

## 基于 Boltzmann 机神经网络认知机制的机器人趋光控制

阮晓钢<sup>1</sup>, 庞涛<sup>1,2</sup>, 于建均<sup>1</sup>

(1. 北京工业大学 电子信息与控制工程学院, 北京 100124; 2. 沈阳航空航天大学 电子信息工程学院, 沈阳 110136)

**摘要:** 针对移动机器人未知环境下的趋光控制问题, 模拟人或动物“感知-行动”认知机制, 对具有趋光特性的移动机器人进行设计, 提出一种基于 Boltzmann 机神经网络的趋光控制方法. 该方法首先应用知识集对机器人趋光控制器的 Boltzmann 机神经网络进行趋光训练; 然后应用 Boltzmann 机神经网络的运行机制实现趋光控制. 仿真实验表明, 该方法能够提高机器人学习的控制精度.

**关键词:** 移动机器人; 趋光技能; 认知机制; Boltzmann 机

**中图分类号:** TP242.6

**文献标志码:** A

## Robot phototaxis control based on Boltzmann machine neural network cognitive mechanism

RUAN Xiao-gang<sup>1</sup>, PANG Tao<sup>1,2</sup>, YU Jian-jun<sup>1</sup>

(1. College of Electronic and Control Engineering, Beijing University of Technology, Beijing 100124, China; 2. College of Electronic Information Engineering, Shenyang Aerospace University, Shenyang 110136, China. Correspondent: PANG Tao, E-mail: pangtao163@126.com)

**Abstract:** For mobile robot phototaxis control problems, the human or animal “perception-action” cognitive mechanism is simulated. The structure of mobile robot is designed and the method of phototaxis control is proposed based on the Boltzmann machine neural network. The Boltzmann machine neural network is trained by the knowledge set. The phototaxis control method is implemented by using the Boltzmann machine neural network operation mechanism. Simulation results show that the proposed method can improve the control accuracy and the success rate of robot learning.

**Key words:** mobile robot; phototaxis skill; cognitive mechanism; Boltzmann machine

### 0 引言

探索认知机理、理解认知行为是认知科学、人工智能、机器人学以及神经生理学和心理学等诸多学科共同关心的课题. 近年来, 机器人的趋光控制特性作为认知和心智发育的渐近过程研究范例已经得到广泛重视<sup>[1-8]</sup>. 维纳采用惠斯登电桥实现了机电反射弧和机器蠕虫趋光控制. 何光峰等<sup>[1]</sup>采用硅光电池作为传感器的智能小车, 根据环境设定合适的规定值能较好地避开光的干扰. 这些方法采用对称结构模拟趋光生命特性, 对器件参数和结构的对称性要求较高且控制器自身不具有学习能力. Crespi 等<sup>[2]</sup>利用中心模式生成器, 采用 PD 控制器控制电机驱动机械鱼以各种

速度、方向、多种姿态完成趋光运动. 周超等<sup>[3]</sup>设计了一种可自主游动的微小型仿生机器鱼, 给出了机器鱼推进和转弯等运动的控制方法, 实现了机器鱼趋光和动态光源跟踪. 以上方法采用仿生物理系统和设定行为规则实现趋光生命特性, 但因其控制规则预先设定, 所以该方法仍缺乏有效的学习能力. 具备学习能力是机器人具备智能的首要环节, Watson 等<sup>[4]</sup>利用移动机器人对前方左右传感器感知光强的不同, 采用 4 个神经元构成的人工神经网络模拟生物进化功能, 实现了多机器人的趋光移动. Peter 等<sup>[5]</sup>采用由 4 个神经元组成的全互联动态人工神经网络实现了移动机器人趋光控制. Tuci<sup>[6]</sup>采用动态人工神经网络成

收稿日期: 2013-08-10; 修回日期: 2014-01-13.

基金项目: 国家 973 计划项目(2012CB720000); 国家自然科学基金项目(61075110, 61375086); 北京市自然科学基金/北京市教育委员会科技计划重点项目(KZ201210005001); 高等学校博士学科点专项科研基金项目(20101103110007).

作者简介: 阮晓钢(1958—), 男, 教授, 博士生导师, 从事机器人学、自动控制与人工智能等研究; 庞涛(1976—), 女, 博士生, 从事机器人学、人工智能的研究.

功地模拟生物的神经系统,多机器人合作成功避开障碍物,实现了趋光移动. Jose等<sup>[7]</sup>采用3层神经网络,模拟智能体适应环境的改变,完成趋光避障任务. Dai等<sup>[8]</sup>采用3层前馈神经网络,实现桌面六足机器人趋光控制. 上述方法提高了机器人的智能化程度,但学习的控制精度有待进一步提高.

针对上述问题,本文对人或动物“感知-行动”的认知机制进行研究,基于 Boltzmann 机神经网络对该机制进行模拟,并将其应用于机器人的趋光控制过程. 实验表明,该方法能够逐渐形成、发展和完善机器人的趋光认知机制,并可有效避免学习过程中的局部极小问题,提高学习的控制精度.

### 1 机器人模型和坐标

采用圆盘状三轮式移动机器人模型,结构如图1所示,左右两侧安装有驱动轮,尾部有一个起支撑作用的方向轮. 机器人圆盘前端安装6个光敏传感器,将6个传感器分为左右两组,分别测定左侧和右侧的光强度,每组3个传感器中测定光强最大值作为该组传感器测定的光强度值,左侧光强度值表示为  $b_1$ , 右侧光强度值表示为  $b_2$ .




图1 机器人结构

机器人系统模型采用两个坐标系,全局坐标系  $X_W O_W Y_W$  和机器人坐标系  $X_R O_R Y_R$ , 其中  $O_R$  是机器人的中心,  $X_R$  轴直接通过机器人的两个驱动轮轴心.

机器人运动学方程为

$$\begin{cases} x = x + v \cos \theta \Delta \phi, \\ y = y + v \sin \theta \Delta \phi. \end{cases} \quad (1)$$

其中:  $v$  为机器人运动线速度,  $\theta$  为机器人运动方向与全局坐标系  $X_W$  的夹角,  $\Delta \phi$  为采样时间.

## 2 基于 Boltzmann 机神经网络的趋光学习控制器设计

### 2.1 “感知-行动”认知机制

感觉运动系统是综合了感受器功能和运动神经能的神经生理组织. 根据神经生理学<sup>[9-10]</sup>, 生物体

利用感受器、运动神经系统和效应器,通过自学习和自组织过程,逐渐掌握运动技能的学习机制. 如图2所示,感受器是感觉器官,其功能是感知环境(或客体)状态;运动神经系统是调节特定技能的神经细胞群,根据环境(或客体)状态产生动作决策;效应器是机体的运动器官,其功能是根据运动神经系统动作决策对环境(或客体)施加操作. 人或动物的运动控制技能是在感觉运动系统自学习和自组织的过程中渐近地形成、发展和完善.




图2 “感知-行动”认知机制

### 2.2 基于 Boltzmann 机神经网络趋光控制器

#### 2.2.1 基于 Boltzmann 机神经网络趋光控制器结构

Hinton等<sup>[11-12]</sup>构造了一种模拟热力学系统的神经计算模型,被称为 Boltzmann 机. Boltzmann 机具有理论上完善的克服局部极小问题的机制,是隐含神经元可训练的神经计算模型. 一个  $N$  阶的 Boltzmann 机  $\text{ncm}_B^{(N)} = \langle \mathbf{W}, \mathbf{b} \rangle$  可由其联结关系矩阵  $\mathbf{W}$  和阈值向量  $\mathbf{b} = (b_1, b_2, \dots, b_N)^T$  唯一地确定, 其中  $N = 1, 2, \dots$ . Boltzmann 机神经元集合为

$$\mathcal{Q}_G = \{q_i, i = 1, 2, \dots, N\},$$

其中  $q_i$  为第  $i$  个神经元,  $o_i$  为  $q_i$  的状态,  $\mathbf{o}_I = (o_i, i = 1, 2, \dots, N)^T$  称为  $\text{ncm}_B^{(N)}$  的状态.  $\mathcal{Q}_G$  可划分为两个子集,即

$$\mathcal{Q}_G = \{\mathcal{Q}_H, \mathcal{Q}_Q\}.$$

其中:  $\mathcal{Q}_H$  为隐含域;  $\mathcal{Q}_Q$  为可视域,可视域可进一步划分为输入域  $\mathcal{Q}_I$  和输出域  $\mathcal{Q}_O$ .

机器人趋光控制器结构主要由传感器、1个6阶的 Boltzmann 机  $\text{ncm}_B^{(6)} = \langle \mathbf{W}, \mathbf{b} \rangle$  和电机等构成,如图3所示. 传感器测量左右光强度  $b_1$  和  $b_2$ , 作为  $\text{ncm}_B^{(6)}$  神经网络输入状态量;  $\text{ncm}_B^{(6)}$  神经元集合为

$$\mathcal{Q}_G = \{q_i, i = 1, 2, \dots, 6\}.$$




图3 基于 Boltzmann 机趋光控制器结构

其中:  $\mathbf{Q}_H = \{q_3, q_4\}$  为隐含域,  $\mathbf{Q}_O = \{q_1, q_2, q_5, q_6\}$  为可视域,  $\mathbf{Q}_I = \{q_1, q_2\}$  为输入域,  $\mathbf{Q}_O = \{q_5, q_6\}$  为输出域,  $\mathbf{o}_I = (o_i, i = 1, 2)^T$  为  $\mathbf{Q}_I$  的状态, 其为  $\text{ncm}_B^{(6)}$  的输入状态量;  $\mathbf{o}_P = (o_i, i = 5, 6)$  为  $\mathbf{Q}_O$  的状态, 其为  $\text{ncm}_B^{(6)}$  的输出动作量;  $\text{ncm}_B^{(6)}$  输出动作量给电机等驱动装置, 以完成趋光运动。

**定义 1** 趋光控制器  $\text{ncm}_B^{(6)}$  的输入状态量

$$\mathbf{o}_I = (o_1, o_2)^T = \begin{cases} (-1, 1)^T, & o_1 > o_2; \\ (1, 1)^T, & o_1 = o_2 < A; \\ (-1, -1)^T, & o_1 = o_2 = A; \\ (1, -1)^T, & o_1 < o_2. \end{cases} \quad (2)$$

其中: 第 1 种  $(-1, 1)^T$  表示左侧光强度大于右侧光强度; 第 2 种  $(1, 1)^T$  表示左侧光强度等于右侧光强度, 但小于光源的光强度  $A$ ; 第 3 种  $(-1, -1)^T$  表示左侧光强度、右侧光强度与光源的光强度  $A$  相等; 第 4 种  $(1, -1)^T$  表示右侧光强度大于左侧光强度。

**定义 2** 趋光控制器  $\text{ncm}_B^{(6)}$  的输出动作量

$$\mathbf{o}_P = (o_5, o_6)^T = \begin{cases} (-1, 1)^T, & \theta = \theta - 10^\circ, v \neq 0; \\ (1, 1)^T, & \theta = \theta, v \neq 0; \\ (-1, -1)^T, & \theta = 0, v = 0; \\ (1, -1)^T, & \theta = \theta + 10^\circ, v \neq 0. \end{cases} \quad (3)$$

其中: 第 1 种动作量  $(-1, 1)^T$  表示左转  $10^\circ$ , 前进; 第 2 种动作量  $(1, 1)^T$  表示前进; 第 3 种动作量  $(-1, -1)^T$  表示停止; 第 4 种动作量  $(1, -1)^T$  表示右转  $10^\circ$ , 前进。

**定义 3** 根据趋光情况设计 4 种控制逻辑, 第 1 种左侧光强度大于右侧光强度左转  $10^\circ$ , 前进; 第 2 种左侧光强度等于右侧光强度但小于光源的光强度, 前进; 第 3 种为左侧光强度、右侧光强度与光源强度相等, 停止; 第 4 种为右侧光强度大于左侧光强度, 右转  $10^\circ$ , 前进。根据 4 种控制逻辑定义  $\text{ncm}_B^{(6)}$  的知识集

$$\mathbf{K}_B^{(6)} = \{ \langle \mathbf{o}_I^{(s)}, \mathbf{o}_P^{(s)} \rangle | s = 1, 2, 3, 4 \} = \{ \langle (-1, 1)^T, (-1, 1)^T \rangle, \langle (1, 1)^T, (1, 1)^T \rangle, \langle (-1, -1)^T, (-1, -1)^T \rangle, \langle (1, -1)^T, (1, -1)^T \rangle \}. \quad (4)$$

## 2.2.2 Boltzmann 神经元的“整合-激发”

Boltzmann 神经元整合映射

$$u_j(t) = \sum_{i \neq j} w_{ij} o_i(t) - b_j. \quad (5)$$

其中:  $b_i$  为  $q_i$  的阈值,  $u_i$  为  $q_i$  的整合量,  $w_{ij}$  为  $q_i$  与  $q_j$  的联结强度值,  $t = 0, 1, \dots$  为离散时间。

Boltzmann 机能量函数定义为

$$\varepsilon(t) = -\frac{1}{2} \sum_{j=1}^N \sum_{i=1}^N w_{ij} o_i(t) o_j(t) + \sum_{i=1}^N b_i o_i(t) =$$

$$-\frac{1}{2} \mathbf{o}^T(t) \mathbf{W} \mathbf{o}(t) + \mathbf{b}^T \mathbf{o}(t). \quad (6)$$

假设 Boltzmann 机第  $j$  个神经元  $q_j$  的状态  $o_j$  迁移或跃变, 则由能量函数可知

$$\Delta \varepsilon(t) = -\frac{1}{2} \Delta o_j(t) \left\{ \sum_{i=1}^N w_{ij} o_i(t) + \sum_{i=1}^N w_{ji} o_i(t) \right\} + \Delta o_j(t) b_j - \Delta o_j^2(t) w_{jj}. \quad (7)$$

其中:  $\Delta \varepsilon(t) = \varepsilon(t+1) - \varepsilon(t)$  为 Boltzmann 机的能量变化,  $\Delta o_j(t) = o_j(t+1) - o_j(t)$  为  $q_j$  的状态变化。

Boltzmann 机的能量增量为

$$\begin{cases} \Delta \varepsilon^{(-)}(t) = \sum_{i \neq j} w_{ij} o_i(t) - b_j = u_j(t), \\ \Delta \varepsilon^{(+)}(t) = -\Delta \varepsilon^{(-)}(t) = -u_j(t). \end{cases} \quad (8)$$

其中:  $\Delta \varepsilon^{(-)}(t)$  为  $q_j$  由  $o_j(t) = +1$  迁移至  $o_j(t+1) = -1$  时 Boltzmann 机的能量增量,  $\Delta \varepsilon^{(+)}(t)$  为  $q_j$  由  $o_j(t) = -1$  迁移至  $o_j(t+1) = +1$  时 Boltzmann 机的能量增量。Boltzmann 机联结关系  $\mathbf{W}$  是对称的, 即  $w_{ij} = w_{ji}$ , 并且无自联结, 即  $w_{ii} = 0$ 。

Boltzmann 机神经元  $q_j$  的激发概率为

$$\begin{cases} p_j^+(t) = (1 + \exp\{-u_j(t)/T\})^{-1}, \\ p_j^-(t) = (1 + \exp\{u_j(t)/T\})^{-1}. \end{cases} \quad (9)$$

其中:  $p_j^{(+)}(t) = p(-1 \rightarrow +1, t)$  为  $q_j$  状态由  $o_j(t) = -1$  迁移至  $o_j(t+1) = +1$  的概率, 称为  $q_j$  的兴奋概率;  $p_j^{(-)}(t) = p(+1 \rightarrow -1, t)$  为  $q_j$  状态由  $o_j(t) = +1$  迁移至  $o_j(t+1) = -1$  的概率, 称为  $q_j$  的抑制概率;  $T$  为温度值。

用能量改变量表示为

$$\begin{cases} p_j^{(+)}(t) = (1 + \exp\{\Delta \varepsilon^{(+)}(t)/T\})^{-1}, \\ p_j^{(-)}(t) = (1 + \exp\{\Delta \varepsilon^{(-)}(t)/T\})^{-1}. \end{cases} \quad (10)$$

Boltzmann 机中的神经元的激发概率是由其状态改变时能量的增量决定的。Boltzmann 机神经元状态的变化, 导致能量的变化, 反之, Boltzmann 机能量的变化, 意味着神经元状态的变化。

## 2.2.3 Boltzmann 机运行机制

Kirkpatrick 等<sup>[13]</sup>建立了一种能搜索到全局极小的模拟退火算法, 其基本思想是从高温到低温, 使系统在每一个温度上都达到热平衡, 最后在某个低温处系统能量达到全局极小。退火算法的时间复杂度极高, 确保算法收敛至全局极小的降温策略为

$$T(k) = \frac{T_0}{1+k}, \quad k = 1, 2, \dots, r. \quad (11)$$

其中:  $T_0$  为初始温度,  $k$  为时间。

## 2.3 移动机器人趋光控制算法

移动机器人趋光控制算法步骤如下。

Step 1: 初始化.  $\text{ncm}_B^{(6)}$  伪随机数发生器生成阈值  $\mathbf{b}_0$  和联结强度值  $\mathbf{W}_0$ .

Step 2: 通过对知识集  $\mathbf{K}_B^{(6)}$  学习, 将  $\text{ncm}_B^{(6)}$  的神经元阈值  $b_j (j = 1, 2, \dots, 6)$  和 Boltzmann 机神经元之间的联结强度值  $w_{ij} (i, j = 1, 2, \dots, 6)$  进行调节.

Step 3: 将学习和训练后的 Boltzmann 机  $\text{ncm}_B^{(6)} = \langle \mathbf{W}, \mathbf{b} \rangle$  用于趋光控制. 设置  $t = 0$  和  $k = 0$ ,  $\text{ncm}_B^{(6)}$  接受初始状态  $\mathbf{o}^{(k)} = \mathbf{o}_0$  和初始温度  $T^{(k)} = T_0$ . 将输入域  $\mathbf{Q}_I$  钳制于  $\mathbf{o}_I$ , 而隐含域  $\mathbf{Q}_H$  和输出域  $\mathbf{Q}_O$  的初始状态随机生成.

Step 4: 选择“整合-激发”单元. 随机选择神经元  $q_j \in V_G, j \in \{1, 2, \dots, N\}$ .

Step 5: 随机状态生成. 等概率地产生  $q_j$  的随机状态  $o_j = +1$  或  $o_j = -1$ , 并计算能量增量  $\Delta\varepsilon = \varepsilon(o_j) - \varepsilon(o_j(t))$ .

Step 6: 随机状态的接受. 若  $\Delta\varepsilon < 0$ , 则接受  $o_j$ ,  $o_j(t+1) = o_j$ ; 否则计算  $q_j$  迁移概率  $p_{TR} = \exp\{-\Delta\varepsilon/T\}$ , 并在区间  $[0, 1]$  上依均匀分布产生随机数  $N_R$ , 依迁移概率  $p_{TR}$  激发  $q_j$ , 即若  $p_{TR} \geq N_R$ , 则接受  $o_j$ ,  $o_j(t+1) = o_j$ ; 否则,  $q_j$  保持原有状态,  $o_j(t+1) = o_j(t)$ .

Step 7: Metropolis 循环. 若  $\text{ncm}_B^{(6)}$  在温度  $T^{(k)}$  达到热平衡, 即下列条件之一成立:

- 1)  $\text{ncm}_B^{(6)}$  所有可能状态具有相同出现的概率.
- 2)  $\text{ncm}_B^{(6)}$  所有 Boltzmann 机神经元具有相同被选中概率.
- 3)  $\text{ncm}_B^{(6)}$  所有 Boltzmann 机神经元的状态不再发生改变.
- 4)  $\text{ncm}_B^{(6)}$  能量函数达到温度  $T^{(k)}$  下的极小.
- 5) 循环次数达到上限  $M$ ,  $M$  为正整数. 置  $k = k + 1$  和当前解  $\mathbf{o}(T^{(k)}) = \mathbf{o}(t + 1)$ , 转 Step 8; 否则  $t = t + 1$ , 转 Step 4.

Step 8: 条件停机. 输出最优解  $\mathbf{o}(T_{\text{Final}})$ ,  $T_{\text{Final}} = T^{(k)}$ .

Step 9: 降温循环. 依一定的降温策略选择  $T^{(k)} < T^{(k-1)}$ , 然后转向 Step 4.

Step 10: Boltzmann 机  $\text{ncm}_B^{(6)}$  在低温平衡状态下的输出动作量, 实现正确的趋光控制逻辑关系.

Step 11: 结束.

## 2.4 算法收敛性证明

**定理 1** 系统的状态服从 Boltzmann-Gibbs 分布并且在温度  $T$  下达到热平衡的一个充分条件是

$$\frac{p(\alpha \rightarrow \beta)}{p(\beta \rightarrow \alpha)} = \frac{p(\beta)}{p(\alpha)} = \exp\left\{-\frac{\Delta\varepsilon(\alpha \rightarrow \beta)}{K_B T}\right\}. \quad (12)$$

其中:  $\alpha$  和  $\beta$  为热力学系统可能的状态,  $\Delta\varepsilon(\alpha \rightarrow \beta) = \varepsilon(\beta) - \varepsilon(\alpha)$ ;  $p(x)$  为状态  $x$  的出现概率,  $p(x \rightarrow y)$  为状态

$x$  转移至  $y$  的概率. 对于给定的温度  $T$ , Boltzmann 机工作算法中的 Metropolis 循环必能达到温度  $T$  下的热平衡状态.

**证明** 假定 Boltzmann 机当前被选定的“整合-激发”单元为神经元  $q_j$ , 则式 (7) 状态  $o_j$  的改变  $\Delta o_j$  将导致 Boltzmann 机能量函数的改变 ( $\Delta\varepsilon$ ), 且

$$\Delta\varepsilon = -0.5\Delta o_j u_j. \quad (13)$$

由式 (9) 可知: 若  $u_j > 0$ , 则  $p_j^{(+)} > 0.5$ ,  $o_j$  倾向于取  $+1$ ,  $\Delta o_j$  倾向于大于  $0$ ,  $\Delta\varepsilon$  倾向于小于  $0$ ; 若  $u_j < 0$ , 则  $p_j^{(-)} > 0.5$ ,  $o_j$  倾向于取  $-1$ ,  $\Delta o_j$  倾向于小于  $0$ ,  $\Delta\varepsilon$  仍然倾向小于  $0$ . 这意味着, Boltzmann 机的能量函数  $\varepsilon(t)$  在其状态演化的过程中始终倾向于递减.

Metropolis 基于 Boltzmann 分布和最小自由能原理给出了一个准则<sup>[4]</sup>: 物质粒子在热力学温度  $T$  下趋于热平衡状态的概率为  $\exp\{-\Delta\varepsilon/(K_B T)\}$ , 其中  $K_B (K_B = 1.38 \times 10^{-23} \text{Js/K})$  为 Boltzmann 常数.

对于给定的热力学温度  $T$ , 孤立热力学系统能量的变化量  $\Delta\varepsilon$  必定是减少的. 退火过程中, 充分缓慢地降温意味着能量的变化量  $\Delta\varepsilon$  能在任意热力学温度  $T$  下达到  $0$ , 因而根据 Metropolis 准则, 物质粒子趋于热平衡状态的概率为  $1$ , 即在每个热力学温度值  $T$  都能达到热平衡状态, 并最终在常温达到基态, 其内能倾向于达到最低.

能量函数  $\varepsilon(t)$  是有下界的, 随着 Metropolis 循环的无限加深, 其递减势必导致  $\Delta(\varepsilon)$  最终依概率  $1$  达到  $0$ , 而  $\varepsilon(t)$  依概率  $1$  收敛到温度  $T$  下的某个能量极小值. 根据式 (10), 对于任意 Boltzmann 机神经元  $q_j \in V_G$ , 其兴奋概率  $p_j^{(+)}$  和抑制概率  $p_j^{(-)}$  均为  $0.5 (p_j^{(+)} = p_j^{(-)} = 0.5)$ , 即 Boltzmann 机  $\text{ncm}_B^{(N)} = \langle \mathbf{W}, \mathbf{b} \rangle$  依概率  $1$  达到温度  $T$  下的热平衡状态.  $\square$


## 3 仿真实验

为验证算法的有效性, 在 Matlab 仿真环境下, 以机器人的趋光学习控制为目标进行研究, 机器人对环境是完全未知的. 仿真环境中圆形表示光源位置, 方形表示障碍物, 光源位置坐标和移动机器人运动起点位置坐标可以任意设定, 起点位置注明“S”, 终点位置注明“G”. 设定机器人移动的线速度  $v$  为  $0.5 \text{ m/s}$ , 光源所在位置光强是  $1$  坎德拉, 与光源越近的位置光强越强, 采样时间  $\Delta\phi = 1 \text{ s}$ .


### 3.1 基于 Boltzmann 机神经网络趋光控制实验

将移动机器人用于仿真环境中, 移动机器人趋光控制器的 Boltzmann 机神经网络  $\text{ncm}_B^{(6)}$  的神经元阈值和联结强度值随机生成, 采用知识集  $\mathbf{K}_B^{(6)}$  作为训练样本, 调用 Boltzmann 机工作算法, 使  $\text{ncm}_B^{(6)}$  由初


始温度  $T_0 = 10^\circ\text{C}$  运行至低温  $T_{\text{final}} = 0.01^\circ\text{C}$  的状态, 观察学习情况. 图 4(a) 是学习初期机器人趋光轨迹, 温度降为  $T = 9.1^\circ\text{C}$ , 机器人从起始位置出发并不向光源方向运动, 说明机器人原本不具备趋光能力. 图 4(b) 是学习中期机器人趋光轨迹, 温度降为  $T = 0.2^\circ\text{C}$ , 机器人起始位置出发, 到达接近光源附近位置停止, 但并未按最短路径移动, 说明并未完全掌握趋光能力. 图 4(c) 是学习结束机器人趋光轨迹, 温度降为  $T = 0.01^\circ\text{C}$ , 从起点出发以最短路径到达接近光源附近位置停止运动的轨迹, 表明机器人通过学习后能表现出其自主趋光能力. 图 4(d) 为移动机器人在趋




(a) 学习初期运行轨迹



(b) 学习中期运行轨迹



(c) 学习末期运行轨迹



(d) 学习末期光强曲线

图 4 认知机器人趋光学习过程曲线

光移动中感知光强的变化曲线, 横轴  $d$  表示机器人与光源的距离, 纵轴  $A$  表示机器人所在位置的光强度. 机器人在起点位置时光强最弱, 随着与光源距离的接近, 光强逐渐增加, 最后到达光源附近, 感知的光强最强. 从图 4 中可看出, 通过学习和训练, 随着温度参数适当的降低, 机器人逐渐学会并掌握了趋光控制技能.


在学习和训练后的趋光仿真实验中随机选取 200 组实验数据, 统计“感知-行动”规则的实现概率, 如表 1 所示. 可见 Boltzmann 机在学习过程中, 能克服局部极小, 较好地完成趋光控制.

表 1 基于 Boltzmann 机神经网络趋光控制实现概率


序号	知识集		实现概率/%
	$o_1$	$o_0$	
1	$(1, 1)^T$	$(1, 1)^T$	100
2	$(-1, 1)^T$	$(-1, 1)^T$	100
3	$(1, -1)^T$	$(1, -1)^T$	100
4	$(-1, -1)^T$	$(-1, -1)^T$	100

### 3.2 趋光对比实验

在存在障碍物的仿真环境中, 将本文的趋光控制算法与参考文献 [5] 中的方法作仿真对比实验. 采用本文方法, Boltzmann 机神经网络的训练由初始温度  $T = 10^\circ\text{C}$  降为  $T = 0.01^\circ\text{C}$ , 所用时间为 36.2 min, 与采用参考文献 [5] 中方法的训练时间基本相同. 图 5(a) 和图 5(b) 分别是采用本文方法和参考文献 [5] 中方法的仿真结果, 两者都能绕过障碍物到达光源位置, 实现趋光控制, 但采用本文方法实现趋光控制运动轨迹更优, 说明本文方法趋光路径精度更高.



(a) 采用本文方法的趋光轨迹



(b) 采用参考文献[5]方法的趋光轨迹

图 5 趋光对比实验

## 4 结 论

本文模拟生物的“感知-行动”学习机制,采用基于 Boltzmann 机神经网络的趋光控制方法使移动机器人在未知环境下通过学习和训练,逐步形成、发展和完善趋光控制技能.该方法经过充分的探索和学习能够克服局部极小,提高学习的控制精度.

### 参考文献(References)

- [1] 何光锋,王凌云,徐加鹏.基于模块化控制的多功能智能小车设计[J].现代电子技术,2013,36(16): 137-142.  
(He G F, Wang L Y, Xu J P. Multifunction smart car based on modular control[J]. Modern Electronic Technology, 2013, 36(16): 137-142.)
- [2] Crespi A, Lachat D, Pasquier A. Controlling swimming and crawling in a fish robot using a central pattern generator[J]. Autonomous Robots, 2008, 25(1/2): 3-13.
- [3] 周超,曹志强,王硕,等.微小型仿生机器鱼设计与实时路径规划[J].自动化学报,2008,34(7): 772-777.  
(Zhou C, Cao Z Q, Wang S, et al. A miniature fish robot design and real-time path planning[J]. Acta Automatica Sinica, 2008, 34(7): 772-777.)
- [4] Sumoto H, Yamaguchi S. Development of a motion control system using phototaxis for a fish type robot[C]. Proc of the 20th Int Offshore and Polar Engineering Conf. Cupertino: ISOPE, 2010: 307-310.
- [5] Watson R A, Ficici S G, Pollack J B. Embodied evolution: Distributing an evolutionary algorithm in a population of robots[J]. Robotics and Autonomous Systems, 2002, 39(1): 1-18.
- [6] Tuci E, Ampatzis C, Vicentini F, et al. Evolving homogeneous neurocontrollers for a group of heterogeneous robots: Coordinated motion, cooperation, and acoustic communication[J]. Artificial Life, 2008, 14(2): 157-178.
- [7] Jose A F, Gerardo G A, Miguel A M. Behavioral control through evolutionary neurocontrollers for autonomous mobile robot navigation[J]. Robotics and Autonomous Systems, 2009, 57(4): 411-419.
- [8] Dai L Z, Ruan X G, Wang G W, et al. Neural networks based autonomous learning for a desktop robot[C]. Proc of the World Congress on Intelligent Control and Automation. New York: IEEE, 2012: 739-742.
- [9] Asada M, Uchibe E, Hosoda K. Cooperative behavior acquisition for mobile robots in dynamically changing real worlds via vision-based reinforcement learning and development[J]. Artificial Intelligence, 1999, 110(2): 275-292.
- [10] Mihai D, Grigore B F, Ahmed T. Obstacle avoidance of redundant manipulators using neural networks based reinforcement learning[J]. Robotics and Computer Integrated Manufacturing, 2012, 28(2): 132-146.
- [11] Hinton G E, Sejnowski T J. Learning and relearning in Boltzmann machines[M]. Cambridge: MIT Press, 1986: 282-317.
- [12] Agliari E, Barra A, De Antoni A, et al. Parallel retrieval of correlated patterns: From Hopfield networks to Boltzmann machines[J]. Neural Networks, 2013, 38(2): 52-63.
- [13] Lazo A V, Rathie P. On the entropy of continuous probability distributions[J]. IEEE Trans on Information Theory, 1978, 24(1): 120-122.
- [14] Metropolis N, Rosenbluth A W, Rosenbluth M N, et al. Equation of state calculations by fast computing machines[J]. The J of Chemical Physics, 1953, 21(6): 1087-1090.

(责任编辑: 孙艺红)