

神经网络的知识表示

TPI8

王继成 吕维雪 (浙江大学生物医学工程研究所, 杭州310027)

摘 要

Traditional artificial intelligence and knowledge engineering put forward that knowledge can be expressed in a certain form or data structure. PDP (Parallel Distributed Processing) Model of neural network considers that knowledge is encoded in connection model of neurons. In this paper, we present that processing is the expression, i.e. processing encodes knowledge. There are no places and there are no needs to store general rules used in network inference. If there are rules, there rules are local rules used in local processing. Also, we think that neural network consists of many different kinds of neurons.

神经网络是一类新型的信息加工系统,人们对它的能力和性质有极大的兴趣,并广泛地开发使用这种计算。神经网络的并行分布性质,可以通过大的网络和相对基本的处理单元,以我们所观察到的生物神经网络的形式联接而实现。这样一个系统适合于大规模集成电路构造,可以模拟一些惊人的感知和认知过程、形象思维、直觉顿悟、分布式记忆和自学习自组织过程^[1]。

在传统的人工智能和知识工程中,人们习惯于知识表示假说,即知识以一些表达式的形式或数据结构符号来表示,这些表示的处理可以产生有用的结果(即已存在表示的逻辑结果)。但当开始进一步研究神经网络和神经计算时,我们认为在神经计算中,处理就是表示,即处理将知识编码,没有地方也没有必要存放用于网络进行推理的总的规则。如果有规则的话,也则是一些局部规则,用来响应其它神经元的刺激。根据神经科学和认知科学的研究,我们提出神经网络由异类网实现,而并非仅仅由大量相同的基本处理单元组成。神经网络中不同类的神经元,有

的功能可能相当复杂,但可以调节神经元功能的复杂性和神经元联结的简单性,进一步提高神经网络的适应能力。

本文首先简要地讨论四种神经计算模型及其应用,然后研究神经网络的知识表示问题,说明知识如何编码于处理中,复杂的过程可以由功能复杂的处理单元集合来完成,但这些处理单元之间的联结可以相对简单。

一、四个神经计算模型及其应用

下面简单介绍四个神经计算模型,尽管它们具有不同的计算过程,但其应用场合有些重叠。

一般的0规则网络用于模式的联想输入、




图1 多层感知机结构图

输出对的监督学习 (Supervised learning), 多层感知机结构用于实现模式的输入、输出对联想, 反向传播误差算法用来修改联结权和偏置, 直到网络已学到一个权和偏置的集合, 它使所有相对应的输入都有正确的输出。这种网络结构见图1。

图1中同层神经元之间没有连接, 相邻层之间有全部连接, 并由低层指向高层。令 $W_{k,j}$ 表示输出层神经元与隐含层间的联结权, $W_{j,i}$ 表示隐含层与输入层间的联结权, 神经元输出的计算公式为:

$$Y_k = f\left(\sum_{j=1}^l W_{k,j} Z_j\right) \quad k=0, 1, \dots, m$$

其中: f 是S型函数, Z_j ($j=1, 2, \dots, l$) 为隐含层神经元输出。当选定 L 个训练样本后, 调整 $W_{k,j}, W_{j,i}$ ($i=1, 2, \dots, n; j=1, 2, \dots, l; k=1, 2, \dots, m$) 的目的是使输出层神经元的实际输出和应有的已知输出的均方差最小, 即:

$$\min E = \sum_{p=1}^L E_p = \sum_{p=1}^L \left\{ \frac{1}{2} \sum_{k=1}^m (Y_k^{(p)} - O_k^{(p)})^2 \right\}$$

其中: $O_k^{(p)}$ 为第 p 个样本输入时, 第 k 个神经元应输出值。 $Y_k^{(p)}$ 为第 p 个样本输入时, 第 k 个神经元实际输出值。

调整 $W_{k,j}$ 的公式为:

$$W_{k,j}^{(p)} = W_{k,j}^{(p-1)} + \Delta W_{k,j}^{(p)} \quad p=1, 2, \dots, L$$

写成一般形式:

$$\Delta W_{k,j}^{(p)} = \eta \delta_k^{(p)} \cdot Z_j^{(p)}$$

其中: $0 \leq \eta \leq 1$ 为学习参数; $\delta_k^{(p)}$ 为输出层误差 ($k=1, 2, \dots, m$); $Z_j^{(p)}$ 为隐含层神经元输出 ($j=1, 2, \dots, l$)。

$$\delta_k^{(p)} = (Y_k^{(p)} - O_k^{(p)}) O_k^{(p)} (1 - O_k^{(p)})$$

调整 $W_{j,i}$ 的公式为:

$$W_{j,i}^{(p)} = W_{j,i}^{(p-1)} + \Delta W_{j,i}^{(p)} \quad p=1, 2, \dots, L$$

$$\Delta W_{j,i}^{(p)} = \eta \delta_j^{(p)} \cdot X_i^{(p)}$$

其中: $0 \leq \eta \leq 1$ 为学习参数; $\delta_j^{(p)}$ 为隐含层误差 ($j=1, 2, \dots, l$); $X_i^{(p)}$ 为输入层神经元输出, ($i=1, 2, \dots, n$)。

$$\delta_j^{(p)} = O_j^{(p)} (1 - O_j^{(p)}) \sum_{k=1}^m \delta_k^{(p)} W_{k,j}$$

一般来说, 这种神经计算模型可以用于

从训练样本中收集到的信息来进行模式分类, 已经成功地应用于许多图象和信号处理场合。

第二种神经计算模型是无监督学习或自组织模型。如果样本没有均匀地遍布整个样本空间, 但是样本以簇的形式出现, 这时无监督学习过程自动形成和保持这些样本簇, 一些新样本输入时, 被自动地认识为某个样本。我们一般用Euclidean距离进行样本聚类, 学习向量量化 (Learning Vector Quantization) 方法是Euclidean距离算法的变形, 它把分类和聚类合为一体。其思想是首先根据Euclidean距离得到一个簇结构, 然后分配一个类标志给这个簇样板。这些簇样板使得原来在一个簇中的样本更加相近, 使得原来相近的样本越来越不同。学习向量量化算法是可行的, 但必须分层实现, 否则就不可能分开相互牵连的联系。




图2 Euclidean 距离的聚类形式

第三种神经计算模型是联想检索, 如Hopfield网络模型。通常认为这种存储器由很大的节点阵列组成。一幅图象构成这些节




图3 Hopfield网络结构

点上输入值的一个阵列。图象不是存贮在这些结点上，就是存贮在这些结点之间的联结上。Hopfield网络结构如图3所示。其记忆和检索算法为：

结点*i*的输入：

$$H_i = \sum_{j=1}^n t_{ij} X_j + I_i \quad (i, j=1, 2, \dots, n)$$

其中： I_i 是输入样本 ($i=1, 2, \dots, n$)， X_j 是神经元*j*的输出， t_{ij} 是第*j*个神经元的输出到第*i*个神经元的输入间的联结权。

结点*i*的输出：

$$X_i = V_i^0 \quad \text{当 } H_i < U_i \text{ 时}$$

$$X_i = V_i^1 \quad \text{当 } H_i > U_i \text{ 时}$$

其中： H_i 是结点*i*的输入， U_i 是结点*i*的阈值。

$$t_{ij} = \begin{cases} \sum_{s=1}^L X_i^{(s)} X_j^{(s)} & \text{当 } i \neq j \text{ 时} \\ 0 & \text{当 } i = j \text{ 时} \end{cases}$$

其中： $s=1, 2, \dots, L$ 为样本个数。

第四种神经计算模型是Hopfield网络计算的一种形式。在联想检索模型中，结点间的联结权构成了存贮器，这里的结点仅作为寄存器使用。任给一个输入可以使网络朝以前所存样本的方向演化。但第四种神经计算模型与之不同，它以优化计算为模型，把一定的联结和结点值的和构成一个Liapunov函数或功能函数，结点的值不断变化直到这个和达到最小值。

二、神经网络的知识表示形式

智能行为是复杂的生物化学反应的结果，它发生在神经生理学活动级上，这种行为通常以神经生理学上的物理表示来描述。由于激励条件与智能行动的关系往往受意图、信仰等影响，所以发生在功能级上的智能行为与神经生理学上的智能行为的物理表示既有关系，但又无必然的联系。智能行为的物理表示是确定的，但智能行为的某些方面却不能用纯粹确定的描述来表示。潜在的物理结构并不能产生同一可观察的事件，因此，智能行为可以从其潜在的生物结构和导致这个结构的自然定律来考察。这种方法既

不同于认知科学的功能方法，也不同于确定的物理结构方法。这样，智能活动可以看作是来自生物化学和潜在的神经生理学及分子生物学，但是不假设联结是确定的，或观察的活动可以从当前机制的分子状态进行预测。认知系统的物理级上有两级：第一级为处理信息符号级，第二级为自然中的语义、知识级。当操作原则不能在单纯的功能级上表示时，但可以在代表多层关系的功能的另一级上表示。编码语义内容于其中的符号表达式用来描述认知行为是不够的，需要区别语义解释符号编码和功能结构在功能级描述与表示级描述的联系，具有相同的一组分子生物机制、处理、存贮和控制符号的两个系统在功能上可能不同。生物中相互联系，非线性系统提供了功能精制的全局机制，自然智能出现在非线性相互作用的复杂网络中。可以利用神经网络的动力学描述记忆和其它形式的自然信息处理，复杂网络的动力学特征包括浑沌行为等，这些动态性质用于动物的内容定址记忆、大量并行处理和其它可想象的信息处理结构。如果浑沌行为出现在复杂神经网络中，这时在神经生理学上不可观察的随机信息可以作为非结构行为出现在中间级。当然，这意味着中间现象不能通过物理级的实验来预测。确定性和非确定性系统的区别在于潜在的物理系统是浑沌的，在浑沌系统中，功能级和物理级被处理耦合在一起。在大脑中，分子物理系统和神经网络的精制功理之间通过分层的结构而紧密耦合在一起。

神经网络的知识编码于其内部结构中，处理就是知识，知识可以以分布形式表示。图4说明了神经网络的知识以分布形式表示在联结权和偏置上的情况，图中有7个样本点，其中样本点A、D、F、G取值为1，B、C、E取值为0。我们可以用一个在隐含层有三个结点的一般0规则网络来学习这些联想的输入、输出对。如果把每个隐含单元看作为二维样本空间的分界线，则相对于三个隐




图4 二维样本空间

含单元的三条分界线如图4所示。如果把把这个神经网络看作为空间变换系统，这个系统寻找在最合适空间中的输入、输出映射，例如在这些隐含单元的输出空间画上7个样本点(图5)，则我们可以看到这7个点在这个空间是线性可分的。




图5 隐含单元的输出空间

用这个经过7个输入样本训练后的神经网络可以对所有二维空间的样本点分配某个值。如果用规则来表示这些知识，则需要无穷的规则，但在神经网络中没有规则存在，只有知识，处理本身就是知识。

对于Hopfield网络的自动联想检索，既可以用集中处理算法描述，也可以用并行分布处理描述。在并行分布处理中，既没有集中式知识，也没有集中式控制。对于样本Z，矩阵式联想存储是： $M=ZZ'$ 。其中，Z'是Z的转置。如果输入是Z，则自联想检索样本是： $MZ=\langle ZZ' \rangle Z$ 。如果输入是原来样本的变形Z'，则检索的样本为： $MZ'=\langle ZZ' \rangle Z'$ 。

当用并行分布处理描述Hopfield网络的自联想检索时，取神经元之间的联结权为：

$t_{ij}=x_i x_j$, ($i=1, 2, \dots, n, j=1, 2, \dots, n$)。每个神经元根据下面的局部规则修改其输出值。

$$\text{如果 } H_i = \sum_{j=1}^n t_{ij} x_j > 0 \quad \text{则 } x_i = 1$$

$$\text{如果 } H_i < 0 \quad \text{则 } x_i = -1$$

($i=1, 2, \dots, n$)

以上局部处理规则和前面讨论的集中算法：

$$x_i = \sum_{j=1}^n (x_j x_j) x_j \quad (i=1, 2, \dots, n)$$

的作用是相同的。

Hopfield和Tank提出的用神经网络解决优化问题(如资源分配)同样说明了知识可以以分布处理操作表示。局部的知识并不能保证得到最好的解，但能得到较好的解。神经网络可以用于迭代、基于知识的处理。假设有一个任务，要求以一对一的方式分配N种能力来满足N种要求，原始的解决办法是产生N!个需要/能力分配方案，然后从中找出最好的。然而随着N的增加，产生的方案数急剧增加，使问题难以解决。如果用神经网络解决这个问题，则比较容易。假设神经元的输入为 U_{xi} ，其输出 V_{xi} 是 U_{xi} 的S型函数，即： $V_{xi} = f(U_{xi})$ 。

神经网络的能量函数为：

$$E = A \sum_{x=1}^N \sum_{i=1}^N \sum_{j=1}^N V_{xi} V_{xj} + B \sum_{i=1}^N \sum_{x=1}^N \sum_{y=1}^N V_{xi} V_{yi} + C \left(\sum_{x=1}^N \sum_{i=1}^N V_{xi} - N \right)^2 + D \sum_{x=1}^N \sum_{i=1}^N (N_x - C_i)^2 V_{xi}$$

通过求E的最小值，求得 $V_{xi}(x, i=1, 2, \dots, N)$ 即为本问题的方案。

以上讨论的四种神经计算模型，其知识都是表示在处理过程中。一般来说，学习过程是获取知识，处理过程是使用知识，知识

47-49

知识, ~~编译~~ 编译

人工智能

知识编译

TP18

Ashok K. Goel

Goel, AK

刘逸敏

摘要

精确地讲, 什么是知识编译? 它是否具有多种含义? 什么是深层知识和表层知识? 几位专家对此及其它问题作了探讨。

在问题求解, 基于模型推理和自动编程等人工智能领域文献中“知识编译”是一个常用术语。尽管此术语被广泛使用, 但其含义一更不必说其内容和进行过程了—目前还未被清楚地认识。事实上即使给出此术语的各种用法, 但还不能肯定知识编译是否只具有单个意义。最近在人工智能杂志上关于“知识编译”问题引起了广泛的讨论。

早在八十年代一些文章对此问题开始了讨论, 文章提出了通过因果模型和“第一原理”进行推理的一般问题, 并且将编译知识与象MYCIN专家系统中所用的启发式知识类型相比较。Hart比较了“深层”和“表层”知识系统, Michie对照了“高路”和“低路”系统

后都指出启发性关系式有助于快速求解问题, 而解决疑难问题须依靠领域的因果模型。

同时, Deklee也在研究结构知识和因果知识在电子线路推理中的作用。Chandrasekaran和Mittal提出问题求解类型与知识类型是紧密相关的, 并且Sembugamoorthy和Chandrasekaran给出了从系统“较深层”功能结构模型中如何对特殊问题诊断知识进行编译的方法。他们指出只有深层知识表示在各种问题中普遍存在且对解决各种问题有潜在功效时, 解决象诊断这类特殊问题使用深层知识表示就比较有效。因此因果和功能结构模型, 基于模型的推理及知识编译就成为很普及的概念, 且大量研究者在越来越多的文

是以分布形式表示在神经网络中, 即使有规则存在, 也则是局部规则, 没有整个神经网络使用总的规则。这四种模型组成了基本处理器的相似构造阵列。事实上, 扩展的系统不必总具有这种形式。一旦特定联结的基本处理器和特定的处理可以看作是单个更复杂的实体, 则这个实体可以联结到具有不同功能和特性的实体, 这样系统的功能强而复杂但概念简单, 许多知识可以编码于相互联结和分布处理。

参考文献

[1] R. Davis and D. B. Lenat, Knowledge-Based Systems in Artificial Intelligence, McGraw-Hill, New York, 1982

[2] D. E. Rumelhart et al., Parallel Distributed Processing, Vol. 1, MIT Press, 1987

[3] P. Caianiello, Neural Models, Structure & Learning, 1st. Workshop of Italy on Parallel Arch. & Neural Net., 1988

[4] Nakano K., Niizuma M., Omori T., Model of neural visual system with self-organizing cells, Biological Cybernetics, 60, 195-202, 1989

[5] Charles W., Michael P., The Disystem, A Fundamental Process of Nature, Cybernetica, Vol. XXXIV, No 1-1991, 5-21