

神经控制器的典型结构*

蔡自兴

(中南工业大学智能控制研究所·长沙, 410083)

摘要: 本文研究了神经控制的典型结构方案, 包括神经学习控制、神经直接逆控制、神经自适应控制、神经内模控制、神经预测控制、基于小脑模型联接控制(CMAC)、多层神经控制和递阶神经控制等. 文中着重讨论了控制机理, 提供了潜在应用基础, 对神经控制器结构方案的确定具有借鉴作用.

关键词: 神经网络(NN); 神经控制; 结构; 非线性系统

1 引言

自 McCulloch 和 Pitts 于 1943 年提出“似脑机器”(Mind-like Machine)和神经学网络(Neurological Network)概念以来^[1], 人工神经网络(Artificial Neural Network, ANN 或简称为 NN)的研究走过一条波浪式推进的发展道路. 由于 ANN 具有非线性映射、自学习、自适应与自组织、函数逼近和大规模并行分布处理等能力, 因而具有用于智能控制系统的潜力. 已经作出许多努力, 把神经网络用于控制系统, 处理控制系统的非线性和不确定性以及逼近控制系统的辨别函数等^[2~5].

进入 90 年代以来, 已对神经控制的结构研究进行了总结^[5~7]. 迄今为止, 已经提出十多种神经控制器的结构方案. 本文在国内外已有研究工作的基础上试图对这些结构方案进行分类. 由于分类方法的不同, 神经控制器的结构也很自然地有所不同. 下面要讨论的神经控制结构的典型方案包括 NN 学习控制, NN 直接逆控制, NN 自适应控制, NN 内模控制, NN 预测控制, NN 强化控制, CMAC 控制, 分级 NN 控制和多层 NN 控制等.

2 结构方案

2.1 NN 学习控制^[8,9]

由于受控系统的动态特性是未知的或者仅有部分是已知的, 因此需要寻找某些支配系统动作和行为的规律, 使得系统能被有效地控制. 在有些情况下, 需要设计一种能够模仿人类作用的自动控制器. 神经网络(NN)控制是实现这类控制的一种方法, 我们称它为基于神经




图 1 基于神经网络的监督式控制

网络的学习控制、监督式神经控制, 或 NN 监督式控制. 图 1 给出一个 NN 学习控制的结构, 图中, 包括一个导师(监督程序)和一个可训练的神经网络控制器(NNC). 控制器的输入对应于由人接收(收集)的传感输入信息, 而用于训练的输出对应于人对系统的控制输入.

2.2 NN 直接逆模型控制^[3,4,10]

顾名思义, NN 直接逆控制采用受控系统的一个逆模型, 它与受控系统串接以便使系统在

* 国家自然科学基金(69574037)、国家教委博士点基金(9553310)和中国有色金属工业总公司回国基金(9507BL01)的资助项目.

本文于 1996 年 10 月 28 日收到, 1997 年 10 月 23 日收到修改稿.

期望响应(网络输入)与受控系统输出间得到一个相同的映射. 因此, 该网络(NN)直接作为前馈控制器, 而且受控系统的输出等于期望输出. 这种方法在很大程度上依赖于作为控制器的逆模型的精确程度. 由于不存在反馈, 本法鲁棒性不足. 逆模型参数可通过在线学习调整, 以期把受控系统的鲁棒性提高至一定程度.

图 2 给出 NN 直接逆控制的两种结构方案. 在图 2(a)中, 网络 NN1 和 NN2 具有相同的逆模型网络结构, 而且采用同样的学习算法. 图 2(b)为 NN 直接逆控制的另一种结构方案, 图中采用一个评价函数(EF).




图 2 NN 直接逆控制

2.3 NN 自适应控制^[11~14]

与常规自适应控制一样, NN 自适应控制也分为两类, 即自校正控制(STC)和模型参考自适应控制(MRAC). STC 和 MRAC 之间的差别在于: STC 根据受控系统的正和/或逆模型辨识结果直接调节控制器的内部参数, 以期能够满足系统的给定性能指标; 在 MRAC 中, 闭环控制系统的期望性能是由一个稳定的参考模型描述的, 而该模型又是由输入-输出对 $\{r(t), y^*(t)\}$ 确定的. 本控制系统的目标在于使受控装置的输入 $y(t)$ 与参考模型的输出渐近地匹配, 即

$$\lim_{t \rightarrow \infty} \|y^*(t) - y(t)\| \leq \epsilon. \quad (1)$$

式中 ϵ 为一指定常数.

2.3.1 NN 自校正控制(STC)

基于 NN 的 STC 有两种类型, 直接 STC 和间接 STC. NN 直接自校正控制系统由一个常规控制器和一个具有离线辨识能力的识别器组成; 后者具有很高的建模精度. NN 直接自校正控制的结构基本上与直接逆控制相同. NN 间接自校正控制系统由一个 NN 控制器和一个能够在线修正的 NN 识别器组成; 图 3 表示出 NN 间接 STC 的结构.

一般, 我们假设受控对象(装置)为如下式所示的单变量非线性系统:

$$y_{k+1} = f(y_k) + g(y_k)u_k. \quad (2)$$

式中, $f(y_k)$ 和 $g(y_k)$ 为非线性函数. 令 $\hat{f}(y_k)$ 和 $\hat{g}(y_k)$ 分别代表 $f(y_k)$ 和 $g(y_k)$ 的估计值. 如果 $f(y_k)$ 和 $g(y_k)$ 是由神经网络离线辨识的, 那么能够得到足够近似精度的 $\hat{f}(y_k)$ 和 $\hat{g}(y_k)$, 而且可以直接给出常规控制律:

$$u_k = [y_{d,k+1} - \hat{f}(y_k)] / \hat{g}(y_k). \quad (3)$$

式中 $y_{d,k+1}$ 为在 $(k+1)$ 时刻的期望输出.

2.3.2 NN 模型参考自适应控制

基于 NN 的 MRAC 也分为两类, 即 NN 直接 MRAC 和 NN 间接 MRAC. NN 直接模型参




图 3 NN 间接自校正控制

考自适应控制(见图4)力图维持受控对象输出与参考模型输出间的差 $e_c(t) = y(t) - y^m(t) \rightarrow \infty$. 由于反向传播需要知道受控对象的数学模型,因而该NN控制器的学习与修正已遇到许多问题.NN间接模型参考自适应控制(见图5)中,NN识别器(NN1)首先离线辨识受控对象的前馈模型,然后由 $e_c(t)$ 进行在线学习与修正.显然,NN1能提供误差 $e_c(t)$ 或者其变化率的反向传播.




图4 NN直接模型参考自适应控制




图5 NN间接模型参考自适应控制

2.4 NN内模控制^[15~18]

在常规内模控制(IMC)中,受控系统的正和逆模型被用作反馈回路内的单元.IMC经全面检验表明其可用于鲁棒性和稳定性分析,而且是一种新的和重要的非线性系统控制方法.

基于NN的内模控制的结构图示于图6,其中,系统模型(NN2)与实际系统并行设置.反馈信号由系统输出与模型输出间的差得到,而且然后由NN1(在正向控制通道上一个具有逆模型的NN控制器)进行处理:NN1控制器应当与系统的逆有关.图6中,NN2也是基于神经网络的但具有系统的正向模型.该图中的滤波器通常为一线性滤波器,而且可被设计满足必要的鲁棒性和闭环系统跟踪响应.




图6 NN内模控制




图7 NN预测控制

2.5 NN预测控制^[19,20]

预测控制是一种基于模型的控制,具有预测模型、滚动优化和反馈校正等特点.已经证明本控制方法对于非线性系统能够产生有希望的稳定性.

图7表示NN预测控制的一种结构方案:图中,神经网络预测器NNP为一神经网络模型,NLO为一非线性优化器.NNP预测受控对象在一定范围内的未来响应.

值得说明的是,NLO实际上为一最优算法,因此,可用动态反馈网络来代替由本算法实现的NLO和由前馈神经网络构成的NNP.

2.6 NN自适应强化控制^[8,12,21,22]

无论采用何种神经网络控制结构,所有控制方法都有一个共同点,即必须提供受控对象的期望输入.但是,当系统模型未知或部分未知时,就很难提供这种期望输入.

NN自适应判断控制或强化控制应用强化学习的机理,通常由两个网络组成,即自适应判断网络AJN和控制选择网络CSN,如图8所示.

本控制系统中,AJN相当于强化学习需要的“教师”,它起到两种作用:

1) 通过不断的奖罚强化学习,使 AJN 逐渐训练为一个熟练的教师;

2) 经过学习后,根据受控系统的当前状态和外部强反馈信号 $r(t)$, AJN 产生一强化信号,然后提供内部强化信号 $\hat{r}(t)$,以便能够判断当前控制作用的效果. CSN 相当于多层前馈神经网络控制器,它在内部强化信号的引导下进行学习.通过学习,CSN 根据系统编码后的状态,选择下一个控制作用.




图 8 NN 自适应判断控制

2.7 基于 CMAC 的控制^[4,11,14,23~28]

CMAC 是由 Albus 开发的,是近年来获得应用的几种主要神经控制器之一.把 CMAC 用于控制有两种方案.第一种方案的结构如图 9 所示.在该控制系统中,指令信号和反馈信号均用作 CMAC 控制器的输入.控制器输出直接送至受控装置(对象).必须提供神经网络控制器的期望输出.控制器的训练是以期望输出和控制器实际输出间的差别为基础的.系统工作分两阶段进行.第一阶段为训练控制器.当 CMAC 接收到指令和反馈信号时,它产生一个输出,此输出与期望输出 $\bar{u}$ 进行比较;如果两者存在差别,那么调整权值以消除该差别.经过这阶段的竞争,CMAC 已经学会如何根据给定指令和所测反馈信号产生合适的输出,用于控制受控对象.第二阶段为控制.当需要的控制接近所训练的控制要求时,CMAC 就能够很好地工作.这两个阶段工作的完成都无需分析装置的动力学和求解复杂的方程式.不过,在训练阶段,本方案要求期望的装置输入是已知的.




图 9 基于 CMAC 的控制(I)

第二种控制方案图示于图 10.在本方案中,参考输出方块在每个控制周期产生一个期望输出.该期望输出被送至 CMAC 模块,提供一个信号作为对固定增益常规偏差反馈控制器控制信号的补充.在每个控制周期之末,执行一步训练.在前一个控制周期观测到的装置输出用作 CMAC 模块的输入.用计算的装置输入 u^* 与实际输入 u 之间的差来计算权值判断.当 CMAC 跟随连续控制周期不断训练时,CMAC 函数在特定的输入空间域内形成一个近似的装置逆传递函数.如果未来的期望输出在域内相似于前面预测的输出,那么,CMAC 的输出也会与所需的装置实际输入相似.由于上述结果,输出误差将很小,而且 CMAC 将接替固定增益常规控制器.




图 10 基于 CMAC 的控制(II)

2.8 多层 NN 控制^[4,29,30]

多层神经网络控制器基本上是一种前馈控制器.

图 11 表示一个普通的多层神经控制系统.该系统存在两个控制作用:前馈控制和常规反馈控制.前馈控制由神经网络实现;前馈部分的训练目标在于使期望输出与实际装置输出间的

偏差为最小. 该误差作为反馈控制器的输入. 反馈作用与前馈作用被分别考虑, 特别关注前馈控制器的训练而不考虑反馈控制的存在. 已提出多层 NN 控制器的三种结构: 间接结构、通用结构和专用结构.

2.8.1 间接学习结构

图 12 所示的间接多层 NN 控制结构含有两个同样的神经网络, 用于训练. 在本结构中, 每个网络作为一个逆动态辨识器. 训练的目标是要从期望响应 d 中找到一个合适的装置控制 u . 以网络 I 和网络 II 间的差为基础来调整权值, 使得误差 e 为最小; 如果能够训练网络 I 使得 $y = d$, 那么, $u = u^*$. 不过, 这并不能保证期望输出 d 与实际输出 y 之间的差别为最小.




图 11 多层 NN 控制的一般结构




图 12 间接学习结构的多层 NN 控制

2.8.2 通用学习结构

图 13 绘出多层 NN 控制的通用学习结构, 它使图 12 中的 $e = d - g$ 为最小. 该网络被训练使得装置输入 u 与网络输出 u^* 间的差别为最小. 在训练时, u 所处的范围应使得 y 复盖期望输出 d . 训练之后, 如果某一期望输出 d 被送至网络, 那么该网络就能够为受控装置提供一个合适的 u . 本结构的局限性是: 一般无法知道哪一个 u 对应于期望输出 d , 因而网络不得不在 u 的大范围内进行训练以求经过学习能够使装置输出 y 包括期望值 d .




图 13 通用学习结构

2.8.3 专用学习结构

多层 NN 控制的专用学习结构如图 14 所示. 当神经网络训练时, 期望输出 d 是该网络的输入. 采用误差反向传播方法, 经过训练使期望输出 d 与装置的实际输出 y 之间的差别 e 为最小. 因此, 不仅能够期望得到良好的装置输出, 而且训练能够在期望输出范围内执行, 而不需要知道装置的合适输入范围. 不过, 本结构中把装置当作网络的一层来处理. 为了训练该网络, 或者必须知道装置的动力学模型, 或者必须进行某种近似处理. 对多层神经网络控制器的训练是由误差反向传播训练算法来完成的. 该误差可为期望输出与实际装置输出间的差, 也可校正装置输入与由神经网络计算得到的输入之间的差.




图 14 专用学习结构

2.9 分级 NN 控制^[31~34]

基于神经网络的分级控制模




图 15 分级神经网络控制器

型如图 15 所示. 图中, d 为受控装置的期望输出, u 为装置的控制输入, y 为装置的实际输出, u^* 和 y^* 为由神经网络给出的装置计算输入与输出. 该系统由三部分组成. 第一部分为一常规外反馈回路. 反馈控制是以期望装置输出 d 与由传感器测量的实际装置输出 y 间的误差 e 为基础的, 即以 $e = (d - y)$ 为基础的. 通常, 常规外反馈控制器为一比例微分控制器. 第二部分是神经网络 I 连接的通道, 该网络为一受控对象的动力学内模型, 用于监控装置的输入 u 和输出 y , 且学习受控对象的动力学特性. 当接收到装置的输入 u 时, 经过训练, 神经网络 I 能够提供一个近似的装置输出 y^* . 第三部分是神经网络 II, 它监控期望输出 d 和装置输入 u . 这个神经网络学习建立装置的内动力学模型; 当它收到期望输出指令 d 时, 经过训练, 它能够产生一个合适的装置输入分量 u^* . 该受控对象的分级神经网络模型按下列过程运作. 传感反馈主要在学习阶段起作用, 此回路提供一个常规反馈信号去控制装置. 由于传感延时作用和较小的可允许控制增益, 因而系统的响应较慢, 限制了学习阶段的速度. 在学习阶段, 神经网络 I 学习系统动力学特性, 而神经网络 II 学习逆动力学特性. 随着学习的进行, 内反馈逐渐接替外反馈的作用, 成为主控制器. 然后, 当学习进一步进行时, 该逆动力学部分将取代内反馈控制. 最后结果是, 该装置主要由前馈控制器进行控制, 因为装置的输出误差与内反馈一起几乎不复存在, 从而提供处理随机扰动的快速控制. 在上述过程中, 控制与学习同步执行. 两个神经网络起到辨识器的作用, 其中一个用于辨识装置动力学特性, 另一个用于辨识逆动力学特性.

可把分级神经网络模型控制系统分为两个系统, 即基于正向动力学辨识器的系统和基于逆向动力学辨识器的系统, 可以单独应用它们.

3 结 论

本文综述的各类神经控制器的结构方案, 除了具有共性外, 还存在各自特点, 适于不同的应用领域; 其中, 大部分方案已被用于实际控制系统或装置, 取得满意的控制效果. 我们可以根据控制和应用要求, 选择适合于具体应用的某种神经控制结构.

除本文已介绍外, 神经控制还可与其它控制原理结合, 构成新的控制集成, 如 PID 神经混合控制^[35]、基于神经网络的自组织控制^[36,37]、基于神经网络的最优控制以及基于神经网络的专家控制等. 近年来, 一种研究趋势是开发和实现模糊逻辑与神经网络的集成, 构成各种模糊神经控制方案, 用于建模、控制与辨别^[6,13,14,27,38~46].

神经网络控制与其它控制原理的集成, 克服了单一控制方法的局限性, 实现优势互补, 发出控制性能更加优良的控制器, 扩大了自动控制的应用领域, 也促进智能控制的发展.

参 考 文 献

- 1 McCulloch, W. S. and Pitts, W. H. . A logical calculus of the ideas immanent in nervous activity. Bull. Math. Biophysics, 1943, 5(1): 115-123
- 2 Leivn, A. U. and Narendra, K. S. . Recursive identification using feed-forward neural networks. Int. J. Control, 1995, 61(3): 533-547
- 3 Lightbody, G. and Irwin, G. W. . Direct neural model reference adaptive control. IEE Proc. Control Theory Applications, 1995, 142(1): 31-43
- 4 Miller III, W. T. , Henes, R. P. , Glanz, F. H. and Kraft III, L. G. . Real time dynamic control of an industrial manipulator using a neural network based learning controller. IEEE Trans. Robotics and Automation, 1990, 6(1): 1-9
- 5 Narendra, K. S. and Parthasarathy, K. . Identification and control of dynamical system using neural networks. IEEE Trans. Neural Networks, 1990, 1(1): 4-27

- 6 Hunt, K., Sbarbaro, J. D., Zbikowski, R. and Gawthrop, P. J. . Neural networks for control systems — a survey. *Automatica*, 1992, 28(6): 1083—1112
- 7 Pham, D. T. and Liu, X. . *Neural Networks for Identification, Prediction and Control*. London: Springer-Verlag, 1995
- 8 Anderson, C. W. . Learning to control an inverted pendulum using neural networks. *IEEE Control System Magazine*, 1989, 9(1): 31—37
- 9 Grant, E. and Zhang, B. . A neural net approach to supervisory cerebellar used learning of pole balancing. *Proc. IEEE Int. Symp. on Intelligent Control*, 1989, 123—129
- 10 Wang, J. and Cai, Z. X. . Direct fuzzy neural control for train traveling process. *Trans. of Chinese Non-Ferrous Metals*, 1997, 7(1): 146—151
- 11 An, P. E. , Brown, M. , Harris, C. J. , Lawrence, A. J. and Moore, C. J. . Associative memory neural networks: adaptive modeling theory, software implementations and graphical user. *Engng. Appli. Artif. Intell.* , 1994, 7(1): 1—21
- 12 Barto, A. G. , Sutton, R. S. and Anderson, C. W. . Neuron-like adaptive elements that can solve difficult learning control problems. *IEEE Trans. Syst. Man, and Cybern.* , 1983, 13(5): 834—846
- 13 Wang, F. Y. . Design of adaptive fuzzy control systems using neural networks. *Proc. Chinese World Congress on Intelligent Control and Intelligent Automation*, Beijing: Science Press, 1993, 516—522
- 14 Wang, F. Y. and Kim, H. M. . Implementing adaptive fuzzy logic controllers with neural networks: A design paradigm. *J. of Intelligent and Fuzzy Systems*, 1995, 1(1): 110—128
- 15 Morari, M. and Zafiroiu, E. . *Robust Process Control*. Englewood, NJ: Prentice-Hall, 1989
- 16 Chen, J. , Wang, S. Q. , Wang, N. and Wang, J. C. . Application of neuron intelligent control in synchronization of hydraulic turbine generators. *Proc. IEEE Int. Conf. NNSP*, Nanjing, China, 1995, 546—549
- 17 Economou, C. G. , Morari, M. and Palsson, B. O. . Internal model control, 5. Extension to nonlinear systems. *Ind. Eng. Chem. Process Des.*, 1986, 25(3): 403—411
- 18 Hunt, K. J. and Sbarbaro, D. . Neural networks for nonlinear internal model control. *Proc. IEE Pt. D*, 1991, 138: 431—438
- 19 Keerthi, S. S. and Gilbert, E. G. . Moving-horizon approximations for a general class of optimal nonlinear infinite-horizon discrete-time systems. *Proc. 20th Annual Conference on Information Science and Systems*, 1986, 301—306
- 20 Mayne, D. Q. and Michalska, H. . Receding horizon control of nonlinear systems. *IEEE Trans. Automat. Contr.* , 1990, AC-35(7): 814—824
- 21 Lee, C. C. and Berenji, H. R. . An intelligent controller based on approximate reasoning and reinforcement learning. *Proc. IEEE Int. System and Intelligent Control*, 1989, 200—205
- 22 Waltz, M. D. and Fu, K. S. . A heuristic approach to reinforcement learning control system. *IEEE Trans. Automat. Contr.* , 1965, AC-10(4): 612—616
- 23 Albus, J. S. . A new approach to manipulator control: model articulation control (CMAC). *Trans. ASME, J. of Dynamics Syst., Meas. and Contr.* , 1975, 97(2): 220—227
- 24 Albus, J. S. . Data storage in the cerebellar model articulation controller (CMAC). *Trans. ASME, J. of Dynamics Syst., Meas. and Contr.* , 1975, 97(2): 228—233
- 25 Kraft, L. G. and Campagna, D. P. . A comparison between CMAC neural network control and two traditional adaptive control systems. *IEEE Control System Magazine*, 1990, 10(1): 36—43
- 26 Miller, W. T. . Real time application of neural networks for sensor based control of robots with vision. *IEEE Trans. Syst. Man, and Cybern.* , 1989, 19(4): 825—831
- 27 Wang, F. Y. and Chen, D. D. . Rule generation and modification for intelligent controls using fuzzy logic and neural networks. *Intelligent Automation and Soft Computing*, 1993
- 28 Luo, Z. , Zhao, Z. M. and Zhu, C. G. . The unfavourable effects of hash coding on CMAC convergence and compensatory measure. *Proc. IEEE Int. Conf. Intelligent Processing Systems*, Beijing, 1997, 419—422
- 29 Psaltis, D. , Sideris, A. and Yamamura, A. A. . Neural controller. *Proc. IEEE Int. Conf. Neural Networks*. San Diego, CA, 1987, 551—558
- 30 Psaltis, D. , Sideris, A. and Yamamura, A. A. . A multi-layered neural network controller. *IEEE Control Systems Magazine*

- zine, 1988, 8(1): 17—20
- 31 Ichihashi, H. . Learning in hierarchical fuzzy models by conjugate gradient method using BP errors. Proc. Symp. Intelligent Systems, 1991, 235—240
 - 32 Kawato, M. , Furukawa, K. and Suzuki, R. . A hierarchical neural network model for control and learning of voluntary movement. Biol, Cybern. , 1987, 57(2): 169—185
 - 33 Kawato, M. , Uno, Y. , Isobe, M. and Suzuki, R. . Hierarchical neural network model for voluntary movements with application to robotics. IEEE Contr. Mag. , 1988, 8—15
 - 34 Xie, S. M. and Xu, Z. L. . Application of NN to hierarchical optimal control of continuous time-varying large-scale systems. Proc. IEEE Int. Conf. Intelligent Processing Systems, Beijing, 1997, 477—481
 - 35 王耀南, 童调生, 蔡自兴. 基于神经网络的 PID 智能控制与应用. 信息与控制, 1994, 23(3): 185—189
 - 36 Nie, J. and Linkens, D. A. . A hybrid NN-based self-organizing controller. Int. J. of Control, 1994, 60(2): 197—222
 - 37 蔡自兴, 王晶. 具有模糊联想神经网络的自组织模糊控制器. 中南工业大学学报, 1995, 26(6): 793—796
 - 38 Lin, C. T. and Lee, C. S. G. . Neural network based fuzzy logic control and decision system. IEEE Trans. Computer, 1991, 40(3): 1320—1336
 - 39 Halgamug, S. K. and Glesner, M. . Neural networks in designing fuzzy systems for real world applications. Fuzzy Sets and Systems, 1994, 65(1): 1—12
 - 40 Roger Jang, J. S. . ANFIS: Adaptive-network-based fuzzy inference system. IEEE Trans. Syst. Man, and Cybern. , 1993, 23(3): 665—685
 - 41 Kosko, B. . Fuzzy associative memory systems. Fuzzy Expert Systems, A. Kandel, ed. Reading, MA: Addison-Wesley, 1986
 - 42 Kosko, B. . Neural Networks and Fuzzy Systems. Englewood Cliffs, NJ: Prentice-Hall, 1992
 - 43 Widrow, B. , Rumelbart, D. E. and Lehr, M. A. . Neural networks: applications in industry, business and science. Communication of the ACM, 1994, 37(1): 93—105
 - 44 王晶, 贾利民, 蔡自兴. 神经网络在高速列车运行智能控制中的应用研究. 中国铁道科学, 1995, 16(4): 111—116
 - 45 蔡自兴. 模糊控制的典型结构. 工业控制计算机, 1997, (3): 1—4
 - 46 蔡自兴. 学习控制的结构方案. 信息与控制, 1998, 27(1): 36—41

Typical Structures of Neural Control

CAI Zixing

(Center for Intelligent Control, Central South University of Technology • Changsha, 410073, PRC)

Abstract: In this paper some typical structural schemes of neurocontrol have been briefly studied. The schemes include NN-based learning control, NN-based direct inverse control, NN-based adaptive control, CMAC-based control, NN-based internal model control, NN-based predictive control, multilayered NN-based control, and hierarchical NN-based control, etc. This survey focuses on the control mechanism and provides a basis for potential applications. Most of the structural schemes have been used in various control fields.

Key words: neural network (NN); neurocontrol; structure; nonlinear systems

本文作者简介

蔡自兴 1938 年生. 1962 年西安交通大学工业电气化与自动化专业本科毕业. 现为中南工业大学智能控制研究所所长, 教授, 博士生导师, 联合国专家. 目前研究方向为智能控制, 人工智能, 智能机器人和工业自动化等.