

中图法分类号: TP18 文献标志码: A 文章编号: 1006-8961(2011)06-1022-08

论文索引信息: 王传栋, 陈蕾, 杨庚, 孙知信. GAM模型稳定性分析及其在图像识别中的应用[J]. 中国图象图形学报, 2011, 16(6): 1022-1029

GAM模型稳定性分析及其在图像识别中的应用

王传栋^{1),2)}, 陈蕾¹⁾, 杨庚^{1),2)}, 孙知信¹⁾

¹⁾(南京邮电大学 计算机学院, 南京 210003) ²⁾(南京邮电大学 计算机技术研究所, 南京 210003)

摘要: 多值指数关联联想记忆模型(MMECAM)是一种高存储容量的自联想记忆神经网络。在详细分析其优缺点的基础上,通过改进MMECAM模型的更新规则,首先提出一个新的高斯自联想记忆模型(GAM),然后通过定义简单的能量函数从理论上证明其同、异步方式下的稳定性,从而保证所存储的模式能最终成为GAM的稳定点;其次,通过引入一般相似性测度进一步提出广义GAM模型(G-GAMs)框架,使得GAM模型成为其特例;最后,将GAM模型应用于单样本图像识别,计算机模拟证实了该模型的鲁棒性能。

关键词: 联想记忆; 稳定性; 相似性测度; 神经网络; 图像识别

Stability analysis of Gauss Auto-associative Memory model and its application on image recognition

Wang Chuandong^{1),2)}, Chen Lei¹⁾, Yang Geng^{1),2)}, Sun Zhixin¹⁾

¹⁾(College of Computer, Nanjing University of Posts & Telecommunications, Nanjing 210003 China)

²⁾(Institute of Computer Technology, Nanjing University of Posts & Telecommunications, Nanjing 210003 China)

Abstract: Modified Multi-valued Exponential Correlation Associative Memory Model (MMECAM) is a neural network with higher storage capacity. In this paper, based on the analyses of the strengths and weaknesses of MMECAM, a new Gauss Auto-associative Memory Model (GAM) is proposed by modifying its update rule. Then the stability of the proposed GAM is tested in synchronous and asynchronous update modes with a defined energy function, which ensures that the learnt patterns become stable points of the GAM. Further, a framework of Generalized GAM models (G-GAMs) is presented by introducing general similarity measures which makes GAM become its special cases. Finally, the GAM is applied to image recognition from a single sample per image successfully, and the computer simulation results verify GAM's robust performance.

Keywords: associative memory; stability; similarity measure; neural network; image recognition

0 引言

联想记忆模型是人工神经网络研究的一个重要分支,具有信息分布式存储和内容可寻址回忆的重

要特点,能通过联想记忆补全不完整或缺损的输入,模拟人脑简单的思维功能,特别适用于处理含噪和不确定性的信息,可被广泛地应用于智能信息处理和模式识别等领域^[1]。迄今为止,联想记忆的研究已经取得丰硕成果,涉及自联想、双向联想、序列联想、

收稿日期:2010-04-06;修回日期:2010-06-18

基金项目:国家自然科学基金项目(60873231, 60973140);江苏省自然科学基金项目(BK2009425, BK2009426);江苏省高校自然科学基金项目(08KJB520006);南京邮电大学校科研基金项目(NY210043);江苏省高校研究生科研创新基金项目(CX10B_195Z)。

第一作者简介:王传栋(1971—),男,南京邮电大学计算机学院讲师,硕士。主要研究方向为神经网络与模式识别、数据仓库。E-mail: chdwang@njupt.edu.cn, chenlei@njupt.edu.cn。

多向联想和多对多联想等诸多联想模式,研究重点包括体系结构、学习算法和实际应用^[2]。

早在20世纪80年代初,著名物理学家Hopfield发表了两篇非常有影响的论文^[3-4],这两篇文章集中了前人的许多观点,如McCulloch和Pitts的神经网络模型^[5],Grossberg的改进模型^[6],Anderson的线性联想器模型^[7]以及Anderson、Silverstein、Ritz和Jones的盒中脑状态模型^[8]。Hopfield把这些重要思想结合起来并进行简明的数学分析(包括Lyapunov稳定性定理的应用),在此基础上提出了划时代的Hopfield联想记忆模型(HAM),不仅开创了联想记忆模型研究的先河,而且显示出神经网络的巨大潜力,对神经网络研究的复苏起了重要作用。尽管HAM模型的影响甚大,但分析表明其模型存在如下缺陷^[9]:1)存储容量极为有限,其上界仅为 $0.15n$ (n 为网络中神经元个数);2)神经元状态仅取二值,无法直接处理现实中的多值情形。为了提高HAM的存储容量,扩大它的处理范围,众多研究人员对此进行了长期不懈的研究,提出了许多新的自联想记忆模型。其中比较著名的有:1)高阶关联联想记忆模型^[10](HOCAM),HOCAM模型的存储容量较Hopfield模型有相当大的提高,渐近达到模式向量维数的多项式倍;2)潜能函数关联联想记忆模型^[11](PFCAM),PFCAM模型的存储容量达到模式向量维数的指数倍,相比之前的HOCAM模型的存储容量又有了较大提高,但是该模型存在一个最大的缺点是潜能函数的硬件实现非常复杂;3)指数关联联想记忆模型^[12](ECAM),ECAM模型的存储容量和PFCAM相当,也达到了指数级,更为重要的是,ECAM模型的电路实现比较容易,实际的测试结果表明,ECAM芯片执行的效果与ECAM理论模型的仿真结果一致,且能满足实时要求。虽然上述模型的存储容量得到了很大的提高,但是仅能处理二值模式。1993年,Chiueh和Goodman^[13]在前述ECAM的基础上又提出了一种多值指数关联联想记忆模型(MVECAM),该模型拓展了之前提出的自联想记忆模型的数值处理范围,不再局限于二值。虽然该模型在数值表示范围上取得了突破性的进展,但还很不完善。仿真结果表明,MVECAM很难在有限的迭代步数内进化到一个理想的稳定点,并且该模型缺乏收敛性证明和纠错性能的分析。1994

年,Chen和Kwong^[14]在MVECAM模型的基础上设计了一个新颖的阈值函数,提出改进的多值指数递归关联联想记忆模型(MEMRCAM),并且通过定义一个简单的能量函数证明该模型在有限步迭代之内一定收敛,MEMRCAM模型主要采用模式向量的内积相似性度量,适用于解决那些能表征为稀疏向量模式的实际问题,对非稀疏向量模式的存储和纠错性能比较一般,其特点将在第2节阐述。1996年,Wang等人用欧氏距离代替内积相似度,并且修改了多值阶梯阈值函数,把小于1的多值拓展成整数多值,进一步提出多值指数关联联想记忆模型(MMECAM)^[15],同时采用类似于MEMRCAM模型的能量函数分析法证明异步更新模式下的稳定性。其后,本文作者从体系结构方面对自联想记忆神经网络进行了更进一步的研究:首先,通过引入“小世界网络”的思想简化了自联想记忆模型的拓扑结构,提出了一个统一的SWSI-KAMs框架^[16];其次,提出了具有多模块结构的小世界体系多对多联想记忆模型^[17],该模型不仅克服了类似模型不能联机提交训练样本且迭代次数过多的缺陷,而且拓展了智能信息处理的范围。此外,作为联想记忆模型的另外一种表现形式,建立在形态学理论基础上的形态学联想记忆模型研究已日渐成为一个新的研究热点,中国学者在这方面的研究也卓有成效。2006年,吴、王两人提出了模糊形态联想记忆网络,研究了灰度图像的抗随机噪声问题,并应用于细胞图像的联想和识别^[18]。最近,冯又在详细分析现有的典型的形态学联想记忆模型的基础上,引入形态学联想记忆范式和算子,构建了一个基于格代数的形态学联想记忆框架^[19]。

另一方面,MMECAM模型是自联想记忆模型中非常重要的一类多值模型,双向联想、序列联想和多向联想等其他联想记忆模型的多值化拓展大多数采用类似的思想。但是,MMECAM模型的阶梯阈值函数存在缺陷,同时异步更新模式下的稳定性证明也不严谨,更为重要的是,由于联想记忆模型的同步更新效率远高于异步更新模式,因此证明同步更新模式下的稳定性就显得尤为重要。首先在详细分析MMECAM模型优缺点的基础上,通过完善其更新规则,提出一个囊括MMECAM模型的高斯自联想记忆模型(GAM),然后借助能量函数的收敛性从理论

上证明了其同、异步方式下的稳定性,从而保证了所存储的模式能最终成为 GAM 的稳定点;其次,通过引入一般相似性测度进一步提出一个广义 GAM 模型框架(G-GAMs),使得 GAM 模型成为其特例;最后,将 GAM 模型应用于单样本图像识别,计算机模拟证实了该模型的鲁棒性能。

1 高斯自联想记忆模型(GAM)

在介绍 GAM 模型之前,首先介绍 MEMRCAM 模型和 MMECAM 模型,详细分析这两种模型的区别和联系,阐述它们的优缺点。然后在此基础上提出 GAM 模型。

1.1 MEMRCAM 模型与 MMECAM 模型

定义 1 改进的内积指数多值递归关联联想记忆模型(MEMRCAM)

设 $\{X^i | X^i = (x_1^i, x_2^i, \dots, x_n^i)^T, i = 1, 2, \dots, M\}$ 是一组待记忆的模式, $X = (x_1, x_2, \dots, x_n)^T$ 为任一个输入模式, $X' = (x'_1, x'_2, \dots, x'_n)^T$ 是 X 的下一个状态,其中, $X^i, X, X' \in \left\{ -1, -\frac{L-1}{L}, \dots, -\frac{1}{L}, 0, \frac{1}{L}, \dots, \frac{L-1}{L}, 1 \right\}^n$, 如果自联想记忆模型具有如下状态更新规则:

$$X' = H \left(\frac{\sum_{i=1}^M X^i \cdot e^{\langle X^i, X \rangle}}{\sum_{i=1}^M e^{\langle X^i, X \rangle}} \right) \quad (1)$$

这里 $H(\cdot)$ 是矢量阶梯函数,其在每个分量上的定义为

$$H(u_k) = \begin{cases} -1 & u_k < -(2L-1)/(2L+1) \\ 1 & u_k \geq (2L-1)/(2L+1) \\ \frac{r}{L} & u_k \in \left[\frac{2r-1}{2L+1}, \frac{2r+1}{2L+1} \right) \\ r = 0, \pm 1, \pm 2, \dots, \pm(L-1) \end{cases} \quad (2)$$

则称该模型为 MEMRCAM 模型。

Chen 等人定义一个复杂的能量函数,利用凸函数的性质证明 MEMRCAM 模型的稳定性。该模型的特点是能直接处理介于 $[-1, 1]$ 区间的多值模式,但由于该模型使用的是内积形式来度量模式之间的相似度,因此适用于处理那些能表征为高维稀疏向量形式的模式,而对于那些适用于欧氏距离度量的高维非稀疏向量模式则效果较差。

如果我们把式(2)简化为式(3),很容易验证使

用简化阈值函数式(3)的 MEMRCAM 模型在迭代有限步后同样趋于稳定,存储容量和纠错性能没有发生变化:

$$H(u_k) = \begin{cases} -1 & u_k < -(2L-1)/(2L) \\ 1 & u_k \geq (2L-1)/(2L) \\ r/L & u_k \in \left[\frac{2r-1}{2L}, \frac{2r+1}{2L} \right), \\ r = 0, \pm 1, \pm 2, \dots, \pm(L-1) \end{cases} \quad (3)$$

不难发现式(3)等价于

$$H(u_k) = \begin{cases} -1 & u_k < -(2L-1)/(2L) \\ 1 & u_k \geq (2L-1)/(2L) \\ \lfloor u_k \rfloor + 1/(2L) & u_k \in \left[-\frac{2L-1}{2L}, \frac{2L-1}{2L} \right) \end{cases} \quad (4)$$

式中 $\lfloor u_k \rfloor (u_k \in [-(2L-1)/(2L), (2L-1)/(2L)])$ 表示集合 $\{(2r-1)/(2L) | r = 0, \pm 1, \pm 2, \dots, \pm L\}$ 中小于等于 u_k 的最大值。

定义 2 改进的多值指数关联联想记忆模型(MMECAM)

设 $\{X^i | X^i = (x_1^i, x_2^i, \dots, x_n^i)^T, i = 1, 2, \dots, M\}$ 是一组待记忆的模式, $X = (x_1, x_2, \dots, x_n)^T$ 为任一个输入模式, $X' = (x'_1, x'_2, \dots, x'_n)^T$ 是 X 的下一个状态,其中 $X^i, X, X' \in \{1, 2, \dots, L\}^n$, 如果自联想记忆模型具有如下状态更新规则。

$$x'_k = H \left(\frac{\sum_{i=1}^M x_k^i \cdot b^{-\|X^i - X\|^2}}{\sum_{i=1}^M b^{-\|X^i - X\|^2}} \right) \quad b > 1 \quad (5)$$

其中,

$$H(u_k) = \begin{cases} 1 & u_k < 1 \\ L & u_k > D \\ \lfloor (L/D) \cdot u_k + 0.5 \rfloor & \text{其他} \end{cases} \quad (6)$$

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 $u_k > 0$ 时, $H(u_k) = u_k$ 。则称其为改进的多值指数关联联想记忆模型。

MMECAM 模型的贡献在于:1)重新设计了一个阶梯阈值函数,拓展了自联想记忆模型的数值处理范围;2)改变了模式相似度量测度,使用欧氏距离代替内积,弥补了 MEMRCAM 模型未能有效处理高维非稀疏向量模式的问题;3)提供了一种构造多值联想记忆模型思路,其阈值函数被广泛用于双向联想、序列联想、多向联想和多对多联想的多值化

改造。MEMCAM模型同时存在诸多不足,表现在:1)阈值函数式(6)的定义并不严谨,其定义仅适用于 $L=D>1$ 的情形,事实上Wang在证明该模型的稳定性和性能仿真时也没有考虑 $L \neq D$ 的情形;2)Wang仅仅证明了MEMCAM模型在异步更新方式下的稳定性,而且很不幸的是,该证明并不严谨,我们很容易举出反例证明其关键步骤 $\Delta_{x_k} E(X) = \nabla_{x_k} E(X) \cdot \Delta x_k$ 并不成立;3)更新规则式(5)中的欧氏距离度量缺乏可选的参数调节,第5节的仿真实验结果将表明,参数的选取将显著影响模型的存储和纠错性能。

1.2 高斯自联想记忆模型

为了克服上述不足,在MEMRCAM模型与MEMCAM模型的基础上提出一个新的高斯自联想记忆模型GAM,第3节将从理论上证明GAM模型在同、异步方式更新下的稳定性。

定义3 高斯自联想记忆模型(GAM)

设 $\{X^i | X^i = (x_1^i, x_2^i, \dots, x_n^i)^T, i = 1, 2, \dots, M\}$ 是一组待记忆的模式, $X = (x_1, x_2, \dots, x_n)^T$ 为任一输入模式, $X' = (x_1', x_2', \dots, x_n')^T$ 是 X 的下一个状态,其中,

$$X^i, X, X' \in \{D/L, 2D/L, \dots, D\}^n$$

这里 L, D 均为正整数, D 表示模式分量的最大取值, L 是模式分量的级数,如果自联想记忆模型具有如下状态更新规则:

$$x_k' = H \left(\frac{\sum_{i=1}^M x_k^i \cdot b^{-\|X^i - X\|^2 / \sigma^2}}{\sum_{i=1}^M b^{-\|X^i - X\|^2 / \sigma^2}} \right) \quad b > 1, \sigma \neq 0 \quad (7)$$

式中 $H(\cdot)$ 是矢量阶梯函数,其在每个分量上的定义为

$$H(u_k) = \begin{cases} D/L & u_k < D/L \\ D & u_k > D \\ \left[\frac{L}{D} \cdot u_k + 0.5 \right] \cdot \frac{D}{L} & u_k \in \left[\frac{D}{L}, D \right] \end{cases} \quad (8)$$

或其等价形式

$$H(u_k) = \begin{cases} D/L & u_k < D/L \\ D & u_k > D \\ \lfloor u_k \rfloor + D / (2 \cdot L) & u_k \in [D/L, D] \end{cases} \quad (9)$$

式中 $\lfloor u_k \rfloor (u_k \in [D/L, D])$ 表示集合 $\{(2r-1) \cdot D / (2L) | r = 1, 2, \dots, L\}$ 中小于等于 u_k 的最大值。则称其为高斯自联想记忆模型。

分析GAM模型不难发现,当 $D=1$ 时,其阈值函数式(9)形式上等价于MEMRCAM模型的阈值函数式(4);同时,当 $\sigma=1, L=D$ 时,Wang的MEMCAM模型就是GAM模型的特例。

2 GAM模型稳定性分析

稳定性是联想记忆神经网络模型的一个重要属性,是纠错性能的重要体现。具有稳定性能的联想记忆神经网络能保证初始输入的含噪记忆样本经过有限次迭代后收敛到一个稳定点。为了证明GAM模型在同、异步方式更新下的稳定性,不妨先证明如下引理。

引理1 $\forall m, n \in R$, 如果 $b > 1$, 则

$$b^m - b^n \geq (\ln b) \cdot b^n \cdot (m - n)$$

证明:令 $f(x) = b^x$,显然,如果 $m = n$,则: $b^m - b^n = (\ln b) \cdot b^n \cdot (m - n) = 0$ 成立。如果 $m \neq n$,由于 $f(x)$ 在 $(\min(m, n), \max(m, n))$ 上可导, $[\min(m, n), \max(m, n)]$ 上连续,根据拉格朗日中值定理,则必有 $\xi \in (\min(m, n), \max(m, n))$,使得

$$b^m - b^n = (m - n) \cdot \ln b \cdot b^\xi$$

1)当 $m > n$ 时, $\xi > n, m - n > 0, b^\xi > b^n, \ln b > 0$, $\ln b \cdot b^\xi > \ln b \cdot b^n$,所以

$$b^m - b^n = (m - n) \cdot \ln b \cdot b^\xi > (m - n) \cdot \ln b \cdot b^n$$

2)当 $m < n$ 时, $\xi < n, m - n < 0, b^\xi < b^n, \ln b > 0$, $\ln b \cdot b^\xi < \ln b \cdot b^n$,所以

$$b^m - b^n = (m - n) \cdot \ln b \cdot b^\xi > (m - n) \cdot \ln b \cdot b^n$$

因此, $\forall m, n \in R$,如果 $b > 1$,则 $b^m - b^n \geq (\ln b) \cdot b^n \cdot (m - n)$,引理得证。□

定理1 高斯自联想记忆模型GAM在同、异步更新方式下是稳定的。

证明:因为异步更新方式可以看作是同步更新方式的一种特殊情况,因此只需证明同步更新方式下的稳定性即可。这里首先定义一个GAM模型的有界能量函数,然后证明在同步更新模式下该能量函数将随着网络状态的更新而不断递增,从而表明GAM网络终将稳定在一个具有最大能量函数值的网络状态。

因此,不妨构造能量函数如下:

$$E(X) = \sum_{i=1}^M b^{-\|X^i - X\|^2 / \sigma^2} \quad (10)$$

易知

$$0 < E(X) = \sum_{i=1}^M b^{-\|X^i - X\|^2 / \sigma^2} \leq M \cdot b^0 = M, \text{即上述能量函数是有界的。}$$

下面证明在网络状态更新时 $E(X)$ 是递增的, 设 X 和 X' 分别是当前和下一个状态, 定义两者的能量差为 $\Delta E = E(X') - E(X)$, 则

$$\Delta E = \sum_{i=1}^M b^{-\|X^i - X'\|^2 / \sigma^2} - \sum_{i=1}^M b^{-\|X^i - X\|^2 / \sigma^2} = \sum_{i=1}^M [b^{-\|X^i - X'\|^2 / \sigma^2} - b^{-\|X^i - X\|^2 / \sigma^2}]$$

根据引理 1, 易知:

$$\begin{aligned} \Delta E &\geq \sum_{i=1}^M \left[(\ln b) \cdot b^{-\frac{\|X^i - X\|^2}{\sigma^2}} \cdot \left(\frac{\|X^i - X\|^2}{\sigma^2} - \frac{\|X^i - X'\|^2}{\sigma^2} \right) \right] = \\ &\frac{\ln b}{\sigma^2} \cdot \sum_{i=1}^M [b^{-\frac{\|X^i - X\|^2}{\sigma^2}} \cdot (2X^i - X - X')^T \cdot (X' - X)] = \\ &\frac{\ln b}{\sigma^2} \cdot \sum_{i=1}^M [b^{-\frac{\|X^i - X\|^2}{\sigma^2}} \cdot \sum_{k=1}^n (2x_k^i - x_k - x'_k) \cdot (x'_k - x_k)] = \\ &\frac{\ln b}{\sigma^2} \cdot \sum_{k=1}^n \left\{ \sum_{i=1}^M b^{-\frac{\|X^i - X\|^2}{\sigma^2}} \cdot \left[2 \cdot \frac{\sum_{i=1}^M x_k^i \cdot b^{-\frac{\|X^i - X\|^2}{\sigma^2}}}{\sum_{i=1}^M b^{-\frac{\|X^i - X\|^2}{\sigma^2}}} - x_k - x'_k \right] \cdot (x'_k - x_k) \right\} \end{aligned}$$

令 $u_k = \frac{\sum_{i=1}^M x_k^i \cdot b^{-\frac{\|X^i - X\|^2}{\sigma^2}}}{\sum_{i=1}^M b^{-\frac{\|X^i - X\|^2}{\sigma^2}}}$, 则上式转化为

$$\Delta E \geq \frac{\ln b}{\sigma^2} \cdot \sum_{k=1}^n \left\{ \sum_{i=1}^M b^{-\frac{\|X^i - X\|^2}{\sigma^2}} \cdot [(2u_k - x_k - x'_k) \cdot (x'_k - x_k)] \right\} = \frac{\ln b}{\sigma^2} \cdot \sum_{i=1}^M b^{-\frac{\|X^i - X\|^2}{\sigma^2}} \cdot \sum_{k=1}^n \{ [(u_k - x_k) + (u_k - x'_k)] \cdot (x'_k - x_k) \}$$

不妨令 $s_k = [(u_k - x_k) + (u_k - x'_k)] \cdot (x'_k - x_k)$, 同样我们可以分情形讨论。

情形 1 当 $u_k < D/L$ 时, $x'_k = D/L$ 且 $x_k \geq D/L$, 此时 $s_k \geq 0$ 当且仅当 $x'_k = x_k = D/L$ 时, $s_k = 0$;

情形 2 当 $u_k > D$ 时, $x'_k = D$ 且 $x_k \leq D$, 此时 $s_k \geq 0$ 当且仅当 $x'_k = x_k = D$ 时, $s_k = 0$;

情形 3 当 $D/L \leq u_k \leq D$ 时, 根据式 (8) 有 $x'_k = \lfloor (L/D) \cdot u_k + 0.5 \rfloor \cdot (D/L)$, 所以

$-D/2L \leq u_k - x'_k < D/2L$ 。接下来再分 3 种情况讨论。

1) $-D/2L \leq u_k - x'_k < D/2L$, 即

$x_k \cdot (L/D) \leq (L/D) \cdot u_k + 0.5 < x_k \cdot (L/D) + 1$, 此时 $x'_k = x_k$, 所以 $s_k = 0$;

2) $u_k - x_k \geq D/2L$, 即

$(L/D) \cdot u_k + 0.5 \geq (L/D) \cdot x_k + 1$, 此时 $x'_k > x_k$, 同时, $-D/2L \leq u_k - x'_k$, 所以, $s_k \geq 0$ 当且仅当 $\{x_k = u_k - D/2L$ 且 $x'_k = u_k + D/2L\}$ 时, $s_k = 0$;

3) $u_k - x_k < -D/2L$, 即

$(L/D) \cdot u_k + 0.5 < (L/D) \cdot x_k$, 此时, $x'_k < x_k$, 同时 $u_k - x'_k < D/2L$, 所以 $s_k > 0$ 。

综上所述, 可知 $\Delta E \geq 0$, 从而表明随着网络状态的更新, 能量函数将收敛在一个最大点上, 从而保证了 GAM 网络最终趋于稳态。

3 基于一般相似性测度的广义高斯自联想记忆模型 (G-GAMs)

许多机器学习和模式识别方法都依赖于相似性测度。一些常用的方法, 如径向基函数神经网络、支持向量机、K 近邻法、自组织映射神经网络方法等, 它们的性能都依赖于一个合适的相似性测度。相似性测度的选取必须要与数据特征的差异和不同尺度相对应, 不同的测度函数可能使得同一个算法性能迥异。而从 MEMRCAM 模型与 MMECAM 模型的分析容易知道, 两者的区别也仅仅在于其采用了不同的模式相似性测度。因此, 我们可以用一般相似性测度替代 GAM 模型中的平方欧氏距离, 得到一个新的广义高斯自联想记忆模型 (G-GAMs)。

定义 4 广义高斯自联想记忆模型 (G-GAMs)

设 $\{X^i | X^i = (x_1^i, x_2^i, \dots, x_n^i)^T, i = 1, 2, \dots, M\}$ 是一组待记忆的模式, $X = (x_1, x_2, \dots, x_n)^T$ 为任一个输入模式, $X' = (x'_1, x'_2, \dots, x'_n)^T$ 是 X 的下一个状态, 其中 $X^i, X, X' \in \{D/L, 2D/L, \dots, D\}^n, S(X^i, X)$ 表示模式 X^i 与 X 之间的一般相似度, 如果自联想记忆模型具有如下状态更新规则。

$$X' = H \left(\frac{\sum_{i=1}^M X^i \cdot b^{S(X^i, X)}}{\sum_{i=1}^M b^{S(X^i, X)}} \right) \quad b > 1 \quad (11)$$

则称其为广义高斯自联想记忆模型。

许多研究人员根据不同的数据和不同的需要提出一些相似性度量方法^[20-21]。常用的一般相似性测度如下:

1) Minkowski 距离

$$S(\mathbf{X}^i, \mathbf{X}) = - \left[\sum_{j=1}^n |x_j^i - x_j|^q \right]^{1/q}$$

2) Canberra 距离

$$S(\mathbf{X}^i, \mathbf{X}) = - \frac{1}{n} \sum_{j=1}^n |x_j^i - x_j| / (|x_j^i| + |x_j|)$$

3) Mahalanobis 距离

$$S(\mathbf{X}^i, \mathbf{X}) = (\mathbf{X}^i - \mathbf{X})^T \cdot \mathbf{M}^{-1} \cdot (\mathbf{X}^i - \mathbf{X}), \text{ 其中 } \mathbf{M}^{-1} \text{ 是模式关联矩阵 } \mathbf{M} \text{ 的逆矩阵。}$$

4) Bray-Curtis 距离

$$S(\mathbf{X}^i, \mathbf{X}) = - \sum_{j=1}^n |x_j^i - x_j| / \sum_{j=1}^n |x_j^i + x_j|$$

5) Generalized 距离

$$S(\mathbf{X}^i, \mathbf{X}) = - \sum_{j=1}^n |(x_j^i)^a - (x_j)^a| \quad (a > 0, 0 < b \leq 2)$$

6) Pearson 相关系数

$$S(\mathbf{X}^i, \mathbf{X}) = \frac{\left(\sum_{j=1}^n x_j^i \cdot x_j - \frac{1}{n} \sum_{j=1}^n x_j^i \cdot \sum_{j=1}^n x_j \right)}{\sqrt{\left(\sum_{j=1}^n (x_j^i)^2 - \frac{1}{n} \left(\sum_{j=1}^n x_j^i \right)^2 \right) \cdot \left(\sum_{j=1}^n (x_j)^2 - \frac{1}{n} \left(\sum_{j=1}^n x_j \right)^2 \right)}}$$

4 基于 GAM 的单样本图像识别方法及性能仿真

基于 GAM 的图像识别方法有别于传统的图像识别方法,它可以通过学习获得图像识别的规则和规律的隐性表达,适应性强且较易实现。其优点具体体现在:1) GAM 方法具有联机 (on-line) 学习能力,在添加新的模式时,系统只需作增量式的修改,而并不需要对整体重新学习;2) GAM 方法性能鲁棒、并行化程度高,它充分利用了联想记忆的特点,可有效存储和回忆信息,并且允许待识别(测试)样本有较大的缺损、畸变;3) GAM 方法几乎无须任何人工的几何特征提取工作,是一种对数据分布无任何要求的非线性技术;4) GAM 方法不受单训练样本的约束,区别于其他要求多训练样本的传统图像识别算法,每幅图像只需存储一个训练样本,不仅样本采集代价低,而且有限的存储容量可以满足更大的问题规模,特别适合那些获取训练样本代价较高的实际问题。

基于 GAM 的单样本图像识别算法可描述如下:1) 训练记忆阶段 按照 GAM 模型的状态更新

规则训练网络的连接权值;2) 联想识别阶段 把待识别样本集中第 k 个测试样本作为输入模式送到步骤 1) 中训练好的 GAM 模型,经有限次迭代以后,若与训练集中第 k 个训练样本完全吻合,则第 k 个图像被成功识别;否则,第 k 个图像没有被成功识别。

本节将重点考察基于 GAM 的图像识别方法识别含噪图像时的识别性能。实验中随机选取了 200 幅 30×30 像素的不同内容、不同背景的 256 色灰度图像作为训练样本集,训练时除了对它们的大小进行归一化以外,并未进行其他预处理,图 1 给出了部分训练图像样本和添加不同程度椒盐噪声的测试图像样本。

表 1 和表 2 分别考察了参数 b 和 σ 对 GAM 模型识别性能的影响,考虑到噪声的随机性,每个实验重复进行 20 次,表中所获取的数据均为 20 次实验的平均值。

从表 1 和表 2 同时可以看出:1) 如果合理选择参数 b 和 σ 的值, GAM 模型(例如 $\sigma = 256^2/10, b = 4$ 或者 $\sigma = 256^2/20, b = 2$)能够记住所有的训练样本,其更新迭代次数为 1 恰好说明所有的训练样本均为该 GAM 模型的稳定点;2) 如果合理选择参数的值, GAM 模型对于椒盐噪声是不敏感的,即使在测试样本上添加高达 30% 的椒盐噪声, GAM 模型($\sigma = 256^2, b = 2$ 或者 $\sigma = 256^2/10, b = 1.5$)的识别率也能高达 95% 以上,而且网络的平均迭代次数仅为 2 次左右。事实上,如果我们仔细观察图 1(c) 可以看出,即使对于我们人脑而言,其中有些图形也是难以识别的,而 GAM 模型却能以极少的迭代次数快速准确地识别出来,从而在实验上进一步验证了 GAM 模型的稳定性,充分说明联想记忆神经网络所具备的超强纠错能力;3) 表 1 的实验数据表明,当测试图像不含噪声时,参数 b 越大, GAM 模型更新迭代次数越低,越容易趋于稳定,且存储能力越强,但推广能力越差(识别含噪图像的性能随着噪声的增加急剧下降);4) 表 2 的实验数据也表明,当测试图像不含噪声时,随着参数 σ 增大,网络迭代次数增加,存储能力下降,但对于含噪图像的噪声越不敏感,推广能力增强。因此,观察表 1 和表 2 可以得出这样一个结论: GAM 模型的存储能力和推广能力是相互制约的,存储能力越强,推广能力反而越差。



图 1 原始训练图像和含不同程度椒盐噪声测试图像示例

Fig.1 The original training images and testing images with various amounts of salt & pepper noise

表 1 参数 b 对 GAM 模型识别性能的影响

Tab.1 The influence of parameter b for recognition performance of GAM

椒盐噪声 ($\sigma = 256^2/10$)	$b = 1.2$		$b = 1.5$		$b = 2$		$b = 4$	
	识别率	平均迭 代次数	识别率	平均迭 代次数	识别率	平均迭 代次数	识别率	平均迭 代次数
0	99	1.15	99	1.04	100	1	100	1
0.1	99	2.133	99	2.032	99.99	2.005	99.775	1.999
0.15	99	2.129	99	2.035	99.95	2.007	71.03	1.705
0.2	98.975	2.131	99	2.039	99.8	2.009	19.17	1.192
0.25	98.575	2.143	98.575	2.038	96.29	1.974	0.47	1.004
0.3	95.8	2.18	95.825	2.046	72.05	1.728	0	1

表 2 参数 σ 对 GAM 模型识别性能的影响

Tab.2 The influence of parameter σ for recognition performance of GAM

椒盐噪声 ($b = 2$)	$\sigma = 3 \times 256^2$		$\sigma = 2 \times 256^2$		$\sigma = 256^2$		$\sigma = 256^2/10$		$\sigma = 256^2/20$	
	识别率	平均迭 代次数	识别率	平均迭 代次数	识别率	平均迭 代次数	识别率	平均迭 代次数	识别率	平均迭 代次数
0	74.5	2.345	96.5	1.12	99	1.04	100	1	100	1
0.1	74.5	3.519	96.5	2.158	99	2.026	100	2.006	99.9	2.001
0.15	74.5	3.688	96.5	2.221	99	2.024	99.95	2.0125	70.35	1.705
0.2	74.5	3.94	96.5	2.368	99	2.047	99.8	2.008	19.2	1.192
0.25	74.5	4.258	96.45	2.529	98.55	2.104	96.31	1.979	0.55	1.005
0.3	72.85	4.79	93.95	2.741	95.7	2.207	72.08	1.727	0	1

5 结 论

首先在详细分析 MMECAM 模型优缺点的基础上,通过完善其更新规则,提出一个囊括 MMECAM 模型的高斯自联想记忆模型(GAM),然后借助能量函数的收敛性从理论上证明其同、异步方式下的稳定性,从而保证所存储的模式能最终成为 GAM 的稳定点;其次,通过引入一般相似性测度进一步提出广义 GAM 模型(G-GAMs)框架,使得 GAM 模型成为其特例;最后,将 GAM 模型应用于单样本图像识别,进一步从实验上验证了该模型的稳定性和识别含噪图像时的超强鲁棒性能。

参考文献(References)

- [1] Haykin S. Neural Networks: a Comprehensive Foundation[M]. Englewood Cliffs, New Jersey: Prentice-Hall, 1999:1-32.
- [2] Zhou Zhihua, Cao Cungen. Neural Network and Its Application [M]. Beijing: Tsinghua University Press, 2004:1-13. [周志华, 曹存根. 神经网络及其应用[M]. 北京: 清华大学出版社, 2004:1-13.]
- [3] Hopfield J J. Neural network and physical systems with emergent collective computational abilities[J]. Proceedings of the National Academy of Sciences of the USA, 1982, 79(4): 2554-2558.
- [4] Hopfield J J. Neurons with graded response have collective computational properties like those of two-state neurons [J]. Proceedings of the National Academy of Sciences of the USA, 1984, 81(5): 3088-3092.
- [5] McCulloch W S, Pitts W. A logical calculus of the ideas immanent in nervous activity [J]. Bulletin of Mathematical Biophysics, 1943, 5: 115-133.
- [6] Grossberg S. Nonlinear difference-differential equations in prediction and learning theory[J]. Proceedings of the National Academy of Sciences of the USA, 1967, 58(4): 1329-1334.
- [7] Anderson J. A simple neural network generating an interactive memory[J]. Mathematical Biosciences, 1972, 14: 197-220.
- [8] Anderson J A, Silverstein J W, Ritz S A, et al. Distinctive features, categorical perception, and probability learning: some applications of a neural model[J]. Psychological Review, 1977, 84(4): 413-451.
- [9] McEliece R J, Posner E C, Rodemich E R, et al. The capacity of the hopfield associative memory [J]. IEEE Transactions on Information Theory, 1987, 33(11): 461-482.
- [10] Psaltis D, Park H C. Nonlinear discriminant functions and associative memories[C] //Proceedings of the Neural Networks for Computing. New York: American Institute of Physics, 1986: 370-375.
- [11] Dembo A, Zeitouni O. General potential surfaces and neural networks[J]. Physics Review A, 1988, 37(6): 2134-2143.
- [12] Chiueh T D, Goodman R M. Recurrent correlation associative memories[J]. IEEE Transactions on Neural Networks, 1991, 2(2): 275-284.
- [13] Chiueh T D, Tsai H K. Multivalued associative memories based on recurrent networks [J]. IEEE Transactions on Neural Networks, 1993, 4(2):364-366.
- [14] Chen Z Y, Kwong C P. Recurrent correlation associative memories with multiple-value [C] //Proceedings of IEEE International Conference of Neural Networks. Orlando, FL, USA: IEEE Computer Society, 1994: 1068-1073.
- [15] Wang C C, Hwang S M, Lee J P. Capacity analysis of the asymptotically stable multivalued exponential bidirectional associative memory [J]. IEEE Transactions on Systems, Man, and Cybernetics, 1996, 26(3): 733-743.
- [16] Chen S C, Chen L, Zhou Z H. A unified SWSI-KAMs framework and performance evaluation on face recognition [J]. Neurocomputing, 2005, 68(3): 54-69.
- [17] Chen Lei, Chen Songcan. Small world structure inspired many to many kernel associative memory models and their application[J]. Journal of Software, 2006, 17(2): 223-231. [陈蕾, 陈松灿. 小世界体系的多对多核联想记忆模型及其应用[J]. 软件学报, 2006, 17(2): 223-231.]
- [18] Wu Xisheng, Wang Shitong. Fuzzy morphological associative memory and their application in storing and recalling cell images [J]. Journal of Image and Graphics, 2006, 11(10): 1450-1455. [吴锡生, 王士同. 模糊形态联想记忆网络及其在细胞图像联想识别中的应用[J], 中国图象图形学报, 2006, 11(10): 1450-1455.]
- [19] Feng Naiqin, Liu Chunhong, Zhang Congpin, et al. Research on the framework of morphological associative memories [J]. Chinese Journal of Computers, 2010, 33(1): 157-166. [冯乃勤, 刘春红, 张聪品, 等. 形态学联想记忆框架研究[J]. 计算机学报, 2010, 33(1): 157-166.]
- [20] Eric P X, Andrew Y N, Michael I, et al. Distance metric learning with application to clustering with side-information[C] //Advances in Neural Information Processing Systems. Cambridge: MIT Press, 2003, 15: 505-512.
- [21] Chapelle O, Haffner P, Vapnik V N. Support vector machines for histogram-based image classification [J]. IEEE Transactions on Neural Networks, 1999, 10(5):1055-1064.