

文章编号: 1000-8152(2004)03-0345-06

动态未知环境下一一种 Hopfield 神经网络路径规划方法

樊长虹, 陈卫东, 席裕庚

(上海交通大学 自动化研究所, 上海 200030)

摘要: 针对动态未知环境下移动机器人路径规划问题, 采用一种有效的局部连接 Hopfield 神经网络(Hopfield neural networks HNN)来表示机器人的工作空间. 机器人在 HNN 所形成的动态数值势场上进行爬山搜索法来形成避碰路径, 并且不存在非期望的局部吸引点. HNN 权值设计中考虑了路径安全性因素, 通过在障碍物附件形成局部虚拟排斥力来形成安全路径. HNN 的连接权是非对称的, 并且考虑了信号传播时延. 分析了 HNN 的稳定性, 所给稳定性条件和时延无关. HNN 模型中突出了最大传播激励, 从而使得 HNN 具有更广的稳定性范围并能表示具有更多节点的机器人工作空间. 为对该 HNN 有效仿真求解, 结合约束距离变换和 HNN 的时延性, 给出了单处理器上高效的串行模拟方案, 规划路径的时间复杂度为 $O(N)$ (N 是 HNN 中神经元的数目), 使得路径重规划能快速在线进行. 仿真和实验表明该方法的有效性.

关键词: 移动机器人; 动态未知环境; 路径规划; 时延神经网络; 约束距离变换

中图分类号: TP242 **文献标识码:** A

Hopfield neural networks for path planning in dynamic and unknown environments

FAN Chang-hong, CHEN Wei-dong, XI Yu-geng

(Institute of Automation, Shanghai Jiao Tong University, Shanghai 200030, China)

Abstract: To deal with the path planning of mobile robot in dynamic and unknown environment, an efficient and locally connected Hopfield neural network (HNN) is proposed to represent the workspace of the robot. The robot dynamically traced the numerical potential field of the HNN by hill climbing method to find the collision-free path without any unexpected local attractive points. The safety of the planned path was considered in the weight design of the HNN, and local virtual repulsive forces were formed around obstacles to generate safe path. The HNN model considered the time delay of signal diffusion and had asymmetric weights. The stability of the HNN was analyzed and the given stable condition of the HNN was independent on the time-delay of signal diffusion. Because the model emphasizes on the diffusion of maximal stimulation, the given stable condition is more relaxed and leads the HNN to represent a large workspace with more grids. To efficiently simulate the HNN, combining the constrained distance transformation and the delays in HNN, sequential simulation of the HNN on a single processor is proposed to plan path in $O(N)$ time, where N is the number of the nodes of the HNN. The $O(N)$ time complexity of sequential simulation accelerates the path re-planning on-line. The simulations and experiments demonstrate the effectiveness of the method.

Key words: mobile robot; dynamic and unknown environment; path planning; time-delayed neural network; constrained distance transformation

1 引言(Introduction)

动态未知环境下路径规划是移动机器人研究的一个重要问题. 此时机器人工作空间多以栅格方法描述^[1], 可用基于队列优先的 Dijkstra 算法^[2]进行搜索, 建立全局数值势场进行规划, 时间复杂度 $O(N \lg N)$. 全局数值势场不会让机器人陷入局部极值点. 但动态环境中 Dijkstra 算法重新计算数值势场

时, 较难利用原有的数值势场信息. 文献[3~5]利用局部连接的 HNN 建立全局数值势场, 进行动态未知环境下路径规划, 并行计算时间复杂度为 $O(N)$. HNN 方法中障碍物的出现或消失对环境影响被 HNN 节点隐含地表示, 而 HNN 稳定性促进了局部路径修正或全局路径重规划.

文献[3~5]中 HNN 模型均为对称连接且没有

考虑信号传播时延.考虑这两种因素具有一定意义:
1) 路径安全性等会造成栅格之间连接是非对称,需用非对称连接 HNN 表示. 2) 信号传播时延在 HNN 中是客观存在的.

本文提出一种新的局部连接 HNN 进行动态未知环境下移动机器人的路径规划,该 HNN 为非对称连接并具有时延.考虑路径安全性因素,给出了连接权设计,并分析了全局稳定性.利用 HNN 时延性,提出了基于约束距离变换的串行计算,加快了稳定数值势场的形成,使得判断是否存在可行路径和形成优化路径的时间复杂度为 $O(N)$. 仿真和实验表明该方法能在动态环境下快速有效进行在线路径规划.

2 HNN 模型(HNN model)

2.1 HNN 表示(Representation of HNN)

环境为二维有界栅格环境,用图 1 所示局部连接 HNN Net 表示^[3-5]. Net 的每个神经元对应于环境中一个栅格,并且和 $2d = 4$ 个相邻神经元连接.

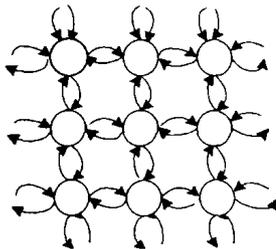


图 1 HNN 示意图
Fig. 1 Diagram of HNN

2.2 神经元模型(Neuron model)

Net 中共有 N 个神经元;第 i 个神经元输出为 $x_i(t)$,而 i 的 1-邻域内神经元集合为 NE_i ,路径目标节点相应神经元为 T_{set} ,仅对 T_{set} 具有外部定常输入 $I(I > 0)$.

本文所构造 HNN 的第 i 个神经元微分方程为

$$\begin{cases} \dot{x}_i = -Ax_i(t) + D_i(t)y_i(t) + u(i), & (1) \\ y_i(t) = g(\alpha \max_{j \in NE_i} \omega_{ij} x_j(t - \tau_{ij}(t)) + \beta \sum_{j \in NE_i} \omega_{ij} x_j(t - \tau_{ij}(t))), \\ b \geq \tau_{ij}(t) \geq 0 \text{ for any } i, j, t. \end{cases} \quad (2)$$

式(1)中: $A > 0$ 为神经元 i 自身负反馈系数;当 $i = T_{set}$ 时 $u(i) = I$,反之 $u(i) = 0$; $D_i(t)$ 反映了 T 时刻对环境的观测信息. i 位置为障碍物时 $D_i(t) = 0$;反之 $D_i(t) = 1$.

式(2)表示神经元 i 所有 1-邻域节点输出加权

和对 i 的激励; $g(z)$ 连续, $g(0) = 0$ 且满足 Lipschitz 条件: $0 < [g(z_1) - g(z_2)] / (z_1 - z_2) \leq m (z_1 \neq z_2)$; $\alpha \geq 0, \beta \geq 0$ 且不同时为 0. $\omega_{ij} \in (0, 1]$, 不要求对称.

将式(2)中右端时延量排成列向量,记为 $x^r(t) = [x_j(t - \tau_{ij}(t))]_{N0 \times 1}$,且 $N0$ 表示所有神经元之间交互连接数目.所有神经元所组成系统的微分方程记为

$$\dot{x}(t) = -Ax(t) + G(x^r(t)) + u. \quad (3)$$

其中 $G(x^r(t))$ 的第 i 个分量等于 $D_i(t)y_i(t)$.

2.3 权值设计(Weight design)

在文献[3,5]的 HNN 路径规划中,都没有考虑到路径安全性,只是规划出最短路径.但最短路径经常紧贴着障碍物,不利于移动机器人的安全;尤其所规划路径离动态障碍物过近,更是不利.本文通过减小障碍物附近节点连接权,减小其响应,在障碍物附近形成局部虚拟排斥力,所规划出来的路径不会贴近障碍物.下面给出权值设计方法.

设神经元 i 到最近障碍物的 4-连通距离为 d_i , 根据对环境离散化时所选取的栅格尺寸与机器人自身尺寸大小,选取安全距离门限值 D_{safe} : 当 $d_i < D_{safe}$ 时,快速减小 ω_{ij} ;反之 $\omega_{ij} = 1$. 为此选择 $\omega_{ij} = [m(\alpha + 2d\beta)/A]^{fs(d_i)}$ (在后面的稳定性条件中要求 $A > m(\alpha + 2d\beta)$, 即 $m(\alpha + 2d\beta)/A < 1$), 其中

$$fs(d_i) = \begin{cases} ks/d_i, & \text{if } 0 < d_i < D_{safe}, \\ 0, & \text{otherwise.} \end{cases} \quad (4)$$

2.4 HNN 机理(Mechanism of HNN)

HNN(3)的每个神经元具有隐含性质:从接受域中选择输出最大激励作为自身主要输入激励,即神经元之间存在着竞争,并通过自身对所选择的最大激励压缩后,进一步向更远的神经元传播.如果神经元 i 和 T_{set} 之间存在可行路径,那么当该神经元被扩展后,只要在接收域中选择具有最大激励神经元当作下一步的后继神经元,通过一系列的后继神经元选取,将回溯到 T_{set} ,形成从 i 到 T_{set} 的最快上升路径.

3 稳定性分析(Stability analysis)

下面先引入 Halanay 不等式,分析 HNN(3)全局稳定性.定义标量函数 $p(t)$ 的 Dini 导数为

$$D^+ p(t) = \lim_{h \rightarrow 0^+} [p(t+h) - p(t)]/h.$$

Halanay 不等式^[6] 给定 $b \geq 0$, 函数 $v: [t_0 - b, \infty) \rightarrow \mathbb{R}^+$ 连续,并对任意 $t \geq t_0$ 有

$$D^+ v(t) \leq -Wv(t) + Z \sup_{t-b \leq s \leq t} v(s).$$

其中 $W > Z > 0$, 必有 $k, \gamma > 0$ 使

$$v(t) \leq k \exp[-\gamma(t - t_0)] (t \geq t_0),$$

即当 $t \rightarrow \infty$ 时, $v(t)$ 指数收敛于0.

设对不同初始状态 HNN(3)有

$$y_i^1(t) = g(\alpha \max_{k \in NE_i} \omega_{ik} x_k^1(t - \tau_{1ik}(t)) + \beta \sum_{k \in NE_i} \omega_{ik} x_k^1(t - \tau_{1ik}(t))), \quad (5)$$

$$y_i^2(t) = g(\alpha \max_{l \in NE_i} \omega_{il} x_l^2(t - \tau_{2il}(t)) + \beta \sum_{l \in NE_i} \omega_{il} x_l^2(t - \tau_{2il}(t))), \quad (6)$$

并记 $x^{\tau^1}(t) = [x_k^1(t - \tau_{1ik}(t))]_{N0 \times 1}$, $x^{\tau^2}(t) = [x_l^2(t - \tau_{2il}(t))]_{N0 \times 1}$, 则 HNN(3)满足定理1.

定理1 对任意节点 i 有

$$\|G(x^{\tau^1}(t)) - G(x^{\tau^2}(t))\|_{\infty} \leq m(\alpha + 2d\beta) \sup_{t-b \leq v \leq t} \|x^{\tau^1}(v) - x^{\tau^2}(v)\|_{\infty}.$$

证 分两步证明. 1) 对任意节点 i 先证明:

$$|\max_{k \in NE_i} \omega_{ik} x_k^1(t - \tau_{1ik}(t)) - \max_{l \in NE_i} \omega_{il} x_l^2(t - \tau_{2il}(t))| \leq \|x^{\tau^1}(t) - x^{\tau^2}(t)\|_{\infty} \leq \sup_{t-b \leq v \leq t} \|x^{\tau^1}(v) - x^{\tau^2}(v)\|_{\infty}.$$

不妨设

$$|\max_{k \in NE_i} \omega_{ik} x_k^1(t - \tau_{1ik}(t))| \geq |\max_{l \in NE_i} \omega_{il} x_l^2(t - \tau_{2il}(t))|.$$

记 $s = \arg \max_{k \in NE_i} \omega_{ik} x_k^1(t - \tau_{1ik}(t))$, 有

$$\max_{k \in NE_i} \omega_{ik} x_k^1(t - \tau_{1ik}(t)) \geq \omega_{is} x_s^2(t - \tau_{2is}(t)),$$

$$|\max_{k \in NE_i} \omega_{ik} x_k^1(t - \tau_{1ik}(t)) - \max_{l \in NE_i} \omega_{il} x_l^2(t - \tau_{2il}(t))| =$$

$$\max_{k \in NE_i} \omega_{ik} x_k^1(t - \tau_{1ik}(t)) - \max_{l \in NE_i} \omega_{il} x_l^2(t - \tau_{2il}(t)) \leq$$

$$\omega_{is} x_s^1(t - \tau_{1is}(t)) - \omega_{is} x_s^2(t - \tau_{2is}(t)) \leq$$

$$x_s^1(t - \tau_{1is}(t)) - x_s^2(t - \tau_{2is}(t)) \leq$$

$$\|x^{\tau^1}(t) - x^{\tau^2}(t)\|_{\infty} \leq \sup_{t-b \leq v \leq t} \|x^{\tau^1}(v) - x^{\tau^2}(v)\|_{\infty}.$$

2) 根据函数 g 的 Lipschitz 性质, 可得

$$|y_i^1(t) - y_i^2(t)| =$$

$$|g(\alpha \max_{k \in NE_i} \omega_{ik} x_k^1(t - \tau_{1ik}(t)) + \beta \sum_{k \in NE_i} \omega_{ik} x_k^1(t - \tau_{1ik}(t))) -$$

$$g(\alpha \max_{l \in NE_i} \omega_{il} x_l^2(t - \tau_{2il}(t)) + \beta \sum_{l \in NE_i} \omega_{il} x_l^2(t - \tau_{2il}(t)))| \leq$$

$$m\alpha \max_{k \in NE_i} \omega_{ik} x_k^1(t - \tau_{1ik}(t)) - \max_{l \in NE_i} \omega_{il} x_l^2(t - \tau_{2il}(t))| +$$

$$m\beta \left| \sum_{k \in NE_i} \omega_{ik} x_k^1(t - \tau_{1ik}(t)) - \sum_{l \in NE_i} \omega_{il} x_l^2(t - \tau_{2il}(t)) \right| \leq$$

$$m\alpha \sup_{t-b \leq v \leq t} \|x^{\tau^1}(v) - x^{\tau^2}(v)\|_{\infty} +$$

$$m\beta \left| \sum_{k \in NE_i} |x_k^1(t - \tau_{1ik}(t)) - x_k^2(t - \tau_{2ik}(t))| \leq$$

$$m(\alpha + 2d\beta) \sup_{t-b \leq v \leq t} \|x^{\tau^1}(v) - x^{\tau^2}(v)\|_{\infty}.$$

由式(3)和 ∞ -范数定义, 知命题成立. 定理1得证.

需指出 $G(x^{\tau^1}(t)) - G(x^{\tau^2}(t))$ 和 $x^{\tau^1}(v) - x^{\tau^2}(v)$ 的维数不同, 分别为 N 和 $N0$.

定理2 $A > m(\alpha + 2d\beta)$ 时, HNN(3)至少有一个平衡点 x_e .

证 当式(3)存在平衡点时, 平衡点和时延变量 $\tau_{ij}(t)$ 无关, 故在平衡点分析中取所有时延变量为 $\tau_{ij}(t) = 0$; 构造映射 $F(x) = x + h(-Ax + G(x) + u)$, 只需要证明对于某些 $h > 0$, $F: \mathbb{R}^N \rightarrow \mathbb{R}^N$ 有唯一不动点即可. 根据定理1有

$$\|G(x_1) - G(x_2)\|_{\infty} \leq m(\alpha + 2d\beta) \|x_1 - x_2\|_{\infty}. \quad (7)$$

故

$$\begin{aligned} \|F(x_1) - F(x_2)\|_{\infty} &= \|(1-hA)(x_1 - x_2) + h(G(x_1) - G(x_2))\|_{\infty} \leq \\ &|1-hA| \|x_1 - x_2\|_{\infty} + h \|G(x_1) - G(x_2)\|_{\infty} \leq \\ &[|1-hA| + mh(\alpha + 2d\beta)] \|x_1 - x_2\|_{\infty}. \end{aligned} \quad (8)$$

当 $A > m(\alpha + 2d\beta)$ 和 $0 < h < 2[A + m(\alpha + 2d\beta)]^{-1}$ 时, 可验证 $|1-hA| + mh(\alpha + 2d\beta) < 1$ 成立, 即映射 F 压缩系数小于1. 又空间 \mathbb{R}^N 完备, 由不动点定理知 F 是压缩映射且有唯一不动点 x_q , 即

$$\begin{aligned} x_q &= F(x_q) = \\ x_q + h(-Ax_q + G(x_q) + u) &\Rightarrow \\ -Ax_q + G(x_q) + u &= 0, \end{aligned} \quad (9)$$

即此时式(3)至少具有一个平衡点 $x_e = x_q$. 定理2得证.

设对任意 $x(0) = x_0$, HNN(3)输出为 $x(t)$, 记 $e(t) = x(t) - x_e$, $e_0 = x_0 - x_e$, 且

$$\dot{e}(t) = -Ae(t) + G(x^{\tau}(t)) - G(x_e). \quad (10)$$

定理3 $A > m(\alpha + 2d\beta)$ 时, HNN(3)全局指数收敛于 x_e .

证 当 $t + h > t \geq 0$ 时, 根据式(10)有

$$\begin{aligned} e(t+h) &= \exp(-Ah)e(t) + \\ \int_t^{t+h} \exp[-A(t+h-p)] [G(x^{\tau}(p)) - G(x_e)] dp, \end{aligned} \quad (11)$$

$$\begin{aligned} (\|e(t+h)\|_{\infty} - \|e(t)\|_{\infty})/h &\leq \\ \{[\exp(-Ah) - 1] \|e(t)\|_{\infty} + \end{aligned}$$

$$\int_t^{t+h} \exp[-A(t+h-p)] \|G(x^\tau(p)) - G(x_e)\|_\infty dp / h. \tag{12}$$

注意 $[x(v) - x_e]_{N_0 \times 1} (p - b \leq v \leq p)$ 中任一个元素的绝对值都小于 $\sup_{p-b \leq v \leq p} \|e(v)\|_\infty$, 根据定理 1 得

$$\|G(x^\tau(p)) - G(x_e)\|_\infty \leq m(\alpha + 2d\beta) \sup_{p-b \leq v \leq p} \|e(v)\|_\infty. \tag{13}$$

结合式(13), 并对式(12)取极限 $h \rightarrow 0$, 有

$$D^+ \|e(t)\|_\infty \leq -A \|e(t)\|_\infty + m(\alpha + 2d\beta) \sup_{t-b \leq v \leq t} \|e(v)\|_\infty \tag{14}$$

结合 Halanay 不等式, $A > m(\alpha + 2d\beta)$ 时, $\|e(t)\|_\infty$ 指数渐近收敛于 0, 即 HNN(3) 指数收敛于 x_e . 定理 3 得证.

定理 3 还表明定理 2 中平衡点 x_e 是唯一的.

模拟中选取积分步长 $h = 1/A$ 进行 Euler 积分, 即

$$x_i(k+1) = x_i(k) + h \dot{x}_i(k) = x_i(k) + \dot{x}_i(k)/A. \tag{15}$$

4 HNN 路径规划和串行模拟(Path planning)

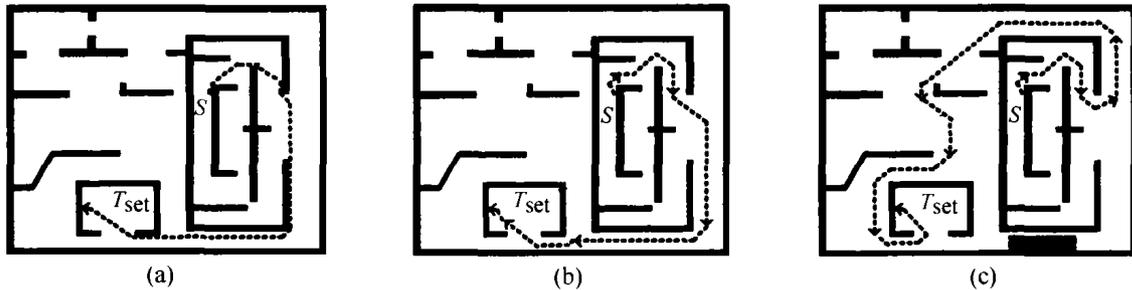


图 2 不同参数的 HNN 路径规划
Fig. 2 Paths planned by HNN with different parameters

4.2 串行模拟(Sequential simulation)

文献[4]指出对局部连接 HNN 用伪并行仿真路径规划的时间复杂度为 $O(N^2)$, 随环境解析度增大, 伪并行仿真不能满足在未知环境中路径规划实时性要求.

下面给出基于约束距离变换的串行模拟方法. 串行模拟相当于假设信号在 HNN 中传播速度足够快, 某个节点当前更新的状态能立即被其周围相邻的节点所应用. 而约束距离变换指导的串行模拟则是在 HNN(3) 中人为指定了时延大小, 时延小的神经元优先被更新, 而时延大的神经元被放在后面更新; 而对神经元仿真顺序的选取, 由基于广度优先搜索^[2]的行列约束距离变换分别来决定. 通过交替执行行列约束距离变换模拟, 加快了 HNN 势场传播,

and sequential simulation of HNN)

4.1 路径规划(Path planning)

在 HNN(3) 输出形成动态数值势场中, 从初始神经元出发, 重复在 8-连通邻域中搜索最大响应神经元, 最后形成到达目标节点的最速上升路径.

图 2(a) 中环境已知, 并选取 HNN(3) 参数为 $A = 11, m = 10, ks = 5, \alpha = 1, \beta = 0.01, D_{safe} = 0$ (此时没有考虑路径安全) 以及所有时延参数为 0. 经过 200 次伪并行迭代, 耗时 0.3 s, 得到最短路径, 长度 148. 显然该路径紧贴障碍物, 不利于机器人安全.

增大安全距离门限 $D_{safe} = 10$, 经过 200 次迭代, 耗时 0.3 s, 图 2(a) 中形成安全路径, 长度 163, 显然该安全路径通常都保持距离障碍物一定距离.

图 2(c) 中增加一个新障碍物后, 虽然图 2(a) 中最短路径仍可行, 但必须经过新障碍物附近狭窄通道. 经过 250 次迭代, 耗时 0.38 s, 图 2(c) 中形成新安全路径. 新路径长度 237, 远长于前两条路径, 但有利于机器人安全.

快速规划出路径.

以图 3 中列约束距离变换为例, 说明一轮模拟基本过程: 首先目标节点 T_{set} 神经元被模拟, 然后对 T_{set} 的上下方向相邻的非障碍物节点进行模拟(模拟时利用的是 T_{set} 神经元的最新状态), 并对新被模拟的这些节点也分别模拟其上下相邻的非障碍物节点(对该轮中已经模拟过的节点不再模拟), 重复该过程直到没有新的节点(显然这些节点到 T_{set} 的最短 4-连通路经中的水平部分的长度为 0, 并把这些节点集合记为 C_0) 可以模拟. 记和 C_0 节点左右相邻的非障碍物节点集合记为 C_1 (显然 C_1 中节点到 T_{set} 的最短 4-连通路经的水平部分的长度为 1). 再对 C_1 中节点依次进行串行模拟, 并同时将与 C_1 节点左右相邻的非障碍物节点集合记为 C_2 (显然 C_2

中节点到 T_{set} 的最短 4-连通路经的水平部分的长度
为 2)。即通过对 C_i 中节点串行模拟的同时也得到了
 C_{i+1} 集合,再对 C_{i+1} 集合中节点更新并求得 C_{i+2} 。不
断重复这样的过程,直到所有和 T_{set} 连通节点被模
拟完毕。由于 C_i 集合中节点到 T_{set} 的最短 4-连通路
径中的水平部分的长度为 i ,本文称之为列约束距
离变换(如图 3 中标号 9 的节点到 T_{set} 最短列连通
距离为 9)。 C_i 集合中节点的模拟顺序在图 3 中用箭
头进行表示。

行约束距离变换可认为是将图 3 旋转 90°后进
行的列约束距离变换,不再解释。约束距离变换中,
如果机器人当前位置节点不能被扩展到,表明当前
不存在可行路径。通过大量仿真发现,交替采用两种
约束距离变换串行模拟,通常能在 2~5 次迭代后即
能找到优化路径。

串行模拟的公式如下:把行(列)约束距离变换
串行模拟中按模拟顺序先后对节点重新排列,可以
得到新的向量 \bar{x} :模拟第 i 个节点 \bar{x}^i 的新状态时,用
到比 \bar{x}^i 的标号 i 小和大的两大类节点的状态,对于
标号小于 i 的节点将直接用其最新更新后得到的状
态,而对于标号下标大于 i 的节点仍用其原状态。有
$$\bar{x}^i(k+1) = \begin{cases} D_i(k)g(f(\bar{x}^i)/A), & \text{if } i \neq T_{set}, \\ D_i(k)g(f(\bar{x}^i)/A + I/A), & \text{otherwise.} \end{cases} \quad (16)$$

其中

$$f(\bar{x}_i) = \alpha \left[\max_{j < i \cap j \in NE_i} \omega_{ij} \bar{x}^j(k+1) + \max_{j < i \cap j \in NE_i} \omega_{ij} \bar{x}^j(k) \right] + \beta \left[\sum_{j < i \cap j \in NE_i} \omega_{ij} \bar{x}^i(k+1) + \sum_{j < i \cap j \in NE_i} \omega_{ij} \bar{x}^i(k) \right]. \quad (17)$$

上面方法被在线路径规划应用时,可概述如下:

Step 1 根据当前障碍物信息,分别采用一次行
约束距离变换串行模拟和列约束变换串行模拟,并
分别记录两种串行计算的节点顺序。如果机器人当
前位置节点不能被扩展到,表明当前不存在可行路
径,跳到 Step 4;反之,转到 Step 2。

Step 2 由记录的串行计算节点顺序,进行两种
串行计算模拟若干次,转到 Step 3。

Step 3 机器人沿着最快上升路径运动,直到发
现新的障碍物后转到 Step 4。

Step 4 下一次决策周期中,如果获得新的障碍
物信息,转到 Step 1 重新模拟计算并记录节点的模
拟顺序;反之,返回 Step 2 按原有顺序继续模拟。

行列约束距离变换只是一种有约束的广度优先
搜索,计算复杂度和一般的广度优先搜索计算复杂
度相同,都为 $O(N)^{[2]}$;又从式(16)和式(17)可知,
每个神经元计算只涉及相邻局部神经元,计算复杂
度为 $O(1)$ 。因此每个路径规划周期内本文算法的计
算复杂度为 $O(N)$ 。

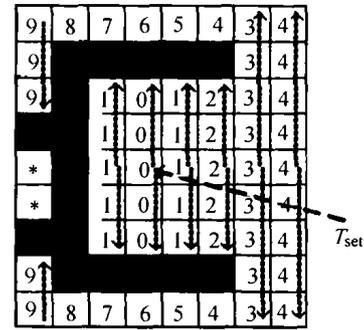


图 3 列约束连通距离

Fig. 3 Column-constrained distance transformation

5 仿真和实验(Simulation and experiment)

仿真机器人感知半径为 10 个单元格,定位精
确。实验用 Pioneer II 机器人有 16 个超声波测距仪,
CPU 主频 266M。环境划分为 100×100 的 $10 \text{ cm} \times 10 \text{ cm}$
栅格。对 HNN 取 $A = 11, m = 10, ks = 5, \alpha = 1, \beta = 0.01, D_{safe} = 5$ 。 $g(z)$ 为线性函数时,对
 100×100 和 500×500 地图所对应 HNN,每秒分别做
670 次和 20 次串行模拟计算,保证每个控制周期内
所有节点都被多次更新。

5.1 实时性(Real-time ability)

使用串行仿真对图 2(b)和图 2(c)环境重新求
解安全路径,得到相同的路径,而 CPU 耗时仅为
 0.005 s ,远小于伪并行仿真所用到的 0.3 和 0.38 s ;
并且串行仿真不受环境复杂性和路径长度影响。

将图 2(b)和图 2(c)环境的地图解析度增加到
 500×500 后,用串行仿真求解路径规划,耗时 0.20 s 。
表明基于约束距离变换的串行仿真具有较高的实
时性,能满足移动机器人导航实时路径规划要求。

5.2 仿真(Simulation)

图 4 中动态障碍物在障碍物运动范围(moving
scope)内随机往复运动,机器人需从 S 点运动到 T_{set}
点,且初始没有障碍物信息。由于缺少障碍物的初始
信息,机器人在多处都试图沿着最短路径向目标点
运动,均为障碍物阻拦,对环境作更多探索。机器
人在探索中并没有陷入到凹形中,最终到达目标点。
并且机器人在运动过程中始终和障碍物之间保持一
定的安全距离。

5.3 实验(Experiment)

Pioneer II 机器人控制决策周期为 0.1 s, 前进速度和所探测到的前方障碍物距离成反比, 最大前进速度设置为 250 mm/s. 为了减小噪声影响, 约束超声波测距仪有效测距范围为 1.5 m, 且每个超声波测距仪每 0.3 s 被激发一次进行测距, 采用柱状图法^[1]确定所感知到栅格是否有障碍物: 每个栅格都有一个置信值, 当超声波测距仪任意时刻探测到该栅格时, 如果本次探测中该栅格是障碍物, 则对其置信值加 3; 反之减 5, 并约束置信值在区间 $[0 \sim 0.15]$ 上. 本文将置信值大于 6 的栅格当作有障碍物, 反之该栅格没有被障碍物占据.

该机器人采用双轮差速, 可实现零半径转弯, 在路径规划中可当作点机器人来看待. 即使将该机器人看作具有非完整约束, 但由于 HNN 所规划的安全路径周围环境比较宽敞, 有较好的转弯余地. 实际上就采用和文献[7]相似的路径跟随控制器, 而文献[7]中控制器本身是针对非完整约束机器人的, 不多赘述.

初始障碍物未知. 机器人轨迹示意图如图 5 中圆圈阴影所示, 而机器人前进速度和圆圈直径成正比. 实验中人在 OB1 附近走动形成动态障碍物, 并且动态障碍物和环境之间形成了狭窄通道(channel). 机器人依靠特定颜色来识别动态障碍物.

虽然缺少障碍物初始信息, 但机器人对环境探测中并没有陷入到凹形中, 最终到达 T_{set} . 实验中机器人始终保持距离障碍物较远, 尤其当碰到狭窄通道 Channel 时, 机器人更趋向于对环境未知部分进行探测来寻找新的可行路径. 从 S 运动到 T_{set} 耗费 78 s, 且每个控制周期都能搜索到优化路径, 满足实时性要求.

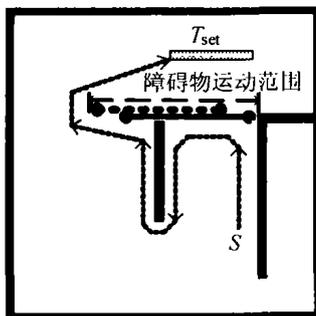


图 4 未知动态环境下仿真

Fig. 4 Simulation in an unknown and dynamic environment

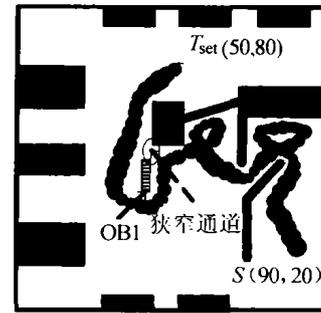


图 5 未知环境下实验

Fig. 5 Experiment in an unknown environment

6 结语(Conclusion)

给出一种新的 HNN 模型进行动态环境下路径规划, 分析了其全局稳定性, 并利用 HNN 时延特性, 提出了基于约束距离变换串行计算在单处理器上对 HNN 进行快速模拟. 仿真和实验表明了该方法有效性.

参考文献(References):

- [1] BORENSTEIN J, KOREB Y. The vector field Histogram-fast obstacle avoidance for mobile robots [J]. *IEEE Trans on Robotics and Automation*, 1991, 7(3): 278 - 288.
- [2] CORMAN T H. *Introduction to Algorithms* [M]. Cambridge, MA: MIT Press, 1990: 101 - 104.
- [3] GLASIUS R, KOMODA A. Neural network dynamics for path planning and obstacle avoidance [J]. *Neural Networks*, 1995, 8(1): 125 - 133.
- [4] KASSIM A, KUMAR V. Path planners based on the wave expansion neural network [J]. *Robotics and Autonomous Systems*, 1999, 26(1): 1 - 22.
- [5] YANG S X, MAX M. Neural network approaches to dynamic collision-free trajectory generation [J]. *IEEE Trans on Systems, Man, and Cybernetics, Part B*, 2001, 31(3): 302 - 318.
- [6] HALANAY A. *Differential Equations* [M]. New York: Academic Press, 1996: 15 - 18.
- [7] RAMIREZ G. Collision-free path planning for nonholonomic mobile robots using a new obstacle representation in the velocity space [J]. *Robotica*, 2001, 19(1): 543 - 555.

作者简介:

樊长虹 (1975 —), 男, 博士研究生, 主要研究方向为智能移动机器人规划与控制, E-mail: changhongfan@sjtu.edu.cn;

陈卫东 (1968 —), 男, 上海交通大学自动化研究所副教授, 主要研究方向为智能移动机器人;

席裕康 (1946 —), 男, 上海交通大学自动化研究所教授, 主要研究方向为预测控制与机器人控制.