

融合 GRU 和改进蚁群算法的火灾逃生路径规划方法

赵 峰¹ 姜孝文¹
ZHAO Feng JIANG Xiaowen

摘 要

高温环境下,传感器节点可能会出现工作状态异常的情况,由此引发误报、漏报等一系列问题,文章提出了融合门控循环单元神经网络(gated recurrent unit, GRU)和改进蚁群算法的室内建筑火灾逃生路径规划研究方法。根据火灾态势信息,建立 GRU 时序预测模型,实现对节点异常情况下火场内温度、CO 浓度等态势信息的预测,并基于预测结果,利用改进的蚁群算法动态规划逃生路径,得到传感器工作异常情况下的火灾最佳安全逃生路径。研究表明,该方法在不同火灾时期都能有效规划出最佳疏散路径,具有实际应用价值。

关键词

GRU 神经网络模型;火灾疏散路径动态规划;蚁群算法

doi: 10.3969/j.issn.1672-9528.2025.01.015

0 引言

室内火灾作为一类极具危害性的灾害事件,往往会引发极为严重的人员伤亡以及造成巨额的财物损毁。为尽可能降低室内火灾所带来的惨痛损失,全方位、强有力的火灾预防举措以及科学高效的灭火应对手段便显得至关重要。

国内外研究人员在火灾逃生路径规划方面取得了显著的研究进展。周敬东等人^[1]通过引入蚂蚁优化排序等方法对蚁群算法进行改进,实现移动机器人路径优化,但只能对初始信息素进行调整,并不能动态调节信息素挥发因子。霍非舟等人^[2]通过建立角栅格环境模型与信息素衰减系数改进蚁群算法,解决人员疏散问题,但仅考虑了拥堵情况下的人员疏散。Gao 等人^[3]在早期迭代中利用改进的人工势场法对蚁群进行引导,实现船舶的实时避障,但地图环境简单且并非最佳路径。郑馨怡^[4]以逃生最短时间为主要目标,以温度、一氧化碳浓度、能见度为主要因素,构建基于蚁群算法的人员逃生路径模型。Wang 等人^[5]提出了基于建筑信息模型(building information modeling, BIM)的实时动态逃生路径预测分析方法,利用火灾动态模拟器模拟火势蔓延,分析 BIM 模型的模拟数据利用 Dijkstra 算法规划最短逃生路径,并根据自由传播数据动态修正逃生路径,输出最优单人逃生路径。Peng 等人^[6]过疏散分析模型,自动生成路径规划算法与评估过程,构建可自学习迭代的初级策略神经网络模型,同时嵌入了动态算法来模拟建筑中所有人员之间的相互影响。在火灾逃生路径的动态规划研究中,关键点包括对火灾情境下路径规划的动态调整以及影响因素的综合考虑。然而,

这些研究往往未充分考虑高温环境对传感器的影响,尤其是在高温下可能出现的传感器工作异常,如误报和漏报。传感器故障可能导致错误的逃生路径规划,从而影响人群的安全疏散,增加火灾中的安全风险。因此,在动态规划和技术应用中,解决传感器在极端条件下的可靠性问题是提高逃生路径安全性的重要方面。

为此,本文提出了融合门控循环单元神经网络(gated recurrent unit, GRU)和改进蚁群算法的室内建筑火灾疏散路径规划研究方法。建立 GRU 网络预测模型,利用火灾态势信息进行训练,实现对火场内温度、CO 浓度的实时预测;将预测信息与改进的蚁群算法结合,实现最佳疏散路径的动态规划。

1 基于 GRU 的异常节点数据预测模型

高温环境常导致传感器故障,影响逃生路径的动态规划。循环神经网络(RNN)因其优良的时序数据处理能力,广泛应用于火场实时信息预测。门控循环单元(GRU)作为 LSTM 的变种,简化了门控机制,提升了计算效率,并有效处理复杂时间序列数据^[7]。因此,GRU 比 LSTM 在小数据集上表现更好,能够缓解长序列训练中的梯度爆炸或消失问题。因此,本文选择 GRU 模型以提高逃生路径规划的准确性。

1.1 GRU 循环神经网络

门控循环单元(GRU)是循环神经网络(RNN)的变体,GRU 简化了 LSTM 中门的设计,只有更新门和重置门 2 种门控制机制,同时使用 1 个状态变量代替 LSTM 中的细胞状态和隐藏状态^[8]。

GRU 的基本原理是在每个时间步上维护 1 个隐藏状态向

1. 安徽工业大学管理科学与工程学院 安徽马鞍山 243032

量,用于捕捉序列中的信息。GRU 网络的隐藏状态 h_t 在每个时间步更新,通过当前时间步的输入 x_t 、上一时间步的隐藏状态 h_{t-1} 以及门控机制计算得到。GRU 引入了更新门 z_t 和重置门 r_t ,通过 2 个门控制机制平衡保留历史信息 and 引入新信息。最后,每个时间步由对应的 GRU 单元输出。图 1 为 GRU 结构示意图。GRU 门控结构相对 LSTM 更加简单,使得其参数数量相应减少,在资源受限的情况下往往更容易训练。




图 1 GRU 网络模型结构

GRU 的隐藏状态在每个时间步更新过程为:

$$h_t = (1 - z_t) \cdot h_{t-1} + z_t \cdot \tilde{h}_t \quad (1)$$

式中: z_t 表示更新门; $\tilde{h}_t$ 表示候选隐藏状态,它是当前时间步输入 x_t 和前一隐藏状态 h_{t-1} 的函数。

门控机制为:

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t]) \quad (2)$$

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t]) \quad (3)$$

$$\tilde{h}_t = \tanh(W_h \cdot [r_t h_{t-1}, x_t]) \quad (4)$$

式中: r_t 表示重置门; σ 表示 sigmoid 激活函数; $\tanh$ 表示双曲正切激活函数。

GRU 神经训练过程基于反向传播,同其他神经网络类似,具体步骤为: (1) 对 GRU 的权重参数进行随机初始化,将输入序列通过 GRU 网络进行前向传播,计算各个隐藏状态和输出值; (2) 将前向传播得到的输出值与真实值进行比较,计算损失函数; (3) 进行反向传播,通过求导链式法则,计算损失函数对所有参数的梯度; (4) 使用优化算法,根据计算得到的梯度更新权重,重复迭代,直至最大迭代次数或损失函数收敛。

1.2 GRU 模型结构的确定

实验选用中国标准实验火的温度和 CO 浓度数据作为数据集,共 200 组数据,本研究模型选择 160 组数据作为训练集,40 组数据作为验证集。基于 GRU 模型,共使用 2 层 GRU 结构。为了防止过拟合,使用比例为 0.2 的 Dropout,选择自适应矩估计优化算法 (Adam)。为了准确评估模型的效能和预测准确性,选择 RMSE (均方根误差) 和 MAE (平均绝对误差) 两个量化指标来进行评价。

在研究模型的预测性能时,需要探索不同参数设置对模

型表现的影响。时间步长被设置为 10、15 和 20,以评估不同时间序列长度对预测精度的影响。同时,隐含层节点数被设置为 100、125 和 150,以探讨不同网络复杂度对模型性能的作用。

优化目标是选择使得均方根误差 (RMSE) 与平均绝对误差 (MAE) 之和最小的 GRU 网络结构参数。通过对这些参数组合进行测试,可以找到在给定的评估指标下表现最佳的 GRU 模型配置,从而提升预测性能和模型准确性。不同网络结构参数下的 GRU 模型的评价结果如表 1、2 所示。

表 1 GRU 不同网络参数下的 RMSE

单位: $^{\circ}\text{C}$

时间步长	隐含层节点数		
	100	125	150
10	1.645 7	1.645 7	1.645 7
15	1.854 6	1.854 6	1.854 6
20	1.990 6	1.990 6	1.990 6

表 2 GRU 不同网络参数下的 MAE

单位: $^{\circ}\text{C}$

时间步长	隐含层节点数		
	100	125	150
10	2.431 8	2.431 8	2.431 8
15	2.608 3	2.608 3	2.608 3
20	2.665 8	2.665 8	2.665 8

通过分析表 1 和表 2 数据发现最佳参数设置为时间步长为 15 和隐含层节点数为 100。在这种配置下,模型的性能表现为均方根误差 (RMSE) 为 2.327 9,平均绝对误差 (MAE) 为 1.674 4。因此,最终将 GRU 网络的时间步长设置为 15,隐含层节点数设置为 100,以实现最佳预测性能。

1.3 GRU 网络预测模型性能测试

在数据预处理中,使用了 Min-Max 归一化方法来处理原始数据。数据集被划分为 160 组训练集和 40 组测试集。GRU 网络的输入包括温度 (T) 和一氧化碳 (CO) 浓度。模型结构为 3 层隐含层,每层有 125 个神经元,时间步长设为 10。性能测试通过对比预测结果与实际数据,评估了 GRU 网络预测模型的效果。如图 2 所示,GRU 神经网络模型在时间序列上对温度和 CO 浓度两个指标的预测偏差较小,真实值与预测值曲线拟合度较高,走势基本一致。因此该网络模型能满足本文需求。




图 2 温度、CO 的预测值与真实值对比

2 基于改进蚁群算法的火灾疏散路径动态规划

蚁群算法 (ant colony optimization, ACO) 是意大利学者 Dorigo 等人^[9]在 1991 年提出, 通过模拟蚂蚁群体觅食行为的启发式优化搜索算法^[9]。

在火灾疏散背景下, 路径优化需要超越传统的几何距离最短路线算法, 考虑更多实际因素。传统算法的局限性在于它只关注距离, 而忽略了火灾对路径的影响。因此, 需要综合考虑火势参数, 如温度、CO 浓度和烟气能见度, 这些因素直接影响疏散路径的安全性。同时, 道路参数, 包括几何距离, 也需纳入考虑。通过改进启发函数, 将火势参数与道路参数结合进行路径优化, 可以在确保路径尽可能短的同时, 最大程度保障安全。最终目标是在火灾条件下提供既高效又安全的疏散路线。火势参数的计算公式为:

$$F_{ij} = f_{ij}(t) \times g_{ij}(\rho) \times h_{ij}(v) \quad (5)$$

式中: F_{ij} 为火势参数; $f_{ij}(t)$ 为温度; $g_{ij}(\rho)$ 为 CO 浓度; $h_{ij}(v)$ 为烟气能见度。

根据人体对温度的耐受能力, 对建筑内收集到的数据进行分段处理。当温度小于 40 °C 时, 人体还能忍受, 此时对人员的撤离没有影响; 当温度在 40~60 °C 时, 人员可暂时忍受高温带来的不适; 当温度大于 60 °C, 此时高温会对人体产生威胁, 无法自主逃生, 建议原地等待救援。

基于上述分析, 设定以下火势参数的分段函数描述。

$$F_{ij}(t) = \begin{cases} 1.0, & t < 40 \text{ }^{\circ}\text{C} \\ 6.0, & 40 \text{ }^{\circ}\text{C} \leq t \leq 60 \text{ }^{\circ}\text{C} \\ \infty, & t > 60 \text{ }^{\circ}\text{C} \end{cases} \quad (6)$$

除疏散路径中高温的威胁, CO 的浓度也严重限制了疏散者选择逃生路线的自由度。在此, 设定 5×10^{-4} 为 CO 的危险浓度阈值, 一旦环境中 CO 的浓度突破这一界限, 将该值视为极端危险, 并据此排除该通道作为逃生路径的考虑。关于 CO 浓度的具体参数设定为:

$$g_{ij}(\rho) = \begin{cases} 1, & c < 5 \times 10^{-4} \\ \infty, & c \geq 5 \times 10^{-4} \end{cases} \quad (7)$$

火场烟雾的特性, 主要包括其惊人的蔓延速度、高浓度的烟雾以及极差的能见度。在这样的环境中, 盲目选择视线不佳的逃生路线, 极易引发方向迷失, 甚至可能误入火源区域。依据本文对环境模型与室内空间特性的深入剖析, 我们设定了以下能见度判断标准: 若通道内的能见度大于 10 m, 则视为该路径相对安全, 适宜通行; 若能见度介于 5~10 m 米之间, 则表明该路径虽可勉强选择, 但需格外小心; 而一旦能见度低于 5 m, 则意味着该路径危险系数极高, 应尽量避免。基于上述分析, 制定了以下关于烟气能见度的参数设置:

$$h_{ij}(v) = \begin{cases} 1.0, & v > 10 \text{ m} \\ 6.0, & 5 \text{ m} \leq v \leq 10 \text{ m} \\ \infty, & v < 5 \text{ m} \end{cases} \quad (8)$$

道路参数 R_{ij} 的计算公式为:

$$R_{ij} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (9)$$

式中: 道路参数指的是从当前节点 i 到下一节点 j 的几何距离。

新的启发函数定义为:

$$\eta_{ij} = \frac{1}{F_{ij} + R_{ij}} \quad (10)$$

在改进蚁群算法时, 信息素挥发因子具有重要影响, 设置过小会导致算法陷入局部最优, 而设置过大会降低搜索效率。动态调整信息素挥发因子是一种有效策略: 若最优路径随着迭代次数的增加仍没变化, 则可以尝试将挥发因子降低, 此时可强化全局搜索能力, 优化路径探索, 并提高搜索效率。

$$\rho = \omega \rho \quad (11)$$

在楼层火灾疏散的蚁群算法中, 动态调整信息素权重 ($\omega=0.85$) 显著提升了寻优能力。这一权重值优化了路径搜索效果, 使算法更有效地找到最佳路径。此外, 通过设定边界停止条件, 当个体路径过长时会被舍弃, 从而减少搜索时间。整体上, 这些优化措施通过调整信息素挥发因子和动态权重, 提升了搜索效率和路径质量。改进后的蚁群算法的火灾疏散路径规划流程如图 3 所示。





图 3 火灾路径规划流程图


3 实验模拟与验证分析

本文选取某办公楼室内一层火灾情景作为模拟实验之背景。为靠近实际环境, 首先用 PyroSim 软件进行建模, 办公楼 3D 模型图如图所示。其次, 利用 FDS 实况模拟办公楼室内火灾。办公楼内墙、柱、楼梯等均为惰性材料, 不参与燃烧, 桌椅等障碍物、地板均可参与燃烧反应。楼层内共布置 13 个传感器节点, 可实时检测温度以及 CO 浓度。起点设于

各房间的出口处，而终点则位于对角线上的安全出口，具体位置如图4所示。



(a) 火灾初起阶段 CO 浓度分布图 (b) 火灾初起阶段温度分布图



(c) 火灾初起阶段逃生规划

图4 火灾初起阶段状况

3.1 火灾安全逃生动态规划路径结果


模拟过程中，逃生人员经由房间出口穿过过道通往安全出口，利用改进蚁群算法进行疏散路径的实时动态规划，避开燃烧区域寻找最优路线。本文仅展示了火灾初起、发展阶段的路径动态规划结果，并对其进行了分析和讨论。

(1) 火灾初起阶段


在火灾的初起阶段，火势仅限于起火点，覆盖的区域相对较小，尚未蔓延至其他区域；烟雾和一氧化碳（CO）的扩散速度较慢，浓度也较低。如图4所示，起火点周围温度约40℃，CO浓度为 3.5×10^{-4} ，对人体健康无威胁。据现阶段火灾态势信息，所规划的安全疏散路径如图4所示，所有出口均未发生燃烧，所有人员可任意选择安全撤离。

(2) 火灾发展阶段

在火灾的发展阶段，火势的燃烧强度会显著增强，导致火势迅速蔓延，燃烧面积随之扩大。同时，烟雾和一氧化碳（CO）不断扩散，其浓度持续上升。如图5所示，着火点温度升高至80℃，同时CO浓度也达到了 2.45×10^{-4} ，已经对人体健康构成威胁，影响其逃生。该区域靠近其中一个出口，被标记为火灾危险区域，在逃生路径的策划与选取阶段，应当规避这一区域，并转而寻找其他安全的出口进行撤离。借助实时更新的通道内温度、一氧化碳浓度等火灾相关动态信息，应及时更新人员的逃生路径。火灾发展阶段实验结果如图5所示。相比较火灾初起阶段，此阶段安全逃生路径有效长度明显缩短。



(a) 火灾发展阶段 CO 浓度分布图 (b) 火灾发展阶段温度分布图




(c) 火灾发展阶段逃生规划


图5 火灾发展阶段状况

3.2 节点数据异常时逃生路径规划

以火灾发展阶段为例，验证节点数据异常情况下逃生路径规划的可靠性。此时随着温度的不断升高，着火点附近的传感器因损坏出现工作异常的情况，将此时刻的异常数据收集并进行处理，绘制火灾态势演变图，如图6所示。通过与图5对比可知，该图中数据明显存在明显异常。图中圆圈标记区域内温度和CO浓度仍处于较低水平，人员可正常通行，而实际上该区域温度和CO浓度数值很高，被标记为危险区域。因此基于异常数据所规划的逃生路径，其可靠性与安全性也就得不到保证。



(a) 节点异常时 CO 浓度分布图 (b) 节点异常时温度分布图



(c) 节点异常时逃生规划

图6 节点数据异常时火灾状况

基于所述情况，应激活异常机制处理预案。将各个传感器收集数据进行预处理，辨别出异常工作节点，将火灾态势信息历史数据输入GRU模型进行预测，预测结果如图7所示。对比分析预测值与温度、CO浓度火灾实时态势信息的实际值，两者的曲线趋势高度一致，预测误差极小，体现了高预测精度，达到了预期目标。






图7 节点数据预测修复后火灾状况

基于修复数据，绘制修复阶段分布图及逃生路径图规划图如图8所示，经过预测修复后的火灾态势已经和实际情况较接近，疏散路径也得到调整，保证了人员撤离的安全。



(a) 节点数据修复阶段CO浓度分布图 (b) 节点数据修复阶段温度分布图



(c) 节点数据修复阶段逃生规划

图8 节点数据修复后时火灾状况

4 结论

本文提出了融合门控循环单元神经网络（GRU）和改进蚁群算法的室内建筑火灾逃生路径规划研究方法。根据火灾态势信息，建立GRU时序预测模型，实现对节点异常情况下火场内温度、CO浓度等火场态势信息的预测；并基于预测结果，利用改进的蚁群算法动态规划逃生路径，得到传感器工作异常情况下的火灾最佳安全逃生路径。本文以某办公楼室内火灾为背景，利用FDS开展火灾逃生模拟实验。实验结果表明，在传感器节点数据异常、缺失情况下，建立GRU

火灾态势信息预测模型与改进蚁群算法结合，能有效提高火灾疏散路径的时效性和可靠性。

参考文献：

[1] 周敬东,高伟周,杨文广,等.基于改进蚁群算法的移动机器人路径规划[J].科学技术与工程,2022,22(28):12484-12490.

[2] 霍非舟,高帅云,魏云飞,等.改进蚁群算法的拥堵环境疏散路径规划研究[J].计算机工程与应用,2023,59(11):263-271.

[3] GAO P, ZHOU L, ZHAO X,et al. Research on ship collision avoidance path planning based on modified potential field ant colony algorithm[J]. Ocean and coastal management, 2023, 235(3): 106482.

[4] 郑馨怡.基于改进蚁群算法在地下商业街火灾疏散系统中的研究与应用[D].沈阳:辽宁大学,2023.

[5] WANG J L, WEI G F, DONG X F. A dynamic fire escape path planning method with BIM[J]. Journal of ambient intelligence and humanized computing, 2021, 12(11): 10253-10256.

[6] PENG Y, LI S W, HU Z Z. A self-learning dynamic path planning method for evacuation in large public buildings based on neural networks[J]. Neurocomputing, 2019, 365(11): 71-85.

[7] 雷鸣,年飞翔,郭阳,等.基于GRU的未来24小时高低温预报技术研究[J].信息技术,2024,48(5):81-85.

[8] 黄莺,杨馥宇.基于GRU神经网络的城市建筑垃圾产量预测[J].工业安全与环保,2024,50(10):93-98.

[9] 郁磊,史峰,王辉,等. MATLAB 智能算法 30 个案例研究[M].北京:北京航空航天大学出版社,2011.

【作者简介】

赵峰（1977—），男，安徽马鞍山人，硕士，副教授，研究方向：数据挖掘、战略管理。

姜孝文（1998—），男，安徽马鞍山人，硕士研究生，研究方向：路径规划。

（收稿日期：2024-09-07）