



递归时滞神经网络的 综合分析与动态特性研究

张化光 著



科学出版社

www.sciencep.com

国家科学技术学术著作出版基金资助出版

递归时滞神经网络的 综合分析与动态特性研究

张化光 著

科学出版社

北京

内 容 简 介

本书系统地研究了递归时滞神经网络的动态特性。全书共九章,针对一系列递归时滞神经网络模型的全局性能进行了分析,给出了时滞、参数摄动、互联结构约束等对其性能的影响。书中所给的动态性能分析方法包括M矩阵、代数不等式以及线性矩阵不等式方法等。本书的主要特点是透彻的性能分析及严谨的理论证明,特别是在时滞、参数摄动以及新型递归神经网络设计等方面提出了开创性的设计与分析方法。书中的内容全部来源于作者近年来的创新性研究成果,新颖实用,研究方法先进,具有重要的理论研究和实际应用价值。

本书适合于高等院校中应用数学、物理学、控制科学、计算机科学、信息技术等专业的高年级本科生、研究生和教师使用,同时也可供相关的科技人员作为参考书使用。

图书在版编目(CIP)数据

递归时滞神经网络的综合分析与动态特性研究/张化光著. —北京:科学出版社, 2008

ISBN 978-7-03-021212-2

I. 递… II. 张… III. 递归论-人工神经网络-研究 IV. TP183

中国版本图书馆 CIP 数据核字(2008)第 035225 号

责任编辑:张海娜/责任校对:邹慧卿

责任印制:刘士平/封面设计:耕者设计工作室

科学出版社 出版

北京东黄城根北街16号

邮政编码:100717

<http://www.sciencep.com>

双青印刷厂 印刷

科学出版社发行 各地新华书店经销

*

2008年5月第 一 版 开本:787×1092 1/16

2008年5月第一次印刷 印张:16

印数:1—3 000 字数:368 000

定价:60.00 元


(如有印装质量问题,我社负责调换〈双青〉)

序

人类的大脑目前是世界上最具复杂性的事物之一,其细胞之间相互连接,形成纵横交错的网状结构,进而构成了一个非常复杂并且高效的信息处理网络。人工神经网络正是模拟人脑的工作模式而提出的一种信息处理网络。从 20 世纪 40 年代人工神经网络首次进入人们的视野到现在,人工神经网络已经广泛应用在经济、医疗、工业、农业等各个领域,被数学、经济学、电子科学、控制科学及工程学等学科作为重要的研究对象和研究工具。特别是在控制领域中,人工神经网络已经成为信号处理、系统建模和模式识别等方向上不可替代的工具。

近几十年来,已经出版了很多关于神经网络方面的书籍,但是真正把神经网络的动态特性作为研究对象的专著还难得一见。动态特性是神经网络本身的重要特点,具有良好的动态特性是应用神经网络的重要条件。本书正是从神经网络动态特性与综合分析的角度出发,对其进行了系统而深入的研究。本书的作者张化光教授及其课题组经过多年的研究与探索,在神经网络这一课题上取得了许多创新性的研究成果。这些成果分别发表在国内外有影响的期刊上,如: *IEEE Transactions on Neural Networks*、*IEEE Transactions on Circuits and Systems*、*Neurocomputing*、*International Journal of Intelligent Control and Systems*、《物理学报》、《电子学报》、《自动化学报》、《自然科学进展》等。本书可以分为三部分:时滞递归神经网络(包括 Hopfield 神经网络、细胞神经网络及 Cohen-Grossberg 神经网络)的动态特性分析;广义递归时滞神经网络(包括 Hopfield 神经网络、细胞神经网络)的动态特性分析;一种新型神经网络——时滞模糊双曲神经网络的动态特性分析。其中第一部分解决了这些经典神经网络中至今仍存在的众多难点和热点问题;后两部分则是对作者近年来独创性工作的阐述,它们既丰富了神经网络理论,同时也填补了该领域的空白。本书涵盖了作者近年来的学术研究成果,同时又有比较系统、完整的理论基础和应用实例,为该领域的进一步深入研究和工业应用提供了极好的参考,是神经网络理论及应用方面不可多得的一本好书。

中国科学院院士



2007 年 12 月 1 日于青岛

前 言

自从 1982 年美国加州理工大学生物理学家 Hopfield 提出了 Hopfield 递归神经网络以来,包括 Hopfield 神经网络、Cohen-Grossberg 神经网络和细胞神经网络等网络在内的递归神经网络,以其在优化、联想记忆、信号处理、图像处理以及模式识别等方面应用的优点,迅速成为人们关注的热点。而随着人们研究的不断深入,且由于神经网络在以上方面的应用都与网络的动态特性有关,所以网络的动态特性也就成了递归神经网络研究方面的重点问题和学术界的前沿。

众所周知,在神经网络的信息传递过程中存在着时滞,而时滞意味着网络模型与过去时间的状态有关。在现有神经网络模型上引入轴突信号传输时滞,那么相应的动力学系统就变成了带时滞的非线性动力学系统。由于时滞对系统的动态特性有很大的影响,例如,时滞常常导致系统失稳,甚至有可能产生周期振荡或混沌现象,因此具有时滞的神经网络模型比无时滞神经网络模型有着更加丰富的动力学特性、更加复杂的分析方法,以及更加实际的研究价值。

本书正是以带有时滞的递归神经网络——递归时滞神经网络为研究对象,对其进行综合分析及动态特性研究,包括对递归时滞神经网络的平衡点的唯一性、稳定性以及鲁棒稳定性等网络的动态特性的分析与研究。全书共分 9 章,其中第 1 章对当前的递归时滞神经网络进行了综合的分析,并介绍了相应的分析方法和数学工具;第 2 章针对时滞 Hopfield 神经网络进行包括稳定性和鲁棒稳定性分析在内的综合分析;第 3 章针对时滞细胞神经网络进行了平衡点稳定性的分析和研究;第 4 章针对时滞递归神经网络进行动态特性的分析和研究;第 5 章和第 6 章针对两类广义递归时滞神经网络进行动态特性的分析和研究;第 7 章和第 8 章针对 Cohen-Grossberg 神经网络进行鲁棒稳定性的分析和研究;第 9 章构造了一种新型的时滞模糊双曲神经网络,并对其动态特性进行了分析和研究。

本书中所讲述的内容是作者近几年的研究成果,内容新颖实用,研究方法先进,属于当前学术界的前沿问题,因此具有重要的理论研究和实际应用价值。

在本书的写作过程中,作者的几位博士生为本书提供了大量的素材和辛勤的劳动,他们分别是王占山、季策、汪刚、关焕新。另外,博士生刘振伟、张欣及崔黎黎在手稿整理、仿真实验和校对文稿等方面做了大量的工作,作者在这里向他们表示由衷的感谢。

本书的出版得到了国家科学技术学术著作出版基金的资助,项目的研究得到了国家自然科学基金(项目编号:60534010,60572070,60521003,60774048,60728307)、长江学者和创新团队发展计划以及东北大学 985 学科建设经费的资助,在此表示感谢。

由于作者水平有限,疏漏之处在所难免,热忱欢迎读者与同行不吝赐教。

张化光

2008 年 1 月于东北大学

目 录

序

前言

第 1 章 递归时滞神经网络及系统动态分析基础	1
1.1 人工神经网络简介	1
1.2 递归神经网络简介	2
1.3 时滞对递归神经网络动态特性的影响	7
1.4 神经元的激励和抑制对网络动态特性的影响	9
1.5 递归时滞神经网络的动态特性分析方法和内容	10
1.6 递归时滞神经网络动态特性分析的预备知识	11
参考文献	19
第 2 章 时滞 Hopfield 神经网络的综合分析	23
2.1 引言	23
2.2 单时滞不对称 Hopfield 神经网络的动态特性分析	24
2.3 单时滞 Hopfield 神经网络模型的鲁棒稳定性分析	27
2.4 多定常时滞不对称 Hopfield 神经网络模型的动态特性分析	32
2.5 多定常时滞 Hopfield 神经网络模型的鲁棒稳定性分析	36
参考文献	45
第 3 章 时滞细胞神经网络的动态特性研究	47
3.1 相关假设和引理	47
3.2 多时滞细胞神经网络的动态特性分析	48
3.3 具有混合时滞的细胞神经网络的动态特性分析	59
参考文献	65
第 4 章 时滞递归神经网络的综合分析	67
4.1 多时变时滞递归神经网络的动态分析	67
4.2 多时变时滞递归神经网络的鲁棒稳定性分析	78
参考文献	82
第 5 章 第一类广义递归时滞神经网络的综合分析	84
5.1 第一类广义递归时滞神经网络	84
5.2 多时变时滞递归神经网络时滞依赖稳定性判据	87
5.3 多时变时滞递归神经网络时滞独立稳定性判据	95
5.4 第一类广义多时变时滞递归神经网络动态特性分析	104
5.5 第一类广义多时滞参数摄动递归神经网络的鲁棒稳定性分析	117
5.6 第一类广义多时变时滞递归神经网络鲁棒稳定性分析	129
参考文献	138

第 6 章 第二类广义递归时滞神经网络的动态特性分析	142
6.1 第二类广义递归时滞神经网络	142
6.2 第二类广义多时变时滞递归神经网络动态特性分析	144
6.3 带有分布时滞的变系数第二类广义递归神经网络动态特性分析	156
参考文献	161
第 7 章 时滞 Cohen-Grossberg 神经网络的综合分析	164
7.1 引言	164
7.2 单时滞不对称 Cohen-Grossberg 神经网络模型的动态特性分析	165
7.3 单时滞 Cohen-Grossberg 神经网络模型的时滞依赖稳定性分析	168
7.4 单时滞 Cohen-Grossberg 神经网络模型鲁棒稳定性分析	173
7.5 多时滞 Cohen-Grossberg 神经网络模型的稳定性	178
7.6 多时滞 Cohen-Grossberg 神经网络模型的鲁棒稳定性	183
参考文献	191
第 8 章 时变时滞区间 Cohen-Grossberg 神经网络的鲁棒稳定性分析	194
8.1 引言	194
8.2 问题描述	194
8.3 相关假设和引理	195
8.4 时滞区间 Cohen-Grossberg 神经网络的鲁棒稳定性分析	196
参考文献	213
第 9 章 时变时滞模糊双曲神经网络的动态特性分析	215
9.1 引言	215
9.2 相关基础知识	216
9.3 时变时滞模糊系统和时变时滞模糊基函数	219
9.4 时变时滞模糊双曲神经网络的模型和实现	228
9.5 时变时滞模糊双曲神经网络的稳定性分析	238
参考文献	242
索引	244
本书中使用的符号	248

第 1 章 递归时滞神经网络 及系统动态分析基础

近 20 年来,由于神经科学、数理科学、信息科学、计算机科学的快速发展,人类认识和了解自身的速度进一步加快,作为研究人类自身科学的重要成果之一的人工神经网络也得到进一步发展。

目前,人们已提出近百种的人工神经网络模型。其中,有的是从人脑生物原型中借鉴的,因而在一定程度上模仿了人脑的某种功能,但也有一些是从数学模型中推导出的。事实上,不论这些模型是通过何种途径诱发而生成的,它们在模式识别、系统辨识、信号处理、自动控制、组合优化、预测预估、故障诊断、专家系统以及经济管理等领域已卓有成效地解决了许多传统数字计算机所难以解决的实际问题,表现出了很好的智能特性和潜在的应用前景。

1.1 人工神经网络简介

为了模拟大脑的基本特性,在现代神经科学研究的基础上,人们提出了人工神经网络的模型。神经元(神经细胞)是神经网络的基本处理单元,神经元模型如图 1.1.1 所示。轴突的功能是将本神经元的输出信号(兴奋)传递给其他神经元,其末端的许多神经末梢使得兴奋可以同时传送给多个神经元。树突的功能是接受来自其他神经元的兴奋。神经元的树突与其他神经元的神经末梢相连的部分称为突触。神经元细胞体将接受到的所有信号进行简单的处理后由轴突输出。大脑之所以能够处理极其复杂的分析、推理工作,一方面是因为其神经元数量的庞大,另一方面还在于神经元能够对输入信号进行非线性处理。

神经网络具有大规模的并行处理能力和分布式的信息存储能力,并有良好的自适应、自组织性以及很强的学习功能、联想功能和容错功能。与当今的冯·诺依曼式计算机相比,神经网络更加接近人脑的信息处理模式。人工神经网络的特点和优越性,主要表现在以下几个方面。

第一,具有自学习功能。例如,在利用神经网络实现图像识别时,只要先把许多不同的图像样本和对应的应识别的结果输入到人工神经网络,网络就会通过自学习功能,慢慢学会识别类似的图像。自学习功能对于预测有特别重要的意义。未来的人工神经网络计算机将为人类提供经济预测、市场预测、效益预测,应用前景令人瞩目。

第二,具有联想记忆功能。人的大脑是具




图 1.1.1 神经元模型

有联想功能的,利用人工神经网络的反馈网络同样可以实现这种联想。

第三,具有高速寻找优化解的能力。寻找一个复杂问题的优化解,往往需要很大的计算量,利用一个针对某问题而设计的递归型人工神经网络,可以发挥计算机的高速运算能力,很快找到优化解。

第四,具有鲁棒性强的特点。人工神经网络的结构特点和其信息存储的分布式特点,使得它相对于其他的判断识别系统(如专家系统)具有一个显著的优点:鲁棒性。生物神经网络不会因为个别神经元的损失而失去对原有模式的记忆。最有力的证明是,一个人的大脑之所以能够处理极其复杂的分析、推理工作,一方面是由大脑的生理机制决定的;另一方面是大脑因意外事故受轻微损伤之后,并不会失去对原有事物的全部记忆。人工神经网络也有类似的情况。因某些原因,无论是网络的硬件实现还是软件实现中的某个或某些神经元失效,整个网络仍然能继续工作。

人工神经网络同现行的计算机网络不同,是一种非线性的处理单元。只有当神经元对所有的输入信号的综合处理结果超过某一阈值后才输出一个信号。因此,神经网络是一种具有高度非线性的超大规模连续时间动力学系统。它突破了传统的以线性处理为基础的数学电子计算机的局限,标志着人们智能信息处理能力和模拟人脑智能行为能力的一大飞跃。

由于人工神经网络所具有的这些优良特性,它已经逐步渗入到其他研究领域,如计算机科学、控制论、信息科学、微电子学、心理学、认知科学、物理学、数学、力学等学科^[1~5,95],并取得了丰富的成果。

1.2 递归神经网络简介

人工神经网络因其自组织、自适应和自学习的特点被广泛应用于各个领域,在非线性系统建模与控制的应用中也发挥着越来越大的作用。不过,一般采用的前向网络所建立的输入/输出之间的关系式往往是静态的,而实际应用中的被控对象通常都是时变的。因此,采用静态神经网络建模就不能准确地描述系统的动态性能。描述系统动态性能的神经网络应当具有反映系统动态特性和存储信息的能力。这就要求网络中存在信息的延时,并具有延时信息反馈。有别于前向网络,这类网络被人们称为递归神经网络或反馈神经网络。递归网络存储信息的特性正是来源于网络信号的反馈,信号反馈使得网络在 k 时刻的输出状态不仅与 k 时刻的输入状态有关,而且还与 k 时刻以前的信号有关,从而表现出网络系统的动态特性。为了适应多种不同动态性能的要求,人们已经提出几十种类型的递归神经网络模型。各种网络由于结构上的不同,必然导致输入/输出关系式的相异,因而表现出不同的动态变化性能。需要指出的是,由于网络中存在着递归信号,网络的状态是随时间的变化而变化的,其运动轨迹必然存在着稳定性的问题。这就是递归网络与前向网络在网络性能分析上最大的区别之一。在使用递归网络时,必须对其稳定性进行专门的分析与讨论,合理选择网络参数的变化范围,才能确保递归网络的正常工作。

递归神经网络是从1982年美国加州物理学家Hopfield提出了Hopfield神经网络模型(HNN)、能量函数及网络稳定性等概念之后才真正发展起来的。Hopfield神经网络模型、Cohen-Grossberg神经网络模型和细胞神经网络模型等网络模型都属于递归型神经

网络。递归型网络的应用都是与其动态性能相关的。例如, Hopfield 网络用于优化时, 要求网络只具有唯一的一个平衡点, 该平衡点对应于待求解的目标, 而且随着时间的增长, 要求网络的所有状态都趋近于这个平衡点, 从数学上看, 就是要求网络必须是全局稳定(渐近稳定或指数稳定)的; 细胞神经网络用于图像处理时, 希望网络的平衡点尽可能地多, 这样就可以将处理后的结果存储于这些平衡点上, 而且网络的状态在一段时间后也要趋近于某个平衡点, 这对应于系统是完全稳定的; 细胞神经网络用于保密通信时, 要求网络是混沌的, 这样可以利用混沌的高度复杂的伪随机性进行加密。因此, 研究递归型神经网络的动态特性具有十分重要的理论及现实意义。事实上, 自 1982 年提出 Hopfield 模型以来, 神经网络的动态特性(主要是指平衡点特性、稳定性、极限环以及混沌等)的研究一直在神经网络理论研究中占有重要的地位。下面, 简要阐述一下几种递归神经网络模型的动态特性及研究现状。

1.2.1 Hopfield 神经网络模型

1982 年, 美国加州理工大学生物物理学家 Hopfield 开创性地在物理学、神经生物学和计算机科学等领域架起了桥梁, 提出了一种新型的连续神经网络模型^[6](原始的 Hopfield 模型), 可用如下常微分方程组来描述:

$$C_i \frac{dx_i}{dt} = -\frac{x_i}{R_i} + \sum_{j=1}^n T_{ij} g_j(x_j) + I_i, \quad i = 1, \dots, n \quad (1.1)$$

其中, 电阻 R_i 和电容 C_i 的并联模拟了生物神经输出的时间常数, 电导 T_{ij} 则模拟神经元之间互连的突触特征, 且如果 $i = j$, 则 $T_{ij} = 0$ 。运算放大器 $g_j(x_j)$ 模拟神经元的非线性特性, 其为连续有界、可微、严格单调的增函数, x_i 为第 i 个神经元的输入 ($i, j = 1, \dots, n$)。

可以看出, 基本的 Hopfield 神经网络是一个由非线性元件构成的全连接型单层递归系统。网络中的每一个神经元都将自己的输出通过连接权传送给所有其他神经元, 同时又都接收所有其他神经元传递过来的信息, 即网络中的神经元在 t 时刻的输出状态实际上间接地与自己 $t-1$ 时刻的输出状态有关。因此, Hopfield 神经网络是一个递归型的网络, 其状态变化可以用差分方程来表征。递归型网络的一个重要特点就是它具有稳定状态。当网络达到稳定状态的时候, 也就是它的能量函数达到最小的时候。这里的能量函数不是物理意义上的能量函数, 而是在表达形式上与物理意义上的能量函数一致, 即它表征网络状态的变化趋势, 并可以依据 Hopfield 网络模型的工作运行规则不断地进行状态变化, 最终能够到达具有某个极小值的目标函数。网络收敛就是指能量函数达到极小值。如果把一个最优化问题的目标函数转换成网络的能量函数, 把问题的变量对应于网络的状态, 那么 Hopfield 神经网络就能够用于解决优化组合问题。

Hopfield 神经网络工作时, 其各个神经元的连接权值是固定的, 更新的只是神经元的输出状态。Hopfield 神经网络的运行规则为: 从网络中随机选取一个神经元进行加权求和, 计算该神经元 $t+1$ 时刻的输出值; 除该神经元以外的所有神经元的输出值保持不变, 以此类推, 再计算 $t+2$ 时刻的值, 直至网络进入稳定状态。

对于同样结构的网络, 当网络参数(指连接权值和阈值)有所变化时, 网络能量函数极小点(称为网络的稳定平衡点)的个数和极小值的大小也将变化。因此, 可以把所需的记

忆模式设计成某个确定网络状态的一个能量函数极小点,即稳定平衡点。若网络有 M 个平衡点,则可以记忆 M 个模式。

当网络从与记忆模式较靠近的某个初始状态(相当于发生了某些变形或含有某些噪声的记忆模式,也即只提供了某个模式的部分信息)出发后,网络按 Hopfield 工作运行规则进行状态更新,最后网络的状态将稳定在能量函数的极小点,这样就完成了由部分信息开始的联想过程。

“能量函数”的概念使人们对这类非线性模型的稳定性研究有了明确的判据。构造合适的能量函数并利用相应的 Lyapunov 判定定理来给出网络稳定性的充分条件成为最重要也是最基本的工具。但遗憾的是,至今人们也没有找到一种普适的构造方法,因而实践中只能依赖个人的经验去选取合适的 Lyapunov 泛函。在早期的研究中,通常假设神经元之间的突触连接权矩阵是对称阵,这显然与实际不符,更加合理的假设是放弃对连接权矩阵对称的假设,即连接权矩阵可以是非对称的。通过对原始的能量函数加以修改,人们获得了许多稳定性准则。除此之外,研究还发现,非对称的连接会使网络的动态特性更加丰富^[7]。从使用的方法上来看,多数采用的仍是 Lyapunov 函数法。文献[8]中没有采用这种方法,而是利用矩阵测度理论研究了 Hopfield 模型的全局稳定性,提出了一系列的充分条件,这为稳定性的研究提供了新的方法。

1.2.2 细胞神经网络模型

1988年,美国伯克莱加利福尼亚大学的 Chua 和 Yang^[9, 10]受 Hopfield 神经网络的直接影响和细胞自动机的启发,集他们多年在非线性电路中的研究成果,提出了如下二维细胞神经网络(cellular neural networks, CNNs)模型:

$$\begin{cases} \dot{x}_{ij} = -x_{ij} + \sum_{k,l \in N_{ij}(r)} a_{kl} f(x_{kl}) + \sum_{k,l \in N_{ij}(r)} b_{kl} u_{kl} + z_{ij} \\ y_{ij} = f(x_{ij}) = 0.5(|x_{ij} + 1| - |x_{ij} - 1|), \quad i = 1, \dots, M, j = 1, \dots, N \end{cases} \quad (1.2)$$

其中,变量 x_{ij} 、 y_{ij} 、 u_{ij} 分别表示细胞 (i, j) 的状态、输出和输入。一个细胞 (i, j) 的状态是由 r 邻域 $N_{ij}(r)$ 内邻近的输入和输出控制。输出信号 y_{ij} 通过加权系数 a_{kl} 作为反馈信号,输入信号 u_{ij} 则通过控制系数 b_{kl} 进入系统。 z_{ij} 是常数且作为阈值调节。反馈系数、控制系数和阈值的集合分别被称之为模板 A 、 B 和 Z , 模板一般来说是不可变的。邻域 $N_{ij}(r)$ ($1 \leq i \leq M, 1 \leq j \leq N$) 表示与细胞 (i, j) 距离为 r 的所有细胞集合。通常称模型(1.2)为克隆模形式的 CNNs。

与 Hopfield 模型相比,细胞神经网络在拓扑结构上是局域连接的,即网络中的每一个神经元仅与其周围的若干个神经元相连接(事实上,局域连接的特性更符合生物神经网络的真实情况。现代神经解剖学与现代神经生理学的研究表明:人脑是由约 10 亿个神经元构成的巨系统,而每个神经元仅与约 $10^3 \sim 10^4$ 个其他神经元相连接。这说明人脑中的神经元连接是相当稀疏的),神经元的激励函数不是连续光滑的 Sigmoid 函数,而是存在不可导点的分段线性函数,这些特点使细胞神经网络的硬件实现变得容易,并很快应用到了图像处理、模式识别等许多领域中^[11, 12]。由于细胞神经网络具有良好的应用前景,因此有必要对它的动态特性加以研究。根据实际需要,在细胞神经网络的稳定性研究中人们主要关心两种稳定性,即完全稳定性以及全局稳定性(渐近稳定或者指数稳

定)^[13, 14]。在 Chua 等^[15]的论文中讨论了反馈模板对称情况下的完全稳定性。Gilli^[16]、Savaci 和 Vandewalle^[17]分别给出了反馈模板非对称时网络完全稳定的充分条件,从而扩充了 Chua 的结论。随后, Arik 等^[18]给出了确保网络完全稳定的一个猜想,并在文献^[19]中给出了证明。从方法上看,证明网络完全稳定的方法大致有三种:第一种是基于 Lyapunov 函数法,通过选择一个与网络输出有关的 Lyapunov 函数,设法证明该函数的有界性及单调性,最后利用网络的激励函数的性质加以证明;第二种是依据著名的 La-Salle 不变原理;第三种是基于数学分析中的 Bartellet 引理及其各种变形。全局稳定性的证明依然是根据个人的经验通过构造合适的 Lyapunov 函数进行证明。

近年来,随着人们对递归神经网络研究的深入,越来越多的学者喜欢使用广义的递归神经网络模型进行研究。这种广义递归神经网络模型,就是指包括上面介绍的 Hopfield 神经网络和细胞神经网络在内的一种广义的网络模型^[20]。笔者通过多年的研究和总结,建立了两种广义递归神经网络模型,得到了一些重要的研究成果,这些成果将在后面的章节中给出详细的介绍。

1.2.3 Cohen-Grossberg 神经网络模型

1983 年, Cohen 和 Grossberg^[21]提出了一种广义的神经网络及生态模型:

$$\frac{dN_i}{dt} = G_i(N_i) \left[b_i(N_i) - \sum_{j=1}^n c_{ij} d_j(N_j) \right], \quad i = 1, \dots, n \quad (1.3)$$

这是一个十分广泛的模型,它包含了多个生态系统及神经网络,如 Volterra-Lotka 系统

$$\dot{x}_i = G_i x_i \left(1 - \sum_{j=1}^n t_{ij} x_j \right) \quad (1.4)$$

Gilpin-Ayala 竞争生态系统

$$\dot{x}_i = G_i x_i \left[1 - \left(\frac{x_i}{K_i} \right)^{\theta_i} - \sum_{j=1}^n t_{ij} \left(\frac{x_j}{K_j} \right) \right] \quad (1.5)$$

及 Eigen-Schuster 系统

$$\dot{x}_i = x_i (m_i x_i^{p-1} - q \sum_{j=1}^n m_j x_j^p) \quad (1.6)$$

若适当选取各参数,还可以得到 Hopfield 神经网络模型

$$C \dot{x}(t) = -R x(t) + T S(x(t-\tau)) + I \quad (1.7)$$

及更一般的非线性神经网络模型

$$\dot{x}_i = -A_i x_i + (B_i - C_i x_i) [I_i + f_i(x_i)] - (D_i x_i + E_i) \left[J_i + \sum_{j=1}^n t_{ij} g_j(x_j) \right] \quad (1.8)$$

目前, Cohen-Grossberg 神经网络模型已经在并行处理、联想记忆,特别是最优化计算等方面引起了学术界广泛的研究兴趣^[22]。在多篇文献中已给出了有时滞或无时滞的该类模型的渐近稳定及指数稳定的充分条件。如,通过构造适当的 Lyapunov 泛函,文献^[23]给出了该类模型的全局稳定性判据。在文献^[24]中, Lu 和 Chen 研究了模型的绝对指数稳定性,并对收敛速率做出了估计。当时滞满足一个可计算的边界条件时,在互连矩阵 T 为对称的假设下,文献^[25]给出了 Cohen-Grossberg 神经网络模型的稳定性结论。时滞在神经网络的实现过程中是不可避免的,因此文献^[26]研究了一类多时滞的 Cohen-Grossberg 神经网络模型并得出了几个指数稳定性的判据。

1.2.4 模糊神经网络模型

当前,模糊神经网络(fuzzy neural network)也称模糊推理网络(fuzzy inference network)已成为研究的热点。神经网络和模糊系统均属无模型的估计器和非线性动力学系统,但二者之间的特性却存在很大的差异,如模糊系统中的抽取和表达比较方便,而神经网络则可从样本中进行有效的学习。正如 Kiszka 等^[27]指出的那样:神经网络适合于处理非结构化信息,而模糊系统对处理结构化的知识更为有效。

与传统的神经网络模型不同,模糊神经网络中的结构与权值都有一定的物理含义。在设计模糊神经网络结构时,可以根据问题的复杂程度及精度要求,结合人的先验知识来构造相应的模糊神经网络模型。同时,模糊神经网络中权值的初始化可根据先验知识人为地加以选择^[28]。这样,网络的学习速度大大加快,并在一定程度上回避了梯度优化算法带来的局部极小值问题。

模糊神经网络的控制大致可分为三类^[29]:第一类是直接利用神经网络的学习功能及映射能力去等效模糊系统中的各个模糊功能块^[30];第二类是在神经网络模型中引入模糊逻辑推理方法,使其具有直接处理模糊信息的能力^[31];第三类是把模糊系统和神经网络集成在一个系统中,以发挥各自的优势^[32]。

由于神经网络的自学习特点,在模糊系统规则建立过程中,采用神经网络可以得到一类基于神经网络的自适应模糊系统。当难以获得足够的知识模型(IF-THEN 规则)时,可通过神经网络训练样本学习、产生、修改、高度概括输入输出之间的关系,形成模糊规则。这样,便可根据输入模糊集合的几何分布及由过去经验产生的原始模糊规则,进行推理并得出结论。

在文献[33]中,应行仁和曾南提出了一种基于 B-P 网的模糊控制方法。通过一组神经元不同程度的兴奋来表达一个抽象的概念值,由此将抽象的经验规则转化成多层神经网络的输入/输出样本,并通过 B-P 学习算法使网络记忆这些样本。Kosko 和 Kong^[30]将模糊系统与神经网络性能进行比较,系统地研究和总结了神经网络与模糊系统的一般原理和方法。研究表明:采用模糊联想记忆规则的模糊控制系统具有良好的鲁棒性,而将微分竞争学习机制引入模糊联想记忆所形成的自适应模糊联想记忆,可以在输入、输出样本不甚完备的条件下,以相对小的计算量获得较好的系统性能。

Jang^[34]采用暂存反向传播算法实现模糊神经网络控制的自学习。这种方法利用自适应神经网络实现了时间序列预测和系统辨识,并形成模糊控制器。倒立摆实验的结果证明了这一方法的有效性和控制器较强的鲁棒性。

Bernji 等^[35]通过采用动态系统的增列式学习方法,实现模糊控制器的学习和整定,同时提出一种基于近似推理的智能控制结构。该系统有三个不同的神经元:作用选择神经元、作用评价神经元和随机作用神经元。作用选择神经元起普通模糊控制器的作用,作用评价神经元对系统进行评价,随机作用神经元起随机综合作用选择神经元和作用评价神经元的作用,然后产生控制信号。

陈建勤等^[36]改进了上述方法,提出利用自适应神经元学习的个性模糊控制规则的方法。该方法既可以学习与当前控制过程输出性能有关的、在过去起作用的控制规则,又可以随过程环境变化自动调整和改进控制规则,对非线性时滞被控对象的仿真研究显示出

良好的学习效果。

神经网络在模糊自适应控制中的另一个应用是改进和增强自组织模糊控制器的学习能力。Yamaguchi 等^[37]提出用模型联想记忆系统实现自组织模糊控制的方法。模型联想记忆系统利用模糊规则表达专家知识,并采用神经网络的自学习能力来提炼知识。这样,在模糊规则的前提部分可产生理想的隶属函数分布,在结论部分可单独训练控制器,保证在特定的条件下达到最佳。对两个可调参数的模型直升机飞行控制器的仿真研究发现,学习后直升机稳定飞行的效果明显优于学习前。

Chen 等直接借鉴自组织模糊控制的设计思想,利用两层前向网络结构构造了反馈控制器,保留了与自组织模糊控制相似的自组织机制,实现了自组织神经网络控制。这种结构弥补了原有常规模糊控制器自调整时间长和计算量大的缺陷。

大多数模糊神经网络将模糊系统看作分层前馈神经网络,然后用 B-P 神经网络来实现。Nie 等^[38]提出一种不同的方法,通过引入局部网络结构和前馈推理算法,用整个径向基函数(radial basis function)网来表达基于规则的模糊知识,并将其发展成多变量自组织和自学习模糊控制器。同时引入模糊竞争组织机构和重复学习控制算法,使基于模糊径向基函数网的模糊控制器在缺少“专家知识”或“教师”的情况下,能够自组织其结构,自学习控制规则,以达到满意的控制效果。

文献[31]给出的模糊神经网络就属于模糊神经网络控制的第二类,即在神经网络中增加了一些模糊逻辑运算(如与、或运算等),使神经网络直接具有模糊推理功能。由于网络含有模糊信息的特殊性,该网络的自学习既继承了常规神经网络的学习算法,又含有一些独有的算法。神经网络的训练可产生模糊逻辑规则 and 最优的输入输出隶属函数,学习速率收敛得比原 B-P 学习算法快。该神经网络模型同时也为常规的前馈多层神经网络提供了“人的理解方式”,并可节省通常模糊逻辑系统的参考机构匹配时间。

与模糊神经网络控制的前两类研究相比,对第三类的研究比较少,主要集中在用模糊逻辑提高神经网络的学习速率。通过对网络的学习性能进行分析得到一些启发性的知识,用这些知识动态地调整学习过程,以提高学习速率,避免陷入局部极小值点。因此,在这类神经网络中都加入了模糊逻辑。

近年来模糊神经网络的研究报道层出不穷,人们期待着它能够对整个控制学科作出突破性贡献。但在实际应用过程中这类神经网络较复杂,学习计算时间长。那么,如何简化模糊控制器的量化过程,将其转换成易于学习的算法;如何确定学习指标,构成有效的模糊逻辑来初始化神经网络;如何分析模糊神经网络的稳定性、收敛性等,都有待于进一步研究。

作者通过多年的研究和总结,建立了一种模糊双曲神经网络模型,得到了一部分研究成果,这些成果将在后面的章节中给予详细的介绍。

1.3 时滞对递归神经网络动态特性的影响

在研究自然现象过程中,人们发现客观事物的规律是复杂的和多样的。在很多情况下,不仅需要考虑到事物的当前状态,而且还需要考虑事物过去的历史,这两者的影响可能同时起着作用。也就是说,需要考虑时间滞后的现象,即“时滞”现象。

在自动控制问题中,由于所控制的系统中都存在着时滞(电流的、机械的、热的、等),实际上的控制行动总是落后于理论上的未加时滞所得出的值,尤其是当控制的精确度要求很高时,问题便更加突出。在工程处理时,一般是略去了时滞,也就是将控制系统中时滞 τ 均用零代替,这样就得到了无时滞的系统方程。用普通方法即可求解这样的系统方程,得到一类无时滞的控制系统的相关结论。

递归神经网络作为一种非线性系统,在其硬件实现过程中,时滞是不可避免的。这是因为在神经网络信息的传递过程中,从神经网络自身来讲,神经元之间的通信存在延迟;从网络的硬件实现考虑,存在开关延迟和通信延迟。时滞意味着网络模型应该与过去时间的神经元状态有关,这也正反映了大脑本身的特点。在现有神经网络模型上引入轴突信号传输时滞,那么相应的动力学系统就变成了带时滞的非线性动力学系统,因而它们的动力学性质将变得非常复杂,其动力学行为有可能演化到稳定的平衡点,还有可能产生周期振荡或混沌。

如果在相应的时滞神经网络模型中令时滞为零,那么此时滞神经网络模型退化为相应的无时滞神经网络模型。在实际建模时,人们很自然地忽略小时滞,而将时滞动力系统约简为一般动力系统。但从动力学的角度看,这样做是不可靠的。事实上,存在这样的时滞动力系统,其约简的系统的平衡点是不稳定的,但对任意时滞,其时滞系统的平衡点是稳定的,反之亦然。对于周期解的存在性也有类似的结论。一个时滞神经网络模型存在 Hopf 分岔时,其约简的无时滞系统却可以不产生 Hopf 分岔。因此,在许多情况下,必须直接研究时滞神经网络模型^[39~41]。

时滞对系统的动态特性有很大的影响,例如,时滞常常导致系统失稳,又如,时滞系统一般有无穷多个特征值,从而从一个侧面说明时滞系统是无穷维的。非线性时滞神经网络模型比无时滞神经网络模型有着更加丰富的动力学特性。

由于有限的运算放大器切换速度和信号传输的影响,在网络模型中引入时滞是适合的^[42]。但文献[42]通过试验和数值计算发现,时滞能够破坏原本稳定的网络并使其呈现持续振荡,这种情况下,时滞的存在是有害的。文献[39]说明了对有时滞的网络,若时滞充分小,其与无时滞情况的网络具有相同的全局稳定特性。当时滞增加时,文献[43]指出,大时滞将破坏网络平衡点的稳定性,即使时滞不改变平衡点的稳定性,也必然会影响稳定平衡点的吸引域。

对于时滞系统,所得到的稳定判据通常有时滞独立稳定判据和时滞依赖稳定判据两种表示形式。一般来讲,时滞独立稳定判据对时滞的大小及对时滞的变化率没有限制,而时滞依赖稳定判据依赖于时滞的大小或时滞的变化率。对于定常时滞情况,时滞独立稳定判据对于存在大时滞的情况,结果一般不保守,但对小时滞情况,结果将很保守;时滞依赖稳定判据对于存在小时滞的情况,结果一般不保守,但对大时滞的情况,结果将很保守。如考虑文献[42]中的单时滞 Hopfield 神经网络,文献[25]、[39]中的全局渐近稳定结果可表示成

$$\tau\beta\|T\| < 1 \quad (1.9)$$

其中, $T = (T_{ij}/C_i)_{n \times n}$, $\beta = \max(g'_j(x_j))(i, j = 1, \dots, n)$, $\|T\|$ 表示由 Euclid 向量范数诱导出的矩阵范数。文献[44]中的全局渐近稳定结果、文献[45]中的渐近稳定结果及文献[9]、[46]中的指数稳定结果可表示成

$$\beta \|T\| < 1 \quad (1.10)$$

其中,各符号定义同式(1.9)中的定义。显然,比较上述两式,则验证了上面的论述。而对于时变时滞的情况,虽然时滞独立稳定判据(如基于 Young 不等式和 Halanay 不等式等代数不等式所得到的结果)完全不依赖时滞的任何信息(如时变时滞的大小和变化率),但此时的稳定判据往往因包含大量的可调参数而不易验证;同时由于对连接权系数进行绝对值运算,神经元的抑制作用也得不到体现,进而又增加了保守性。不论采用何种分析手段,保守性和可验证性都是分析时变时滞神经网络稳定性时不可调和的矛盾,进而也是研究时变时滞神经网络稳定性比研究定常时滞神经网络困难的原因所在。

近几年,各种带有时滞的神经网络,如时滞 Hopfield 神经网络^[39, 42, 44, 45]、时滞细胞神经网络^[47]和时滞双向联想记忆模型^[48]相继提出,这些模型的各种稳定性也已被广泛地研究,如局部稳定性^[17, 49]、全局稳定性^[21, 50]、绝对稳定性^[16]和指数稳定性^[50]等。鉴于许多用途各异的时滞神经网络模型形式上与标准的时滞动力学系统有一定差距,这些网络的稳定性问题一般都采用特殊的手段来处理,如前面所说,时滞细胞神经网络就是一个非光滑的时滞微分方程系统,对这类网络就某些非对称模板类,可以研究其绝对稳定性问题^[16]。由于目前尚未出现关于时滞神经网络系统的统一模型,网络稳定性的研究不仅没有统一的方法可循,而且许多研究结果也时常具有交叉和重复的内容。在研究时滞神经网络稳定性时,通常采用的方法是在其平衡点附近线性化来研究局部稳定性,或构造各种不同的 Lyapunov 泛函,并利用 LaSalle 原理来得到全局或指数稳定性。然而运用 Lyapunov 泛函得到的是一些不等式检验条件,由于该方法依赖不等式的估计技巧,并且所得条件忽略了神经元之间的兴奋与抑制所产生的不同影响,其条件是过度保守的。

虽然在有的时滞神经网络模型中也考虑了干扰信号的影响,却很少有人提到“网络系统的鲁棒稳定性”这个术语。所谓网络系统的鲁棒稳定性,是指在指定网络系统的“邻近”系统中,某些动力学特性,如平衡稳定性的保持问题。现已有结果表明,在某些网络系统中,可以得到鲁棒稳定性条件^[51~53]。然而,如何尽可能地提高系统的鲁棒稳定性却是一个具有挑战性的问题。在时滞神经网络中,过去也常提到系统鲁棒性的概念,这是指在神经网络这个巨系统中,网络中个别神经元和连接权受损并不影响网络的整体特性,如学习和联想记忆等功能。

1.4 神经元的激励和抑制对网络动态特性的影响

突触是神经元之间信息传递的特殊结构,在机能上可以进行神经冲动的传递和情报的整合。为模仿生物神经元求解复杂问题的功能,在传统的人工神经组织描述中,常假定突触是具有激励和抑制作用的简单连接,即正的连接权能够提高神经元的“净”输入信号,进而激励神经元;负的连接权能减少神经元的“净”输入,进而抑制神经元的活性^[54]。与生物神经元中的突触不同,人工神经元中的突触连接权可在正值和负值之间变化^[55],因此呈现出强大的学习和记忆能力。

在神经网络的动态特性,特别是平衡点稳定性的研究中,所得到的时滞独立稳定判据大多忽略了连接权系数的符号,如采用各种微分不等式、Halanay 不等式、代数不等式和非二次 Lyapunov 函数等所得到的稳定判据,进而忽略了神经元的激励和抑制对网络的

影响。文献[56]研究了神经元激励和抑制对平衡点稳定性的影响,以模型(1.1)为例(假定 $n = 2$, 激励函数为 $\tanh(u)$ 函数), $T = (T_{ij})_{n \times n}$ 是全连接的,根据单调动态系统理论,在非抑制互连的情况下(即 $T_{ij} > 0, i \neq j$),如果抑制通道的时滞充分小,则抑制自连接(即 $T_{ii} < 0$)能够镇定网络。文献[57]在网络能够产生单调半流的情况下,证明了激励作用能够镇定网络动态行为。文献[58]的结果表明,抑制作用是通过 Hopf 分岔使网络产生非线性振荡的必要条件。

可见,采用各种微分不等式、Halanay 不等式、代数不等式和非二次 Lyapunov 函数等所得到的时滞独立代数稳定判据,虽然条件易于验证并在某种程度上降低了保守性,但忽略了神经元激励和抑制的作用,进而忽略了自抑制连接通道中的时滞对抑制神经元的影响。如果仅以判别不等式是否成立来断言系统的稳定与否,则如文献[59]中的仿真例子所示,随着自连接通道中时滞的增加(连接权系数都保持不变),系统将不再稳定,将呈现持续振荡的状态。

目前,关于神经网络各种稳定性结果的表示方法多种多样,如 M(P 或 H)矩阵^[8]、矩阵测度^[60]、矩阵范数^[61, 62]、线性矩阵不等式^[63, 64]和代数不等式^[65]等方式。按是否考虑了神经元激励和抑制的作用,表示形式可分为三类:考虑了神经元的激励和抑制的作用、部分考虑了神经元激励和抑制的作用和没有考虑神经元激励和抑制的作用^[66]。考虑神经元激励和抑制的作用,主要表现为对连接权矩阵的直接操作,这类结果的表现形式较之代数不等式形式则少得多,目前常见的是线性矩阵不等式表示、Lyapunov 对角稳定表示等,其中, Lyapunov 对角稳定结果常可用线性矩阵不等式形式表示出来。部分考虑神经元激励和抑制的作用,主要表现在对部分加权矩阵(如与时滞无关的网络加权矩阵)直接进行矩阵操作,而对部分矩阵(如与时滞有关的网络加权矩阵)中的部分权系数(如对角元素和非对角元素)进行绝对值操作,常见的表示形式是用几个分离条件来表示或与矩阵描述方式等混合在一个表达式中。没有考虑神经元激励和抑制的作用,主要表现为对网络连接权系数取绝对值操作,进而得到代数不等式形式的表示。各种不等式表现形式种类繁多,如包含了可调参数的不等式表示和不包含可调参数的不等式表示。其中,不包含可调参数的不等式判据易于验证,但过于保守,如 M 矩阵表示等;包含可调参数的不等式判据,因有很大的自由度,保守性得到相应降低,但往往没有系统的方法来调节这些参数,进而不易验证这些判据是否成立。

用线性矩阵不等式表示的结果可以包含很多的未知参数,具有很大的自由度,与无参数可调的不等式表示结果、M 矩阵表示结果等比较,保守性一般不是很高;在 Matlab 软件包中有现成的 LMI 工具箱,易于验证线性矩阵不等式形式的结果。总之,线性矩阵不等式表示的结果具有既能考虑神经元激励和抑制的作用,又具有大量的可调参数来降低保守性和易于求解等优点,所以基于线性矩阵不等式技术的神经网络动态分析目前已成为主流。

1.5 递归时滞神经网络的动态特性分析方法和内容

固定权值递归神经网络是一个非线性动力系统,具有丰富的动态特性,如稳态行为可呈现平衡态、周期解和混沌等状态。如果神经网络的动力学行为仅依赖于时间,则此时的