

中文引用格式:曹淑超,戈伟斌,李聪慧,等. 基于注意力 Seq2Seq 网络的人群安全风险评估[J]. 中国安全科学学报,2025,35(12): 196–203.

英文引用格式:CAO Shuchao, GE Weibin, LI Conghui, et al. Crowd safety risk assessment based on Seq2Seq-attention network[J]. China Safety Science Journal, 2025, 35(12): 196–203.

基于注意力 Seq2Seq 网络的人群安全风险评估*

曹淑超¹副教授, 戈伟斌¹, 李聪慧¹, 张俊²教授

(1 江苏大学 汽车与交通工程学院, 江苏 镇江 212013;

2 中国科学技术大学 火灾安全全国重点实验室, 安徽 合肥 230027)

中图分类号: X951

文献标志码: A

DOI: 10.16265/j.cnki.issn1003-3033.2025.12.1477

基金项目: 国家自然科学基金资助(72374087, 72001095)。

【摘要】 为探究不同方向人群交互的安全性, 提出一种基于序列到序列(Seq2Seq)网络结合注意力机制(AM)的行人安全风险评估方法。通过分析行人之间的相互作用, 引入局部密度补充模型特征输入, 从而准确刻画行人间的动态交互。将观测行人连续时间窗口序列的特征输入到基于长短期记忆网络(LSTM)的编-解码器, 并利用 AM 捕捉行人运动的多维度关键信息, 最终重现不同场景中人群复杂的运动过程。进一步通过引入人群压力指标量化行人安全风险, 计算得到 3 种典型行人运动状态下的压力值范围, 并对人群安全风险进行分级。结果表明: 在距离误差评估中, 单向流和相向流不同密度下的平均位移误差(ADE)和最终位移误差(FDE)均低于 0.3 m, 验证了该方法在行人轨迹预测中的准确性。基于相向流场景中的风险变化结果, 发现在高密度情形下, 当行人速度发生剧烈变化时, 发生事故的概率显著增加, 此时需要预警人群状态并采取措施以降低安全风险。

【关键词】 序列到序列(Seq2Seq); 人群安全; 风险评估; 轨迹预测; 注意力机制(AM); 人群压力

Crowd safety risk assessment based on Seq2Seq-attention network

CAO Shuchao¹, GE Weibin¹, LI Conghui¹, ZHANG Jun²

(1 School of Automotive and Traffic Engineering, Jiangsu University, Zhenjiang Jiangsu 212013, China;

2 State Key Laboratory of Fire Science, University of Science and Technology of China,
Heifei Anhui 230027, China)

Abstract: In order to explore the safety of interactions between pedestrian groups moving in different directions, a risk assessment method for pedestrian safety was proposed based on a Seq2Seq network integrated with an AM. By analyzing the interactions among pedestrians, local density was introduced as an additional input feature to better characterize dynamic interpersonal behaviors. The observed sequential features of pedestrians within a continuous time window were fed into an LSTM-based encoder-decoder architecture, and AM was employed to capture multidimensional critical information during motion, enabling the reconstruction of complex crowd movement patterns across various scenarios. Furthermore, pedestrian safety risks were quantified by introducing a crowd pressure metric, and the pressure value ranges corresponding to three typical movement states were calculated to enable risk stratification. The

results show that the average displacement error (ADE) and final displacement error (FDE) in trajectory prediction are less than 0.3 m under both unidirectional and bidirectional flow conditions at different densities, indicating the model's high accuracy in trajectory prediction. Based on the risk variation observed in bidirectional flow scenarios, it is found that the probability of accidents increases significantly when pedestrians' velocities change abruptly under high-density conditions. Therefore, timely warnings of crowd states and proactive intervention measures are required to mitigate potential safety risks.

Keywords: sequence to sequence (Seq2Seq); crowd safety; risk assessment; trajectory prediction; attention mechanism(AM); crowd pressure

0 引言

随着城市化水平的提高及人们出行频率的增加,公共场所如火车站、地铁站、体育场等经常出现大规模、高密度的人群集聚。如果此时缺乏有效的行人管理措施,未能及时准确地评估人群安全风险并预警,容易酿成惨重的安全事故。因此,为保障突发事件下人群安全,研究行人运动特性并建立安全风险评估机制变得至关重要^[1]。

目前,针对人群运动的研究方法主要分为 3 类:行人运动试验、基于物理的行人运动建模和基于数据驱动的行人运动预测模型。在行人运动试验研究中,ZHANG Jun 等^[2]采用泰森多边形定量分析了单向行人流,得到了不同密度下的行人流量。LIAN Liping 等^[3]开展了四向交叉行人运动试验,分析了交叉区域内不同方向行人的速度、密度及流量的变化。CAO Shuchao 等^[4]进一步提出适用于多向交叉流场景的速度和流量计算方法。在基于物理的行人运动建模研究中,按照运动规则的不同可划分为基于规则的模型^[5]、基于力的模型^[6]和基于速度的模型^[7],上述模型已被广泛应用于不同场景的行人疏散模拟研究。近年来,基于数据驱动的行人运动预测方法逐渐兴起,常见的方法包括长短期记忆网络(Long Short Term Memory, LSTM)^[8]、门控循环单元^[9]、对抗生成网络^[10]及序列到序列(Sequence to Sequence, Seq2Seq)网络等。LSTM 和门控循环单元在捕捉长时间序列依赖关系方面具有优势,适用于轨迹预测等长期序列任务。对抗生成网络通过生成器和判别器之间的对抗学习提高样本生成质量,多应用于高维场景和生成式任务。Seq2Seq 因其处理变长时序输入输出的能力,被广泛应用于处理序列数据。如 XUE Hao 等^[11]采用 Seq2Seq 方法,结合个人、社会和场景特征有效预测了行人轨迹。王瑞平等^[12]基于行人的姿态,通过卷积编码-解码网络结构预测行人轨迹。CUI Geng 等^[13]以滑动窗口迭代

的方式,通过将当前时刻的输出作为下一时刻的输入来构建轨迹预测模型。

人群运动试验与试验场景、成本和安全等因素相关,使得特定条件下的试验难以实施。而基于物理的行人运动建模虽然能从特定角度解释人群运动特征,但模型的仿真效果与设定的行人运动规则相关。同时,模型的参数验证通常基于某一特定场景的试验。相比之下,基于数据驱动的预测模型能从海量的数据中学习复杂的行人运动特征,减少试验场景和参数假设的依赖,弥补了试验和物理建模的不足。然而,目前大多数基于数据驱动的轨迹预测方法仍主要聚焦于行人的历史轨迹特征,忽略了行人在运动过程中相互间作用的影响。此外,仅依靠编码器提取运动特征难以覆盖所有关键信息,导致模型无法准确刻画个体间的交互机制,进而影响轨迹预测的准确性。

鉴于此,笔者拟综合考虑行人间的相互作用,引入高斯核函数构建局部密度特征,结合 Seq2Seq 网络和注意力机制(Attention Mechanism, AM)提出一种面向人群安全风险评估的轨迹预测模型。基于轨迹预测结果计算人群压力,确定不同行人流动状态下的压力范围及相应风险等级,以期实现对人群运动的实时风险评估与预警。

1 行人轨迹预测

行人轨迹预测可视为序列生成任务,对于不同场景中的 n 个行人 $i(i=1,2,\cdots,n)$,其时空状态可表征为离散时间点上的位置坐标序列。行人 i 在 t 时刻的位置坐标表示为 $p_i^t=(x_i^t, y_i^t)$,当给定行人 i 在观测时序 $T_o=[t_s, t_s+1,\cdots,t_e]$ 的位置坐标后,轨迹预测的任务目标是构建模型,预测行人在未来时段 $T_p=[t_e+1,t_e+2,\cdots,t_p]$ 内的轨迹坐标序列。其中, t_s 和 t_e 分别为观测时序窗口的起始时刻和终止时刻; t_e+1 和 t_p 为推理时序窗口的起始时刻和终止时刻。

1.1 Seq2Seq-AM 模型框架

Seq2Seq-AM 模型由编码器、AM 和解码器 3 部分组成,通过学习历史特征生成预测输出。其中,编码器用于提取输入序列信息并形成潜在表征,解码器将序列数据映射到变长的输出序列。AM 作为中




图1 Seq2Seq-AM 框架

Fig.1 Seq2Seq-AM framework

1.1.1 编码器

在编码器阶段,观测时刻 $t(t=t_s, t_s+1, \dots, t_e)$ 的输入序列 $\mathbf{x}_m(m=t_s, t_s+1, \dots, t_e)$ 经 LSTM 单元处理后生成对应的隐藏状态 $\mathbf{h}_m(m=t_s, t_s+1, \dots, t_e)$ 。隐藏状态序列 $\mathbf{H}=(\mathbf{h}_s, \mathbf{h}_{s+1}, \dots, \mathbf{h}_e)$ 表示输入序列在编码器阶段的特征表示,最后一个时刻的隐藏状态 $\mathbf{h}_e$ 包含输入特征序列的上下文信息,作为解码器的初始隐藏状态 $\mathbf{S}_0$ 。

1.1.2 AM

在解码过程中,对于每个时刻 t (从 t_e+1 到 t_p),AM 先计算编码器的隐藏状态 $\mathbf{h}_m(m=t_s, t_s+1, \dots, t_e)$ 与当前时刻 t 解码器的隐藏状态 $\mathbf{S}_{t-1}$ 之间的相关性得分 $\tilde{a}_{m,t}$,该过程如图 2 所示。随后,利用 Softmax 函数对其进行归一化,得到注意力权重 $\alpha_{m,t}$ 。最后,将注意力权重 $\alpha_{m,t}$ 与对应的隐藏状态 $\mathbf{h}_m$ 相乘并加权求和,生成动态语义向量 $\mathbf{C}_t$,并将其作为解码器的输入,以便其能够更加关注重要时刻信息,提高轨迹预测的准确性。相关性得分 $\tilde{a}_{m,t}$ 、注意力权重 $\alpha_{m,t}$ 、上下文向量 $\mathbf{C}_t$ 的计算如下式:

$$\tilde{a}_{m,t} = \mathbf{V}^T \cdot \tanh(w_h \mathbf{h}_m + w_s \mathbf{S}_{t-1}) \quad (1)$$

式中: $\mathbf{V}$ 为可训练向量; $\tanh$ 为激活函数,取值范围为 $(-1, 1)$ 。

$$\alpha_{m,t} = \frac{\exp(\tilde{a}_{m,t})}{\sum_{m=t_s}^{t_e} \exp(\tilde{a}_{m,t})} \quad (2)$$

$$\mathbf{C}_t = \sum_{m=t_s}^{t_e} \alpha_{m,t} \mathbf{h}_m \quad (3)$$

间衔接模块,计算编码器输出的隐藏状态和解码器当前状态之间的相关性,加权处理重要时刻的输入,使解码器可动态关注不同时刻的关键特征,避免仅依赖隐藏状态可能带来的信息丢失,模型的整体框架如图 1 所示。




图2 相关性得分工作机制

Fig.2 Mechanism of correlation score

1.1.3 解码器

在解码器阶段,解码器会依据编码器提供的上下文信息,结合 AM 逐步生成预测输出。具体而言,对于每个时刻 $t(t=t_e+1, t_e+2, \dots, t_p)$,解码器的输入是由前一时刻的预测输出 y_{t-1} 、隐藏状态 $\mathbf{S}_{t-1}$ 以及动态语义向量 $\mathbf{C}_{t-1}$ 共同构成。AM 通过计算当前时刻 t 的动态语义向量 $\mathbf{C}_t$,并将其和隐藏状态 $\mathbf{S}_t$ 拼接后输入至全连接层(Fully Connected, FC),经非线性激活函数处理后,生成当前时刻 t 的预测输出 y_t 。这一过程重复进行,直至生成完整的输出序列 $[y_1, y_2, \dots, y_t]$ 。隐藏状态 $\mathbf{S}_t$ 和预测输出 y_t 的计算如下式:

$$\mathbf{S}_t = \tanh \left(L \cdot \begin{bmatrix} \mathbf{y}_{t-1} \\ \mathbf{S}_{t-1} \\ \mathbf{C}_{t-1} \end{bmatrix} + \mathbf{b}_s \right) \quad (4)$$

$$\mathbf{y}_t = w_{FC} \cdot \text{cat}(\mathbf{C}_t, \mathbf{S}_t) + \mathbf{b}_{FC} \quad (5)$$

式中: $w_h, w_s, w_{FC}, \mathbf{b}_s, \mathbf{b}_{FC}$ 分别为可训练的权值和偏移量; L 为 LSTM 单元; $\text{cat}(\cdot)$ 为向量拼接操作。

1.2 行人运动特征

基于上述模型框架,结合行人的多维运动特性,构建个体尺度特征和集体尺度特征以刻画行人运动状态。

1.2.1 个体尺度特征

行人的运动决策受速度大小和方向影响,准确描述其运动状态是轨迹预测的关键。为此,分解速度向量,提取水平速度分量 v_x 和垂直速度分量 v_y 作为个体尺度特征,用以描述行人的瞬时运动状态。计算式如下:

$$v_{xi}^t = \frac{x_i^{t+5} - x_i^{t-5}}{\Delta t} \quad (6)$$

$$v_{yi}^t = \frac{y_i^{t+5} - y_i^{t-5}}{\Delta t} \quad (7)$$

式中: $t+5$ 和 $t-5$ 分别为当前时刻 t 向后和向前推移 5 帧,用于平滑速度估计,降低瞬时波动带来的影响; Δt 为时间间隔,文中取 0.4 s; x_i^t 和 y_i^t 分别为行人 i 在 t 时刻的横纵坐标位置。

1.2.2 集体尺度特征

现实中行人会与周围行人及环境产生交互,为量化表征这种交互关系,将研究场景离散划分为 $m \times n$ 的网格单元,每个网格单元大小为 0.5 m×0.5 m。基于社会互动影响范围的相关研究^[8],选择以目标行人中心,5×5 网格区域作为其局部作用域。集体尺度特征包括 2 个特征要素:5×5 占用矩阵和高斯核函数计算出目标行人所在占用单元的局部密度。

占用矩阵用于判别目标行人所处的局部环境以及近邻行人的位置。如图 3 所示, t 时刻以目标行人 i 所在的占用单元 (a, b) 为中心,构建 5×5 占用矩阵,判别函数用于判断行人 j 是否处于该占用矩阵范围内。如果行人位于该范围内,矩阵对应的索引单元记为 1,否则记为 0。




图 3 占用矩阵

Fig. 3 Occupancy matrix

此外,引入基于高斯核函数的密度特征克服二维占用矩阵在内部交互强度表征上的不足,通过距离衰减权重函数,刻画行人间的交互强度分布,高斯核函数 f 的计算式如下:

$$f(\mathbf{p}_j^t - \mathbf{p}_i^t) = \frac{1}{\pi R^2} \exp[-\|\mathbf{p}_j^t - \mathbf{p}_i^t\|^2 / R^2] \quad (8)$$

基于构建的高斯核函数 f ,目标行人 i 所在的占用单元 (a, b) 的局部密度 ρ_i^t 的计算式为

$$\rho_i^t(a, b) = \sum_j^N f(\mathbf{p}_j^t - \mathbf{p}_i^t) \quad (9)$$

式中: R 为有效测量半径, $R = 1.77$ m; $\mathbf{p}_j^t$ 和 $\mathbf{p}_i^t$ 分别为 t 时刻行人 j 和行人 i 的位置; N 为局部作用域内的行人数量。

1.3 轨迹预测模型训练

将试验数据划分为训练集、验证集和测试集(比例为 6 : 2 : 2)。输入特征进行归一化处理,标签采用原始特征数据。损失函数采用均方误差(Mean Squared Error, MSE),优化器使用 Adam 优化模型参数。基于 PyTorch2.0 训练框架,利用验证集进行超参数寻优,并使用测试集进行性能评估。最终当批量大小为 32,隐藏层维度为 128,学习率为 0.001,迭代 50 轮时,模型达到最佳效果。

1.4 轨迹预测模型推理

当模型训练完成后,进行时序推理。推理过程采用滑动窗口重构样本方法,将时间序列划分为等间隔长度的连续窗口片段,在每一时刻,模型基于特征变量构建输入,逐步迭代完成下一时刻的预测,具体操作如下:

首先,模型对个体尺度与集体尺度的 3 个特征进行编码,根据下式将它们首尾拼接成潜在表征 $\mathbf{H}_i^t$ 。最后一个时刻的潜在表征作为初始输入 $\mathbf{S}_0$ 传递给解码器。

$$\mathbf{H}_i^t = \text{cat}[\text{Enc}_v(v_{xi}^t, v_{yi}^t, \mathbf{h}v_i^{t-1}), \text{Enc}_M(\mathbf{M}_i^t, \mathbf{h}m_i^{t-1}), \text{Enc}_\rho(\rho_i^t, \mathbf{h}\rho_i^{t-1})] \quad (10)$$

式中: $\mathbf{h}v_i^{t-1}$ 、 $\mathbf{h}m_i^{t-1}$ 、 $\mathbf{h}\rho_i^{t-1}$ 分别为 LSTM 编码器对 3 个输入特征的抽象表达; $\text{Enc}(\cdot)$ 和 $\text{Dec}(\cdot)$ 为编码和解码阶段的 LSTM 单元; $\mathbf{M}_i^t$ 为 t 时刻行人 i 局部作用域的占用矩阵。

其次,通过 LSTM 网络进行时序推理。AM 在此过程中作为中间层,结合编码器隐藏状态 $\mathbf{h}_m$ 和解码器当前状态 $\mathbf{S}_{t-1}$ (前一时刻的隐藏状态),计算注意力权重 $\alpha_{m,t}$,并生成当前时刻的动态语义向量 $\mathbf{C}_t$ 。

再次,根据下式计算当前时刻 t 解码器的隐藏状态 $\mathbf{S}_t$ 。将动态语义向量 $\mathbf{C}_t$ 与隐藏状态 $\mathbf{S}_t$ 拼接后,经过 FC 调整输出维度,映射到输出空间,生成 t_e+1 时刻的输出 $\mathbf{y}_i^t = (v_{xi}^t, v_{yi}^t, \rho_i^t)$ 。

$$v_{xi}^t, v_{yi}^t, \rho_i^t = \text{Dec}(\mathbf{C}_i^{t-1}, \mathbf{S}_i^{t-1}, \mathbf{y}_i^{t-1}) \quad (11)$$

最后,根据下式计算行人的位置,更新 t_e+1 时刻的位置和邻接占用矩阵,将其作为滑动窗口最后一个时刻的输入,继续迭代,直至推理完成。图 4 为模型时序推理的全过程。




图4 时序推理过程

Fig. 4 Timing inference process

$$x_i^t = x_i^{t-1} + 0.04 \cdot v_{x_i}^t \quad (12)$$

$$y_i^t = y_i^{t-1} + 0.04 \cdot v_{y_i}^t \quad (13)$$

2 轨迹预测结果分析

基于前期试验数据^[1],在单向流和相向流试验场景中评估模型预测的准确性。为衡量模型的轨迹预测精度,选取平均位移误差(Average Displacement Error, ADE)和最终位移误差(Final Displacement Error, FDE)作为评估指标。ADE用于衡量预测轨迹与真实轨迹之间的平均距离误差, FDE用于衡量预测轨迹终点与真实轨迹终点之间的距离误差,其计算如下:

$$ADE = \frac{1}{KT_p} \sum_{i=1}^K \sum_{t=1}^{T_p} \|\hat{p}_i^t - p_i^t\| \quad (14)$$

$$FDE = \frac{1}{K} \sum_{i=1}^K \|\hat{p}_i^{T_p} - p_i^{T_p}\| \quad (15)$$

式中: $\hat{p}_i^t$ 和 p_i^t 为 i 行人在 t 时刻的预测位置和实际位置; K 为轨迹预测的行人总数; $\|\cdot\|$ 为欧几里得距离。在模型预测中,设置观测时序 T_o 长度为25帧,推理时序长度 T_p 为8帧。试验场景被划分为低密度、中密度和高密度3个层级,并通过随机抽样选取不同密度的场景进行预测,以评估所建模型在不同密度场景下行人轨迹预测精度。

图5为不同场景中的预测误差,发现在单向流场景中, ADE和FDE没有随着密度的增加发生显著变化。原因在于单向流中行人的期望方向相同,个体间相互干扰较少,行人运动轨迹不会出现大幅摆

动,这使得在不同密度条件下的预测误差无显著差异。此外,相同密度条件下的FDE始终高于ADE。这是由时序误差累积所致, FDE衡量预测轨迹终点与真实轨迹终点之间的误差,而ADE衡量整个预测过程中每个时刻的平均误差,由于FDE反映的是最终误差,因此,其值通常高于ADE。在相向流场景中,随着密度的增加, ADE和FDE逐渐减小。原因在于相向流中行人为了避免与对向行人发生冲突,需要频繁调整自身行进方向和速度。在低密度条件下行人运动的自由度较高,轨迹变化较大,因此,预测误差较大。然而,随着密度的增加,行人运动的自由度逐渐降低,且可能会形成分层现象,使得轨迹更为有序,预测误差降低。

综上所述,模型在不同场景和不同密度条件下的ADE和FDE均低于0.3 m。这表明模型能够有效捕捉人群的运动特征,轨迹预测精度较高。

3 人群安全风险评估

3.1 人群压力

为量化人群集聚状态及潜在安全风险,采用人群压力指标^[2],即局部作用域内行人平均密度与速度方差的乘积,计算公式如下:

$$u_i(a, b) = \frac{1}{NT} \sum_{n=1}^N \sum_{t=1}^T v_n^t \quad (16)$$

$$\text{var}v_i^t(a, b) = (v_i^t - u_i(a, b))^2 \quad (17)$$

$$P_i^t(a, b) = \text{var}v_i^t(a, b) \cdot \rho_i^t(a, b) \quad (18)$$

式中: $u_i(a, b)$ 为单元 (a, b) 的速度均值, m/s; T 为




图 5 不同场景中的预测误差

Fig. 5 Prediction error under different scenarios

行人在该单元内的停留时间, s ; $\text{var}v'_i(a,b)$ 为 t 时刻该单元的速度方差, m^2/s^2 ; $P'_i(a,b)$ 为 t 时刻行人 i 所处单元位置的人群压力, s^{-2} 。

图 6 展示了相向流中不同密度场景下的人群压力分布。在低密度场景中,通道左侧形成局部压力热点,但压力值并未超过 0.02 s^{-2} 。在中密度场景中,压力热点几乎遍布整个通道,且多个热点的压力值超过 0.02 s^{-2} 。而在高密度场景中,压力热点分布较为均匀,超过 0.02 s^{-2} 的热点数量反而减少。

值得注意的是,压力值及其热点数量并不随密度单调或线性增长。这是因为压力指标是由局部作用域内行人的平均密度与速度方差的乘积计算得到。因此,速度变化较大的区域即使密度不高,压力值仍可能会显著升高。在低密度场景中,个体为避让对向行人,运动速度和方向发生变化,通道左侧局部压力有所上升。但由于人群整体密度较低,速度波动幅度有限,热点压力峰值相对较小。在中密度场景中,由于行人流尚未完全分层,路径冲突频繁,个体运动




图 6 相向流中不同密度下的人群压力分布(左侧为试验结果,右侧为模型预测结果)

Fig. 6 Crowd pressure distribution at different densities in the counter flow(the left and right figures represent the experimental results and model prediction results respectively)

严重受阻,致使压力热点分布密集,出现了多个高压
力热点。相比之下,在高密度场景中,尽管整体人群
密度更大,但由于分层现象显著,行人速度变化幅度
减小,使得压力热点在通道中分布较均匀,高压
力热点数量有所减少。综上表明:人群压力及其热点分
布并非由密度单一因素驱动,受局部密度、速度波动
及社会互动等多种因素共同影响。此外,模型预测
的人群压力变化趋势与实际情况高度一致,进一步
验证了模型的有效性。

3.2 风险分级与预警

在行人运动过程中,常见的典型运动状态可分
为层流(稳态)、走停和湍流3种^[2]。如图7所示,
在层流状态下,行人运动速度较快且轨迹平滑,个
体间干扰较小;而在走停状态下,行人表现为走走
停停的间歇性运动,并以波的形式反向传播;当人
群密度进一步升高,行人流进入湍流状态,个体的
自主运动被集体流动趋势所主导,运动的速度和方
向不再稳定,局部区域甚至可能出现突然停滞或倒
退现象。此时,频繁的个体相互作用使人群呈现出
高度不稳定的动力学特征,事故发生风险显著增加。

因此,需要对行人聚集运动的安全风险进行分
级并预警。基于上述人群压力指标,计算得到不同
运动状态下行人流压力范围如下:层流($0 \sim 0.006 \text{ s}^{-2}$)、
走停($0.006 \sim 0.02 \text{ s}^{-2}$)和湍流($\geq 0.02 \text{ s}^{-2}$)。进
一步将人群的湍流状态作为高风险边界,层流和走
停状态分别划分为低风险和中风险。当人群压力超
过湍流临界阈值 0.02 s^{-2} 时,发生踩踏事故的
风险极高。




图7 不同行人流状态的时空轨迹

Fig. 7 Spatiotemporal trajectories of different pedestrian flow states

基于上述风险分级结果,以相向流场景中位置坐
标点(0, 1.5)为例,分析中密度与高密度条件下的人
群风险变化过程。如图8所示,发现在中密度条件
下,该位置的人群压力波动较大,时序过程中多次处
于高风险等级。这是因为此时人群尚未形成稳定的
流动结构,个体需要频繁调整速度以避让对向行人。
而在高密度条件下,尽管人群密度更高,但压力波
动幅度有所减小,且大部分时间处于较低水平。然
而,这一现象并不意味着风险降低,而是因为此时个
体移动自由度下降,速度趋于一致,波动减小,从而
使得基于局部密度与速度方差构建的压力指标呈
现出较低数值。事实上,随着密度进一步升高,个
体更容易陷入推挤、停滞或失稳状态,潜在的事故
风险反而增加。





图8 不同密度场景下的风险变化

Fig. 8 Risk variation in different density scenarios

4 结 论

1) 基于 Seq2Seq 与 AM 方法,通过引入速度分

量、高斯核局部密度和占用矩阵的特征输入,有效刻
画行人与其周围环境之间的动态交互关系。在多场
景不同密度条件下的距离误差评估中,ADE 和 FDE

均低于 0.3 m,验证了该方法的准确性。

2) 在行人流风险评估中,基于人群压力指标,确定 3 种典型行人运动状态下的人群压力范围,并据此将人群安全风险划分为低风险、中风险和高风险 3 个等级。

3) 基于风险等级划分,发现在中、高密度的相向流中,当行人速度发生剧烈变化时,人群发生事故风险显著升高,此时需要采取干预措施以降低群集安全风险。

参 考 文 献

[1] WANG Peng, CAO Shuchao, YAO Ming. Fundamental diagrams for pedestrian traffic flow in controlled experiments[J]. Physica A: Statistical Mechanics and its Applications, 2019,525:266–277.

[2] ZHANG Jun, KLINGSCH W, SCHADSCHNEIDER A, et al. Transitions in pedestrian fundamental diagrams of straight corridors and T-junctions[J]. Journal of Statistical Mechanics: Theory and Experiment, 2011,2011(6):DOI:10.1088/1742–5468/2011/06/P06004.

[3] LIAN Liping, MAI Xu, SONG Weiguo, et al. An experimental study on four-directional intersecting pedestrian flows[J]. Journal of Statistical Mechanics: Theory and Experiment, 2015,2015(8):DOI:10.1088/1742–5468/2015/08/P08024.

[4] CAO Shuchao, SEYFRIED A, ZHANG Jun, et al. Fundamental diagrams for multidirectional pedestrian flows[J]. Journal of Statistical Mechanics: Theory and Experiment, 2017,2017(3):DOI:10.1088/1742–5468/aa620d.

[5] 霍非舟, 范丹丹, 刘昶, 等. 考虑结伴行为与情绪感染的人员疏散模型[J]. 中国安全科学学报, 2023,33(11):126–132.

HUO Feizhou, FAN Dandan, LIU Chang, et al. Study on evacuation model considering companion behavior and emotion contagion [J]. China Safety Science Journal, 2023,33(11):126–132.

[6] 邓社军, 虞宇浩, 张俊林, 等. 基于行人恐慌情绪解析的改进社会力模型[J]. 中国安全科学学报, 2024,34(2):45–52.

DENG Shejun, YU Yuhao, ZHANG Junlin, et al. Cellular automata model for emergency evacuation considering panic factor[J]. China Safety Science Journal, 2024,34(2):45–52.

[7] XU Qiancheng, CHRAIBI M, TORDEUX A, et al. Generalized collision-free velocity model for pedestrian dynamics [J]. Physica A: Statistical Mechanics and its Applications, 2019,535:DOI:10.1016/j.physa.2019.122521.

[8] SONG Xiao, CHEN Kai, LI Xu, et al. Pedestrian trajectory prediction based on deep convolutional LSTM network[J]. IEEE Transactions on Intelligent Transportation Systems, 2020,22(6):3285–3302.

[9] YANG Xin, FAN Jiangfeng, XING Siyuan. IST-PTEPN: an improved pedestrian trajectory and endpoint prediction network based on spatio-temporal information[J]. International Journal of Machine Learning and Cybernetics, 2023,14(12):4193–4206.

[10] EIFFERT S, LI Kunming, SHAN Mao, et al. Probabilistic crowd GAN: multimodal pedestrian trajectory prediction using a graph vehicle-pedestrian attention network[J]. IEEE Robotics and Automation Letters, 2020,5(4):5026–5033.

[11] XUE Hao, HUYNH D Q, REYNOLDS M. SS-LSTM: a hierarchical LSTM model for pedestrian trajectory prediction[C]. 2018 IEEE Winter Conference on Applications of Computer Vision (WACV), 2018: 1186–1194.

[12] 王瑞平, 宋晓, 陈凯, 等. 基于行人姿态的轨迹预测方法[J]. 北京航空航天大学学报, 2023,49(7):1743–1754.

WANG Ruiping, SONG Xiao, CHEN Kai, et al. A trajectory prediction method based on pedestrian attitude[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023,49(7):1743–1754.

[13] CUI Geng, YANAGISAWA D, NISHINARI K. Learning from experimental data to simulate pedestrian dynamics[J]. Physica A: Statistical Mechanics and its Applications, 2023,623:DOI:10.1016/j.physa.2023.128837.



作者简介：曹淑超（1989—），男，山东莱芜人，博士，副教授，主要从事人群应急疏散与行人交通流等方面的研究。E-mail: sccao@ujs.edu。