

一种基于 PCA/SOFM 混合神经网络的 图象压缩算法

许 锋 方 骏 卢建刚 孙优贤

(浙江大学工业控制技术国家重点实验室, 杭州 310027)

摘 要 鉴于用神经网络实现图象压缩是一种非常有效的方法, 为此提出了一种基于 PCA/SOFM 混合神经网络的图象压缩编码算法, 并对 SOFM 网络学习参数的优化进行了探讨. 实验证明, 与 PCA+SOFM 连续编码算法和基本 SOFM 算法相比, 这种混合编码算法, 由于占用存储空间少, 因而降低了码书设计的计算量, 并改善了码书的性能.

关键词 图象处理(510·4050) 矢量量化 变换编码 混合编码 神经网络 自组织特征映射 主元分析

中图分类号: TN919.81 **文献标识码:** A **文章编号:** 1006-8961(2003)09-1100-05

An Image Compressing Algorithm Based on PCA/SOFM Hybrid Neural Network

XU Feng, FANG Tao, LU Jian-gang, SUN You-xian

(National Laboratory of Industrial Control Technology, Zhejiang University, Hangzhou 310027)

Abstract Neural network is a very efficient method for image compression. It is suited to the problem of image compression due to its massively parallel and distributed architecture. Principle component analysis (PCA) neural network model and self-organizing feature map (SOFM) neural network model are often adopted for image compression in many references. In this paper, the authors propose an image compressing algorithm based on PCA/SOFM hybrid neural network, which has the advantages of both PCA and SOFM. A new method of selecting initial codebook and distortion criterion is presented to improve the efficiency of SOFM neural network according to the statistical feature of PCA transformational coefficient. Simulation results show that compared to successive PCA and SOFM algorithm or basic SOFM algorithm, PCA/SOFM hybrid algorithm has many advantages: lower memory storage; the substantial reduction of computation and the better performance of codebook.

Keywords Vector quantization (VQ), Transform coding, Hybrid coding, Neural network, Self-organizing feature map (SOFM), Principle component analysis (PCA)

0 引 言

自 Linde, Buzo 和 Gray 等于 1980 年提出了 LBG 算法^[1]以来, 矢量量化 (VQ) 作为一种高效的数据压缩算法, 在图象压缩、语音编码等系统中得到了广泛的应用和研究^[2-3]. 虽然矢量量化算法具有高效压缩和解码迅速等优点, 但传统的矢量量化方法存在着许多自身无法克服的缺陷: 如对初始码书很敏感, 即初始码书的选取, 对最优码书设计影响很大; 编码时间长, 不能够反映图象信源的统计特性;

解码恢复图象质量不好, 即存在可见的方块效应和图象细节的丢失等.

针对基本矢量量化的不足, 近年来许多研究人员在矢量量化算法优化方面进行了探索和改进, 文献^[4]详细综述了图象矢量量化的研究现状和发展方向. 目前越来越多的研究人员把目光投向了将矢量量化与其他的编码方法相结合的领域, 如 Kim 和 Lee 提出了一种基于人眼视觉特性的离散余弦变换 (DCT) 矢量量化算法^[5], 该算法由于是通过 8×8 DCT 变换系数进行分类和矢量量化, 因此压缩比高, 主观评价质量良好. 文献^[6]提出了 VQ +

基金项目: 国家自然科学基金 NSFC-60084001; 中法先进研究计划 PRAS101-04 项目

收稿日期: 2002-07-24; 改回日期: 2003-04-15

DPCM(差分脉冲编码)+DCT 算法,同样具有很好的编码效果.此外,还有矢量量化与小波变换相结合的算法^[7],分形变换与矢量量化相结合的算法^[8].种种研究表明,将矢量量化方法与其他编码方法相结合的方向是行之有效的.

主元分析(PCA)是一种有效的图象变换编码算法,由于它能够提取图象数据的主特征分量,因此能在降低图象输入数据维数的同时,使压缩图象达到最小失真.而 Kohonen 自组织特征映射(SOFM)算法用于图象矢量量化则具有不易受初始码本的影响,同时能够保持图象数据的拓扑结构等优点.为此本文将两者结合,提出了 PCA/SOFM 混合神经网络图象混合编码算法,即先用 PCA 对图象进行降维处理,然后用 SOFM 神经网络进行码本设计,同时根据 PCA 变换系数的统计特征对 SOFM 神经网络学习训练的参数进行了优化.实验表明,该混合编码算法的编码效果要比 PCA 和 SOFM 连续编码算法效果好,还减少了存储空间,比起基本 SOFM 算法,不仅设计时间能够大大降低,而且编码效果也明显改善.

1 PCA/SOFM 混合神经网络编码算法

图 1 是 PCA+SOFM 连续编码算法结构图,图 2 是 PCA/SOFM 混合神经网络结构图.图 2 的 PCA/SOFM 混合编码算法不等同于图 1 的 PCA+SOFM 连续编码算法,PCA+SOFM 连续编码算法只是 PCA 变换编码和 SOFM 矢量量化的简单结合,而 PCA/SOFM 混合编码算法基本原理则是用 SOFM 神经网络来设计码书,尽管 SOFM 神经网络比起 LBG 算法设计码书有很大的优势,但由于




图 1 PCA+SOFM 连续编码算法结构图




图 2 PCA/SOFM 混合神经网络结构图

SOFM 算法具有收敛速度慢,计算量大等缺点,因此应先用 PCA 线性神经网络对输入矢量(图象子方块)进行降维处理.这样经 PCA 线性神经网络处理后,SOFM 神经网络处理的数据量大大地降低,同时由于 PCA 变换系数具有明显的统计特征和特征意义,因此根据这些统计特征,可以对 SOFM 神经网络的训练参数进行优化,以便提高图象编码效率.

1.1 PCA 线性神经网络

PCA/SOFM 混合神经网络第 1 部分是 PCA 线性神经网络.该网络的输入矢量是图象子块 X_{PCA} ,输出矢量是 PCA 变换系数 Y_{PCA} ,神经网络权值 W_{PCA} 是 PCA 投影空间的 PCA 变换矩阵.具体算法如下:

- (1) 设定第 i 个网络单元节点的神经网络初始权值 $W_{PCA}(i)$ 和权值更新步长 η .
- (2) 原始图象按照图象子块(如 4×4)进行分割,然后转换成一维矢量作为 PCA 线性神经网络的训练矢量 X_{PCA}^t .
- (3) PCA 线性神经网络的输出矢量 Y_{PCA}^t 为

$$Y_{PCA}^t(i) = \sum_{j=1}^n W_{PCA}^t(i, j) X_{PCA}^t(j) \quad (1)$$

式中, t 为迭代次数, n 是 PCA 神经网络输入矢量 X_{PCA} 的维数.

- (4) 神经网络权值修正算法采用 Sanger 提出的广义 Hebb 算法(GHA)^[9].

$$W_{PCA}^{t+1}(i) = W_{PCA}^t(i) + \eta Y_{PCA}^t(i) [X_{PCA}^t - Y_{PCA}^t(i) W_{PCA}^t(i) - \sum_{j=1}^{i-1} Y_{PCA}^t(j) W_{PCA}^t(j)] \quad (2)$$

- (5) 重复步骤(2)至(4),直至算法收敛.

1.2 SOFM 神经网络

PCA/SOFM 混合神经网络第 2 部分是 SOFM 神经网络.该网络输入矢量是 PCA 变换系数 X_{SOFM} ,其神经网络的权值矩阵 W_{SOFM} 是结果码书,其神经网络输出矢量为 Y_{SOFM} ,具体算法如下:

- (1) 根据 PCA 变换系数统计特征确定第 i 个网络单元节点的初始码书 $W_{SOFM}^0(i)$,并设定初始拓扑邻域 $E^0, i = 1, 2, \dots, N_{SOFM}$,其中 N_{SOFM} 为码书大小,即 SOFM 神经网络隐层单元数.
- (2) 将 PCA 线性神经网络的输出变量 PCA 变换系数作为 SOFM 网络训练矢量 X_{SOFM}^0 .
- (3) 按一定的失真准则,通过计算输入矢量与各码矢(即神经网络权矢量)的失真值 d_i 来选择具有最小失真值的网络节点 \hat{i} .若失真值为

$$d_i^{(t)} = \sum_{j=1}^m [X_{SOFM}^{(t)}(j) - W_{SOFM}^{(t)}(j, i)]^2 \quad (3)$$

$(i = 1, 2, \dots, N_{SOFM})$

m 是训练欠量的维数, 则最小失真值 d_i 为 $d_i(t) = \min\{d_i\}, (i=1, 2, \dots, N_{SOFM})$. 按下式调整与 \hat{i} 对应的最小失真码矢 Z_i 及拓扑邻域内码矢 $E_i(t)$.

$$W_{SOFM}^{(t+1)}(j) = \begin{cases} W_{SOFM}^{(t)}(j) + v^{(t)} [X_{SOFM}^{(t)}(j) - W_{SOFM}^{(t)}(j, \hat{i})] & Z_i \in [Z_i^{(t)}, E_i^{(t)}] \\ W_{SOFM}^{(t)}(j) & \text{其他} \end{cases} \quad (4)$$

式中, t 为迭代次数; $Z_i^{(t)}$ 为网络单元节点 i 的码矢, $E_i^{(t)}$ 的邻域大小由邻域调整参数 $\beta^{(t)}$ 确定, 通常

$$\beta^{(t)} = A_{\min} + A_{\max} e^{-t/T_1} \quad (5)$$

其中, A_{\min} 为最小邻域, 常取 1; A_{\max} 为训练开始时的最大邻域; T_1 为衰减常数.

式(4)中 $v^{(t)}$ 为学习速度, 它反映了码矢分量变化调整的幅度大小. 理论上讲, 一般选 $0 < v^{(t)} < 1$, 以保证算法的收敛. $v^{(t)}$ 通常由下式确定

$$v^{(t)} = v_{\max} e^{-t/T_2} \quad (6)$$

式中, v_{\max} 为训练开始时的最大学习速度; T_2 同 T_1 .

(4) 对所有输入训练矢量, 重复步骤(2)至(3), 直至算法收敛.

1.3 SOFM 神经网络参数的优化

1.3.1 PCA 变换系数统计特征

PCA 编码算法是在均方误差意义下的最佳变换. 它能够抽取图象的主特征分量, 因此能在得到较高压缩比的同时, 使压缩图象达到最小失真. PCA 编码应首先计算输入向量的相关矩阵 R_{xx} 的特征值和特征向量, 同时将特征向量单位化, 再按特征值的大小重新排序; 然后将原始图象数据投影到由前 m 个特征向量构成的子空间中去, 若用 u_1, u_2, \dots, u_m 表示投影后的各分量, 则 u_1 具有最大方差, 即与 u_2 不相关的方向中, u_2 有最大方差, 依次类推^[10]如图 3 所示: 由于图象数据的最大特征向量的投影方差最大, 因此数据分类能力最强. 图象数据的最大特征向量的投影系数, 其对图象数据的分类贡献最大.

图象的 PCA 变换系数有很明显的统计特性, 本文对 4 幅图象(Lena, Girl, Couple and Baboo)的投影系数的概率分布进行了分析, 通过分析发现, 最大主特征向量的投影系数分布比较广, 但概率分布没有明显特征, 而图象数据的其他 7 个特征向量投影系数分布则很有规律, 即数据点的分布基本上集中在零值附近, 呈近似的正态分布(如图 4 所示).




图 3 PCA 变换的几何说明

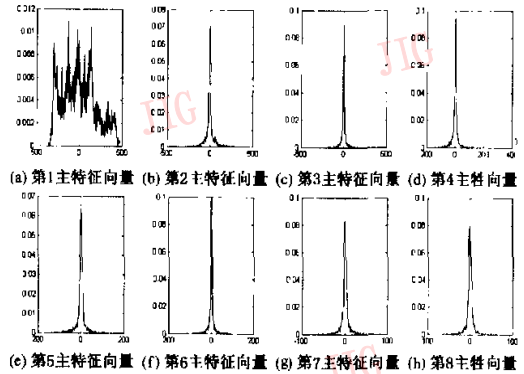


图 4 PCA 变换系数概率分布图(Lena 图象)

(纵坐标为图象系数概率分布, 横坐标为图象投影系数)

1.3.2 SOFM 神经网络参数的优化策略

本文根据 PCA 变换系数的统计特征, 首先选择了 SOFM 神经网络的初始码书, 然后进一步依据失真准则(即输入矢量与权值矢量的距离函数)进行优化, 因其不仅可提高收敛速度, 还能改善结果码书的性能.

(1) 贡献率 η_i 的求取. 贡献率定义为投影空间中特征向量基对图象数据有效分类的影响, 严格意义上说, 应该通过计算图象数据各特征向量的投影系数的方差值来求取贡献率. 本文则首先通过设定概率阈值 $\rho_{\text{threshold}}$, 然后通过统计各特征向量上超过 $\rho_{\text{threshold}}$ 的系数个数 n_i 来求取贡献率, 则贡献率 ξ_i 等于

$$\xi_i = \frac{n_i}{\sum_{j=1}^l n_j} \quad (j = 1, 2, \dots, l) \quad (7)$$

l 为主特征向量个数, 其等于 SOFM 输入矢量的维数 m .

(2) 初始码书的选择不是从训练矢量集中随机选取, 而是通过统计法即根据 PCA 变换系数概率分布特征来选取的, 码书的大小为 N_{SOFM} , 具体规则如下:

初始码书中最大主特征向量系数的选取. 由于最大主特征向量投影系数方差最大, 虽然其对图象数据

分类贡献最大,但根据统计图系数概率分布则没有规律可言,所以本文初始码书的最大主特征分量的选取是用间隔法,即根据主特征向量对数据分类的贡献率设定主特征向量系数个数 M ,并设初始码书中的最大主特征向量系数重复次数为 N_{SOFM}/M ,则 M 个初始主特征向量系数 $W_{\text{SOFM}}^{(0)}(1, j)$ 选取为

$$W_{\text{SOFM}}^{(0)}(1, j) = \min Y_{\text{SOFM}}^{(0)}(1) + \frac{j}{M} [\max Y_{\text{SOFM}}^{(0)}(1) - \min Y_{\text{SOFM}}^{(0)}(1)]$$

$$(t=1, 2, \dots, K; j=1, 2, \dots, M) \quad (8)$$

K 为 SOFM 神经网络训练矢量个数。

初始码书中其他主特征向量系数的选取 因为这些主特征向量对图象数据的分类贡献没有最大主特征向量贡献大,所以可以想象结果码书中这些主特征向量系数集中在系数统计图中概率比较大的点上.通过设定概率阈值 $P_{\text{threshold}}$,可以获得初始码书中这些特征向量系数的选取范围.

$$[\min Y_{\text{SOFM}}^{(0)}(i), \max Y_{\text{SOFM}}^{(0)}(i)],$$

$$(p[\min Y_{\text{SOFM}}^{(0)}(i)] \geq p_{\text{threshold}}, p[\max Y_{\text{SOFM}}^{(0)}(i)] \geq p_{\text{threshold}})$$

$$(i=2, 3, \dots, N_{\text{SOFM}}; t=1, 2, \dots, K) \quad (9)$$

然后随机从此范围选取初始码书系数值。

(3)失真准则 d_i (即输入矢量与权值矢量的距离函数)的优化 因为各特征向量对图象数据分类贡献有大有小,所以基本 SOFM 算法中的失真准则式(3)并不能有效地改善码本性能.本文将贡献率与失真相关联,提出了一种新的失真准则

$$d_i^{(w)} = \sum_{j=1}^m \xi_j [X_{\text{SOFM}}^{(0)}(j) - X_{\text{SOFM}}^{(0)}(j, i)]^2$$

$$i = 1, 2, \dots, N_{\text{SOFM}} \quad (10)$$

实验证明,结合贡献率的失真准则能有效地改善码本的性能。

2 实验及结果

为了验证算法的有效性,本文把 PCA/SOFM 混合神经网络编码算法和 PCA+SOFM 连续编码算法和基本 SOFM 编码算法分别用于图象的压缩编码,并比较各自的编码效果,实验时,采用信噪比(SNR)作为描述码本性能的指标.对于 $N_1 \times N_2$ 像素的图象,SNR 定义为

$$\text{SNR} = 10 \lg \frac{\sum_{i=1}^{N_1-1} \sum_{j=1}^{N_2-1} I_{i,j}^2}{\sum_{i=1}^{N_1-1} \sum_{j=1}^{N_2-1} (I_{i,j} - \hat{I}_{i,j})^2} \quad (11)$$

式(11)中,原始图象像素为 $I_{i,j}$,而重建图象像素为 $\hat{I}_{i,j}$.

本文采用的是 256×256 像素,256 级灰度的 Lena, Girl, Couple, Baboo 图象用于训练和压缩.压缩时首先将图象分为 4×4 子块,然后将每一小块的 16 个像素灰度值作一个训练矢量,依此送入 PCA 线性神经网络. PCA 线性神经网络输出节点为 8 维 PCA 变换系数矢量,其同时作为 SOFM 神经网络的输入矢量,用于进行码本设计。

本文提出的混合编码算法在赛扬 800/128M 的 PC 机上以 matlab 语言仿真实现,所涉及的所有实验都重复做了 15 次,然后取其平均值作为实验结果.试验结果表明混合编码算法恢复图象比较满意.图 5 给出了各种编码算法的恢复图象。



图 5 原始 Lena 图和各种算法的恢复图象

(1)PCA/SOFM 混合算法与相关算法编码效果的对比(见表 1)

从表 1 可以看出,PCA/SOFM 混合算法的码书性能和设计时间都优于 PCA+SOFM 连续编码算法和基本 SOFM 编码算法. SOFM 基本算法虽然

能处理大信息量数据,但码本性能却较差,可能是由于训练过程中输入信息量太大,码本不能在有限的时间内有效地正确聚类所致.而在 PCA/SOFM 混合神经网络中,由于 PCA 线性神经网络输出的变换系数矢量直接被 SOFM 神经网络训练,因而节省了

存储空间,不像 PCA + SOFM 连续变换编码算法中,PCA 变换系数需先全部计算存储,然后再作为 SOFM 神经网络的训练矢量那样复杂。

表 1 PCA/SOFM 混合算法与相关算法编码效果的对比 (码书尺寸 512Lena 图)

评价指标	PCA/SOFM 混合算法	PCA+SOFM 基本算法	SOFM 基本算法
SNR(dB)	28.798 0	26.341 6	23.502 6
设计时间(s)	170 5	262 3	325 6

(2)初始码书选择对图象编码性能和时间的影响(见表 2)

表 2 初始码书的选择对图象编码性能和时间的影响(Lena 图)

码书尺寸	SNR(dB)			设计时间(s)			压缩比
	统计法	等间隔法	随机法	统计法	等间隔法	随机法	
256	25.751 2	24.412 3	24.102 4	895	129 5	134 1	16:1
512	28.798 0	27.142 5	26.941 6	170 5	2349	241 2	8:1

表 3 失真准则对码书设计性能的影响(Lena 图)

码书尺寸	SNR(dB)		设计时间(s)	
	改进的失真准则	基本失真准则	改进的失真准则	基本失真准则
256	26.124 3	25.751 2	890	895
512	29.145 2	28.798 0	171 2	170 5

3 结 论

混合编码是目前图象编码领域中的热门研究课题,本文提出了一种基于 PCA/SOFM 混合神经网络的编码算法,并根据 PCA 投影系数的统计特性对 SOFM 神经网络的参数进行了优化,实验结果表明,该算法不仅明显地改善码书的性能,而且也降低了编码时间。

参 考 文 献

- Lind Y, Buzo A, Gray R M. An algorithm for vector quantizer design [J]. IEEE Transactions on Communications, 1980, COM-28(1): 84~95.
- Nasrabadi N M, King R A. Image coding using vector quantization, a review [J]. IEEE Transactions on Communications, 1988, 36(8): 957~971.
- Fang W C, Shen B J, Chen O T. A neural network based VLSI vector quantizer for real-time compression[A]. In: Proceedings Data Compression Conference [C], Snowbird, Utah, USA, 1991, 342~351.
- 张震,万国金,吴建华. 矢量量化在图象编码中的应用进展[J]. 数据采集与处理, 1999, 14(1): 52~56.
- Kim D S, Lee S U. Image vector quantizer based on classification in the DCT domain [J]. IEEE Transactions on Communication, 1991, COM-39(4): 1011~1016.
- 黎洪松,金子. 一种基于自组织神经网络的图象压缩编码算法

SOFM 神经网络初始码书的选择对图象编码的性能好坏和设计时间多少均有很大的影响. 实验中,采用了随机法,等间隔法和本文提出的统计法来初始化码书. 实验数据(见表 2)证明,用统计法设计初始码书不仅能够改善编码的性能,而且降低了码书设计时间,而等间隔法和随机法之间的优劣则很难区分,可能是因 PCA 变换系数不是均匀分布的缘故。


(3)失真准则对码书设计性能的影响(见表 3)

实验中,对 SOFM 神经网络的失真准则进行了设计. 从表 3 的数据中可以看出,采用本文改进的失真准则可改善码书性能。

- [J]. 电子学报, 1996, 24(1): 6~11.
- 王卫,蔡德钧,万发贵. 一种多分辨率图象混合编码方案[J]. 通信学报, 1995, 15(2): 71~78.
- 张颖. 基于分形的改进矢量量化器[D]. 广州:华南理工大学, 1997.
- Sanger T D. Optimal unsupervised learning in a single layer linear feedforward neural network[J]. Neural Networks, 1989, 2(2): 459~473.
- 阎平凡,张长水. 人工神经网络与模拟进化计算[M]. 北京:清华大学出版社, 2000.



许 钟 1977 年生,2003 年获浙江大学信息学院控制系硕士学位,现在宁波电信局计算机中心工作. 主要研究方向为神经网络、图象处理和现场总线。



方 强 1978 年生,2001 年获浙江大学自动化专业学士学位,现为浙江大学信息学院控制系硕士生. 主要研究方向为先进控制、图象处理和现场总线。



卢建刚 1968 年生,1995 年获浙江大学化学工程专业工学博士学位,现为浙江大学信息学院控制系副研究员. 主要研究方向为工业过程的建模、仿真、优化、控制和相关软件开发。



孙优贤 1940 年生,1964 年毕业于浙江大学化工自动化专业,现为浙江大学信息学院控制系教授,博士生导师,中国工程院院士. 主要研究方向为鲁棒控制和容错控制。