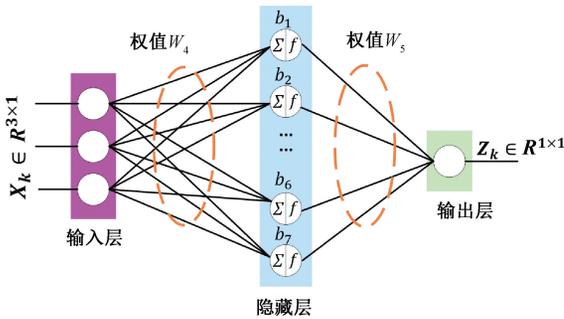


图 7 辨识观测函数  $h(\cdot)$  的 BP 网络结构

Fig. 7 BP neural network structure for identifying observation function  $h(\cdot)$

## 2) 辨识 BP 网络的迭代训练

本文采用 20 000 次仿真实验过程中产生的历史过程数据作为训练数据集。训练时将样本数据以 7:3 的比例分成训练集和验证集, 同时采用随机梯度下降 (stochastic gradient descent, SGD) 优化器更新权重, 采用均方误差 (mean squared error, MSE) 作为损失函数进行迭代学习。同时在训练的过程中设置了早停机制, 即超过 20 步验证集的损失值没有下降, 则提前停止网络的训练。

## 3) 函数的求解

BP 神经网络训练结束后可得到各层网络的权值。根据各层权值结合神经网络的传输函数, 可求得  $f(\cdot)$  和

$h(\cdot)$  的具体表达式。根据图 6 中辨识  $f(\cdot)$  的网络结构, 辨识  $f(\cdot)$  的 BP 网络整体表达式如下:

$$\mathbf{N}_f = \mathbf{W}_1^T \mathbf{X}_{k-1} + \mathbf{W}_2^T \mathbf{U}_{k-1} \quad (11)$$

$$\mathbf{O}_f = \mathbf{W}_3^T \text{Sigmoid}(\mathbf{N}_f) = \mathbf{W}_3^T \text{Sigmoid}(\mathbf{W}_1^T \mathbf{X}_{k-1} + \mathbf{W}_2^T \mathbf{U}_{k-1}) \quad (12)$$

根据式 (6) 和 (12) 可得状态函数的表达式为:

$$f(\mathbf{X}_{k-1}, \mathbf{U}_{k-1}) = \mathbf{W}_3^T \text{Sigmoid}(\mathbf{W}_1^T \mathbf{X}_{k-1} + \mathbf{W}_2^T \mathbf{U}_{k-1}) \quad (13)$$

根据图 7 中辨识  $h(\cdot)$  的 BP 网络结构, 辨识  $h(\cdot)$  的 BP 网络整体表达式如下:

$$\mathbf{N}_h = \mathbf{W}_4^T \mathbf{X}_k \quad (14)$$

$$\mathbf{O}_h = \mathbf{W}_5^T \text{Sigmoid}(\mathbf{N}_h) = \mathbf{W}_5^T \text{Sigmoid}(\mathbf{W}_4^T \mathbf{X}_k) \quad (15)$$

根据式 (7) 和 (15) 可得观测函数的表达式为:

$$h(\mathbf{X}_k) = \mathbf{W}_5^T \text{Sigmoid}(\mathbf{W}_4^T \mathbf{X}_k) \quad (16)$$

## 2.3 疏散人员密度预测

在完成系统建模和辨识的基础上, 本文采用扩展卡尔曼的递推算法进行故障出口的疏散人员密度预测, 算法的核心流程如图 8 所示。扩展卡尔曼的递推算法包括预测和更新两个模块, 两个模块顺序迭代执行实现预测校正。

### 1) 预测模块

求解  $f(\cdot)$  的雅克比矩阵实现  $f(\cdot)$  的近似线性化处理:

$$\mathbf{F}_{k-1} = \left. \frac{\partial f(\mathbf{X}_{k-1})}{\partial \mathbf{X}} \right|_{\mathbf{X}_{k-1}} = \mathbf{W}_3^T \text{Sigmoid}(\mathbf{W}_1^T \mathbf{X}_{k-1} + \mathbf{W}_2^T \mathbf{U}_{k-1}) (1 - \text{Sigmoid}(\mathbf{W}_1^T \mathbf{X}_{k-1} + \mathbf{W}_2^T \mathbf{U}_{k-1})) \mathbf{W}_1^T \quad (17)$$

根据  $k-1$  时刻的疏散人员密度对  $k$  时刻的疏散人员密度做出估计:

$$\mathbf{X}_{k|k-1} = f(\mathbf{X}_{k-1}, \mathbf{U}_{k-1}) \quad (18)$$

对  $k$  时刻的误差协方差矩阵进行估计:

$$\mathbf{P}_{k|k-1} = \mathbf{F}_{k-1} \mathbf{P}_{k-1} \mathbf{F}_{k-1}^T + \mathbf{Q}_k \quad (19)$$

### 2) 更新模块

求解  $h(\cdot)$  的雅克比矩阵实现  $h(\cdot)$  的近似线性化处理:

$$\mathbf{H}_{k-1} = \left. \frac{\partial h(\mathbf{X}_{k-1})}{\partial \mathbf{X}} \right|_{\mathbf{X}_{k-1}} = \mathbf{W}_5^T \text{Sigmoid}(\mathbf{W}_4^T \mathbf{X}_k) (1 - \text{Sigmoid}(\mathbf{W}_4^T \mathbf{X}_k)) \mathbf{X}_k^T \quad (20)$$

扩展卡尔曼滤波的增益计算:

$$\mathbf{K} = \mathbf{P}_k \mathbf{H}_k^T [\mathbf{H}_k \mathbf{P}_k \mathbf{H}_k^T + \mathbf{R}]^{-1} \quad (21)$$

根据  $k$  时刻的疏散人员密度估计对  $k$  时刻的疏散人员密度做出预测, 从而得到校正后的疏散人员密度:

$$\mathbf{X}_k = \mathbf{X}_{k|k-1} + \mathbf{K}(\mathbf{Z}_k - \mathbf{H}_k \mathbf{X}_{k|k-1}) \quad (22)$$

对  $k$  时刻的误差协方差矩阵进行更新:

$$\mathbf{P}_k = [\mathbf{I} - \mathbf{K} \mathbf{H}_{k-1}] \mathbf{P}_{k|k-1} \quad (23)$$

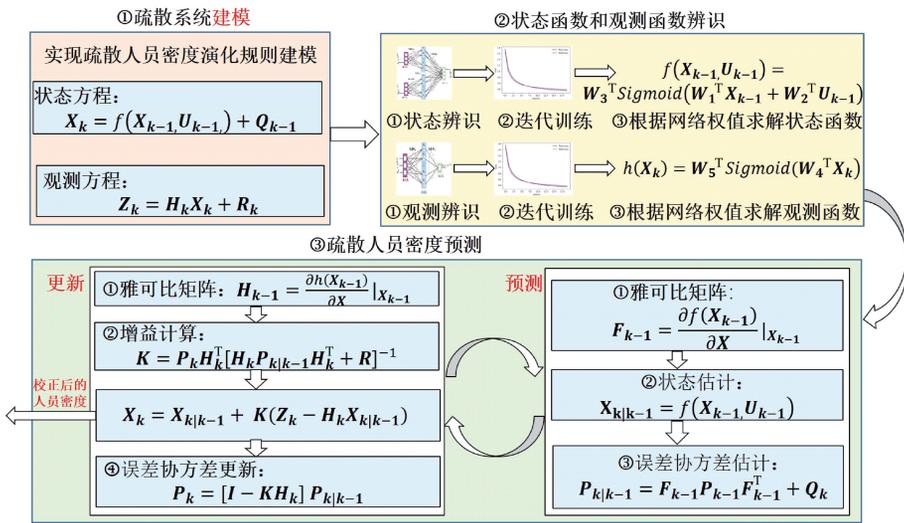


图 8 基于 EKF 的疏散人员密度预测核心步骤

Fig. 8 Core steps of evacuees density prediction based on EKF

### 3 实验分析

#### 3.1 仿真对比实验

为了验证本文提出的校正算法的有效性,本文进行了校正算法应用前后以及正常数据条件下的对比实验。3 组对比实验分别对应采用预测校正算法修正不同出口异常的情况,“出口 3 校正”、“出口 2 校正”和“出口 1 校正”分别对应出口 3、2 和 1 异常的情况。实验结果如图 9 所示。从图 9 可以观察到,采用校正算法后控制曲线基本上都位于黑色失效线下方,并且围绕正常曲线上波动。该情况说明校正算法的引入有效改善了故障条件下的控制效果,使得控制曲线接近各出口正常情况下的曲线。为进一步说明校正算法的优势,本文将出口 4 异常的控制曲线加入对比,结果如图 10 所示。从图 10 可以看出,采用校正算法的“出口 4 校正”曲线相对于“出口 4 异常”曲线有显著的效率提升。

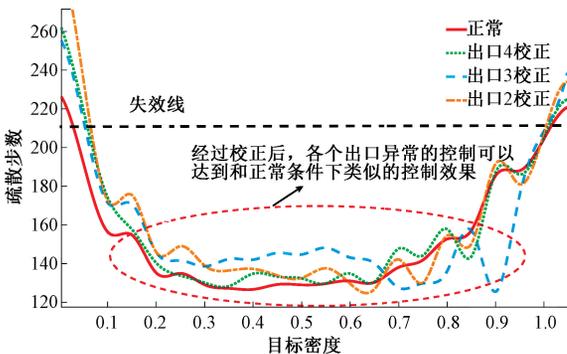


图 9 校正后的控制曲线

Fig. 9 Control curve after correction

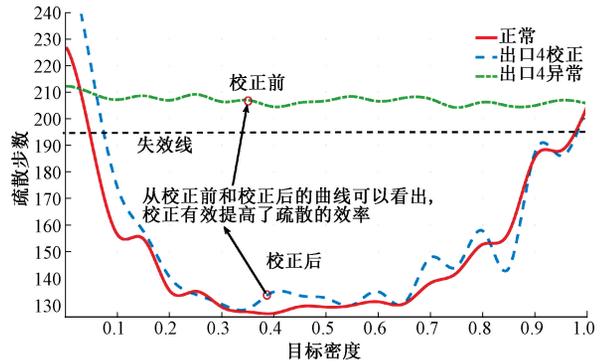


图 10 出口 4 异常校正前后曲线对比

Fig. 10 Comparison of curves before and after correction for abnormality in exit 4

为了更详细地观察校正算法对疏散过程的宏观影响,出口 4 故障以及采用预测校正算法后的典型实时人员分布,如图 11 所示。预测校正后的疏散人员在各个出口分布较为均匀,更加接近数据正常的疏散人员分布,如图 11(b) 和图 4(a) 所示。进一步观察对比可以发现采用 EKF 预测校正可以让异常数据下出现的拥堵现象和部分出口人员为空的问题得到改善,如图 11(a) 和 (b) 所示。此外,各个出口的疏散利用率得到提高,从而提高了整体的疏散效率。

同时,为了定量分析校正前后的提升比例,本文统计了校正前的最优疏散值(疏散步数最小)和校正后的最优疏散值,并计算了提升比例,结果如表 1 所示。从表 1 可以看出,采用本文提出的校正算法可实现最高 38.9% 的效率提升,最少 21.8% 的效率提升。

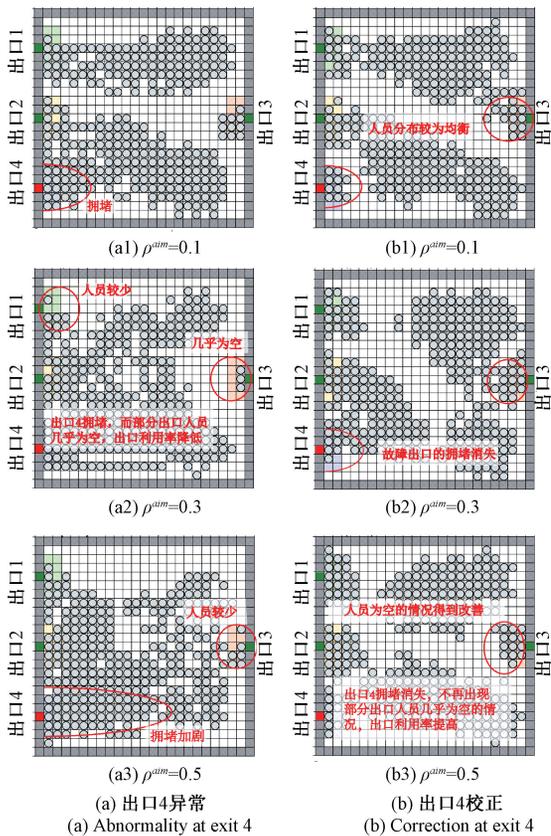


图 11 出口 4 故障校正前后的疏散人员实时分布情况  
Fig. 11 Real-time distribution of evacuees after correction for exit 4 fault

表 1 校正前后疏散效率提升数值

Table 1 Numerical improvement in evacuation efficiency before and after correction

异常位置	校正前最优值(步数)	校正后最优值(步数)	提升比例/%
出口 2	204.1	124.8	38.9
出口 3	160.5	125.5	21.8
出口 4	204.5	128.1	37.4

### 3.2 可控对比实验

为了进一步验证本算法在实际场景中的有效性,并为其实际应用提供依据,本文设计并开展了真人疏散可控对比实验。该实验布局与仿真实验相似,场地长宽均为 17 个方格,每个方格尺寸为 0.6 m×0.6 m。实验场地共设有 4 个出口,其航拍图如图 12 所示。

本文所设计的实验疏散引导系统由摄像机、指示灯和服务器组成,整体控制结构如图 13(a)所示。在该系统中,摄像机负责实时采集出口行人流视频数据,为算法处理提供输入。同时,指示灯以直观的方式展现出口当前状态:亮起代表通畅,熄灭则意味着拥堵,为行人提供

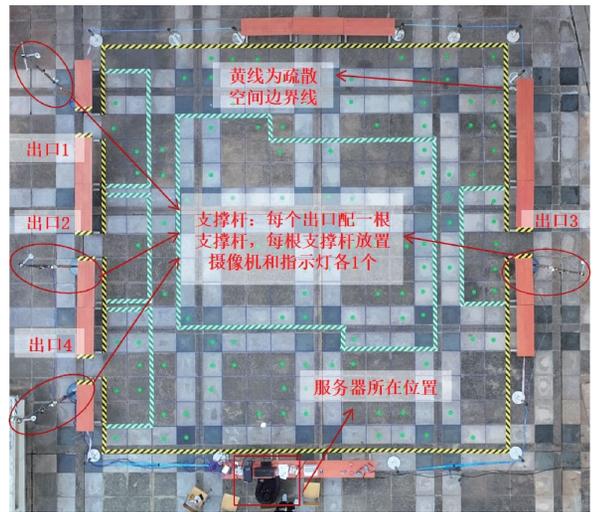


图 12 可控实验现场航拍图

Fig. 12 Aerial image of the controllable experimental site

实时的引导信息。服务器执行出口行人密度计算算法、密度控制算法和人员密度预测校正算法,3 个算法的关系如图 13(b)所示。其中,出口行人密度计算算法通过摄像机捕捉的行人流视频计算出当前出口区域的人员密度,为系统提供实时的人员密度数据。密度控制算法则根据实时的人员密度与预设的目标密度进行比对,并进行指示灯状态的实时调整,以实现对外出口行人流的有效干预。此外,人员密度预测校正算法采用本文提出的基于 EKF 的预测校正方法,为密度控制算法提供经过校正的出口人员密度数据。通过上述算法与组件的协同工作,引导系统不仅可以实时地监控出口的行人流动态,还能有效地开展多出口疏散可控实验。该系统的实施为本文所提算法的实际应用提供技术支撑。

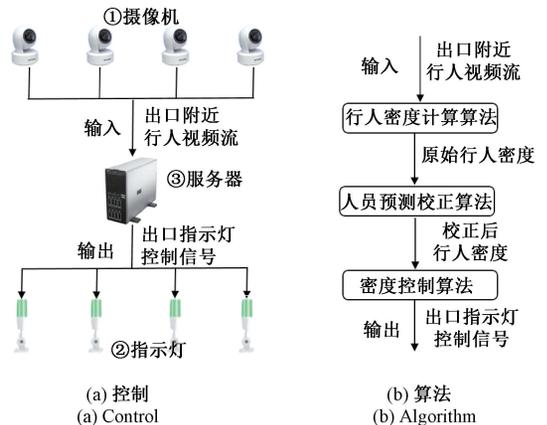


图 13 疏散引导系统控制结构图和算法关系

Fig. 13 Control structure diagram and algorithm relationship diagram of the evacuation guidance system

为评估校正算法在不同数据异常条件下的有效性,

本文的真人疏散可控对比实验涵盖了校正算法应用前后的场景,初始人员分布如图 14 所示,实验结果如表 2 所示。根据实验结果进行统计分析,校正算法在可控实验中最高可获得 23.26% 的效率提升。为了进一步理解校正算法的优化细节,本文对比了应用校正算法前后的实时人员分布变化,如图 15 所示。通过对比图 15(a)和(b)可以发现,预测校正算法在异常数据条件下有效缓解了部分出口人员空置问题,从而提高了各出口的疏散利用率和整体疏散效率。



图 14 初始人员分布

Fig. 14 Initial personnel distribution map

表 2 校正前后疏散效率提升数值表

Table 2 Numerical improvement in evacuation efficiency before and after correction

异常位置	校正前/s	校正后/s	提升比例/%
出口 2	34.72	32.12	7.49
出口 3	31.80	25.84	18.74
出口 4	37.84	29.04	23.26

制策略的不良影响。同时,仿真和可控实验结果的定性分析和量化评估也进一步说明了校正算法的有效性和性能提升程度。

## 4 结 论

针对局部出口人员密度的异常观测信息会降低疏散控制效果的问题,本文提出了一种基于 EKF 的人员密度预测校正方法。本方法基于 EKF 的原理对疏散系统进行建模,并通过 BP 神经网络对模型中的状态函数和观测函数进行辨识,实现疏散人流密度的预测校正。同时,本文将提出的密度预测校正算法与密度控制算法相结合,实现了对异常疏散场景下人流的有效控制。仿真和可控对比实验结果显示,相较于没有进行异常数据校正的控制,本文算法最高可分别提高疏散效率 38.9% 和 23.26%,为解决异常疏散场景中的控制策略提供了有效的解决思路。在该方法的基础上,未来的研究工作可包括进一步优化算法性能将其应用于复杂多出口场景,并进行更全面的实际应用验证。

## 参考文献

[ 1 ] MENG Q, ZHOU M, LIU J, et al. Pedestrian evacuation with herding behavior in the view-limited condition [ J ]. IEEE Transactions on Computational Social Systems, 2019, 6(3): 567-575.

[ 2 ] DIND J X, HUANG H J. A cellular automaton model of public transport system considering control strategy [ J ]. Journal of Transportation Systems Engineering and Information Technology, 2010, 10(3): 35-41.

[ 3 ] CHEN C K, LU T, JIAO W B, et al. An extended model for crowd evacuation considering crowding and stampede damage under the internal crushing [ J ]. Physica A: Statistical Mechanics and its Applications, 2023, 625: 129002.

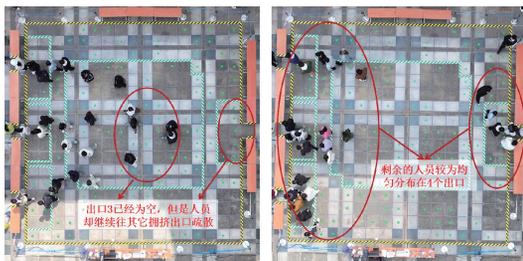
[ 4 ] LI N, GUO R Y. Human behavior during emergency evacuation: Cell transmission model [ J ]. IEEE Access, 2021, 9: 42463-42482.

[ 5 ] KODUR V, JHA A, LAJNEF N. Critical egress parameters governing assisted evacuation in hospital buildings [ J ]. Fire, 2024, 7 (3): 85.

[ 6 ] SHIN G R, TSAI P H. Safest-path planning approach for indoor fire evacuation [ J ]. International Journal of Disaster Risk Reduction, 2023, 93: 103760.

[ 7 ] 薛怡然, 吴锐, 刘家锋. 组合动作空间深度强化学习的人群疏散引导方法 [ J ]. 哈尔滨工业大学学报, 2021, 53(8): 29-38.

XUE Y R, WU R, LIU J F. Crowd evacuation guidance based on combined action-space deep reinforcement



(a) 校正前

(a) Before calibration

(b) 校正后

(b) After calibration

图 15 出口 3 故障校正前后的疏散人员实时分布情况

Fig. 15 Real-time distribution of evacuees before and after correction of malfunction at exit 3

综上所述,仿真和真人疏散可控的实验结果都表明本文提出的校正算法有效降低了异常密度数据对疏散控

- learning[J]. Journal of Harbin Institute of Technology, 2021, 53(8): 29-38.
- [ 8 ] LOPEZ-CARMONA M A, PARICIO A. Adaptive cell-based evacuation systems for leader-follower crowd evacuation [ J ]. Transportation Research Part C: Emerging Technologies, 2022, 140: 103699.
- [ 9 ] LOPEZ-CARMONA M A, PARICIO A. CelleVAC: An adaptive guidance system for crowd evacuation through behavioral optimization[J]. Safety Science, 2021, 139: 105215.
- [ 10 ] GORBIL G, GELENBE E. Resilient emergency evacuation using opportunistic communications [ J ]. In Computer and Information Sciences III, 2013: 249-257.
- [ 11 ] QIU M, MING Z, WANG J, et al. Enabling cloud computing in emergency management systems[J]. IEEE Cloud Computing, 2014, 1(4): 60-67.
- [ 12 ] REN H, YAN Y, GAO F Q. Variable guiding strategies in multi-exits evacuation: Pursuing balanced pedestrian densities [ J ]. Applied Mathematics and Computation, 2021, 397: 125965.
- [ 13 ] GAO F Q, YAN Y, CHEN Z, et al. Effect of density control in partially observable asymmetric-exit evacuation under guidance: Strategic suggestion under time delay[J]. Applied Mathematics and Computation, 2022, 418: 126838.
- [ 14 ] KUMAR K, PANDE B P. Air pollution prediction with machine learning: A case study of Indian cities [ J ]. International Journal of Environmental Science and Technology, 2023, 20(5): 5333-5348.
- [ 15 ] 俞子牛,刘跃跃,巫亦浩,等. 基于阻抗模型的不确定环境下微纳操作力跟踪控制策略研究[J]. 仪器仪表学报, 2023, 44(3): 191-199.
- YU Z N, LIU Y Y, WU Y H, et al. Research on control strategy of micro and nano operating force tracking in uncertain environment based on impedance mode [ J ]. Chinese Journal of Scientific Instrument, 2023, 44(3): 191-199.
- [ 16 ] PALLATHADKA H, WENDA A, RAMIREZ-ASÍS E, et al. Classification and prediction of student performance data using various machine learning algorithms [ J ]. Materials Today: Proceedings, 2023, 80: 3782-3785.
- [ 17 ] KAPP S, CHOI JK, HONG T. Predicting industrial building energy consumption with statistical and machine-learning models informed by physical system parameters[J]. Renewable and Sustainable Energy Reviews, 2023, 172: 113045.
- [ 18 ] KHODARAHMI M, MAIHAMI V. A review on Kalman filter models[J]. Archives of Computational Methods in Engineering, 2023, 30(1): 727-747.
- [ 19 ] NAYA M Á, SANJURJO E, RODRÍGUEZ A J, et al. Kalman filters based on multibody models: Linking simulation and real world. A comprehensive review[J]. Multibody System Dynamics, 2023, 58(3): 479-521.
- [ 20 ] HONG X, MITCHELL R J, CHEN S, et al. Model selection approaches for non-linear system identification: A review[J]. International Journal of Systems Science, 2008, 39(10): 925-946.
- [ 21 ] LIAO M, LIANG S, LUO R, et al. The moving load identification method on asphalt roads based on the BP neural network and FBG sensor monitoring [ J ]. Construction and Building Materials, 2023, 378: 131216.
- [ 22 ] YANG, X X, YANG X L, WANG Q L, et al. Guide optimization in pedestrian emergency evacuation [ J ]. Applied Mathematics and Computation, 2020, 365: 124711.

### 作者简介



高凤强, 2007 年于厦门大学获得学士学位, 2010 年于厦门大学获得硕士学位, 现为厦门大学博士研究生, 厦门大学嘉庚学院副教授, 主要研究方向为疏散仿真模型、疏散行人流管理和机器视觉等。

E-mail: fengqianggao@foxmail.com

**Gao Fengqiang** received his B.Sc. degree from Xiamen University in 2007, and M. Sc. degree from Xiamen University in 2010. He is currently a Ph. D. candidate at Xiamen University and an associate professor at Xiamen University Tan Kah Kee College. His main research interests include evacuation simulation models, pedestrian flow management during evacuations, and machine vision.



刘瞰东 (通信作者), 2003 年于中国科技大学获得博士学位, 现为厦门大学教授、博士生导师, 主要研究方向为工业机器人控制、机器视觉和疏散仿真系统等。

E-mail: ltd@xmu.edu.cn

**Liu Tundong** (Corresponding author) received his Ph. D. degree from University of Science and Technology of China in 2003. He is currently a professor and a Ph. D. advisor at Xiamen University. His main research interests include industrial robot control, machine vision and simulation of evacuation systems.