

基于神经网络的专家规则推理系统*

张 冰

(深圳大学电子工程系 深圳 518060)

摘 要 本文将专家在平衡—模拟倒摆小车时记录下来的数据经处理后,用监督式学习的方法训练一前置式神经网络。训练后的神经网络派生出了一组专家尚未意识到或者表达不出来的规则,并将该规则构造的专家系统控制器与使用 Quinlan 的 ID3 算法推导出的规则构造的专家系统控制器进行比较。实验结果表明,神经网络算法学习出来的规则较 ID3 算法推导出的规则更为有效,且更有应用价值。本文成功地将该规则应用于火箭的姿态控制,一类似倒摆小车的问题。

关键词 智能控制, 专家系统, 神经网络, 机器学习

分类号 TP39

An Expert Rule Deduction System Based on Neural Networks

Zhang Bing

(Department of Electrical Engineering, Shenzhen University, Shenzhen, 518060)

Abstract In this paper, we present a method of training a feedforward neural network using supervised learning scheme to balance an inverted pendulum and cart system. The data used to train the neural network was obtained from a human expert doing the same task. The trained neural network uncovers a set of rules which could be very difficult to derive from the human expert. Comparison was made between the neural-network learned rule and a decision tree rule deducted by Quinlan's ID3 induction algorithm using the same set of data. Experiment results showed that the neural network learned rule is more robust. At the same time, we find that the neural network learned rule can be modified to do a similar and more important task—the attitude control of a rocket.

Key words intelligent control, expert system, neural network, machine learning

倒摆小车的平衡控制问题是一个经典的非线性控制问题,它与火箭的姿态控制问题有类似之处。采用常规控制方法处理这类问题需要建立系统的数学模型,求解比较困难。然而,人类独特的平衡机动能力使得人在处理这类问题时却易如反掌。如何模仿人的机动能力,而不是去建立系统复杂数学模型,求解微分方程来解决控制问题一直是控制专家和人工智能学者研究的问题。智能控制采用人工智能的方法,应用专家系统,机器学习,神经网络技术来模仿人的机动控制能力^[5]。本文通过对倒摆小车问题的研究,探讨了如何采用神经网络方法来学习人的平衡控制能力,不同于其它类似的研究^[1~3],神经网络算法获得了人意识不到或者无法表达的经验法则。学习到的控制规则又能应用到类似的问题——火箭姿态的控制。

倒摆小车问题描述为:将一根具有一定质量的倒摆铰接在一个可以在一定长度的导轨上移动的小车上,通过向小车施加一大小固定,方向或左或右的力,使倒摆保持平衡不倒,且小车不超出导轨的两端。系统示意图见图1。倒摆小车系统的数学模型为:

* 1997年12月25日收稿
第一作者:张冰,男,1962年生,副教授

$$\ddot{\theta} = \frac{g \sin \theta - \cos \theta \left[\frac{F + m_p l \ddot{\theta} \sin \theta}{m_c + m_p} \right]}{l \left[\frac{4}{3} - \frac{m_p (\cos \theta)^2}{m_c + m_p} \right]}$$

$$\ddot{x} = \frac{F + m_p l [\ddot{\theta} \sin \theta - \dot{\theta}^2 \cos \theta]}{m_c + m_p}$$




图1 倒摆小车系统示意图

其中, x, \dot{x} 分别为小车在导轨距离导轨中央的位置 ($\pm 2.4\text{m}$) 及小车在导轨的运动速度; $\theta, \dot{\theta}$ 分别为倒摆偏离垂直位置的角度 ($\pm 0.2\text{rad}$) 及角速度; g 为重力加速度; F 为施加到小车上的力 ($\pm 10\text{N}$); m_c 为小车质量 (1.0kg); m_p 为倒摆的质量 (0.1kg); l 为倒摆的长度 (0.5m)。

1 神经网络学习器

1.1 预处理算法

本文提出的前置式神经网络学习控制器如图2所示。神经网络有6个输入节点。人在平衡控制模拟倒摆小车时系统的状态数据 $x, \dot{x}, \theta, \dot{\theta}$ 以及将相应采取的动作 ($\pm F$) 被记录下来。状态数据经过预处理转换成能够体现系统特性的归一化形式。




图2 神经网络学习控制器

6个输入 $u_1 \sim u_6$ 具体的预处理算法如下:

如果 $\theta > TH$ 则 $u_1 = 1.0$

如果 $\theta < -TH$ 则 $u_1 = 0.0$

如果 $\theta_k < TH$ 则 $u_1 = 0.5$

如果 $\theta_k > \theta_{k-1}$ 则 $u_2 = 1.0$, 否则 $u_2 = 0.0$

如果 $\theta_k - \theta_{k-1} > \theta_{k-1} - \theta_{k-2}$ 则 $u_3 = 1.0$, 否则 $u_3 = 0.0$

如果 $x_k > 0.0$ 则 $u_4 = 1.0$, 否则 $u_4 = 0.0$

如果 $x_k > x_{k-1}$ 则 $u_5 = 1.0$, 否则 $u_5 = 0.0$

如果 $x_k - x_{k-1} > x_{k-1} - x_{k-2}$ 则 $u_6 = 1.0$, 否则 $u_6 = 0.0$

其中 $\theta, \theta_{k-1}, \theta_{k-2}$ 和 x_k, x_{k-1}, x_{k-2} 分别为某一时刻, 上一时刻, 上上一时刻倒摆的角度和小车的位置。人相应采取的动作同样经过归一化处理成网络的期望输出 y_k 。若人采取的动作作为 $-F$, 则 $y_k = 0.0$; 若人采取的动作作为 $+F$, 则 $y_k = 1.0$ 。

1.2 神经网络学习算法

根据预处理算法对状态数据进行处理后, 产生可直接训练神经网络的500组输入输出模式。采用的学习算法为标准的BP算法, 节点间加权系数的调节采用下式:

$$\Delta w_{ji}^{n+1} = \epsilon \delta_j \times y_j + \alpha \Delta w_{ji}^n$$

式中: Δw_{ji} 为节点 j 到节点 i 的加权系数调节值, 学习速度 $\epsilon = 0.5$, 衰减系数 $\alpha = 0.5$, δ_i 为节点 i 的反向误差, 对于输出节点 k , 其误差 δ_k 为: $\delta_k = (t_k - y_k) \times y_k \times (1 - y_k)$

对于中间层节点 i , 其误差 δ_i 为: $\delta_i = y^k \times (1 - y^k) \times \sum_{k=1}^m \delta_k w_{ki}$

t_k 为网络第 k 个输出节点期望的输出, m 为某一节点的扇入, y_j 为节点 j 的输出。节点的输出函数采用 Sigmoidal 函数: $y_j = \frac{1}{1 + e^{-(x_j + \sigma_j)}}$, σ_j 节点 j 的偏置临界值, x_j 为节点 j 的输入: $x_j = \sum_{i=0}^n w_{ji} \times y_i$, n 为节点 j 的扇出。

2 仿真实验结果

2.1 神经网络的训练

根据上述算法, 用 500 个经过预处理的输入输出模式训练神经网络。经过第一次循环 500 个模式的学习, 网络的误差大约在 30%; 经第二次对 500 个模式的循环学习后, 网络的误差仅 5%。训练得到的网络节点的权值及各节点的门限值示于表 1。

表 1 经训练后神经网络各节点的权值及临界值

中间节点	中间节点至输入节点的权值及临界值						中间节点临界值	中间节点至输出节点的权值及临界值	
	输入节点							输出节点权值	输出节点临界值
	1	2	3	4	5	6			
1	-13.5	-8.13	8.13	2.50	2.06	-2.05	8.46	-17.4	-6.40
2	12.4	-6.88	6.85	-2.16	-1.78	1.75	-0.835	16.8	
3	-16.1	-0.65	0.67	6.22	3.14	-3.11	3.22	14.2	

学习后的神经网络可以成功地取代人而单独实现对倒摆小车系统的控制, 在模拟实验中倒摆小车系统可以被控制住长达 100 000 个时间步长, 相当于 2000s 的实时时间, 且见不到任何系统失败的迹象。

2.2 从神经网络导出控制规则

本文不仅研究训练神经网络学习人的经验控制倒摆小车系统, 而且研究通过神经网络获取专家经验, 并以规则的形式表达出来, 使之能应用到类似问题上。数据的预处理方法共可能有 $3 \times 2 \times 2 \times 2 \times 2 = 96$ 种不同的输入模式。这些模式输入到训练好的神经网络, 根据输出节点的输出值确定所采取的动作, 若输出小于 0.5 则施加一向左的力, 若输出大于 0.5 则施加一向右的力。如此可将神经网络学到的输入输出对应关系通过以下规则表达出来, 即专家人员的经验通过神经网络学习推理如下:

如果 倒摆的角度大于一开关值 (即倒摆在偏右部分)

则 如果 倒摆的角度向顺时针方向增大 (即倒摆向右倒)

则 施加一向右的力

如果 倒摆的角度向反时针方向减小且倒摆角度变化量增大

则 施加一向左的力

如果 倒摆的角度向反时针方向减小且倒摆角度变化量减小

则 施加一向右的力

如果 倒摆的角度小于一开关值 (即倒摆在偏左部分)

则 如果 倒摆的角度向反时针方向增大 (即倒摆向左倒)

则 施加一向左的力

如果 倒摆的角度在向顺时针方向减小且倒摆角度变化量增大

则 施加一向右的力

如果 倒摆的角度在向顺时针方向减小且倒摆角度变化量减小

则 施加一向左的力

如果 倒摆的角度在一开关值内 (倒摆接进垂直)

则 如果 小车在导轨的右端
 则 如果 小车向右移动
 则 施加一向右的力
 如果 小车向左移动且移动的速度增大
 则 施加一向左的力
 如果 小车向左移动且移动的速度减小
 则 施加一向右的力
 如果 小车在导轨的左端

则 如果 小车向左移动
 则 施加一向左的力
 如果 小车向右移动且移动的速度增大
 则 施加一向右的力
 如果 小车向右移动且移动的速度减小
 则 施加一向左的力

2.3 神经网络算法与 ID3 算法的比较

ID3是由 Quinlan 推出的人工智能领域中一个经典的决策推理算法^[4]，它最初用于计算机对弈，能够从大量的原始数据中归纳演绎出规律性的东西。为了能将神经网络方法与人工智能的决策推理方法进行比较，将训练神经网络的数据用同样的预处理算法处理成具有6个输入特征的模式，作为 Quinlan 的 ID3 决策树推理算法的输入数据，推理出的规则如下：

如果 倒摆的角度大于一开关值
 则 施加一向左的力
 否则 如果 倒摆的角度向反时针方向增大
 则 施加一向左的力
 否则 施加一向右的力
 如果 倒摆的角度在一开关值内
 则 如果 小车在导轨的右端
 则 施加一向右的力
 否则 施加一向左的力
 如果 倒摆的角度小于一开关值
 则 如果 倒摆角度变化量减小
 则 施加一向右的力
 否则 如果 倒摆的角度向顺时针方向增大
 则 施加一向右的力
 否则 施加一向左的力

分别用神经网络规则及决策树规则来构造控制倒摆小车的专家系统，模拟实验的结果示于表2。从中可见，在系统参数不变的情况下，神经网络规则和决策树规则都可以达到在20次随机实验中，每次平衡控制倒摆小车系统200s（10 000个时间步长）的标准。而在系统参数发生变化的三种情况下，神经网络规则仍然能够在20次实验中成功20次，而决策树规则在20次实验只能够分别成功1次，3次和0次。因此神经网络规则具有较好的自适应能力。

表2 神经网络算法导出的规则与决策树规则的性能比较

系统参数				成功率/%	
m_c	m_p	l	F	神经网络	ID3
1.0	0.1	0.5	10	100	100
0.5	0.1	0.15	10	100	1
0.5	0.1	0.25	10	100	3
0.5	0.1	0.25	15	100	0

3 讨论与结论

本文采用神经网络监督式学习的方法，对倒摆小车问题进行了研究，主要目的是为了能够学到人的控制经验，并将其表达出来，以便构造专家系统控制器应用于类似问题。作为本文的一个讨论，我们将上面神经网络算法推导的控制规则应用于火箭的姿态控制。

假设火箭通过其导航系统控制火箭发动机的推力角速度来改变推力角，以减小火箭运行的姿态误差，使火箭实际运行轨迹与期望的轨迹相符。火箭示意图如图3。

$$I\ddot{\theta} = -T \times r \times \sin\phi$$

其中 T 为推力向量； ϕ 为推力角； θ 为火箭的姿态角； r 为火箭箭体的半径； I 为火箭的惯性向量。从数学模型可见，火箭系统与倒摆小车系统有一定的相似




图3 火箭工作示意图

之处。

在仿真实验中, 火箭模型的参数取值如下: 发动机推力 T 为恒定, 大小为 $3.0 \times 10^6 \text{N}$; 火箭的惯性向量 I 大小为 $5.0 \times 10^6 \text{kgm}^2$; 火箭箭体的半径为 $r = 10.0 \text{m}$; 且推力角速度 $\dot{\phi}$ 的取值只能有三种: $\dot{\phi} \pm 10.0 (\text{rad/s})$, $\dot{\phi} = 0.0 (\text{rad/s})$ 。则火箭的姿态控制问题与倒摆小车系统的 BANGBANG 控制问题极为相似。因此将由神经网络推导出来的控制倒摆小车的规则经修改后用于构造控制火箭飞行姿态的专家系统。具体规则推导如下:

如果 火箭的姿态角向右偏离一定角度

则 如果 火箭的姿态角继续向右偏离

则 使推力角速度为+ 10

如果 火箭的姿态角偏向期望值且角度的变化量在增大

则 使推力角速度为- 10

如果 火箭的姿态角偏向期望值且角度的变化量在减小

则 使推力角速度为+ 10

如果 火箭的姿态角向左偏离一定角度

则 如果 火箭的姿态角继续向左偏离

则 使推力角速度为- 10

如果 火箭的姿态角偏向期望值且角度的变化量在增大

则 使推力角速度为+ 10

如果 火箭的姿态角偏向期望值且角度的变化量在减小

则 使推力角速度为- 10

如果 火箭的姿态角在期望值某一误差范围内

则 使推力角速度为0

每次实验首先输入火箭期望的姿态角 θ_{REQ} , 然后输入容许的姿态角误差。实验结果表明, 如果容许的最大姿态角误差在0 和10 之间, 使用上述规则构成的专家系统控制器能够在一定的时间内将火箭姿态从任一初始角度控制返回到期望的姿态角度, 并动态稳定在 θ_{REQ} 的上述误差范围内。表3示出了部分实验结果。

表3 火箭姿态控制的部分实验结果

初始姿态角/rad	期望姿态角/rad	所需时间/s
1.0	0.0	13.7
0.8	0.0	12.2
0.6	0.0	10.5
0.4	0.0	8.55

本文的工作表明神经网络应用的成功与否, 很大程度上取决于训练数据的预处理算法。如何将数据处理成既符合具体问题的特征, 又能适合神经网络学习的经归一化处理的输入输出模式, 是一个与应用领域有关的很重要的问题。

参考文献

- 张冰, 张基宏. 一种基于神经网络的学习控制方法. 深圳大学学报, 1997, 14 (1): 83~88
- Edward Grant, Zhang Bing. A Neural Net Approach to Supervised Learning of Pole Balancing. Proc. of the 4th IEEE Symp. On Intelligent Control. Albany, USA, 1989
- Zhang Bing, Edward Grant. Experiments in Adaptive Rule-Based Control. Proc. of the 3rd Int. Conf. on Industrial Application of AI and Expert Systems. Charleston, USA, Jul. 1990
- Quinlan J.R. Learning Efficient Classification Procedures and Their Application to Chess End Games. Machine Learning, 1983. Michalski edits. Palo Alto, CA: 463~482
- Lisboa P.G.J. 现代神经网络应用. 邢春阳, 阳影等译. 北京: 电子工业出版社, 1996