

小世界体系的多对多核联想记忆模型及其应用*

陈 蕾^{1,2}, 陈松灿¹⁺, 张道强^{1,3}

¹(南京航空航天大学 计算机科学与工程系,江苏 南京 210016)

²(南京邮电大学 计算机科学与技术系,江苏 南京 210003)

³(计算机软件新技术国家重点实验室(南京大学),江苏 南京 210093)

Small World Structure Inspired Many to Many Kernel Associative Memory Models and Their Application

CHEN Lei^{1,2}, CHEN Song-Can¹⁺, ZHANG Dao-Qiang^{1,3}

¹(Department of Computer Science and Engineering, Nanjing University of Aeronautics & Astronautics, Nanjing 210016, China)

²(Department of Computer Science and Technology, Nanjing University of Posts & Telecommunications, Nanjing 210003, China)

³(State Key Laboratory for Novel Software Technology (Nanjing University), Nanjing 210093, China)

+ Corresponding author: Phn: +86-25-84896481 ext 12106, E-mail: s.chen@nuaa.edu.cn, <http://parnec.nuaa.edu.cn>

Chen L, Chen SC, Zhang DQ. Small world structure inspired many to many kernel associative memory models and their application. *Journal of Software*, 2006,17(2):223–231. <http://www.jos.org.cn/1000-9825/17/223.htm>

Abstract: Kernel method is an effective and popular trick in machine learning, and small world network is a common phenomenon which exists widely in social fields. In this paper, by introducing them into Hattori et al's multi-module associative memory for many-to-many associations ((MMA)²), a unified framework of small world structure inspired many-to-many kernel associative memory models (SWSI-M²KAMs) is proposed. The SWSI-M²KAMs not only can store patterns online without more iteration steps, but also extend the range of the processed intelligent information. More importantly, the SWSI-M²KAMs framework can develop more new many-to-many associative memory models by selecting different kernel functions and reduce models' configuration complexity by using the sparse small world architecture. Finally, computer simulations demonstrate that the constructed models have good performance on many-to-many associative memory.

Key words: neural network; many to many associative memory; kernel trick; small world theory; intelligent information processing

摘 要: 运用机器学习中新颖的核方法和社会网络中广泛存在的小世界现象,对 Hattori 等人提出的多模块多对多联想记忆模型(multi-module associative memory for many-to-many associations,简称(MMA)²)进行了改进,构建出了一个基于小世界体系的多对多核联想记忆模型框架(small world structure inspired many to many kernel

* Supported by the National Natural Science Foundation of China under Grant Nos.60271017, 60505004 (国家自然科学基金); the Jiangsu Natural Science Foundation of China under Grant No.BK2004001 (江苏省自然科学基金); the Jiangsu Planned Projects for Postdoctoral Research Funds (江苏省博士后科研资助计划)

Received 2005-02-28; Accepted 2005-07-11

associative memory models,简称 SWSI-M²KAMs).该框架不仅克服了原模型不能联机提交训练样本且迭代次数过多的缺陷,而且拓展了原模型的智能信息处理范围.更重要的是,通过核函数的选取,该模型框架可以衍生出更多新的多对多联想记忆模型,而且,由于小世界结构的引入,在一定程度上简化了模型的结构复杂度.最后的计算机模拟,证实了新的模型具有良好的多对多联想记忆功能.

关键词: 神经网络;多对多联想记忆;核方法;小世界理论;智能信息处理

中图分类号: TP18 文献标识码: A

联想记忆模型是人工神经网络研究的一个重要分支.它可以模仿人脑处理不完整、不准确、甚至非常模糊的信息,并能够进行联想记忆,因而具有很大的潜在应用价值,如图像恢复、图像和语音处理、模式识别、分类等.在联想记忆的研究领域中,研究人员已经提出了数十种有代表性的学习算法,这些算法实现的都是一对一或者多对一联想,联想方式分别涉及到单向、双向和多向联想.但是,适用于智能信息处理的多对多联想记忆模型却一直鲜有研究.而由多个事件一次联想到与之相关的多个事件,是人脑最普通的功能之一,也是实现智能信息处理的关键.对于多对多联想而言,一个最关键的问题是如何解决待存储样本中公共项的影响,也就是一对多映射的问题,因为对传统的联想记忆学习算法来说,公共项的存在会导致一些非常复杂的未知模式出现.

迄今为止,先后有 4 种较为典型的多对多联想记忆模型被提出出来^[1-5].但是,它们都不同程度地存在着一些不足和缺陷.例如:Hirai 等人^[1]提出的模型结构非常复杂,并且涉及到许多未定参数;文献[2,3]提出的两种方法,由于均采用了 Hebbian 学习算法,从而导致这两种模型的存储容量都相当低.后来,Hattori 等人^[4,5]在多对多联想记忆的研究中取得了突破性的进展,提出了具有多模块结构的多对多联想记忆模型(multi-module associative memory for many-to-many associations,简称(MMA)²).由于采用了新的交集学习算法,并且利用了扩频通信中的伪噪声编码理论,引入了模式分量的地址表示,不仅克服了公共项带来的不利影响,在存储容量上得到了较大的提高,而且首次把它应用到智能信息处理中,显示出了良好的应用前景.

尽管如此,(MMA)² 仍然存在以下不足:(1) (MMA)² 模型所采用的交集学习算法,使得该模型的训练模式不能联机提交,即每增加一个模式就必须重新迭代计算权值矩阵,而且迭代次数随着所存储的模式数急剧增加;(2) (MMA)² 模型仅能处理二值模式,亦即,其对多值情形失效,而很多多值情形是现实存在的;(3) (MMA)² 模型未能在理论上保证所存储的模式能得到正确回忆.

在本文中,我们借鉴(MMA)² 模型的多模块结构构建思想,通过引用机器学习中新颖的核方法^[6]和社会网络中广泛存在的小世界理论^[7],构建了一个基于小世界体系的多对多核联想记忆模型框架(small world structure inspired many to many kernel associative memory models,简称 SWSI-M²KAMs).SWSI-M²KAMs 模型不仅克服了(MMA)² 模型的上述 3 点不足,而且提出了一个统一框架,通过核函数的选取,可以获得更多新的多对多联想记忆模型.同时,由于稀疏的小世界网络结构的引入,在一定程度上简化了模型的结构复杂度,这一点对于模型的电路实现尤为重要.最后,计算机模拟证实了 SWSI-M²KAMs 模型具有良好的多对多联想记忆功能.

1 多对多联想

传统的联想记忆模型,无论它的联想方式是单向、双向还是多向,实现的都只能是一对一或者多对一的映射,无法实现一对多映射.而要实现多对多联想,就必须使模型具有一对多映射的基本功能.从联想方式来看,多对多联想可分为双向多对多联想和多向多对多联想.其中,双向多对多联想处理的对象为二元模式集,例如:简单的语义网络如(苹果,甜味)、(苹果,红色)、(苹果,水果)、(草莓,红色)、(草莓,水果)、(水果,香蕉)、(水果,桃子)等.当输入(?,红色)时,要求输出(苹果,红色)和(草莓,红色);而当输入(苹果,?)时,要求输出(苹果,甜味)、(苹果,红色)、(苹果,水果).这些看似简单的联想功能,由于涉及到一对多映射,在一般的双向联想记忆模型中是难以实现的.

除了上述的双向多对多联想以外,真实世界中的智能信息处理要求的是多向多对多联想.人脑中存储的多向多对多关系的一个典型例子,我们可以简化为如下三元模式集加以说明:(A₁,B₁,C₁),(A₁,B₂,C₂),(A₁,B₂,C₃),

(A_2, B_2, C_4) . 其中的 A_1, B_1, C_1 等字母可以代表任意的字符、表格或者图像等, 当输入 $(A_1, B_2, ?)$ 时, 要求输出 (A_1, B_2, C_2) 和 (A_1, B_2, C_3) ; 而当输入 $(?, B_2, ?)$ 时, 要求输出 $(A_1, B_2, C_2), (A_1, B_2, C_3), (A_2, B_2, C_4)$.

如果把上述的三元模式 (A, B, C) 看成一维向量 $|A|B|C|$, 那么, 上述的三元模式集也可以存储在单向联想记忆模型中, 但是, 当仅输入公共项 (例如 $(?, B_2, ?)$) 时, 该模型却不可能输出 3 个相应的正确的回忆项, 这也正是传统的联想记忆模型的局限所在. 而 Hattori 等人提出的多模块结构则很好地解决了这个问题, 使得传统的联想记忆模型具备了一对多映射的功能.

2 核双向联想记忆模型框架(KBAMs)

核方法是近年来机器学习领域研究的热点之一. 它的基本思想是: 通过把数据映射到高维特征空间来增加传统的线性学习器的计算能力. 一个关键技巧是用核函数替换内积, 从而使线性算法变成非线性. 由满足 Mercer 定理^[8]的核函数可以诱导出从输入空间到高维特征空间的隐含映射. 在高维空间中, 特征向量的内积可以通过核函数用低维空间中的输入向量直接计算得到, 从而避免了维数灾难 (curse of dimensionality), 使得计算量并没有随着维数升高而增加很多. 这种思想已经先后被成功地运用到支持向量机 (SVMs)^[6]、核模糊 C 均值 (KFCM)^[9]、核主分量分析 (KPCA)^[10] 以及核 Fisher 判别^[11] 上. 本文将利用上述思想去改造传统的 BAM 模型^[12], 得到核双向联想记忆模型 (kernel bidirectional associative memory models, 简称 KBAMs) 框架.

与原始 BAM 的两层网络结构不同, KBAMs 由 3 层结构组成, 除了输入层 $X=(x_1, x_2, \dots, x_n)$ 和输出层 $Y=(y_1, y_2, \dots, y_p)$ 之外, 还多了一个隐层. 隐层的神经元个数等于存储的模式对个数 M , 其功能是从 X 到 Y 方向计算核函数 $K(X_i, X)$ 或从 Y 到 X 方向计算核函数 $K(Y_i, Y)$. 设 $(X_i, Y_i) (i=1, \dots, M)$ 为一组待存储的输入输出模式对, 其中 $X_i=(x_{i1}, x_{i2}, \dots, x_{in}), Y_i=(y_{i1}, y_{i2}, \dots, y_{ip})$, 且所有模式分量的取值范围为 $\{1, 2, \dots, L\}$. KBAMs 的回忆规则为

$$Y' = H \left[\frac{\sum_{i=1}^M Y_i K(X_i, X)}{\sum_{i=1}^M K(X_i, X)} \right], \quad X' = H \left[\frac{\sum_{i=1}^M X_i K(Y_i, Y)}{\sum_{i=1}^M K(Y_i, Y)} \right] \quad (1)$$

其中, $H(\cdot)$ 是矢量阶梯函数, 其在每个分量上的定义为

$$H(x_k) = \begin{cases} 1, & x_k < 1 \\ L, & x_k > D \\ \left[\frac{L}{D} x_k + 0.5 \right], & \text{其他} \end{cases} \quad (2)$$

这里, L 是阶梯函数级数, D 是阶梯函数间隔. 当 $D \rightarrow \infty, L \rightarrow \infty$ 且 $x_k > 0$ 时, $H(x_k) \approx x_k$.

定理 1. 对于核双向联想记忆模型 KBAMs, 如果对任意 X_i, X 和 Y_i, Y , 都有 $K(X_i, X) \geq 0$ 和 $K(Y_i, Y) \geq 0$, 则该模型是稳定的.

证明: 分别构造 X 和 Y 方向上的能量函数如下:

$$E_X(X, Y) = \sum_{i=1}^M \|X - X_i\|^2 K(Y_i, Y), \quad E_Y(X, Y) = \sum_{i=1}^M \|Y - Y_i\|^2 K(X_i, X).$$

先证明 E_X 在 X 状态改变的情况下是减少的. 设 (X, Y) 与 (X', Y') 分别是当前和下一个状态, 则两者的能量差为

$$\begin{aligned} \Delta E_X(X, Y) &= (\nabla E_X(X, Y))^T \cdot \Delta X = -2 \left[\sum_{i=1}^M (X_i - X) K(Y_i, Y) \right]^T (X' - X) \\ &= -2 \left[\sum_{i=1}^M K(Y_i, Y) \left[\frac{\sum_{i=1}^M X_i K(Y_i, Y)}{\sum_{i=1}^M K(Y_i, Y)} - X \right] \right]^T (X' - X) \\ &= -2 \left(\sum_{i=1}^M K(Y_i, Y) \right) \cdot \sum_{k=1}^n \left[\left(\frac{\sum_{i=1}^M x_{ik} K(Y_i, Y)}{\sum_{i=1}^M K(Y_i, Y)} \right) - x_k \right] (x'_k - x_k) \end{aligned} \quad (3)$$

其中, x_k, x'_k 和 x_{ik} 分别是 X, X' 和 X_i 的第 k 个分量. 令 $\sigma = \frac{\sum_{i=1}^M x_{ik} K(Y_i, Y)}{\sum_{i=1}^M K(Y_i, Y)} - x_k$, 下面分 3 种情形进行讨论:

1. 当 $-\frac{1}{2} \leq \sigma < \frac{1}{2}$ 时, 由式(1)和式(2)可知 $x'_k = x_k$, 有 $\sigma(x'_k - x_k) = 0$.
2. 当 $\sigma < -\frac{1}{2}$ 时, $x'_k < x_k$, 有 $\sigma(x'_k - x_k) > 0$.
3. 当 $\sigma \geq \frac{1}{2}$ 时, $x'_k > x_k$, 有 $\sigma(x'_k - x_k) > 0$.

综合上面 3 种情形, 并且由已知条件 $K(Y_i, Y) \geq 0$, 从而有 $\Delta E_X(X, Y) \leq 0$, 即当 X 的状态发生变化时, 能量函数的值是减小的.

类似地, $\Delta E_Y = E_Y(X, Y') - E_Y(X, Y) \leq 0$, 即能量函数的值也是减小的.

由已知条件易知, 能量函数 $E_X(X, Y)$ 和 $E_Y(X, Y)$ 是有下界的, 又因为 $\Delta E_X \leq 0, \Delta E_Y \leq 0$, 经过一系列演化之后, 网络停留在一个局部最小点上.

由此证明了 KBAMs 在同步更新下的稳定性. 又由式(3)可知, 在异步更新模式下, KBAMs 仍然是稳定的.

3 基于小世界体系的核自联想记忆模型框架(SWSI-KAMs)

全互连结构是联想记忆模型最普遍采用的互连方式, 在大规模的互连过程中, 所造成的复杂性无法控制. 同时, 全互连并不是人脑神经元的构成方式. 神经网络模型既然是对人脑记忆功能的模仿, 那么, 自然应该融入更多的生物特性. 有研究表明^[7,13], 人脑神经元的构成呈现出小世界网络的结构, 如图 1 所示, 即以大量的短程连接为主, 少量的长程连接(捷径)为辅的一种稀疏网络结构. 因此, 本文作者在文献[14]中构建了一种基于小世界体系的核自联想记忆模型(small world structure inspired kernel auto-associative memory models, SWSI-KAMs), 非常有效地简化了传统的自联想记忆模型的全互连结构, 并且在人脸识别中得到了应用. 下面我们详细说明 SWSI-KAMs 的结构.



Fig.1 Network connection topologies^[7]

图 1 网络互连拓扑结构^[7]

核自联想记忆模型实际上是前述 KBAMs 模型的特例, 但由于核自联想记忆模型中神经元的排列方式可以看作环形, 所以, 很容易引入稀疏的小世界体系结构对它进行改造. 而对于非环形的 KBAMs 模型, 其稀疏化改造还有待进一步的研究.

假设小世界网络由 n 个神经元组成, 神经元之间的连接由图 G 给出. 如果边 $\{i, j\} \in G$, 那么从神经元 i 到 j 存在一个连接. 即

$$D(i, j) = \begin{cases} 0, & \text{if } \{i, j\} \notin G \\ 1, & \text{if } \{i, j\} \in G \end{cases}$$

这里, D 是一个体现小世界结构的矩阵. 初始时, 网络是一封闭环(如图 1(a)所示), 每个神经元仅将其输出反馈给它的 $l = \alpha n$ 个最近邻, 这里, α 是网络的全局连接度(即实际连接占全互连连接的比例). 然后, 按照文献[7]中的方法, 以重连概率 p 遍历网络中的所有连接一次, 这样就形成了小世界网络结构(如图 1(b)所示).

SWSI-KAMs 模型可由如下的回忆规则来描述:

$$X'_j = H \left[\frac{\sum_{i=1}^M X_j^i \cdot k_j(\hat{X}^i, \hat{X})}{\sum_{i=1}^M k_j(\hat{X}^i, \hat{X})} \right],$$

其中, X'_j, X_j^i 分别表示向量 X', X^i 的第 j 个分量, $k_j(\hat{X}^i, \hat{X})$ 中的 \hat{X}^i, \hat{X} 分别如下计算:

$$\hat{X}^i = X^i \circ D(:, j); \hat{X} = X \circ D(:, j),$$

这里的运算符号 \circ 表示点乘, $D(:, j)$ 表示前述距离矩阵 D 的第 j 列. 这样一来, 核函数 $k_j(\hat{X}^i, \hat{X})$ 的计算只涉及到部分的神经元, 可以一定程度地降低全互连模型的复杂度.

4 基于小世界体系的多对多核联想记忆模型(SWSI-M2KAMs)

在这一节中, 我们将利用 KBAMs 和 SWSI-KAMs 算法代替(MMA)² 模型中的交集学习算法, 构建出一类基于小世界体系的多对多核联想记忆模型(SWSI-M²KAMs)的统一框架.

4.1 SWSI-M²KAMs模型的结构

SWSI-M²KAMs 模型依然采用了(MMA)² 模型的多模块结构, 如图 2 所示. 该模型由 4 层组成, 从下到上依次分为: 伪噪声编码层(pseudo-noise pattern layer, PN)、输入输出层(input/output layer, I/O)、预移位控制层(pre-shift-control layer, PS)和移位控制层(shift-control layer, SC). 其中, I/O 层和 PS 层包含多个模块, 模块数目的多少依赖于待记忆样本的性质, 由待记忆样本的模式分量数决定.

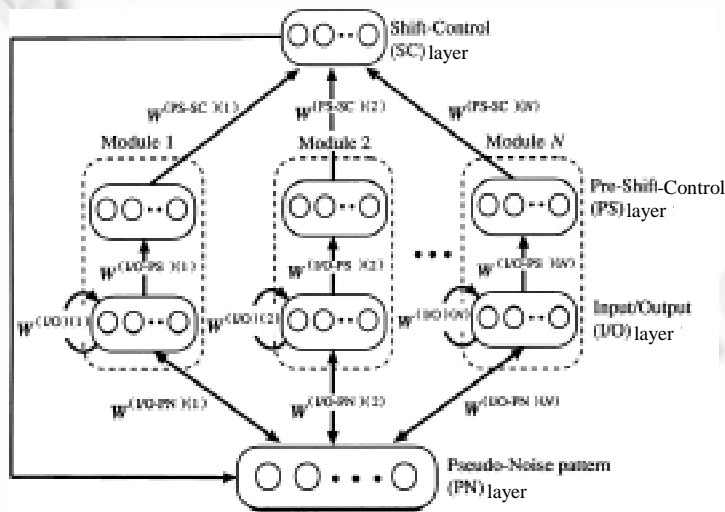


Fig.2 The structure of SWSI-M²KAMs^[4]
图 2 SWSI-M²KAMs 模型的结构^[4]

在 I/O 层, 每一个模块存储着所有待记忆模式的对应模式分量, 该层的神经元内部按小世界网络的方式连接, 实际上是一个稀疏的核自联想记忆模型. 采用 SWSI-KAMs 模型的回忆规则, 当有缺失、污损或含噪的模式分量输入 I/O 层时, SWSI-KAMs 模型的超强纠错功能可以复原出一个正确、完整的模式分量作为 I/O 层的输出, 从而进入下一步的从 I/O 层到 PS 层的联想. 此时, 从 I/O 层到 PS 层的联想采用的是 KBAMs 算法, 而 PS 层到 SC 层实现的则是一种逻辑运算. 从 SC 层到 PN 层则实现的是一种简单的移位运算(详见第 4.2 节). 最后, PN 层和 I/O 层之间仍然采用的是 KBAMs 算法.

4.2 SWSI-M²KAMs模型的联想策略

下面, 我们以包含公共项的三元模式集 $(A_1, B_1, C_1), (A_1, B_2, C_2), (A_1, B_2, C_3), (A_2, B_2, C_4)$ 为例来说明 SWSI-M²KAMs 模型实现多对多联想的策略:

首先,每一个待记忆模式被依序编号为:1— (A_1, B_1, C_1) ,2— (A_1, B_2, C_2) ,3— (A_1, B_2, C_3) ,4— (A_2, B_2, C_4) .然后,待记忆模式的每一个模式分量被翻译成地址表示向量,如 A_1 — $(1\ 1\ 1\ 0)$, B_1 — $(1\ 0\ 0\ 0)$, B_2 — $(0\ 1\ 1\ 1)$,地址向量中第 i 个元素为 1 或者 0,分别表示该模式分量是否在编号为 i 的待记忆模式的对应模块中出现过.当输入 $(A_1, B_2, ?)$ 时,只需考虑 A_1 和 B_2 对应地址向量的交集 $(1\ 1\ 1\ 0) \cap (0\ 1\ 1\ 1) = (0\ 1\ 1\ 0)$,从而由地址向量 $(0\ 1\ 1\ 0)$ 可知:输出项应分别为第 2,3 个待记忆模式 (A_1, B_2, C_2) 和 (A_1, B_2, C_3) .同时,为了适合 $SWSI-M^2KAMs$ 模型的编码,在联想记忆的过程中,每一个待记忆模式对应着一个 m 序列的伪噪声循环码向量.假设初始 m 序列循环码记为 PN_0 ,则 PN_0 向左平移 k 位后记为 PN_k ,用来表示第 k 个待记忆模式.例如:设初始 m 序列循环码 $PN_0=(1\ 1\ 1\ 0\ 1\ 0\ 0)$,则

$$\begin{aligned} (A_1, B_1, C_1) \quad PN_1 &= (1\ 1\ 0\ 1\ 0\ 0\ 1) & (A_1, B_2, C_2) \quad PN_2 &= (1\ 0\ 1\ 0\ 0\ 1\ 1) \\ (A_1, B_2, C_3) \quad PN_3 &= (0\ 1\ 0\ 0\ 1\ 1\ 1) & (A_2, B_2, C_4) \quad PN_4 &= (1\ 0\ 0\ 1\ 1\ 1\ 0) \end{aligned}$$

文献[15]详细介绍了有关伪噪声编码的理论.

在 PS 层,每一个模块存储的是多元模式分量的地址表示向量,从 I/O 层到 PS 层的联想,实际上就是从模式分量到它的地址表示向量的联想,遵循 KBAMs 模型的回忆规则,实现的仍然是一对一的映射,而且,KBAMs 模型能从理论上保证满足条件的模式集得到正确的联想.在每一个模块中,如果 I/O 层有输入,那么,该模块的 PS 层就可以输出一个地址表示向量;如果 I/O 层没有输入,那么,该模块的 PS 层则根据预先的设定,输出一个全 1 或者全 0 向量.接着,进入下一步的逻辑运算操作.

从 PS 层到 SC 层的逻辑运算操作较为简单,它们之间神经元的连接如图 3 所示,PS 层每个模块中同一位置的神经元都与 SC 层该位置的神经元相连.在 SC 层,每一个神经元通过实现逻辑乘或者逻辑加来异步改变其状态,当其中的一个神经元被激活时,它将限制其他神经元激活,从而保证每次只能有一个神经元被激活.被激活的神经元的地址正是初始 m 序列循环码 PN_0 的平移位数,平移信号被传送到 PN 层完成移位操作后,输出对应的 PN_k 向量.最后进行的一步是从 PN 层到 I/O 层的联想.PN 层的神经元与 I/O 层每一个模块的神经元各组成一个 KBAM 模型,从 PN_k 向量到模式分量的联想是一个多对一的映射,KBAM 模型可以非常好地实现这个功能.




Fig.3 The connection of neurons from PS layer to SC layer
图 3 从 PS 层到 SC 层的神经元连接

5 SWSI-M²KAMs 模型在多对多联想中的应用

在本文的实验仿真中,如表 1 所示的 9 个三元模式作为训练数据被存储在包含 3 个模块的 $SWSI-M^2KAMs$ 模型中.其中,I/O 层中第 1 个模块存储人物肖像,第 2 个模块存储水果,第 3 个模块存储景观图片,这些都是经过裁剪后的 60×60 的 256 色灰度图像,它们之间存在典型的多对多关系.在所用的 $SWSI-M^2KAMs$ 模型中,每一个模块的 I/O 层和 PS 层分别有 3 600 个和 9 个神经元,SC 层有 9 个神经元,PN 层有 15 个神经元,任意选取初始 m 序列循环码 $PN_0=[1\ 1\ 0\ 0\ 0\ 1\ 0\ 0\ 1\ 1\ 0\ 1\ 0\ 1\ 1]$.此外, $SWSI-M^2KAMs$ 模型中的核函数选用一个范数指数核 $k_{exp}(x, y) = \exp(-\sum_{i=1}^n |x_i - y_i|)$,I/O 层中 $SWSI-KAM$ 模型的连接参数分别设置为:全局连接度 $\alpha = 0.4$,重连概率 $p = 0.3778$.由于 I/O 层含有 3 600 个神经元,如果采用传统的全互连连接,则神经元模型的结构过于复杂,对于布线工艺的实现也有很大的难度,因此在这里引入稀疏的小世界网络结构,既简化了模型结构,又减少了计算耗费,具有较大的现实意义.

Table 1 The three-tuple sample sets for training and the corresponding numbers and codes

表 1 用于训练的三元模式集及其对应的编号和编码

Pattern number	Module 1	Module 2	Module 3	Pseudo-Noise code
1				100010011010111
2				000100110101111
3				001001101011110
4				010011010111100
5				100110101111000
6				001101011110001
7				011010111100010
8				110101111000100
9				101011110001001

仿真结果表明,SWSI-M²KAMs 模型不仅能正确实现表 1 的多对多联想,而且有较强的容噪能力,即使当输入项被噪声污染或者被马赛克遮挡后,依然能够准确回忆。下面分别给出了 3 种满足不同要求的多对多联想实验:

1. 单输入常规联想:输入污损的单个模式分量,要求联想出所有含有该模式分量的待记忆模式。

图 4 表明,即使输入的小孩肖像含有 25% 的椒盐噪声,SWSI-M²KAMs 模型仍然能够正确回忆出所有包含该肖像的第 1,2,6 号样本。

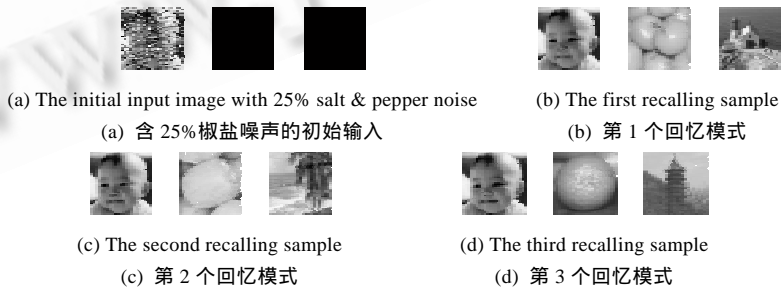


Fig.4 Routine association of single-input sample with salt & pepper noise

图 4 添加椒盐噪声后的单输入常规联想

2. 多输入交集联想:输入污损的两个模式分量,要求联想出同时含有这两个模式分量的待记忆模式。

图 5 表明,当同时输入含 0 均值、0.05 方差高斯噪声的猕猴桃和含 25% 椒盐噪声的海滩风景图片

时,SWSI-M²KAMs 模型正确回忆出了第 2,8 号样本.

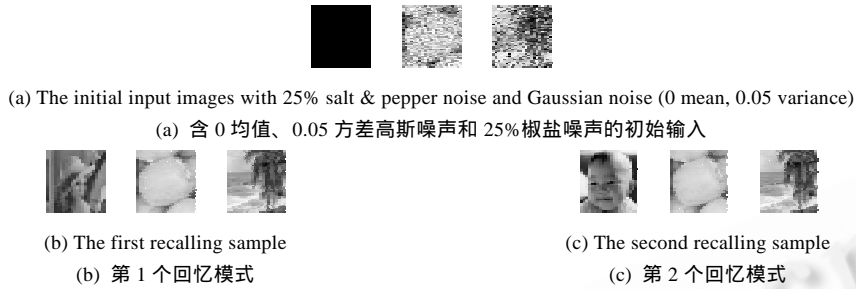


Fig.5 Intersection association of multi-input samples with Gaussian and salt & pepper noise

图 5 添加高斯噪声和椒盐噪声后的多输入交集联想

3. 多输入并集联想:输入污损和遮挡的两个模式分量,要求同时联想出分别含有这两个模式分量的所有待记忆模式.

图 6 表明,当同时输入含 0 均值、0.04 方差高斯噪声的塔和上遮挡 30%的橙子时,SWSI-M²KAMs 模型正确回忆出了分别含有塔和橙子的第 3,4,6,7,9 号样本.

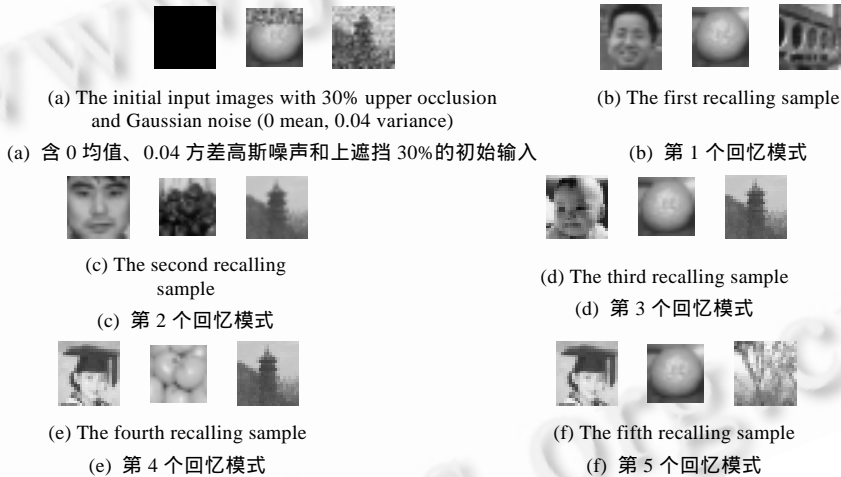


Fig.6 Union association of multi-input samples with gaussian noise and partly upper occlusion

图 6 添加高斯噪声和部分上遮挡后的多输入并集联想

6 结 论

本文通过运用核方法和小世界理论,构建了一个较 Hattori 的(MMA)²更加完善的多对多联想记忆模型统一框架:SWSI-M²KAMs.首先,SWSI-M²KAMs 具备和(MMA)²相同的下列特点:

- 1) 区别于传统的地址可寻址方式,联想记忆模型采用的是内容可寻址方式;
- 2) 能从缺失、污损的输入中正确回忆出所有的完整信息;
- 3) 不仅能处理多对多联想,而且可以通过改变移位控制层的逻辑运算和神经元被激活的方式来实现上下文和联合联想;

4) 信息分布式地存储于所有的神经元中,具备很强的鲁棒性能.

除此之外,SWSI-M²KAMs 模型还具备下列一些新的特点:

- 1) 拓展了智能信息处理范围,不仅能处理二值信息,而且能处理多值信息;
- 2) 采用新的学习算法不仅可以联机提交待记忆样本,而且无须重新迭代计算连接权值,节省了学习时间;

- 3) SWSI-M²KAMs 是一个模型框架,由于核函数选取的多样性,使得它囊括了一系列新的学习算法,从而使得针对不同的信息处理对象选取不同的学习算法成为可能;
- 4) 它能从理论上保证所有的满足条件的待记忆模式得到正确回忆;
- 5) 自联想记忆模型中引入稀疏的小世界网络体系,一定程度上简化了多对多联想记忆模型的结构.

致谢 在此,我们谨向对本文的工作给予支持和建议的同行表示诚挚的感谢.

References:

- [1] Hirai Y. Mutually linked HASP's a solution for constraint-satisfaction problem by associative processing. IEEE Trans. on Systems Man. & Cybernetics, 1985,15(3):432-442.
- [2] Ohsumi T, Kajiura M, Anzai Y. Multimodule neural network for associative memory. Systems and Computers in Japan, 1993, 24(13):98-108.
- [3] Hattori M, Hagiwara M, Nakagawa M. Improved multidirectional associative memory for training sets including common terms. In: Proc. of the IEEE and INNS Int'l Conf. on Neural Networks, Vol 2. Baltimore, 1992. 172-177.
- [4] Hattori M, Hagiwara M. Multimodule associative memory for many-to-many associations. Neurocomputing, 1998,19(1-3):99-119.
- [5] Hattori M, Hagiwara M. Associative memory for intelligent control. Mathematics and Computers in Simulation, 2000,51(3-4): 349-374.
- [6] Cristianini N, Shawe-Taylor J. An Introduction to Support Vector Machines And Other Kernel-Based Learning Methods. Cambridge: Cambridge University Press, 2000.
- [7] Watts DJ, Strogatz SH. Collective dynamics of 'small-world' networks. Nature, 1998,393(4):440-442.
- [8] Mercer J. Functions of positive and negative type, and their connection with the theory of integral equations. Trans. of the London Philosophical Society, 1909,209:415-446.
- [9] Zhang DQ, Chen SC. Clustering incomplete data using kernel-based fuzzy c-means algorithm. Neural Processing Letters, 2003, 18(3):155-162.
- [10] Scholkopf B, Smola AJ, Muller KR. Nonlinear component analysis as a kernel eigenvalue problem. Neural Computation, 1998, 10(5):1299-1319.
- [11] Mika S, Ratsch G, Weston J, Scholkopf B, Muller KR. Fisher discriminant analysis with kernels. In: Hu YH, Larsen J, Wilson E, Douglas S, eds. Proc. of the IEEE Neural Networks for Signal Processing Workshop. Madison: IEEE Press, 1999. 41-48.
- [12] Kosko B. Bidirectional associative memory. IEEE Trans. on SMC, 1988,18(1):49-60.
- [13] Achacoso TB, Yamamoto WS. AY's Neuroanatomy of C. elegans for Computation. Boca Raton: CRC Press, 1992.
- [14] Chen SC, Chen L, Zhou ZH. A unified SWSI-KAMs framework and performance evaluation on face recognition. Neurocomputing, 2005,68:54-69.
- [15] Simon MK, Omura JK, Scholz RA, Levitt BK. Spread Spectrum Communications. Rochville: Computer Science Press, 1985.



陈蕾(1975 -),男,江西宜春人,助教,主要研究领域为神经网络,模式识别.



张道强(1978 -),男,博士,讲师,主要研究领域为神经网络,模式识别,数据挖掘.



陈松灿(1962 -),男,教授,博士生导师,主要研究领域为神经计算,模式识别,机器学习.