规模化牛场智能巡检路径规划算法

陈若彤[1,2], 刘继芳[1*], 张志勇[3], 马 楠[1,3], 卫培刚[1,2], 王 亿[1,2], 杨艳涛[4,5]

(1. 中国农业科学院农业信息研究所,北京 100081,中国; 2. 国家农业科学数据中心,北京 100081,中国; 3. 新疆农业大学 计算机与信息工程学院,新疆乌鲁木齐 830052,中国; 4. 中国农业科学院农业经济与发展研究所, 北京 100081, 中国;5. 三亚中国农业科学院国家南繁研究院, 海南三亚 572024, 中国)

摘 要: [**目的/意义**] 畜禽健康问题的及时发现和早期预警对绿色高效养殖至关重要,传统人工巡检耗时耗力且易漏检错检。机器人巡检具有全天候、高精度、高效率和低成本等优势,但现有巡检路径规划较少考虑规模养殖场内肉牛、奶牛等大型畜种个体的全局遍历和动态障碍物导致的局部可通行性优化问题。[**方法**] 本研究提出了一种融合旅行商问题(Traveling Salesman Problem, TSP)、A*(A-Star)和动态窗口法(Dynamic Window Approach, DWA)的全局-局部优化的规模化牛场智能巡检路径规划算法,解决了牛场动态场景下的全局多目标个体遍历、路径冗余与局部通行避障的问题。在全局遍历优化上,提出了融合改进TSP和A*算法的全局巡检路径规划算法;在局部通行优化上,改进DWA实现动态障碍物引起的局部区域可通行性实时判别与提前主动避障。融合全局和局部算法并在Matlab中搭建动态环境验证。[**结果和讨论**] 改进A*算法在规划时间、路径平滑性、路径长度和搜索效率上均优于传统A*算法;融合TSP和A*的全局巡检算法的平均巡检覆盖率达100%,巡检距离和时间较经典蚁群算法分别缩短了17.99%和20.85%;改进DWA可根据障碍物的尺寸提前判断巡检通道的局部可通行性,实时调整机器人线速度、角速度和姿态角度,提前主动避障。[**结论**] 本研究提出的智能巡检算法能够在规模化牛场中实现一定时间内的牛只个体遍历和实时主动避障,有效提升了巡检效率和质量。

关键词: 智能巡检;多目标路径规划;全局个体遍历;局部通行避障;巡检机器人;A*

中图分类号: TP242.6;S823;TP18 **文献标识码:** A **文章编号:** SA202504004

引用格式:陈若彤, 刘继芳, 张志勇, 马楠, 卫培刚, 王亿, 杨艳涛. 规模化牛场智能巡检路径规划算法[J]. 智慧农业(中英文), 2026, 8(1): 178-191. DOI: 10.12133/j.smartag.SA202504004

CHEN Ruotong, LIU Jifang, ZHANG Zhiyong, MA Nan, WEI Peigang, WANG Yi, YANG Yantao. Intelligent Inspection Path Planning Algorithm for Large-Scale Cattle Farms[J]. Smart Agriculture, 2026, 8(1): 178-191. DOI: 10.12133/j.smartag.SA202504004 (in Chinese with English abstract)

0 引 言

全球人口持续增长,对肉蛋奶的需求与日俱增,加速推动了畜牧养殖业朝着规模化、集约化的方向发展[1]。奶牛、肉牛等大型家畜规模化养殖中高效的个体识别[2,3]与巡检[4]对保障家畜健康、提高养殖管理水平具有重要意义。但传统的人工巡检存在耗时耗力且易漏检等问题。基于物联网(Internet of Things, IoT)[5]、人工智能[6]等技术的养殖场巡检机器人[7]对牛只个体进行多视角多目标动态连续监测[8]和即时响应[9],具有效率高、成本低、全天候、高精度等优势,但在复杂养殖场景中仍面临自主导航与路径规划的技术瓶颈。现有机器人多沿预设轨道巡检[10],存在路径固定、灵活性差等问题。具备自主导航能力的巡检机器人[11]可动态应对复杂环境,实现全域覆盖的高效巡检,逐渐成为研究热点[12]。

规模养殖场内多个养殖舍和未知障碍物等对路径规划提出双重挑战[13]:一方面,部分个体在巡检时可能被遗漏,需重复巡检[14];另一方面,巡检时需避开堆料车等障碍物,确保巡检机器人安全,因此需同时优化多目标全局遍历效率[15]与局

收稿日期:2025-04-04

基金项目:国家重点研发计划项目课题(2024YFD2000305);中国农业科学院国家南繁研究院“南繁专项”(YBXM2544)

作者简介:陈若彤,硕士,研究方向为农业信息技术。E-mail:CRT_1001@163.com

*通信作者:刘继芳,博士,研究员,研究方向为农业可持续发展与信息化。E-mail:liujifang@caas.cn

copyright©2026 by the authors (登录www.smartag.net.cn免费获取电子版全文)

部动态避障能力。针对复杂多目标巡检路径规划难题，近年来，研究呈现多元算法融合趋势。秦文龙等[16]提出引入SAC（Soft Actor-Critic）模型参数调优机制的遗传算法规划多换电站的巡检路径。乔道迹和张艳兵[17]提出改进D*（D-Star）算法解决多障碍物环境下巡检机器人避障路径规划问题，提升了巡检效率与可靠性。赵宁磊等[18]采用A*（A-Star）算法和动态窗口法（Dynamic Window Approach, DWA）实现羊舍多目标点的循环巡航和自动避障。然而，现有的路径规划算法大多是针对固定点位的静态或简单动态环境下的巡检[19, 20]，在面对复杂养殖场景[21]和实际巡检需求时还有所不足。深度强化学习动态路径优化方法[22]虽然在无人驾驶、物流配送等工业场景中展现出较大潜力，但在养殖场巡检中仍存在一定局限，其将导航视为一系列动态决策的结果[23]，在空间分布固定场景下训练收敛速度较慢，且无特别优化时决策效率可能不如预期。在巡检任务具有优先级差异时，基于旅行商问题（Traveling Salesman Problem, TSP）的求解思路可对动态多目标巡检问题进行简化建模。TSP已在农业多目标作物连续采摘的路径规划[24]和配电室巡检多目标点路径规划[25]等领域得到应用。但现有算法仍存在以下问题：一是难以实现对所有动态牛只个体的全面覆盖巡检；二是缺乏有效的动态调整机制，巡检路线相对固定、效率低；三是缺少局部可通过性判断，在狭窄巡检通道内面对大型障碍物时无法主动避障。在养殖场动态复杂环境中，如何在保证巡检质量的前提下，高效地规划巡检路径，在一定时间内完成对所有区域、全部牛只个体的巡检，最大限度地减少机器人的能耗和巡检时间，是养殖巡检领域亟待解决的问题。因此，开展动态场景下养殖场巡检机器人路径规划算法[26]研究具有重要意义和应用前景。

本研究围绕养殖场智能巡检需求，确定巡检机器人的核心任务为全面巡检养殖场内所有牛只个体，遗漏时重复巡检，遇到未知障碍物时需提前判断是否可以通过，实时主动避障，确保巡检安全；巡检目标是在保障机器人安全的前提下，完成巡检任务并最大程度提升巡检效率，以满足养殖场智能化巡检需求。因此，本研究提出了融合TSP、A*和DWA的规模化牛场动态多目标巡检路径规划算法，构建动态巡检任务优先级与距离成本优化框架，通过改进TSP最近邻法规划多养殖舍最佳巡检顺序，引入贪婪策略、对角线启发式函数及高效数据结构优化A*算法，实现养殖舍间高效平滑的路径规划，并融合障碍物尺寸动态安全阈值改进DWA进行局部通行判断以主动避障。本研究解决了以下三个问题：一是实现动态养殖场景下牛只个体全局遍历巡检并动态调整路径；二是改进A*算法提高搜索效率，降低路径冗余度；三是通过改进DWA实现局部可通过性判断与动态主动避障。本研究的意义在于通过全局规划与局部避障优化，解决了规模化牛场巡检中个体遍历缺失、路径冗余及避障被动等问题，可有效巡检遍历牛只个体并实时响应突发情况，提升养殖场巡检适应性与管理效率。

1 材料与方法

1.1 规模化牛场巡检实验场景

本研究以中国农业机械化科学研究院集团有限公司农机试验站奶牛养殖场为原型开展巡检路径规划算法研究与验证。该养殖场位于北京市昌平区，占地3.13 hm^2，圈舍11个，奶牛存栏量450头。作为中国首批机械化奶牛场，该养殖场在智能化养殖领域具有重要的示范价值，为本研究提供了数据采集和算法验证的真实场景。为提高巡检效率与安全性，构建综合考虑牛只动态性与未知障碍物的智能巡检算法，通过多模态传感器阵列获取牛只、环境信息，优化全局与局部路径规划策略，从而实现巡检机器人在复杂场景中的安全自主导航。为验证本算法的有效性，以昌平牛场遥感地图数据（源自Google Earth网页版，Airbus数据，来自2023年5月10日后图像，40°09'46"N，116°17'02"E）为基础，基于离散网格映射和牛只个体移动模型建模方法构建包含全局空间结构与局部障碍信息的牛场动态仿真环境（如图1所示），以便进行动态多目标巡检路径规划算法的构建与性能验证。巡检仿真环境建模包括静态环境建模和动态环境建模。

1）静态环境建模。构建基于双重网格映射的养殖舍区域，采用空间膨胀算法对养殖舍进行缓冲区扩展，生成包含安全边界的养殖舍区域（标记为1，不可通行），其他网格单元（标记为0）可通行，为路径规划提供精细化的空间约束信息。为确保机器人对牛只个体的有效观测，沿扩展后的安全边界按视场分辨率 *inspection_view*/2 等间距采样，经坐标去重与边界过滤生成养殖舍边界巡检点集，作为后续路径规划算法的输入。

2）动态环境建模。基于离散马尔可夫过程构



图 1 规模化牛场巡检场景

Fig. 1 Large-scale cattle farm inspection scene

建牛只个体行为仿真模型[27]，定义了休息、觅食和活动三种离散状态，并通过状态转移概率矩阵模拟牛只在不同状态间的转换。休息状态定义为牛只在圈舍角落处静态分布，觅食状态对应食槽区域的集群行为，活动状态则通过随机游走模型描述社交、活动行为。模型引入随机初始化和严格的空间边界约束，以保证个体行为在动态变化的同时符合牛场的实际情况。相比传统的确定性行为建模方法，基于马尔可夫过程的模型在个体行为复杂度、场景真实性和参数可调性方面表现出显著优势，为路径规划算法研究提供了可靠的仿真场景。在测试算法性能时，通过调整各状态的转移概率矩阵，可灵活构建不同复杂度的测试场景，实现对巡检算法鲁棒性的全面评估。

1.2 牛场动态多目标巡检路径规划算法

1.2.1 巡检路径规划算法整体架构

针对规模化牛场巡检问题，本研究将巡检任务拆解为多目标巡检顺序优化、全局路径规划与局部避障策略三个子问题。多目标巡检顺序优化是规划多养殖舍的最优巡检顺序，以最小化巡检总距离。合理的巡检顺序能避免不必要的迂回移动，从而提高巡检效率。该问题与TSP的求解思路相似，通过最近邻法根据当前位置快速选择距离最近的未访问圈舍作为下一个目标。结合巡检场景改进最近邻法，融入待巡检养殖舍、牛只个体列表，可避免对已巡检区域的无效重复巡检。针对养殖场动态不确定性场景，最近邻法可有效平衡计算效率和结果质量，对于多养殖舍的巡检顺序规划具有较高的适用性。全局路径规划是在确定各圈舍访问顺序后，规划出包含相邻养殖舍间移动路径，以及单个养殖舍巡检路径的全局最优巡检路径。A*算法是一种常用的启发式路径搜索算法，但在巡检场景下存在路径平滑性不足与动态障碍物适应性弱等问题。本研究结合巡检需求改进A*算法，规划出养殖舍之间的高效、平滑路径。到达一个养殖舍后，通过最近邻法围绕养殖舍边界规划巡检路径。局部避障策略是通过局部路径规划算法增加机器人的可通过性判断，主动避障，弥补全局规划的不足，为巡检机器人提供兼具全局效率与局部安全的协同规划框架（如图2所示）。

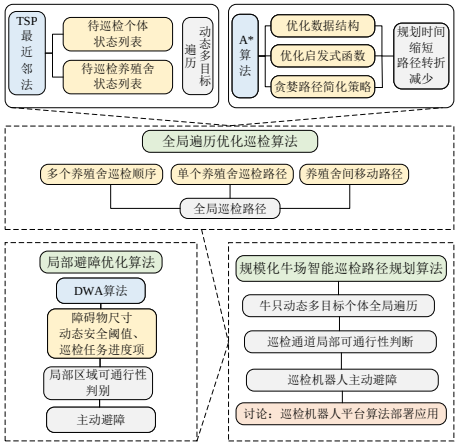


图 2 牛场智能巡检路径规划算法研究框架图

Fig. 2 Research framework diagram of intelligent inspection path planning algorithm for cattle farm

综上所述，为解决上述三个子问题，本研究提出了一种融合全局和局部优化的规模化牛场动态多目标巡检路径规划算法：首先改进TSP最近邻法确定各养殖舍最佳访问顺序，其次改进A*算法规划出当前位置到下一个待巡检养殖舍的移动路径，到达下一个养殖舍后，再通过最近邻法规划出该舍的巡检路径。巡检过程中实时更新待巡检列表，将已完成巡检的圈舍将移除列表，后续只对有漏检个体的养殖舍重复巡检。在全局路径规划基础上，融合改进DWA进行局部路径优化，实现局部区域可通行性实时判别与主动避障。巡检算法整体流程如图

3所示。

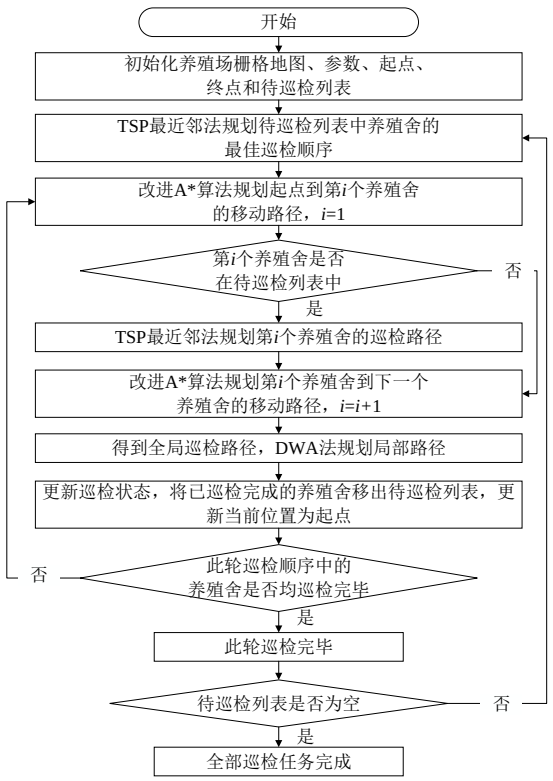


图3　规模化牛场智能巡检路径规划算法流程图

Fig. 3　Flow chart of intelligent inspection path planning algorithm for large-scale cattle farm

1.2.2　全局巡检算法优化

1.2.2.1　改进TSP的动态多目标巡检规划

规模化牛场巡检规划的核心目标是确定机器人访问各养殖舍的最优顺序，以实现总路径最短。该问题在本质上是旅行商问题，可将多个养殖舍类比为TSP中的城市节点，巡检机器人视为遍历所有节点的旅行商。然而，与传统TSP相比，本研究场景存在两个显著差异：其一，牛只个体的动态不确定性导致单次巡检难以覆盖所有个体，需要重复巡检；其二，待重复巡检养殖舍具有随机性，难以确保总巡检路径最短，因此本研究选择可以实现局部最优的最近邻法，其计算复杂度低，能快速规划出多养殖舍的访问顺序。基于巡检场景改进最近邻算法流程如下：

1）养殖舍中心点计算。将养殖舍抽象为矩形区域，计算其中心点坐标，并将其作为该舍的代表点，用于后续的距离计算。

2）初始位置设定。根据机器人的停放或充电位置设定初始位置。

3）待巡检养殖舍列表。为所有牛只个体和每个养殖舍建立待巡检列表（如表1和表2所示），初始状态均为“待巡检”。牛只个体进入机器人视野后标记为“已巡检”。当一个圈舍内全部牛只个体均为“已巡检”时，该舍转为“已巡检”状态，如果圈舍内仍然有“待巡检”个体则保持“待巡检”状态不变。巡检过程中，机器人根据观察到的牛只个体实时更新养殖舍的剩余待巡检个体数量。一轮巡检后，机器人检查任务列表，继续将“待巡检”的养殖舍作为巡检目标，进行重复巡检。这一标记机制能够有效避免对已巡检完成圈舍的重复巡检，从而提高巡检效率。

表1　待巡检牛只个体列表(示例)

Table 1　List of cattle individuals to be inspected (example)

牛只个体编号	所属养殖舍编号	巡检状态
Cow_001	Shed_001	已巡检
Cow_002	Shed_001	已巡检
Cow_030	Shed_002	已巡检

表2　待巡检养殖舍列表(示例)

Table 2　List of barns to be inspected (example)

养殖舍编号	舍内个体总数/只	待巡检个体数量/只	巡检状态
Shed_001	20	0	已巡检
Shed_002	15	5	待巡检
Shed_008	3	3	待巡检

4）未访问节点集合。每轮巡检时，将所有待巡检的养殖舍的索引放入一个未访问节点集合中。随着养殖舍的依次访问，该集合中的元素逐渐减少。

5）选择下一个访问节点。从当前位置出发，从未访问节点集合*unvisited*中选择距离最近的节点*k*作为下一个访问目标，并添加到访问顺序*shed_sequence*中。

6）更新当前位置。将下一个访问目标作为新的当前位置，同时将该养殖舍标记为已访问，从*unvisited*中移除，重复步骤5），直到未访问节点集合为空，即所有养殖舍都被访问。

通过前面6个步骤确定机器人访问各个养殖舍的最优顺序后进行巡检路径规划：

1）找到养殖舍之间的过渡路径。调用改进A*算法找到从当前位置*s*到下一个待巡检养殖舍边界的最佳行进路径*entry_path*。

2）生成养殖舍环绕巡检路径。到达当前养殖舍后，再次使用最近邻算法规划出当前养殖舍边界点的遍历路径，基于欧几里得距离来选择离当前位

置最近的边界点，逐步构建完整的路径，生成当前养殖舍的环绕巡检路径*shed_path*。

3）生成完整路径。最后将过渡路径*entry_path*和环绕巡检路径*shed_path*依次添加到完整路径*complete_path*中。

1.2.2.2 改进A*算法的养殖舍间移动路径规划

A*算法通过评价函数$f(n)$指导搜索方向，从而快速找到从起点到目标点的最优路径[28]。然而，传统A*算法对障碍物的处理不够灵活、在网格地图中生成的路径可能会包含许多不必要的拐点[29]。基于养殖舍间移动巡检路径规划中对巡检效率、避障的要求，本研究改进A*算法，整体流程如图4所示。初始化阶段设置起点并初始化OPEN和CLOSED列表。主循环阶段从OPEN列表中选择$f(n)$值最小的节点进行扩展，更新邻居节点的代价并将其加入OPEN列表，同时将当前节点移至CLOSED列表。路径回溯阶段从目标节点回溯至起点，利用CLOSED列表中的父节点信息生成路径。最后，通过贪婪策略简化路径，移除冗余拐点，生成更平滑的路径。

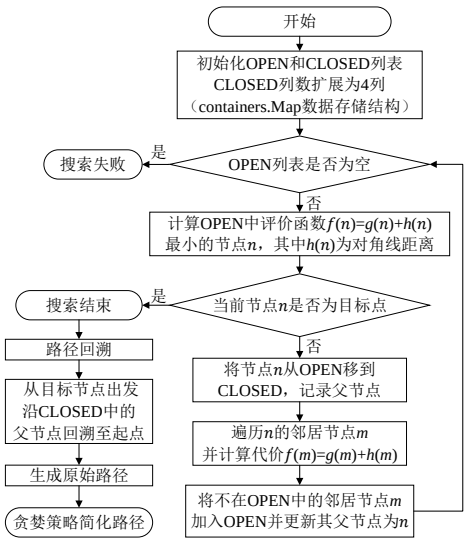


图4 引入贪婪策略、对角线启发式函数及高效数据结构的改进A*算法流程图

Fig. 4 Flowchart of the improved A* algorithm with greedy strategy, diagonal heuristic function and efficient data structure

改进A*算法在传统A*算法的基础上引入了以下三个改进点：

1）数据结构优化。在A*算法中，OPEN列表需要频繁查找和更新节点的代价，传统优先队列效率不高，如二叉堆。Containers.Map是一种基于哈希表的数据结构，数据结构如表3所示，查找、插入和删除操作的平均时间复杂度为$\boldsymbol{O}(1)$，显著优于二叉堆的$\boldsymbol{O}(logn)$，适合频繁查找和更新节点的场景。因此，使用containers.Map来存储OPEN、CLOSED列表，动态调整内存分配，以键值对形式存储数据，将节点坐标(x, y)作为键，节点信息$[x, y, parent_x, parent_y, g(n), h(n), f(n)]$作为值，数据结构如图5所示。键唯一可自动避免重复插入相同节点，便于快速查找和更新。此外，扩展CLOSED列表的列数，存储每个节点的父节点坐标，以便在路径回溯时可直接从CLOSED中获取父节点信息，避免再次搜索OPEN列表，提高了路径回溯效率。

表3 Containers.Map数据结构表

Table 3 Containers.Map data structure table

键(x, y)	值$[x, y, parent_x, parent_y, g(n), h(n), f(n)]$
(1, 2)	[1, 2, 0, 0, 10, 20, 30]
(3, 4)	[3, 4, 1, 2, 15, 25, 40]

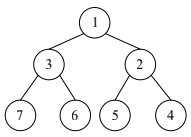


图5 传统优先队列(二叉堆)数据结构视图

Fig. 5 Traditional priority queue (binary heap) data structure view

2）启发式函数优化。启发式函数$h(n)$直接影响A*算法的效率和路径最优性。传统A*算法的曼哈顿距离启发式函数无法精确反映节点的八方向（上、下、左、右四个基本方向及右上、右下、左上、左下四个对角线方向）移动（图6）[30]的实际代价，路径如图7所示。改进A*算法使用对角线距离（Octile Distance）[31]作为新的启发式函数，更接近真实代价，从而减少扩展冗余节点，路径如图8所示。对角线距离如公式（1）所示。

$$h(n)=(dx+dy)+(\sqrt{2}-2)\times \min(dx,dy) \quad (1)$$

式中：$h(n)$是对角线距离，$dx=|x_2-x_1|$是节点(x_1, y_1)与目标节点(x_2, y_2)在水平方向（x轴）上的绝对距离差，$dy=|y_2-y_1|$是垂直方向（y轴）上的绝对距离差，min( )表示取两者中的较小值。

3）贪婪策略简化路径。传统A*算法生成的路径可能包含冗余拐点，增加了路径长度，在巡检中会增加机器人转向能耗。因此，在生成路径后，引入贪婪策略简化路径，移除路径中不必要的中间点，在避障的前提下生成更接近直线的最优路径。

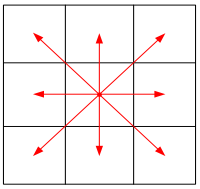


图 6　节点的八方向移动示意

Fig. 6　Schematic movement of node in 8 directions

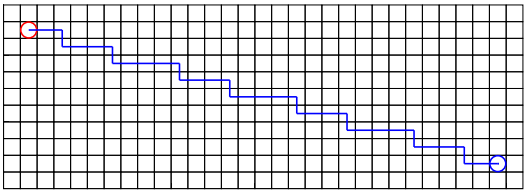


图 7　曼哈顿距离启发式函数路径

Fig. 7　Manhattan distance heuristic function path



图 8　对角线距离启发式函数路径

Fig. 8　Diagonal distance heuristic function path

贪婪策略简化路径（*greedy_simplify_path*）的主要步骤如下：

①从起点开始，依次检查路径中的每个点；

②对于当前点（初始为起点），尝试直接连接到后续的某个点（从终点开始逆向检查），跳过中间点；

③如果两点之间没有障碍物（通过直线视野函数*is_line_of_sight*检查），则移除中间点；

④重复此过程，直到路径无法进一步简化。

其中，直线视野检查*is_line_of_sight*即检查两点之间是否有直线路径且路径上没有障碍物，使用Bresenham算法，如公式（2）所示，遍历两点之间的所有点，检查是否在障碍物列表中。

$$is_{line_{of_{sight}(p_i,p_j)}} = \bigwedge_{k=1}^{N} \left((x_k, y_k) \notin Obs \right) \tag{2}$$

式中：p_i，p_j分别为路径中的两个节点；N为Bresenham算法生成的从p_i到p_j的路径点数；$\bigwedge$表示逻辑与运算；(x_k, y_k)是路径上的第k个点；Obs表示障碍物集合。

假设生成的路径为A → B → C → D → E，如果A和C之间、C和E之间没有障碍物，通过贪婪策略简化后（图9），路径会简化为A → C → E，如图10所示。

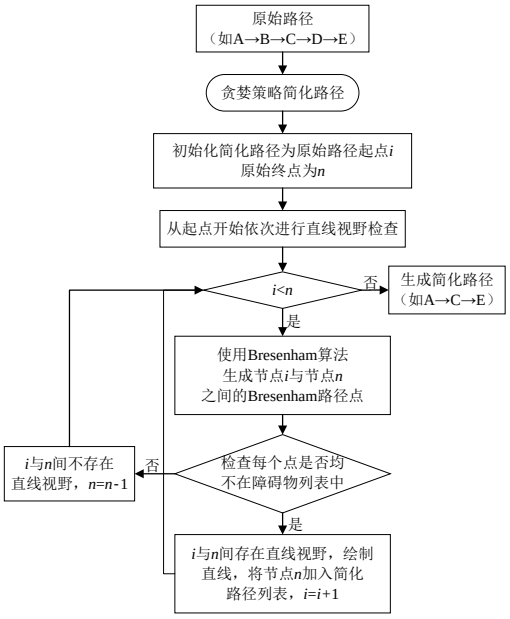
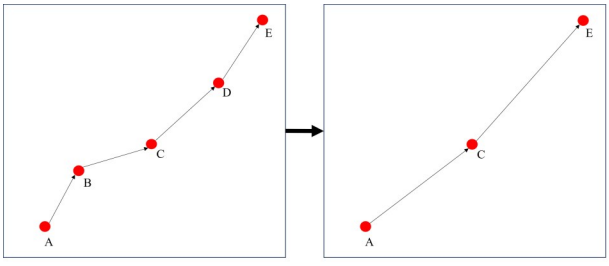


图 9　贪婪策略简化路径流程图

Fig. 9　Greedy strategy simplified path flow chart



优化前　　优化后

图 10　贪婪策略简化路径示例

Fig. 10　Example of greedy strategy simplified path

1.2.3　局部通行避障算法优化

在非结构化牛场环境中，狭窄的巡检通道，以及大型饲料运输车、行走的工作人员等未知障碍物[32]的出现，要求巡检算法应具备实时响应与自适应调整能力。DWA可根据当前传感器信息动态调整路径，实时避障。因此，在全局巡检算法的基础上，融合DWA来实时调整局部路径[33]。结合牛场巡检中可能遇到的问题，如巡检机器人与大型设备于狭窄通道内迎面相遇时，障碍物的尺寸会影响机器人可通过的空间大小，本研究通过引入障碍物尺寸动态安全阈值、任务进度项改进轨迹评分函数，实现巡检机器人的局部可通过性判别，以便根据障碍物情况提前主动避障。

1）障碍物尺寸动态安全阈值（Obstacle Size Dynamic Safety Threshold）。在牛场狭窄通道内遇到大型障碍物时，机器人需要更多的空间和更低的速度来保证安全通行，如无法保障安全则需避让或

绕行。因此，牛场巡检场景中，DWA的轨迹评分函数中需要充分考虑障碍物的尺寸，比对机器人避障的“安全距离阈值”，提前进行主动避障。设T为轨迹，o_i为第i个障碍物，$d_{obs}(T,\ o_i)$为轨迹T到障碍物o_i的最小距离，s_i为障碍物o_i的尺寸（用障碍物外接圆半径或最大边长表示）。定义第i个障碍物与障碍物尺寸相关的动态安全距离阈值$d_{Dyn_{safe}}(s_i)$如公式（3）所示。

$$d_{Dyn_{safe}}(s_i) = k \times s_i + d_{safe} \tag{3}$$

式中：k为一个正的比例系数，用于衡量障碍物尺寸对安全距离的影响程度；d_{safe}为安全距离阈值。障碍物尺寸动态安全阈值评分项*ObstacleSizeDynSafe*可表示为公式（4）。

$$ObstacleSizeDynSafe(T) = \sum_{i=1}^{n}\begin{cases} 0 & \min_{t\in T} d_{obs}(t, o_i) < d_{Dyn_{safe}}(s_i) \\ \dfrac{\min_{t\in T} d_{obs}(t, o_i) - d_{Dyn_{safe}}(s_i)}{d_{max} - d_{Dyn_{safe}}(s_i)} & \min_{t\in T} d_{obs}(t, o_i) \geq d_{Dyn_{safe}}(s_i) \end{cases} \tag{4}$$

式中：n为障碍物的总数；t是轨迹T上的点；$\min_{t\in T} d_{obs}(t,\ o_i)$表示轨迹T上距离第$i$个障碍物$o_i$最近点之间的距离；$d_{max}$是用于评分归一化的最大参考安全距离。当轨迹与某个障碍物的距离小于动态安全距离时，该障碍物对应的评分贡献为0，否则按照线性比例计算评分。

2）障碍物距离评分项（Dist）。$Dist(T)$如公式（5）所示。

$$Dist(T) = \begin{cases} 0 & \min d_{obs}(T) < d_{safe} \\ \dfrac{\min\limits_{t\in T} d_{obs}(t)}{d_{max}} & \min d_{obs}(T) \geq d_{safe} \end{cases} \tag{5}$$

式中：$\min\limits_{t\in T} d_{obs}(t)$为轨迹到最近障碍物的最小距离；$d_{max}$为传感器最大探测范围；$Dist(T)$将轨迹到最近障碍物的最小距离与传感器最大探测范围进行归一化处理。因为前面$ObstacleSizeDynSafe(T)$已经考虑了障碍物尺寸对安全距离的影响，因此$Dist(T)$评分项可以简化为只考虑与障碍物的基本距离关系，不再依赖固定的安全距离阈值。

3）任务进度项（Task Progress）。建立引力场模型驱动的待访问圈舍吸引力。设机器人当前位置为p_{robot}，下一个待访问的圈舍节点为v_{next}，则任务进度项$TaskProgress(T)$（如公式（6）所示）可视为势能函数的最小化问题。

$$TaskProgress(T) = -\lambda \times /\!/\ p_T - v_{next}\ /\!/^{\,2} \tag{6}$$

式中：p_T为轨迹终点坐标；λ为势场增益系数，控制引力强度，λ越大表示待访问圈舍节点v_{next}对机器人的吸引力越强；$/\!/\ p_T - v_{next}\ /\!/^{\,2}$表示轨迹终点到待访问圈舍节点之间欧几里得距离的平方。通过梯度下降原理引导机器人向目标节点运动，同时与路径贴合项（Path Alignment）形成协同作用。

其余各评分项定义如下：

1）目标朝向（Heading）定义轨迹终点朝向与局部目标点方向的一致性，如公式（7）所示。

$$Heading(T) = 1 - \frac{|\theta_T - \theta_{local}|}{\pi} \tag{7}$$

式中：θ_T为轨迹终点朝向；θ_{local}为机器人到p_{local}的方向角。

2）速度（Velocity）是考虑线速度和转向平滑度的综合评分，如公式（8）所示。

$$Velocity(T) = v \times \left(1 - \frac{|\omega|}{\omega_{max}}\right) \tag{8}$$

式中：v为机器人在当前轨迹T上的线速度；ω为机器人在当前轨迹T上的角速度；ω_{max}为机器人能够达到的最大角速度。

3）路径贴合项（Path Align）是轨迹终点与全局路径的贴合度，如公式（9）所示。

$$PathAlign(T) = \frac{1}{1 + \alpha \times /\!/\ e_{tangent}\ /\!/ + \beta \times /\!/\ e_{normal}\ /\!/} \tag{9}$$

式中：$e_{tangent}$和e_{normal}分别为轨迹终点在全局路径切向与法向的偏差；α和β为权重系数（$\alpha < \beta$以优先减少横向偏移）。

改进后完整的DWA轨迹评分函数如公式（10）所示。

$$\begin{aligned} Score(T) = {} & \alpha \times Heading(T) + \\ & \beta \times ObstacleSizeDynSafe(T) + \\ & \gamma \times Dist(T) + \delta \times Velocity(T) + \\ & \eta \times PathAlign(T) + \\ & \zeta \times TaskProgress(T) \end{aligned} \tag{10}$$

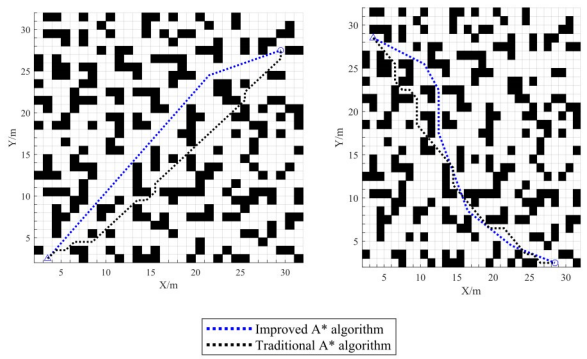
通过引入拉格朗日乘子法，可证明轨迹评分函数的凸组合形式能够保证帕累托最优性（Pareto Optimality），即权重系数α，β，γ，δ，η，$\zeta \geq 0$且$\alpha + \beta + \gamma + \delta + \eta + \zeta = 1$，且在多目标冲突下实现折衷最优解，实现避障安全与路径跟踪的权衡，任务效率与运动平滑性的平衡。改进后的DWA通过多目标协同优化，在牛场巡检中充分考虑实际情况，实现了局部区域可通过性判断、主动避障与巡检路径跟踪，为复杂环境下巡检机器人的全局-局

部协同规划提供了完备、可行的解决方案。

2　结果与分析

2.1　改进A*算法仿真对比

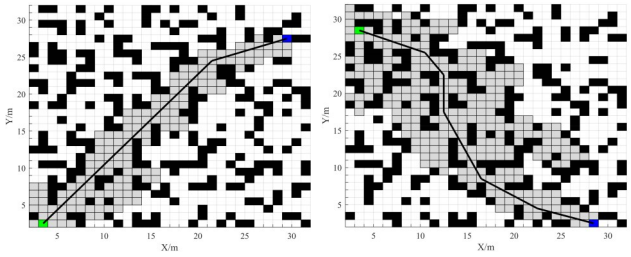
为了验证改进A*算法的性能，设计传统A*与改进A*算法对比实验，分析算法在路径质量、计算效率上的性能差异。构建30×30网格地图，障碍物覆盖率p为25%。选取可以反映路径质量、计算效率、搜索过程效率的以下5个量化指标评估算法性能，分别为规划时间、转折次数、转折度数、路径长度和遍历节点数。规划时间使用Matlab的tic与toc函数计算算法从启动到输出最终路径的运行时间；转折度数是计算路径中连续三点之间的转折角度，然后累加所有转折角度；转折次数是将总的转折度数除以45°得到转折次数的估算值（假设每次转折角度大于45°视为一次转折）；路径长度根据路径节点坐标序列计算欧几里得距离总和；遍历节点数是算法在搜索过程中访问的节点总数，记录了算法遍历状态空间的开销。重复运行10次后取均值，对比实验结果如表4和图11～图13所示。为验证算法在不同环境中的适应性及泛化性能，采用固定地图环境与差异化起止点配置设计对照实验：实验a将路径起点设定于地图左下方，终点设定于地图右上方，执行对角线路径规划；实验b将路径起点设定于地图左上方，终点设定于地图右下方，执行对角线路径规划。



a. 实验a路径对比　　b. 实验b路径对比

图11　引入贪婪策略、对角线启发式函数及高效数据结构改进的A*与传统A*算法路径对比

Fig. 11　Path comparison between the improved A* algorithm with greedy strategy, diagonal heuristic function and efficient data structure and the traditional A* algorithm



a. 实验a改进A*算法搜索空间　　b. 实验b改进A*算法搜索空间

图12　引入贪婪策略、对角线启发式函数及高效数据结构改进的A*算法搜索空间可视化

Fig. 12　Search space visualization of the improved A* algorithm with greedy strategy, diagonal heuristic function and efficient data structure

由上述结果可知，与传统A*算法相比，改进A*算法规划时间平均减少90.06%，转折度数和转折次数减少85.13%，路径长度减少1.83%，搜索过程访问节点数平均减少42%。从图12～图14也可以看出，改进后的A*算法所规划的路径搜索空间更小、转折次数更少、路径更加平滑。实验结果表明，改进A*算法通过贪婪策略简化路径、对角线距离启发式函数、数据结构优化策略，显著降低了启发函数的过估计风险，有效减少了冗余节点扩展，使路径更平滑。通过对比实验可以看出，改进A*算法在规划时间、路径平滑性、路径长度和搜索效率等方面均优于传统A*算法。

2.2　牛场全局优化巡检路径仿真

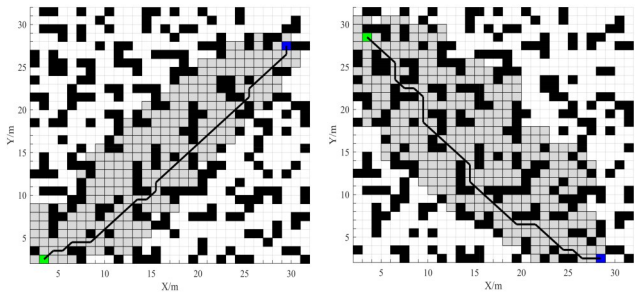
为实现动态环境下的全局巡检路径规划算法验

表4　引入贪婪策略、对角线启发式函数及高效数据结构改进的A*与传统A*算法性能对比

Table 4　Performance comparison between the A* algorithm improved by introducing greedy strategy, diagonal heuristic function and efficient data structure and the traditional A* algorithm

实验	算法类型	规划时间/ms	转折次数	转折度数/(°)	路径长度/cm	遍历节点数
a	改进A*算法	0.032 5(SD=0.006 8)	0.670 1	30.154 5	36.969 3	111
	传统A*算法	0.378 9(SD=0.017 8)	11.000 0	495.000 0	38.112 7	241
b	改进A*算法	0.053 1(SD=0.003 7)	3.074 8	138.366 5	39. 605 8	214
	传统A*算法	0.469 5(SD=0.028 4)	13.000 0	585.000 0	39.870 1	306

注：其中，样本标准差$SD=\sqrt{\frac{\sum_{i=1}^{n}(x_i-\bar{x})^2}{n-1}}$，$n=10$，转折次数、转折度数、路径长度、遍历节点数四个指标的SD均为0。



a. 实验a传统A*算法搜索空间 b. 实验b传统A*算法搜索空间

图13 传统A*算法搜索空间可视化

Fig. 13 Traditional A* algorithm search space visualization

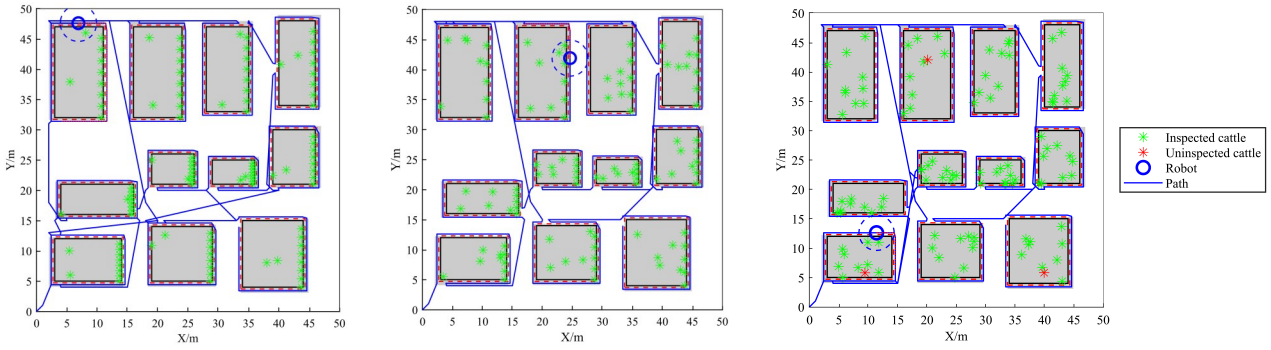
证，按照第1.1节的动态环境建模方法，在Matlab中搭建50×50牛场动态场景仿真地图，共计11个圈舍，每个圈舍内10个牛只个体。为了评估牛只不同活动状态下巡检路径规划算法的效率，设置了以下三组实验，牛只活动状态概率如表5所示，最大程度模拟牛只个体活动的不确定性。

表5 牛只不同活动概率设定

Table 5 Setting of livestock different activity probabilities

实验组数	固定进食和停留总概率/%	牛只随机游走概率/%
1	80	20
2	50	50
3	0	100

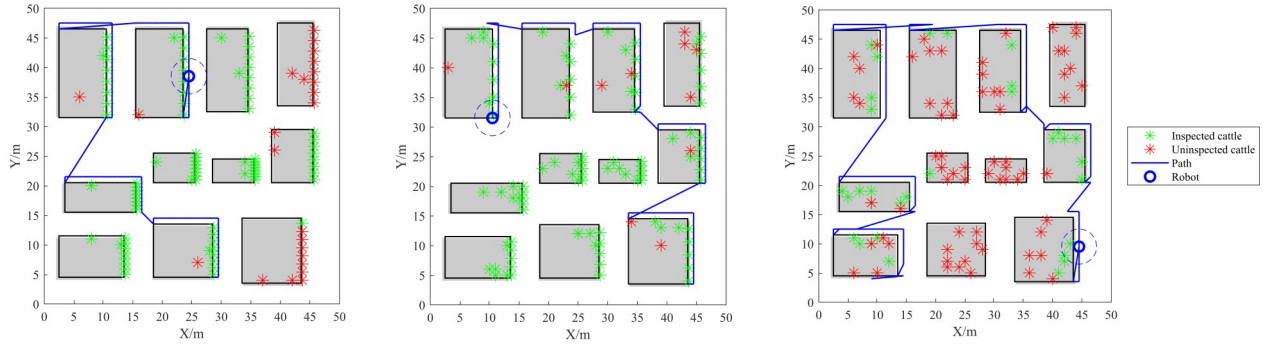
为评估本文算法与传统方法在巡检效率方面的性能差异，在统一环境配置（包括静态场景拓扑与动态牛只活动概率模型）约束下，分别运行本文算法与经典蚁群算法（Ant Colony Algorithm, ACO）进行牛场巡检实验，实验过程如图14和图15所示，其中蓝色线条为阶段性巡检路径，红色*为待巡检个体，绿色*为已巡检个体。表6总结了牛只不同活动状态下机器人的总巡检时间、巡检路径长度、牛只个体巡检覆盖率。因为牛只个体移动的随机不确定性，每组实验开展30次，计算平均值。



a. 随机游走概率20% b. 随机游走概率50% c. 随机游走概率100%

图14 TSP+A*算法巡检路径

Fig. 14 TSP + A * algorithm inspection path



a. 随机游走概率20% b. 随机游走概率50% c. 随机游走概率100%

图15 经典蚁群算法牛场巡检路径

Fig. 15 Classical ant colony algorithm inspection path of cattle farm

从实验结果可以发现，随着牛只个体随机游走模式概率的增加，机器人的总巡检时间、巡检路径长度均在增加。仅在牛只随机游走概率较低（牛只随机游走概率20%）时，蚁群算法和TSP+A*全局优化巡检算法的巡检效率差别不大，但TSP+A*算法的巡检覆盖率提高了4.73个百分点。其余两组实验中，TSP+A*算法巡检效率明显高于蚁群算法，巡检路径长度和时间平均缩短了17.99%和20.85%，

表6　牛只不同活动状态下巡检实验记录

Table 6　Inspection experimental records of cattle under different activity probability

牛只随机游走概率/%	巡检算法	总路径长度/m	总巡检时间/s	牛只个体巡检覆盖率/%
20	TSP+A*	789.98	270.49	100.00
	ACO	793.27	281.71	95.27
50	TSP+A*	992.71	341.44	100.00
	ACO	1 206.67	432.03	93.29
100	TSP+A*	1 125.63	385.56	100.00
	ACO	1 376.95	486.38	92.42

巡检覆盖率平均提高了7.15个百分点，表明牛只个体移动概率较高时TSP+A*算法可以显著提高巡检效率和覆盖率。

通过上述实验结果分析，在牛场动态重复巡检场景下，采用蚁群等启发式算法通常需要一定的时间才能收敛到一个较优解，优势不明显。随着巡检次数的增加，巡检目标点会不断减少，搜索空间变小，需要重新调整信息素分布或重新初始化蚂蚁的搜索过程，这会增加额外的计算开销，降低巡检效率。然而使用改进TSP最近邻法规划养殖舍的最佳巡检顺序和路径，并结合改进A*算法规划养殖舍建移动路径的方法更高效，可以在重复巡检、目标点减少时进行增量式更新，进一步提高了巡检效率。

2.3　牛场局部通行避障路径仿真

为验证全局巡检路径规划算法融合局部通行避障DWA算法的有效性，以牛场网格地图为模拟环境，在可行通道内设置临时动态、静态障碍物（深灰色为未知静态障碍物，黄色为动态障碍物），模拟机器人在巡检过程中可能遇到的真实情况。运行全局和局部巡检算法，得到的全局路径（蓝色粗虚线）、融合DWA算法后的实时路径（蓝色细实线）如图16所示，机器人的运行姿态角度、线速度和角速度如图17～图19所示。

图18中姿态角度曲线呈现波动变化，表明机器人在巡检过程中因转弯或避障调整行进方向：转弯时姿态角度变化相对较小，避障时姿态角度变化较大，机器人通过调整方向适应环境与全局路径。图19中无障碍物时机器人行进的线速度相对稳定且接近预设值，遇到障碍物时线速度提前下降主动避障；避障时角速度波动明显，即机器人发现障碍物时会快速调整角速度以实现转向动作。这表明DWA算法判断局部可通过性后，可提前主动规避障碍物，动态调整角速度配合线速度变化，如果可以通过则减速转向避障，如果无法通过则主动绕行避让。实验结果表明融合改进DWA的机器人在全局巡检任务中表现出较好的适应性和稳定性。

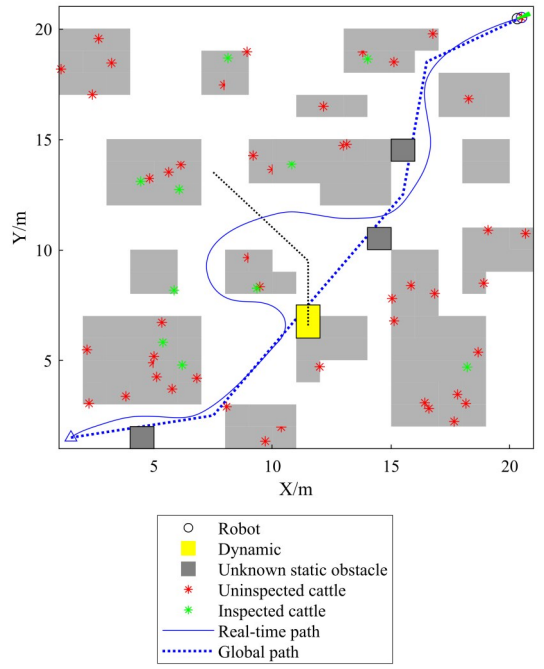


图16　牛场巡检机器人局部避障路径

Fig. 16　Local obstacle avoidance path of cattle farm inspection robot

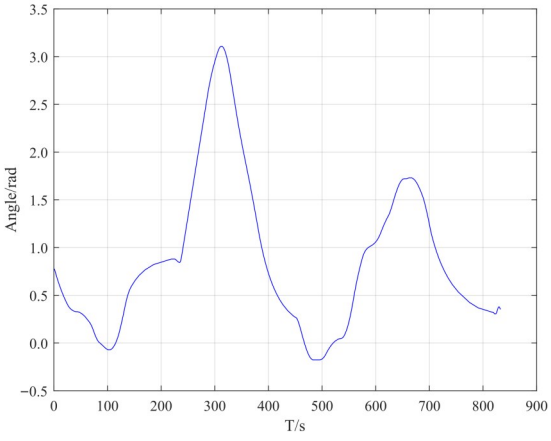


图17　牛场巡检机器人局部避障姿态角度

Fig. 17　Local obstacle avoidance attitude angle of cattle farm inspection robot

2.4　智能巡检算法部署应用

为进一步验证本研究所提出智能巡检路径规划算法的有效性与实用性，在牛场中部署巡检机器人平台（图20），搭载双目深度相机等传感器实时感知牛只位置、障碍物等信息，并在机器人操作系统（Robot Operating System, ROS）上集成相关巡检算法开展牛场巡检实验，在存在移动牛只个体与未知

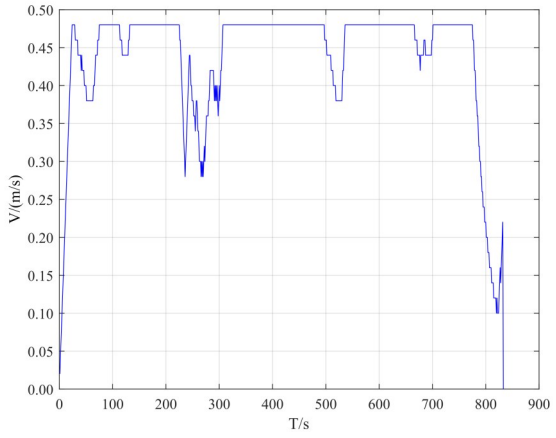


图 18 牛场巡检机器人局部避障线速度

Fig. 18 Local obstacle avoidance linear velocity of cattle farm inspection robot

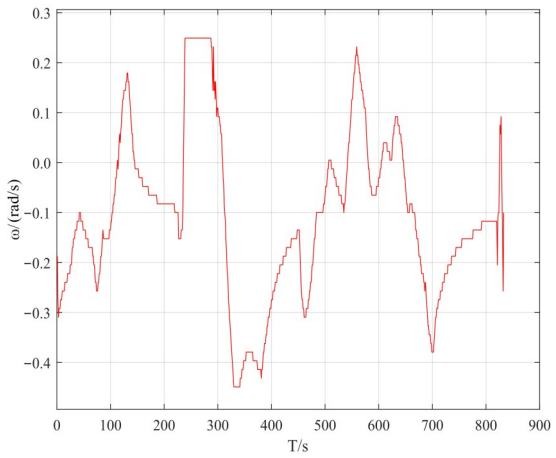


图 19 牛场巡检机器人局部避障角速度

Fig. 19 Local obstacle avoidance angular velocity of cattle farm inspection robot

静态/动态障碍物干扰的条件下执行多目标巡检任务。



图 20 规模化牛场巡检机器人平台

Fig. 20 Inspection robot platform in large-scale cattle farm

在规模化牛场智能巡检任务中，路径规划算法需与多种感知与识别模块紧密协同，以实现对动态环境的有效理解与响应。通过同步定位与建图（Simultaneous Localization and Mapping, SLAM）模块获取牛场环境地图及机器人当前位姿，结合深度信息和几何计算完成视野范围内机器人与牛只之间的相对距离估算，通过牛只个体身份识别模块[34]实现一定距离内个体的精准识别。上述模块输出的环境信息、个体信息与障碍物信息将作为本研究智能巡检路径规划算法的输入。智能巡检算法融合上述场景与个体信息感知后，即可动态生成最优巡检路径，确保机器人在限定时间内高效覆盖所有目标，将规划路径实时反馈至控制模块，实现对巡检机器人的精确导航与避障控制，从而提升整体巡检效率与智能化水平。

3 讨 论

现有巡检路径规划研究较少考虑规模化养殖场内肉牛、奶牛等大型畜种个体的全局遍历和动态障碍物导致的局部可通行性优化问题。本研究聚焦于动态非结构化的规模养殖场环境，提出了一种融合全局和局部优化的规模化牛场动态多目标智能巡检路径规划算法，有效解决了传统算法在动态复杂养殖环境中无法巡检覆盖全部牛只个体、巡检效率低、缺少局部可通过性判断与主动避障能力，传统A*算法冗余节点多等问题。在全局遍历优化上，针对牛只个体的动态性与不确定性设计巡检路径生成策略，融合改进TSP和A*算法的全局巡检路径规划算法，实现对多个动态目标的巡检遍历：在TSP最近邻法中引入由牛只个体和养殖舍构建的巡检状态列表，确定多个养殖舍的最优巡检顺序和动态巡检路径；优化A*算法的数据结构和启发式函数，同时引入贪婪策略，构建养殖舍间的最佳移动路径。在局部通行优化上，在DWA中引入基于障碍物尺寸的动态安全阈值与巡检任务进度项，增强局部路径规划的可行性与鲁棒性，适应牛场巡检通道与未知障碍物。本研究所提出的算法未来可应用在牛、羊、猪等大型家畜个体的健康巡检上，从而提升规模养殖场个体巡检的质量与效率。

然而，本研究仍存在不足之处，有待在未来的研究中进一步完善。首先，在环境仿真建模层面，本研究的牛场动态仿真环境中个体移动模型尚未充分反映牛只群体性复杂行为特征，未来可引入群体动力学的复杂交互机制，基于力导向交互规则模拟牛只群体运动状态，通过参数化权重系数实现群体聚集、排斥、对齐的动态平衡。其次，因实际牛场巡检实验需集成SLAM、牛只个体身份识别、距离

检测等多种感知与识别模块，当前研究主要通过仿真实验对所提出的巡检路径规划算法进行了性能验证，尽管仿真环境在一定程度上复现了牛场的空间结构与动态干扰特性，但与真实环境仍存在一定差异，后续将进一步推进算法在规模化牛场的实地测试，针对实地测试中的环境感知挑战可考虑结合视觉语言导航（Vision-and-Language Navigation, VLN）[35] 构建动态语义地图，生成带牛只健康状态、障碍物等标注的语义栅格，并基于自然语言指令（如“优先检测妊娠舍”）提取任务语义，生成带语义约束的全局巡检路径，实现巡检路径优化与异常状态即时响应。最后，针对更大规模养殖场的复杂巡检需求，现有算法巡检任务分配机制灵活性不足，还需突破多机协作瓶颈，基于多智能体协同技术动态分配多机器人的巡检任务，拓展多机协同巡检框架，在全局路径中增加碰撞约束，通过分布式模型预测控制进行多机器人动态路径重规划；结合视频监控系统辅助观察巡检机器人视野范围外的个体，突破巡检盲区对算法效能的限制。

4 结 论

本研究聚焦于动态复杂场景下牛场巡检机器人的路径规划研究，通过深入剖析规模化牛场的环境特点和巡检任务需求，优化全局和局部路径规划算法，提出一种融合改进TSP、A*算法与DWA的规模化牛场动态多目标巡检路径规划方法，主要研究结论如下。

1）在TSP最近邻法中引入由牛只个体和养殖舍构建的巡检状态列表，确定多个养殖舍的最优巡检顺序和动态路径；优化A*算法的数据结构和启发式函数，同时引入贪婪策略，构建养殖舍间的最佳移动路径，相较于传统A*算法在规划时间、路径长度、转折次数、搜索节点数上分别平均减少了约90.06%、1.83%、85.13%、42%，实现了搜索效率与路径质量的协同优化。在牛场动态仿真场景下，全局巡检算法的平均巡检覆盖率达100%，巡检路径长度和时间较传统蚁群算法分别缩短了17.99%和20.85%，显著提高了巡检质量和效率。

2）在全局巡检路径中融合改进的局部通行优化算法DWA，增加基于障碍物尺寸的动态安全阈值和巡检任务进度项，可实现狭窄通道内动态障碍物引起的局部区域可通行性判别与提前主动避障，确保机器人安全、顺利地完成巡检任务。

3）融合全局和局部优化的巡检算法在包含动态/静态障碍物和牛只个体的牛场仿真场景下，能够实现一定时间内的牛只个体遍历和主动避障。巡检算法融合SLAM、牛只个体身份识别、距离检测等模块实现场景与个体信息感知后，即可动态生成最优巡检路径，确保在限定时间内安全、高效地覆盖所有巡检目标。

综上所述，本研究提出的融合全局和局部优化的动态多目标智能巡检路径规划算法能够在规模化牛场环境下实现牛只个体全局遍历和实时主动避障，有效提升了牛只个体巡检的效率和质量，为养殖场的智能化管理提供了技术支撑。

利益冲突声明：本研究不存在研究者以及与公开研究成果有关的利益冲突。

参考文献：

[1] SHARMA V, TRIPATHI A K, MITTAL H. Technological revolutions in smart farming: Current trends, challenges & future directions[J]. Computers and Electronics in Agriculture, 2022, 201: 107217.
[2] SHANG Z D, LI Z Y, WEI Q Z, et al. Livestock and poultry posture monitoring based on cloud platform and distributed collection system[J]. Internet of Things, 2024, 25: 101039.
[3] WILLEMS S, MOUNIR M, VAN HERTEM T, et al. Monitoring night-time activity and perch occupation of laying hens using night-vision cameras for the early detection of poultry red mite: A proof of concept[J]. Applied Animal Behaviour Science, 2025, 283: 106517.
[4] CHEN C S, CHEN W C. Research and development of automatic monitoring system for livestock farms[J]. Applied Sciences, 2019, 9(6): 1132.
[5] FAROOQ M S, SOHAIL O O, ABID A, et al. A survey on the role of IoT in agriculture for the implementation of smart livestock environment[J]. IEEE Access, 2022, 10: 9483-9505.
[6] ARULMOZHI E, DEB N C, TAMRAKAR N, et al. From reality to virtuality: Revolutionizing livestock farming through digital twins[J]. Agriculture, 2024, 14(12): 2231.
[7] REN G Q, LIN T, YING Y B, et al. Agricultural robotics research applicable to poultry production: A review[J]. Computers and Electronics in Agriculture, 2020, 169: 105216.
[8] ÖZENTÜRK U, CHEN Z Q, JAMONE L, et al. Robotics for poultry farming: Challenges and opportunities[J]. Computers and Electronics in Agriculture, 2024, 226: 109411.
[9] ROSERO-MONTALVO P D, ERAZO-CHAMORRO V C, LÓPEZ-BATISTA V F, et al. Environment monitoring of rose crops greenhouse based on autonomous vehicles with a WSN and data analysis[J]. Sensors, 2020, 20(20): 5905.
[10] 吕恩利, 韦鉴峰, 王昱, 等. 畜牧养殖环境监测自主移动平台轨迹跟踪控制算法[J]. 农业工程学报, 2018, 34(13): 86-94.
LÜ E L, WEI J F, WANG Y, et al. Trajectory tracking algorithm of autonomous mobile platform for animal husbandry environment information monitoring[J]. Transactions of the Chinese Society of Agricultural Engineering, 2018, 34(13): 86-94.
[11] LINAZA M T, POSADA J, BUND J, et al. Data-driven artificial intelligence applications for sustainable precision agriculture[J]. Agronomy, 2021, 11(6): 1227.
[12] CHEN Z J, WANG H F, ZHOU M C, et al. Design and experiment of an autonomous navigation system for a cattle barn feed-pushing robot based on UWB positioning[J]. Agriculture, 2024, 14(5): 694.
[13] ZHANG Y Y, TIAN K P, HUANG J C, et al. Field obstacle detec-

tion and location method based on binocular vision[J]. Agriculture, 2024, 14(9): 1493.
[14] YANG W J, WU J C, ZHANG J L, et al. Deformable convolution and coordinate attention for fast cattle detection[J]. Computers and Electronics in Agriculture, 2023, 211: 108006.
[15] 王璞, 刘宏杰, 周永录. 基于改进人工鱼群算法求解旅行商问题及多点路径规划[J]. 科学技术与工程, 2024, 24(35): 15090-15097.
WANG P, LIU H J, ZHOU Y L. Solving traveling salesman problem and multi-point path planning based on improved artificial fish swarm algorithm[J]. Science Technology and Engineering, 2024, 24(35): 15090-15097.
[16] 秦文龙, 罗贺, 李晓多, 等. 考虑多换电站的多无人机应急电力巡检路径规划方法[J]. 控制与决策, 2025, 40(8): 2391-2399.
QIN W L, LUO H, LI X D, et al. Multi-UAV emergency power inspection path planning method considering multiple charging stations[J]. Control and Decision, 2025, 40(8): 2391-2399.
[17] 乔道迹, 张艳兵. 多障碍环境下巡检机器人路径规划优化研究[J]. 现代电子技术, 2025, 48(1): 130-134.
QIAO D J, ZHANG Y B. Research on path planning optimization of inspection robot in multi-obstacle environment[J]. Modern Electronics Technique, 2025, 48(1): 130-134.
[18] 赵宁磊, 程曼, 袁洪波, 等. 羊舍自主巡检机器人设计与试验[J]. 中国农机化学报, 2025, 46(1): 78-84.
ZHAO N L, CHENG M, YUAN H B, et al. Design and experiment of autonomous inspection robot for sheep house[J]. Journal of Chinese Agricultural Mechanization, 2025, 46(1): 78-84.
[19] 毛建旭, 贺振宇, 王耀南, 等. 电力巡检机器人路径规划技术及应用综述[J]. 控制与决策, 2023, 38(11): 3009-3024.
MAO J X, HE Z Y, WANG Y N, et al. Review of research and applications on path planning technology for power inspection robots[J]. Control and Decision, 2023, 38(11): 3009-3024.
[20] 范铭铄, 周平, 李淼, 等. 羊场自动导航喷药机器人设计与实验[J]. 智慧农业(中英文), 2024, 6(4): 103-115.
FAN M S, ZHOU P, LI M, et al. Automatic navigation and spraying robot in sheep farm[J]. Smart Agriculture, 2024, 6(4): 103-115.
[21] 孙志强, 唐森洋, 罗兴发, 等. 农业巡检机器人路径规划研究应用现状[J]. 农业装备与车辆工程, 2025, 63(1): 18-24.
SUN Z Q, TANG S Y, LUO X F, et al. Research and application status of path planning for agricultural inspection robots[J]. Agricultural Equipment & Vehicle Engineering, 2025, 63(1): 18-24.
[22] ALMAZROUEI K, KAMEL I, RABIE T. Dynamic obstacle avoidance and path planning through reinforcement learning[J]. Applied Sciences, 2023, 13(14): 8174.
[23] LI H X, LUO B, SONG W, et al. Predictive hierarchical reinforcement learning for path-efficient mapless navigation with moving target[J]. Neural Networks, 2023, 165: 677-688.
[24] 马萧杰, 施新宇, 肖文星, 等. 基于TSP__RRT算法的柑橘多目标连续采摘路径规划[J]. 江西农业大学学报, 2024, 46(2): 490-501.
MA X J, SHI X Y, XIAO W X, et al. Multi-objective continuous picking path planning for *Citrus* based on TSP__RRT algorithm [J]. Acta Agriculturae Universitatis Jiangxiensis, 2024, 46(2): 490-501.
[25] 黄淼, 郝真鸣, 冉宁, 等. 配电室巡检机器人多目标点路径规划算法[J]. 电子测量技术, 2024, 47(16): 49-57.
HUANG M, HAO Z M, RAN N, et al. Multi-target point path planning algorithm for inspection robots in power distribution rooms[J]. Electronic Measurement Technology, 2024, 47(16): 49-57.
[26] PAPADOPOULOS G, PAPANTONATOU M Z, UYAR H, et al. Economic and environmental benefits of digital agricultural technological solutions in livestock farming: A review[J]. Smart Agricultural Technology, 2025, 10: 100783.
[27] PHYO C N, TIN P, ZIN T T. A Markov chain model for determining the optimal time to move pregnant cows to individual calving pens[J]. Sensors, 2023, 23(19): 8141.
[28] LIU L X, WANG X, YANG X, et al. Path planning techniques for mobile robots: Review and prospect[J]. Expert Systems with Applications, 2023, 227: 120254.
[29] 王中玉, 曾国辉, 黄勃, 等. 改进A*算法的机器人全局最优路径规划[J]. 计算机应用, 2019, 39(9): 2517-2522.
WANG Z Y, ZENG G H, HUANG B, et al. Global optimal path planning for robots with improved A* algorithm[J]. Journal of Computer Applications, 2019, 39(9): 2517-2522.
[30] 迟旭, 李花, 费继友. 基于改进A*算法与动态窗口法融合的机器人随机避障方法研究[J]. 仪器仪表学报, 2021, 42(3): 132-140.
CHI X, LI H, FEI J Y. Research on robot random obstacle avoidance method based on fusion of improved A* algorithm and dynamic window method[J]. Chinese Journal of Scientific Instrument, 2021, 42(3): 132-140.
[31] 王志特, 罗丽平, 廖义奎, 等. 适合复杂环境的改进A*路径规划算法[J]. 广西大学学报(自然科学版), 2024, 49(5): 1099-1111.
WANG Z T, LUO L P, LIAO Y K, et al. An improved A* path planning algorithm for complex environments[J]. Journal of Guangxi University (Natural Science Edition), 2024, 49(5): 1099-1111.
[32] GUO H P, LI Y, WANG H, et al. Path planning of greenhouse electric crawler tractor based on the improved A* and DWA algorithms[J]. Computers and Electronics in Agriculture, 2024, 227: 109596.
[33] ZHAO J L, DENG C S, YU H H, et al. Path planning of unmanned vehicles based on adaptive particle swarm optimization algorithm[J]. Computer Communications, 2024, 216: 112-129.
[34] XU X S, DENG H X, WANG Y F, et al. Boosting cattle face recognition under uncontrolled scenes by embedding enhancement and optimization[J]. Applied Soft Computing, 2024, 164: 111951.
[35] ZHANG Y, MA Z Q, LI J L, et al. Vision-and-language navigation today and tomorrow: A survey in the era of foundation models[EB/OL]. arXiv: 2407.07035, 2024.

Intelligent Inspection Path Planning Algorithm for Large-Scale Cattle Farms

CHEN Ruotong[1,2], LIU Jifang[1*], ZHANG Zhiyong[3], MA Nan[1,3], WEI Peigang[1,2], WANG Yi[1,2], YANG Yantao[4,5]

(1. *Agricultural Information Institute of CAAS*, *Beijing* 100081, *China*; 2. *National Agriculture Science Data Center*, *Beijing* 100081, *China*; 3. *College of Computer and Information Engineering*, *Xinjiang Agricultural University*, *Urumqi* 830052, *China*; 4. *Institute of Agricultural Economics and development of CAAS*, *Beijing* 100081, *China*; 5. *National Nanfan Research Institute* (*Sanya*) *of CAAS*, *Sanya* 572024, *China*)

Abstract: [Objective] Timely detection and early warning of livestock health issues are critical for green and efficient management

within large-scale cattle farms. Traditional manual inspections are time-consuming, labor-intensive, and prone to missed or erroneous detections. Robotic inspections offer significant advantages including all-weather operation, high precision, high efficiency, and low cost. However, existing path planning approaches predominantly focus on dynamic obstacle avoidance and fixed target point inspection path, often failing to address two key challenges in dynamic large-scale farm environments: global traversal of individual large livestock (e.g., beef cattle, dairy cows) and accessibility of local areas compromised by dynamic obstacles. This study aims to overcome the limitations of existing robotic inspection systems in large-scale cattle farms, specifically addressing the lack of comprehensive inspection capability for dynamic individuals, excessive path redundancy, and insufficient proactive obstacle avoidance capability. **[Methods]** A global-local optimization algorithm was proposed for large-scale cattle farm intelligent inspection path planning, which integrated the traveling salesman problem (TSP), A* and dynamic window approach (DWA), and solved the problems of global multi-objective individual traversal, path redundancy and local passability with proactive obstacle avoidance in dynamic cattle farm scenarios. For global traversal optimization, a global path planning algorithm was introduced which combined improved TSP and optimized A*. Specifically, the inspection status list tracking breeding sheds and individual cattle was maintained to enhance the TSP's Nearest Neighbor Algorithm, dynamically updating targets to avoid re-visits. A dynamic priority mechanism optimized multi-objective inspection, determining the optimal visitation sequence across barns and dynamic paths within barns. The data structure of the A* algorithm was optimized, a diagonal distance heuristic function was introduced to replace Manhattan distance, which more accurately reflected the movement cost in eight directions. The path obtained by the A* algorithm through greedy strategy was simplified, and Bresenham's line algorithm was used to check whether there were obstacles in the straight line field of view. If there were no obstacles, redundant inflection points were removed to construct an efficient moving path between sheds. For local passability optimization, an enhanced DWA-based local path was proposed for planning algorithm. The dynamic safety threshold of obstacle size was introduced to improve the DWA. When the inspection robot judged that the size of the obstacle in the local accessible area was too large and the robot was difficult to pass, it would actively avoid or detour in advance to ensure the safe avoidance of large obstacles in narrow passages. The improved DWA also increased the task progress potential field, drived the robot to move to the breeding shed to be visited with the attractive force field model, balanced the local obstacle avoidance and global inspection efficiency, and realized the real-time judgment of local area passability caused by dynamic obstacles and proactive obstacle avoidance in advance. **[Results and Discussions]** The optimized A* algorithm's data structures significantly improved search efficiency. The diagonal distance heuristic and greedy strategy substantially enhanced path smoothness. Compared to the traditional A*, the improved A* achieved average reductions of 90.06% in planning time, 85.13% in path turns, and 1.83% in path length. The global inspection algorithm combining improved TSP and optimized A* achieved 100% average coverage of individual cattle. Inspection path length and time were reduced by 17.99% and 20.85%, respectively, compared to the classic ant colony optimization (ACO) algorithm, demonstrating superior efficiency in dynamic multi-objective inspection scenarios. The improved DWA successfully enabled proactive judgment of local path passability based on obstacle size. By adjusting the robot's linear velocity, angular velocity, and attitude angle in real time, the algorithm achieved robust proactive obstacle avoidance. The inspection robot would reduce the linear velocity in advance when encountering obstacles, and realize proactive obstacle avoidance by adjusting the attitude angle. Simulation experiments confirmed that robots equipped with the improved DWA effectively navigated around unknown static and dynamic obstacles while maintaining global path-tracking capability. **[Conclusions]** The global inspection algorithm combining improved TSP and optimized A*, utilizing dynamic inspection status lists and path optimization techniques, achieved global inspection coverage of individual cattle and could significantly improve inspection quality and efficiency. The local inspection algorithm based on improved DWA, incorporating obstacle size dynamic safety threshold and task progress, achieved real-time judgment of local passability and proactive obstacle avoidance, ensuring safe robot navigation in complex environments. The global-local co-optimization framework demonstrated adaptability to the dynamic farm environment, enabling the timely completion of individual traversal tasks, and providing a robust solution for intelligent inspection in large-scale cattle operations. Future work involves integrating the proposed path planning algorithm with simultaneous localization and mapping (SLAM), cattle identification, distance detection systems on inspection robot platforms, and conducting extensive field tests within operational cattle farms. Exploring multi-robot collaborative inspection frameworks and incorporating the Vision-and-Language Navigation model to enhance environmental perception and anomaly-handling capabilities are promising directions for adapting to the complexities of even larger-scale farming scenarios.

Key words: intelligent inspection; multi-objective path planning; global individual traversal; local traffic obstacle avoidance; inspection robot; A*

Foundation items: National Key Research and Development Program of China (2024YFD2000305); The Nanfan Special Project of the National Nanfan Research Institute, Chinese Academy of Agricultural Sciences (YBXM2544)

First author: CHEN Ruotong, E-mail: CRT_1001@163.com

***Corresponding author:** LIU Jifang, E-mail: liujifang@caas.cn