

基于结构学习和迭代自映射的自联想记忆模型*

危 辉

(浙江大学 计算机科学系 人工智能研究所,浙江 杭州 310027);

(复旦大学 计算机科学系,上海 200433)

E-mail: weihui@fudan.edu.cn

http://www.cs.fudan.edu.cn

摘要: 传统的人工神经网络连接结构是固定的,是对权值的学习.提出一种基于生理神经元特征的人工神经元模型,并在以此为单元构成的用于实现自联想记忆的神经网络上进行对结构的学习.学习算法以设定神经元的输入/输出感受野、调整突触和轴突末梢的连接、并行的自投影迭代为特征.给出了此网络模型的矩阵描述和实验结果.

关键词: 联想记忆;人工神经网络

中图分类号: TP18 **文献标识码:** A

目前,人工神经网络与神经科学的联系还较弱,权值的调整技巧被称作是一种“black arts”,很难预料与掌握.通常的人工神经网络的学习方式是“对权值的学习”,本文讲述一种“对结构的学习”.它将“用数值隐含表示记忆模式”转向“用结构连接表示记忆模式”.

在新生儿的脑生理发育过程中有一个突触的爆发生长期(bloom bursting),产生极为巨量的神经连接.在新生儿以后的认知发展过程中,随着对外界刺激的加工的增加,这些神经连接会进行自行调整和裁剪^[1];不仅如此,认知发展成熟以后,神经元树突的形态也是经常变化的^[2],使神经元能改变接收信息的对象的范围.这些显然都是对结构的学习.

联想是一种记忆,心理学中进行的再认实验是一种自联想,再认的成功率比回忆的成功率要好很多,比如对测试“回忆国家的名称”和“根据词头回忆国家的名称”的成绩进行比较,后一个包含可供联想的依据的测试成绩会好许多,这似乎能隐晦地说明实现联想记忆的机理是结构表示和结构间的激励.已有的联想记忆模型^[3]无论是映射式,还是将联想记忆过程看成是非线性动力系统的演化过程,都是基于连接固定、对连接权值进行优化计算的方法,那么能否将自联想记忆建立在对结构学习的网络模型上呢?

1 网络结构设计

1.1 逻辑神经元设计

经典的神经元模型是数值计算型的,它的活跃函数和输出函数通常选择连续型的函数.用权值表示突触的连接强度.由于神经网络连接关系固定、均质和呈现高度规律性,所以,权值成为网络中唯一可以通过学习来改变的部分,这也就决定了对模式的记忆是通过权值而不是通过结构来进行的.当把模式的表示基础转向通过结构来进行时,权值的设置就不必要了,对权值进行学习的低效率的算法也就可以放弃了.

生理神经元在信息处理上有以下几个特点^[2,4]:(1) 神经元的轴突和树突的形态是可变的,使其能改变接收信息的神经元范围,也能改变其输出信息的范围.在神经科学中感受野的概念是非常重要的,所以,文中称接收信息的范围为输入野,称输出信息的范围为输出野.(2) 突触连接间传递信息是通过神经递质的释放来改变生

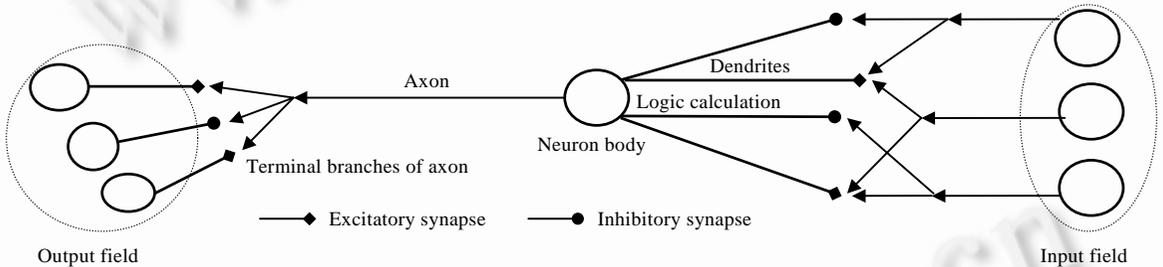
* 收稿日期: 2000-02-15; 修改日期: 2000-08-03

基金项目: 国家高性能计算基金资助项目(970064)

作者简介: 危辉(1971 -),男,江西南昌人,博士,副研究员,主要研究领域为人工智能,认知科学.

物膜的通透性,从而引起膜两边正负离子的流动来实现的.如果能使正(负)离子流入(出)突触后端(postsynaptic dendrite),那么这是一个兴奋性的突触连接,它总给出更多的动作电位(action potentials);相反,如果能使正(负)离子流出(入)突触后端,那么这是一个抑制性突触连接,它总是减少动作电位的数量.(3) 轴突传递动作电位时,由于管道膜交替改变两边的电势,钠离子不断地进入轴突,使动作电位能不衰减地被传递.动作电位到达其他神经元的树突后,由那些突触的性质来解释它,动作电位的强度并不被再次传递.由(2)和(3)可见,生理神经元处理的信息更注重它们的性质,而不是具体的数值;抑制性突触是对轴突信号的求反运算,表现出一种布尔运算的特征,它似乎是一种逻辑神经元,这与通常的数值神经元有根本的不同.而且用权值来表示突触连接强度的方法似乎其生理基础并不牢靠.虽然说人工神经元的模型取自生理神经元,但从前者身上反映出的后者的痕迹还是很少,自然也就有本质的不同.

在人工神经元和生理神经元之间存在一个“模糊的暗喻(metaphor)”^[5]:前者可以自称为一个“node”,至于这个“node”是一个神经元,一个膜结构,还是一个计算单元,并不明确加以说明.其原因在于,就并行分式处理而言,这一细节明确与否并不妨碍计算.由前述对生理神经元的讨论而引出逻辑神经元设计将改变这种模糊性.如图 1 所示为一个进行布尔运算的逻辑神经元,它有两种类型的突触而没有权值,兴奋型突触不改变所接收到的信号,抑制型突触对所接收到的信号求反;神经元体对树突输入的信息进行某种逻辑演算,若结果为真,则轴突有输出,否则没有输出;每个神经元有兴奋和被抑制两种状态,只有当兴奋时,轴突才有输出;每个神经元都有自己的、独特的输入野与输出野.可见,神经元的轴突只有在神经元的输入野(另外一群神经元)的活动呈现恰当的模式时才会有输出,也就是说,此神经元对此模式有选择性响应;对这个模式的记忆不是通过权值,而是通过连接的结构,所以,网络的学习就变成对突触类型的学习,这当然是对结构的学习.



输入野, 树突, 轴突, 逻辑运算, 神经元体, 轴突末梢, 输出野, 兴奋型突触, 抑制型突触.

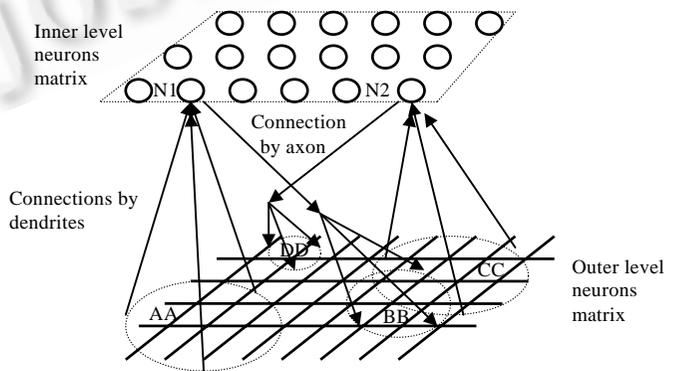
Fig.1 A neuron which performs Boolean calculation

图 1 一个进行布尔运算的逻辑神经元

1.2 网络结构设计

Pylyshyn 说:“发现思维的认知结构是认知科学的中心问题”,从生理心理学中“神经对精神的决定论”和构造主义的观点出发,对联想记忆考察的核心是可能完成这一高层心理机能的神经结构.在人的大脑中,平行的等级结构是一种普遍存在的对信息进行处理的结构^[6].它为认知心理学基于信息加工的观点寻找底层神经活动对高层集体行为(如概念)的整合作用提供了一个精确的模型,这就是计算神经科学的内涵.

以上述进行逻辑演算的神经元为结构单位的网络结构和一些说明如图 2 所示.



内层神经元阵列, 轴突连接, 树突连接, 外层神经元阵列.

Fig.2 The hierarchical neural networks of associative memory

图 2 实现联想记忆的层次网络模型

它是一个两层的层次结构,特别强调:外层神经元的功能性质可以是像感光细胞那样的传感器,也可以是像复杂细胞那样的特征提取器;内层神经元发挥联想记忆的作用;网络的学习就发生在对突触性质的确定上;外层神经元阵列的规模决定了学习样本的复杂度,在它具有足够多的轴突与树突和内层神经元阵列连接的情况下,内层神经元的数量决定了记忆的容量,通过扩充内层神经元可使网络的容量增加。

图 2 作了简略,两层神经元的结构细节被省略了。 N_1 和 N_2 是两个神经元的编号,椭圆区域 AA 和 BB 分别是 N_1 的输入野和输出野,椭圆区域 CC 和 DD 分别是 N_2 的输入野和输出野,在 N_1 的输出野 BB 和 N_2 的输入野 CC 间有交差重叠的部分。内层神经元在外层神经元上的输入/输出野的拓扑形状可以是任意的,如不连续的几个区域。内层和外层神经元阵列的规模是可拓展的,由于没有权值的设置问题,任何拓展的影响都是局部的,没有全局连锁效应。从图 2 可见, N_1 将 AA 区域的输入处理后投影到 BB 区域,BB 的部分信息又和 CC 中其他信息一起经 N_2 处理后投影到 DD 区域。这样的区域交替投影过程是可以一直进行下去的,作者称其为迭代自映射。本文所述联想记忆算法的核心就是这个迭代自映射过程,它将局部的信息以某种方式和其他区域的信息联系起来,使要被记忆的模式发生内部关联,当只出现局部信息或发生局部的信息损伤时,可通过内部关联恢复全部信息或由已知区域的信息对损伤部分进行修正,这就是自联想过程。

本文所述算法无论是在网络结构还是在学习算法上与“交替投影算法(alternative project neural network)”都是根本不同的,后者还是属于传统权值学习的范畴。其区别的细节不是本文重点,在此略去,可参看文献[3]。

1.3 学习与回忆算法

首先,必须构造出整个网络,产生大量可供学习的突触。基于结构学习的网络构造算法:

第 1 步.按预置数量随机产生外层神经元阵列,每一神经元的突触数目是随机的,类型为未确定;

第 2 步.按预置数量随机产生内层神经元阵列,每一神经元的突触数目是随机的,类型为未确定,在外层神经元阵列中随机选择与突触数目相同的外层神经元作为输入野,并将它们的轴突末梢指向那个内层神经元的突触(多对一),这些连接用矩阵表示是 $in = \begin{bmatrix} f/\bar{f} & \dots & 0 \\ \vdots & \ddots & \vdots \\ f/\bar{f} & \dots & 0 \end{bmatrix}$, f/\bar{f} 表示未确定型突触,0 表示不在输入野范围内;再随机

选择一定数量的外层神经元作为输出野,并将内层神经元的轴突末梢指向外层神经元的的一个突触(一对多),这些连接用矩阵表示为 $out = \begin{bmatrix} 0 & \dots & f/\bar{f} \\ \vdots & \ddots & \vdots \\ f/\bar{f} & \dots & 0 \end{bmatrix}$, f/\bar{f} 表示未确定型突触,0 表示不在输出野范围内。

学习算法分两部分来叙述:单个神经元的突触学习和整个网络的学习。首先假设若神经元活跃,则它的轴突发出一个高电位(记作 1);若神经元被抑制,则它的轴突发出一个低电位(记作 0);兴奋型突触进行一次恒等运算,抑制型突触进行一次逻辑求反运算。高/低电位分别模拟轴突中动作电位的增加和减少,这是逻辑神经元进行运算的基础。

单个神经元的突触学习内层和外层分别发生两次,如图 3 所示,突触学习只发生在未确定类型的突触上,其基本原则是:“内层神经元的突触类型由外层神经元的输入决定,外层神经元的突触类型由自身和来自内层的反馈共同决定”;突触学习的顺序是先内层,后外层。单个神经元的突触学习算法:

第 1 步.内层的一个神经元,对任何一个未确定型的、和输入野中某一外层神经元轴突相连的突触,即对矩阵 in 中任意 f/\bar{f} :若外层神经元的状态为兴奋,则此突触的类型设为兴奋型 f (输出时保持原值);若外层神经元的状态为抑制,则此突触的类型设为抑制型 \bar{f} (输出时逻辑求反)。

第 2 步.按第一步,对内层神经元与其输入野中所有外层神经元轴突相连的未确定型突触进行学习。

第 3 步.内层神经元对所有突触的输入进行逻辑与运算,若结果为 1,则它的轴突有高电位输出;否则,它的轴突输出低电位(在模式学习阶段与运算的结果一定是 1)。

第 4 步.对与内层神经元的轴突相连的、其输出野中任意一个外层神经元的未确定类型突触,即对矩阵 out 中任意 f/\bar{f} :若轴突的输出为 1,且外层神经元是活跃的,则将此未确定类型突触的类型设定为兴奋型 f ;若轴突

的输出为 1,且外层神经元是抑制的,则将此未确定类型突触的类型设定为抑制型 \bar{f} ;若轴突的输出为 0,则不进行学习(此种情况仅在网络应用阶段出现).

第 5 步.按第 4 步,对与内层神经元的轴突相连的、位于其输出野中所有外层神经元的未确定类型突触进行学习.

当在外层神经元阵列上给定一个模式要求网络记忆时就是记忆(样本学习)算法:

第 1 步.在内层神经元阵列中寻找一个对整个外层神经元阵列的覆盖,即使这些神经元输入野的并集覆盖整个要记忆的样本模式,记录这个神经元的集合;

第 2 步.外层神经元向集合中内层神经元映射,按突触学习算法第 1、2 步进行;

第 3 步.集合中内层神经元向外层神经元投影,按突触学习算法第 3 步进行;

第 4 步.外层神经元突触学习,按突触学习算法第 4、5 步进行.

由于输入样本是稳定的,所以学习算法会很快收敛.对图 3 中的例子,内层神经元 N 的突触 A 和 B 分别被设为兴奋型和抑制型,外层神经元的突触 C 和 D 分别被设为兴奋型和抑制型.当所有突触的类型被确定后,N 所记忆的模式就等同于那样一个由 0 和 1 构成的矩阵.

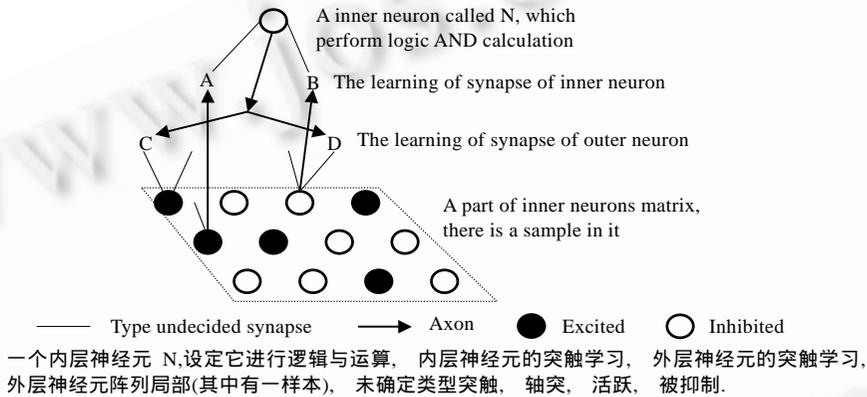


Fig.3 The learning of synapse

图 3 突触学习

当学习了一些样本模式之后,可以给出一个测试样本让网络进行识别.它可以是不完整的或是被部分污损的,这时就要进行自联想了.以下是回忆迭代算法:

第 1 步.所有内层神经元对各自突触的输入进行逻辑运算,若计算结果为 1,则它的轴突有输出.

第 2 步.任何有输出的轴突对各自输出野中所有外层神经元进行投影,按所连接的、外层神经元突触的类型改变外层神经元的状态:若突触是兴奋型,则将其状态置为 1;若是抑制型,则将其状态置为 0.

第 3 步.以改变的外层神经元阵列进行迭代,继续从第 1 步开始,直到外层神经元阵列的状态不再改变为止,算法停止时的外层神经元状态为回忆结果.

关于算法终止的讨论请参看第 2 节,关于实验结果请参看第 3 节.

2 网络结构和迭代过程的数学描述

2.1 网络结构及算法的矩阵描述

对前述网络模型最好的数学描述工具是矩阵.假设:(1) 供给网络模型学习和记忆的样本是这样

一个由 0 和 1 组成的 n 阶矩阵, $Sample = \begin{bmatrix} 1 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 1 & \cdots & 0 \end{bmatrix}$,它是从与传感器相连的外层神经元阵列得到的,其中 1 代表对应位置的

神经元状态为活跃,0 则代表对应位置神经元被抑制;(2) 对于每一个内层神经元的输入野,它相当于这样一个

矩阵 $Synapse = \begin{bmatrix} \bar{f} & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & f \end{bmatrix}$, 其中 f 和 \bar{f} 分别代表兴奋型和抑制型突触, 在逻辑上分别表示恒等运算和求反运算, 0 代表对应位置的外层神经元不在此内层神经元的输入野范围之内; (3) 对于它的输出野, 则相当于这样一个矩阵 $Axon = \begin{bmatrix} 1 & \dots & 1 \\ \vdots & \ddots & \vdots \\ 0 & \dots & 1 \end{bmatrix}$, 1 代表对应位置的外层神经元在此内层神经元的轴突输出范围之内, 0 所代表的反之。

每一个内层神经元先通过树突对样本进行采样, 然后在神经元内进行逻辑与运算, 最后再通过轴突投影到外层神经元上的过程就是这样一个矩阵运算过程:

(1) 输入 $Input = Sample \wedge Synapse$, 其中 \wedge 为按位与运算和按 f/\bar{f} 运算, 所以 $Input$ 仍是一个 n 阶的 0/1 矩阵。

(2) $Middle = [1 \dots 1] (*\wedge) Input (*\wedge) \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix}$, 其中 $[1 \dots 1]$ 和 $\begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix}$ 是元素全为 1 的向量矩阵, 新运算 $(*\wedge)$ 表示

在进行矩阵乘法的过程中用逻辑与代替算术加的运算, 所以 $Middle$ 是一个将输入野中所有突触的采样输入进行逻辑与的结果, 它或是 0 或是 1。

(3) $Project = Axon * Middle$, 其中运算 $*$ 代表矩阵乘法. 完整表示该内层神经元的运算就是: $Project =$

$$\begin{bmatrix} \bigcap_{i=1}^k f/\bar{f} & \dots & \bigcap_{i=1}^k f/\bar{f} \\ \vdots & \ddots & \vdots \\ 0 & \dots & \bigcap_{i=1}^k f/\bar{f} \end{bmatrix} = \begin{bmatrix} 1 & \dots & 1 \\ \vdots & \ddots & \vdots \\ 0 & \dots & 1 \end{bmatrix} * \left([1 \dots 1] (*\wedge) (Sample \wedge Synapse) (*\wedge) \begin{bmatrix} 1 \\ \vdots \\ 1 \end{bmatrix} \right),$$

其中 $\bigcap_{i=1}^k f/\bar{f}$ 是新运算 $(*\wedge)$ 的结果, k 是该内层神经元输入野的大小, 它等于突触的数量。

在意义明确的前提下, 我们把每一个内层神经元(用 j 标识)对样本矩阵所进行的运算看作一个变换, 并将其

函数化, 设为 $P(Sample)$, 同时不妨把计算结果用分块矩阵的形式表示: $Project^{(j)} = P^{(j)}(Sample) = \begin{bmatrix} 0 & \dots & 0 \\ \vdots & M^{(j)} & \vdots \\ 0 & \dots & 0 \end{bmatrix}$, 其

中 $M^{(j)}$ 是元素为 $\bigcap_{i=1}^k f/\bar{f}$ 的子矩阵, k 的值随 j 而异. 当数量规模为 N 的内层神经元阵列的所有有效神经元(突触

类型确定的神经元)对一个样本进行一次计算时, 就对应这样一个矩阵运算: $\bigcup_{j=1}^N P^{(j)}(Sample) = \bigcup_{j=1}^N \begin{bmatrix} 0 & \dots & 0 \\ \vdots & M^{(j)} & \vdots \\ 0 & \dots & 0 \end{bmatrix}$,

其中 $\bigcup_{j=1}^N P^{(j)}$ 是矩阵按位逻辑或运算. 那么, 回忆迭代算法就是这样一个过程: $Mode_{(0)} = \bigcup_{j=1}^N P^{(j)}(Sample)$,

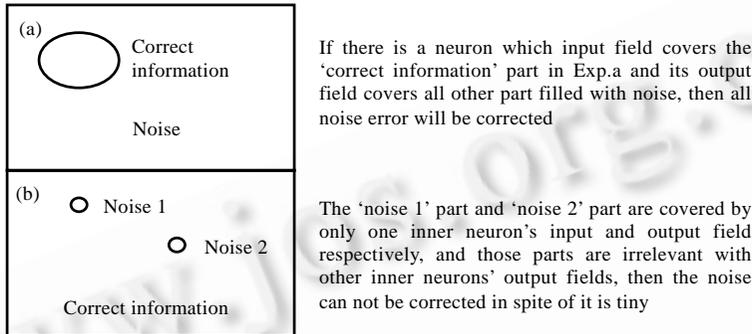
$Mode_{(1)} = \bigcup_{j=1}^N P^{(j)}(Mode_{(0)})$, ..., $Mode_{(x+1)} = \bigcup_{j=1}^N P^{(j)}(Mode_{(x)})$, ... 我们希望当 x 迭代到一定次数时迭代算法结

束, $Mode_{(x)}$ 等于 $Sample$. 由于每个经过学习的内层神经元都对应一种特定的输入模式, 且两层神经元阵列间轴突与突触的连接是按要求记忆的模式匹配好的, 所以通常不会出现矩阵中的某一位或某些位被交替更改而致使算法不收敛的可能. 但当若干个内层神经元的输入野与输出野彼此相交和形成一个“映射环”时, 在输入野与输出野彼此相交区域中几个严格一致的对应位上, 它们的几个学习样本恰恰出现 0/1 交替的现象, 同时又存在另

外几个学习样本在上述相交区域中那几个对应位上的 0/1 变化和前面几个学习样本正好配对相反,且测试样本正好包括了几个学习样本的敏感局部,就会出现不收敛的情况,但实际使用中这些事件同时发生的概率非常小。

2.2 模型纠错能力与网络容量的说明

模型对有噪音样本的纠错能力主要受 3 个因素影响:(1) 噪音的数量与分布(越不均衡越好);(2) 内层神经元输出野的分布(越均衡越好);(3) 不存在噪音的内层神经元输入野个数,以及这些内层神经元输出野的分布。由于是随机分布,也许会出现任何一个内层神经元的输入野中都有噪音的极端情况,噪音如此之多而不能成功回忆也属难免。我们来看一下图 4 中另外两个与输入/输出野分布相关的极端的样本纠错例子。



正确的信息, 噪音, 若存在一个输入野为“正确”范围的内层神经元,它的输出野完全覆盖其余部分,所有噪音部分都能被纠正, 正确的信息, 噪音 1 和噪音 2 部分仅被一个内层神经元的输入野和输出野分别覆盖,而与别的内层神经元输出野无关,则这少量的噪音也不能被纠正。

Fig.4 The extreme examples of correcting error

图 4 纠错的极端例子

在如图 4 所示的例子中,随机分布被均匀化的概率更大,所以我们仅考虑更常见的纠错失败:“噪音出现在外层神经元阵列的 y 个地方,且它们均不被任何一个内层神经元输出野覆盖;或图 4(b)的情况”。一个噪音出现在何处的概率是相等的,设为 $\frac{1}{n^*n}$, n^*n 是外层神经元阵列的规模;一个外层神经元不被一个内层神经元输出野覆

盖的概率是 $\frac{n^*n - |O|}{n^*n}$, 其中 $|O|$ 是一个内层神经元轴突末梢的数量;两个噪音相关的概率等于两个区域有输入/输出野相关的概率,是 $\frac{|O| + |I|}{n^*n}$, 其中 $|I|$ 是一个内层神经元树突的数量。那么成功纠错的概率便是不出现上述情

况的概率,即 $1 - \left[\left(\frac{1}{n^*n} \right)^y * \left(\frac{n^*n - |O|}{n^*n} \right)^{m^*y} + \left(\frac{1}{n^*n} \right)^{\left[\frac{w+1}{2} \right]} \left(\frac{|O| + |I|}{n^*n} \right)^w \right]$, m 是用于记忆该样本的内层神经元个数, w 是

出现图 4(b)类噪音相关的次数,这种相关是可传递的。此概率是不知道噪音是否会发生的前提下理论值。当我们已经知道有 y 个噪音,又没有出现图 4(b)的情况时,纠错的概率是 $1 - \left(\frac{n^*n - |O|}{n^*n} \right)^{m^*y}$, 当 $n=10, y=2, m=12, |O|=10$ 时,纠错概率是 92.1%,由它所反映出来的成功纠错的可能性还是令人满意的。

在对一个样本进行学习之前要选择一定数量的内层神经元作为记忆的载体,按记忆算法的陈述,这种选择是随机的,条件是所选择的那些神经元的输入野的并集形成一个对外层神经元阵列(样本在此呈现)的覆盖。那么,现在的问题是平均需要多少个神经元才能形成一个覆盖呢?这是一个求随机事件——“需要多少(记作 x)个神经元才能覆盖整个输入样本”——的数学期望(记作 E_x)的问题。在网络的构造算法中,内层神经元的输入野和输出野是随机选择的,每个内层神经元轴突选择外层神经元的突触作连接在概率上都是独立事件,所以每个突触被选中的概率相同;同理,每个外层神经元轴突选择内层神经元的突触作连接在概率上也是独立事件,所以每个突触被选中的概率也相同。若外层阵列的规模是 n^*n ,每个神经元具有的突触数平均为 k ,且突触的分布均匀,

那么上述问题可改为:需要多少个(用 x 表示)这样的神经元同时作用才能使整个输入样本以接近 100% 的概率被覆盖呢?这类似于“空盒问题”^[7]:有 $n*n$ 个盒子,把 kx 个质点随机地分配到 $n*n$ 个盒子中去,假设每个质点落入各盒的概率相等,求事件 $A_v = \{\text{恰好有 } v \text{ 个空盒}\}$ 的概率.当我们把 v 设为 0,即设事件“恰好有 0 个空盒”的概率为 100% 时,本文的问题就完全等效于“空盒问题”了.根据“空盒问题”的概率计算公式有: $P(A_0) = C_{n*n}^0 (1 - \frac{0}{n*n})^{kx} \sum_{i=0}^{n*n-0} (-1)^i C_{n*n}^i (1 - \frac{i}{n*n-0})^{kx} = 1$,这是一个复杂的指数方程.在本文的例子中 $n=10, k=20$,将它们代入上述指数方程,得 $\sum_{i=0}^{100} (-1)^i C_{100}^i (1 - \frac{i}{100})^{20x} = 1$.用试探法求解,让 $x=1, 2, 3, \dots$,当 $x \geq 35$ 时, $P(A_0)$ 已经很接近 100% 了;而且 x 越大或 k 越大,让 $P(A_0)$ 接近 100% 的速度就越快,这从直观覆盖实验上是很容易解释的.这是作为古典型概率事件计算的理论值,5 是所需的最小值($n*n/k$),在真实的实验中以 20 个神经元就覆盖了这个输入样本的例子也多次出现,甚至到 17 个也行.

由于对每一个输入模式的记忆都选择不同的内层神经元来完成,所以网络容量 $R = \frac{N*N}{Ex}$,其中 $N*N$ 是内层神经元阵列的规模, Ex 是前述随机事件的数学期望.我们这样来求 Ex : 前述事件等同于“当增选到 kx 个质点时, $n*n$ 个盒子至少都有一个质点的概率”,这是一个还原、无次序的分配问题^[7].它是一个条件概率:在“ $n*n$ 个盒子中各有一个质点”的前提下,“剩余的质点随机分配”,所以,概率 $p_x = \frac{1}{C_{n*n+n*n-1}} * \frac{1}{C_{n*n+kx-n*n+1}} = \frac{1}{C_{2*n*n-1} * C_{kx+1}}$,

得到 $Ex = \sum_{x=\lfloor \frac{n*n}{k} \rfloor}^{n*n} x * p_x$,代入前式即得理论容量.只要树突的数量不变、外层阵列的规模确定, Ex 就是确定的,容量

随内层阵列的规模线性变化.当我们不要求记忆时所选择的内层神经元的输入野并集一定要完全覆盖外层神经元阵列时,容量可以扩大许多,这可以应用在对小样本的记忆上.

3 实验结果

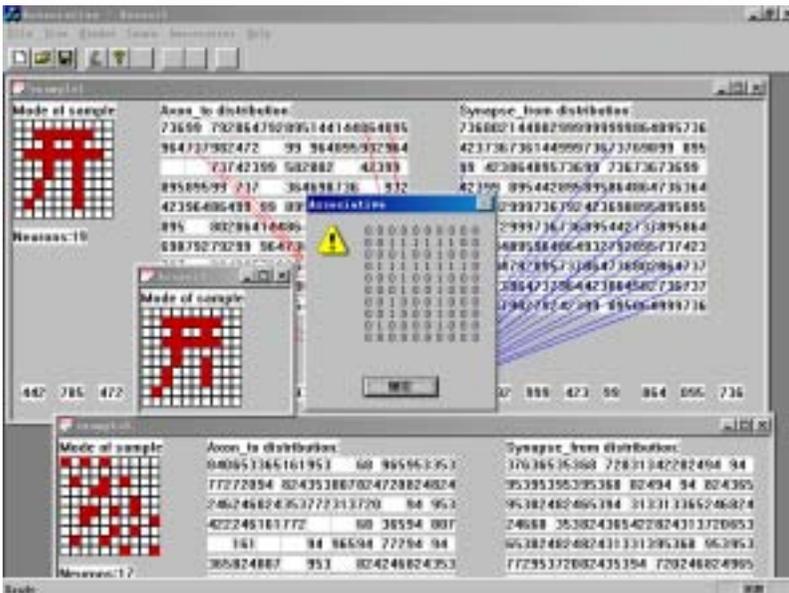


Fig.5 The interface of experimental program

图 5 实验程序界面

话图中所列出的一个 0/1 矩阵是自联想回忆的结果,它补齐了在测试样本中残缺的部分,和学习样本一致.在图 6

在前述理论和算法的指导下,作者在 Visual C++ 开发环境下设计并实现了一个进行联想记忆的系统,网络结构的所有细节都是通过开放数据库连接(open date base connection)保存在 Access 数据库中,程序代码复杂,在此仅呈现一个程序运行界面(如图 5 所示).界面中呈现了内层神经元阵列对外层神经元阵列的覆盖作用,所示学习样本使用汉字(此例中为“开”)仅是为了实验观察的需要.

在界面图所展示的例子中,左上角的“开”表示一个学习样本,中间是测试样本(一个部分残缺的“开”),而中间的对

中,学习样本是一个国际象棋的棋盘图案,中间是测试样本,在其中既有缺少的部分也有新添加的部分,也就是说,为回忆设置了干扰,在右边的对话框中列出的位矩阵准确地回忆起了学习样本,添上了原本有的点,去掉了原本没有的点.当然,用图案作为例子并不表示这个网络模型仅是用来记忆图案模式的,在视觉和听觉皮层中普遍存在着提取和表达某种微小特征的神经细胞^[6,8,9],而从视觉和听觉获取的信息占所

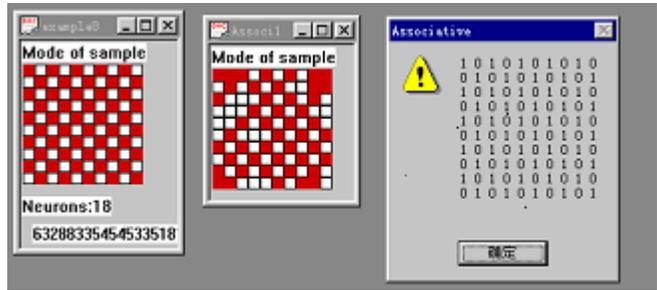


Fig.6 The result of correcting experiment

图6 纠错的实验结果

获信息总量的 90%以上,作为用特征进行知觉信息表示的例子,若将外层神经元阵列作为前述特征响应细胞,学习样本就可看成是用多个局部特征来组合表达某一知觉模式的产生,那么网络就可以用来记忆这些知觉模式.

4 讨论

经典神经网络用权值分布来表示所记忆的模式,对一个模式的记忆计算涉及所有的神经元和连接,而且所有模式的表示是交织在一起的;而本文所用方法是基于结构的,对一个模式的记忆仅涉及部分网络结构.这种网络具有以下几个优点:网络结构是部分可变的、学习速度快、学习样本间不存在顺序性和相关性、在回忆的同时具有容错性、增加新的或部分更改或部分损坏网络结构都不影响以前的学习或仅是部分影响.所有这些优点都是由于采用了不同于权值学习的结构学习思想,且具有神经生理上的支持,有明显的认知意义.无论在生物学还是在工程应用中都存在强烈的证据:神经网络处理信息的能力是由它的结构决定的,所以,目前也有学者通过诸如遗传算法来实现网络结构的进化^[10].在文献[11]中就开发了一种基于 Fogel 进化编程、将结构进化和权值学习联系起来的方法,以优化前馈网络的结构.神经网络单元的同质、高度规律性的和固定的连接、可任意调整的值参数是连接主义的特征,也是计算上的需要.如果每个神经元的结构和功能带有随机性,那么在计算上就没有高度的重复性,为了保持应有的计算效率,就需要一一对应的计算硬件的支持,而这是对当前计算机结构的一种挑战,或说是“可变结构连接”还不适应目前计算机系统结构的之处.

图灵在 1948 年撰写(1968 年才发表)的一篇论文中就提出一种称为“B 型无组织机(B_type unorganized machine)”的神经网络^[12],其中的每一个神经元执行简单的与非逻辑运算,而且整个网络以随机的方式连接起来,网络的学习就是改变每一个连接的调节器状态,或是让数据通过而不发生变化,或是破坏被传送的信息.本文所述的方法和图灵的设想类似.

表示问题是人工智能和认知科学中最核心的问题^[13].对于计算机而言,它的用户和系统设计者都是所需信息的提供者和解释者,他们可以解释形式语义,这一点没有问题;然而用同样的想法来说明大脑中精神活动的过程是不行的,它应该是形式语义终结的地方,对认知模型的研究必须建立在对语义的直接表达基础之上.本文所用方法在作为记忆载体的同时,也是一种基于认知心理的特征学说和神经生理上关于神经元具有的高度模式选择性和可靠性理论的信息直接表达方式.知觉的神经元学说^[14]对核心细胞表征与群编码表征的讨论都证明了建立一种基于局部微结构、微结构有独特功能且结构可组合的神经网络模型对认知行为研究的重要性.

致谢 感谢北京航空航天大学计算机科学与工程系葛声博士给作者的帮助.

References:

- [1] Rosemary, R.A. Cognitive development: psychological and biological perspectives. Needham Heights, MA: Simon & Schuster, Inc., 1994. 285~289.
- [2] Kalat, J.W. Introduction to psychology. 4th ed. Pacific Grove, CA: Brooks/Cole Publishing Company, 1996. 87~98.
- [3] Jiao, Li-cheng. Neural Network Computation. Xi'an: Xi'an Electronic Science and Technology University Press, 1995. 433~434 (in Chinese).

- [4] John, P.J. Pintel. Biopsychology. 3rd ed. Needham Heights, MA: Allyn & Bacon A Viacm Company, 1997.
- [5] Aparicio IV. Manual, Levine Daniel S. Why are neural networks relevant to higher cognitive function, Neural Networks for knowledge representation and inference. Hillsdale, NJ: Lawrence Erlbaum Associates, 1994. 3~5.
- [6] Han, Ji-sheng. The Essentials of Neuroscience. Beijing: the Joint Publishing Company of Beijing Medical University and Xiehe Medical University, 1993. 495~504 (in Chinese).
- [7] Zhou, Gai-rong. Probability Theory and Mathematical Statistics. Beijing: Higher Educational Press, 1984 (in Chinese).
- [8] Carlson, N.R. Foundations of physiological psychology. Needham Heights, MA: Allyn & Bacon A Viacm Company, 1988. 167~185.
- [9] Zhou, Shao-ci. Neurophysiology. Shanghai: East China Normal University Press, 1994. 155~163 (in Chinese).
- [10] Andrew, C.C., Cheng Ling-guan. A combined evolution method for associative memory networks. Neural Networks, 1998,11(5): 785~792.
- [11] Yao, Xin, Liu, Yong. A new evolutionary system for evolving artificial neural network. IEEE Transactions on Neural Networks, 1997,8(3):694~713.
- [12] B.Jack Copeland, Diane Proudfoot. The forgotten computer science idea of Allen Turing. Journal of Science, 1999,(7):38~41 (in Chinese).
- [13] Bickhard, M.H., Terveen, L. Foundational Issues in Artificial Intelligence and Cognitive Science. Amsterdam: Elsevier, 1995. 11~18.
- [14] Shen, Zheng, Chen, Yong-ming, Huang, Xi-ting, Trans. Cognitive Neuroscience. Shanghai: Shanghai Educational Publishing Company, 1998. 208~230 (in Chinese).

附中文参考文献:

- [3] 焦李成.神经网络计算.西安:西安电子科技大学出版社,1995.433~434.
- [6] 韩济生.神经科学纲要.北京:北京医科大学、协和医科大学联合出版社,1993.495~504.
- [7] 周概容.概率论与数理统计.北京:高等教育出版社,1984.
- [9] 周绍慈.神经生理学.上海:华东师范大学出版社,1994.155~163.
- [12] B.Jack Copeland & Diane Proudfoot.被遗忘的阿兰·图灵计算机科学思想.科学,1999,(7):38~41.
- [14] 沈政,陈永明,黄希庭.译.认知神经科学.上海:上海教育出版社,1998.208~230.

A Homogenous Associative Memory Model Based on Structure Learning and Iterative Self-Mapping*

WEI Hui

(Artificial Intelligence Institute, Department of Computer Science, Zhejiang University, Hangzhou 310027, China);

(Department of Computer Science, Fudan University, Shanghai 200433, China)

E-mail: weihui@fudan.edu.cn

http://www.cs.fudan.edu.cn

Abstract: The connections of traditional ANN (artificial neural network) are fixed, and the learning algorithm is to change the weight of every connection. In this paper, a new model is presented which is based on the characteristic of physiological neuron, and as a unit, a homogenous associative memory neural network was built, the learning algorithm was performed to change the structure of the neural network. The characteristic of this algorithm sets the input and output field of a neuron, adjusts the connection between synapse and axon and parallel iterative self-mapping. The matrix model of the network and the experiment results are also presented in this paper.

Key words: associative memory; artificial neural network

* Received February 15, 2000; accepted August 3, 2000

Supported by the National High Performance Calculation Foundation of China under Grant No.970064