

基于改进 Hopfiled 网络的机器人 路径优化控制

黄海龙¹, 蔡娟¹, 刘源²

(1. 广州科技职业技术大学 信息工程学院, 广州 510000;

2. 南京理工大学 电子工程与光电技术学院, 南京 210094)

摘要: 针对现有移动机器人路径优化算法存在的迭代效率低、路径规划距离长等问题, 提出一种基于改进 Hopfiled 神经网络的机器人路径优化算法; 在世界坐标系内对移动机器人空间运动进行了研究, 掌握移动机器人不同时刻的位置信息和移动信息; 构建 Hopfiled 神经网络模型, 并采用感知机优化 Hopfiled 神经网络模型的结构, 提升其数据训练能力; 同时利用 LSTM 网络的门控结构替代原网络隐含层的神经元, 引入遗忘门、输入门和输出门, 提升 Hopfiled 神经网络的泛化学习能力和样本容纳能力; 引入路径评价函数, 评价局部区域内的碰撞风险以降低移动机器人之间的碰撞概率; 经实验测试得出: 改进 Hopfiled 神经网络模型路径规划均值为 104.3 m, 耗时均值为 122.1 s, 随机提取采样点的方差值仅为 0.01, 显著低于其他的传统路径优化算法。

关键词: Hopfiled 神经网络; BP 网络; LSTM; 移动机器人; 路径优化

Robot Path Optimization Control Based on Improved Hopfiled Network

HUANG Hailong¹, CAI Juan¹, LIU Yuan²

(1. College of Information Engineering, Guangzhou Vocational and Technical University of Science and Technology,
Guangzhou 510000, China;

2. School of Electronic and Optical Engineering, Nanjing University of Science and Technology,
Nanjing 210094, China)

Abstract: Aiming at the problems of existing mobile robot path optimization algorithms, such as low iteration efficiency and long path planning distance, a machine path optimization algorithm based on improved Hopfiled neural network is proposed. The space motion of the mobile robot is studied in the world coordinate system, and the position and movement information of the mobile robot at different times are mastered. The Hopfiled neural network model is constructed, and the perceptron is used to optimize the structure of the Hopfiled neural network model to improve the ability of its data training. At the same time, the gating structure of the Long Short-Term Memory (LSTM) network is used to replace the neurons in the hidden layer of the original network, and the forgetting gates, input gates and output gates are introduced to improve the generalization learning and sample holding ability of the Hopfiled neural network. The path evaluation function is introduced to evaluate collision risk in local area to reduce collision probability between mobile robots. Experimental results show that the path planning average value of the improved Hopfiled neural network model is 104.3 m, the average time is 122.1 s, and the variance value of random sampling points is only 0.01, which is significantly lower than other traditional path optimization algorithms.

Keywords: hopfiled neural network; back propagation (BP) network; LSTM; mobile robot; path optimization

0 引言

伴随着计算机科学技术、人工智能技术、自动化控制技术 & 无线通信技术的飞速发展, 机器人的智能化水平不断提高, 应用场景也逐渐增多。当前, 机器人在智能加工制造、野外作业与救援、医疗服务、仓储物流和军事等领域, 都有较为广泛的应用。可移动机器人是智能机器人的一个重要门类^[1-2], 具体包括轮式机器人、双足机器人、多足机器人、爬墙机器人等, 可移动机器人内置了控制芯片、

通信模块、红外传感器、距离传感器、激光雷达等, 来综合获取周围的环境信息^[3-5], 与后台控制中心通信实时选取最经济的行进路径, 并同步躲避周围的静态或可移动得障碍物。路径优化是移动机器人控制最重要的一个环节, 而现有的移动机器人轨迹控制与路径规划算法^[6], 都对机器人的工作环境状态过度依赖, 在复杂路径环境下机器人行进高精度纠偏等方面存在不足。

文献 [7] 提出一种基于稀疏 A-STR 算法的路径规划方案, 稀疏 A-STR 算法是一种经典的启发式遍历算法,

收稿日期: 2024-08-07; 修回日期: 2024-08-27。

作者简介: 黄海龙(1984-), 男, 硕士研究生, 副教授。

引用格式: 黄海龙, 蔡娟, 刘源, 等. 基于改进 Hopfiled 网络的机器人路径优化控制[J]. 计算机测量与控制, 2024, 32(11): 204-210.

能够通过核查最短路径的同时兼顾全局信息, 并对当前位置到目的地有效距离进行评估并通过稀疏表示优化算法全局寻优乐力。但稀疏 A-STRA 算法在计算最优路径时需要保存大量节点的信息, 计算量大且无法识别出距离最近的路径; 文献 [8] 提出一种基于 GA 模糊优化控制的路径寻优算法 (Genetic Algorithm), 通过制定合理的模糊规则进行模糊推理, 最后再经过去模糊化处理选择出最优的移动机器人行进路径, 再利用 GA 算法提升算法的收敛性能。利用模糊控制算法寻找最佳的路径也存在模糊理论的固有缺点, 即模糊规则的制定缺乏系统性, 最优参数的选择和隶属度函数的选择难度较高, 路径规划的耗时较长; 文献 [9] 提出一种基于势场蚁群的路径寻优算法, 人工势场路径寻优方法的基本原理是将移动机器人运动环境, 模拟成为一个人工的引力和斥力场, 根据采集到的位置信息和障碍物信息综合判断与选择最佳的路径, 目的地会对移动机器人产生引力, 而障碍物会对移动机器人产生斥力, 蚁群优化算法强化了人工势场算法的全局寻优能力。但势场蚁群算法更适合于机器人局部的避障, 全局的路径寻优能力较弱。

近年来, 人工智能算法发展迅速尤其是以机器学习和神经网络为代表的智能算法^[10-11], 凭借其强大数据训练能力和模型复杂度可调整的优势, 受到了越来越多使用者的青睐。针对现有的移动机器人路径寻优算法存在的缺陷和不足, 本文提出一种基于 Hopfiled 网络的机器人路径寻优算法, Hopfiled 网络本质上是一种高效的反馈性循环神经网络, Hopfiled 网络的优势主要是在数据训练中可通过多次迭代和重新计算, 有效对能量函数进行约束, 且在数据输入后, 可以自适应调整参数提升了数据训练能力和效率。但经典的 Hopfiled 神经网络也存在一定局限性, 如记忆内容不可改变, 样本的学习能力较差, 当数据集规模过大或样本的复杂度过高时, 模式容易收敛至一个伪模式或陷入局部最优解。本文针对 Hopfiled 神经网络的缺点, 利用 BP 神经网络 (Back Propagation) 优化 Hopfiled 神经网络的结构, 提升模型的训练能力, 同步引入了 LSTM 模型 (Long Short-Term Memory 长短期记忆网络模型) 对 Hopfiled 神经网络进行性能上的优化, 提升神经元的记忆功能, 样本容纳能力和训练能力。此外, 还利用路径规划评价函数, 提升了移动机器人的局部避障能力。

1 移动机器人空间运动模型构建与移动位置控制

对可移动机器人的运动轨迹进行精确控制, 首先需要明确机器人在空间范围内的位置变化信息、运动过程和运动规律, 本文以仓储物流管理中常用的双轮差速移动机器人运动过程为例, 构建机器人的运动模型。双轮差速移动机器人的底盘包括两个驱动轮和一个万向轮^[12-13], 其中驱动轮电机配备编码器能够感知实时的速度^[14], 通过万向轮调整机器人的运动方向。当机器人直线运动时两个驱动轮之间并不会产生速度差, 而机器需要转向时由万向轮调整方向和角度, 两个驱动轮之间会出现速度差, 令机器人左

右轮的速度分别为 v_L 和 v_R , 当机器人向左转向时, 左轮、机器人重心 O 和右轮相当于同向做圆周运动, 半径分别为 r 、 $\frac{(r+d)}{2}$ 、 $r+d$, (d 为两个轮子之间的轮距), 此时在一个可以忽略的左右轮间隔时间 t 内左右轮行进的弧长 s_L 和 s_R , 分别表示如下:

$$\begin{cases} s_L = \theta \cdot r = v_L \cdot t \\ s_R = \theta \cdot (r+d) = v_R \cdot t \end{cases} \quad (1)$$

式中, θ 表示机器人的转向角度^[15]:

$$\theta = \left(\frac{v_R - v_L}{d} \right) t \quad (2)$$

当机器人的转向角度 θ 越小时两个轮子的轮速差越小, 当机器人直线运动式两个轮子同步运动, 轮速差为零。若整个机器人运动过程中的角速度和线速度分别为 ω 和 v , 则有:

$$\begin{bmatrix} v \\ \omega \end{bmatrix} = \begin{bmatrix} v_L \\ v_R \end{bmatrix} \begin{bmatrix} \frac{1}{2} & -\frac{d}{2} \\ \frac{1}{2} & \frac{d}{2} \end{bmatrix} \quad (3)$$

机器人带有无线通信模块和自动定位系统^[16], 与后台控制中心进行实时交互, 双轮差速移动机器人也内置了单片机用于局部地区的航迹推算和障碍物避让, 此时需要将双轮差速移动机器人置于世界坐标系内, 分析其局部航迹的变化情况, 具体如图 1 所示。




图 1 双轮差速移动机器人的航迹变化分析

在世界坐标系内 XOY 内机器人当前 t 时刻位置坐标 (x_t, y_t, θ_t) 与角速度、两个驱动轮线速度之间的关系表示如下:

$$\begin{bmatrix} \dot{x}_t \\ \dot{y}_t \\ \dot{\theta}_t \end{bmatrix} = \begin{bmatrix} v_L \\ v_R \\ \omega_t \end{bmatrix} \begin{bmatrix} \cos\theta & -\sin\theta & 0 \\ \sin\theta & \cos\theta & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (4)$$

在 $t+1$ 时刻机器人运动会产生增量, (x_t, y_t, θ_t) 对应的增量分别表示为 dx 、 dy 和 $d\theta$, 则下一时刻的坐标 $(x_{t+1}, y_{t+1}, \theta_{t+1})$ 表示如下:

$$\begin{bmatrix} x_{t+1} \\ y_{t+1} \\ \theta_{t+1} \end{bmatrix} = \begin{bmatrix} x_t \\ y_t \\ \theta_t \end{bmatrix} + \begin{bmatrix} \cos\theta & -\sin\theta & 0 \\ \sin\theta & \cos\theta & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} dx \\ dy \\ d\theta \end{bmatrix} \quad (5)$$

机器人运动过程中根据传感器获取的位置信息调整运行航迹,同时也将最新的数据上传至后台并接收后台控制中心的执行。机器人运动时的最优路径并不是初始路径,需要根据局部的具体情况变化适时调整行进轨迹并躲避移动障碍物和静态的障碍物。根据移动机器人空间位置信息做出动态的调整,机器人路径优化和实时调整对机器人算力和优化算法要求较高,最重要的一点是要对采集到的位置数据进行训练,并获取到下一时刻最优的路径,从全局总体规划和局部路径规划双重视角确保机器人所选择的路径为最佳路径。

2 改进的 Hopfiled 神经网络

2.1 Hopfiled 神经网络的构建

神经网络是一种模拟人脑神经元工作原理的信息处理与运算模型^[17-18],在移动机器人的运行过程中会实时采集位置信息并通过无线网络将信息传递给后台中心,在单位时间内会有海量的信息源传递回后台中心,这对于算法的选择和算法的在线运算能力提出较高的要求。在神经网络中包含了大量的神经元^[19-20],这些神经元互相连接并以分布式的方式存储于中间隐含层中,隐含层的复杂程度决定了神经网络的复杂程度,可以根据输入数据集的规模确定神经网络隐含层的层数,再根据神经元的连接特点和已有的拓扑结构而选择适合的激励函数。Hopfiled 神经网络是一种高效的反馈型神经网络,具有较为强大的自学习功能,通过对输入数据进行学习和记忆,适时调整网络权值系数并优化神经网络的拓扑结构。Hopfiled 神经网络的结构设计,如图 2 所示。




图 2 Hopfiled 神经网络的结构设计

Hopfiled 神经网络中的神经元个体的功能相当于一种感知器,神经元之间互相连接,可以解决神经网络固有的非线性二元逻辑运算复杂度过高或精度较差等问题。hopfiled 神经网络可以用向量 S 来表示:

$$S = \{s_1, s_2, \dots, s_n\} \tag{6}$$

式中, s_1, s_2 和 s_n 分别表示网络中对应的神经元,基于向量 S 来描述 Hopfiled 神经网络的瞬时数据训练状态,利用二进制规则 (0 或 1) 对 Hopfiled 神经网络中的节点 s_1, s_2 和 s_n 赋值,例如节点 s_i 和节点 s_j ,若有 $w_{ij} = w_{ji}$,则有 $w_{ii} = w_{jj} = 0$ 。

Hopfiled 神经网络中的任意两个节点都是采用双向链接的方式,节点是否进入工作状态取决于节点当前的激活值。当前节点的激活值达到了阈值范围,被触发而进入了激活状态,此时的输出值为 1,相反如果当前节点的激活值并没有达到被激活的状态,输出的值为 0。

2.2 基于感知机的结构优化

Hopfiled 神经网络中的激活函数又被称为能量函数,即函数根据节点的剩余能量和赋权比重决定输出值的选择,通常情况下节点的剩余能量高,节点的赋权值就越高。若两个对应的节点 s_i 和节点 s_j ,如果 s_i 的赋权高于 s_j 则 s_i 的输出值为 1, s_j 的赋权值为 0。由于 Hopfiled 神经网络中的隐含层神经元采用了分布式结构设计,每个节点的输出值会根据赋权值变化而进行适度调整,当节点的能量发生变化或节点的赋权值发生变化时,节点数据输出会出现相反的趋势,但过于频繁的输出值转换也将不断地消耗 Hopfiled 神经网络的总体能量。为进一步提升 Hopfiled 网络的泛化学习能力、数据训练能力和记忆能力,本文分别利用感知机和 LSTM 神经网络分别对 Hopfiled 神经网络的结构和记忆功能进行优化,其中感知机从结构对 Hopfiled 神经网络进行第一次化,提升 Hopfiled 神经网络的数据训练能力。感知机优势是分布式信息存储能力强,且具有较强的鲁棒性和泛化学习能力,经过结构优化后的 Hopfiled 神经网络结构,如图 3 所示。

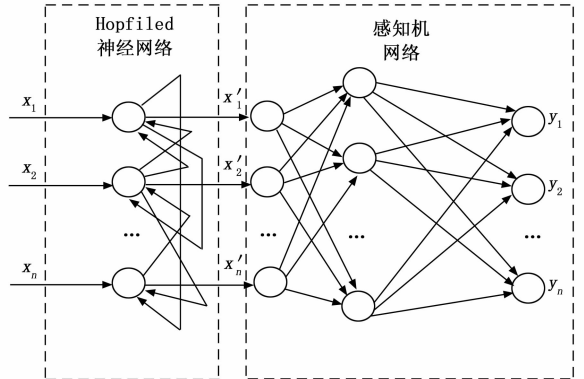


图 3 经过结构优化后的 Hopfiled 神经网络

经过结构优化后的 Hopfiled 神经网络,显著提升了对机器人空间位置信息、最优路径选择和局部障碍物避碰的数据训练能力。选取 m 个训练样本作为输入感知机的输入向量用 X'_k 表示:

$$X'_k = [x'_{k1}, x'_{k2}, \dots, x'_{kn}] (k = 1, 2, \dots, m) \tag{7}$$

优化后的 Hopfiled 神经网络输入层与隐含层、隐含层之间、及隐含层和输出层之间的神经元权向量分别为 W_1 、 W_2 和 W_3 ,按照二进制规则确定权向量矩阵。经过 N 次迭代后的输出的目标函数表示为 $Y_k(N)$:

$$Y_k(N) = [y_{k1}(N), y_{k2}(N), \dots, y_{km}(N)] \tag{8}$$

定义与 $Y_k(N)$ 对应的输出序列 E_k :

$$E_k = [e_{k1}, e_{k2}, \dots, e_{km}] \tag{9}$$

将 Hopfiled 神经网络各层之间的权向量进行初始化设置, 同时计算实际输出序列 $Y_k(N)$ 和期望输出序列 E_k 之间的差值 μ_k :

$$\mu_k = Y_k(N) - E_k \quad (10)$$

将 μ_k 作为是否进行下一次迭代的条件, 在数据训练过程中同步修正各层之间的权值, 以确保每次迭代后得到的差值 μ_k 呈逐步缩小的趋势。

2.3 LSMT 网络优化

Hopfiled 神经网络本质是一种循环神经网络有其固有的缺陷, 经过结构优化后网络的数据训练能力得到进一步提升, 但网络的记忆功能并没有得到实质性的改善。由 Hopfiled 神经网络中的神经元记忆内容无法有效适时调整和改变, 并没有较强的泛化学学习能力, 而且每个神经元的样本容量能力十分有限, 当输入样本的规模较大时或短时间内进入神经元的记忆样本数量过多时, Hopfiled 神经网络的数据记忆功能无法进入一个平衡状态。此外, Hopfiled 神经网络作为一种循环神经网络, 还容易出现梯度消失的问题, 经过感知机结构优化后, 无法解决循环神经网络存在的梯度问题。移动机器人的位置信息、移动信息会实时地传递到后台控制中心, 当数据集的规模较大且存在多源异构数据的条件下, Hopfiled 神经网络的记忆模式同步增加, 运算复杂度随之提升会导致路径优化算法的精度降低。针对结构优化后的 Hopfiled 神经网络依旧存在的问题, 本文选择利用 LSTM 网络模型对 Hopfiled 神经网络进行二次优化, 解决其存在的样本记忆功能差, 学习能力差及循环神经网络存在的梯度消失问题。

LSTM 网络模型是一种特殊的循环神经网络, 尽管它也采用了循环神经网络的链式结构, 但 LSTM 网络模型提升了神经元的复杂程度, 与之对应的神经元记忆功能也得到了显著改善, LSTM 网络结构示意图如图 4 所示。




图 4 LSTM 网络的神经元结构图

尽管都采用了链式结构, 但 LSTM 网络中的神经元结构相对于普通的循环神经网络要更加复杂, 如图 4 所示。普通的循环神经网络中的神经元较为简单, 包括一个或多个 \tanh 层, 而 LSTM 网络中的神经元结构由遗忘门、输入门和输出门构成, 结构更为复杂内部包含了 4 个网络层。利用 LSTM 网络中的神经元替代了 Hopfiled 神经网络中隐含层的神经元, 将有效提升神经网络模型的记忆能力和应对大规模数据集的处理能力。LSTM 网络神经元的链式结构中单元状态贯穿于整个神经元, 对于微小且波动较小,

不需训练处理的数值型数据直接从单元状态通道流过; 而对于非线性、多源异构且包含较多特征的数据需要借助输入门、遗忘门和输出门进行调节, 每个门对应的激活函数都选择 sigmoid 函数, 但权重和偏置会各不相同, sigmoid 函数 $\sigma(x_i)$ 表示如下:

$$\sigma(x_i) = \frac{1}{1 + e^{-x}} \quad (11)$$

式中, e 表示自然底数, 如图 4 的 LSTM 网络结构中, 第一层 F_t 表示当前 t 时刻的遗忘门, 决定了 Hopfiled 神经网络中神经元该剔除的信息:

$$F_t = \sigma_1(W_F \cdot (h_{t-1}, x_t) + b_F) \quad (12)$$

式中, σ_1 表示遗忘门的激活函数, W_F, b_F 分别表示遗忘门的权重和偏置, h_{t-1} 表示上一时刻的隐含层状态。LSTM 网络结构中第二层 I_t 表示输入层:

$$I_t = \sigma_2(W_I \cdot (h_{t-1}, x_t) + b_I) \quad (13)$$

式中, σ_2 表示输入门的激活函数, W_I, b_I 分别表示输入门的权重和偏置, 输入门负责训练和处理输入 Hopfiled 神经网络的移动机器人位置信息和运动轨迹数据。LSTM 网络结构中第三层为状态层, 描述神经元从上一 $t-1$ 时刻, 到当前 t 时刻再到下一 $t+1$ 时刻的状态变化:

$$C_t = \tanh(W_C \cdot (h_{t-1}, x_t) + b_C) \quad (14)$$

式中, C_t 表示神经元当前 t 时刻的状态, W_C, b_C 分别表示与 C_t 对应的权重和偏置, 在公式 (14) 中选择的激活函数为 \tanh 函数, 该函数的特点是映射值在 -1 到 1 区间, 更适合于添加数据的非线性特征。LSTM 网络结构中第四层为输出层 O_t :

$$O_t = \sigma_3(W_O \cdot (h_{t-1}, x_t) + b_O) \quad (15)$$

式中, σ_3 表示输入门的激活函数, W_O, b_O 分别表示输入门的权重和偏置。经过遗忘门、输入门和输出门的处理后, 当前 t 时刻隐含层 h_t 的输出数据表示如下:

$$h_t = O_t \cdot \tanh(C_t) \quad (16)$$

经过 LSTM 网络优化后的 Hopfiled 神经网络, 记忆能力得到显著提升, 同时循环网络固有的梯度消失或梯度弥散问题也可以得到显著抑制。

2.4 机器人坐标匹配路径规划及局部避碰控制

经过二次优化的 Hopfiled 神经网络具有较强的数据训练能力和较强的学习能力, 利用改进后的 Hopfiled 神经网络实时处理目标机器人的位置信息, 区域内其他机器人的位置信息, 根据事先规划好的路径及机器人的位置信息, 在躲避局部移动障碍物的前提下重新进行机器人的坐标匹配, 并规划出最优的行进路径, 算法的执行流程如图 5 所示。

在确定移动机器人的最优新进路径后, 还必须考虑到移动机器人的局部避碰问题, 因此在利用改进 Hopfiled 神经网络实时处理目标机器人的位置信息的同时, 引入路径评价函数, 综合评估移动机器人的当前位置与目的地的距离, 及在机器人行进路径中的其他移动障碍物 (其他工作中的

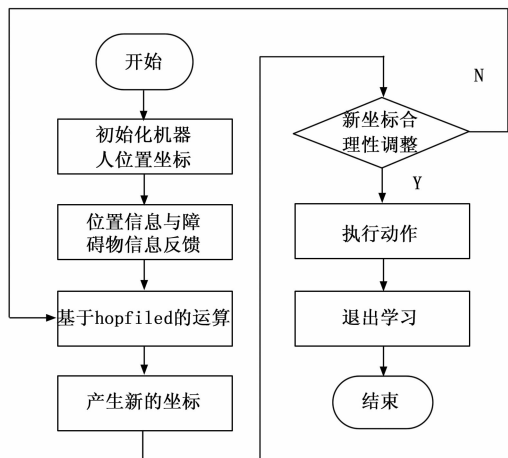


图 5 移动机器人的坐标匹配与路径寻优

移动机器人), 路径评价函数 L 表示如下:

$$L = \sum_{j=1}^M \sqrt{\left(\frac{D}{q}\right)^2 + (y_i - y_j)^2} \quad (17)$$

式中, M 表示工作场地中移动机器人的总数量, D 表示当前第 i 个机器人距离目的地的最近距离, q 表示在世界坐标系 x 轴映射等分值, y_i 表示当前移动机器人位置信息输出值, y_j 是与 y_i 距离最近的机器人位置信息输出值, 两者的差值越小证明避碰的风险越大, 当两者的差值为 0 时表明两台移动机器人已经发生了碰撞。路径评价函数 L 综合考虑了当前的移动机器人与目的地, 及与临近移动障碍物之间的关系, 为此特殊地引入了相交函数 G 辅助路径评价函数 L , 用于专门评估当前机器人与移动障碍物之间的位置关系:

$$G = \eta \sum_{j=1}^M \sum_{j=1}^N \sqrt{isacross(y_i, y_j)} \quad (18)$$

式中, η 为模型常数, $isacross(\cdot)$ 表示为相交函数, 在利用 Hopfiled 神经网络模型做瞬时数据训练时基于二进制规则 (0 或 1) 确定节点之间的权重, 在确定移动障碍物与当前机器人位置关系时依然采用二进制规则, 当 $isacross(\cdot)$ 输出结果为 0 时, 表明两者不相交, 当 $isacross(\cdot)$ 输出结果为 1 时, 表明两者出现了相交的情况, 可以根据 $isacross(\cdot)$ 的具体函数值确定局部区域内的移动机器人碰撞分析。本文针对于移动机器人的路径规划的避碰问题, 设计了一种基于 Hopfiled 神经网络的路径规划方案, 针对 Hopfiled 神经网络存在的固有缺点, 对网络的结构和学习能力进行了二次优化, 提升模型的训练能力同时解决了循环网络中存在的梯度弥散和梯度消失问题, 最后引入了评价函数和相交函数以解决移动机器人的局部避碰问题。

3 实验测试结果与分析

3.1 实验环境搭建

大型仓储物流中社会经济发展的重要节点, 随着仓储物流中心大型化、智能化趋势的到来, 智能物流机器人成为大型仓储物流的核心设备, 不仅能够节省大量的人

力成本, 还能够提升工作效率和出入库数据的准确性。实验环境设置选择了某大型仓储物流中心 (占地面积为 $60 \text{ m} \times 40 \text{ m}$), 可移动物流机器人负责对货物的送达和存取, 仓储物流中心共有 5 台同样配置的移动机器人同时工作, 机器人需要再制定好的时间周期内, 完成指定的人物, 同时还要避免与其他工作中的机器人发生碰撞, 实验的现场图和仓储物流中心的平面图, 分别如图 6 和图 7 所示。



图 6 仓储物流中心现场图




图 7 仓储物流中心平面布局图

实验用的移动机器人电机驱动总扭力为 200 N, 最大速度 1 m/s, 电机的其他参数设定, 如表 1 所示。

表 1 移动机器人相关参数设计

序号	参数	数值
1	电压	24 V
2	额定转速	2 500 rpm
3	主减速比	1:10
4	额定功率	200 W
5	整备质量	750 kg

机器人在控制中选择了光电式编码器和智能型双直流无刷控制马达, 内置了意法半导体的 STM32F103C8 型高性能单片机, 用于接收信号的处理及与后台上位机之间的通信信号处理。机器人配备了 360° 云台, 配备了高清摄像机, 导航摄像头和激光雷达, 其中高清摄像机的分辨率为 $1\,920 \times 1\,080$, 32 倍光学变焦用于采集和捕捉前端的景物; 导航

摄像头内置了通信模块, 负责控制机器人的行进方向和纠正; 激光雷达是一种主动传感器能够高精度测量距离, 且不受光照阴影等外界因素的影响。经过优化和改进的 Hopfiled 神经网络相关参数设定, 如表 2 所示。

表 2 改进 Hopfiled 神经网络相关参数设定

序号	参数	数值
1	隐含层层数	5
2	最大迭代次数	200
3	学习率	0.001
4	激活函数	Sigmiod
5	激活函数	Tanh
6	遗忘门权重	0.75
7	遗忘门偏置	2.45
8	输入门权重	0.70
9	输入门偏置	3.10
10	输出门权重	0.60
11	输出门偏置	2.50

3.2 实验数据对比分析

3.2.1 迭代次数对比

首先验证经过优化和改进的 Hopfiled 神经网络迭代收敛能力, 迭代收敛能力越强表明模型的训练能力和学习能力越强, 引入稀疏 A-STRR、GA 模糊算法和势场蚁群算法参与对比, 4 种控制算法参数设定都调整到最优状态, 对比结果如图 8 所示。




图 8 不同神经网络算法的迭代次数对比

数据统计结果显示, 在 40 s 的统计周期内, 经过改进的 Hopfiled 神经网络算法在 70 次完成了迭代, 而稀疏 A-STRR、GA 模糊算法和势场蚁群算法, 分别第 110 次、114 次和 120 次完成的迭代, 效率要低于改进的 Hopfiled 神经网络算法。

3.2.2 路径规划能力对比

路径规划能力考察的是算法在避免发生碰撞的前提下, 所选择路径的合理性, 算法的路径规划能力越强其从起始点到目标地的行进总体路程更少, 完成单次巡检任务的耗时更少效率更高。为了使算法的路径规划能力显示效果更加直观, 引入了稀疏 A-STRA 算法、GA 模糊控制算法和势场蚁群算法参与对比, 各算法从图 7 中起始点到目标地

路径规划距离对比和耗时对比, 具体如表 3 和表 4 所示 (实验次数设定为 5 次, 每次的起始地和目的地相同):

表 3 各算法的规划路径长度对比

实验次数	路径规划算法/m			
	本文算法	稀疏 A-STRA	GA 模糊	势场蚁群
1	105.5	131.4	111.2	117.2
2	103.2	120.1	109.7	118.7
3	105.1	116.5	112.3	117.4
4	104.2	113.4	118.4	119.6
5	103.5	115.6	121.3	127.0
均值	104.3	119.4	114.6	120.0

表 4 各算法的机器人的巡检耗时对比

实验次数	路径规划算法耗时/s			
	本文算法	稀疏 A-STRA	GA 模糊	势场蚁群
1	123.6	156.1	137.2	141.7
2	120.3	143.5	144.4	144.2
3	124.5	140.4	148.9	148.3
4	121.2	141.7	147.3	150.1
5	120.8	149.5	150.5	155.3
均值	122.1	146.2	145.7	147.9

各算法的行进路径距离统计结果显示, 在避免与其他机器人发生碰撞的前提下, 需要从全局规划和局部避碰两个视角综合考虑, 因此对算法的数值训练能力提出了较高的要求。本文提出的改进 Hopfiled 算法融合了 BP 神经网络的结构优势和 LSTM 算法的学习能力和记忆功能, 能够选择一条最优的路径, 5 次路程规划的均值为 104.3 m, 优于 5 种传统算法的表现, 这证明改进 Hopfiled 算法具有良好的轨迹规划能力, 可以节省机器人的行进路程。

移动机器人在工作中的行进速度通常保持稳定, 机器人所行进的路程越长, 耗时相对越长, 两者大致呈正比例的变化关系。本文提出的改进 Hopfiled 算法的耗时均值为 122.1 s, 也少于 3 种传统算法, 证明本文设计算法的时效性较好。

3.2.3 轨迹纠偏能力和避碰效果对比

轨迹纠偏能力是评价移动机器人控制的重要指标之一, 机器人运动中由于受到多种因素的影响会发展与设定轨迹的偏差, 实时纠偏可以确保机器人沿着既定路线前进, 也能够有效规避机器人之间的碰撞。随机选择一条机器人的行进路径 (包括直线路径和弯路路径), 分别应用本文算法和 3 种传统方法随机标定和采集 10 个采样点, 分析这 10 个采样点的位置偏差情况, 统计结果如表 5 所示。

各采样点得出的方差值越小表明波动值越小, 整体的行进路径越趋近于理论路径, 本文改进 Hopfiled 算法的方差值仅为 0.01, 远优于 3 种传统算法。最后统计在 5 次路径规划中各算法出现的机器人碰撞情况, 具体统计结果如图 9 所示。

表 5 各算法的标定点的偏差情况

实验次数	移动机器人路径标定点偏差/m			
	本文算法	稀疏 A-STAR	GA 模糊	势场蚁群
1	0.15	0.40	0.35	0.25
2	-0.10	0.34	-0.31	0.28
3	0.13	0.41	0.40	0.33
4	0.09	-0.30	-0.42	-0.33
5	-0.15	-0.31	-0.41	-0.34
6	0.15	-0.29	-0.35	-0.40
7	0.08	0.30	0.31	-0.41
8	-0.07	0.30	0.29	0.33
9	0.06	-0.38	-0.30	0.35
10	0.10	-0.31	-0.30	0.35
方差值	0.01	0.11	0.11	0.12




图 9 各算法的碰撞次数统计

在相对有限的空间内多台机器人同时作业，发生碰撞的风险会显著提升，尤其在通信不畅或通信延迟情况下更容易发生碰撞，这对于机器人的视觉硬件配置和软件算法的避障能力均提出了更高的要求。本文提出的改进 Hopfiled 算法利用 LSTM 网络模型的记忆功能和学习能力强化了其具备避障性能，因此在实验中未出现碰撞情况，其他 3 种算法均出现了 1~3 次的碰撞，造成了一定的损失。

4 结束语

近年来，可移动机器人控制技术不断进步，控制精度、控制效率和可靠性都有了显著提升，移动机器人开始在多个领域被广泛使用。在相对复杂的场景中，会存在静态障碍物，机器人在行进中需要必然障碍物，而且可能还会出现多台机器人同时作业的情况，机器人之间互为动态障碍物。由此可见，移动机器人的轨迹规划不仅要考虑到最优路径，还要兼顾到局部区域的移动障碍物干扰。Hopfiled 网络是一种高校的循环神经网络，但经典 Hopfiled 网络存在一定问题，比如，自学习能力较强但泛化学习能力较差，样本容量不足，记忆功能较差等，本文对 Hopfiled 网络进行了二次优化，既改进了网络结构又利用 LSTM 优化了隐含层神经元的学习能力和数据训练能力，同时也改善了循环神经网络固有的梯度弥散问题。实验结果显示，经过二次改进的 Hopfiled 神经网络具有更强的路径规划能力和局部避障能力。深度神经网络算法是现阶段较为热门的优化算法之一，但不同类型的神经网络有其优势，也尤其固有缺陷，如果根据实践需求将不同神经网络进行有机融合，

以达到取长补短的效果，将会极大地拓展深度神经网络的应用场景。

参考文献:

- [1] 叶鸿达, 黄山, 涂海燕. 基于改进 Bi-RRT 算法的移动机器人路径规划 [J]. 电光与控制, 2022, 29 (2): 76-81.
- [2] 刘金辉, 陈孟元, 韩朋朋, 等. 面向移动机器人视角运动的图神经网络视觉 SLAM 算法 [J]. 系统仿真学报, 2024, 36 (5): 1043-1060.
- [3] 黄梦涛, 李智伟. 改进 ARA* 算法的移动机器人路径规划 [J]. 计算机工程与应用, 2022, 58 (24): 291-297.
- [4] 王旭, 朱其新, 朱永红. 面向二维移动机器人的路径规划算法综述 [J]. 计算机工程与应用, 2023, 59 (20): 51-66.
- [5] 杨帆, 李玮, 严天宏. 基于梯度优化的移动机器人路径规划算法 [J]. 现代电子技术, 2023, 46 (21): 99-104.
- [6] 李诣坤, 韦思亮. 无人仓多搬运机器人协同作业轨迹自动控制研究 [J]. 计算机测量与控制, 2023, 31 (2): 115-121.
- [7] 蒋承杰, 朱华, 谢瑶, 等. 基于改进 A* 算法的移动机器人的路径规划 [J]. 制造技术与机床, 2024 (6): 33-36, 73.
- [8] 程志远, 方聪, 李峥, 等. 变论域自适应模糊控制在机器人无线充电中的研究 [J]. 电气传动, 2022, 52 (1): 54-59, 75.
- [9] 郑维, 王昊, 王洪斌. 动态环境下基于自适应步长 Informed-RRT* 和人工势场法的机器人混合路径规划 [J]. 计量学报, 2023, 44 (1): 26-34.
- [10] 于军琪, 陈易圣, 冯春勇, 等. 智能建造机器人局部路径规划研究综述 [J]. 计算机工程与应用, 2024, 60 (10): 16-29.
- [11] 侯建军, 毛轶超, 陈利, 等. 基于 AHP 层次分析法的履带式智能消防机器人设计研究 [J]. 包装工程, 2023, 44 (10): 172-180.
- [12] 郭忠峰, 徐博闻. 机械差速式管道机器人运动特性及仿真分析 [J]. 沈阳工业大学学报, 2022 (3): 295-300.
- [13] 刘延彬, 姜媛媛. 基于路标点追踪的差速驱动机器人运动规划 [J]. 控制与决策, 2023, 38 (9): 2529-2536.
- [14] 丁皓, 刘浩宇, 庄逸, 等. 基于四轮差速模型的多机器人路径规划 [J]. 控制工程, 2023, 30 (4): 730-738.
- [15] 姜俊豪, 陈刚. 驾驶机器人转向操纵的动态模型预测控制方法 [J]. 上海交通大学学报, 2022 (5): 594-603.
- [16] 李文华, 张英杰, 张铁柱, 等. 穿地龙机器人液压冲击与转向机构研究 [J]. 机械设计, 2022 (9): 42-45.
- [17] 黄颖, 顾长贵, 杨会杰. 神经网络超参数优化的删除垃圾神经元策略 [J]. 物理学报, 2022, 71 (16): 77-85.
- [18] 周雅, 栗心怡, 武喜艳, 等. 基于 DT-LIF 神经元与 SSD 的脉冲神经网络目标检测方法 [J]. 电子与信息学报, 2023, 45 (8): 2722-2730.
- [19] 王凤娟, 吕攀, 金欧文, 等. 神经元计算机操作系统的资源分配方法 [J]. 计算机研究与发展, 2023, 60 (9): 1948-1959.
- [20] 王淑青, 鲁濠, 鲁东林, 等. 基于轻量化人工神经网络的 PCB 板缺陷检测 [J]. 仪表技术与传感器, 2022 (5): 98-104.