

基于中枢模式发生器的步态控制策略的研究

张益军, 朱庆保

(南京师范大学 数学与计算机科学学院, 江苏 南京 210097)

[摘要] 针对基于仿生学原理的足式机器人步态控制方法, 探讨了基于细胞神经网络 (CNN) 的中枢模式发生器 (CPG) 实现机器人运动控制的基本思想及不足. 提出了基于模糊神经网络 (FNN) 和 CNN 的 CPG 步态控制模型, 给出了 CNN 中自动波稳定性的数值判别方法. FNN 与遗传算法 (GA) 相结合形成的调整机制的引入, 增强了系统的抗干扰能力. 仿真结果表明, 此控制策略具有较理想的效果, 并且原理简单, 易于实现.

[关键词] 运动控制, 中枢模式发生器, 细胞神经网络, 模糊神经网络, 智能控制

[中图分类号] TP242 **[文献标识码]** A **[文章编号]** 1672-1292(2005) 03-0054-04

Research in Locomotion Control Based on Central Pattern Generation

ZHANG Yijun ZHU Qingbao

(School of Mathematics and Computer Science, Nanjing Normal University, Jiangsu Nanjing 210097, China)

Abstract Based on the control method of amble-robots' pace in bionics principles, this paper discusses the main idea that Central Pattern Generation (CPG) is used to implement the hexapod's locomotion control with Cellular Neural Networks (CNNs) as its base, and for the shortages of the main idea now available, put forward a new CPG model based on Fuzzy Neural Networks (FNN) and CNN, and presents a numerical discriminant technique for the stability of autowaves in CNN. Drawing of compensation based on FNN and Genetic Algorithms (GA) heightens the system anti-jamming capability. The simulation experiment shows that this control strategy has an ideal effect, is simple in principle, and is easy to realize.

Key words locomotion control, central pattern generation, cellular neural networks, fuzzy neural networks, intelligent control

0 引言

足式机器人运动控制策略的研究, 一直是机器人研发过程中的重点和难点. 现阶段, 对动物体中枢模式发生器 CPG (Central Pattern Generation) 的研究为其提供了新思路. 生物学家普遍认为动物体的节律运动是由其脊髓中的 CPG 控制的. 从提出到现在, CPG 的研究取得了较大进展. 工程中将 CPG 建模成一组相互耦合的非线性振荡器, 利用振荡器的状态变量和机器人足变量的严格耦合, 实现机器人的运动控制. 由于细胞神经网络 CNN (Cellular Neural Networks) 可通过电路实现, Arana P 等人利用两层 CNN 实现了对六足机器人的“快

步态”, “中步态”和“慢步态”的运动控制^[1, 2]. 但这种方法缺少对系统控制误差的调整机制, 严格的耦合也使系统缺乏灵活性和自适应性, 同时控制误差的积累, 会导致系统的不稳定. 鉴于此, 本文给出了 CNN 网络稳定性的评估函数, 提出了基于模糊神经网络 FNN (Fuzzy Neural Network) 和 CNN 模拟 CPG 的控制策略. 仿真结果表明, 这种控制策略具有较强的抗干扰能力.

1 CNN 网络稳定性评估

建立图 1 所示的环状 CNN 结构, 每个小圆代表一个 CNN 细胞, 则 CNN 的状态方程如下:

收稿日期: 2004-03-18
作者简介: 张益军 (1979-), 硕士研究生. 主要从事智能控制等方面的学习和研究. E-mail: zyjca@163.com
通讯联系人: 朱庆保 (1955-), 教授. 主要从事机器人路径规划, 人工智能与智能控制等方面的教学与研究.
E-mail: zhuqingbao@njnu.edu.cn




图1 环状 CNN 结构示意图

$$\begin{cases} x_{1j} = -x_{1j} + (1 + \mu)y_{1j} - sy_{2j} + \\ i_1 + D_1 \cdot (y_{1p} + y_{1q} - 2y_{1j}) \\ x_{2j} = -x_{2j} + (1 + \mu)y_{2j} + sy_{1j} + \\ i_2 + D_2 \cdot (y_{2p} + y_{2q} - 2y_{2j}) \end{cases} \quad (1)$$

$$\text{其中 } p = \begin{cases} j+1 & 0 < j < N \\ 1 & j = N \end{cases}$$

$$q = \begin{cases} N & j = 1 \\ j-1 & 1 < j \leq N \end{cases}$$

输出函数为:

$$y_{ij} = 0.5(|x_{ij} + 1| - |x_{ij} - 1|).$$

D_i 为第 i 层细胞之间的连接强度, 这里 $i = 1, 2, j = 1, 2, \dots, N, N$ 为环中细胞的个数.

仿真结果表明, 适当的参数配置, 式 (1) 可以产生自动波^[3]. 但如何评估 CNN 中自动波的稳定性, 到目前为止, 仍没有有效的方法. 为此, 本文使用一条平行于时间轴的直线 $x = c$ 切割所有细胞的振荡轨迹, 如图 2 所示. 虚线和实线分别表示细胞 $i-1$ 和 i 在一段时间内的振荡轨迹. 令 p_f^{ij} 、 p_b^{ij} 分别表示第 j 个周期细胞 i 振荡的前半周期和后半周期; t^{1j} 表示第 j 个周期自动波从细胞 $i-1$ 传递到 i 所用的时间, t^{1j} 表示波从细胞 N 传递到细胞 1 所用的时间. p_f^{ij} 、 p_b^{ij} 和 t^{1j} 的几何意义分别如图 2 中 $|AB|$ 、 $|BC|$ 和 $|DB|$ 部分所示. 下面给出 3 个判定指标:




图2 网络参数指标示意图

- (1) D_f 细胞前半周期 p_f^{ij} 方差 D_f^i 的平均值;
 - (2) D_b 细胞后半周期 p_b^{ij} 方差 D_b^i 的平均值;
 - (3) D_t 自动波传递时间 t^{ij} 方差 D_t^i 的平均值.
- 其中 $i = 1, 2, \dots, N, j = 1, 2, \dots, M, M$ 为自动波周

期的个数.

根据 3 个指标的几何意义, 可得:

$$D_f = \frac{1}{N} \sum_{i=1}^N \sum_{k=1}^M \left(p_f^{ik} - \frac{1}{M} \sum_{j=1}^M p_f^{ij} \right)^2$$

$$D_b = \frac{1}{N} \sum_{i=1}^N \sum_{k=1}^M \left(p_b^{ik} - \frac{1}{M} \sum_{j=1}^M p_b^{ij} \right)^2$$

$$D_t = \frac{1}{M} \sum_{j=1}^M \sum_{i=1}^N \left(t^{ij} - \frac{1}{N \times N} \sum_{k=1}^N (p_f^{kj} + p_b^{kj}) \right)^2$$

显然, 若

$$\lim_{t \rightarrow \infty} D_f = \lim_{t \rightarrow \infty} D_b = \lim_{t \rightarrow \infty} D_t = 0 \quad (2)$$

成立, 则网络中的自动波是稳定的.

在实际应用中, 式 (2) 的要求是很难达到的. 由于测量和计算精度的限制, 即使是理想的振荡, D_f, D_b, D_t 往往比零略大, 因此定义网络中自动波的“健康度”函数, 如下式:

$$f(D_f, D_b, D_t) = \begin{cases} 0 & g(D_f, D_b, D_t) > 5.0 \\ 1 - \frac{g(D_f, D_b, D_t)}{5.0} & \text{其它} \end{cases} \quad (3)$$

$$g(D_f, D_b, D_t) = (e^{f_0 + D_f} + e^{b_0 + D_b} + e^{t_0 + D_t}) - (e^{f_0} + e^{b_0} + e^{t_0}) \quad (4)$$

其中 f_0, b_0, t_0 反映了对应参数 D_f, D_b, D_t 的重要程度, 一般取为 0.8, 0.7 和 0.5. 显然, $f(D_f, D_b, D_t) \in [0, 1]$, 其值越大, 则自动波越“健康”.

2 控制策略

引言中提到, 基于 CNN 的机器人步态控制策略存在诸多缺点, 本文建立图 3 所示的闭环控制. FNN 接受高层控制信号和反馈信号, 根据事先学习的模糊控制规则进行模糊推理, 为调整器提供智力支持. 误差信号经调整器整定后, 作为局部模式发生器 (LPG) 的输入, 使 LPG 产生维持网络稳定运行的模式. LPG 是整个控制器的核心, 采用图 1 所示的环状 CNN 结构. 以下对 FNN 和调整器模块作详细说明.

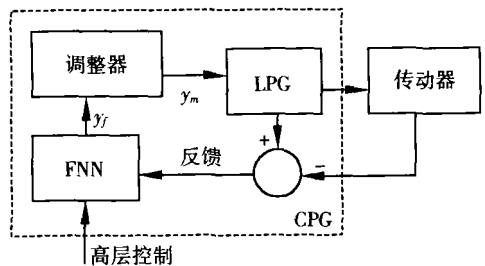


图3 基于 CPG 的控制策略示意图

2.1 模糊神经网络控制器

构造图 4 所示的四层 FNN, 第一、四层分别有 2 个和 3 个神经元, 为输入输出层; 设模糊论域为 Q , 第二和第三层分别有 $2Q$ 和 Q^2 个神经元. 令反馈误差为:

$$e_j^i = \hat{\theta}_j^i - o_j^i \tag{5}$$

其中 $\hat{\theta}_j^i$ 为 LPG 的输出, o_j^i 为传动器的输出.

FNN 的输入 x_i 由式 (5)、(6) 给出.

$$\hat{e}^j = \frac{1}{N} \sum_{k=1}^N e_k^j \tag{6}$$

$$x_i = \log \left[\frac{w}{\frac{1}{N} \sum_{j=1}^N (e_j^i - \hat{e}^j)^2} \right] \tag{7}$$

其中 $i = 1, 2, j = 1, 2 \dots N$, w 表示无干扰的理想状态下网络信号的平均功率. 根据式 (7), FNN 的输入 x_i 即为系统运行过程中的信噪比 (S/N).




图 4 模糊神经网络结构图

FNN 各层的输入输出关系如下:

第一层输出: $y_i^{(1)} = x_i$

第二层输出: $y_{ij}^{(2)} = e^{-\left[\frac{y_i^{(1)} - \xi_{ij}}{\sigma_{ij}} \right]^2}$

第三层输出: $y_{(k-1)N+j}^{(3)} = y_{ik}^{(2)} \cdot y_{2j}^{(2)}$

第四层输出: $y_p^{(4)} = \frac{\sum_{i=1}^{Q \times Q} y_i^{(3)} \cdot w_{ip}}{\sum_{i=1}^{Q \times Q} y_i^{(3)}}$

其中 $y^{(l)}$ 为第 l 层网络的输出, ξ_{ij}, σ_{ij} 为需要调整的参数, w_{ik} 为第三层神经元 i 和第四层神经元 k 间的连接权值. 这里, $i = 1, 2, p = 1, 2, 3, k, j = 1, 2 \dots Q$.

为使网络输入输出达到期望的映射, 使用梯度法调整网络参数和权值, 设 FNN 的实际输出 $y = (y_1^{(4)}, y_2^{(4)}, y_3^{(4)})^T$, 期望输出为 $y^* = (y_1^*, y_2^*, y_3^*)^T$, 定义误差函数 E 为:

$$E = \frac{1}{2} (y - y^*)^2 = \frac{1}{2} \sum_{i=1}^3 (y_i^{(4)} - y_i^*)^2 \tag{8}$$

权值修正函数为:

$$\Delta w_{ij}(t) = -\varepsilon \frac{\partial E}{\partial w_{ij}} + \alpha \cdot (w_{ij}(t-1) - w_{ij}(t-2))$$

其中 ε 为学习效率, α 为动力因子. $i = 1, 2 \dots Q^2; j = 1, 2, 3$

根据式 (7), 得:

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial E}{\partial y} \cdot \frac{\partial y}{\partial w_{ij}} = (y - y^*) \cdot \frac{y_i^{(3)}}{\sum_{i=1}^{N \times N} y_i^{(3)}}$$

使用梯度法调整参数 ξ_{ij}, σ_{ij} 以调整 ξ_{ij} 为例:

$$\xi_{ij}(t) = \xi_{ij}(t-1) - \varepsilon \frac{\partial E}{\partial \xi_{ij}} + \alpha \cdot (\xi_{ij}(t-1) + \xi_{ij}(t-2)) \tag{9}$$

$$\frac{\partial E}{\partial \xi_{ij}} = 2(y - y^*) \times$$

$$\sum_{i=1}^3 \sum_{k=1}^N \sum_{p=1}^{N \times N} y_p^{(3)} \cdot (w_{(j-1)N+i, p} - w_{p, i}) \cdot \left[\frac{\sum_{p=1}^{N \times N} y_p^{(3)}}{\sum_{p=1}^{N \times N} y_p^{(3)}} \right]^2 y_{2l}^{(2)} \times \frac{y_1^{(1)} - \xi_{ij}}{\sigma_{ij}^2} \cdot e^{-\left[\frac{y_1^{(1)} - \xi_{ij}}{\sigma_{ij}} \right]^2}$$

$\xi_{ij}, \sigma_{ij}, \sigma_{ij}$ 的调整公式和式 (9) 具有相似的形式. 当离线完成权值和参数的训练, FNN 就记忆了需要达到的模糊控制规则. 另外, 这里采用的 FNN 是易于用硬件实现的: 可以用电阻产生连接权值, 用加法器实现输入电压和权值的求和, 用电压放大器实现神经网络中非线性传递函数.

2.2 调整器

设调整器的输入信号为 y_f , 输出信号为 y_m , 令:

$$y_f = (K_1, K_2, K_3)^T = (y_1^{(4)}, y_2^{(4)}, y_3^{(4)})^T$$

$$y_m = (\Delta u_1, \Delta u_2 \dots \Delta u_N)^T$$

调整器的误差整合函数定义为:

$$\Delta u_i(t) = K_1 e_i(t) + K_2 \Delta e_i(t) + K_3 \Delta^2 e_i(t)$$

$$\Delta e_i(t) = e_i(t) - e_i(t-1)$$

$$\Delta^2 e_i(t) = e_i(t) - 2e_i(t-1) + e_i^2(t-2)$$

这里 $e_i(t) = (e_i^1, e_i^2), i = 1, 2 \dots N$.

为了给 FNN 提供训练数据, 必须给出在不同误差环境下, 能使自动波稳定传递的参数 K_1, K_2, K_3 . 建立如图 5 所示的结构, 利用遗传算法 GA (Genetic Algorithms) 对 K_1, K_2, K_3 进行全局搜索. 个体采用 0-1 编码, 利用式 (3)、(4) 计算得到的网络健康度作为个体适应度函数, 满足正态分布的随机干扰 d 由 Matlab 中 `normrnd()` 函数产生.

3 仿真实验

为验证本文所提理论的有效性, 进行以下仿真




图5 产生FNN训练数组的框架图

实验。

(1) 对调整器进行适当的参数配置,可消减控制误差对系统稳定性的影响.表1显示了未进行调整时系统在不同信噪比下各指标的值,其中 P_1 、 P_2 和 P_3 分别表示 D_4 、 D_4 和 D_4 (下同);表2是进行误差整合后系统各指标的值.通过对比不难发现,本文提出的控制误差整合策略是有效的.

表1 不同信噪比下网络各指标值

S/N (B)	P_1	P_2	P_3	健康度
> 12.8406	0.007 0	0.026 8	0.050 2	0.969 0
10.557 2	0.082 0	0.137 0	0.070 0	0.878 9
8.262 8	0.194 0	0.116 8	0.183 5	0.788 4
7.107 2	0.511 2	0.321 2	0.275 0	0.446 1

表2 调整误差后网络各指标值

S/N (B)	K_1	K_2	K_3	健康度
7.107 2	2.200 0	- 2.647 1	1.447 1	0.936 6
8.262 8	1.658 8	0.929 4	- 1.494 1	0.928 3

表3 部分输入对应的系统参数指标

模糊网络输入		调整器中的参数			系统参数指标			
X_1	X_2	K_1	K_2	K_3	P_1	P_2	P_3	健康度
7.108 2	8.256 8	2.137 8	- 0.413 5	- 0.302 1	0.033 8	0.043 3	0.104 8	0.930 4
8.258 0	8.259 1	- 0.552 9	2.858 8	- 0.458 8	0.036 5	0.020 1	0.093 0	0.943 1
7.108 3	7.113 4	2.200 0	- 2.647 1	1.447 1	0.043 1	0.062 3	0.052 7	0.936 6
9.415 8	12.841 3	- 1.035 2	- 0.677 4	2.683 3	0.049 5	0.049 8	0.065 3	0.934 6

表4 用模糊神经网络和BP网络时系统运行个参数

网络类型	模糊网络输入		调整器中的参数			系统参数指标			
	X_1	X_2	K_1	K_2	K_3	P_1	P_2	P_3	健康度
模糊神经网络	5.943 5	8.262 3	1.275 7	0.929 6	- 1.146 6	0.066 6	0.028 3	0.069 8	0.934 0
BP网络			2.155 4	- 2.900 3	2.178 9	0.082 9	0.075 1	0.082 2	0.901 9

[参考文献]

[1] Arena P, Fortuna L, Frasca M, et al. Multi-template approach to artificial locomotion control[J]. IEEE Trans on Circ and Syst. 2001(2): 37-40.

(2) 经过训练后的 FNN 能记住模糊控制规则.令模糊集论域 $Q = 5$ 取 50组输入输出对对 FNN进行训练,使网络在一定的误差范围内能产生正确的推理.表3列出了部分用于检测的输入输出和此时网络各参数指标的值.表4对比了利用 FNN和 BP网络进行推理时 CNN的各参数指标,容易看出利用 FNN记忆控制规则,更能使系统稳定.

4 结论

利用 CNN模拟 CPG对机器人步态实行控制的策略其优点在于可以通过电路实现.但 CNN对细胞参数的敏感性,使得控制误差的存在影响系统的稳定性.本文提出的利用 FNN记忆模糊控制规则,来整合控制误差,仿真结果表明其是有效的.同时 FNN并不会增大控制策略硬件实现的难度,一旦训练好权值,其响应时间是极快的.但在 FNN调整下,网络的稳定是指在一定的误差范围内的相对稳定,其主要原因在于遗传算法在搜索调整器参数配置时,往往不能搜到使网络健康度为 1的参数.同时控制策略在设计的过程中也需要很大的计算量,因此一种简单高效的控制策略仍是后续研究的重点.

[2] Arena P, Fortuna L. Analog cellular locomotion control of hexapod robots[J]. IEEE Cont Syst Magazine. 2002. 22(6): 21-36.

[3] Arena P, Fortuna L. Autowaves in single layer CNNs [J]. IEEE Trans on Circ and Syst. 1999(5): 351-354.

[责任编辑: 刘健]