

神经网络控制

人工神经网络(ANN)是智能控制领域研究历史相对比较长但发展历经曲折的交叉学科。简单地说,神经网络就是用物理上可以实现的器件、系统或现有的计算机来模拟人脑的结构和功能的人工系统。它由大量简单的神经元经广泛互联构成自适应非线性动态系统,在某种程度上可以模拟人脑生物神经系统的工作过程。神经网络通过模拟人脑结构来实现对人脑信息处理功能的模拟,并应用这种模拟来解决工程实际问题。这种应用已经有了许多著名的成功先例,并正在展示出更广的应用前景。

基于人工神经网络的控制(ANN-based Control)简称神经控制(Neural Control)。神经网络具有很强的学习能力、非线性映射能力、鲁棒性和容错能力,充分地将这些神经网络特性应用于控制领域,可使控制系统的智能化向前迈进一大步。随着控制系统的复杂性增强,人们对控制系统的要求增高,特别是要求控制系统能适应不确定性、时变的对象与环境。传统的基于精确模型的控制方法难以适应要求,现在关于控制的概念也已更加广泛,它要求包括一些决策、规划以及学习功能。神经网络由于具有这些优点而越来越受到人们的重视。

本章首先介绍神经网络的概念、典型的前馈和反馈网络、BP学习算法,然后介绍MATLAB神经网络工具箱的使用、模糊神经网络,最后通过应用实例介绍神经网络在自动控制领域的应用。

3.1 神经网络的理论概述

3.1.1 生物神经元模型

人工神经网络是参照生物神经网络发展起来的,本书若不作特别说明,神经网络均指人工神经网络。为了深入学习和研究人工神经网络,了解生物神经网络的基本原理是很有必要的。

人脑神经系统的基本单元是神经细胞,即生物神经元,人脑神经系统约由 10^{11} 个神经元构成,每个神经元与约 10^4 个其他神经元相连接。神经细胞与人体中其他细胞的关

键区别在于,神经细胞具有产生、处理和传递信号的能力。如图 3-1 所示,生物神经元主要包括细胞体、树突和轴突。每一部分虽具有各自的功能,但相互之间是互补的。

在生物神经细胞中,除了特殊的无“轴突”神经元外,一般每个神经元从细胞体伸出一根粗细均匀、表面光滑的突起,称为轴突,它的功能是细胞的输出端,用于传出神经冲动。从细胞体延伸出像树枝一样向四处分散开来的许多突起,称之为树突,起作用细胞的输入端,通过“突触”接受四周细胞传来的神经冲动。轴突末端有许多细的分支,称之为神经末梢,每一根神经末梢可以与其他神经元连接,其连接的末端称之为突触。

神经元之间的连接是靠突触实现的。当传入的神经元冲动使细胞膜电位升高并超过阈值时,细胞进入兴奋状态,产生神经冲动,由轴突输出;相反,若传入的神经冲动使细胞膜电位下降到低于阈值时,进入抑制状态,则轴突没有神经冲动输出。根据突触对下一个神经细胞的功能活动的影响,突触又可分为兴奋性的和抑制性的两种。兴奋性的突触可能引起下一个神经细胞兴奋,抑制性的突触使下一个神经细胞抑制。

3.1.2 人工神经元模型

人工神经元是生物神经元的简化和模拟,它是神经网络的基本处理单元。

图 3-2 表示神经元结构,它是一个多输入单输出的非线性元件,其输入输出关系可描述为

$$I_i = \sum_{j=1}^n w_{ij} x_j - \theta_i \quad (3-1)$$

$$y_i = f(I_i) \quad (3-2)$$

其中, $x_j (j=1, 2, \dots, n)$ 是从其他细胞传来的输入信号, θ_i 为阈值, w_{ij} 表示从神经元 j 到神经元 i 的连接权值, $f(\cdot)$ 称为作用函数。




图 3-1 生物神经元




图 3-2 人工神经元结构模型

从上面分析可以看出,人工神经元反映了生物神经元的基本功能。

作用函数 $f(\cdot)$ 又称为变换函数,它决定神经元的输出。作用函数 $f(\cdot)$ 可为线性函数,但通常为阶跃函数或 S 状曲线那样的非线性函数。常用的神经元非线性函数列举如下。

1. 阈值型函数

当 y_i 取 0 或 1 时, $f(x)$ 为图 3-3(a) 所示的阶跃函数。

$$f(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (3-3)$$

当 y_i 取 -1 或 1 时, $f(x)$ 为图 3-3(b) 所示的 sign 函数。

$$\text{sgn}(x) = \begin{cases} 1, & x \geq 0 \\ -1, & x < 0 \end{cases} \quad (3-4)$$




图 3-3 阈值型函数

2. S 状曲线

通常是在 $(0, 1)$ 或 $(-1, 1)$ 内连续取值的单调可微函数, 常用如下两种函数。

1) Sigmoid 函数

$$f(x) = \frac{1}{1 + e^{-\beta x}} \quad (3-5)$$

2) 双曲正切型函数

$$f(x) = \tanh x = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (3-6)$$

其中 $\beta > 0$ 。Sigmoid 函数为应用最广泛的作用函数。当 β 趋于无限时, S 状曲线趋近于阶跃函数。通常取 $\beta = 1$ 。图 3-4 为 Sigmoid 函数曲线。




图 3-4 Sigmoid 函数

3. 饱和型函数

饱和型函数如式(3-7)所示。

$$f(x) = \begin{cases} 1, & x \geq \frac{1}{k} \\ kx, & -\frac{1}{k} \leq x \leq \frac{1}{k} \\ 0, & x < -\frac{1}{k} \end{cases} \quad (3-7)$$

3.1.3 神经网络模型

人工神经网络是由大量简单的基本元件——神经元相互连接而成的自适应非线性动态系统。每个神经元的结构和功能比较简单, 而大量的神经元组合产生的系统行为却非常复杂。人工神经网络是生理学上的真实人脑神经网络的结构和功能, 以及若干基本

特性的某种理论抽象、简化和模拟而构成的一种信息处理系统。由大量神经元相互连接组成人工神经网络将显示出人脑的某些基本特征。

根据连接方式不同,神经网络可分成两大类:没有反馈的前向网络和相互结合型网络。

- 前向网络:由输入层、中间层和输出层组成,中间层可有若干层,也可以没有,每一层的神经元只接收前一层神经元的输出,如图 3-5(a)所示。




图 3-5 两种不同连接方式的网络

- 相互结合型网络:任意两个神经元之间都可能连接,因此输入信号要在神经元之间反复往返传递,从某一初态开始,经过若干次的变化,渐渐趋于某一稳定状态或进入周期振荡等其他状态,如图 3-5(b)所示。

3.1.4 神经网络分类

神经网络发展几十年来,形成了数十种网络,包括多层感知器、自适应共振理论、Kohomen 自组织特征映射、Hopfield 网络、RBF 网络、小波神经网络、混沌神经网络、细胞神经网络、模糊神经网络等。这些网络结构不同,应用范围也各不相同。这里介绍神经网络中应用较多的几种主要的模型。

(1) 多层前向神经网络(multilayer feedforward neural network, MLFN)。这是一种直至目前研究得最多且应用最广的 ANN,它采用多层局部连接结构、无反馈,神经元函数通常取 Sigmoid 函数或 RBF,一般按离散时间运行,采用有监督学习算法。其应用涵盖面很宽:函数逼近、分类与模式识别、系统辨识与控制、后验概率估计、主分量分析 PCA。

(2) 递归神经网络(recurrent neural network, RNN)。这是一种局部连接或全连接、有反馈的网络,其学习、运行、神经元函数选择等方面与 MLFN 类似。主要用途是非线性动力系统的辨识、建模和控制。

(3) 自组织神经网络(Self-Organized neural network)。这种网络的主要特点是学习算法为无监督的自组织算法,其主要功能是实现对输入特征向量的聚类且在此基础上用于完成函数逼近、分类及模式识别等映射。最著名的两种自组织神经网络是自组织映射(self-organized mapping, SOM)网络和自适应谐振理论(adaptive-resonance theory, ART)网络。目前 SOM 网络在模式识别和信号处理等领域颇受重视。ART 网络的特点在于汲取了人脑智能活动的许多心理特点,诸如集中注意、短期与长期记忆、记忆的弹性

与刚性、学习与外界奖惩的关系等。

(4) Hopfield 神经网络。这是一种全连接反馈网络,其运行可按连续时间也可按离散时间进行。前者称为连续时间 HNN,主要用于解决各种优化问题。后者称为离散时间 HNN,主要用于联想记忆、信号的增强与恢复。Lyapunov 能量函数的概念在这类网络的研究中起重要作用。

(5) 模糊神经网络。模糊神经网络是神经网络与模糊逻辑的结合。一种方案是在 MLFN 或 RNN 中纳入模糊逻辑,以使人的知识能够以模糊逻辑的形式用于神经网络的结构设计和参数的粗调整,而 ANN 的学习算法则用于参数细调整。这样就使结构设计和参数学习的效率有很大的提高。其应用与 MLFN 及 RNN 相似,特别适用于非线性动力系统的辨识和控制。另一种方案是模糊逻辑和 SOM 结合构成模糊聚类系统,与确定聚类系统相比,这种系统对聚类的形成更符合人的认知行为,因此在 DM 这一类应用中性能明显优越。

3.1.5 神经网络的学习规则

学习功能是人工神经网络中最重要的特征之一。神经网络主要由三种因素决定:神经元的特性、网络的连接和学习算法规则。其中,学习算法对网络学习速度、收敛特性、泛化能力等有很大的影响。对各种学习算法规则的研究,在人工神经网络理论与实践发展过程中起着相当重要的作用。当前,人工神经网络研究的许多课题仍然是致力于学习算法规则的改进、更新和应用。

对于大脑神经而言,不同的功能区域均有各自的学习规则。这些完整和巧妙的学习规则是大脑在进化过程中通过学习得到的。对于人工神经网络而言,学习方法归根到底就是网络连接权的调整方法。

人工神经网络连接权的确定通常有两种方法:一种是根据具体要求直接计算出来,如 Hopfield 网络作优化计算时就属于这种情况;另一种是通过学习得到的,大多数人工神经网络都是采用这种方法。随着网络结构和功能的不同,人工神经网络的学习方法也是多种多样的。在这里简要介绍人工神经网络中一些最基本的、最通用的学习规则,这些规则主要包括以下方面。

1. 无监督 Hebb 学习规则

Hebb 学习规则是 1949 年由 Hebb 根据生理学中条件反射机理,提出的神经元连接强度变换的规则,它是人工神经网络学习的基本规则,可以这样形容,几乎所有的人工神经网络的学习规则都可以看做是 Hebb 学习规则的变形。

假定第 j 个神经元到第 i 个神经元之间的连接强度(突触权重)为 w_{ij} ,样本序号 S 是从 0 到 $M-1$, $x_i^{(s)}$ 和 $x_j^{(s)}$ 分别表示第 s 样本矢量的第 i 个和第 j 个元素,以它们分别作为第 i 个和第 j 个神经元的输入,那么, w_{ij} 的计算规律是

$$w_{ij} = \begin{cases} \sum_{s=0}^{m-1} x_i^{(s)} x_j^{(s)}, & (i \neq j) \\ 0, & (i = j) \end{cases} \quad (3-8)$$

规则表明,是将全部 M 个样本的第 i 和第 j 元素进行相关运算,以求得连接权值 w_{ij} ,如果两者符合得越多,则 w_{ij} 值越大,也即两神经元之间的连接权重越强。简单地说,若两个神经元同时处于兴奋状态,则它们之间的连接应该加强。

2. Perception 学习规则

Perception 学习规则是采用有导师学习方法。首先,设置权值的初值,一般是较小的随机非零值。然后,给定输入 u_p 和输出 d_p 的样本对,即导师信号。其次,可以求出感知器的输出 $y_p(k)$ 。最后,可以求出权值的调整公式

$$w_j(k+1) = w_j(k) + \eta(d_p - y_p(k))u_{jp} \quad (3-9)$$

其中, k 为第 k 次调整权值; η 为学习率, $0 < \eta \leq 1$, 用来控制权值的调整速度。

3. δ 学习规则

这种方法是用已知样本作为教师对网络进行学习,又称误差校正规则,或最小方差法。

首先设置初始权值 $w(0)$,一般是较小的随机非零值;给定输入 u_p 和输出 d_p 的样本对,即导师信号;再计算网络的目标函数 J ,神经元在第 p 组样本输入下的输出为

$$y_p(t) = \sum_{j=0}^n w_j(t)u_{jp} \quad (3-10)$$

$$E_p(t) = \|d_p - y_p(t)\|_2^2 = \frac{1}{2}[d_p - y_p(t)]^2 = \frac{1}{2}e_p^2(t) \quad (3-11)$$

$$J(t) = \frac{1}{2} \sum_p [d_p - y_p(t)]^2 = \frac{1}{2} \sum_p e_p^2(t) \quad (3-12)$$

$$w_j(t+1) = w_j(t) - \eta \frac{\partial E_p(t)}{\partial w_j(t)} \quad (3-13)$$

公式(3-13)是用于权值调整的自适应学习算法,当 $J(t) = \sum_p E_p(t) \leq \epsilon$ 时,算法结束。

4. 内星/外星学习规则

设 w_{ij} 为神经元 i 到神经元 j 的连接权值, v_i 为神经元 i 的输出,则连接权值的调整为

$$\Delta w_{ij} = \alpha(v_i - w_{ij}) \quad (3-14)$$

在这种学习中,是使 w_{ij} 趋近输入的值,为内星学习规则。

当 v_i 为神经元 i 的输出,采用公式(3-14)进行连接权值调整是使 w_{ij} 趋近输出的值,为外星学习规则。内星学习规则适用于图形识别等方向,而外星学习规则适用信号传递领域。

3.1.6 用于控制的神经网络

神经网络的下列特性对控制是至关重要的。

(1) 并行性。人脑神经元之间传递脉冲信号的速度远远低于冯·诺依曼计算机的工作速度,前者仅为毫秒量级,但是由于人脑是一个大规模并行处理与串行处理组合的系统,因而在许多问题上可以作出快速判断、决策和处理,其速度可以远远高于冯·诺依曼计算机。神经网络是对人脑结构和功能的模拟,但是更偏重于对结构的模拟。各个神经元处理信息时是各自独立的,这种并行计算的处理,使得神经网络可用于实时快速处理信息。

(2) 分布式。在神经网络中,信息则分散分布在神经元的连接上,单个的连接权值和神经元都没有多大的用途,它们的组合才能从宏观上反映出一定信息特征。神经网络在局部网络受损或输入信号因各种原因发生部分畸变时,仍然能够保证网络的正确输出,提高网络的容错性和鲁棒性。

(3) 自适应学习过程。人工神经网络具有初步的自适应能力与自组织能力。通过训练可以改变连接权值,以适应周围环境的要求,抽象出样本的主要特征。神经网络是一个具有学习能力的系统,可以发展知识,以至超过设计者原有的知识水平。因此,神经网络能够解决那些由数学模型或描述规则难以处理的控制过程问题。

(4) 非线性。神经网络可以有效地实现输入空间到输出空间的非线性映射。寻求输入到输出间的非线性关系模型,是工程界普遍面临的难题。对大部分无模型的非线性系统,神经网络都能够很好的模拟。这一特性给非线性控制问题带来新的希望。

(5) 硬件实现。神经网络不仅能够通过软件而且可借助硬件实现并行处理。近年来,一些超大规模集成电路实现硬件已经问世,而且可从市场上购买到。这使得神经网络具有快速和大规模处理能力得以实现,为神经网络在控制中的应用开辟了广阔的前景。

从以上几点可以看出,神经网络由于其学习和适应、自组织、函数逼近和大规模并行处理等能力,因而具有用于智能控制系统的潜力。神经网络在模式识别、信号处理、系统辨识和优化等方面的应用已有广泛研究。人们在控制领域已经做出许多努力,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及逼近系统的辨识函数等。

3.1.7 神经网络控制的研究内容

1. 基于神经网络的系统辨识

(1) 将神经网络作为被辨识系统的模型,可在已知常规模型结构的情况下,估计模型的参数。

(2) 利用神经网络的线性、非线性特性,可建立线性、非线性系统的静态、动态、逆动态及预测模型,实现系统的建模和辨识。

2. 神经网络控制器

神经网络作为控制器,可对不确定、不确知系统及扰动进行有效的控制,使控制系统达到所要求的动态、静态特性。

3. 神经网络与其他智能技术的结合

将神经网络与专家系统、模糊逻辑、遗传算法等相结合,可设计新型智能控制系统。

4. 优化计算

在常规的控制系统中,常遇到求解约束优化问题,神经网络为这类问题的解决提供了有效的途径。

目前,神经网络控制已经在多种控制结构中得到应用,如 PID 控制、模型参考自适应控制、前馈反馈控制、内模控制、预测控制、模糊控制等。

3.2 前馈网络及其 BP 学习算法

3.2.1 感知器

将神经网络与专家系统、模糊逻辑、遗传算法等相结合,可设计新型智能控制系统。

感知器(perceptron)是一个具有单层神经元的神经网络,并由线性阈值元件组成,是最简单的前向网络。主要用于模式分类,单层的感知器网络结构如图 3-6 所示。图中, $X=[x_1, x_2, \dots, x_n]^T$ 是输入特性向量; $y_i(i=1, 2, \dots, m)$ 为输出量,是按照不同特性分类的结果; w_{ij} 是 x_i 到 y_i 的连接权值,此权值是可调的,因而有学习功能。

由于按不同特性的分类是相互独立的,因而可以取出其中的一个神经元来讨论,如图 3-7 所示。




图 3-6 单层感知器网络




图 3-7 单个神经元的感知器

为方便起见,令输入量 $x_0=1$,将阈值 θ 并入权中(因为 θ 值也需要学习), $-\theta=w_0$,感知器的输入输出关系表示为

$$y = f\left(\sum_{i=0}^n w_i x_i\right) \quad (3-15)$$

当其输入的加权和大于或等于阈值时,输出为 1,否则为 -1(或为 0)。

下面给出感知器的一种学习算法:

(1) 随机给定一组连接权 $w_i(0)$ (较小的非零值),这里 $w_i(k)$ 为 k 时刻第 i 个输入上的权($1 \leq i \leq n$), $w_0(k)$ 为 k 时刻的阈值。

(2) 输入一组样本 $X = [x_0, x_1, \dots, x_n]$ 和期望的输出 d (也称为教师信号)。如果 $X \in A$ 类(某一类), 则 $y_d = 1$; 如果 $X \in B$ 类(另一类), 则 $y_d = -1$ 。

(3) 计算感知器实际输出:

$$y(k) = f\left(\sum_{i=0}^n w_i(k)x_i\right) = \begin{cases} 1, & \text{当 } \sum_{i=0}^n w_i(k)x_i \geq 0 \\ -1, & \text{当 } \sum_{i=0}^n w_i(k)x_i < 0 \end{cases}, \quad (x_0 = 1, w_0(0) = -\theta)$$

(4) 按下式修正权值:

$$w_i(k+1) = w_i(k) + \eta[d(k) - y(k)]x_i, \quad i = 0, 1, 2, \dots, n$$

其中, $w_i(k)$ 为当前权值; $d(k)$ 为导师信号; $y(k)$ 为感知器的输出值; η 为学习速率 ($0 < \eta < 1$), η 选取太小学习太慢, η 太大会影响 $w_i(k)$ 的稳定, 即引起震荡。

(5) 选取另外一组样本, 重复上述(2)~(4)的过程, 直到权值对一切样本均稳定不变为止, 学习过程结束。

上述的单层感知器能解决一阶谓词逻辑问题, 如逻辑“与”、逻辑“或”问题, 但不能解决像异或问题的二阶谓词逻辑问题。感知器的学习算法保证收敛的条件是, 要求函数是线性可分的(即输入样本函数类成员可分别位于直线分界线的两侧), 当输入函数不满足线性可分条件时, 上述算法受到了限制, 也不能推广到一般的前向网络中, 其主要原因是由于激发函数是阈值函数。

3.2.2 径向基函数神经网络

径向基函数神经网络(RBF 网络)是一种前馈神经网络, 一般分为三层结构, 如图 3-8 所示。

图 3-8 为 $n-h-m$ 结构的 RBF 网络, 即网络具有 n 个输入, h 个隐层节点, m 个输出。其中, $\mathbf{x} = (x_1, x_2, \dots, x_n)^T \in R^n$ 为网络输入矢量, $\mathbf{W} \in R^{h \times m}$ 为输出权值矩阵, b_0, \dots, b_m 为输出单元偏移, $\mathbf{y} = (y_1, \dots, y_m)^T$ 为网络输出, $\Phi_i(\cdot)$ 为第 i 个隐层节点的激活函数。图 3-8 中输出层节点中的 \sum 表示输出层神经元采用线性激活函数, 当然输出层神经元也可以采用其他非线性激活函数(如 Sigmoidal 函数)。




图 3-8 径向基函数网络结构

众所周知, 多层感知器(包括 BP 网络)的隐层节点基函数采用线性函数, 激活函数则采用 Sigmoidal 函数或硬极限函数。与多层感知器不同, RBF 网络的最显著的特点是隐层节点的基函数采用距离函数(如欧氏距离), 并使用径向基函数(如 Gaussian 函数)作为激活函数。径向基函数关于 n 维空间的一个中心点具有径向对称性, 而且神经元的输入离该中心点越远, 神经元的激活程度就越低。隐层节点的这一特性常被称为“局部特

性”。因此 RBF 网络的每个隐层节点都具有一个数据中心,图 3-8 中的 c_i 就是网络中的第 i 个隐层节点的数据中心值, $\| \cdot \|$ 则表示欧氏范数。

径向基函数 $\Phi_i(\cdot)$ 可以取多种形式,如下面的式(3-16)~式(3-18)。

1. Gaussian 函数

$$\Phi_i(t) = e^{-\frac{t^2}{\delta_i^2}} \quad (3-16)$$

2. Reflected Sigmoidal 函数

$$\Phi_i(t) = \frac{1}{1 + e^{\frac{t^2}{\delta_i^2}}} \quad (3-17)$$

3. Multiquadric 函数

$$\Phi_i(t) = \frac{1}{(t^2 + \delta_i^2)^\alpha}, \quad \alpha > 0 \quad (3-18)$$

式(3-16)~式(3-18)中的 δ_i 称为该基函数的扩展函数(spread)或宽度。显然, δ_i 越小,径向基函数的宽度就越小,基函数就越具有选择性。

于是图 3-8 中, RBF 网络的第 i 个输出可表示为

$$y_k = \sum_{i=1}^h \omega_i \Phi_i(\|x - c_i\|) \quad (3-19)$$

RBF 网络是一种局部逼近的神经网络,它对于输入空间的某个局部区域,只有少数几个连接权影响网络的输出,从而使局部逼近网络具有学习速度快的优点。

3.2.3 BP 网络

误差反向传播神经网络,即 BP 网络(Back Propagation),是一种单向传播的多层前向网络。在模式识别、系统辨识、函数拟合、优化计算、最优预测和自适应控制等领域有着较为广泛的应用。图 3-9 是 BP 网络结构示意图。




图 3-9 BP 神经网络的结构