

基于距离学习法的模式识别

杨 盈, 李朝峰

(江南大学, 江苏 无锡 214122)

摘 要:提出了一种用于改善二维 Hopfield 神经网络性能的模块化方法。这种方法受到了生物视觉感知系统的启发。图像处理过程采用了 Hebbian 学习规则,并在训练过程中引入了衰减距离因子。距离因子的取值,综合考虑了各神经元与当前神经元空间位置的因素。对字符图像识别的实验表明,新方法学习和识别的性能都非常优秀。

关键词:模式识别; Hopfield 网络; 学习算法

中图分类号: TP301.6

文献标识码: A

文章编号: 1673-629X(2009)03-0077-03

Learning Using Distance Based Training Algorithm for Pattern Recognition

YANG Ying, LI Chao-feng

(Jiangnan University, Wuxi 214122, China)

Abstract: A modular approach for improving the performance of 2-D Hopfield neural network is presented in this paper. The approach is inspired by biological visual perception phenomenon. The training method introduces a decaying distance factor into the Hebbian learning rule for image processing applications. The value of the distance factor varies based on the spatial location of the neurons with respect to the neuron under consideration. Experiments performed with character images show that the new approach can learn and recognize patterns very effectively.

Key words: pattern recognition; Hopfield network; learning algorithm

0 引 言

模式识别是相联存储器的主要应用方向。主要任务是在输入模型是有噪声的训练模型时,能输出清晰的、无噪声的模型^[1]。Hopfield 模型使得相联存储器成为神经网络研究中的主要方向,它利用 Kohonen 算法描述相联矩阵存储器的起始过程。神经网络可以通过例子来进行学习。模块化网络被赋予了特殊使命,在这种网络中,只有相邻的神经元连接在一起。模块化网络是模仿大脑中的信息处理模型构建的。理论研究表明,模块化网络中每个神经元的能量存储能力比非模块化网络大得多^[2~4]。

模块化网络采用全连接网络模式,可以通过减少权重值、保持最有效的连接组织等方式来达到网络的模块化。一个模块可以同时与其它相邻模块进行通话。一些网络(如 Hopfield 网络)假设所有节点都是互

相连接的。在图像处理的应用中发现,邻近像素对一个节点的影响要比更远一些的像素的影响大得多。因此,二维 Hopfield 网络在图像处理中的应用可以通过合并衰变权重因数来进行改进,衰变权重因数减少了更远处神经元的连接权值^[2,4]。

利用 Hebbian 学习法验证了在二维 Hopfield 网络中像素点离的越远连接权值影响越小的结论。广义模块化系统是相邻神经元组成的一个模块,所有模块都与其他模块相联。在 Hebbian 学习法中应用了空间衰减距离,以减少来自远处神经元对本神经元的影响。可以证明,应用距离训练算法减少更远处神经元的连接权值能够改善网络的收敛和学习能力。

1 网络模型

对于一个普通的有 $N \times M$ 个神经元的二维 Hopfield 网络, w_{ijkl} 用表示第 k 行 l 列神经元到第 i 行 j 列神经元的连接权值,其值可以用下式计算^[5]:

$$w_{ijkl} = \sum_{s=1}^P x_{ij}^s x_{kl}^s \quad (1)$$
$$1 \leq i, k \leq N; 1 \leq j, l \leq M$$

收稿日期: 2008-06-03

作者简介: 杨 盈(1980-),女,硕士研究生,研究方向为人工智能与模式识别;李朝峰,博士后,副教授,研究方向为人工智能与模式识别。

其中 $x_{nm}^s \in \{-1, +1\}$ 是第 s 个训练模型中网络第 m 行 n 列的输入值, P 是用于训练的模型的数目。网络的输出网络可用下式计算^[5]:

$$\text{Net}_{ij} = \sum_{k=1}^N \sum_{l=1}^M w_{ijkl} x_{kl} \quad (2)$$

$$1 \leq i \leq N, 1 \leq j \leq M$$

其输出值由下式得出^[5]:

$$o_{ij} = f(\text{Net}_{ij}) = \begin{cases} +1 & \text{Net}_{ij} \geq 0 \\ -1 & \text{Net}_{ij} < 0 \end{cases} \quad (3)$$

$$1 \leq i \leq N, 1 \leq j \leq M$$

由式(2)可看出,每个神经元都由一定的连接权值与其他神经元相连。要实现距离学习方法需要更复杂的反馈方法,而这一点在式(1)~(3)中没有体现出来。Hopfield 网络可以通过加入权重系数影响因子 D 来进行改进,相对的值也依赖于距离,越远处的神经元对本神经元的影响越小。这就减小了远处神经元对本神经元的连接权值。也就是说可以通过加入 D 值来改进权值^[5]:

$$w_{ijkl} = \sum_{s=1}^P x_{ij}^s x_{kl}^s D_{ijkl} \quad (4)$$

$$1 \leq i, k \leq N; 1 \leq j, l \leq M$$

其中 D_{ijkl} 是神经元 (k, l) 到神经元 (i, j) 的距离。通过因子 D 来对每两组相连的神经元进行区分。

1.1 距离学习法

为了确定连接线路以得到期望的结果,可以从生物系统中得到启示。用一个几何特征模块来描述视觉神经模块。在视觉神经模块中发现了短程反馈系统,这在 Hopfield 网络中也存在。在一个图像处理程序中,将输入的大小为 $N \times M$ 的图像分为大小为 $n \times m$ 的子块,并将每一个子图像应用到一个大小为 $(N \times M)/(n \times m)$,与其他模块相连的子网络模块中。可以发现一个 $n \times m$ 子图与它在 $N \times M$ 图中多数相邻的其他子图有相近的亮度值。由于各相邻块像素的亮度值相近,可以用下式表示尺寸为 $n \times m$ 的细胞的距离因子 D :

$$D_{ijkl} = 2^{-\alpha\eta} \quad (5)$$

其中, η 由下式给出:

$$\eta = \max \left\{ \left| \left\lfloor \frac{i-1}{n} \right\rfloor - \left\lfloor \frac{k-1}{n} \right\rfloor \right|, \left| \left\lfloor \frac{j-1}{m} \right\rfloor - \left\lfloor \frac{l-1}{m} \right\rfloor \right| \right\} \quad (6)$$

α 是表示模块间连接强度的参数, $\alpha \geq 1$ 。 η 是 (i, j) 神经元和 (k, l) 神经元的距离。每一个神经元块和其他神经元块相连接,这种连接形成了一种循环回路。可以通过邻近区域中的相似模块的存在来证明在一个大的图像中小空间模块是合理存在的。通过对整

个图像的透视法分析之后,可以减少网络训练的数量。中心模块与其相邻模块交互连接的减少使得神经元学习过程中的有害连接也大大减少。训练算法中 D 的一个主要优势就是,所有权值处于 D 范围外的点都不需要考虑也不参加网络的训练。这就减少了需要训练的权值的量也大大降低了训练时间。

1.2 稳定性和收敛性

基于距离算法的能量函数可以用下式表示^[5]:

$$E = -\frac{1}{2} \sum_{i,j} \sum_{k,l} w_{ijkl} x_{ij} x_{kl} D_{ijkl} \quad (7)$$

神经元 (a, b) 的能量值可用下式表示^[5]:

$$E = -\frac{1}{2} \sum_{\substack{i,j \\ i \neq a \\ j \neq b}} \sum_{\substack{k,l \\ k \neq a \\ l \neq b}} w_{ijkl} x_{ij} x_{kl} D_{ijkl} - \frac{1}{2} \sum_{i,j} w_{ijab} x_{ij} x_{ab} D_{ijab} - \frac{1}{2} \sum_{i,j} w_{abij} x_{ab} x_{ij} D_{abij} \quad (8)$$

因为 $w_{ijkl} D_{ijkl} = w_{klji} D_{klji}$, 所以后两项可以合并为:

$$E = -\frac{1}{2} \sum_{\substack{i,j \\ i \neq a \\ j \neq b}} \sum_{\substack{k,l \\ k \neq a \\ l \neq b}} w_{ijkl} x_{ij} x_{kl} D_{ijkl} - \sum_{i,j} w_{ijab} x_{ij} x_{ab} D_{ijab} \quad (9)$$

通过分析可知,前一项是个常量,可记为 C ,则有:

$$E = C - \sum_{i,j} w_{ijab} x_{ij} x_{ab} D_{ijab} \quad (10)$$

能量的变化值 ΔE 可用下式计算得出^[5]:

$$\begin{aligned} \Delta E = E^{\text{new}} - E^{\text{old}} &= \left(C - \sum_{i,j} w_{ijab} x_{ij} x_{ab}^{\text{new}} D_{ijab} \right) - \\ &\left(C - \sum_{i,j} w_{ijab} x_{ij} x_{ab}^{\text{old}} D_{ijab} \right) = - \sum_{i,j} w_{ijab} x_{ij} x_{ab}^{\text{new}} D_{ijab} + \\ &\sum_{i,j} w_{ijab} x_{ij} x_{ab}^{\text{old}} D_{ijab} = - (x_{ab}^{\text{new}} - x_{ab}^{\text{old}}) \sum_{i,j} w_{ijab} x_{ij} D_{ijab} \quad (11) \end{aligned}$$

用 Δx_{ab} 代替上式中的 $(x_{ab}^{\text{new}} - x_{ab}^{\text{old}})$, 代入式(3), 则上式可简化为:

$$\Delta E = -\Delta x_{ab} \text{Net}_{ab} D_{ijab} \quad (12)$$

对上式进行分析得出:

1) 如果 $\text{Net}_{ab} \geq 0$, 则输出值保持 1, 或由 -1 变为 1。即 $\Delta x_{ab} \text{Net}_{ab} D_{ijab} \geq 0$, 所以有 $\Delta E \leq 0$ 。

2) 如果 $\text{Net}_{ab} < 0$, 则输出值保持为 -1, 或由 1 变为 -1。即 $\Delta x_{ab} \text{Net}_{ab} D_{ijab} \geq 0$, 所以有 $\Delta E \leq 0$ 。

因此可以得出,在神经元更新过程中, $\Delta E \leq 0$, 即能量递减或保持不变。

2 神经网络模块的分析

本节提出一个新的理论模型。分析了网络的运行方式,并给出了网络运行速度和学习能力的分析。

2.1 速度

由于连接权重数量的减少,使得新的模块化网络在训练和记忆方面比传统的单片模块网络要快得多。假设网络由 $N \times M$ 个神经元组成,每个用于训练的子

块的大小为 $n \times m$, 则神经元 NumWeight 值的范围为:

$$(N \times M \times n \times m) \leq \text{NumWeight} \leq (NM)^2$$

连接权值可以减少, 因此在网络模块中连线的数量要比普通 Hopfield 神经网络中少得多。由于权值数量少, 也就减少了训练和记忆的时间, 这就是说提高了学习和记忆的速度。

2.2 学习

Hebbian 学习法定义如下^[6]:

$$w_{ij} = \sum_{s=1}^P x_i^s x_j^s$$

其中, P 为训练的模型数, 新的权值是旧权值与新图像中权值改变量的和:

$$w_{ij}^{\text{new}} = w_{ij}^{\text{old}} + \Delta w_{ij}^s \quad (13)$$

其中 Δw_{ij}^s 由下式算得:

$$\Delta w_{ij}^s = x_i^s x_j^s \quad (14)$$

由此可得权矩阵 W 为:

$$W = \sum_{s=1}^P X^s X^{sT} \quad (15)$$

接下来分析网络的连接性能。假设 Hebbian 学习法是完善的, 网络的输入为图像 X^k , 则有:

$$f(X^k W) = X^k \quad (16)$$

其中, $f(\cdot)$ 是一个阈函数, 可由下式计算得出:

$$f(x) = \begin{cases} +1 & x \geq 0 \\ -1 & x < 0 \end{cases} \quad (17)$$

可用下式分析网络的连接性能:

$$\begin{aligned} X^k W &= X^k \sum_{s=1}^P X^s X^{sT} = \sum_{s=1}^P X^k X^s X^{sT} \\ &= X^k X^k X^{kT} + \sum_{s=1, s \neq k}^P X^k X^s X^{sT} \\ &= \|X^k\|^2 X^k + \sum_{s=1, s \neq k}^P X^k X^s X^{sT} \end{aligned} \quad (18)$$

$\|X^k\|^2 X^k$ 与图像直接相关, 将给出训练图像的记忆结果。 $\sum_{s=1, s \neq k}^P X^k X^s X^{sT}$ 是一个亮度干扰项。由上面的等式可以看出, 如果训练项是正交的, 结果将为 0, 即:

$$X^k X^s T = \|X^k\| \|X^s\| \cos(X^k, X^s T) = 0 \quad (19)$$

由距离学习算法的定义式(5)和(6)可以知道, 可以通过距离因数来大大减小亮度干扰项。这也使得网络的学习能力增强了。

3 仿真及其结果

通常用存储容量和噪声耐量来衡量相联存储器的性能。相对的, 我们更关注于网络的噪声耐量。图 1 (a)~(c) 分别是 26 个字符的原始图像、加噪图像和识别图像^[7]。



图 1 26 个字符图像

通过检查识别结果知道新的网络学习算法比原有的算法优秀。图 2 给出了传统 Hopfield 网络用于识别字符图像的模块大小分别为 2×2 、 4×4 、 8×8 、 32×32 时图像噪声为 10%、20%、30%、40%、50% 的识别率。可以看出, 对于模块大小为 2×2 的情况, 随着噪声的增加识别率降低。这是由于局部极小值少, 所以随着噪声的增加识别的可能性降低。而在 8×8 网络模型中比 4×4 网络模型存在更多的局部极小值点, 这就使得在 8×8 网络模型中存在更多偏离局部极小值的可能。当图像为非正交时, 传统的 Hopfield 网络的识别率为 0。

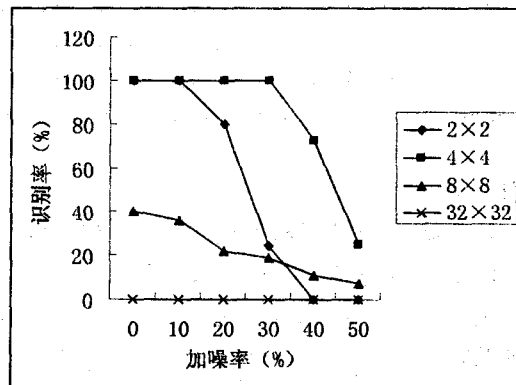


图 2 传统 Hopfield 网络的识别性能

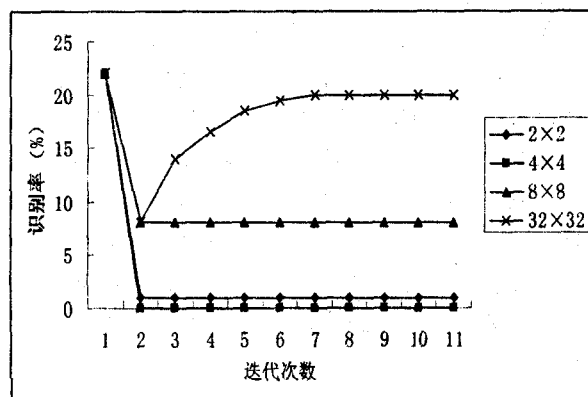


图 3 基于距离算法模块网络的收敛性
通过对新网络收敛性能的考察, 发现比传统网络

(下转第 83 页)

增加了复杂度等一些不完善的问题,还需日后进一步的深入研究。

参考文献:

- [1] 沈波,张世永,钟亦平.无线传感器网络分簇路由协议[J].软件学报,2006,17(7):1588-1600.
- [2] 金骥,徐昌庆,葛颖君.无线传感器网络基于类的 LEACH 路由算法研究[J].计算机应用与软件,2006,23(11):137-138.
- [3] 李秉智,赵娜.基于无线传感器网络的 LEACH 算法的改进[J].传感器与仪器仪表,2006,23(8):153-155.
- [4] 吴臻,金心宇.无限传感器网络的 LEACH 算法的改进[J].传感技术学报,2006,19(1):34-36.
- [5] Kim J M, Joo H K, Hong S S. An efficient clustering scheme through estimate in centralized hierarchical routing protocol [C]//International Conference on Hybrid Information Technology. Washington, DC, USA: IEEE Computer Society, 2006:145-152.
- [6] Chang R S, Kuo C J. An energy efficient routing mechanism for wireless sensor networks[C]//Proceedings of the 20th International Conference on Advanced Information Networking and Applications. Washington, DC, USA: IEEE Computer Society, 2006:308-312.
- [7] 李利民,李建中,陈渝.无限传感器网络[M].北京:清华大学出版社,2005:95-96.
- [8] Heinzelman W. Application-Specific protocol architectures for wireless networks [D]. Boston: Massachusetts Institute of Technology, 2000.
- [9] Heinzelman W R, Chandrakasan A, Balakrishnan H. An Application-Specific Protocol Architecture for Wireless Microsensor Networks[J]. IEEE Transactions on Wireless Communications, 2002,1(4):660-670.
- [10] Heinzelman W R, Chandrakasan A, Balakrishnan H. Energy-Efficient Communication Protocol for Wireless Microsensor Networks[C]//In: the proceedings of the Hawaii International Conference on System Sciences. Maui, Hawaii: [s. n.], 2000.

(上接第 76 页)

到底层实现之间跨度太大的问题。

参考文献:

- [1] Gupta A. Formal Hardware Verification Methods: A Survey [J]. Formal Methods in System Design, 1992(1):151-238.
- [2] Samman G A, Schmaltz J, Toma D, et al. TheoSim: combining symbolic simulation and theorem proving for hardware verification[C]//In: Proc of the Integrated Circuits and Systems Design. [s. l.]: [s. n.], 2004:60-65.
- [3] 边计年,薛宏熙,苏明,等.数字系统设计自动化[M].北京:清华大学出版社,2005.
- [4] Touati H J, Savoj H, Lin B, et al. Implicit state enumeration of finite state machines using BDDs[C]//Proceedings of International Conference on Computer-Aided Design. Santa Clara: [s. n.], 1990:130-133.
- [5] Huang S Y, Cheng K T, Chen K C, et al. Aquila: An Equivalence Checking System for Large Sequential Designs[J]. IEEE Transactions on Computers, 2000,49(5):443-464.
- [6] 方敏,张雅顺,李辉.混合系统的形式验证方法[J].系统仿真学报,2006,18(10):2921-2928.

(上接第 79 页)

的速度提高很多。图 3 给出了网络用于识别字符图像的模块大小分别为 2×2 、 4×4 、 8×8 、 32×32 时,图像噪声为 30% 的情况下网络的收敛性。通过比较可以知道,新网络通过 2 次迭代就可以达到传统网络 10 次迭代的效果。

4 结束语

提出了一种利用距离学习算法来减少 Hopfield 网络连接权值的新方法。

仿真结果证实了数据分析的结论,与传统 Hopfield 网络相比,新方法在复杂度、速度和学习能力上都有改善。距离因子的属性使得它可以滤除一些远处神经元的连接权值,这就使网络无论在软件还是硬件的执行过程中减少了复杂性。

参考文献:

- [1] de Sa Marques J P. 模式识别——原理、方法及应用[M]. 吴逸飞译. 北京:清华大学出版社,2002.
- [2] Kuhlmann P, Garces R, Eissfeller H. A dilution algorithm for neural networks[J]. Journal of Physics, 1992(25):593-598.
- [3] Gazzaniga M S. Organization of the human brain[J]. Science, 1989(245):947-952.
- [4] 韩力群. 人工神经网络理论、设计及应用[M]. 北京:化学工业出版社,2002.
- [5] Hopfield J J. Neural networks and physical systems with emergent collective computational abilities[J]. Proceedings of the National Academy of Science, 1982(79):2554-2558.
- [6] Hebb D O. The organization of behavior: a neuropsychological theory[M]. New York: Wiley, 1949.
- [7] 孙兆林. Matlab 6. x 图像处理[M]. 北京:清华大学出版社,2002.