

学 术 著 作 丛 书

Neural Networks for Adaptive Control

神经网络自适应控制

胡德文 王正志 王耀南 马宏绪 著

国防科技大学出版社

神经网络自适应控制

胡德文 王正志 王耀南 马宏绪 著
周宗潭 徐 昕 沈 辉 尹俊松

国防科技大学出版社
·长沙·

内容简介

神经网络具有本质的非线性逼近能力、容错能力和并行计算能力,为非线性与自适应控制提供了一个统一的模型框架,为控制科学与工程带来了新的机遇与挑战。本书介绍了著者在本领域近年来的一些研究工作积累,包括理论研究以及在机器人眼手/手眼协调、步行机器人控制和移动机器人路径规划和工业过程智能控制等方面的应用。

本书可作为自动控制、计算机科学、人工智能、模式识别、智能机器人、认知科学等有关专业的大学高年级学生和研究生的教学和自学教材,也可供相关领域的科研工作者参考。

图书在版编目(CIP)数据

神经网络自适应控制/胡德文等著. —长沙:国防科技大学出版社, 2005.7

ISBN 7-81099-205-8

I. 神… II. 胡… III. 人工神经网络—自适应控制 IV. TP183

中国版本图书馆 CIP 数据核字(2005)第 069709 号

国防科技大学出版社出版发行

电话:(0731)4572640 邮政编码:410073

<http://www.gfkdcbs.com>

责任编辑:何晋 责任校对:肖滨

新华书店总店北京发行所经销

国防科技大学印刷厂印装

*

开本:850×1168 1/32 印张:11.5 字数:309 千

2006 年 1 月第 1 版第 1 次印刷 印数:1-1500 册

ISBN 7-81099-205-8/TP·19

定价:29.00 元

出版说明

本书被列入国家新闻出版总署“国家九·五重点图书”出版计划,并被列入2003年度军队重点图书出版计划。本书工作得到了多项国家自然科学基金(编号:60171003,60234030,60303012)、国家杰出青年科学基金(编号:60225015)和高等学校优秀青年教师教学科研奖励计划等项目的资助。

本书由胡德文主编,各章节内容相对独立,分别由各位著者根据自己的实际研究工作,围绕神经网络自适应控制这一主题撰写。第一章由周宗潭、沈辉、胡德文、王正志撰写;第二章由胡德文、沈辉、周宗潭、尹俊松撰写;第三、四章由王耀南撰写;第五章由马宏绪撰写;第六章由徐昕和胡德文撰写。

由于本书涉及领域较广,并牵涉不同著者所做的具体工作,内容疏忽之处和一些个人见解在所难免,敬请批评指正。

著 者

2004年7月

目 录

第一章 自组织特征映射神经网络与控制	(1)
1.1 引言	(1)
1.2 自组织神经网络的基本原理	(3)
1.2.1 特征空间的划分	(3)
1.2.2 WTA 竞争学习机制	(3)
1.2.3 SOFM 模型及其学习算法	(5)
1.3 SOFM 算法的稳态性质	(5)
1.3.1 输入空间逼近与广义 Lloyd 算法	(5)
1.3.2 学习向量量化(LVQ) ^[23]	(11)
1.3.3 SOFM 稳态性质定量描述 ^[21]	(13)
1.4 SOFM 算法的规范化数学模型	(20)
1.4.1 改进的自组织神经网络模型	(20)
1.4.2 自组织算法的 ODE 分析	(21)
1.4.3 神经元权重集唯一解的存在性 ^[3]	(24)
1.4.4 神经元权重稳态解的形式	(30)
1.4.5 拓扑保持自组织模型的分析	(35)
1.5 SOFM 算法与系统辨识	(36)
1.5.1 自组织最小二乘辨识	(36)
1.5.2 算法仿真与分析	(40)
1.6 SOFM 在机器人手眼协调控制中的应用	(42)
1.6.1 机器人手眼系统描述	(42)
1.6.2 基于自组织网络的手眼协调控制	(50)
1.6.3 仿真结果	(56)

参考文献	(58)
第二章 非拓扑保持自组织算法	(61)
2.1 神经气体模型	(61)
2.2 群落生长型自组织模型	(62)
2.3 自组织聚类实验	(64)
2.4 GGM 模型用于混沌系统辨识	(71)
2.4.1 混沌系统的相空间重构	(71)
2.4.2 相空间划分与混沌系统辨识	(72)
2.4.3 仿真结果与分析	(74)
2.5 NO 自组织神经网络原理与应用	(77)
2.5.1 引言	(77)
2.5.2 内源性 NO 扩散机制	(79)
2.5.3 规则空间 NO 扩散模型	(82)
2.5.4 NO 自组织神经网络 ^[51]	(91)
2.5.5 GasNets 网络模型及应用	(102)
参考文献	(112)
第三章 神经网络智能控制系统	(118)
3.1 基于高斯函数网络(GPFN)的智能控制	(118)
3.1.1 引言	(118)
3.1.2 GPFN 网络与系统辨识	(119)
3.1.3 基于 GPFN 网络的智能 PID 控制器设计	(125)
3.1.4 仿真实验结果	(131)
3.1.5 小结	(131)
3.2 神经网络非线性智能控制系统	(132)
3.2.1 基于自适应神经网络的智能控制	(133)
3.2.2 单层自适应 Adaline 网络的智能控制器设计	(142)
3.2.3 基于多层自适应网络的非线性自校正控制	(145)
3.3 基于动态递归网络的非线性智能控制	(150)

3.3.1 改进型动态递归网络与控制算法	(150)
参考文献	(160)
第四章 模糊神经网络与自适应控制	(162)
4.1 模糊神经网络自组织控制	(162)
4.1.1 自组织模糊控制器	(162)
4.1.2 模糊神经网络自组织控制系统	(166)
4.1.3 仿真实验结果及应用分析	(182)
4.2 神经网络模糊逻辑推理智能控制	(184)
4.2.1 模糊逻辑控制	(185)
4.2.2 模糊高斯基函数网络推理控制	(189)
4.2.3 神经网络动态系统辨识	(196)
4.2.4 系统仿真结果与倒立摆控制	(199)
参考文献	(203)
第五章 神经网络在两足步行机器人控制中的应用	(204)
5.1 概述	(204)
5.2 两足步行机器人建模	(208)
5.2.1 引言	(208)
5.2.2 解耦模型	(210)
5.2.3 ZMP 计算	(216)
5.3 两足步行机器人稳定性分析与运动控制	(217)
5.3.1 序言	(217)
5.3.2 基本概念	(219)
5.3.3 两足动态步行的姿态稳定性分析及姿态控制器构造	(221)
5.3.4 步态稳定性分析及步态控制	(226)
5.3.5 两足步行机器人动态步行的实时时位控制方案	(237)
5.4 神经网络学习步态控制器	(239)
5.4.1 CMAC 模型及其特点	(239)
5.4.2 神经网络学习步态控制	(242)

5.4.3 计算机仿真研究与结果分析	(247)
5.5 利用 CMAC 神经网络的两足机器人稳定自适应控制 ^[6]	(258)
5.5.1 序言	(258)
5.5.2 CMAC 神经网络与自组织学习结构	(259)
5.5.3 虚拟模型控制与虚拟动态空间	(262)
5.5.4 自适应 CMAC 神经网络控制	(265)
5.5.5 仿真分析	(267)
参考文献.....	(270)
第六章 增强学习与神经动态规划	(271)
6.1 引言	(271)
6.2 增强学习理论的形成和发展	(274)
6.2.1 增强学习的学科基础	(274)
6.2.2 增强学习理论的早期发展	(276)
6.2.3 增强学习理论的成熟	(277)
6.3 神经元的非联想与联想增强学习算法	(278)
6.3.1 神经元的非联想增强学习算法(Non - associative RL)	(278)
6.3.2 联想增强学习算法	(284)
6.4 时域差值学习理论与算法	(289)
6.4.1 Markov 链与多步学习预测问题	(291)
6.4.2 时域差值 TD(Temporal Difference)学习算法	(296)
6.5 基于动态规划的增强学习方法	(301)
6.5.1 MDP 与动态规划.....	(301)
6.5.2 基于动态规划的增强学习方法	(303)
6.6 神经动态规划	(312)
6.6.1 基于线性值函数逼近的时域差值学习算法	(312)
6.6.2 基于 CMAC 的增强学习算法	(315)
6.6.3 非线性函数逼近与残差增强学习算法	(318)

6.6.4 基于执行器 – 评判器结构的神经动态规划方法	(320)
6.7 增强学习与神经动态规划的应用	(322)
6.7.1 增强学习在机器人控制中的应用	(322)
6.7.2 增强学习在非线性系统学习控制中的应用	(334)
6.7.3 增强学习在优化和调度中的应用	(342)
6.8 小结	(344)
参考文献	(345)

第一章

自组织特征映射神经网络与控制

1.1 引言

在人类的认知过程中,除了从教师那里得到知识以外,还有另外一种不需要通过老师而自动地向环境学习以获得知识的能力。在人与环境的接触中,当关于外部环境信息的编码自动地在神经网络中产生时,我们就称为神经网络经历了自组织过程。这种仅依靠环境刺激而实现的自动学习过程称为自组织学习。

在人和其他一些高等生物的神经系统中,还存在一种叫做侧抑制的神经现象,即当一个神经细胞兴奋以后,会对周围其他神经细胞产生抑制作用。这种抑制作用不仅在脊髓和海马体中存在,而且在眼睛的视网膜中也存在。这种抑制作用会使神经细胞之间出现竞争,其结果是某些神经细胞在竞争中获胜。其外在表现形式是获胜神经细胞处于兴奋状态,而其他神经细胞则被抑制。

自组织神经网络就是模拟上述生物神经系统功能而发展起来的人工神经网络的一种类型,该类型神经网络的特点是通过训练,能自动对输入模式进行分类,或者说对输入模式空间进行划分。自组织神经网络一般是由输入层和竞争层构成的两层网络,两层之间各神经元的连接是双向的,通常竞争层各神经元之间还存在横向连接;而在学习算法上,自组织神经网络除了模拟生物神经系统中神经元的

兴奋、抑制作用外,还模拟神经元之间竞争与合作关系的神经动力学过程,它不像大多数其他类型的神经网络那样是以输出误差或能量函数作为学习算法的惟一准则。

自组织的思想源于信息和数据压缩的向量聚类方法。关于自组织的最早模型可以追溯到 20 世纪 50 年代 Lloyd 等的工作。1982 年,芬兰学者 Kohonen 提出了自组织特征映射模型 SOFM(Self Organizing Feature Mapping),这是第一个比较成熟的同时也是目前应用最为普遍的一种神经网络自组织方法。SOFM 引入的 WTA 竞争机制反映了自组织学习最基本的特征。SOFM 模型最早应用于语音和图像处理等领域,近几年来,以 SOFM 为基础又发展了其他自组织网络模型,如神经气体网络模型等。同时,一种生长型自组织神经网络模型也得到了应用和发展,自组织网络的应用范围已扩大到非线性系统的辨识和机器人控制方面。

自组织神经网络的基本工作原理是要在网络竞争层中的各神经元之间展开竞争,竞争的目的是获得对输入模式的响应的机会,而竞争的结果是最终仅有一个神经元成为胜利者,该神经元全权负责对相应输入模式响应(分类)。一般来说,该竞争过程是通过一种称为侧抑制的方法来实现的。所谓侧抑制是指某神经元对其他神经元的抑制作用只局限于其周围的临近神经元,而对更远处的神经元则不产生抑制作用。

以上述竞争和侧抑制过程为基础的神经网络模型一般都具有自组织能力,这方面最具代表性的模型就是自组织特征映射 SOFM 和由该模型推广出来的如神经气体网络。ART(Adaptive Resonance Theory,自适应共振理论)是另外一种具有自组织能力的重要神经网络模型,限于篇幅,本书暂不讨论。下面就介绍自组织特征映射(SOFM)神经网络的基本结构和学习算法,结合非线性系统辨识和机器人手眼系统的控制问题,介绍自组织神经网络在控制系统中的应用方法。

1.2 自组织神经网络的基本原理

1.2.1 特征空间的划分

为了使自组织神经网络能够实现对特征空间的划分,首先选取一定数量的处理单元作为神经元聚类中心,使得每个神经元对应于一个类别子空间。设在特征空间 U 中共有 n 个神经元, w_r 是第 r 个神经元聚类中心的权重, U_s 为神经元 s 所对应的类别子空间,则这 n 个神经元可完成对特征空间的如下分割:

$$U_s = \{u \in U \mid \|u - w_s\| \leq \|u - w_r\|, r = 1, 2, \dots, n\} \quad (1.1)$$

自组织学习的目的就是为了实现这么一种空间分割。对于二维特征空间,式(1.1)所实现的空间分割区域 $\{U_s\}$ 一般被称为 Voronoi 区。学习过程是通过不断调整各神经元聚类中心权重 w_r ,使全部的神经元集合(构成了自组织神经网络)能根据特征空间的样本分布形成相应的分类结构。为便于描述,引入能量函数:

$$E = \int_{u \in U} p(u) \|u - w_s\|^2 du \quad (1.2)$$

其中, $p(u)$ 是特征空间 U 中样本 u 的概率密度, s 是 u 所在子空间的聚类神经元。从原理上可以认为自组织学习就是一个根据样本序列 u_k 通过不断调整各神经元的权重 w ,而极小化能量函数 E 的过程。

为了实现自组织学习,首先要引入 WTA 竞争学习机制。

1.2.2 WTA 竞争学习机制

自组织神经网络一般采用所谓的“赢家通吃”(Winner Takes All, WTA)的竞争学习机制。考虑图 1.1 所示的一种由两层神经细胞组成的神经网络结构。我们可以看出,在竞争层各细胞之间具有侧抑

制型的连接关系:每个细胞和其本身之间的连接是兴奋型连接(正权重),而不同细胞之间的连接是抑制型连接(负权重)。另外,在图 1.1 中,处于竞争层的所有细胞单元从输入层接收同样一组输入。




图 1.1 自组织 WTA 竞争机制

假设在输入层有一个刺激(向量) X ,竞争层的每个细胞(称为神经元)都对该输入向量的刺激具有响应:

$$\theta_i = h(W_i, X) \quad (1.3)$$

其中, W_i 是第 i 个神经元的权重向量, θ_i 是该细胞对输入 u 的响应, h 是神经元的响应函数。侧抑制竞争的动态方程为:

$$\frac{dO_i}{dt} = \alpha O_i + f(\theta_i) - \sum_{j, j \neq i} g(O_j) \quad (1.4)$$

其中, O_i 是第 i 个神经元的输出, f 和 g 分别是兴奋连接和抑制连接函数, α 是动态系数。假设在竞争层中有一个神经元 s ,它对于刺激 X 的响应 θ_i 比层内其他神经元的响应具有更大的值,则通过侧抑制竞争,该神经元的响应会得到增强,而层内的所有其他神经元的响应输出则最终会变为 0(图 1.2)。这种类型竞争神经网络常被称为 WTA 网络,WTA 是实现自组织学习的基本机制。




图 1.2 神经细胞层的动态输出

1.2.3 SOFM 模型及其学习算法

SOFM 所建的就是图 1.1 所示的 WTA 竞争细胞网络。另外, SOFM 还是一种保持拓扑的网络结构, 其神经元的分布一般取为空间网格的形式。SOFM 的分类功能是利用自组织学习过程实现的, 通过学习可以实现对特征空间中的输入向量进行自适应聚类。自组织学习算法的权重调整公式是:

$$\Delta w_r = \epsilon h_{rs}(u - w_r), \forall r \quad (1.5)$$

其中, s 对应于输入 u 在竞争中取胜的神经元 (Winner) ($\|u - w_s\| \leq \|u - w_r\|, \forall r$)。 ϵ 是学习增益系数, 一般取为依学习次数 t 指数下降函数:

$$\epsilon = \epsilon_0 e^{-\alpha t} \quad (1.6)$$

h_{rs} 是邻域作用函数, 其目的是使 Winner 神经元 s 附近的其他神经元也共享学习调整:

$$h_{rs} = e^{-\frac{\|r-s\|^2}{2\sigma^2}} \quad (1.7)$$

σ 决定邻域的范围, 一般也取为依学习次数 t 指数下降函数:

$$\sigma = \sigma_0 e^{-\alpha t} \quad (1.8)$$

这样, 各神经元的邻域范围随学习过程不断减小。在式(1.7)中, $\|r-s\|$ 是神经元 r 和 s 之间的拓扑距离。如果两个神经元是相邻的, 则有 $\|r-s\| = 1$ 。当输入 u 与神经元 s 的权重 w_s 有差别时, 除了对 w_s 本身进行修正外, s 邻域其他神经元的权重也将依拓扑距离 $\|r-s\|$ 作一定的调整, 越靠近 s 的神经元, 其权重调整幅度越大。

1.3 SOFM 算法的稳态性质

1.3.1 输入空间逼近与广义 Lloyd 算法^[23]

下面讨论当自组织特征映射算法收敛后, 网络呈现在输入空间

的重要统计特性。令 X 表示一个连续的输入(数据)空间,其拓朴性质由输入向量 $x \in X$ 的距离测度描述。令 A 表示一个离散的输出空间,其拓朴性质由网络上神经元的标号描述。令 ϕ 表示一个非线性变换,这是从输入空间 X 到输出空间 A 的特征映射

$$\phi: X \rightarrow A \quad (1.9)$$

是获胜神经元对输入向量的响应。例如,在神经生理学中,输入空间 X 可代表整个躯体上密布的体感受器的坐标系,而输出空间 A 则代表大脑皮层中与体感受器对应的神经元集合。给出一个输入向量 x ,自组织网络首先从输出空间中找出一个与输入最佳匹配(即获胜)的神经元。

性质 1.1(输入空间逼近):由输出空间 A 中一组突触权向量 $\{w_j\}$ 表示的特征映射 ϕ 是输入空间 X 的一个良好的逼近。

SOFM 算法的根本目的是寻找较小的权重集合以存储更大的输入向量集合 $w_j \in A$,从而对原始输入空间 X 进行良好的逼近。这一思想的基础来自向量量化理论,其原始动机是降维或数据压缩。下面对这一理论作津单介绍。




图 1.3 编码—解码模型

如图 1.3, $c(x)$ 是输入向量 x 的一个编码器, $x'(c)$ 是 $c(x)$ 解码器。向量 x 是从训练样本(即输入空间 X)中随机地选取的,概率密度函数为 $f_x(x)$ 。最佳的编码—解码方案是通过改变函数 $c(x)$ 和 $x'(c)$,使得期望的畸变最小化:

$$D = \frac{1}{2} \int_{-\infty}^{\infty} dx f_x(x) d(x, x') \quad (1.10)$$

其中, $d(x, x')$ 是畸变的度量,通常取为输入向量 x 与重构向量 x' 的

欧氏距离平方,

$$d(x, x') = \|x - x'\|^2 = (x - x')^T (x - x') \quad (1.11)$$

广义 Lloyd 算法给出了使期望畸变 D 最小化的必要条件, 可分成两个方面:

步骤 1: 给定输入向量 x , 选取码 $c = c(x)$, 使得平方误差畸变 $\|x - x'(c)\|^2$ 最小化。

步骤 2: 给定码 c , 计算重构向量 $x' = x'(c)$, 作为输入向量 x 的中心, 使之满足步骤 1。

步骤 1 就是最近邻编码规则。步骤 1 和步骤 2 意味着平均畸变 D 对于编码器 $c(x)$ 和解码器 $x'(c)$ 都是局部最小的。为构造向量量化, 以批训练模式运行广义 Lloyd 算法。一般来讲, 计算过程包括根据步骤 1 优化编码器 $c(x)$ 和根据步骤 2 优化解码器 $x'(c)$, 二者交替进行, 直至期望的畸变 D 达到最小。为了克服局部最小问题, 可从不同初始码向量开始, 多次运行广义 Lloyd 算法。

Luttrell^[10,11] 指出, 广义 Lloyd 算法与 SOFM 算法非常相似。我们在图 1.4 中画出这种联系, 图中在编码器之后引入了噪声 v , 与输入信号 x 是独立的, 可理解为编码器与解码器之间的一个虚假的“通信频道”, 为的是考虑输出码 $c(x)$ 畸变的可能性。由此, 我们可考虑一种修改的期望畸变:




图 1.4 有噪声的编码—解码模型

$$D_1 = \frac{1}{2} \int_{-\infty}^{\infty} dx f_x(x) \int_{-\infty}^{\infty} dv \pi(v) \|x - x'(c(x) + v)\|^2 \quad (1.12)$$

其中, $\pi(v)$ 是加性噪声 v 的相应概率密度函数(pdf), 第二个积分只针对该噪声的各种可能实现。与广义 Lloyd 算法一样的是, 图 1.4 的模型也要考虑两个单独的优化, 一个是编码, 另一个是解码。对给定的输入 x , 为得到最优编码, 要求期望畸变 D_1 对编码向量 c 的偏导数:

$$\frac{\partial D_1}{\partial c} = \frac{1}{2} f_x(x) \int_{-\infty}^{\infty} dv \pi(v) \frac{\partial}{\partial c} \|x - x'(c)\|_{c=c(x)+v}^2 \quad (1.13)$$

对于给定的 c , 为求得最优解码, 要求期望畸变 D_1 对解码向量 $x'(c)$ 的偏导数:

$$\frac{\partial D_1}{\partial x'(c)} = \int_{-\infty}^{\infty} dx f_x(x) \pi(c - c(x)) (x - x'(c)) \quad (1.14)$$

考虑到上面两个偏导数公式, 对广义 Lloyd 算法的步骤 1 和步骤 2 作如下修改^[10]。

步骤 I: 给出输入向量 x , 选取码 $c = c(x)$, 使得如下畸变测度最小化

$$D_2 = \int_{-\infty}^{\infty} dv \pi(v) \|x - x'(c(x) + v)\|^2 \quad (1.15)$$

步骤 II: 给定 c , 计算重构向量 $x'(c)$, 使之满足

$$x'(c) = \frac{\int_{-\infty}^{\infty} dx f_x(x) \pi(c - c(x)) x}{\int_{-\infty}^{\infty} dx f_x(x) \pi(c - c(x))} \quad (1.16)$$

上式是由(1.14)式求解得到的。

图 1.3 描述的模型可以看做是图 1.4 模型的一个特例。如果我们令噪声的概率密度函数等于 Dirac- δ 函数 $\delta(v)$, 则步骤 I 和步骤 II 分别退化为广义 Lloyd 算法的一个特例。为简化步骤 I, 假设 $\pi(v)$ 是 v 的光滑函数, 则可证明, 对二阶逼近而言, 由式(1.15)定义的畸变测量 D_2 由两部分组成: 一般意义的畸变项, 由平方误差畸变 $\|x - x'(c)\|^2$ 表示; 曲率项, 来源于噪声模型 $\pi(v)$ 。