

文章编号: 1002-0411(2001)02-097-07

典型人工神经网络的结构、功能及其在智能系统中的应用

从 爽

(中国科学技术大学自动化系 合肥 230027)

摘 要: 人工神经网络已在各个领域得到广泛的应用, 尤其是在智能系统中的非线性建模及其控制器的设计、模式分类与模式识别、联想记忆和优化计算等方面更是得到人们的极大关注. 本文从网络在智能系统中建模及控制器设计的具体训练结构入手, 详细介绍了 BP 网络在系统控制中的典型应用方式, 并根据不同网络所具有的功能, 从性能对比的角度对人工神经网络在上述各方面的应用给予综述.*

关键词: 人工神经网络; 非线性系统建模与控制; 模式分类; 模式识别; 优化计算; 联想记忆

中图分类号: TP13

文献标识码: A

A SURVEY OF STRUCTURES, FUNCTIONS OF ARTIFICIAL NEURAL NETWORKS AND THEIR APPLICATIONS IN INTELLIGENT SYSTEMS

CONG Shuang

(Dept. of Automation, University of Science and Technology of China, Hefei 230027)

Abstract: The artificial neural networks have been widely used in very kinds of areas, especially they are paid great attention to the applications in intelligent system of nonlinear modeling, design of controller, pattern classification and recognition, association memory and optimal calculation. A survey of neural networks from identifications and controller design to the different system structures in system control are given, including feature comparisons between their functions.

Keywords: artificial neural networks, nonlinear system modeling and control, pattern classification and recognition, optimal calculation, association memory

1 引言(Introduction)

人工神经网络已在各个领域得到广泛的应用, 尤其是在智能系统中的非线性建模及其控制器的设计、模式分类与模式识别、联想记忆和优化计算等方面更是得到人们的极大关注. 从控制理论的观点来看, 神经网络对非线性函数的逼近能力是最有意义的, 因为非线性系统的变化多端是采用常规方法无法建模和控制的基本原因, 而神经网络描述非线性图形的能力, 也就是对非线性系统的建模能力, 正适合于解决非线性系统建模与控制器综合中的这些问题. 具有这一特性的前向反向传播网络(简称 BP 网络)在实际应用中的比例要占所有人工神经网络应用的 80% 以上. 所以下面我们从 BP 网络入手, 介绍

BP 网络在控制系统中的非线性建模、控制器设计以及多种常用的系统控制方案. 接下来还将介绍其他典型网络在模式分类与识别、联想记忆与优化计算等方面的应用, 最后给出总结.

2 BP 网络在智能系统中的建模与控制 (The modeling and control of BP network in the intelligent systems)

BP 网络是一个至少包含一个隐含层, 并且网络中至少具有一个非线性激活函数的多层前向网络. 因为必须采用输出误差的反向传播来训练这种非线性多层网络的权值, 所以人们一般把这种非线性多层前向网络统称为 BP 网络(BP 是英文“反向传播”

* 收稿日期: 2000-04-14
基金项目: 中科院盈科优秀青年学者奖资助项目

的缩写). 虽然人工神经网络的种类已多达上百种, 但应用最多的还是 BP 网络. 不过 BP 网络所具有的基本功能只有一个, 那就是非线性连续有理函数的逼近功能. 对控制系统中的非线性过程的建模以及对系统的控制器的设计也是利用 BP 网络这一基本的功能.

2.1 直接正向模型建立

假定(被控)系统离散型非线性差分方程为:

$$y_p(k+1) = f(y_p(k), \dots, y_p(k-n+1), u(k), \dots, u(k-m+1)) \quad (1)$$

即由非线性函数 f 所确定的系统, 在 $k+1$ 时刻的输出取决于过去 n 个时刻的输出值, 以及过去 m 个时刻的输入值.

这里我们关心的是系统响应的动态部分, 模型对系统的干扰的表达式是隐含在其中的. 那么对系统建模的一个直接的方法是通过选择与系统相同的输入/输出数据作为训练用样本, 对神经网络进行训练, 其目的是为了使得网络的输入/输出能够与系统的输入/输出完全一致. 若取网络的输出变量为, 那么训练网络时的网络结构图应如图 1 所示.




图 1 网络建模训练时结构图

Fig. 1 The structure of network used in the training model

根据图 1 所示的网络建模训练图可以写出网络输入与输出之间的关系式为:

$$y_m(k+1) = \hat{f}(y_p(k), \dots, y_p(k-n+1), u(k), \dots, u(k-m+1)) \quad (2)$$

此处, \hat{f} 代表网络的非线性输入/输出映照关系(即为函数 f 的逼近). 注意训练中的网络输入包括真实系统过去时刻的输出值(作为样本输入的一部

分), 不过此时网络没有反馈.

假定网络在经过适当的训练过程后, 得到了满意的函数拟合(即获得 $y_m \approx y_p$), 那么网络的训练则完成, 并在网络以后的工作中, 可以将网络自身的输出反馈回来作为网络输入的一部分, 以这种方法使网络能够独立的使用, 如图 2 所示.




图 2 网络模型使用时结构图

Fig. 2 The structure of network in the work of model

由图 2 可以得到网络模型的输入/输出关系式为:

$$y_m(k+1) = \hat{f}(y_m(k), \dots, y_m(k-n+1), u(k), \dots, u(k-m+1)) \quad (3)$$

由于系统建模的需要, 网络在结构上将其输出经过延时, 作为网络输入的一部分, 所以, 控制系统中用于建模的网络可以被称为“带有反馈变量的前向网络”, 它与霍普菲尔德型的反馈网络仍然是两种截然不同的网络.

2.2 逆模型建立

采用非线性系统的逆模型与系统本身相串联而消除其非线性影响的思想, 促使人们感兴趣对逆模型的建立. 人们最容易想到的利用神经网络建立逆模型的方法则是将(被控)系统的输入和输出数据分别作为网络的输出和输入来训练网络获得. 即所谓的直接逆模型建立, 其网络的训练用结构图如图 3 所示. 从图中可以看出, 与直接建模一样, 网络的输入利用了系统输入/输出的综合信息, 网络训练采用系统输入信号与网络输出信号的误差来修正网络权值. 从这个训练网络的结构上还可以看出, 训练网络的目的是迫使网络作为系统的逆模型. 但是, 这种方法存在着缺陷, 首先, 网络权值的修正过程不是采用期望的样本进行学习训练的. 训练逆模型所用的输入信号起码应当遍及控制器可能输入的所有范围. 但实际训练时所采用的样本不可能被事先定义. 另外, 控制系统的实际目标是希望通过控制器的行为

产生期望的系统输出, 而训练逆模型时所产生的系统输出也并不是期望的系统输出. 所以, 在直接逆建模中所采用的训练样本并不与所需要的训练样本相对应, 因而必然有可能存在未被训练到的控制域. 其次, 如果该非线性系统的映照关系不是一一对应, 那么, 可能产生一个不正确的逆模型. 实际应用中常被采用的建立逆模型的方法是能够克服上述缺点的第二种方法, 可以被称为间接逆模型训练法. 在此训练方法中, 网络逆模型被置于(被控)系统的前端, 并且将网络的输出作为系统的输入, 如图 4 所示.




图 3 直接逆模型训练图

Fig. 3 The training structure of direct inverse model




图 4 间接逆模型训练图

Fig. 4 The training structure of indirect inverse model

在实际训练中, 也可用一个已训练过的系统模型(如前述的建模网络)替代实际被控系统进行逆模型的训练(如图 4 中虚线所示). 采用间接法的特点是: 训练过程是直接指向目标的. 因为它是基于期望的系统输出与实际输出之间的误差来调整训练控制器权值的, 换句话说, 在训练过程中, 网络所接受的样本输入对应于它最终工作时接受的实际输入值. 另外, 在系统的逆关系不是一一对应的情况下, 用此法也能对期望的特性找到一个对应的逆.

2.3 系统中的控制

2.3.1 监督式控制

在许多难以用常规控制技术设计自动控制器, 而采用手动对特殊任务进行反馈控制的地方, 或需要用自动控制器来模仿人的行为的地方, 都可以用一个神经网络来实现, 网络的训练过程类似于上述的正向模型的训练(见图 5), 但是, 此时的网络结构可以根据需要不再有延时的反馈输出量, 只要对应于比如人所感觉的信息, 而用于训练网络的目标输出则对应于人对系统的控制量. 另外, 对于只要能够写出足够范围内一定的对感应到的系统输出误差给出相应控制值的地方, 都可以采用这种监督式训练的网络进行非线性自动控制.



图 5 监督式网络控制训练图

Fig. 5 The training structure of supervise network used as a controller

2.3.2 直接逆控制

直接逆控制器采用的就是一个逆系统模型, 将逆模型网络做为控制器使用, 简单地与被控系统相级联, 以使复合系统的输出与期望的响应(即网络输入)相一致. 很明显, 这种控制策略的控制精度极大地依赖于作为控制器的逆模型的精度及其自适应能力. 一般情况下可能会产生鲁棒问题. 低鲁棒性的主要原因是由于系统为开环控制, 没有形成闭环回路, 解决这一问题可以通过以下两种方案.

第一种方案是在系统进行控制的同时, 并行地对控制器的参数进行在线地修正, 如图 6 所示的整个控制系统结构图, 其中 C2 表示控制中使用的逆模型控制器, C1 表示在线调整的与 C2 结构完全相同的逆模型控制器, 并定期将产生修正的新权值送入到 C2 中.

第二种方案是对整个系统加入负反馈回路(见图 7). 由于逆模型 C2 的使用, 使得前向回路中的非线性得以抵消, 所以很容易采用某种简单的常规控制器 C1 的设计方法, 设计一个负反馈回路来满足期望的系统性的要求.




图6 在线调整权值的逆控制系统

Fig. 6 The inverse control system with on-line turning weights




图7 带有负反馈回路的控制系统

Fig. 7 The feedback control system

2.3.3 模型参考控制

自适应控制中的模型参考控制同样可以用于神经网络的控制系统中,此时闭环系统的期望特性由一个适当的参考模型来确定.这个参考模型也可以用一组期望的输入/输出数据对来定义,仔细观察一下可以发现,前面所用过的间接逆模型控制器的训练过程,实际上用了模型参考的概念,不过真正意义上的模型参考控制器的训练是在闭环回路下进行的见图8.




图8 网络模型参考控制系统

Fig. 8 Network model reference control system

系统控制的目的是使系统输出与参考模型的输出渐近一致.即

$$\lim_{k \rightarrow \infty} \| y_r(k) - y_p(k) \| \leq \epsilon \quad (4)$$

对某一个确定的常数 $\epsilon \geq 0$ 成立.

类似于逆建模的情况,在训练控制器时,被控系统可以用训练好的神经网络模型来替代.对于控制工程中的模型参考控制,所求的自适应控制律往往会含有较复杂的,甚至难以实现的控制项.通过训练,采用模型参考神经网络控制,可以克服以上的困难.

2.3.4 内模控制

神经网络的正向模型与逆模型在内模控制中得到了充分的应用,内模控制系统的结构图如图9所示,图中将一个网络正模型与实际系统相并联,并将两者的输出误差作为对输入信号的干扰反馈到网络控制器的输入端.




图9 内模控制系统图

Fig. 9 The structure of internal model control system

已经证明,对于开环稳定的系统,利用内模控制可以消除干扰和扰动,得到很好的跟踪控制.内模控制已在过程控制中得到广泛的应用.

3 神经网络在模式分类与识别中的应用 (The applications of neural network in pattern classification and recognition)

有许多典型网络都具有进行模式分类或识别的功能,并且效果相当好.本节给出网络的几种典型的应用.

3.1 感知器的模式线性分类

感知器是一个单层的、具有符号函数(或阶跃函数)为激活函数的神经网络,它的网络结构图如图10所示.




图10 感知器网络结构图

Fig. 10 The structure of perceptron

单层感知器是最早的人工神经网络,它以输出为1或0(-1),通过对网络权值的训练,实现对输入模式进行1或0(-1)的分类目的,感知器的权值训练是监督式的,它可以被设计成很好的线性分类器.应用过程分为两个步骤:1)选择样本模式训练网络;2)网络作为分类器进行工作.在训练网络时,设计者首先从大量的数据中选出能够代表所有类型的典型数据作为样本,并根据所需要分类的样本类型数确定网络的输入/输出节点数:网络输入节点数由样本本身维数确定;网络输出节点由需要分成的样

本种类决定, 网络可分样本总数等于 2^s , 其中 s 为输出神经元.

网络训练好后, 即可以进行工作. 对于向网络输入的任意模式, 网络都可以根据网络的输出而将输入模式自动地分到训练时所用样本的某一类型中.

感知器工作的实质实际上是用直线、平面或超平面在平面、立体空间或超空间中进行线性切割而得到不同的区域进行线性分类的. 所以利用单层感知器得不到线性不可分的样本分类器. 感知器的这个缺陷可以通过增加一层网络的两层感知器来克服. 需要提醒的是, 因为感知器的学习规则只适用于单层, 所以对两层感知器进行权值训练时, 每一次训练都需要对每一层网络权值分别进行修正, 第一层网络的目标函数需由设计者从确认为线性可分的任意目标函数中选取.

感知器作为线性分类器具有设计简单, 工作效率高等突出优点.

3.2 自组织竞争网络

当大量具有典型特性的模式需要进行分类时, 除了可以用感知器进行分类外, 还可以采用自组织竞争网络, 利用竞争网络进行模式分类的另一个特点是, 它不但可以将每个模式分成各自所属于的类型, 而且还可以同时获得每一种类型的典型模式(一般为该类型模式的平均值). 从网络结构上讲, 竞争网络是一种单层神经网络, 与普通单层网络不同的是, 除了输入节点与输出节点之间为全互连接外, 竞争网络在输出层每个输出节点之间还具有相互的连接(如图 11 所示), 并且网络在学习中的竞争特性也是表现在输出层上, 所以在竞争网络中, 人们把输出层又称为竞争层, 而输入节点及与其相连的权值合称为输入层. 实际上, 在竞争层中, 输入层与竞争层的加权输入和共用同一个激活函数, 其激活函数的类型为阶跃型 $\{0, 1\}$ 函数. 网络的每次输入只有唯一的一个输出节点在经过竞争获胜后能够输出为 1, 而所有其他输出均为 0.

竞争网络在经过竞争而求得唯一输出为 1 的获胜节点后, 则对与获胜节点相连的权值进行调整, 调整权值的目的是为了使权植与其输入模式之间的差别越来越小, 从而使修正后的竞争网络权值能够代表对应输入模式的特征, 把相似的输入模式分成了同一类, 并由每次输出为 1 的节点指示出所代表的

类别.




图 11 竞争网络结构图

Fig. 11 The structure of competition network

竞争网络的设计是通过无监督式的学习过程来完成的, 并且训练过程同时也是网络的工作过程, 或者换句话说, 网络在进行分类的过程中不断地调整网络的权值, 以实时给出最新典型模式的结果. 在设计竞争网络时, 网络的输入节点数是由模式的维数确定的. 而网络的输出节点个数 s 代表可能分类的种类数. 每一个输入模式只能使得网络输出端的一个输出节点为 1, 该输出为 1 的节点表示正在输入模式属于该输出节点所代表的类型. 而输出节点数 s 的确定由设计者根据对样本的分析给出一个稍微大一点的估值, 或根据网络工作后的情况进行调整来确定. 在竞争网络中的偏差 B 表征模式聚类的相似度, 是一个 $0 \sim 1$ 之间的固定值, 一般取 $0.8 \sim 0.99$, 由设计者根据需要选定.

3.3 科荷伦(Kohonen)自组织映射网络

当遇到具有概率分布的大量模式分类时, 感知器与竞争网络都将无能为力. 此时则可能采用科荷伦网络, 这种网络的激活函数也是二值型, 网络结构与竞争方式和一般竞争网络相同, 不同的是在网络权值的修正上. 竞争网络只对与获胜节点相连的一组网络权值进行修正, 而科荷伦网络除了对与获胜节点相连的网络权值进行修正, 而且还对与获胜节点相邻节点相连的权值进行调整. 相邻节点又分为一维和二维的, 对于二维的科荷伦自组织映射网络又称为特性图.

科荷伦网络可以作为一种样本特性检测器, 在样本排序、样本分类以及样本检测方面有广泛的应用. 在无监督式学习规则下, 网络通过重复几十次的样本输入并不断修正网络权值, 最终使网络的权值

收敛到所代表的输入模式的平均值,它反映了输入数据(模式)的统计特性以及统计密度的大小.

图 12a 表示为落在单位圆四分之一周期圆周上随机的 100 个点在经过用 20 个神经元的科荷伦网络将其表示出的数据初始图以及用网络表示的最后




图 12a 左图: 输入模式矢量图
右图: 训练 400 次后的权值矢量图

Fig. 12a Left: Input pattern vector

Fig. 12a Right: Weight vector after 400 times training

由以上两个例子可以看出: 1) 科荷伦自组织映射网络除可以进行分类外, 还具有数据压缩功能; 2) 包括竞争网络在内, 这些网络的工作输入模式都必须经过归一化处理, 即将输入模式转化为单位矢量来处理; 3) 这些网络的各自特点是: 普通竞争网络能够训练识别出输入模式在的“点”特征; 科荷伦网络能够表现了输出模式在“线”上或“平面”上的分布特性.

3.4 自适应共振理论

自适应共振理论(简称 ART)是一种具有避免对网络已分类模式的修改, 能够自动添加适应新输入模式的一种模式分类器. 它的分类作用与竞争网络基本相同, 但其记忆容量可以随着样本模式的增加而自动增加, 两者表现的不同点在于: 竞争网络中代表分类模式种类的输出节点数是由设计事先确定好的, 而 ART 则是由网络本身根据输入模式的实际情况自动增加的, 具有自适应、自调节分类能力, 这里不详述其工作细节.

4 用于联想记忆和优化计算的反馈网络 (The recurrent network used in the associative memory and optimal calculation)

反馈网络是不同于前向网络的另一大类网络, 它的网络结构特点之一是单层的, 之二是输入节点数与输出节点数相同, 并且每一个输出节点都反馈连接到其输入节点, 即每个神经元的输入和输出节

结果图. 图中各种神经元之间的距离长短表示其密度的大小, 距离越短密度越高. 图 12b 为用 5×5 的网络输出节点面积表示 2000 个随机输入的样本图以及网络训练后的特性图.




图 12b 左图: 输入模式特性图
右图: 训练 4 000 次后的特性图

Fig. 12b Left: Input pattern vector

Fig. 12a Right: Weight vector after 4000 times training

点为一同个点, 从而形成一个反馈的网络, 使得输入矢量通过网络输出再反馈到输入时, 与原有的输入相比, 或有了新的变化, 或保持不变, 而达到所谓的平衡状态, 因而表现出由网络所代表的非线性动力学系统的动态特性(见图 13).




图 13 反馈网络结构图

Fig. 13 The structure of recurrent network

反馈网络根据其激活函数是符号型(或阶跃型), 还是连续型, 可分为离散型和连续型, 离散型反馈网络主要用于联想记忆, 而连续型反馈网络主要用于优化计算.

4.1 联想记忆

用于联想记忆的反馈网络设计过程是, 首先由设计者将正确的或者目标模式, 转化成网络的某些平衡点, 并设计网络权值使网络记住这些目标模式, 然后让网络进行工作. 此时网络已具备了这样的能力: 对于任一给定的输入模式, 通过网络本身的不断循环与联想, 最终能够将其收敛到网络已记住的某

一个平衡点上, 找到输入模式的归属. 这有什么用处呢? 它可以从带有干扰或错误的输入信号中识别出正确的信号, 或具有纠错能力. 正是因为如此, 离散型反馈网络常可用于图像处理、语声处理、信号处理、容错计算、模式分类与识别. 一个典型的应用例子是识别数字或字母之类的文字. 首先将标准模式转化成网络平衡点让其记住, 或选定网路结构让其记住所具有的全部平衡点, 然后, 将带有一定错误(干扰)显示的文字, 以一定的方式输入给网络, 网络经过反馈循环运行最终能够指出所属于的正确文字, 研究表明, 采用反馈网络进行识别的抗干扰能力远远大于采用前向 BP 网络加上竞争网络所进行的文字识别的抗干扰能力.




图 14a 带有噪声的字母 图 14b 网络识别的正确结果

Fig. 14a The letter with noise

Fig. 14b The right result of network recognition

4.2 优化计算

表 1 典型网络及其功能总结

Table 1 The summary of typical networks and their functions

名称	功能
BP 网络(反向传播网络)	非线性系统的建模与控制
感知器	样本的简单分类与模式识别
竞争网络	模式分类, 样本的“点”特性检测
科荷伦网络	模式分类, 样本的“线”特性检测
特性图	模式分类, 样本的“面”特性检测
自适应共振理论网络	样本种类的自动模式分类
反馈网络	联想记忆(离散型)和优化计算(连续型)

总而言之, 神经网络已被人们应用到几乎各个领域, 其中每一种网络都可能有多种不同的应用, 人们仍然还在不断拓宽各种神经网络的实际应用的范围.

参 考 文 献(References)

1 从 爽. 面向 MATLAB 工具箱的神经网络理论与应用. 中国科学技术大学出版社, 1998
 2 K J Hunt, D Sbarbaro R, Zbikowski, P J Gauthrop. Neural

因为反馈网络表现出一个系统的动态特性, 所以可以利用控制系统的分析方法求解出网络系统稳定时的参数(对应为网络权值). 霍普菲尔德在 80 年代初提出了一个对反馈连续网路的稳定性判别的函数, 这个函数有明确的物理意义, 是建立在能量基础上的, 同李雅普诺夫函数一样. 霍普菲尔德认为在系统的运动过程中, 其内部储存的能量随着时间的增加而逐渐减少, 当运动到平衡状态时系统的能量耗尽或变得最小, 那么系统自然在此平衡状态处于渐近稳定. 利用能量函数的概念, 可以设计连续反馈网络进行优化计算. 加上连续型反馈网络与电子线路之间存在着直接对应关系, 这样就可以方便地用大规模电子线路来实现网络的并行自循环的运行. 通过这种并行运算, 有可能解决优化计算中的“指数爆炸”问题. 最典型的应用例子为旅行商问题: 一个商人要在 n 个城市中不重复地各走一遍的最短路径的求解. 利用软件来实现连续反馈网络的优化问题也是可能的.

5 总结(Conclusions)

由上可知, 典型网络都是为了完成某种功能(任务)而提出的, 在典型网络的基础上, 可以改型或拓展成其他网络以完成其应用. 表 1 中总结了典型网络及其功能.

Networks for Control System - A Survey. Automatica, 1992, 28 (6):1083~ 1112

3 B Widrow, M Bilello. Nonlinear Adaptive Signal Processing for Inverse Control. World Conference on Neural Network (WCNN'94), 1994

作者简介

从 爽(1961-), 博士, 教授. 研究领域为先进控制策略在运动控制中的应用与实现, 模糊控制, 神经网络控制, 变结构控制, 重复控制, B 样条控制等.