

基于自组织特征映射神经网络的矢量量化

陆哲明 孙圣和

(哈尔滨工业大学自动化测试与控制系, 哈尔滨 150001)

摘要 近年来, 许多学者已经成功地将 Kohonen 的自组织特征映射(SOFM)神经网络应用于矢量量化(VQ)图象压缩编码. 相对于传统的 LBG 算法, 基本的 SOFM 算法的两个主要缺点是计算量大和生成的码书性能较差, 因此为了改善码书性能, 对基本的 SOFM 算法的权值调整方法作了一些改进, 同时为了降低计算量, 又在决定获胜神经元的过程中, 采用了快速搜索算法. 在将改进的算法用于矢量量化码书设计后, 并把生成的码书用于图象的压缩编码. 测试结果表明, 改进的算法使码书设计的计算量得到明显的降低, 而且码书的性能得到了提高. 相对于基本算法, 码书设计的计算时间减少了约 75%. 在图象编码中, 不论是训练集内的图象, 还是训练集外的图象, 相对于基本算法, 编码质量均提高了 0.80dB~ 0.90dB.

关键词 矢量量化 自组织特征映射神经网络 图象压缩

中图法分类号: TN919.31 文献标识码: A 文章编号: 1006-8961(2000)10-0846-05

Vector Quantization Based on Self-Organizing Feature Map Neural Network

LU Zhe-ming, SUN Sheng-he

(Department of Automatic Test and Control, Harbin Institute of Technology, Harbin 150001)

Abstract In recent years, many scholars have successfully applied the Kohonen's self-organizing feature map (SOFM) neural networks to vector quantization image compression encoding. The two main shortcomings of the basic SOFM method are its high computation complexity and its poor codebook quality, compared to the conventional LBG algorithm. In order to improve the codebook performance, some modification is made in the weight factor adjustment of the basic SOFM algorithm in this paper. In order to reduce the computation complexity of the basic SOFM algorithm, some fast search methods are used in SOFM iterations during the search for the winning neuron. The proposed algorithm is used to generate vector quantization codebook and the generated codebooks are used for image compression encoding in this paper. Simulation shows that the reduction of computation is substantial and the codebook performance is improved. Compared to the basic SOFM algorithm, the reduction of computation is about 75%. For not only image in the training set but also the image outside the training set, the encoding quality can be improved by 0.80dB~ 0.90dB compared to the basic SOFM algorithm.

Keywords Vector quantization, Self-organizing feature map neural network, Image compression

0 引言

矢量量化技术^[1,2]已经成功地应用于语音编码和图象压缩系统中. 矢量量化可以定义为从 k 维欧几里德空间 R^k 到其一个有限子集 C 的一个映射, 即 $Q: R^k \rightarrow C$, 其中 $C = \{Y_1, Y_2, \dots, Y_N | Y_i \in R^k\}$ 称为码书, Y_i 称为码字, N 为码书长度. 该映射满足:

$Q(V) \in R^k = Y_p$, 其中, $V = (v_1, v_2, \dots, v_k)$ 为 R^k 中的 k 维矢量, $Y_p = (y_{p1}, y_{p2}, \dots, y_{pk})$ 为码书 C 中的码字, 并满足

$$d(V, Y_p) = \min_{1 \leq j \leq N} (d(V, Y_j)) \quad (1)$$

其中, $d(V, Y_j)$ 为矢量 V 与码字 Y_j 之间的失真测度. 常用的失真测度为欧氏距离的平方, 其表达式为

$$d(V, Y_j) = \sum_{l=1}^k (v_l - y_{jl})^2 \quad (2)$$

考虑 k 维欧几里德空间的训练矢量集 $S = \{X_1, X_2, \dots, X_M | X_i \in R^k\}$, 其中, M 为训练矢量个数. 码书设计的目的是将这些训练矢量分成互不重叠的 N 个聚类. 每个聚类都用一个码字来描述, 这个码字是其相应聚类的中心矢量, 所有这些码字则构成了码书 $C = \{Y_1, Y_2, \dots, Y_N\}$, 而分类的效果和性能用平均失真来描述. 这里设计码书算法的原则是使最终的平均失真最小, 而平均失真可以用均方误差来描述, 即

$$MSE = \frac{1}{M} \sum_{i=1}^M d(X_i, Q(X_i)) \quad (3)$$

这里, $Q(X_i)$ 表示码书中与训练矢量 X_i 最相近的码字.

作为人工神经网络的一种应用, 许多学者已经成功地将 Kohonen 的自组织特征映射算法(SOFM)应用于图象的矢量量化编码^[3], 但该算法的缺点是计算量大, 而且生成的码书性能较差. 为此, 本文对基本的 SOFM 算法的权值调整方法作了一些改进, 从而使码书性能得到了改善. 与此同时, 本文在决定获胜神经元的过程中, 采用了快速搜索算法, 从而大大降低了搜索获胜神经元过程的计算量.

1 算 法

Kohonen 提出的自组织特征映射神经网络是一种具有侧向联想能力的两层结构网络(如图 1(a)所示), 它采用SOFM学习算法, 其输出节点呈二维


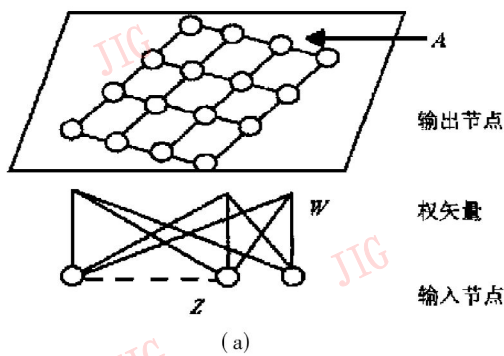


图 1 自组织特征映射神经网络

阵列分布, 每个输入节点与输出节点之间有可变权值连接, 且每个输出节点都有一个拓扑邻域, 其邻域大小随时间变化, 一种可能的拓扑邻域变化如图 1(b)所示. 因此, Kohonen 自组织特征映射网络的学习是一种无监督的聚类方法, 对相近的输入模式, 输出节点也是拓扑意义上相邻的.

1.1 基本的 SOFM 算法

设训练矢量数为 M , 且训练矢量集表示为 $S = \{X_1, X_2, \dots, X_M\}$, 网络有 k 个输入节点(等于矢量维数), N 个输出节点(等于码书大小), 各输入节点到各输出节点的权值为 $y_{jl}, l \in [1, k], j \in [1, N]$, 即为码书 $C = \{Y_1, Y_2, \dots, Y_N\}$ 的第 j 个码字 Y_j 的第 l 个分量, 则基本的 SOFM 算法步骤如下:

- (1) 初始化权值 $y_{jl}(0), l \in [1, k], j \in [1, N]$, 可从训练序列中随机取数.
- (2) 输入训练矢量 $X_i = \{x_{i1}, x_{i2}, \dots, x_{ik}\}, i \in [1, M], X_i$ 以并行方式输入到每一个神经元.
- (3) 计算输入训练矢量与码书中各码矢(输出节点的权矢量)间的失真, 选择最小失真的神经元 j' 为获胜神经元, 按下式调整码矢 j' 及 j' 拓扑邻域内各码矢的权值, 其它权值保持不变, 即

$$d_{j'} = \min_{1 \leq j \leq N} \left| \sum_{l=1}^k [x_{il} - y_{jl}(t)]^2 \right| \quad j' \in [1, N]$$

$$y_{jl}(t+1) = y_{jl}(t) + \alpha(t)[x_{il} - y_{jl}(t)] \quad (4)$$

式中, $j \in NE_{j'}(t), l \in [1, k], t$ 为迭代次数, $NE_{j'}(t)$ 为码矢 j' 的邻域, 且是 t 的减函数, $\alpha(t)$ 为学习速率因子, 一般选 $0 < \alpha(t) < 1$, 以保证算法的收敛.

- (4) 对所有输入训练矢量, 重复步骤(2)至(3), 直至算法收敛.

上述算法除确定获胜神经元外, 所有的运算都是并行的.

由式(4)可见, 权矢量 $Y_j(t+1)$ 实际上是权矢量 $Y_j(t)$ 和输入矢量 X_i 的矢量加权和, 图 2 的几何表示说明了权矢量(码字)的调整过程. 图中, 点 A 代表权矢量 $Y_j(t+1)$, 点 B 代表权矢量 $Y_j(t)$, 点 C 代表输入矢量 X_i . 由图 2 可见, 按式(4)修正后的权矢量




图 2 式(4)的几何表示

A 位于 B、C 的连线上,即调整的过程就是使点 B 向输入矢量 X_i 所在的位置靠拢.

1.2 改进的 SOFM 算法

基本的 SOFM 算法在选择获胜神经元时需要进行 N 次失真计算,那么 M 个输入矢量需要进行 MN 次失真计算,如果平均迭代次数为 R ,则共需 MNR 次失真计算,由此可见,该计算量是相当大的.基于此,本文在选取获胜神经元时,采用了一些距离不等式判据来减少许多失真计算,并对基本 SOFM 算法的权值调整方法作了一些改动,以提高码书的性能.

将一个矢量各分量的和定义为一个矢量的和值.设输入矢量 X_i 的和值为 $S_{X_i}, i \in [1, M]$, 码字 Y_j 的和值为 $S_{Y_j}, j \in [1, N]$, 即

$$S_{X_i} = \sum_{l=1}^k x_{il}, S_{Y_j} = \sum_{l=1}^k y_{jl}$$

容易证明

$$d(X_i, Y_j) = \sum_{l=1}^k (x_{il} - y_{jl})^2 \geq k \left| \frac{\sum_{l=1}^k (x_{il} - y_{jl})}{k} \right|^2 = \frac{(S_{X_i} - S_{Y_j})^2}{k} \quad (5)$$

设当前的最小失真为 d_{\min} , 并令 $MD_1 = kd_{\min}$. 若

$$(S_{X_i} - S_{Y_j})^2 \geq MD_1 \quad (6)$$

则根据式(5)可得

$$d(X_i, Y_j) \geq d_{\min} \quad (7)$$

因此,可以在每次搜索获胜神经元前,预先计算 N 个码字的和值 $S_{Y_j}, j \in [1, N]$, 并保存在码书中,同时在搜索获胜神经元过程中预先计算 MD_1 , 然后判断码字 Y_j 的和值 S_{Y_j} 是否满足式(6), 若满足,则码字 Y_j 可以排除,而免去距离计算.

另外,根据距离测度的三角不等式性质,可得

$$\sqrt{d(Y_l, Y_j)} \leq \sqrt{d(Y_l, X_i)} + \sqrt{d(Y_j, X_i)} \quad (8)$$

此处, X_i 为输入矢量, Y_l 和 Y_j 是码书 C 中的任意两个码字.假设 Y_j 是与目前输入矢量 X_i 最近的码字,如果码字 Y_l 要比码字 Y_j 更接近于输入矢量 X_i , 则

$$\sqrt{d(Y_l, Y_j)} \leq 2 \sqrt{d(Y_j, X_i)}, \text{ 即 } d(Y_l, Y_j) \leq 4d(Y_j, X_i) \quad (9)$$

同时也容易证明

$$d(Y_l, Y_j) = \sum_{i=1}^k (y_{li} - y_{ji})^2 \geq k \left| \frac{\sum_{i=1}^k (y_{li} - y_{ji})}{k} \right|^2 = \frac{(S_{Y_l} - S_{Y_j})^2}{k} \quad (10)$$

设当前最小失真 $d_{\min} = d(Y_j, X_i)$, 并令 $MD_1 = 4kd_{\min}$. 若

$$(S_{Y_l} - S_{Y_j})^2 \geq MD_2 \quad (11)$$

则根据式(10)可得

$$d(Y_l, Y_j) \geq 4d_{\min} \quad (12)$$

从而 Y_l 就可以排除,而无需计算其距离.因此,也就可以在每次搜索获胜神经元前,预先计算 N 个码字的和值,并保存在码书中,而在搜索获胜神经元过程中预先计算 MD_2 , 然后用式(11)来排除一些码字.

根据以上两条不等式判据,本文改进的快速 SOFM 算法可以描述为:

(1) 初始化权值 $y_{jl}(0), l \in [1, k], j \in [1, N]$, 可从训练序列中随机取数.

(2) 计算当前码书中各码矢 $y_{jl}(t)$ 的和值 $S_{Y_j}, j \in [1, N]$.

(3) 计算输入训练矢量 X_i 的和值 $S_{X_i}, i \in [1, M]$, X_i 以并行方式输入到每一个神经元.

(4) 根据以上两条不等式判据和文献[4]提出的部分失真排除算法,来搜索与训练矢量 X_i 距离最小的神经元 j' , 将其作为获胜神经元,并按下式调整码矢 j' 及 j' 拓扑邻域内码矢的权值,而其它权值保持不变,即

$$d_{j'} = \min_{1 \leq j \leq N} \left| \sum_{l=1}^k [x_{il} - y_{jl}(t)]^2 \right| \quad j' \in [1, N]$$
$$y_{jl}(t+1) = y_{jl}(t) + \alpha(t) \left| \frac{1}{N_{j'}} \sum_{d_j} x_{il} - y_{jl}(t) \right| \quad (13)$$

式中, $j \in NE_{j'}(t), l \in [1, k], t$ 为迭代次数, $N_{j'}$ 为当前与码矢量 j' 距离最近的训练矢量数目, $\sum_{d_j} x_{il}$ 为当前与码矢量 j' 距离最近的那些训练矢量的第 l 分量的和, $NE_{j'}(t)$ 为码矢 j' 的邻域, 且是 t 的减函数, $\alpha(t)$ 为学习速率因子, 一般选 $0 < \alpha(t) < 1$, 以保证算法的收敛.

(5) 对所有训练矢量,重复步骤(2)至(4),直至算法收敛.

由式(13)可见,权矢量 $Y_j(t+1)$ 实际上是权矢量 $Y_j(t)$ 和当前与码矢量 j' 距离最近的那些输入矢量的加权和.图3的几何表示说明了权矢量的调整过程.其中,设点 A 代表权矢量 $Y_j(t+1)$, 点 B 代表权矢量 $Y_j(t)$, 点 C、D、E... 代表当前与码矢量 j' 距离最近的那些输入矢量.由图3可见按式(13)修正后的权值 A 位于点 B 和点 C、D、E... 的中心矢量 Q 的连线上,即调整的过程就是使点 B 向中心矢量 Q




图 3 式(13)的几何表示

所在的位置靠拢.

2 实验结果

为了验证本文算法的有效性, 本文把基本的 SOFM 算法和改进的 SOFM 算法分别用于图象的压缩编码. 本文用 512×512 象素, 256 级灰度的 Lena 图及 Peppers 图作为训练图象进行码书设计,

把生成的码书用于训练集内的 Lena 图、Peppers 图的编码和训练集外的 F16 飞机图象的编码. 在实验中取

$$\alpha(t) = A_1 \exp\{-t/T_1\}$$

$$NE_j(t) = A_2 + A_3 \exp\{-t/T_2\}$$

其中, A_1, A_2, A_3, T_1, T_2 为常数, 同时, 将图象分成 4×4 子块, 将每一小块的 16 个象素灰度值作一个训练矢量, 依次送入神经网络. 网络输出节点的数量 N 分别为 256, 512, 1 024, 即码书尺寸分别为 256, 512, 1 024. 用上述两种算法在 Pentium II 微机上对所有训练矢量进行训练. 为了给出编码图象的主观质量, 图 4 给出了以训练集内的 Lena 图为例(码书大小为 256)的不同算法恢复效果对比. 图 5 给出了以训练集外的 F16 飞机图为例(码书大小为 256)的不同算法恢复效果对比.



(a) 原始的 Lena 图

(b) 基本算法的恢复图象

(c) 改进算法的恢复图象

图 4 训练集内的 Lena 图象不同算法恢复效果对比(码书大小为 256)



(a) 原始的 F16 图

(b) 基本算法的恢复图象

(c) 改进算法的恢复图象

图 5 训练集外的 F16 图象不同算法恢复效果对比(码书大小为 256)

表1 基于SOFM码书设计方法的编码质量PSNR和设计时间比较

码书尺寸	PSNR(dB)						设计时间(s)	
	基本算法			改进算法			基本算法	改进算法
	训练集内		训练集外	训练集内		训练集外		
	Lena	Peppers	F16	Lena	Peppers	F16		
256	28.92	28.54	25.35	29.74	29.44	26.22	910	243
512	31.23	30.89	27.76	32.01	32.81	28.62	1 193	375
1 024	33.45	32.98	30.01	34.23	33.87	30.80	1 790	435

经过训练后,各神经元权矢量趋于稳定值,表1给出了编码后的尖峰信噪比PSNR和码书设计时间。

从测试的结果可以看到,对于不同大小的码书,采用本文提出的算法都可以有效地减少码书设计时间和提高码书性能,相对于基本算法,码书设计时间减少了约75%。不论对于训练集内的图象还是对于训练集外的图象,和基本算法相比,编码质量均提高0.80dB~0.90dB左右。

3 结论

本文介绍了一种基于自组织特征映射神经网络的矢量量化方法。对自组织特征映射算法(SOFM)的权值调整方法作了一些改进,以使码书性能得到了改善。与此同时,在决定获胜神经元的过程中采用了快速搜索算法,从而免去了许多距离计算,从而大大降低了搜索获胜神经元过程中的计算量。

参考文献

- 1 Linde Y, Buzo A, Gray R M. An algorithm for vector quantizer design. IEEE Trans. On Commun., 1980, 28(1): 84~ 95.
- 2 Gersho A, Gray R M. Vector quantization and signal compression. Boston, MA: Kluwer, 1992.

- 3 Nasrabadi N M, Feng Y. Vector quantization of images based upon the Kohonen self-organizing feature maps. Proc. ICNN, San Diego, 1988, 1: 101~ 108.
- 4 Bei C D, Gray R M. An improvement on minimum distortion encoding algorithm for vector quantization. IEEE Trans. On Commun., 1985, 33(10): 1132~ 1133.



陆哲明 哈尔滨工业大学自动化测试与控制系博士研究生。1995年获哈尔滨工业大学电气工程系学士学位,1997年获哈尔滨工业大学电气工程系硕士学位。研究方向为数据压缩和图象编码、模式识别。



孙圣和 哈尔滨工业大学自动化测试与控制系教授,博导。中国电子学会会士,电子学报编委。获多项国家级和省部级科技成果奖。已发表著作5本,论文150多篇。研究领域包括计算机测试与控制、信号处理与系统辨识、数据压缩编码。