

一种随机竞争学习矢量量化图像编码算法

张基宏,李霞,谢维信

(深圳大学信息工程学院,深圳 518060)

摘要: 本文分析了确定性模拟退火技术、竞争学习算法在图像编码中的压缩机理,提出了一种新的随机竞争学习矢量量化算法.该算法将竞争过程与代价函数最小化结合起来,在学习过程中引入模拟退火,并针对矢量量化图像编码的特点,提出了新的参数选取策略,具有对初始码书依赖性小,不会局部最小,收敛速度快,码书性能好等优点.文中还通过计算机实践对该方法进行了性能分析,验证了算法的有效性和鲁棒性.

关键词: 图像编码;确定性模拟退火;竞争学习

中图分类号: TN919.81

文献标识码: A

文章编号: 0372-2112 (2000) 10-0023-04

A Stochastic Competitive Learning Vector Quantization Algorithm for Image Coding

ZHANG Ji-hong, LI Xia, XIE Wei-xin

(Information Engineering Faculty of Shenzhen Univ., Shenzhen 518060, China)

Abstract: In this paper, we analyze the principles of deterministic annealing technique and competitive learning algorithm for image coding, and present a new stochastic competitive learning vector quantization algorithm for image coding. It combines the procedure of competition with the minimization of cost function. Simulated annealing is used in learning procedure, and several new strategies are presented in the vector quantization for image coding. The algorithm can eliminate the effect of initial codebook selection on the quality of clustering, is not trapped in local minimum, has a good convergence rate, and can get the codebook with good performance. Computer simulation results confirm the effectiveness and robustness of the approach.

Key words: image coding; deterministic annealing; competitive learning

1 引言

聚类或码书设计是基于矢量量化图像编码的必需过程.近年来研究较多的码书设计算法有:LBG算法^[1],随机松弛技术(SR)^[2],基于竞争学习网络的学习矢量量化(LVQ)^[3]和频次敏感竞争学习算法(FSCL)^[4],基于退火技术的模拟退火(SA)^[5]和确定性模拟退火算法(DA)^[6],及模糊矢量量化(FVQ)^[7-9]等.经典 LBG 是较成功的算法,但是它强烈依赖于初始码书的选取,并且容易陷入局部最小. LVQ 和 FSCL 算法结构简单,便于学习和并行实现,但所得码书与 LBG 存在同样的问题,性能也比 LBG 差. SR、SA、DA 能得到全局最小的码书,但计算量很大, FVQ 设计的码书同样对初始码书依赖性小,而且不会局部最小;运算量也小于 SR、SA、DA,但仍然较大.

利用统计物理的退火过程,美国加州理工学院 K. Rose 博士于 1990 年首先提出了确定性退火技术^[6],它是根据退火过程,将求解优化问题的最优点转化为求一系列随温度变化的物理系统的自由能函数的极小,它能够使算法避开局部极小而得到全局最小,被广泛应用于模式识别、图像处理与数据压缩领域.但是,对该技术的物理背景及数学描述没有进行详细

的分析,从而不能保证解的有效性,对应用缺乏有力的理论指导,而且过大的计算量也是它实用化的最大障碍.

本文将竞争过程与代价函数最小化结合起来,在学习过程中引入模拟退火,提出了一种随机竞争学习算法(SCLA),旨在发展确定性退火技术的启发式策略,给予搜索过程更明确的指导,克服竞争学习算法的缺点,提高算法收敛速度鲁棒性和并行性.

2 确定性模拟退火技术

为了减小初始胸腔质心对聚类性能的影响, Rose 用 DA 来进行 VQ 的胸腔搜索,其实质就是热平衡原理.对数据集中的每一点,它与能量通过给定胸腔互相联系着.因此,可以为所有可能的关联定义 Gibbs 分布规律

$$p(X = U_j) = (-E_X(j)) / Z_X, \text{ for } j = 1, 2, \dots, K \quad (1)$$

式中 K 、 X 、 U_j 、 $E_X(j)$ 分别为总胸腔个数、训练矢量、第 j 个胸腔、控制参数(温度的倒数)、 X 与 U_j 关联的能量, Z_X 为分离函数,定义为

$$Z_X = \sum_{j=1}^K e^{-E_X(j)} \quad (2)$$

基于欧氏距离平方定义的能量函数为

$$E_X(j) = |X - m_j|^2 \quad (3)$$

式中 m_j 为第 j 个胞腔的质心. 给定概率 $p(X \in U_j)$, 定义 X 的期望能量为

$$\bar{E}_X = \sum_{j=1}^K p(X \in U_j) E_X(j) \quad (4)$$

本文的目标是最小化总体期望能量, 总体期望能量为

$$\bar{E} = \bar{E}_X \quad (5)$$

假定不同 X 属于胞腔的概率相互独立, 定义总的分离函数为

$$Z = \prod_{X} Z_X \quad (6)$$

定义自由能 F 为

$$F = -\ln Z = -\sum_{X} \ln Z_X = -\sum_{X} \ln \left(\sum_{j=1}^K e^{-E_X(j)} \right) \quad (7)$$

能够看出当 $\beta \rightarrow \infty$, F 将近似与总体期望能量 \bar{E} 相等. 在实际中 β 是有限的, 因此 F 与 \bar{E} 不同. 计算过程中, 对每一温度点, F 不能适当地直接表示局部最小. 然而可以通过梯度下降法来积累每步关于 E 的最小的信息. 为了表示胞腔, DA 用 F 代替 \bar{E} 进行最小化. 为了最小化 F , 对 $j=1, 2, \dots, K$ 先计算 F 对 m_j 求偏导

$$\frac{\partial F}{\partial m_j} = -2 \sum_{X} \frac{(X - m_j) e^{-\frac{1}{2}|X - m_j|^2}}{\sum_{i=1}^K e^{-\frac{1}{2}|X - m_i|^2}} = -2(X - m_j) p(X \in U_j) \quad (8)$$

在 LBG 算法中, 代价函数 E 定义为

$$E = \sum_{j=1}^K \sum_{X \in U_j} |X - m_j|^2 \quad (9)$$

对 m_j 求偏导得

$$\frac{\partial E}{\partial m_j} = -2 \sum_{X \in U_j} (X - m_j) \quad \text{for } j=1, 2, \dots, K \quad (10)$$

显然 K 均值算法中, 仅仅是属于 U_j 的数据才有偏导. 然而 DA 算法所有的训练数据都有偏导, 每个权值都是 Gibbs 概率 $p(X \in U_j)$. 当 β 很小时, 所有数据的偏导近似相等. 当 β 逐渐增大时, 数据逐渐分离, 数据通过求偏导归属于其比较近的质心概率就越大, 远离其它. 在极限 $\beta \rightarrow \infty$, 数据就跟质心靠得很近, 式(8)与式(10)等效.

确定性退化算法实质上在聚类中采用统计方法, 它的胞腔均值 m_j 计算迭代公式为:

$$m_j(n+1) = \frac{\sum_{X} \exp\left(-\frac{1}{2}(n) |X - m_j(n)|^2\right)}{\sum_{X} \exp\left(-\frac{1}{2}(n) |X - m_K(n)|^2\right)} \quad (11)$$

DA 算法具体步骤如下:

- (1) 设定 ϵ 为一个很小的数, 随机给定初始胞腔.
- (2) 按式(11)进行迭代, 计算 m_j .
- (3) 如果发现很多胞腔是一致的, 则提供一个小小的扰动使胞腔分离, 否则继续.
- (4) 计算下一个 ϵ , 若 $\epsilon < \epsilon_{\max}$ 则回到第二步, 否则停止迭代.

3 竞争学习算法

竞争学习网络 (CL) 是一种重要的神经网络, 如图 1 所示. 人们已对它作了大量研究, 并已在模式识别和矢量量化等方面得到了应用^[3,4,10].

假设竞争网络的训练数据由一系列输入矢量 $X = X(k) \in R^N$ 组成, 这里 K 为序列号. 当每一输入矢量进入网络时, 数据处理单元以最小距离为基础

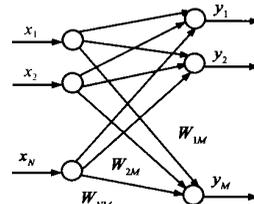


图 1 竞争学习网络

相互之间进行竞争而决定获胜单元, 数据处理单元输出为

$$y_i(k) = \begin{cases} 1, & \text{if } |X - W_i(k)| \leq \min_{j=1,2,\dots,M} |X - W_j(k)| \\ 0, & \text{otherwise} \end{cases} \quad (12)$$

获胜单元的学习更新公式定义为

$$W_i(k+1) = W_i(k) + \eta y_i(k) (X(k) - W_i(k)) \quad (13)$$

这里 η 是学习常数. 由于仅仅获胜单元输出为 1, 其它单元输出为 0, 所以对失败单元有 $W_i(k+1) = W_i(k)$. 典型的竞争学习算法是 LVQ 算法, 显然 LVQ 的主要问题是与输入矢量相距很远的权值决不可能赢, 因此就不能学习. 这就导致一些数据处理单元没有被利用. 为此 Ahalt 等人提出了一种频次敏感竞争学习算法 (FSCL)^[4], 该算法当数据处理单元在竞争失败时, 变得敏感; 而在取得赢时变得不敏感, 其学习率也是可变的. 它克服了 LVQ 的局限性而保留了其优越性.

FSCL 算法的基本思想是: 在训练过程中, 把基本 CL 网中的误差测度与网络中神经元的获胜次数相结合, 形成一个新的误差测度. 每个神经元设置一个计数器 μ_i , μ_i 是第 i 个神经元为获胜单元的次數. 用于选择获胜单元的误差测度为 $D_i = f(\mu_i) |X - W_i|$, 其中 $f(\mu_i)$ 称为“公平”函数. $f(\mu_i)$ 随 μ_i 增大单调递增. “公平”函数是将频次加权引入误差测度的基本方法, 相当于模式识别技术中的概率密度加权. 引入这种加权误差测度的结果是: 如果某神经元频繁获胜 (即频繁地被激活), 它的计数器增加, 因此, 加权误差测度增大, 就可为其它神经元创造竞争获胜的机会. 它的激活测度写为

$$i^* = D^*(X, W_i) = \min_i |X - W_i| f(\mu_i^*(k)) \quad (14)$$

FSCL 与传统的 LBG 算法相比, 优点是: 首先, 由于网络是自组织的, 因而, 构成的矢量量化编码系统是自适应的. 即对任何不同统计特性的图像信源, 其码本的确是完全自适应的, 这是一种在线训练过程. 而 LBG 算法则是对整个训练集以批处理的方式进行计算. 其次, 它是由许多神经元组成的高度并行的运算结构, 因而构成的矢量量化系统运算速度快. 但 FSCL 与 LBG 算法一样, 都很有可能陷入局部最小, 而且实验结果表明 LVQ 与 FSCL 算法设计的码书性能比 LBG 算法还差.

4 随机竞争学习算法

4.1 竞争学习网络的代价函数

对于简单竞争学习规则式(12), 其代价函数定义为

$$E = \frac{1}{2} \sum_{k=1}^P \sum_{j=1}^M \sum_{i=1}^N y_i(k) (X(k) - W_{ij})^2 \quad (15)$$

式中 P, M 分别为训练样本总数和胞腔总数, 对代价函数式 (15), 用梯度下降法, 有

$$W_{ij} = - \frac{\partial E}{\partial W_{ij}} = \sum_{k=1}^P y_j(k) (X_i(k) - W_{ij}) \quad (16)$$

这里 η 为更新步长.

明显地, 式 (16) 是简单学习规则式 (13) 在第 j 个单元获胜时所有模式 $X(k)$ 的总和. 竞争学习被认为是用梯度下降法对代价函数式 (15) 求最小值. 如果直接用式 (16), 也就是说, 权值的更新是积累每一有限训练模式集的 W_{ij} 的改变, 即批学习模式. 相反, 如果在每次输入后就更新与取得获胜单元相连接的权值, 这就是简单竞争学习规则等式 (13), 即在线学习模式.

把竞争学习过程和代价函数最小化结合起来, 因此对学习性能的评估就是算法能找到局部最小或全局最小程度的评价. 性能越好的算法其最小值越小. 如式 (15) 的代价函数, 它有几种典型的局部最小, 简单竞争学习算法不能很好地表示, 因为它易陷入一个局部最小.

4.2 随机竞争学习公式

在简单竞争网络中, 数据处理单元的输出定义为式 (12). 随机竞争学习算法允许 $y_i(k)$ 为区间 $[0, 1]$ 的实数, 用 $y_i(k)$ 来表示单元 i 获胜机率. $y_i(k)$ 值越大, 单元 i 赢的机会就越大; 相反 $y_i(k)$ 值越小, 单元输的机率就越大. $y_i(k)$ 如式 (1) 具有 Gibbs 分布规律

$$y_i(k) = \frac{e^{-\frac{X(k) - W_i(k)}{2}}}{\sum_{j=1}^M e^{-\frac{X(k) - W_j(k)}{2}}} \quad (17)$$

现在竞争网络的代价函数式 (15) 与期望代价函数式 (5) 有相同的格式, 相似地, 网络的自由能应定义如式 (7). 本文的目的是最小化式 (15), 能够通过退火过程来最小化 F , F 定义为

$$F = - \frac{1}{2} \sum_{k=1}^P \log \left(\sum_{i=1}^M e^{-\frac{X(k) - W_i(k)}{2}} \right) \quad (18)$$

对 F 的权值矢量求偏导有

$$\frac{\partial F}{\partial W_i} = - \sum_{k=1}^P y_i(k) (X(k) - W_i) \quad \text{for } i = 1, \dots, M \quad (19)$$

因此可以定义随机竞争学习算法 (SCLA) 如下:

- (1) 初始化权值 $W_1(0), W_2(0), \dots, W_M(0)$, 设定 $\eta(0)$ 和 $\eta(\infty) > 0$ 为小值.
- (2) 对所有 $i = 1, 2, \dots, M$, 按下式更新所有权值矢量

$$W_i(n+1) = W_i(n) + \eta(n) \sum_{k=1}^P y_i(k) (X(k) - W_i(n))$$
- (3) 分别按式 (15) 和式 (18) 计算 E 和 F , 若 $|E - F| / E < \epsilon$, 则停止迭代; 否则增加 η , 回到 (2).

4.3 算法参数选取

SCLA 算法权值更新是批模式, 权值只有在全部输入矢量都进入网络后才更新. 这个过程与在线模式相反, 它能排除由于输入系列的顺序不同而对最后结果的影响. 在 SCLA 实现以前, 须确定几个参数.

首先是初始控制参数 $\eta(0)$ 的选取, 该值既不能太大也不能太小. 如果太小, 所有的输出将会聚在一起, 结果很差; 相

反, 如果太大, 退火过程可能会无效. 通过经验和实践, 这里选择 $\eta(0)$ 为所有输入样本与他们的质心的欧氏距离平方均值的倒数, 即

$$\eta(0) = \frac{1}{\sum_{k=1}^N \frac{1}{X(k) - C}^2} \quad (20)$$

式中 C 为正常数. $C = \frac{1}{T} \sum_{k=1}^N X(k)$ 是所有训练样本的质心矢量.

其次是温度降低的方案, 在研究中采用了一个叫“概念样本”的冷却方案^[11], 对 $\eta > 1$, 定义

$$\eta(n+1) = \eta(n) \quad \text{for } \eta > 1 \quad (21)$$

另一个重要的参数是更新学习率, Grossberg 建议^[12]: 如果一个单元经常赢, 则其学习率减小; 相反, 如果一个单元经常输, 则其学习率应增大. 基于这个建议, SCLA 选择学习率为

$$\eta_i(n) = \frac{1}{\sum_{k=1}^N y_i(k, n)} \quad \text{for } i = 1, 2, \dots, M \quad (22)$$

这里 $y_i(k, n)$ 是单元 i 在时刻 n 的输出. 输出单元输出越大, 这单元赢的机会越大, 学习率减小; 相反, 输出单元输出越小, 这单元输的机会越大, 学习率增大.

最后是 SCLA 算法收敛的判断准则, 确定性模拟退火收敛的判断准则是 $T < T_{\min}$, 即 $\eta > \eta_{\max}$, 但实际应用中很难决定 η_{\max} 值. 竞争学习算法则经过一系列迭代后, 计算当前输出与上一次输出的绝对值差是否小于某一门限而终止或强迫终止迭代. 为此 SCLA 算法基于目标为最小化 E 和优化自由函数 F 内在的联系, 给出了一种新的收敛判断准则. 当 E 和 F 之间足够接近时算法终止, 即 $|E - F| / E < \epsilon$.

5 性能比较与结论

本文的计算是在奔腾 260 计算机上完成的, 采用峰值信噪比 (PSNR) 和收敛时平均最小失真 D^v 来对算法设计的图像码书性能进行客观评价. 算法运算量的评价是基于收敛时所需迭代次数 v . 并将 SCLA 算法与 LVQ、FSLC、FVQ、DA 算法进行了比较. 处理图像是 8bits, 尺寸为 256 × 256 的 Lenna 标准图像. 采用 16 维矢量, 即有 4096 个矢量作为训练矢量; 码书大小为 256. 对每种算法进行了五次仿真, 将其统计结果列于表 1 中, 表中所有算法压缩比均为 16.

表 1 算法统计性能比较

算法	LVQ ^[3]	FSLC ^[4]	DA ^[6]	FVQ ^[7]	SCLA
v	8	9	18	29	13
D^v	229.89	217.32	101.67	104.44	77.89
PSNR (dB)	20.60	22.59	28.08	27.91	29.21

实验表明在同样的 $\eta(0)$ 条件下, η 选得越大, 即退火速度越快, 收敛也就越快, 但效果没退火速度慢的好; 如果 η 选得很小, 其效果固然好, 但收敛比较慢. 因此参数的实验经验取值为: $\eta = 1.5$, $\epsilon = 10^{-4}$, $\eta_{\max} = 1.1$.

由表 1 可见 SCLA 设计的码书性能分别比 LVQ、FSLC、DA、FVQ 改善了 8.61dB, 6.62dB, 1.13dB 和 1.3dB. 图 2、图 3、图 4 分别给出了 Lenna 原图像、SCLA 和 DA 仿真图像结果. SCLA



图2 Lenna 原图像 图3 DA 算法 图4 SCLA 算法

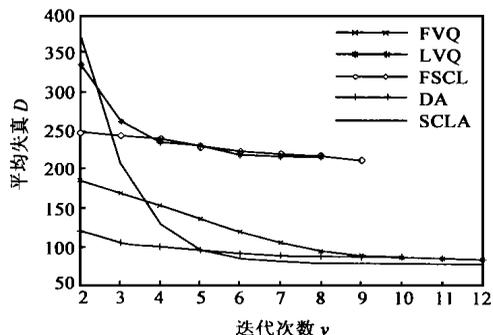


图5 算法收敛特性比较

与 DA 相比,译码图像的主观效果也有一定的改善.图 5 给出了算法的收敛特性,显然 SCLA 的收敛最快.实验同时发现,随机选取的码书对 SCLA 设计结果影响很小,而且 SCLA 比 DA 算法稳定.

本文将确定性模拟退火技术运用到神经网络中,提出了一种随机竞争学习算法,该算法能够训练出较高质量的图像码书,收敛速度也比较快.实验表明算法非常有效.

参考文献:

[1] R. M. Gray. Vector quantization [J]. IEEE ASSP Magazine , 1984 , 1 (1) : 4 - 29 .
 [2] K. Zeger et al. Globally optimal vector quantizer design by stochastic relaxation [J]. IEEE Trans. , 1992 , SP - 40 (2) : 310 - 312 .
 [3] E. Yair et al. Competitive learning and soft competition for vector quantizer design [J]. IEEE Trans. , 1992 , SP - 40 (2) : 294 - 309 .
 [4] S. C. Ahalt et al. Competitive learning algorithms for vector quantization [J]. Neural Networks , 1990 , 3 : 277 - 290 .
 [5] J. Hertz et al. Introduction to the theory of neural computation [Z]. 1991 , Vol. 1 , Addison-Wesley Publishing Company .
 [6] Rose K et al. Statistic mechanics and phase transitions in clustering [J]. Physical Review Letters. 1990 , 65 : 945 - 948 .

[7] N. B. Karayannis et al. Fuzzy vector quantization algorithm and their application in image compression [J]. IEEE Trans. 1995 , IP-4 (9) : 1193 - 1201 .
 [8] 张基宏,谢维信.一种快速模糊矢量量化图像编码算法 [J]. 电子学报,1999,27(2):106 - 108 .
 [9] J. H. Zhang ,X.Li ,W. X. Xie. Convergent performance of fuzzy VQ for image coding [J]. Chinese Journal of Electronics , 1999 , 8 (2) : 107 - 111 .
 [10] L. D. Rubin et al. Neural network techniques for objective orientation detection : Solution by optimal feed forward network and learning vector quantization approaches [J]. IEEE Trans. 1990 , PAMI - 12 (11) : 1107 - 1114 .
 [11] E. Arants et al. Simulated annealing and Boltzmann machines [M]. Wiley , New York , 1989 .
 [12] S. Grossberg. Competitive learning : From interactive activation to adaptive resonance [J]. Cognitive Science , 1987 , 1 (11) : 23 - 63 .

作者简介:



张基宏 1964 年出生,1986,1989,1992 年于东南大学无线电系分别获得学士、硕士、博士学位.先后在英国Lacashire 大学和日本 Soka 大学合作科研.现为深圳大学信息工程学院副校长、教授、电子系系主任,主要从事信息论与编码理论研究,发表学术论文三十余篇.



李 霞 1968 年生,1997 年于香港中文大学获得博士学位.现为深圳大学信息工程学院副教授,主要研究兴趣:智能信息处理、决策与控制系统中的信息编码研究等.



谢维信 深圳大学信息工程学院教授、博士生导师、深圳大学校长.主要从事信号和图像处理、智能信息处理、模糊信息处理等方面的研究.已发表学术论文百余篇,出版学术专著数部,并获多项科研奖励.