

联接主义智能控制综述¹⁾

袁著祉 陈增强 李翔

(南开大学自动化系 天津 300071)

(E-mail: Aecyzz@public.tpt.tj.cn)

摘要 综述了近年来联接主义智能控制的理论和应用上的研究进展,覆盖了神经网络的逼近和泛化能力、神经网络与混沌、监督学习算法等基本性质,以及神经网络建模、预测、优化和控制等联接主义智能控制系统的各个部分,并对今后的研究发展提出了展望.

关键词 联接主义, 智能控制, 神经网络, 混沌

中图分类号 TP18

CONNECTIONISM INTELLIGENT CONTROL: A SURVEY

YUAN Zhu-Zhi CHEN Zeng-Qiang LI Xiang

(Department of Automation, Nankai University, Tianjin 300071)

(E-mail: Aecyzz@public.tpt.tj.cn)

Abstract The recent theoretic accomplishments and applications for connectionism intelligent control are thoroughly surveyed, including neural network's basic properties and all aspects of the connectionism intelligent control systems, such as approximation and generalization abilities, neural networks and chaos, supervised learning algorithms, neural networks modeling, prediction, optimization, control, etc. Finally the future research directions are suggested.

Key words Connectionism, intelligent control, neural networks, chaos

1 引言

从智能控制基于智能模拟的根源出发,智能控制系统主要可以分为下面的4种类型:1)基于规则推理的智能控制系统;2)基于联接主义的智能控制系统;3)基于群体进化机制的智能控制系统;4)基于行为主义的智能控制系统.

联接主义(亦称为连接主义)的 Connectionism 源于人们在脑科学中的研究. 在思考如何更好地提高机器智能的人们看来,从脑神经系统的结构形式开始模拟人脑智慧,建立(人工)神经网络模型,以此来帮助人类提高所利用的机械的“智能”程度.

1) 国家自然科学基金(60174021)和国家科技攻关计划基金(2001BA204B01-02)资助

收稿日期 2002-04-18 收修改稿日期 2002-08-10

联接主义先驱 McCulloch 和 Pitts 在 1943 年 M-P 神经元模型的提出,标志着思考智能模拟的人们从功能模拟而开始关注结构模拟的方式。尽管在 1969 年 Minsky 和 Paper 发表的《感知器》中,严格论证了简单线性神经元感知器的功能局限,此后 20 余年神经网络进入了研究的低潮期。然而数十年来 Rosenblatt(Perceptron 模型 1958), Widrow(Adaline 模型 1962), Albus(CMAC 模型, 1975), Kohonen(自组织映射理论 1980), Hopfield(Hopfield 模型 1982), Grossberg, Hiton(Boltzmann 机模型 1984), Rumelhart(BP 网络 1986), Anderson 等神经网络研究人员的不懈努力和卓越贡献,使得人工神经网络理论在 20 世纪 80 年代以来获得重大突破,为实现联接主义的智能模拟和智能控制创造了条件。从思维规律角度而言,联接机制的模拟方法描述的是人脑形象思维的模拟。目前来说,神经网络控制是智能控制的主要形式之一。神经网络不断与其它计算智能技术交叉、融合、发展,模糊神经网络^[1~6]、进化神经网络^[7~9]、混沌神经网络^[10~21]以及因素神经网络^[22,23]等也使得联接主义智能控制获得更多的生命点。

本文将以神经网络为主线,着眼于联接主义智能控制近年来的理论研究和应用现状来做一个综述。

2 联接主义智能控制系统研究进展

2.1 联接主义智能控制系统基础——神经网络

神经网络是联接主义智能控制系统的基础,同时也在其它研究领域获得了广泛的关注。本节将着重围绕智能控制有关的方面介绍神经网络在近年来的发展。

简单地说,(人工)神经网络(Neural Networks, NN)是由一组功能简单的信息处理单元(即神经元)在一定联接方式下构成的动力学系统。它以并行机制处理数据信息,大多具有自适应、自学习、自组织的能力,信息分布存储在各神经元中,具有较强的容错性和鲁棒性。神经网络模型迄今为止已经有大约 100 余种,大多都是反映人脑的某方面特性。一个基本的人工神经网络包括神经元、网络拓扑结构、学习(修正)规则三部分。神经元相当于一个信息传递函数,线性或非线性,甚至是混沌的。网络拓扑结构则主要包括神经元的联接方式,如前馈(静态)和反馈(动态)、部分联接和全联接、单层和多层,以及各联接方式下神经元的数目(神经网络规模)。学习规则则决定网络权值的修正和进化方式,包括监督、无监督和激励学习、Hebb 调节和纠错学习、竞争式和被动式学习、确定式和随机式学习等。

2.1.1 神经网络有关性质的研究进展

1) 非线性(计算)逼近能力

因为 Minsky 对感知器模型计算能力的否定而导致早期神经网络陷入 20 世纪 60~70 年代的低潮,从 80 年代中期 Hopfield 网和多层感知器误差反传算法提出以来,神经网络的非线性(计算)逼近能力最受学者们的关注。

多层前馈神经网络(Multilayer Feedforward Neural Network, MFNN)的逼近性质得到了比较彻底的研究。1989 年 Cybenko, Hornik, Funahashi 和 Hecht-Nielsen 等众多学者几乎同时证明了 MFNN 对任意连续函数的逼近能力^[24~27]。我国学者陈天平等^[28,29]人获得了更一般性的结论,指出有界的激励函数就能保证神经网络的这种任意逼近能力。值得一提的是,与此前的神经网络逼近能力的存在性思路不同,Scarselli 和 Tsoi 从构造角度讨论了在

任意逼近精度下的 MFNN 实现方法^[30]. 在模糊环境下, Buckley 和 Yoichi^[31]证明 MFNN 具有对连续模糊函数(fuzzy function)的任意逼近能力, 规则的模糊神经网络(Regular Fuzzy Neural Network, RFNN)不具有该性质^[32], 我国学者进一步证明多隐层的 RFNN 同样能获得对连续模糊函数的任意逼近^[33].

径向基(Radial Basis Functions, RBF)网络、B 样条神经网络以及 CMAC 网络等都是针对脑皮层中存在局部、重叠的感受区域而提出的线性参数化神经网络模型, 与 MFNN 不同的是, 它们在功能行为上与模糊逻辑系统是等价的. 因此, 模糊逻辑系统在任意紧致集上的对任意非线性函数的逼近能力, 在基函数类神经网络上也得到了等价证明^[3, 6, 34, 35].

在有限神经元节点规模的限制下, 不同类型的神经网络的逼近能力则有较大差异. Barron 曾对于有限规模的 MFNN 给出一个精致的逼近误差刻划^[36], 针对各类逼近函数给出了一个统一的逼近误差上界 $O(n^{-2/d})$, 其中 n 是神经元节点数, d 是输入维数. 进一步, Dingankar^[37]根据数论证明逼近率可达到 $O(n^{-2})$. Corradi 和 Xu 得到了 RBF 网络的类似结果, L_2 范数下逼近误差界为 $O(n^{-2/(2+d)})$. 因此, 相比之下, 在处理高维输入信息时, 有限规模的 MFNN 要比 RBF 具有优势. 作为小波分析理论和神经网络理论的结合产物, 小波神经网络^[38, 39]与 RBF 网络在结构上很相似, 与文献[36]中的结果作比较, Delyon 和 Juditsky 指出^[40]小波网络具有 L_2 范数意义下的误差为 $O(n^{-\rho/d})$, 其中 ρ 为被逼近函数的可和导数的个数.

动态递归神经网络(Dynamic Recurrent Neural Networks, DRNN)是 MFNN 在时间、空间轴上的延伸. 一般认为 DRNN 比 MFNN 应该具有更好的逼近能力, 但由于递归形式繁多, 结构复杂, 不同的 DRNN 逼近能力也不尽相同. Tsoi 和 Back^[41]比较了三种递归结构与 MFNN 的性能比较, 只有一种与 MFNN 相当; Sperduti 则证明了只有 Elman 网络具有模拟任意有限识别自动机的能力, 而级联相关型、神经树型 DRNN 不具有此能力^[42]. 因此, 并非任何一种有限规模的递归神经网络都能有效逼近非线性问题. Elman 网络(及其具有类似简化结构的对角神经网络)等简单递归神经网络获得了较为广泛的关注, 在应用于非线性系统辨识与控制的研究中取得很大的进展^[20, 21, 43~58].

2) 泛化能力

神经网络的泛化(generalization)能力是指神经网络对未知模式的逼近或分类能力, 而逼近能力更侧重于对于已知模式的学习. 因此, 一定程度上泛化能力更有意义.

通常认为神经网络的泛化能力和逼近能力渊源甚广: 达不到一定的逼近精度, 泛化能力则无从谈起; 过拟和(over-fitting)的逼近则会导致泛化能力的下降. 对于单隐层的 MFNN, Barron^[59]界定了学习后的神经网络泛化误差 $err(f_{n,N})$ 的上界为 $O(C_f^2/n)$ 和 $O(nd/N)\log N$ 之和. 因此, 随着隐层神经元节点 n 的增加, 前者将逐步减小, 而后者则逐步增大, 好的泛化能力取决于二者的协调. 类似地, Niyogo^[60]也得到了 RBF 网络的泛化误差上界为 $O\left(\frac{1}{n}\right) + O\left(\left[\frac{nd\ln(nN)-\ln\delta}{N}\right]^{\frac{1}{2}}\right)$, $\forall 0 < \delta < 1$.

尽管从泛化理论而言, 强调适度的逼近精度能获得更好的泛化能力, 然而如何保证在网络训练过程中适当的逼近精度目前仍没有明确的研究报道. 人们从各种角度来考虑提高神经网络的泛化能力, 比较直观的思路包括: 或采用适当的信息结构样本, 如在训练样本中附加随机噪声^[61~63], 这样一方面相当于丰富了训练样本, 另一方面迫使神经网络不能精确拟

和训练数据,使噪声起到了平滑作用,防止了过拟合;或约束网络权值以保证权值分布均匀,如 Hinton 认为零权重具有最少的位表示,因而在训练的目标函数中加入特殊项,促使权值衰减^[64];或根据奥卡姆剃刀(Ocam's razor)原则(即在所有达到给定学习精度的神经网络中,结构越简单,泛化能力越好)来设计神经网络结构,通过协调神经网络的结构复杂性和样本复杂性来获得较好的泛化能力,如 Murata 根据 Akaike 信息准则删除次要、冗余节点^[65]等等。而 Schmidhuber 则率先从 Kolmogorov 复杂性和 Solomonhoff-Levin 分布的角度,利用 Levin 随机全局优化算法,探索了具有低 Kolmogorov 复杂性和高泛化能力的神经网络设计方法^[66]。相关综述可以参考文献[67~69]等。

他山之石可以攻玉。支持向量机^[70](Support Vector Machine, SVM)以及自适应推进 AdaBoost 算法^[71]被普遍认为具有比神经网络更好的泛化性能,笔者认为将它们与神经网络的结合可以作为提高神经网络泛化能力的新的考虑角度。

3) 神经网络与混沌

人脑生物神经系统活动中的混沌现象一直被关注着。美国加州大学 Berkeley 分校的 Freeman 教授早在 1991 年就指出^[72]:“大脑中被控制的混沌现象其实不仅仅是大脑复杂性的一种副产品”,而控制混沌现象的能力“可能是大脑区别于任何一种人工智能机器的主要特性”,近年来更是提出将随机性混沌作为大脑非周期性活动的别名^[73]。最新的脑神经科学研究表明,混沌不仅存在于脑神经系统,而且还影响着脑神经系统的活动^[74,75]。Selvam 更是发现^[76],大脑的信息存储、更新等传递过程(长期记忆)与大气流所表现的大范围时空关联(long-range spatiotemporal correlations)非常相似(而在自然界这种无处不在的大范围时空关联即体现为混沌)。

伴随着对生物(人脑)神经系统的混沌的探索过程,众多学者也开始剖析人工神经网络模型的复杂动力学行为。然而,为服务于联想记忆、模式识别和优化处理等应用的目的而建立的具有不动点吸引子的(人工)神经网络模型,如全对称互联的单层反馈 Hopfield 网络模型和 MFNN 网络模型。Marcus 和 Westervelt 的研究表明^[77],当阈函数是单增的 Sigmoid 型函数时,则上述这两类神经网络系统只有简单的不动点和周期解。因此,为混沌化神经网络模型以获得更好的性质,各种混沌神经网络模型结构纷纷被提出来,并在联想记忆、模式识别、信息处理、组合优化、同步与通信等领域得到了广泛关注,如引入了具有激发/抑制机制的不对称连接^[78,79]、具有动态阈值^[80]等特征的非平衡点神经网络^[81],并在模式识别中充分利用混沌特征而提高了模式存储(记忆)容量。Inoue 和 Nagayoshi 则是直接用简单的混沌振子相互耦合构成神经元,以振子的同步来决定神经元的状态^[14,15]。Ishii 和 Fukumizu 则利用混沌单元之间达到的同步振荡,使得相应的混沌网络产生的聚类形式可以用做信息编码^[16,17]。着眼于解决组合优化的混沌神经网络是另一个广泛研究的热点,以改造后(如神经元状态自反馈、离散步长周期衰减、引入混沌噪声等)的混沌 Hopfield 网络^[18,29,82~87]和 Aihara 暂态混沌神经网络^[11~13]为主要类型,在这里,混沌被激发以避免局部极小,并最终在某种退火机制下衰减以确保优化求解收敛到全局最小,混沌退火机制或搜索收敛条件成为关键。

笔者致力于混沌 Elman 类网络的设计^[20,21],分别针对 SISO 的非线性 Elman 网络和 MIMO 的线性 Elman 网络,利用一维和高维动态系统的混沌定义展开各自的混沌化分析过程。文献[20]在 SISO 的 Elman 网络的隐层神经元引入新的非线性激励函数,系统讨论了一

维混沌 Elman 网络的不动点稳定性,在“正 Lyapunov 指数意味着混沌产生”的定义下寻找混沌产生的激励函数参数条件。文献[21]则是针对 MIMO 的线性 Elman 网络的混沌化设计,通过简单的 Modulo 操作,在 Li-Yorke 混沌定义下,证明了多维 Elman 网络权值矩阵的混沌化条件,提供了另一条设计混沌 Elman 网络的思路。混沌 Elman 网络的进一步深入剖析和应用无疑是更有挑战性和吸引力的研究课题。

2.1.2 神经网络监督学习算法

20 世纪 80 年代以来掀起的神经网络研究热潮,其直接原因之一是 BP 算法的提出使得神经网络的权值训练变得简单、易行,学习机制的引入使得神经网络的适应性在工程应用中获得了实际应用的途径。快速、实用的学习算法是神经网络的一个重要研究课题,(快速)收敛性和实时性则是衡量各种学习算法优劣的重要尺度。

基于 MFNN 的 BP 算法理所当然地受到了广泛关注。本质上是梯度法的标准 BP 算法简单易用,但也存在一些缺陷。学习因子 η 是标准 BP 算法的唯一调节参数,在 η 很小时,学习速度缓慢,若选择很大的 η ,则容易引起学习过程的振荡乃至发散。Kuan 和 Hornik 较早地运用 ODE 方法从理论上指出^[88]:即使 η 取很小的定常正数,也不能保证标准 BP 算法的收敛性。比较简单直接的改进是动量 BP 算法,

$$w_{k+1} = w_k - \eta \frac{\partial J}{\partial w_k} + \alpha(w_k - w_{k-1}) \quad (1)$$

其中 η 为学习因子, α 是动量因子。针对标准 BP 算法和动量 BP 算法,动态改变 η, α 的变尺度算法也应运而生,如 Salomon 和 Hemmen^[89]通过比较在增大和减小 η_{k-1} 情况下目标函数的变化来选择 η_k , Magoulas 则通过估计 Lipschitz 常数来保证其改进的具有可变步长的 BP 算法全局收敛^[90]。Hertz 和 Krogh 提出了一种无需计算反传误差梯度的非线性 BP 算法^[91],颇有新意。

与 BP 型学习算法相比,基于二阶梯度信息的学习算法则具有更快的学习(收敛)速度。伪牛顿法中 BFGS(Broyden-Fletcher-Goldfarb-Shanno)和 DFP(Davidon-Fletcher-Powell)算法被认为是最有效的非线性优化算法,但算法计算量太大而不适合大规模网络在线训练^[92]。Osowski^[93]综合了变尺度 BFGS 法和变尺度共轭梯度法的优点,提高了算法性能。Kasparian 等人针对多输入单输出系统提出了基于 MFNN 的 Davidon 最小二乘法(Davidon-LS),获得了对包括 Henon 混沌模型等非线性系统的很好的建模性能^[94]。贺江峰^[95]进一步将 Davidon-LS 扩展到多输入多输出系统和权重受限的形式,并根据二阶算法存在 Hessian 信息阵病态的缺陷,提出了多种改进的鲁棒 Davidon-LS。Puskorius 和 Feldkamp 提出了 MFNN 下的解耦型扩展 Kalman 滤波算法^[96](Decoupled Extended Kalman Filter, DEKF),大量的仿真研究表明,EKF 算法不仅在线计算量与通常的 Davidon-LS 等同,而且克服了 Hessian 信息阵病态的缺陷^[55, 97~99]。此外,林茂琼^[100]系统研究了阻尼最小二乘法(Damped-LS),将神经网络权值约束引入学习算法的目标函数,同样获得了好的数值鲁棒性。

RBF 网络的权值学习包括样条(基)函数中心单元的选取和输出权值的修正,理论上,对中心和权值同时进行优化是一个很复杂的非线性规划问题,一般是将二者分离独立处理。比较典型的学习算法有 1) M-D 算法^[101];2) 正交最小二乘法^[102];3) K-聚类和 Givens 变幻的联合迭代算法^[103];4) Holcomb 等人提出的局部算法^[104];5) Hwang 和 Bang 首先根据他

们 1994 年提出的一次完成快速聚类算法确定得到基函数中心点, 然后采用 LMS 算法或 Bayesian 决策法求解权值^[105]. 然而这些算法或在线难以应用, 或无法确定隐层节点数目. 结合各自算法的优点, 文献[103]的联合迭代法代表了这一发展方向. 贺江峰^[95]根据联合迭代的学习策略, 采用自适应模糊广义学习向量量化方法(Adaptive Fuzzy Generalized Learning Vector Quantization, AFGLVQ)动态聚类以获得中心点, 采用带时变遗忘因子的递推最小二乘法在线修正权值, 更好地提高了 RBF 网络的适应性. 小波网络和模糊神经网络的隶属度(小波基)函数的中心、半径和连接权值的学习过程, 与 RBF 网络类似, 因此二者之间的学习算法是可以通用和借鉴的. 与感知器类似的 CMAC 网络的学习过程中则因存在编码机制(如 hash 编码)而显得较为特殊, 罗忠等^[106]证明了没有 hash 编码的 CMAC 学习过程必收敛, 而有 hash 编码的 CMAC 学习过程收敛性受碰撞影响则可能不收敛、收敛变慢或者收敛性态变坏. 刘慧等^[107]则发现了 Albus 算法在批学习下的易发散的缺陷并提出了相应的改进算法.

动态递归神经网络的学习算法本质上与 MFNN 的学习算法是一致的, 然而由于递归神经网络的结构各自存在特点, 在算法推导上也存在各自的差异, 比较典型的通用学习算法如实时递归学习(Real Time Recurrent Learning, RTRL)算法和时间演化反向传播(Back Propagation Through Time, BPTT)^[108]. Williams, Puskorius 等人相继将 EKF 算法应用到递归神经网络权值学习和相应的控制设计中^[97, 98], Hornik 和 Kuan^[109]针对递归神经网络, 从连续系统的角度推广了离散 BP 算法, 并指出适当的权值约束有益于算法的收敛. 针对 Elman 网络这种特殊的简单型递归网络, Pham 和 Liu 率先推导了动态 BP 算法^[50](DBP), 标准 Elman 网络也能够表征任意高阶非线性系统^[46]. 陈巍等修正了文献[45]中 BP 算法的若干错误, 并进一步提出了一种结合扩展 Kalman 滤波算法的分层学习算法^[53]. 与 MFNN 相比, 动态递归神经网络因各自结构上的差异, 使得其学习算法的研究远不如 MFNN 的系统. 笔者在对角递归神经网络、Elman 网络和扩展 Elman 网络的基础上, 总结得到简单递归神经网络的结构特点, 并将 DBP 作为其学习算法^[47, 48, 55]. 因此, 深入剖析递归神经网络各种动力学结构, 将为寻找通用且实用的递归神经网络算法提供基础.

由于无监督学习和竞争学习等机制的神经网络在控制中的系统研究结果还相对较少, 因而在此不对这些学习机制多着笔墨阐述. 以 MFNN 为代表的监督学习机制下的神经网络模型虽然已发展较为成熟, 依然还存在着一些人们尚未完全找到答案的问题, 如有限样本容量与定量泛化能力之间的确定关系, 建模复杂性与神经网络复杂性的对比分析等等^[110, 111]. 通常, 神经网络因为强大的计算能力, 更多扮演的是形同“黑匣子”的逼近非线性特性的角色, 而逻辑规则推理是其弱项. 模糊神经网络综合了模糊逻辑和神经网络二者的优劣而产生, 理所应当具有更强大的生命力. 近年来, 为揭示神经网络“黑匣子”的内在奥秘, 关于神经网络的灵敏度分析^[112]也开始得到关注. 郭雷和郭宝龙^[113]系统地研究了神经网络的逻辑分析和时间表示理论, 刘增良等人提出的具有逻辑思维方式的因素神经网络^[22, 23], 这些研究表明神经网络本身同样可以模拟人脑的逻辑思维, 这必将为具有更高智慧的控制策略提供推动力.

2.2 联接主义智能控制系统——神经网络建模、预测、优化、控制

从认知学科角度来看, 人们都在建立对这个世界万物的各自的认识模型, 以此为自己的行为提供经验和决策支撑. 在工程学科中, 持经典线性系统模型论观点的人们开始不得不审

慎对待从前被忽略、简化的非线性环节。在工具上,神经网络的强大非线性逼近能力无疑极大的鼓舞了人们的信心。神经网络不仅仅停留在作为认知模型替代未知系统,在识别—推理—决策—执行的过程中,神经网络作为联接主义智能控制系统的底层基石已经构筑了其中的各个环节。

2.2.1 神经网络建模、预测、优化

神经网络建模无非是对非线性系统的一种刻划,以输入输出模型和状态空间模型为主要形式。在输入输出模型形式中,对单输入单输出(SISO)非线性系统

$$y(k) = f(y(k-1), \dots, y(k-n_y), u(k-1), \dots, u(k-n_u)) \quad (2)$$

其中 $f(\cdot)$ 为非线性映射。神经网络辨识模型可以分为如下两种结构:

- 1) 串-并式结构 $\hat{y}(k) = f_{NN}(W, y(k-1), \dots, y(k-n), u(k-1), \dots, u(k-m))$;
- 2) 并式结构 $\hat{y}(k) = f_{NN}(W, \hat{y}(k-1), \dots, \hat{y}(k-n), u(k-1), \dots, u(k-m))$.

这里 $f_{NN}(\cdot)$ 为神经网络辨识得到的映射, W 为神经网络权值空间。串-并式结构比较常用,与神经网络的输入/输出的结构很类似,在辨识建模上通常可以得到较好的稳定结果;并式结构适用于系统输出被噪声严重干扰的情形,它可以避免由于系统输出受噪声“污染”而造成的偏差。Narendra 和 Parthasarathy 曾指出神经网络建模辨识过程中并式结构辨识模型的不利因素,认为在系统受严重噪声耦合或系统与神经网络模型很接近时比较适用,但不能保证其稳定和权值参数收敛;还指出,即使是在线性系统采用并式结构辨识模型尚无法得到输出误差趋于零的理论保证^[114]。近年来有研究认为神经网络的并式结构在一定条件下也能获得较好的建模辨识结果,但仍有待严格论证和深入地研究,如文献[115]中证明了只要动态系统估计的参数满足条件 $w_0^* v_0^* < \frac{16}{n}$, 则并联辨识算法局部收敛,并联预测过程收敛。

在状态空间形式上,神经网络形式的状态观测器大多仍是形式上的状态估计。Suykens^[116]利用 MFNN 建立了神经网络结构的状态空间模型,讨论了三种形式估计算法,为建模辨识和鲁棒控制之间提供了联系的纽带。Jagannathan 等人在神经网络直接控制框架下设计了 MISO 状态空间的 MFNN 辨识模型^[117],文献[46]进一步将其扩展到 Elman 网络,并突破了其持续激励的约束。由于神经网络建模大多作为预测和控制的基础,从闭环系统的统一角度来研究特定目标下的模型建立^[118]还是很有意义的。

神经网络预测一般来说是神经网络建模的直接延伸,得到所需的未知系统的逼近模型是一种后验的“知识”,并进一步平滑过渡到前瞻性的预测。当然,也有直接建立神经网络预测模型的,这大多出现在对时间序列进行分析处理的场合中。这种方法预测域受训练过程的限制而不宜过大,若用迭代方式来获取多步预测,则容易导致预测误差积累。Schenker 和 Agarwal 因而构造了两个神经网络预测器^[119],一个做一步预测,一个做多步预测,两个预测器之间通过内部状态估计传递信息,这就有效地避免了预测误差的积累,在大范围预测中显示了卓越性能。但这种结构的预测模型相对较为具体化,要求已知系统的输出测量方程,无疑大大削减了其可应用性。Atiya 和 Shaheen 指出^[120],在建立尼罗河流量预测模型中,直接多步预测模型要比递推多步预测模型更精确。文献[54]则认为在具有小样本高噪声特征的失业率模型预测中,递推多步预测模型比直接多步预测模型更加可信。文献[55, 95, 121]都构筑了多种基于神经网络的一步/多步预测模型,具有较广的应用范围。

从具体预测内容上看,神经网络多被用于预测非线性强、噪声干扰大、复杂程度高的系

统。文献[122]研究了股市上证指数的可预测性和神经网络预测方案,给出了过拟和现象的解决方法。文献[85]中提出了多种神经网络、模糊理论和遗传算法综合的电力负荷预测方案。文献[123]则系统研究了一种利用局部样本信息的神经网络(Utilization of Local Samples Information Neural Networks, ULSINN),并运用于地震资料解释研究的地壳储层参数的横向预测。对于存在样本信息匮乏的劳动力失业率和金融汇率等社会经济系统,文献[54,124]作了建模、预测方面的工作。

工程与现代科学中的复杂优化问题同样为神经网络提供了广阔的舞台。Hopfield 网络通过能量函数趋于平衡态收敛来获得优化求解。为解决 Hopfield 网陷入局部极小的缺陷,在 Boltzman 机中引入概率意义的模拟退火机制,增强了全局搜索优化解的能力。一般来说,线性规划、二次规划和凸规划的全局优化问题得到的研究比较彻底,只是尚无一个统一通用的解决方案和神经网络优化模型。在解决的策略和原理上,大多根据对偶原理、Kuhn-Tucker 最优性条件,如 Xia 和 Wang^[125,126]根据对偶原理和 Kuhn-Tucker 最优性条件针对线性规划分别设计了非梯度和梯度神经网络模型,其梯度神经网络模型能够得到问题的精确最优解;类似地,文献[127,128]根据二次规划的对偶原理提出了相应的非梯度模型。惩罚因子和退火算法也是主要解决思路,如文献[129,130]分别设计了使惩罚项不断单调增加和时变域值的线性规划神经网络,文献[131]进一步改进了求解凸规划的模拟退火神经网络,但由于存在模拟退火的类似过程,迭代求解过程较长,此外,退火策略也成为优化性能的关键。而在非线性规划上,由于非线性函数的复杂性,人们大多是针对如何找到非线性规划的局部最优解,用神经网络搜索非线性规划全局最优解的研究迄今仍无报道。文献[132]提出了设计非线性规划求解方法的通用思路,但在目标函数或约束函数不满足凸条件时,他们的模型也只能保证局部收敛。Liang 和 Wang^[133]设计了一个解有界约束的非线性规划神经网络,同样也只能保证在凸规划的情况下网络的平衡点与问题最优解之间的对应,而在一般非线性规划,网络的平衡点不一定是最优解。从传统的非线性最优化的数值方法来看,期望设计一个万能的非线性规划神经网络是不切实际的,具体问题具体对待目前仍是可行之道。

混沌神经网络在相空间分形结构上的混沌运动,大大降低了陷入局部极小的可能,在组合优化问题上获得了较多的关注。混沌神经网络模型,如文献[10]中提出的神经网络推广化结构,文献[14,15]提出的双/单混沌振荡子耦合的混沌神经元模型,文献[20,21]设计的混沌 Elman 网络模型。为避免无谓的混沌无序搜索,加速优化收敛过程,结合混沌动力学全局搜索能力和传统神经网络收敛特性,具有暂态混沌特性的神经网络模型中引入了退火机制中的温度变量,以模拟退火技术来控制混沌的收敛:温度高则神经网络处于混沌状态,温度低则成为梯度下降 Hopfield 网络,并且这种暂态混沌神经网络具有渐近稳定性和全局搜索最优解的能力^[11~13]。类似的,Wang 和 Smith^[82]在连续 Hopfield 网络的差分形式下,利用时间步长 Δt 控制混沌收敛,同样具有 Chen 和 Aihara 网络的性能。Hayakawa 将混沌噪声引入 Hopfield 网,不利用退火过程保证收敛,而是将网络状态达到最优解的频率作为寻优效率指标^[134]。文献[83]将 Hopfield 神经元状态自反馈加入,用混沌退火的机制求解 TSP 问题。有别于前面在组合优化中的应用,张国平^[84]提出了用于非线性全局优化的混沌神经网络模型,这也是将来非线性优化的主要研究方向。此外,Tokuda 等人^[135]指出混沌神经网络的优化性能取决于其全局分叉结构,并提出了自适应退火机制的混沌神经网络模型^[136]。Kwok 和 Smith^[18,19]将数个混沌神经网络模型统一在一个整体框架下,指出 Hopfield 网络

的能量函数上增加一个不同的附加能量则构成不同的混沌神经网络。这些系统化的研究有助于抽取混沌优化的机制原理，并为混沌神经网络优化领域的发展提供了方向指南。

神经网络建模、预测和优化都为神经网络控制提供了一个或多个前提，同时也丰富了神经网络控制的形式。神经网络模型的建立可以将传统的线性模型控制理论移植到非线性系统的控制研究中来^[99,137]，神经预测器为进一步的控制策略提供了前瞻性的预测行为，而控制策略也可以转化为优化问题而获得求解^[138]。因此，它们与神经网络控制在整个智能控制系统中互为唇齿，相辅相成。

2.2.2 神经网络控制

神经网络控制(Neural Network Control, NNC)即基于神经网络的控制，也称神经控制(Neurocontrol, NC)，最早源于1992年Tolle和Ersu的专著《Neurocontrol》，而后在1994年《Automatica》的第11期上首先使用。然而，神经网络在控制中的研究最早可以追溯到20世纪60年代Widrow等人利用自适应线性神经网络模型和Widrow-Hoffd最小均方差学习算法来复现一个开关曲面并控制一个倒立摆。在神经网络80年代复兴以后，神经网络控制研究也迅速活跃起来并延续至今。

神经网络与控制领域各分支、流派10余年来充分交融、发展，吸收了各种控制理论的特点和精华，神经网络控制的结构也复杂多样，比较典型的结构如逆动态控制、内模控制、前馈控制和反馈控制、自校正控制、模型参考自适应控制、PID控制、预测控制、自适应激励控制、滑模控制等10余种，它们或平行、或交叉，大多隶属于直接控制和间接控制两种基本结构，或者是二者的复合形式^[137,139~143]。通常，神经网络直接控制结构在于系统的逆模型近似，在静态和重复学习(如机器人控制)的环境下有应用价值。间接控制则以其可塑的内模机制，充分结合已有控制策略，在应用形式与成果上更为丰富。

在非线性系统神经网络控制的基本理论问题上，耶鲁大学Narendra教授的研究组针对有关的能控性、能观测性以及状态空间描述的神经网络控制的可实施性做了一系列研究^[114,144~149]。显然，静态单一的局部线性系统只能在平衡点附近获得线性反馈镇定，而无法保证全局镇定(动态的多模型集是获得全局镇定的一种可能)；利用反馈线性化的非线性系统控制器的镇定区域也很有限，何况在仿射非线性系统结构下，可反馈线性化的系统本身也很有限。因此，从系统全局镇定考虑，文献[145]认为应该发展一般意义描述结构的直接非线性反馈控制器，以获得全局范围的镇定，并探讨了这种直接非线性反馈控制的存在性和神经网络逼近方案。当非线性系统状态空间模型的状态不可获得时，进一步讨论了非线性系统的能观测性概念^[146]，并以此研究了神经网络系统辨识、构造状态估计器和实现输出调节、跟踪的神经网络控制器的设计。文献[149]对MIMO非线性系统解耦控制的神经网络实现做了研究，文献[144]发展了逆控制原理下的神经网络跟踪控制器。

神经网络控制的收敛性和稳定性等基本控制性质主要针对采用在线学习方案的神经网络控制器或学习控制器而展开。宏观来看，这方面的进展与非线性控制系统中有关稳定性理论研究的发展密不可分，除了传统的Lyapunov方法，耗散系统理论和相关的系统无源设计理论^[150,151]、 H^∞ 非线性控制(基于微分对策方法)、Backstepping反馈系统控制^[152,153]等理论的引入，使得神经网络控制的设计和定量分析工具大大丰富，有助于闭环系统性能的精致分析。

基于仿射非线性系统的神经网络控制器的收敛性和稳定性最先被予以分析。Chen^[154]

最早讨论了其反馈线性化下的自校正控制的神经网络实现. 进一步, Chen 和 Khalil 利用 Lyapunov 方法, 证明了在 MFNN 和 BP 算法下神经网络权值和系统输入输出的收敛性和稳定性条件^[155], 针对最小相位的仿射非线性系统

$$y_{k+1} = f(y_k, \dots, y_{k-n+1}, u_{k-1}, \dots, u_{k-m}) + g(y_k, \dots, y_{k-n+1}, u_{k-1}, \dots, u_{k-m})u_k \quad (3)$$

通过反馈线性化直接设计逆系统控制器. 文献[156]中还推广到包含非最小相位系统的状态空间形式.

自适应性是神经网络和神经网络控制的重要特征, 传统的自适应控制的思想和方法也为其并行的神经网络自适应控制提供借鉴, 例如基于常规模梯度信息类学习算法的神经网络自适应控制的闭环系统需要在持续激励(PE, Persistent Excitation)条件下才能获得有界保证, 实际上 PE 条件很难满足, 因而可能导致与线性自适应系统类似的参数漂移现象. Lewis 等通过引入 ϵ -修正的权值学习算法, 针对仿射非线性多变量离散系统

$$\begin{cases} x_1(k+1) = x_2(k) \\ \vdots \\ x_{n-1}(k+1) = x_n(k) \\ x_n(k+1) = f(x(k)) + u(k) + d(k) \end{cases} \quad (4)$$

引入滤波跟踪误差 $r_k = e_n(k) + \lambda_1 e_{n-1}(k) + \dots + \lambda_{n-1} e_1(k)$, 利用 Lyapunov 方法证明了在满足一定条件下权值 \hat{W}_k 和跟踪误差 r_k 一致有界的结论^[117, 157, 158]. 基于类似的思路, 他们引入了离散无源性神经网络(Passive NN)、耗散神经网络(Dissipative NN)和鲁棒神经网络(Robust NN)等概念, 对于开环无源性不明确的非线性对象通过自适应神经网络控制器使得闭环系统无源, 从而保证了稳定性, 并能承受未知有界干扰的影响. 在文献[46]中则构造了在 Elman 网络结构下抛弃 PE 约束的无源闭环系统.

将仿射非线性系统通过一定的微分同胚变换, 可以进一步划分为严格反馈(strict-feedback)、纯反馈(pure-feedback)系统和模块严格反馈(block-strict-feedback)系统的形式, 一类称为 Backstepping 的方法在非线性自适应控制中获得了充分展示其魅力的机会^[152, 153]. 自适应的 Backstepping 方法对参数化的反馈系统迭代设计其各级子系统的 Lyapunov 稳定函数, 突破了全局稳定通常所需要的匹配条件和系统非线性的增长条件等的约束, 成为目前非线性自适应控制的一个重要分支, 也在神经网络的自适应控制和鲁棒控制中获得广泛的关注^[159~164]. 以严格反馈系统的标准形式^[164]为例(纯反馈系统和模块严格反馈系统类似)

$$\begin{cases} \dot{x}_i = f_i(x_1, x_2, \dots, x_i) + g_i(x_1, x_2, \dots, x_i)x_{i+1}, & 1 \leq i \leq n-1 \\ \dot{x}_n = f_n(x) + g_n(x)u \\ y = x_1 \end{cases} \quad (5)$$

在自适应 Backstepping 的思想下, Polycarpou^[162]构造了一个已知 $g_i(\cdot)$ 情形的闭环系统半全局稳定的神经网络控制器; 而 Kwan 和 Lewis 在此思路下将鲁棒神经网络控制应用到感应电动机和机器人系统中^[159~161]; Zhang 和 Ge^[164]则扩展了文献[162]的工作, 不必估计出未知 $g_i(\cdot)$, 避免了通常的反馈线性化设计中存在的控制器奇异, 而同样获得了闭环系统半全局稳定的性质.

上述这些精致的稳定神经网络控制器均是为仿射输入非线性系统而量身订做, 因此控制律的解析形式便于获取, 从而利于定量分析闭环性能. 在一般意义描述下的非线性系统神经网络控制器尚无如此细致的研究结果. 对于离散 SISO 的非线性输入输出模型(2), Ku 等

人^[45]构造了对角神经网络控制器,在动态 BP(Dynamic BP)算法下,将闭环稳定的条件剥离得到对角网络的各层(输出层、对角层和输入层)学习因子的稳定域. 该文中的学习算法在文献[53]中得到了修正. 笔者^[47]则更进一步地扩展得到了广义最小方差神经网络控制器. Chen 和 Chang 提出了通用神经控制器(universal neural controller)的概念,证明了由 RBF 网络构成的 PD 型和 PI 型非线性控制器均为通用控制器,指出了对 BIBO 稳定的非线性对象闭环稳定的充分条件^[165].

对一般性描述结构的非线性系统,神经网络预测控制是获得最多关注的研究结合点之一. 模型预测控制(Model Predictive Control, MPC)如 DMC^[166](Dynamic Matrix Control)和 GPC^[167, 168](Generalized Predictive Control)对具有慢时变、大滞后、不稳定、非最小相位等环节的线性系统取得了满意的控制性能,并被推广到如双线性系统^[169]、Hammerstein^[170]模型等特殊的非线性系统中^[171]. 随着理论与应用的长足发展,预测控制已经从一种控制方法上升成为一种控制思想,并成为神经网络控制、模糊控制等智能控制中的一种重要形式. 文献[172]较早地研究了一步在线神经网络预测控制器,其辨识和控制分别用两个 BP 网络实现. 文献[173]中将 GRNN 作为预测器,模糊 RBF 网络作为控制器,所提出的学习算法可以从初始阶段就自动组织控制器规则,具有较高的自治性. Parlos 等人提出了一种 PI 型多步预测控制策略^[174]. Wang 和 Wan 利用投影网络(projection networks)和梯度投影学习算法来求解带约束 MPC 中的二次规划问题,以求减少在线计算达到实时控制的要求,并在简化的造纸机模型上做了相应试验^[175]. 我国学者丁国锋等也研究了 RBF 网络的一步预测控制机制^[176]. 戴先中等^[177]则针对较一般的模型未知非线性大时延系统,构造 NN 的 α 阶逆系统与原系统复合成 $NN\alpha$ 阶伪线性复合系统,用线性预测控制方法实现有效控制,以求简化预测控制器,便于稳定性和稳态偏差分析. 刘贺平等提出了神经网络直接多步预测控制方案^[178].

南开大学自适应研究室多年来致力于神经网络预测控制的研究,取得了一系列理论研究和应用成果^[46~48, 54~57, 95, 99, 100, 121, 122, 138, 179, 182~184]. 车海平^[121]、贺江峰^[95]、王群仙^[184]、林茂琼^[100]和李翔^[55]在 BP, RBF, Elman 网络、模糊神经网络和小波网络的结构下,讨论了多步预测控制器的若干预测模型结构以及相应的神经网络预测控制算法. 文献[121]中针对非线性系统,设计了在标准模型滚动优化法、多模型法和整体模型法这三种结构下的神经网络非线性预测控制器,具有普遍意义和推广价值;文献[95]中采用 Davidon 最小二乘法来优化预测控制律;文献[100]利用阻尼最小二乘法作为学习算法,设计预测误差补偿的神经网络预测控制器;文献[55]中结合多层前馈神经网络、复合神经网络、扩展 Elman 网络和模糊神经网络,设计了具有不需要离线训练、消除控制过程稳态误差等优点的非线性预测控制器. 文献[48]进一步讨论了一般意义非线性系统下神经网络预测控制器的通用设计方案,采用动态 BP 算法和简单递归神经网络,在一步预测的框架下,证明了整个闭环神经系统的无源稳定性,并进一步提出了递推结构的广义预测神经网络控制器. 总体上,大范围预测的神经网络控制器的关键在于预测器与系统的匹配与否,对于强非线性系统甚至混沌系统,预测域更应该考虑该系统对象的 Kolmogorov-sinai 熵、分维数、Lyapunov 指数等非线性动力学度量性质,以求获得具有合理结构、有限理性的神经网络预测控制^[56].

我国学者陈卫田等^[185]对当时神经网络自适应控制的研究现状做了系统综述,蔡自兴^[140]也总结了多种典型的神经网络控制结构,李少远等则从模糊推理与神经网络内在联系

的角度展望了智能控制的发展前景^[186]. 着眼于提高神经网络控制器乃至整个智能控制系统的自治性, 非监督学习和竞争学习机制下的神经网络控制, 如再励学习的神经网络控制^[187~189], 应该是今后研究的一个着眼点. 非线性系统的控制理论依旧是神经网络控制继续发展的动力源泉. 祈望深入剖析神经网络控制的本征能力, 寻求通用统一的控制结构达到满意的控制是一种可能, 而“没有免费午餐”(no-free-lunch) 定律^[190,191]则暗示了寻求“万能控制器”过程的高昂代价. 分门别类, 按图索骥, 不仅仅只是对各种非线性系统进行形式上的划分, 更需要把握非线性系统内在的复杂动力学行为^[192~194]的脉络.

3 联接主义智能控制应用进展

10 多年来神经网络的应用研究遍及医学诊断、金融证券、电力系统、航空航天飞行器、交通运输、电梯群控、机器人、化工工业过程、家用电器等行业中, 笔者管中窥豹, 试图从下面这些实例中来说明联接主义智能控制当前的应用概况.

神经网络最早应用于解决电力系统安全评估问题^[195], 此后被广泛运用到电力系统的各个领域, 比较成功的包括静/动态安全分析、负荷预报两个方面. 1986 年 S Y Oh 用模式识别和联想记忆的方法, 对一个有 196 个节点、9 台发电机的实际电力系统进行在线安全分析研究, 而 Y H Pao 等人在 1990 年采用他提出的函数联接网络模型使学习速度大大提高, 评估速度比基于潮流的安全评估速度快 10^4 倍^[196]. 负荷预报是神经网络在电力系统应用最多的一个领域. Khotanzad 和 Hwang^[197] 等将电力负荷与天气变量的关系特性分成周、日、时 3 个模型, 整个神经网络短期负荷预报器包括 3 部分, 每部分独立地产生自己的预报, 最后通过自适应滤波器将它们结合起来产生最终预报. 该系统目前已在美国 20 多家电力公司得到了应用^[85].

在医学诊断方面, 神经网络目前更多的是被应用于图像分析与辅助诊断中^[198]. 用神经网络对胸部透视数据进行分析, 评判病灶的良/恶性, 减少不必要的活组织检查. 在单光子发射计算机断层成像中, 神经网络分析比人工看片在病灶探测方面更为准确. 超声图像数据库中的神经网络分析法, 已被用来从肾癌细胞中鉴别出肾囊肿, 准确度相当高.

在飞行器、水下运载工具、电梯群控等航空航天、交通运输方面也有颇多应用研究成果. 在这里, 故障诊断、控制器重配、非线性动态系统辨识和自适应控制都是其中的重要研究方向^[199]. Narendra 等人提出的基于神经网络的多模型自适应控制方案^[148] 具有普遍性, 有报道称 Lockheed 公司的研究人员将其应用到 F/A-18 战斗机的故障模拟诊断中. Steinberg 针对航空飞行器的六自由度的航空动力学模型和发动机模型, 比较了包括模糊控制、自适应 Backstepping 控制、神经网络扩张控制、变结构控制和模型预测控制等 7 种控制策略, 并仿真试验了多种故障下的各种控制算法的鲁棒性^[200]. Kodogiannis 和 Lisboa 等在水下运载器的原型上试验比较了几种神经网络控制策略^[201], 进一步提出了一种嵌入记忆网络(internal memory network) 结构, 在水下机器人的推进器上获得了响应速度和精度的改善^[202]. 此外, 在电梯群控系统中, 神经网络也被引入用于描述电梯群控系统的动态特性^[203,204], 并被用于识别交通模式^[205], 以提高电梯运行效率.

机器人控制也是神经网络应用的一个主要领域. Miller 等学者多年来潜心研究 CMAC 网络, 并成功地用于机器人的运动轨迹控制和眼手协调控制^[206]. 而日本学者 Kawato 则提

出“中枢神经系统”模型,采用反馈误差学习算法来解决这类问题^[207]. Zellerhe 和 Sharma 等人采用文献[105]的拓扑表征网络算法来逼近机器人受约束的轨迹规划空间结构,使柔性机械手可以绕过障碍物^[208~210]. 在基于视觉的机器人自动驾驶系统中,Pomerleau 利用 BP 网络来模拟人的反应,显著提高了该系统的驾驶速度^[211]. Beer 等人则认为神经网络结构可直接用于自治系统的控制,提出一种全分布的网络结构,来指导一个六足机器人的行走^[212,213].

在工业过程中的应用实例则更为突出. 神经应用公司研制的智能电弧炉是一个比较成功的例子,电弧炉通过在 3 个大的电极加电来融化回炉料,对于这个多变量、非线性、时变控制系统,无法用数学模型表示,Staib 等人应用神经网络控制明显提高了其性能^[214,215]. 文献[216]对某钢厂电镀生产线电镀过程进行神经网络智能控制,提高了产品纯度. 文献[217]将神经网络预测器和模糊控制器结合在一起,在一个 6 万人容量的市政污水处理加工厂得到了应用. Galvan 和 Zaldivar 采用并行结构,从多个递归神经网络中选取最佳逼近器,在套管式化学反应釜(jacket chemical reactor)中获得应用,指出并行结构的递归神经网络可以很好地模拟各个反应器不同的加热冷却回路中的动力学行为^[218]. 他们还将神经网络逆控制和预测控制应用在试验性化学反应堆(pilot chemical reactor)上,比反应器装置上原先安装的自校正 PID 控制器有更好的控制品质^[219]. 2001 年 EDS 组织和 Newcastle-upon-Tyne 大学会同 24 个英国的跨国公司联合调查了神经网络在这些公司中的工业应用现状^[220],指出在工业过程中神经网络控制的稳定性是应用关键,而结合神经网络与模糊逻辑的优势形成的模糊神经网络则具有更为广阔的应用前景.

我国学者也成功实现了大量的实际应用工作,胡守仁等^[141,221]、焦李成^[142]、徐秉铮^[108]、王永骥等^[143]、蔡自兴^[222]、李人厚^[223]、李士勇^[224]、王顺晃等^[225]的文献和国内近年来的控制会议论文集上均有报道. 笔者的课题组曾对某涤纶片基拉膜生产线进行品质改造,对其横向剖面和纵向平均厚度分别实施了自适应神经网络控制和广义预测自校正控制^[180,181],大大提高了产品合格率和优质率. 东北大学柴天佑教授率领研究人员采用神经网络作为解耦补偿器,结合专家系统针对钢球磨中储式制粉系统设计了多变量自适应神经网络解耦控制器,大大提高了制粉效率,获得显著的经济效益^[226].

4 感想与展望

在多年来的研究过程中,笔者有如下几点感想.

1)半个世纪多沉积的精华与新的思想相互碰撞,主宰着现代智能控制理论的发展. 尽管正反馈与失稳已经在当前的研究大潮中获得崭新定位^[86,193,194,227~230],负反馈原理和稳(镇)定控制器依然引导着智能控制的大旗. 以 PID 控制为代表的传统反馈调节策略,只能根据当前和历史的偏差信息来被动地调整自身. 自适应控制通过学习、调整来馈入环境信息的变化,以提高自身的动态适应能力,体现着人类认知的朴素思想. 与鲁棒控制对待未知环境变化的“以静制动、一劳永逸”保守策略相反,预测控制基于预测模型的信息,在适度风险下获得对未知因素的主动控制策略. 因此,体现着相当自治色彩的自适应、预测机制将被更多地引入到智能控制系统中来,与神经网络控制的结合是其中的重点之一.

2)实际系统对象本身和所处的复杂环境,都只能得到一定程度上的刻划. 如何尽可能消

除这些被“忽略”因素的干扰,设计适宜的控制策略显得非常重要. 最优效应是夸父追日的动力,而“精致意味着脆弱”的原理却往往被忽视. 因此,整个闭环系统的稳定则显得格外重要. 面对背景纷繁变幻,在尚未充分了解系统本然特征之前,先采取“大而化之”的寻求普遍通用的稳定控制的策略,在充分把握非线性系统特征后再分门别类、按图索骥地“分而治之”是合宜的.

3)混沌(混杂)通常被视为有序的对立面和改造原型,近来这种人脑固有的动力学行为被重新审视,并被暗示成为人类智慧的特征. 相对于消除和控制混沌,混沌反控制^[23](chaos anti-control)、混沌化(chaotifying)等概念是这种认识推动的结果. 在迭代学习的神经网络原型被证明不具有混沌等复杂动力学行为特征时,具有“仿人”情节的联接主义者们开始思考如何能够寻找更接近脑神经原型的混沌神经网络模型. 作为嵌入在“稳定”的人工框架结构下的局部不稳定模型,混沌神经网络和神经网络混沌化的研究背离了传统的负反馈原理,而正反馈的思维无疑是令人好奇并使其深受鼓舞的.

4)神经网络完美的非线性逼近能力不能成为对复杂不确定系统建模的唯一理由. 面对具有高度非线性、大噪声干扰、耦合性强、系统规模庞大等特征的复杂巨系统(如社会经济系统),单纯依靠神经网络来描述其复杂动力学特性显然比较盲目. 模糊逻辑长于经验规则的表述和逻辑推理,以遗传算法为代表的进化算法在全局并行优化上技高一筹,它们与神经网络之间取长补短,相互结合,可以获得局部战术上的改进. 而进一步结合机理模型,才不会使得神经网络建模器、预测器成为无本之木,无源之水.

笔者认为,联接主义智能控制在如下几个方面将会取得进一步的研究突破:

- 1)在有限容量的样本下,有限规模的神经网络的逼近、泛化能力的解析表征;
- 2)针对非线性系统采用局部线性化神经网络模型设计控制器,其局部线性控制器的能控域和稳定域的定量刻划;
- 3)大范围的神经网络预测控制(多步预测)的稳定性、鲁棒性分析及预测域等控制参数的理性表征;
- 4)混沌神经网络复杂动力学行为的统一与分类刻划,以及其广泛应用前景;
- 5)抛弃有教师监督学习的约束,高度自治的联接主义智能控制系统的设计.

回顾 10 余年来智能控制的繁荣发展,各种新的方法理论层出不穷,每年各类研究论文和应用成果数以万计,真可谓“乱花渐欲迷人眼”. 根据 Saridis 提出的 IPDI 原理(精度随智能降低而增加),一个智能控制系统应该具有递阶的结构,从系统结构而言应该包括执行器、感知处理器、环境模型、判值部件、传感器和行为发生器等环节. 客观而言,大多数目前的智能控制研究仍然局限于上述递阶系统的环节层次上的讨论,而从智能控制的识别—推理—决策—执行的整体模式来研究的则相对较少. 因此,无论是从智能模拟根源出发,还是更多着眼于工程应用实际,智能控制理论的研究都将需要走向进一步的系统化.

5 结束语

本文以神经网络为主线,穿插于智能控制的各个环节,对近年来理论研究和应用现状方面的联接主义智能控制的进展做了综述. 在本文即将结束的时候,在这里借用控制论的鼻祖维纳所提倡的一句话:“控制论学家应该继续走向新的领域,应该把他的大部分注意力转到

近10年来的发展中新兴的思想上去”。智能控制不会是控制科学的最终形式,联接主义的思想也不是人类对自身的最终认识,在学科之间的交叉、碰撞中,智能控制理论会推动着控制科学走向更加理性、高级的阶段,而这一切,最终都将交给时间和实践来检验。

参考文献

- 1 Aliev R A, Fazlollahi B, Vahidov R M. Genetic algorithm-based learning of fuzzy neural networks, part 1: Feed-forward fuzzy neural networks. *Fuzzy Sets and Systems*, 2001, **118**(2): 351~358
- 2 Brown M, Harris C J. Neurofuzzy Adaptive Modelling and Control. Hertfordshire: Prentice Hall International (UK) Limited, 1994
- 3 Kim H M, Mendal J M. Fuzzy basis functions: comparisons with other basis functions. *IEEE Trans. on Fuzzy Systems*, 1995, **3**(2):158~168
- 4 Spooner J T, Passino K M. Stable adaptive control using fuzzy systems and neural networks. *IEEE Trans. on Fuzzy Systems*, 1996, **4**(3): 339~359
- 5 Spooner J T, Passino K M. Adaptive prediction using fuzzy systems and neural networks. In: Proc. of American Control Conference, New Mexico: 1997. 1266~1270
- 6 Wang L X. Fuzzy basis function, universal approximation and orthogonal least squares. *IEEE Trans. on Neural Networks*, 1992, **3**(5): 807~814
- 7 Yao X. Review of evolutionary artificial neural networks. *Int. J. Intelligent Systems*, 1993, **8**(4): 539~567
- 8 何永勇,褚福磊,钟秉林. 基于进化计算的神经网络设计与实现. 控制与决策,2001, **16**(3):257~262
- 9 阎平凡,张长水. 人工神经网络与模拟进化计算. 北京:清华大学出版社,2000
- 10 Aihara K, Takabe T, Toyoda M. Chaotic neural networks. *Physics Letters A*, 1990, **144**(6): 333~340
- 11 Chen L N, Aihara K. Chaotic simulated annealing by a neural network model with transient chaos. *Neural Networks*, 1995, **8**(6):915~930
- 12 Chen L N, Aihara K. Chaos and asymptotical stability in discrete-time neural networks. *Physica D.*, 1997, **104**(3):286~325
- 13 Chen L N, Aihara K. Global searching ability of chaotic neural networks. *IEEE Trans. on Circuits and Systems-I*, 1999, **46**(8):974~993
- 14 Inoue M, Fukushima S. A neural network of chaotic oscillators. *Prog. Theor. Phys.*, 1992, **87**(3):771~774
- 15 Inoue M, Nagayoshi A. A chaos neuro-computer. *Physics Letters A*, 1991, **158**(8):373~376
- 16 Ishii S, Fukumizu K, Watanabe S. A network of chaotic elements for information processing. *Neural Networks*, 1996, **9**(1):25~40
- 17 Ishii S, Fukumizu K, Watanabe S. Associative memory based on parametrically coupled chaotic elements. *Physica D*, 1998, **121**(3,4): 344~366
- 18 Kwok T, Smith K A. A unified framework for chaotic neural network approaches to combinatorial optimization. *IEEE Trans. on Neural Networks*, 1999, **10**(4):978~981
- 19 Kwok T, Smith K A. Experimental analysis of chaotic neural network model for combinatorial optimization under a unifying framework. *Neural Networks*, 2000, **13**(7):731~744
- 20 Li X, Chen Z Q, Yuan Z Z et al. Generating chaos by an elman network. *IEEE Trans. on Circuits and Systems-I*, 2001, **48**(9): 1126~1131
- 21 Li X, Chen G R, Chen Z Q et al. Chaotifying linear elman networks. *IEEE Trans. on Neural Networks*, 2002, to be published
- 22 刘增良. 因素神经网络理论及其实现策略研究. 北京:北京师范大学出版社,1992
- 23 刘增良. 模糊逻辑与神经网络理论研究与探索. 北京:北京航空航天大学出版社,1996
- 24 Cybenko G. Approximation by superpositon of a sigmoidal function. *Math. Control Signal Systems*, 1989, **2**(3): 303~314
- 25 Funahashi K I. On the approximate realization of continuous mappings by neural networks. *Neural Networks*, 1989, **2**(2):183~192
- 26 Hecht-Nielsen R. Theory of backpropagation neural network. In: Proc. IJCNN, New York: IEEE Press, 1989.

- 593~605
- 27 Hornik K, Stinchcombe M, White H. Multilayer feedforward networks are universal approximators. *Neural Networks*, 1989, 2(2): 359~366
- 28 Chen T P, Chen H. Approximations of continuous functionals by NN with application to dynamic systems. *IEEE Trans. on Neural Networks*, 1993, 4(6): 910~918
- 29 Chen T P. Approximation Capability in $C(\bar{R}^n)$ by multilayer feedforward networks and related problems. *IEEE Trans. on Neural Networks*, 1995, 6(1): 25~30
- 30 Scarselli F, Tsoi C A. Universal approximation using feedforward neural networks: a survey of some existing methods, and some new results. *Neural Network*, 1998, 11(1): 15~37
- 31 Buckley J J, Yoichi H. Can neural nets be universal approximators for fuzzy functions? *Fuzzy Sets and Systems*, 1999, 101(3): 323~330
- 32 Buckley J J, Yoichi H. Can fuzzy neural nets approximate continuous fuzzy functions? *Fuzzy Sets and Systems*, 1994, 61(1): 43~51
- 33 Liu P Y. Universal approximations of continuous fuzzy-valued functions by multi-layer regular fuzzy neural networks. *Fuzzy Sets and Systems*, 2001, 119(2): 313~320
- 34 Harris C J, Moore C G, Brown M. Intelligent Control: Some Aspects of Fuzzy Logic and Neural Networks. Singapore: World Scientific Press, 1993
- 35 Roger J S, Sun C T. Functional equivalence between radial basis function networks and fuzzy inference systems. *IEEE Trans. on Neural Networks*, 1993, 4(1): 156~159
- 36 Barron A R. Universal approximation bounds for superpositions of a sigmoidal function. *IEEE Trans. Inf. Theory*, 1993, 39(3): 930~945
- 37 Dingankar A T. The unreasonable effectiveness of neural networks approximation. *IEEE Trans. on Automatic Control*, 1999, 44(11): 2043~2044
- 38 Zhang Q H, Benveniste A. Wavelet networks. *IEEE Trans. on Neural Networks*, 1992, 3(6): 889~898
- 39 Zhang Q H. Using wavelet networks in nonparametric estimation. *IEEE Trans. on Neural Networks*, 1997, 8(2): 227~236
- 40 Delyon B, Juditsky A, Benveniste A. Accuracy analysis for wavelet approximation. *IEEE Trans. on Neural Networks*, 1995, 6(2): 332~348
- 41 Tsoi A C, Back A D. Locally recurrent globally feed forward networks: a critical review of architectures. *IEEE Trans. on Neural Networks*, 1994, 5(2): 229~239
- 42 Sperduti A. On the computational power of recurrent neural networks for structure. *Neural Networks*, 1997, 10(3): 395~400
- 43 Elman J L. Finding structure in time. *Cognitive Science*, 1990, 179~211
- 44 Elman J L. Learning and development in neural networks: the importance of starting small. *Cognition*, 1993, 48(1): 71~99
- 45 Ku C C, Lee K Y. Diagonal recurrent neural networks for dynamic system control. *IEEE Trans. on Neural Networks*, 1995, 6(1): 144~156
- 46 Li X, Chen Z Q, Yuan Z Z. Nonlinear stable adaptive control based upon elman networks. *Appl. Math. J. Chinese Univ., Ser. B*, 2000, 15(3): 332~340
- 47 Li X, Chen Z Q, Yuan Z Z. Simple recurrent neural networks control for non-minimum phase nonlinear systems. *Chinese Journal of Control Theory and Applications*, 2001, 18(3): 456~460
- 48 Li X, Chen Z Q, Yuan Z Z. Simple recurrent neural networks-based adaptive predictive control for nonlinear systems. *Asian Journal of Control*, 2002, 4(2): 231~239
- 49 Pham D T, Liu X. Dynamic system modelling using partially recurrent neural networks. *Journal of Systems Engineering*, 1992, 2(1): 90~97
- 50 Pham D T, Liu X. Training of Elman network and dynamic system modeling. *Int J. Systems Science*, 1996, 27(2): 221~226
- 51 Wang D L. On yemperal generalization of simple recurrent networks. *Neural Networks*, 1996, 9(7): 1099~1118
- 52 陈巍. 递归神经网络建模、控制及其在静止无功发生器中的应用研究[博士学位论文]. 广州: 华南理工大学, 1998
- 53 陈巍, 吴捷. 对一种递归神经网络算法的修正. 控制理论与应用, 1998, 15(5): 814~816

- 54 张兴会,杜升之,陈增强等. 基于对角 Elman 神经网络的失业预测模型. 南开大学学报, 2002, **35**(2): 60~64
- 55 李翔. 联接主义智能控制分析与综合[博士学位论文]. 天津:南开大学, 2002
- 56 李翔,陈增强,袁著祉. 基于 Wiener 模型的混沌系统辨识与控制研究. 信息与控制, 2001, **30**(3): 267~270
- 57 李翔,陈增强,袁著祉. 神经网络结构的递归 T-S 模糊模型. 系统工程学报, 2001, **16**(4): 268~274
- 58 韦巍. 一种回归神经网络的快速在线学习算法. 自动化学报, 1998, **24**(5): 618~621
- 59 Barron A R. Approximation and estimation bounds for artificial neural network. *Machine Learning*, 1994, **14**(1): 115~133
- 60 Niyogo P. On the relationship between generalization error, hypothesis complexity, and sample complexity for radial basis function. *Neural Computation*, 1996, **8**(4): 819~842
- 61 An G Z. The effect of adding noise during backpropagation training on a generalization performance. *Neural Computation*, 1996, **8**(3): 643~671
- 62 Bishop C M. Training with noise is equivalent to Tikhonov regularization. *Neural Computation*, 1995, **7**(1): 108~116
- 63 Holmstrom L, Koistinen P. Using additive noise in backpropagation training. *IEEE Trans. on Neural Networks*, 1992, **3**(1): 24~38
- 64 Hinton G E. Keeping neural networks simple. In: Proc. of the International Conference on Artificial Neural Networks, Amsterdam, Berlin: Springer, 1993. 11~18
- 65 Murata N. Network information criterion determining the number of hidden units for an artificial neural network model. *IEEE Trans. on Neural Networks*, 1994, **5**(6): 865~872
- 66 Schmidhuber J. Discovering neural nets with low kolmogorov complexity and high generalization capability. *Neural Networks*, 1997, **10**(5): 857~873
- 67 董 聪. 多层前向网络的逼近与泛化机制. 控制与决策, 1998, **13**(增刊): 413~417
- 68 何述东. 多层前向神经网络结构的研究进展. 控制理论与应用, 1998, **15**(3): 313~319
- 69 魏海坤. 神经网络的泛化理论和泛化方法. 自动化学报, 2001, **27**(6): 806~815
- 70 王国胜,钟义信. 支持向量机的若干新进展. 电子学报, 2001, **29**(10): 1397~1400
- 71 Schapire R E. A brief introduction to boosting. In: Proc. of the Sixteenth International Joint Conference on Artificial Intelligence, 1999, 1231~1234
- 72 Freeman W J. The physiology of perception. *Scientific American*, 1991, (2): 78~85
- 73 Freeman W J. A proposed name for aperiodic brain activity: stochastic chaos. *Neural Networks*, 2000, **13**(1): 11~13
- 74 Rabinovich M I, Abarbanel H D I. The role of chaos in neural systems. *Neuroscience*, 1998, **87**(1): 5~14
- 75 Sarbadhikari S N, Chakrabarty K. Chaos in the brain: a short review alluding to epilepsy, depression, exercise and lateralization. *Medical Engineering and Physics*, 2001, **23**(7): 447~457
- 76 Selvam A M. Cantorian fractal spacetime and information in neural network of the human brain. *Chaos, Solitons and Fractals*, 1999, **10**(1): 25~29
- 77 Marcus C M, Westervelt R M. Dynamics of iterated-map neural networks. *Phys. Rev. A.*, 1989, **40**(1): 501~504
- 78 Lie Z, Hofield J J. Modeling the olfactory bulb and its neural oscillatory processing. *Biological Cybernetics*, 1989, **61**(3): 379~392
- 79 Yao Y, Freeman W J. Model of biological pattern recognition with spatially chaotic dynamics. *Neural Networks*, 1990, **3**(2): 153~170
- 80 Lemke N, Arenzon J J. Nonlinear behaviour of neural networks with dynamical thresholds. *J. of Coal Quality*, 1994, **13**(1): 1335~1343
- 81 Tsuda I. Dynamic link of memory: chaotic memory map in nonequilibrium neural networks. *Neural Networks*, 1992, **5**(2): 313~326
- 82 Wang L, Smith K. On chaotic simulated annealing. *IEEE Trans. on Neural Networks*, 1998, **9**(4): 716~718
- 83 Zhou C S, Chen T L. Chaotic annealing for optimization. *Phys. Rev. E.*, 1997, **55**(3): 2580~2587
- 84 张国平. 神经网络优化技术研究[博士学位论文]. 天津:天津大学, 2001
- 85 张昊. 电力调度自动化系统及电力负荷智能化预测方法的研究[博士学位论文]. 广州:华南理工大学, 1997
- 86 郑维敏. 正反馈. 北京:清华大学出版社, 1998
- 87 周昌松. 混沌动力学及其应用[博士学位论文]. 天津:南开大学, 1997

- 88 Kuan C M, Hornik K. Convergence of learning algorithms with constant learning rates. *IEEE Trans. on Neural Networks*, 1991, **2**(5): 484~489
- 89 Salomon R, Hemmon V J L. Accelerating backpropagation through dynamic self-adaptation. *Neural Networks*, 1996, **9**(4): 589~601
- 90 Magoulas G D. Effective backpropagation training with variable stepsize. *Neural Networks*, 1997, **10**(1): 69~82
- 91 Hertz J, Krogh A. Nonlinear backpropagation: doing backpropagation without derivatives of the activation function. *IEEE Trans. on Neural Networks*, 1997, **8**(6): 1321~1328
- 92 Smagt P. Minimization methods for training feedforward neural networks. *Neural Networks*, 1994, **7**(1): 1~11
- 93 Osowski P. Fast second order algorhim for feedforward multilayer neural networks and its applications. *Neural Networks*, 1996, **9**(9): 1583~1596
- 94 Davidon K V. Least square-based learning algorithm for feedforword neural networks. *Neural Networks*, 1994, **7**(4): 661~670
- 95 贺江峰. 基于神经网络的自适应辨识与控制算法及应用[博士学位论文]. 天津: 南开大学, 1998
- 96 Puskorius G V, Feldkamp L A. Decoupled extended Kalman filter training of feedforward layered networks. In: International Joint Conference on Neural Networks, Seattle, 1991. 307~312
- 97 Puskorius G V, Feldkamp L A. Neurocontrol of nonlinear dynamical systems with Kalman filter trained recurrent networks. *IEEE Trans. on Neural Networks*, 1994, **5**(2): 279~297
- 98 Williams R J. Training recurrent network using the extended Kalman filter. In: International Joint Conference on Neural Networks, Baltimore, 1992. 241~246
- 99 陈增强, 袁著祉, 李 翔. 基于神经元网络的非线性系统预测控制研究. 系统科学与工程研究, 许国志主编, 上海: 上海科技教育出版社, 2000. 506~512
- 100 林茂琼. 基于阻尼最小二乘法的系统辨识与智能控制[博士学位论文]. 天津: 南开大学, 1999
- 101 Moody J, Darkin C. Fast learning in networks of locally-tuned processing units. *Neural Computation*, 1989, **1**(2): 281~294
- 102 Chen S, Billings S A, Grant P M. Recursive hybrid algorithm for nonlinear system identification using radial basis function networks. *Int. J. Control.*, 1992, **55**(5): 1051~1070
- 103 Chen S, Cowan C F N, Grant P M. Orthogonal least squares algorithm for radial basis function networks. *IEEE Trans. on Neural Networks*, 1991, **2**(2): 302~309
- 104 Holcomb T, Morari M. Local training for radial function networks: towards solving the hidden unit problem. In: American Control Conference, 1993. 2331~2335
- 105 Hwang Y S, Bang S Y. An efficient method to construct a radial basis function neural network classifier. *Neural Networks*, 1997, **10**(8): 1495~1503
- 106 罗 忠, 谢永斌, 朱重光. CMAC 学习过程收敛性的研究. 自动化学报, 1997, **23**(4): 455~461
- 107 刘 慧, 许晓鸣, 张钟俊. 小脑模型神经网络改进算法的研究. 自动化学报, 1997, **23**(4): 482~487
- 108 徐秉铮. 神经网络理论与应用. 广州: 华南理工大学出版社, 1994
- 109 Hornik K, Kuan C M. Gradient-based learning in recurrent networks. *Neural Network World*, 1994, **4**(2): 157~172
- 110 沈世镒. 神经网络系统理论及其应用. 北京: 科学出版社, 1998
- 111 阎平凡. 对多层前向神经网络研究的几点看法. 自动化学报, 1997, **23**(1): 129~135
- 112 孙学全. 多层感知器的灵敏度分析与区域映射模型[博士学位论文]. 哈尔滨: 哈尔滨工业大学, 2001
- 113 郭 雷, 郭宝龙. 神经网络计算理论—逻辑分析和时间表示. 北京: 科学出版社, 2000
- 114 Narendra K S, Parthasarathy K. Identification and control of dynamical systems using neural networks. *IEEE Trans. on Neural Networks*, 1990, **1**(1): 4~27
- 115 卢 进, 徐文立, 韩曾晋. 神经网络并联辨识算法的收敛性研究. 控制理论与应用, 1998, **15**(5): 741~745
- 116 Suykens J A K. Nonlinear system identification using neural state space models, applicable to robust control design. *Int. J. Control.*, 1995, **62**(1): 129~152
- 117 Jagannathan S, Lewis F L. Multilayer discrete-time neural-net controller with guaranteed performance. *IEEE Trans. on Neural Networks*, 1996, **7**(1): 107~130
- 118 Landau I D, Karimi A. Recursive algorithms for identification in closed loop: A unified approach and evaluation. *Automatica*, 1997, **33**(8): 1499~1523

- 119 Schenker B, Agarwal M. Long-range prediction for poorly-known systems. *Int. J. Control.*, 1995, **62**(1): 227~238
- 120 Atiya A F, Shaheen S I. A comparison between neural network forecasting techniques case study: river flow forecasting. *IEEE Trans. on Neural Network*, 1999, **10**(2):402~409
- 121 车海平. 自适应预测控制分析与综合[博士学位论文]. 天津:南天大学,1997
- 122 刘新勇. 神经网络在股市预测中的应用研究[硕士学位论文]. 天津:南开大学,1997
- 123 翟军. 一种利用局部样本信息的神经网络[博士学位论文]. 哈尔滨:哈尔滨工业大学,1996
- 124 靳玉英. 稳定、效率理念与东亚汇率合作[博士学位论文]. 天津:南开大学,2002
- 125 Xia Y S. A new neural network for linear programming problems and its application. *IEEE Trans. on Neural Networks*, 1996, **7**(2): 525~529
- 126 Xia Y S, Wang J. Neural network for solving linear programming problems with bounded variables. *IEEE Trans. on Neural Networks*, 1995, **6**(2): 515~519
- 127 Wu X, Xia Y S. A high performance neural networks for solving linear and quadratic programming problems. *IEEE Trans. on Neural Networks*, 1996, **7**(3): 643~651
- 128 Xia Y S. A new neural network for solving linear and quadratic programming problems. *IEEE Trans. on Neural Networks*, 1996, **7**(6): 1544~1547
- 129 Wang J. Analysis and design of a recurrent neural network for linear programming. *IEEE Trans. on Circuits and Systems-I*, 1993, **40**(9): 613~618
- 130 Wang J, Chankong V. Recurrent neural networks for linear programming: analysis and design principles. *Computer and Operations Research*, 1992, **19**(3-4): 297~311
- 131 Wang J. A deterministic annealing neural network for convex programming. *Neural Networks*, 1994, **7**(4): 629~641
- 132 Xia Y S, Wang J. A general methodology for designing globally convergent optimization neural networks. *IEEE Trans. on Neural Networks*, 1998, **9**(6): 1331~1343
- 133 Liang X B, Wang J. A recurrent neural network for nonlinear optimization with a continuously differentiable objective function and bound constraints. *IEEE Trans. on Neural Networks*, 2000, **11**(6): 1251~1262
- 134 贺昱曜,王力波. 混沌神经网络及其在最优化问题中的运用. 控制理论与应用,2000,**17**(6):847~852
- 135 Tokuda I, Nagashima T, Aihara K. Global bifurcation structure of chaotic neural networks and its application to traveling salesman problems. *Neural Networks*, 1997, **10**(9): 1673~1690
- 136 Tokuda I, Aihara K, Nagashima T. Adaptive annealing for chaotic optimization. *Physical Review E*, 1998, **58**(4): 5157~5160
- 137 Agarwal M. Combining neural and conventional paradigms for modeling, prediction and control. *Int. J. System Science*, 1997, **28**(1): 65~81
- 138 陈增强,赵天航,袁著祉. 基于 Tank-Hopfield 神经网络的有约束多变量广义预测控制器. 控制理论与应用,1998,**15**(6):847~852
- 139 Hunt K J, Sbarbaro D. Neural networks for control systems-A survey. *Automatica*, 1992, **28**(6): 1083~1112
- 140 蔡自兴. 神经控制器的典型结构. 控制理论与应用,1998,**15**(1):1~8
- 141 胡守仁. 神经网络应用技术. 长沙:国防科技大学出版社,1993
- 142 焦李成. 神经网络系统理论. 西安:西安电子科技大学出版社, 1990
- 143 王永骥,涂健. 神经元网络控制. 北京:机械工业出版社, 1998
- 144 Cabrera J B D, Narendra K S. Issues in the application of neural networks for tracking based on inverse control. *IEEE Trans. on Automatic Control*, 1999, **44**(11): 2007~2027
- 145 Levin A U, Narendra K S. Control of nonlinear dynamical systems using neural networks: controllability and stabilization. *IEEE Trans. on Neural Networks*, 1993, **4**(2): 192~205
- 146 Levin A U, Narendra K S. Control of nonlinear dynamical systems using neural networks-Part II: observability, identification, and control. *IEEE Trans. on Neural Networks*, 1996, **7**(1): 30~42
- 147 Narendra K S. Neural networks for control: theory and practice. In: Proceeding of the IEEE, 1996, **84**(10): 1385~1406
- 148 Narendra K S, Mukhopadhyay S. Intelligent control using neural networks. *IEEE Control System Magazine*, 1992, **12**(4):11~18

- 149 Narendra K S, Mukhopadhyay S. Adaptive control of nonlinear multivariable systems using neural networks. *Neural Networks*, 1994, **7**(5): 737~752
- 150 Goodwin G C, Sin K S. Adaptive Filtering, Prediction and Control. Englewood Cliffs, NJ: Prentice-Hall, 1984
- 151 Narendra K S. Stable Adaptive Control. Englewood Cliffs, NJ: Prentice-Hall, 1989
- 152 Kanellakopoulos I, Kokotovic P V, Morse A S. Systematic design of adaptive controllers for feedback linearizable systems. *IEEE Trans. on Automatic Control*, 1991, **36**(11): 1241~1253
- 153 Krstic M, Kanellakopoulos I, Kokotovic P V. Nonlinear and Adaptive Control Design. New York: John Wiley & Sons Inc., 1995
- 154 Chen F C. Back-propagation neural networks for nonlinear self-tuning adaptive control. *IEEE Control System Magazine*, 1990, **10**(3): 44~48
- 155 Chen F C, Khalil H K. Adaptive control of a nonlinear systems using neural networks. *Int. J. Control*, 1992, **55**(6): 1299~1317
- 156 Chen F C, Khalil H K. Adaptive control of a class of nonlinear discrete-time systems using neural networks. *IEEE Trans. on Automatic Control*, 1995, **40**(5): 791~801
- 157 Jagannathan S, Lewis F L. Discrete-time neural net controller for a class of nonlinear dynamical systems. *IEEE Trans. Automatic Control*, 1996, **41**(11): 1693~1699
- 158 Jagannathan S, Commuri S, Lewis F L. Feedback linearizaton using CMAC neural networks. *Automatica*, 1998, **34**(5): 547~557
- 159 Kwan C M, Lewis F L, Dawson D M. Robust neural network control of rigid-link electrically driven robots. *IEEE Trans. on Neural Networks*, 1998, **9**(6): 581~588
- 160 Kwan C M, Lewis F L. Robust backstepping control for induction motors using neural networks. *IEEE Trans. on Neural Networks*, 2000, **11**(5): 1178~1187
- 161 Kwan C M, Lewis F L. Robust backstepping control of nonlinear systems using neural networks. *IEEE Trans. on System, Man and Cybernetics-A*, 2000, **30**(6): 753~766
- 162 Polycarou M M. Stable adaptive neural control scheme for nonlinear systems. *IEEE Trans. on Automatic Control*, 1996, **41**(3): 447~451
- 163 Polycarpou M M, Ioannou P A. A robust adaptive nonlinear control design. *Automatica*, 1996, **32**(3): 423~427
- 164 Zhang T, Ge S S, Hang C C. Adaptive neural network control for strict-feedback nonlinear systems using back-stepping design. *Automatica*, 2000, **36**(11): 1835~1846
- 165 Chen C L, Chang F Y. Universal neural controllers and stability analysis. *Int. J. Systems Science*, 1996, **27**(2): 171~177
- 166 Cutler C R, Ramaker B L. Dynamic matrix control-a computer control algorithm. In: Proc. of the 1980 joint automatic control conference, San Francisco: 1980, **1**, 5~13
- 167 Clarke D W, Mohtadi C, Tuffs P S. Generalized predictive control-part I: the basic algorithm, part II:extensions and interpretations. *Automatica*, 1987, **23**(2): 137~160
- 168 Clarke D W, Mohtadi C. Properties of generalized predictive control. *Automatica*, 1989, **25**(6): 859~875
- 169 Feng E B, Yu J S. New method for predictive controllers design for bilinear systems. *Int. J. Control*, 1991, **53**(1): 97~111
- 170 Zhu Q M, Warwich K. Adaptive generalized predictive controller for nonlinear systems. *IEE Pt D.*, 1991, **138**(1): 33~40
- 171 陈虹, 刘志远, 解小华. 非线性模型预测控制的现状与问题. *控制与决策*, 2001, **16**(4): 385~391
- 172 Hao J B. Predictive control of nonlinear system based on identification by backpropagation networks. *Int. J. Neural Systems*, 1994, **5**(3): 335~344
- 173 Lian S T, Marzuki K. Adaptive neuro-fuzzy control system by RBF and GRNN neural networks. *Journal of Intelligent and Robotic Systems: Theory & Applications*, 1998, **23**(2~4): 267~289
- 174 Parlos A G, Parthasarathy S, Atiya A F. Neuro-predictive process control using on-line controller adaptation. *IEEE Trans. on Control Systems Technology*, 2001, **9**(5): 741~755
- 175 Wang L X, Wan F. Structured neural networks for constrained model predictive control. *Automatica*, 2001, **37**(8): 1235~1243
- 176 丁国锋, 王孙安. 基于径向基函数网络的一步超前预测控制研究. *控制与决策*, 1996, **11**(4): 485~489

- 177 戴先中,何丹. 基于 NN α 阶逆的非线性大时延系统预测控制. 控制理论与应用, 2000, 17(4): 589~592
- 178 刘贺平, 张兰玲, 孙一康. 基于多层局部回归神经网络的多变量非线性系统预测控制. 控制理论与应用, 2001, 18(2): 298~300
- 179 Chen Z Q, Yuan Z Z, Lin M Q. Application of damped least squares to neural-net-based nonlinear adaptive controller. *Int. J. of Nonlinear Sciences and Numerical simulation*, 2001, 2(2): 65~66
- 180 陈增强, 袁著祉, 刘忠信等. 涤纶薄膜拉伸生产线纵向分布自校正预测控制. 仪器仪表学报, 2001, 22(1): 21~24
- 181 陈增强, 袁著祉, 刘忠信等. 涤纶片基拉膜生产线横向分布神经网络自校正预测控制. 自动化学报, 2001, 27(3): 332~337
- 182 李少远, 刘浩, 袁著祉. 基于神经网络误差修正的广义预测控制. 控制理论与应用, 1996, 13(5): 677~680
- 183 李少远. 模糊智能预测控制研究[博士学位论文]. 天津: 南开大学, 1997
- 184 王群仙. 基于神经网络和小波分析的预测控制研究[博士学位论文]. 天津: 南开大学, 1998
- 185 陈卫田, 施颂淑, 张仲俊. 基于神经网络的非线性自适应控制. 控制理论与应用, 1996, 13(5): 545~552
- 186 李少远, 席裕庚, 陈增强等. 智能控制的新进展(II). 控制与决策, 2000, 15(2): 136~140
- 187 Si J, Wang Y T. On-line learning control by association and reinforcement. *IEEE Trans. on Neural Networks*, 2001, 12(2): 264~276
- 188 蒋志明, 王丽红. 非线性系统的再励学习控制研究. 控制理论与应用, 2000, 17(6): 899~903
- 189 阎平凡. 再励学习——原理、算法及其在智能控制中的应用. 信息与控制, 1996, 25(1): 29~34
- 190 Ho Y C. The no free lunch theorem and the human-machine interface. *IEEE Control Systems*, 1999, 19(3): 8~10
- 191 Macready W G, Wolpert D H. The no free lunch theorem. *IEEE Trans. Evolutionary Computing*, 1997, 1(1): 67~82
- 192 Chen G R, Dong X N. From Chaos to Order: Methodologies, Perspectives and Applications. Singapore: World Scientific Pub. Co., 1998
- 193 陈关荣. 控制非线性动力系统的混沌现象. 控制理论与应用, 1997, 14(1): 1~6
- 194 陈关荣. 控制动力学系统的分岔. 控制理论与应用, 2001, 18(2): 153~159
- 195 Pao Y H, Oh S Y. A rule-based approach to power systems security assessment. In: Proc. of Pattern Recognition and Image Processing Conference, 1981. 340~342
- 196 Sobajic D J, Pao Y H. Real-time security monitoring of electric power systems using parallel associative memories. In: Proc. of IEEE International Symposium on Circuits and Systems, 1990. 2929~2932
- 197 Khotanzad A, Hwang R C. An adaptive modular artificial neural network hourly load forecaster and its implementation at electric utilities. *IEEE Trans. on Power Systems*, 1995, 10(3): 1716~1722
- 198 任劲松. 人工神经网络在生物医学技术中的应用. 国外医学生物医学工程分册, 1996, 19(1): 40~45
- 199 Rauch H E, Schaecter D B. Neural networks for control, identification and diagnosis. In: Proc. of World Space Congress, 1992. 4~16
- 200 Steinberg M L. Comparison of intelligent, adaptive, and nonlinear flight control laws. *Journal of Guidance, Control, and Dynamics*, 2001, 24(4): 693~699
- 201 Kodogiannis V S, Lisboa P J G, Lucas J. Neural network modeling and control for underwater vehicles. *Artificial Intelligence in Engineering*, 1996, 10(3): 203~212
- 202 Lisboa P J G, Kodogiannis V S, Lucas J. Neural network identification and control of an underwater vehicle. *Transactions of the Institute of Measurement and Control*, 1997, 19(4): 202~210
- 203 Markon S, Kita H, Nishikawa Y. Adaptive optimal elevator group control by use of neural networks. *Trans. of the Institute of Systems, Control & Information Engineers*, 1994, 7(12): 487~497
- 204 Yamazaki M, Onishi K. The latest group-control system for double-deck elevators. *Mitsubishi Electric Advance*, 1994, 67(6): 21~22
- 205 Sasaki K. Elevator group supervisory control system using neural networks. *Elevator World*, 1996, 44(2): 81~86
- 206 Miller W T, Sutton R S, Werbos P J. Neural Networks for Control. Cambridge, MA: MIT Press, 1990
- 207 Kawato M. Hierarchical neural network model for voluntary movement with application to robotics. *IEEE Control Systems Magazine*, 1988, 8(2): 8~16
- 208 Martinetz T, Schulten K. Topology representing networks. *Neural Networks*, 1994, 7(3): 507~522

- 209 Sharma R, Sutanto H. A framework for robot motion planning with sensor constraints. *IEEE Trans. on Robotics and Automation*, 1997, **13**(1): 61~73
- 210 Zeller M, Sharma R. Motion planning of a pneumatic robot using a neural network. *IEEE Control System Magazine*, 1997, **17**(3): 89~98
- 211 Pomerleau D A. Efficient training of artificial neural networks for autonomous navigation. *Neural Computation*, 1991, **3**(1): 88~97
- 212 Beer R D. Intelligence as Adaptive Behavior: an Experiment in Computational Neuroethology. San Diego: Academic, 1990
- 213 Beer R D, Chiel H J. A distributed neural network architecture for hexaped robot locomotion. *Neural Computation*, 1991, **4**(3): 356~365
- 214 Staib W E, Staib R B. The intelligent arc furnace TM controller: a neural network electrode position optimization system for the electric arc furnace. In: Proc. Int Joint Conf. on Neural Networks, 1992, **3**: 1~9
- 215 Staib W E, McNames J N. Operating experience from intelligent arc furnace installations. *Iron and Steel Engineer*, 1994, **71**(5): 38~41
- 216 Bloch G, Sirou F. Neural intelligent control for a steel plant. *IEEE Trans. on Neural Networks*, 1997, **8**(4): 910~918
- 217 Bongards M. Improving the efficiency of a wastewater treatment plant by fuzzy control and neural networks. *Water Science and Technology*, 2001, **43**(11): 189~196
- 218 Galvan I M, Zaldivar J M. Application of recurrent neural networks in batch reactors part I: NARMA modelling of the dynamic behaviour of the heat transfer fluid temperature. *Chemical Engineering and Processing*, 1997, **36**(6): 505~518
- 219 Galvan I M, Zaldivar J M. Application of recurrent neural networks in batch reactors: part II: nonlinear inverse and predictive control of the heat transfer fluid temperature. *Chemical Engineering and Processing*, 1998, **37**(2): 149~161
- 220 Lennox B, Montague G A. Industrial application of neural networks—an investigation. *Journal of Process Control*, 2001, **11**(5): 497~507
- 221 胡守仁. 神经网络导论. 长沙: 国防科技大学出版社, 1993
- 222 蔡自兴. 智能控制. 北京: 电子工业出版社, 1990
- 223 李人厚. 智能控制理论和方法. 西安: 西安电子科技大学出版社, 1999
- 224 李士勇. 模糊控制、神经控制和智能控制论. 哈尔滨: 哈尔滨工业大学出版社, 1998
- 225 王顺晃, 舒迪前. 智能控制系统及其应用. 北京: 机械工业出版社, 1998
- 226 柴天佑. 多变量自适应解耦控制及应用. 北京: 科学出版社, 2001
- 227 Chen G R, Lai D J. Feedback control of Lyapunov exponents for discrete-time dynamical systems. *Int. J. Bifurcation and Chaos*, 1996, **6**(7): 1341~1349
- 228 Chen G R, Lai D J. Making a dynamical system chaotic: feedback control of lyapunov exponenets for discrete-time dynamical systems. *IEEE Trans. on Circuits System-I*, 1997, **44**(2): 250~253
- 229 Chen G R, Lai D J. Feedback anticontrol of discrete chaos. *Int. J. of Bifurcation and chaos*, 1998, **8**(7): 1585~1590
- 230 Wang X F, Chen G R. Chaotification via arbitrarily small feedback controls: theory, method, and applications. *Int. J. of Bifurcation and Chaos*, 2000, **10**(3): 549~570

袁著祉 1962年毕业于南开大学数学系, 现为南开大学自动化系教授, 博士生导师。研究领域为预测控制、自适应控制和智能控制理论及计算机控制与管理。

陈增强 1997年毕业于南开大学计算机与系统科学系, 获得工学博士学位, 现为南开大学自动化系教授, 博士生导师。研究领域为预测控制、自适应控制和智能控制理论。

李翔 1997年毕业于南开大学计算机与系统科学系, 现为南开大学自动化系博士生。研究领域为神经网络控制、混沌神经网络和联接主义智能控制。