



3.1 引言

模糊逻辑控制解决了人类智能行为语言的描述和推理问题,尤其是一些不确定性语言的描述和推理问题,从而在机器模拟人脑的感知和推理等智能行为方面迈出了重大的一步。然而,模糊控制在处理数值数据和自学习能力等方面还远没有达到人脑的境界。本章将从另一个角度出发,即从人脑的生理学和心理学着手,通过人工模拟人脑信息处理机理来实现机器的部分智能行为。人工神经网络就是模拟人脑细胞的分布式工作特点和自组织功能,且能实现并行处理、自学习和非线性映射等能力的一种系统模型。

自 20 世纪 80 年代以来,神经网络的研究出现了突破性的进展。神经网络作为揭开人脑生理机制的一个重要手段越来越引起各行各业科学家的浓厚兴趣。早在 1943 年,心理学家 McMloch 和数学家 Pitts 合作提出形式神经元数学模型(MP),揭开了神经科学理论的新时代。1944 年 Hebb 提出了改变神经元连接强度的 Hebb 规则,至今仍在各种神经网络模型中起着重要作用。1957 年 Rosenblatt 首次引进了感知器概念(perceptron)。它由阈值性神经元组成,试图模拟动物和人脑的感知和学习能力。1976 年 Grossberg 基于生理和心理学的经验,提出了自适应共振理论,各种神经网络模型和结构的提出进一步推动神经网络理论的研究和发展。1982 年,美国加州工学院物理学家 Hopfield 提出了 HNN 模型,他引入了“计算能量函数”的概念,给出了网络的稳定性判据,HNN 网络的电子电路实现为神经计算机的研究奠定了基础,同时也开拓了神经网络用于记忆和优化计算的新途径。值得一提的,1986 年,Rumelhart 等 PDP 研究小组提出了多层前向传播网络的 BP 学习算法,为前向传播神经网络的快速有导学习提供十分有效的方法,也为神经网络的实际应用开辟了一条新途径。

神经网络经历了近半个多世纪的研究和发展已经取得了重大的进展。尤其在最近十多年来人工神经网络得到迅速发展。神经网络系统实质上是由大量的，同时也是很简单的处理单元(或称神经元)广泛地互相连接而形成的复杂网络系统。它反映了人脑功能的许多基本特性，但它并不是人脑神经系统的真实写照，而只是对其作某种简化、抽象和模拟。神经网络系统是一个高度复杂的非线性动力学系统，虽然每一个神经元的结构和功能十分简单，但由大量神经元构成的网络系统的行为却是丰富多彩和十分复杂的。神经网络系统除了具备一般非线性动力学系统的共性之外，还具有一些明显的特点，如快速并行处理能力和自学习能力。因此神经网络控制确实是一种很有前途的智能控制方法。但必须指出，神经网络控制存在大量的理论问题有待解决。本章将就目前在控制领域中用得相对普遍的神经网络模型、神经网络控制结构及学习算法作一介绍。同时对神经网络系统建模、神经网络控制等进行了研究和总结。作者认为，神经网络理论处在发展阶段，有很多问题如学习的快速性问题、网络结构的最佳选择问题、新颖的特别适用于控制的专用网络模型、非线性系统的神经网络可辨识性问题、控制算法的收敛性和稳定性问题等都没有明确的答案。作者希望通过本书对神经网络控制的介绍能起到抛砖引玉之效，促进神经网络控制理论的深入发展。

神经元网络系统的研究主要有三个方面的内容，即神经元模型、神经网络结构、神经网络学习方法。从神经元模型角度来看，有线性处理单元和非线性处理单元；从网络结构方面来看，主要表现出三大类，前向网络、反馈网络和自组织网络。目前已被广泛应用的神经网络结构种类大致可以由图 3-1 示意。




图 3-1 神经网络结构分类示意图

虽然神经网络的组成原理和结构都不尽相同，但是它们都具有学习功能。因此，在一般意义上统称为神经元网络。所谓学习是指神经元系统能根据某种学习方法调整它内部的参数以完成特定任务的过程。根据不同的神经网络结构，学习方法主要有两大类，有导师指导下的学习和无导师指导下的学习。在全面介绍各

种神经网络模型之前,先来讨论人工神经网络的一些共性问题。

3.1.1 神经元模型

神经元是生物神经系统的最基本单元,其形状和大小是多种多样的。从组成结构方面来看,各种神经元是有共性的。神经元模型是生物神经元的抽象和模拟,它是模拟生物神经元的结构和功能,并从数学角度抽象出来的一个基本单元。在构造神经网络模型前,首先就要确定神经元的各种特性。神经元一般是多输入单输出的非线性器件(如图3-2所示)。

图3-2中, u_i ——神经元的内部状态;

θ_i ——阈值; x_i ——输入信号, $i=1,2,\dots,n$;

w_{ij} ——表示从单元 u_j 到单元 u_i 的连接权值;

s_i ——外部输入信号。

那么,上述模型可描述为

$$Net_i = \sum_j w_{ij} x_j + s_i - \theta_i \quad (3-1)$$

$$u_i = f(Net_i) \quad (3-2)$$

$$y_i = g(u_i) = h(Net_i) \quad (3-3)$$

通常情况下,可以假设 $g(u_i)=u_i$,即 $y_i=f(Net_i)$ 。目前常用的神经元数学模型主要有以下四种。

(1) 阈值型(图3-3)

$$f(Net_i) = \begin{cases} 1 & Net_i > 0 \\ 0 & Net_i \leqslant 0 \end{cases}$$

(2) 分段线性型(图3-4)

$$f(Net_i) = \begin{cases} 0 & Net_i \leqslant Net_{i0} \\ kNet_i & Net_{i0} < Net_i < Net_{i1} \\ f_{\max} & Net_i \geqslant Net_{i1} \end{cases}$$




图3-3 阈值函数




图3-2 神经元结构模型




图3-4 线性函数

(3) Sigmoid 函数型(图 3-5)

$$f(Net_i) = \frac{1}{1 + e^{-\frac{Net_i}{T}}}$$

(4) Tan 函数型(图 3-6)

$$f(Net_i) = \frac{e^{\frac{Net_i}{T}} - e^{-\frac{Net_i}{T}}}{e^{\frac{Net_i}{T}} + e^{-\frac{Net_i}{T}}}$$




图 3-5 Sigmoid 函数




图 3-6 Tan 函数

3.1.2 神经网络的模型分类

目前神经网络模型的种类相当丰富,已有 40 余种各式各样的神经网络模型,其中典型的有多层前向传播网络(BP 网)、Hopfield 网络、CMAC 小脑模型、ART 自适应共振理论、BAM 双向联想记忆、SOM 自组织网络、Boltzman 机网络和 Madaline 网络等。

神经网络的强大功能就是通过神经元互连而达到的。根据连接方式的不同,神经网络可分为以下 4 种形式。

(1) 前向网络。如图 3-7(a)所示,神经元分层排列,组成输入层、隐含层(可以有若干层)和输出层。每一层的神经元只接受前一层神经元的输入。输入模式经过各层的顺次变换后,得到输出层输出。各神经元之间不存在反馈。感知器和误差反向传播算法中使用的网络都属于这种类型。

(2) 反馈网络。这种网络结构指的是只有输出层到输入层存在反馈,即每一个输入节点都有可能接受来自外部的输入和来自输出神经元的反馈,如图 3-7(b)所示。这种模式可用来存储某种模式序列,如神经认知机即属于此类。也可以用于动态时间序列系统的神经网络建模。

(3) 相互结合型网络。与前面两种结构模型不同,相互结合型模型属于网状结构,如图 3-7(c)所示。这种神经网络模型在任意两个神经元之间都可能存在连接。HNN 网络和 Boltzmann 机网络都属于这一类。在无反馈的前向网络中,信号一旦通过某个神经元,过程就结束了。而在相互结合的网络中,信号要在神经元之间反复往返传递,网络处在一种不断改变的状态之中。从某个初态开始,经




图 3-7 神经网络的 4 种形式

过若干次变化,才能达到某种平衡状态,根据网络结构和神经元的特性,还有可能进入周期振荡或其他如混沌等状态。

(4) 混合型网络。它是层次型网络和网状结构网络的一种结合,如图 3-7(d)所示。通过层内神经元的相互结合,可以实现同一层内的神经元的横向抑制或兴奋机制,这样可以限制每层内能同时动作的神经元数,或者把每层内的神经元分成若干组,让每组作为一个整体来动作。

3.1.3 神经网络的学习算法

学习的过程实质上是针对一组给定输入 $X_p (p=1, 2, \dots, N)$ 使网络产生相应期望输出的过程。总的来说,神经网络的学习算法分为两大类,有导师学习和无导师学习(分别如图 3-8(a)和(b)所示)。




图 3-8 神经网络学习方式

所谓有导师学习就是在训练过程中,始终存在一个期望的网络输出。期望输出和实际输出之间的距离作为误差度量并用于调整权值。而无导师学习指的是网络不存在一个期望的输出值,因而没有直接的误差信息,因此,为实现对网络训练,需建立一个间接的评价函数,以对网络的某种行为趋向作出评价。神经网络学习规则根据连接权系数的改变方式不同又可分为如下三类。

1. 相关学习

仅仅根据连接间的激活水平改变权系数。它常用于自联想网络,执行特殊记忆状态的死记式学习。最常见的学习算法是 Hebb 规则。

(1) Hebbian 学习规则

Hebb 在 1949 年提出了网络学习 Hebbian 规则,Hebb 学习规则的基本思想是,如果单元 u_i 接受来自另一单元 u_j 的输出,那么,如果两个单元都高度兴奋,则从 u_j 到 u_i 的权值 w_{ij} 便得到加强。用数学形式可以表示为

$$\Delta w_{ij} = g(y_i(t), t_i(t))h(o_j(t), w_{ij}) \quad (3-4)$$

这里, $t_i(t)$ 是对于 u_i 的一种理想输入。简单地说,该式意味着,从 u_j 到 u_i 的连接权阵的修改量是由 u_i 的活跃值 y_i 和它的理想输入 t_i 的函数 g ,及 u_j 的输出值 $o_j(t)$ 和连接强度 w_{ij} 的函数 h 的积确定。在 Hebb 学习规则的最简单形式中没有理想输入,而且函数 g 和 h 与它们的第一个自变量成正比。因此有

$$\Delta w_{ij} = \eta y_i o_j \quad (3-5)$$

这里 η 表示学习步长。

(2) 相关学习法

相关学习法实际上是一种有导师指导下的 Hebbian 学习法,它是将 Hebbian 学习法(如式(3-5))中的 y_i 用期望输出值 t_i 来代替,即

$$\Delta w_{ij} = \eta t_i x_j \quad i = 1, 2, \dots, n_o; j = 1, 2, \dots, n_i$$

相关学习法的权系数初值通常取为 0。

2. 纠错学习

依赖于输出节点的外部反馈改变权系数。它常用于感知器网络、多层前向传播网络和 Boltzmann 机网络。其学习的方法是梯度下降法。最常见的学习算法有 δ 规则、模拟退火学习规则。

(1) 感知器学习规则

感知器学习规则是一种最基本的有导师学习方法。其学习信号就是网络的期望输出 t 与网络实际输出 y 的偏差 $\delta_j = t_j - y_j$ 。连接权阵的更新规则为

$$\Delta w_{ji} = \eta \delta_j y_i \quad (3-6)$$

感知器学习规则只适用于二值输出网络,且是线性可分函数。

(2) Delta 学习规则

Delta 学习规则是对感知器学习规则的改进。它不但适用于线性可分函数也适用于非线性可分函数,且激励函数的输出可以为连续函数。与感知器学习规则一样,Delta 学习规则也属于有导师学习方法。它适用于多层前向传播网络,其中 BP 学习算法是最典型的 Delta 学习规则。定义指标函数

$$E_p = \frac{1}{2} \sum_{i=1}^{n_o} (t_i - y_i)^2$$

连接权阵的更新规则为 $\Delta W = -\eta \nabla E_p$ 。

(3) Widrow-Hoff 学习规则

Widrow-Hoff 学习规则是由 Widrow 和 Hoff 在 1962 年共同提出来的。主要用于有导师学习。当输出单元为线性函数时,其校正量为 $\delta_j = t_j - W_i^T X$,因而有

$$\Delta w_{ji} = \eta \delta_j X_i \quad i = 1, 2, \dots, n_i$$

实质上,Widrow-Hoff 学习规则是 Delta 学习规则的一个特例,即当输出单元为线性单元时,Delta 学习规则就退化为 Widrow-Hoff 学习规则。

3. 无导师学习

学习表现为自适应实现输入空间的检测规则。它常用于 ART、Kohonen 自组织网络。在这类学习规则中,关键不在于实际节点的输出怎样与外部的期望输出相一致,而在于调整参数以反映观察事件的分布。

无导师学习中常用的有 Winner-Take-All 学习规则,如下所示。

如图 3-9 所示的网络结构, Winner-Take-All 学习规则的基本思想是,假设输出层共有 n_o 个输出神经元,且当输入为 x 时,第 m 个神经元输出值最大,则称此神经元为胜者。并将与此胜者神经元相连的权系数 W_m 进行更新。其更新公式为

$$\Delta w_{mj} = \eta(x_j - w_{mj}) \quad j = 1, 2, \dots, n_i$$

式中 $\eta > 0$,为小常数。

有导师指导下的学习中通常有一维矢量组形成的训练样本集,并利用这一样本对神经网络进行训练。在这一矢量对中,其中一个矢量对应于网络的输入,另一个矢量表示期望输出。网络训练的目的是通过调整神经网络的权系数阵以便使网络的实际输出与期望输出之间的偏差达到极小。这一过程可以是一个迭代过程,也可以通过一个闭合方程一次性解得权系数阵的值。

无导师指导下的学习有时又称为自组织训练。它只需要输入样本就可以进行网络的训练。在整个训练过程中,神经网络权系数调整的目的是保证此网络能够将相类似的输入样本映射到相近似的输出单元中去。这一训练过程实质上是从输入样本集中抽取其统计特性。

虽然学习算法众多,但无论哪一种都不是完全理想的。它们都受到这样或那样的限制。因此,在神经网络理论的研究中,学习算法的研究占据重要一席之地。学习速度、算法的可靠性和通用性是评价一个学习算法好坏的重要因素。对学习算法的进一步改进应该着重于这些方面。

除此之外,在神经网络理论的研究中还有许多问题困扰着人们,如

(1) 神经网络能否实现期望的表示? 满足期望输入输出映射的网络权阵是否存在?




图 3-9 前向传播神经网络结构图

- (2) 学习算法能否保证权值收敛于真值?
- (3) 权值能否通过网络训练达到最佳值?
- (4) 神经网络的泛化能力是否充分?
- (5) 训练样本集是否合理? 它们能否充分地描述系统的输入输出特性?

对于这些问题的满意解答目前还没有定论。因此,人们对人工神经网络的利用还带有许多经验和判断。目前,人们不能保证对于一个给定的神经网络、学习算法和训练样本集能够产生满意的逼近结果。就现在的背景知识而言,为了得到较好的结果,大量的试验是不可避免的。

3.1.4 神经网络的泛化能力

现实世界是五颜六色的,充满变化和发展。因此,不可能存在两个完全一致的事物。但是人们能够很容易地区别出这里的相同或相异。例如,我们能够轻易地从电话中听出朋友的声音,不管其噪声有多大。那么,对于人工神经网络而言是否也应该具有这样类似的性能呢?希望是肯定的。我们希望人工神经网络也能容许某些变化,如当输入矢量带有噪声时,即与样本输入矢量存在差异时,其神经网络的输出同样能够准确地呈现出应有的输出。这种能力就称为神经网络的泛化能力。

在有导师指导下的学习中,泛化能力可以给出定量的定义。对于某一个概率分布的样本中随机选取一部分作为神经网络的训练样本,并且首先对这一组样本进行网络训练最终得出神经网络输出的误差 e_1 。接下去再从全体样本数据中随机选取另一组输入输出数据,这一批数据对已经训练好的神经网络进行校对,记它们的校对误差即神经网络的实际输出与期望输出之差为 e_2 。那么,定义 $|e_1 - e_2|$ 为此神经网络的泛化能力。

神经网络的泛化又可以看作是一种多维插值。为了说明这一点,我们先来看一个例子。为了便于分析,考虑一个一维问题。假设给定 5 个样本点,如图 3-10 所示。我们假定这 5 个点取于某一条潜在的曲线。通过插值计算可以得到在这 5 个点之间任意输入点 x 的未知曲线的输出值 $y = f(x)$ 。图中给出了三条不同的插值计算曲线,它们分别是五阶多项式、七阶多项式和九阶多项式。通过插值计算可以得到其余输入点的输出值。每一条曲线对于已知的 5 个样本的逼近都是完美无缺的。但是,在没有进一步的信息之前,我们无法判断哪一条曲线更符合实际的输出响应。这一例子说明了泛化存在的一个基本问题,即只用有限的样本数据集难以正确地确定其他点的输出情况。目前神经网络理论对此类问题也无法有满意的解释。因此,必须借助于系统的一些背景知识和校验数据。在缺乏任何其他信息的条件下,人们习惯于选择那些比较简单又比较平滑的结果,如上例中可选五阶多项式曲线来描述输入输出关系。同样的道理,对于一样的样本集系统产生同样精度的神经网络结构,则应选择最简单的那一个网络结构类型。但是必须清楚地认识到,这样的选择是武断的和主观的,会产生不良结果。




图 3-10 多项式逼近示意图

以上分析可知,泛化或插值都需要一定数量的样本训练集。很显然,如果仅仅只有少数样本点,那么点之间的曲线形状的不确定性将是相当严重的。因此,可以这样说,输入矢量的个数、网络的节点数和权值与训练样本集数目之间存在密切的关系。

3.2 前向神经网络模型

3.2.1 多层神经网络结构

前向神经网络是由一层或多层非线性处理单元组成。相邻层之间通过突触权系数连接起来。由于每一层的输出传播到下一层的输入,因此称此类网络结构为前向神经网络。前向神经网络结构的出现是相当早的,1962年 Rosenblatt 提出的感知器和 1962 年 Widrow 提出的 Adaline 网络是最早的前向神经网络结构。然而前向神经网络真正发挥出它应有的潜力是在 1986 年 Rumelhart 等提出的多层感知网络及其 BP 学习算法以后。前向神经网络可以看成是一种一组输入模式到一组输出模式的系统变换。这种变换通过对某一给定的输入样本相应的输出数据集训练得到。为了能实现这一行为,网络的突触权系数阵能在某种学习规则的指导下进行自适应学习。通常情况下,前向神经网络的训练需要一组输入输出样本集,因此这种学习方法又称为有导师指导下的学习。下面先来看一下几种前向神经网络结构。

1. 单一人工神经元

单一人工神经元可以看作是某一试图建立人工神经元和生物神经元之间联系的动态模型。根据这一解释,每一神经元的激励输出是由一组连续输入信号 $x_i, i=1, 2, \dots, n_i$ 决定的,而这些输入信号代表着从另外神经元传递过来的神经脉

冲的瞬间激励。设 y 代表神经元的连续输出状态值,一般 y 可取 0 或 1 来表示神经元的兴奋和抑制。

为了模拟生物神经元函数, y 的动态行为可以由如下微分方程来表示

$$\frac{dy}{dt} = -\xi(y) + Net \quad (3-7)$$

其中, Net 表示所有输入细胞膜电流的总效应, $\xi(\cdot)$ 是非递减的非线性函数, $-\xi(y)$ 项表示神经元激励的延迟。

最简单的人工神经元是假设输入项 Net 由输入信号 $x_j (j=1, 2, \dots, n)$ 的线性组合构成, 即

$$Net = w_0 + \sum_{j=1}^n w_j x_j \quad (3-8)$$

其中 w_0 为阈值, w_j 决定第 j 个输入的突触权系数。

如果输入信号是稳定的或变化缓慢时, y 趋近于它的渐近稳定点, 即 $dy/dt=0$ 。在平衡点, 方程式(3-7)就变成为

$$y = \sigma(w_0 + \sum_{j=1}^n w_j x_j)$$

其中 $\sigma(x) = \xi^{-1}(x)$ 。图 3-11 形象地表示了单个神经元的输入输出关系图。




图 3-11 单一人工神经元的示意图

根据以前的讨论, 如果输出变量 y 是一个二值元素, 则在平衡点 $y=+1(1)$ 表示兴奋状态, $y=-1(0)$ 表示抑制状态。这样, 每一个神经元的输出都可以用一个阈值型非线性函数来表示。但是为了分析方便起见, 阈值型非线性函数通常用软阈值型非线性函数来代替, 即 $\sigma(\cdot)$ 可以用方程式(3-9)来代替。

$$\sigma(x) = \xi^{-1}(x) = \tanh(\beta x) \quad (3-9)$$

由前面讨论可知, 最简单的单一神经元中, 我们是假设输入项 Net 是输入信号 x_i 的线性函数。但在一般情况下, Net 应该是输入 x_i 的非线性函数, 即

$$Net = w_0 + \sum_{j=1}^n w_j x_j + \sum_{j=1}^n \sum_{k=1}^n w_{jk} x_j x_k + \dots \quad (3-10)$$

此时, 神经元的平衡态输出 y 为

$$y = \sigma(w_0 + \sum_{j=1}^n w_j x_j + \sum_{j=1}^n \sum_{k=1}^n w_{jk} x_j x_k + \dots) \quad (3-11)$$

对于神经元输出只含兴奋和抑制两状态的神经元可以看作是一个分类器, 即能对任意一组输入信号进行是否属于的分类映射。当神经元输出为连续状态时, 单一神经元可以作为一个简单的神经控制器进行参数自适应控制, 如传统的 PID 调节器就可以用单一神经元来实现。这样, 可以通过调节神经元的连接权系数来达到 PID 参数的自适应。

2. 单层神经网络结构

前面描述的单一神经元是神经网络结构的基本组成部分。为了强调它在神经网络结构中的作用,又把人工神经元称为单元(unit)。单层神经网络结构是由 n_i 个输入单元和 n_o 个输出单元组成(如图3-12)。系统 n_i 个输入变量用 $x_j, j=1, 2, \dots, n_i$ 表示, n_o 个输出变量用 $y_i, i=1, 2, \dots, n_o$ 表示。则每一个输出神经元 y_i 满足




图3-12 单层前向传播网络结构示意图

$$\frac{dy_i}{dt} = -\xi(y_i) + Net_i \quad (3-12)$$

其中 Net_i 为输入到第*i*个单元的信号总和,即

$$Net_i = w_{i0} + \sum_{j=1}^{n_i} w_{ij}x_j \quad (3-13)$$

那么,每一单元*i*的输出满足

$$\frac{dy_i}{dt} = -\xi(y_i) + w_{i0} + \sum_{j=1}^{n_i} w_{ij}x_j = -\xi(y_i) + \sum_{j=0}^{n_i} w_{ij}x_j \quad (3-14)$$

其中 $x_0 = 1$ 。

同单一神经元一样,假设输入信号的变化相当缓慢或保持常值,则系统可达到平衡点,且满足方程

$$y_i = \sigma\left(\sum_{j=0}^{n_i} w_{ij}x_j\right) \quad (3-15)$$

其中 $\sigma(x) = \xi - 1(x)$ 。

同理,对于高阶神经单元(如式(3-11))也可以用来构成一种神经网络结构。

3. 多层神经网络结构

早期对神经网络的研究着重于简单的神经网络,如单层具有线性或非线性输出单元的研究。然而,很早就发现单靠单层神经元网络无法满足许多复杂问题的




图3-13 含一个隐含层前向传播
网络结构示意图

求解。许多学者(如 Widrow, Lehr 等人)提出了更复杂的结构来试图克服单层网络的众多缺陷。但真正起决定作用的是 Rumelhart 等人引入的多层传播网络结构。多层传播网络结构是在输入层和输出层之间嵌入一层或多层隐含层的网络结构。隐含单元既可以与输入输出单元相连,也可以与其他隐含单元相连。图3-13表示了具有一个隐含层