




主办: 中国科学院遥感与数字地球研究所
中国图象图形学学会
北京应用物理与计算数学研究所

中国图象图形学报

2015
02
VOL.20

ISSN1006-8961
CN11-3758/TB



等值面光线跟踪 P193



第20卷第2期（总第226期）

2015年2月16日

中国精品科技期刊
中国国际影响力优秀学术期刊
中国科技核心期刊

版权声明

凡向《中国图象图形学报》投稿，均视为同意在本刊网站及CNKI等全文数据库出版，所刊载论文已获得著作权人的授权。本刊所有图片均为非商业目的使用，所有内容，未经许可，不得转载或以其他方式使用。

Copyright

All rights reserved by Journal of Image and Graphics, Institute of Remote Sensing and Digital Earth, CAS. The content (including but not limited text, photo, etc) published in this journal is for non-commercial use.

主管单位 中国科学院

主办单位 中国科学院遥感与数字地球研究所

中国图象图形学学会

北京应用物理与计算数学研究所

主 编 李小文

编辑出版《中国图象图形学报》编辑出版委员会

邮政信箱 北京9718信箱

邮 编 100101

电子信箱 jig@irsa.ac.cn

电 话 010-64807995

网 址 www.cjig.cn

广告经营许可证 京朝工商广字第0361号

总 发 行 北京报刊发行局

订 购 全国各地邮局

海外发行 中国国际图书贸易集团有限公司

（邮政信箱：北京399信箱 邮编：100048）

印刷装订 北京科信印刷有限公司

Journal of Image and Graphics

Title inscription: Song Jian

Monthly, Started in 1996

Superintended by Chinese Academy of Sciences

Sponsored by Institute of Remote Sensing and Digital Earth, CAS

China Society of Image and Graphics

Institute of Applied Physics and Computational Mathematics

Editor-in-Chief LI Xiaowen

Editor, Publisher Editorial and Publishing Board of Journal of Image and Graphics

P.O.Box 9718, Beijing, P.R.China

Zip code 100101

E-mail jig@radi.ac.cn

Telephone 010-64807995

Website www.cjig.cn

Distributed by Beijing Bureau for Distribution of Newspapers and Journals

Domestic All Local Post Offices in China

Overseas China International Book Trading Corporation
(P.O.Box 399, Beijing 100048, P.R.China))

Printed by Beijing Kexin Printing Co., Ltd.

CN 11-3758/TB

ISSN 1006-8961

CODEN ZTTXFZ

国外发行代号 M1406

国内邮发代号 82-831

国内定价 50.00元



多尺度活动网格在云场景仿真中的应用(第0202页)



自然环境视频中基于显著鲁棒轨迹的行为识别(第0245页)



虚拟手抓持力觉生成算法真实性的评价(第0280页)

图像处理和编码

引入神经网络中间神经元的快速小波图像压缩

张海涛, 张永霖 0159

拟正态分布扩散的图像平滑

周先春, 汪美玲, 周林锋 0169

可选特征的快速分形图像编码

袁宗文, 鲁业频, 杨汉生 0177

图像分析和识别

融合多尺度码本的全局编码图像分类

董振宇, 赵杰煜, 祝军 0183

计算机图形学

结合K-D树和Shell的快速动态等值面光线跟踪法

罗月童, 石放放, 张伟, 朱会国 0193

多尺度活动网格在云场景仿真中的应用

范晓磊, 张立民, 张建廷, 徐涛 0202

第十届和谐人机环境联合会议专栏

低资源语言的无监督语音关键词检测技术综述

杨鹏, 谢磊, 张艳宁 0211

快速离散Curvelet变换域的图像融合

杨勇, 董松, 黄淑英 0219

高效视频编码中变换跳过模式的快速选择

王宁, 张永飞, 樊锐 0229

主动学习的多标签图像在线分类

徐美香, 孙福明, 李豪杰 0237

自然环境视频中基于显著鲁棒轨迹的行为识别

易云, 王瀚漓 0245

特征变换和数据集分块的行人比对

沈洋, 林巍峭, 殷惠清 0254

移动手持环境下触摸式目标选择技术对比

辛义忠, 李岩, 袁伟强, 郑谦 0264

虚拟环境的用户意图捕获

程成, 赵东坡, 卢保安 0271

虚拟手抓持力觉生成算法真实性的评价

杨文珍, 许艳, 颜传武, 吴新丽, 张昊, 孟闯 0280

交互式乐器演奏的六自由度力觉渲染方法

童号, 史有姣, 王党校, 张玉茹 0288

CONTENTS

JOURNAL OF IMAGE AND GRAPHICS



Multi-scale moving grids and its application in clouds scene simulation(P0202)



Action recognition from unconstrained videos via salient and robust trajectory (P0245)



Validation the Authenticity of Virtual fingers Grasping Haptic Algorithm(P0280)

Image Processing and Coding

- Fast wavelet image compression introducing neural network of relay neuron
Zhang Haitao, Zhang Yonglin 0159
- Image smoothing algorithm based on matching normal distribution diffusion
Zhou Xianchun, Wang Meiling, Zhou Linfeng 0169
- Optional features fast fractal image coding algorithm
Yuan Zongwen, Lu Yepin, Yang Hansheng 0177

Image Analysis and Recognition

- Image classification based on global coding combined with multi-scale codebook
Dong Zhenyu, Zhao Jieyu, Zhu Jun 0183

Computer Graphics

- Fast isosurface ray tracing method by combining K-D tree and Shell
Luo Yuetong, Shi Fangfang, Zhang Wei, Zhu Huiguo 0193
- Multi-scale moving grids and its application in clouds scene simulation
Fan Xiaolei, Zhang Limin, Zhang Jianting, Xu Tao 0202

Column of HHME'2014

- Survey on unsupervised spoken term detection for low-resource languages
Yang Peng, Xie Lei, Zhang Yanning 0211
- Image fusion based on fast discrete Curvelet transform
Yang Yong, Tong Song, Huang Shuying 0219
- Fast transform skip mode decision for high efficiency video coding
Wang Ning, Zhang Yongfei, Fan Rui 0229
- Online multi-label image classification with active learning
Xu Meixiang, Sun Fuming, Li haojie 0237
- Action recognition from unconstrained videos via salient and robust trajectory
Yi Yun, Wang Hanli 0245
- Pedestrian re-identification based on feature transformation and dataset classification
Shen Yang, Lin Weiyao, Yin Huiqing 0254
- Comparison of target selection techniques in mobile handheld environment
Xin Yizhong, Li Yan, Yuan Weiqiang, Zheng Qian 0264
- Intent understanding for virtual environments
Cheng Cheng, Zhao Dongpo, Lu Baoan 0271
- Validation the authenticity of virtual fingers grasping haptic algorithm
Yang Wenzhen, Xu Yan, Yan Chuanwu, Wu Xinli, Zhang Hao, Meng Chuang 0280
- Interactive simulation of music instrument playing by a six degree-of-freedom haptic rendering approach
Tong Hao, Shi Youjiao, Wang Dangxiao, Zhang Yuru 0288

中图法分类号: TP751.1 文献标识码: A 文章编号: 1006-8961(2015)02-0159-10

论文引用格式: Zhang H T, Zhang Y L. Fast wavelet image compression introducing neural network of relay neuron[J]. Journal of Image and Graphics, 2015, 20(2): 0159-0168. [张海涛, 张永霖. 引入神经网络中间神经元的快速小波图像压缩[J]. 中国图象图形学报, 2015, 20(2): 0159-0168.] [DOI:10.11834/jig.20150201]

引入神经网络中间神经元的快速小波图像压缩

张海涛, 张永霖

辽宁工程技术大学软件学院, 葫芦岛 125105

摘要: 目的 针对自组织特征映射(SOFM)算法会出现严重的分块现象和快速小波变换在高压比的情况下图像恢复质量差的问题,提出引入神经网络中间神经元(relay neurons)的RSOFM-C矢量量化算法。方法 引入了中间神经元的概念,使用中间神经元有效解决了码字利用不均匀的问题,并在神经网络中间层给出了欧氏距离不等式判据,排除不满足失真测度的神经元,减少重复计算,加快学习速度。根据差分脉冲编码调制(DPCM)中的差值信号编码原理将RSOFM-C算法与快速小波变换结合,使用RSOFM-C算法对由快速小波变换得到的图像低频信号进一步压缩。结果 在仿真实验中,将本文算法与同类压缩方法进行对比,当压缩比为52%时,本文算法的峰值信噪比(PSNR)达到了39.28 dB,远远高于其他方法。结果表明,本文的压缩算法消除了分块现象,并且在保证高压比的同时获得高质量的重构图像。结论 实验结果表明,本文提出的引入了中间神经元的快速小波压缩方法,具有高压比、高保真、速度快等优点,可以高效地压缩图像。

关键词: 图像压缩;中间神经元;快速小波变换;神经网络;自组织特征映射

Fast wavelet image compression introducing neural network of relay neuron

Zhang Haitao, Zhang Yonglin

School of Software, Liaoning Technical University, Huludao 125105, China

Abstract: **Objective** A fast wavelet transform with high compression ratio results in a serious block phenomenon in self-organization feature mapping (SOFM) algorithm and a poor image restoration quality. **Method** To address the above problem, RSOFM-C vector quantization algorithm is proposed, in which the neural network relay neurons are introduced. The use of relay neurons addresses the problem of uneven code words by introducing the concept of relay neurons. Euclidean distance discriminant inequality is given in neural network middle layer. Neurons that failed to satisfy the distortion measure are excluded, thus reducing repeated calculation and accelerating the learning speed. SOFM-C algorithm and fast wavelet transform are combined according to the difference signal coding principle in DPCM. The low frequency image signal is further compressed by using the RSOFM-C algorithm. **Result** In the simulation experiment, the proposed algorithm is compared with similar compression method. At 52% compression ratio, the peak signal-to-noise ratio of this method reached 39.28 dB, which is higher than that of other methods. The compression algorithm can eliminate the blocking phenomenon,

收稿日期:2014-05-08;修回日期:2014-09-22

基金项目:国家自然科学基金项目(61172144)

第一作者简介:张海涛(1974—),男,副教授,2014年于辽宁工程技术大学获得地图制图学与地理信息工程专业博士学位,主要研究方向为图形图像处理、高光谱图像压缩。E-mail: Intuzht@163.com

通信作者:张永霖, E-mail: zyl0920010925@163.com

Supported by: National Natural Science Foundation of China (61172144)

and a high quality reconstructed image can be obtained while ensuring high compression ratio. **Conclusion** Experiment shows that by introducing the fast wavelet compression method of interneuron, images can be compressed with high compression ratio, fidelity, and speed.

Key words: image compression; relay neuron; fast wavelet transform; neural network; self-organization feature mapping (SOFM-C)

0 引言

Kohonen 提出的自组织特征映射 (SOFM)^[1-3] 被认为是最适合码书设计的神经网络模型,但是 SOFM 算法的时间复杂度较高,并且该算法对码字的利用不均匀,导致有些神经元无法胜出,从而在神经网络中产生“死神经元”,严重影响了图像的压缩效果。Bebis 等人提出了 SOFM-C 算法^[4],该算法中的神经元使用率更加均匀,避免了“死神经元”的问题。黎洪松等人提出了频率敏感自组织特征映射 (FSOFM) 算法^[5],对网络学习训练参数的优化进行了探讨,引入了频率敏感因子,在一定程度上减少 SOFM 算法中编码图像的分块现象。王卫提出了改进的自组织特征映射 (MSOFM) 算法^[6],设计了 DCT (离散余弦变换) 域的特征值,将特征值用于图像数据块的分类,该方法有效地减少了分块效应,解决了压缩比提高的同时图像质量变差的现象,但没有解决神经元利用不均的问题。马勇等人提出了 ASOFM-C 算法^[7],针对 SOFM 在胜出神经元的邻域内神经元修改权值的方法需要进一步改进,引入了辅助神经元 (auxiliary neurons) 的概念,获得了良好的码书。

矢量量化是一种利用相近元素采样高关联性的有损方法,它经常被用于图像和语言信号的压缩,它的核心内容是关于码书的设计^[8]。矢量量化^[9]的过程就是将输入矢量空间 $\mathbf{R}^k$ 分割成块,每个数据块是一个矢量,通过训练将满足相似测度的矢量聚为一类,对每个数据块指定代表矢量并分配索引。矢量量化的实质就是找出一种最优的空间分割以及每个数据块的质心,从而使失真误差最小。矢量量化方法在单独使用的情况下,对图像的压缩效果不明显,在高压缩比的情况下会产生分块现象,并且细节部分会变得模糊不可分辨。

小波分析^[9]是变换的一种最普遍使用的方法,它利用图像的统计相关性,将原始图像变换到了另

一个域中,分离低频与高频信号,有效集中了能量,因此具有良好的时频局部化特性。

为了实现较高的压缩比,采用 Kohonen 神经网络的矢量量化方法获得了较好的码书。根据 Agarwal 等人对中间神经元的研研究^[10],将中间神经元的数学模型与 RSOFM-C 算法结合;通过中间神经元来获得稳定的神经元权向量;利用不等式判据来加快神经网络收敛速度,减少不必要的失真运算;使用快速小波变换实现图像的分解和重构^[11],减少了失真。此种复合方法与单独使用小波变换或矢量量化方法相比,提高了压缩比,并且保证图像压缩后的质量,减小了 SOFM 中的分块现象。

1 RSOFM-C 神经网络

1.1 SOFM 神经网络结构

Kohonen 提出的自组织特征映射网络 (如图 1 所示),由输入层和输出层构成^[12],输入层又称匹配层,该层用来计算输入端向量与神经元之间距离的大小,也就是匹配程度;输出层又称竞争层,各个神经元需要针对匹配的程度大小而竞争,通过竞争来得到胜出神经元,胜出的神经元与在邻域范围内的神经元的权值向量进行更新,通过反复的竞争和更新以后,神经元成功地学习了输入向量,并保存为权值向量的形式,最终以聚类的思想将相似的向量聚集到一起,并指明索引。




图 1 神经网络结构图

Fig. 1 Neural network structure diagram

1.2 RSOFM-C 神经网络中间层

引入了中间神经元(relay neurons)的概念,神经网络中间层由中间神经元组成(如图2所示),中间神经元负责记录最后两次胜出的中间权矢量 P_j 和 P_{j-1} ,当神经元成为胜出神经元邻域内的神经元时,这个神经元要向输入向量和最后两次胜出的神经元权矢量 P_j 和 P_{j-1} 三者学习。

在神经网络中间层,利用欧氏距离不等式判断将超过当前最小欧氏距离的矢量进行排除,这样每个神经元就可以以较为均衡的几率胜出,减少了计算量,避免一些神经元永远无法取胜而产生“死神经元”,既保持了该神经元的特点,同时保持了拓扑不变性。




图2 RSOFM-C 中间层神经网络

Fig. 2 RSOFM-C interlayer neural network

2 矢量量化算法

2.1 SOFM-C 算法

设训练矢量个数为 L , 训练矢量集合表示为 $X = \{X_1, X_2, \dots, X_L\}$, 神经网络内有 K 个输入神经元, N 个输出神经元, 输入神经元到输出神经元的权矢量为 W_{ij} , 设 $i \in [1, N], j \in [1, K]$ 。

码书 $Y = \{Y_1, Y_2, \dots, Y_N\}$ 。邻域大小由邻域调整参数 $\beta(t)$ 确定。参数 $\alpha(t)$ 为偏置值的收敛参数。 $v(t)$ 为学习速度, 它反映了码书分量变化调整的幅度。

$$\beta(t) = A_1 + A_2 e^{-t/T_1} \quad (1)$$

$$v(t) = A_3 e^{-t/T_1} \quad (2)$$

式中, A_1 为最小邻域, 常取 1; A_2 为训练开始时的最

大邻域; A_3 为训练开始时的最大学习速度; T_1 为衰减常数。

SOFM-C 算法^[2]步骤如下:

1) 用随机数初始化连接权值 W_{ij} , 初始化学习速率 $v(0)$ ($0 < v(0) < 1$), 初始化邻域半径 $N_r(0)$, 初始化参数 $\alpha(t)$ 和 $\beta(t)$, 初始化偏置 $b_i = 1/c$ (c 为聚类类别数)。

2) 从训练集中选出训练矢量 $X_k, k \in [1, L-1]$, 以并行的方式输入到每个神经元。

3) 计算输入训练矢量 X_{kj} 与每个神经元的欧氏距离

$$d_j = \sum_{i=1}^K [X_{kj} - W_{ij}(t)]^2 - \alpha(t) \left(\frac{1}{c} - b_i \right) \quad (3)$$

$$j \in [1, N]$$

4) 计算 X_k 与码书中各个码字的欧氏距离, 设最小欧氏距离为 $d_{\min}$ 的神经元是胜出神经元 j^* 。

$$d_{\min} = \min_{1 \leq j \leq K} \left| \sum_{i=1}^K [X_{kj} - W_{ij}(t)] \right| \quad (4)$$

5) 更改胜出神经元 j^* 及其邻域内神经元的权矢量, 即

$$W_{ij}(t+1) = W_{ij}(t) + v(t) [X_{kj} - W_{ij}(t)]$$

6) 更新学习速率 $v(t)$ 及邻域半径 $N_r(t)$, $v(t)$ 是随着次数 t 的递增而递减的项, 取值为 0 和 1 之间, 以保证算法的收敛性。

$$N_r(t) = \text{int} \left[N_r(0) \left(1 - \frac{t}{T} \right) \right] \quad (5)$$

更新胜出神经元的偏置值 b_i , 更新参数 $\alpha(t)$, 即

$$\alpha(t) = \alpha(0) \left(1 - \frac{t}{T} \right) \quad (6)$$

$$b_i = b_i + \beta(1 - b_i) \quad (7)$$

7) 对所有训练矢量执行步骤 2)~7), 直至算法收敛或达到初始设定的最大迭代次数。

2.2 RSOFM-C 算法

设训练矢量个数为 L , 训练矢量集合表示为 $X = \{X_1, X_2, \dots, X_L\}$, 神经网络内有 K 个输入神经元, N 个输出神经元, 输入神经元到输出神经元的权矢量为 W_{ij} , 设 $i \in [1, N], j \in [1, K]$ 。从训练集中选出训练矢量 $X_k, k \in [1, L-1]$, 以并行的方式输入到每个神经元。参数 $\alpha(t)$, $\beta(t)$ 与 $v(t)$ 的描述见 SOFM-C 算法。

1) 用随机数初始化连接权值 W_{ij} , 初始化邻域半径 $N_r(0)$, 初始化学习速率 $v(0)$ ($0 < v(0) < 1$),

初始化参数 $\alpha(t)$ 和 $\beta(t)$, $b_i = 1/c$ (c 为聚类类别数)。

2) 计算输入训练矢量 X_{kj} 与每个神经元的欧氏距离

$$d_i = \sum_{j=1}^K [X_{kj} - W_{ij}(t)]^2 - \alpha(t) \left(\frac{1}{c} - b_i \right) \quad (8)$$

$$j \in [1, N]$$

3) 计算 X_k 与码书在神经网络中间层中各码字的欧氏距离, 设最小欧氏距离为 $d_{\min}$ 。将一个矢量的各分量的和定义为一个矢量的和值, 设输入矢量 X_k 和值为 H_{X_k} , $k \in [1, L-1]$, 权矢量 W_{ij} 的和值为 $H_{W_{ij}}$, $i \in [1, N]$ 。根据式 (10) (11) 两个判别不等式搜索与训练矢量 X_k 失真最小的神经元 $\hat{j}$ 为取胜神经元, $L_D = K \cdot d_{\min}$ 。

$$H_{X_k} = \sum_{j=1}^K X_k \quad H_{W_{ij}} = \sum_{j=1}^K W_{ij} \quad (9)$$

$$d(X_{kj}, W_{ij}(t)) = \sum_{i=1}^k [X_{kj} - W_{ij}(t)]^2 \geq \frac{(H_{X_k} - H_{W_{ij}})^2}{k} \quad (10)$$

$$(H_{X_k} - H_{W_{ij}})^2 \geq L_D \quad (11)$$

$$d_{\min} = \min_{1 \leq j \leq K} \left| \sum_{i=1}^K [X_{kj} - W_{ij}(t)] \right| \quad (12)$$

4) 训练矢量向中间神经元 P_j, P_{j-1} 的权矢量学习, 更新取胜神经元 $\hat{j}$ 及其邻域 $N_r(t)$ 的权值。

$$W_{ij}(t+1) = \begin{cases} W_{ij}(t) + \nu(t) \times \\ \left[\frac{1}{3}(X_{kj} + P_j + P_{j-1}) - W_{ij}(t) \right] & e \neq \hat{e} \\ W_{ij}(t) + \nu(t) [X_{kj} - W_{ij}(t)] & e = \hat{e} \end{cases} \quad (13)$$

5) 更新学习速率 $\nu(t)$ 及邻域半径 $N_r(t)$ 。是随次数增加而减少的项, 取值在 0 和 1 之间, 以保证算

法的收敛性。

$$\nu(t) = \nu_0 \left(1 - \frac{t}{T} \right) \quad (14)$$

$$N_r(t) = \text{int} \left[N_r(0) \left(1 - \frac{t}{T} \right) \right] \quad (15)$$

6) 更新胜出神经元的偏置值 b_i , 更新参数 $\alpha(t)$, 即

$$b_i = b_i + \beta(1 - b_i) \quad (16)$$

$$\alpha(t) = \alpha(0) \left(1 - \frac{t}{T} \right) \quad (17)$$

7) 对所有训练矢量执行步骤 2)–7), 直至算法收敛或达到初始设定的最大迭代次数。

3 基于 RSOFM-C 的小波压缩

3.1 算法原理

根据差值脉冲编码调制 (DPCM) 中提到的差值信号编码方法, 差值脉冲编码系统中包含预测器和量化器, 由于进行编码的主要对象是预测的误差信号, 因此有能力大幅提高整个系统的压缩效率。

提出了一种基于改进的神经网络的矢量量化快速小波压缩方法, 它是一种基于差值编码的算法。图 3 为 RSOFM-C 算法流程。

它的工作原理是对输入图像进行小波分解, 实现图像中低频能量的集中, 将 Mallat 塔式分解^[13]后的低频图像进行 RSOFM-C 算法得到量化图像, 基于熵编码器的差值图像是由输入图像减去量化图像后得到的, 量化图像经熵编码器编码形成码流, 熵编码器可以减少一部分图像编码的比特数, 再由反熵编码得到重建的差值图像, 最后由小波重构得到压缩后的图像。RSOFM-C 算法在这里实现预测器的功能, 而快速小波变换实现量化器的功能。




图3 RSOFM-C 算法流程图

Fig. 3 RSOFM-C algorithm flow chart

SOFM-C 算法中的编码图像中的分块现象比较明显,原因是图像块与图像块之间存在像素值失真使图像块连接处产生伪边缘。因此,设法减小像素值的失真,可以避免产生分块现象。

3.2 快速小波变换(FWT)

Mallat 算法又被称为塔式分解法^[13],是 Mallat 在结合多分辨率分析^[13-15]的基础上提出的。Mallat 算法^[16-17]将小波变换系数的计算与滤波器结合到一起,再利用塔式分解构造出简化算法。

构造 2 维可分离正交小波基^[16-17]的方法:

设 $f=f(x,y) \in Y_j^2 (j \in \mathbf{Z})$ 是大小为 $M \times N$ 的图像信号, $V_j^2 (j \in \mathbf{Z})$ 为 2 维空间 $L^2(\mathbf{R}^2)$ 的子集^[13], $\phi(x,y) = \phi(x)\phi(y)$ 是相应的 2 维可分尺度函数, $\psi(x)$ 是尺度函数对应的 1 维小波母函数, $\psi^H(x,y)$, $\psi^V(x,y)$, $\psi^D(x,y)$ 分别为水平、垂直和对角小波母函数,这 3 个 2 维母函数通过伸缩平移构成空间 $L^2(\mathbf{R}^2)$ 的 2 维可分离正交小波基。

定义 3 个可分的 2 维小波

$$\begin{cases} \psi^H(x,y) = \phi(x)\psi(y) \\ \psi^V(x,y) = \phi(x)\psi(y) \\ \psi^D(x,y) = \phi(x)\psi(y) \end{cases} \quad (18)$$

由多分辨率分析的性质^[17]可得其 2 维图像为

$$A_j f = A_{j+1} f + \sum_i D_{j+1}^i f \quad (19)$$

$$i \in \{H, V, D\}$$

多分辨率分析的子图像为 $C_j(m,n) \in \mathbf{Z}^2$

$$A_{j+1} f = \sum_m \sum_n C_{j+1}(m,n) \phi_{j+1}(m,n) \quad (20)$$

$$D_{j+1} f = \sum_m \sum_n C_{j+1}(m,n) \phi_{j+1}(m,n) \quad (21)$$

2 维 Mallat 重构公式^[17]为

$$C_j = \hat{P}_r \hat{P}_c C_{j+1} + \hat{P}_r \hat{Q}_c D_{j+1}^i \quad (22)$$

$$i \in \{H, V, D\}$$

2 维 Mallat 分解算法^[17]为

$$\begin{cases} C_{j+1} = P_r P_c C_j \\ D_{j+1}^H = P_r Q_c C_j \\ D_{j+1}^V = Q_r P_c C_j \\ D_{j+1}^D = Q_r Q_c C_j \end{cases}, j = 0, 1, \dots, J \quad (23)$$

式中, $A_j f$ 为 f 在 2^j 分辨率下的连续逼近函数, $D_{j+1} f$ 为 f 在 2^{j+1} 分辨率下的连续细节函数; C_j 是在 2^j 分辨率下的离散逼近矩阵; D_{j+1} 是在 2^{j+1} 分辨率下的离散细节矩阵。 P_r 和 P_c 分别表示对多分辨率分析

的子图像 $C_j(m,n)$ 的行和列作用的算子, Q_r 和 Q_c 分别表示对 $C_j(m,n)$ 行和列作用的算子。 $\hat{P}$ 和 $\hat{Q}$ 分别为 P 和 Q 的共轭转置矩阵。 H, V, D 分别代表水平、垂直和对角 3 个方向。

4 仿真实验及分析

4.1 实验环境

实验在 CPU Intel Core I5 2.67 GHz, 内存 4 G, Matlab 2012b 的编程环境下进行,实验图像采用了 8 位 512×512 的国际标准图像 Lena 和 Boat 的灰度图像作为输入图像。

4.2 码书尺寸的选择

根据 Shannon 编码定理^[18],信源熵是平均码长的下限,图像熵的减小对于压缩比的提高有很大帮助,随着码书大小的增加矢量量化的差值图像的熵值会减少。图像熵的计算公式为

$$H_p = - \sum_k p_k \times \log_2 p_k \quad (24)$$

式中, p_k 表示图像中灰度值为 k 的像素所占的比例, k 的取值为 $(0, 255)$ 。聚类分类个数会随着码书尺寸的增大而增加,算法的时间复杂度以及码书所需的存储空间大小也会随之增加,因此在码书尺寸的选择上需要综合考虑图像残差大小、图像的熵值以及算法的时间复杂度。图 4 为 Lena 图像中熵值与码书尺寸的关系。




图 4 Lena 图像中熵值与码书尺寸的关系

Fig. 4 The relationship between entropy and the size of the code book in Lena image

4.3 RSOFM-C 神经网络训练

在 RSOFM-C 神经网络的码书生成之前,需要将原始图像分成相同大小的连续图像块,实验中采用 512×512 (262 144 个像元) 的 8 位 Lena 和 Boat 的灰度图像。按照 8×8 大小的相同的正方形将原

始图像分成 $262\ 144/64 = 4\ 096$ 个子图像块, 每个子块的 64 个像素灰度值作为输入模式向量, 一次送入神经网络进行训练。

图 5 为训练矢量数目与编码性能的关系图, 图 6 为训练矢量数目与训练时间的关系图。实验中测试图像为 Lena, 对于大于 4 096 个训练矢量的情况采取重复训练的方法, 即用同一幅图像反复进行训练。实验结果表明, 训练矢量数目越大, 其编码性能越好; 当训练矢量超过一定数目后, 其改善效果并不明显, 但会大大增加训练时间。这说明了两点: 一是训练矢量数目不能太少, 否则编码性能较差; 二是训练矢量数目越大, 训练时间越长。因此, 可适当地限制训练矢量数目, 以缩短训练时间。为了在保证编码质量的同时使训练时间尽可能短, 最终确定训练样本个数为 $3 \times 4\ 096$ 。




图 5 训练矢量数对编码性能的影响

Fig. 5 The influence of the number of training vectors for coding




图 6 训练样本矢量数目与训练时间的关系

Fig. 6 The relationship between the training sample number vector and the training time

4.4 图像质量评价

峰值信噪比 (PSNR) 是两个长和宽分别为 M 和 N 的灰度图像 $f(x, y)$ 以及 $f'(x, y)$ 之间的失真测度, 即

$$\text{PSNR} = 10 \times \lg \left(\frac{l_{\max}^2}{\text{MSE}} \right) \quad (25)$$

$$\text{MSE} = \frac{\sum_{x=0}^{M-1} \sum_{y=0}^{N-1} (f(x, y) - f'(x, y))^2}{M \times N} \quad (26)$$

$$l_{\max} = 255$$

设 B_p 为像素内比特数, $B_{\text{RSOFM-C}}$ 为 RSOFM-C 算法的总编码比特数。分块数 $Q = 8 \times 8$, N_{ne} 为神经元的总个数, B_{FWT} 为快速小波变换的总编码比特数。

压缩比为

$$C_r = \frac{M \times N \times B_p}{B} \quad (27)$$

$$B = B_{\text{RSOFM-C}} + B_{\text{FWT}}$$

$$B_{\text{RSOFM-C}} = Q \times \log_2 N_{\text{ne}}$$

C_r 为原图像数字位数与压缩后图像数字位数之比。

4.5 SOFM-C 与 RSOFM-C 运算量比对

SOFM-C 算法在选择获胜神经元时需要进行 L 次欧氏距离计算, K 个训练样本完成一次迭代需要进行 $L \times K$ 次失真运算, 而每次失真计算需要进行 N 次乘法和 $2N - 1$ 次加法, 运算量比较大, 算法速度和收敛性能都受到影响。而另一方面, 由于训练矢量统计特性的影响, 有些输出神经元竞争获胜的概率大, 其权值经常调整, 而有些输出神经元的权值则很少调整。因此, 通过采用欧氏距离不等式判据对基本 SOFM-C 算法进行了改进, 以提高码书的性能, 加快学习速度。

RSOFM-C 算法在每次搜索获胜神经元前, 预先计算权矢量 $\mathbf{W}_{ij}$ 的和值为 $\mathbf{H}_{\mathbf{W}_{ij}}$, $i \in [1, N]$, 并保存在码书中, 同时在搜索获胜神经元过程中预先计算 L_D , 然后判断权矢量 $\mathbf{W}_{ij}$ 的和值为 $\mathbf{H}_{\mathbf{W}_{ij}}$ 是否满足式 $(\mathbf{H}_{\mathbf{x}_k} - \mathbf{H}_{\mathbf{W}_{ij}})^2$, 若满足, 则码字 $\mathbf{W}_{ij}$ 可以排除, 而免去计算失真误差, 即 $L \times K$ 次失真运算以及每次失真计算需要进行 N 次乘法和 $2N - 1$ 次加法。图 7 为通过 RSOFM-C 神经网络中间层欧氏距离判据排除的码字数量与码书尺寸的关系。

由图 7 可知, 当码书尺寸为 2^{10} 时, 通过欧氏距离判据减少计算的码字数量为 331, 相比 SOFM-C


图7 减少的码字数量与码书尺寸(2^k)的关系

Fig. 7 The relationship between the amount of reduced code word with code book size

算法的计算量,每次失真计算减少了331次乘法以及661次加法,总计算量减少 $992 \times L \times K$ 。因此可以证明RSOFM-C算法减少了重复计算,总计算量比SOFM-C低。

4.6 实验结果

比较SOFM、FSOFM、MSOFM和RSOFM-C 4种方法在不同码书尺寸的情况下所得重建图像的PSNR后可得表1。同理,比较4种方法与FWT结合后在不同码书尺寸的情况下所得重建图像的PSNR可得表2。

由表1可知,重构图像的PSNR随着码书尺寸的增大而增大,并且相对于其他算法,RSOFM-C算法的效果更好一些。

表1 4种矢量量化算法比较

Table 1 Four kinds of vector quantization algorithm comparison

码书尺寸	SOFM-C		FSOFM		MSOFM		RSOFM-C	
	Lena	Boat	Lena	Boat	Lena	Boat	Lena	Boat
64	26.98	25.38	28.12	26.91	28.23	27.55	28.23	28.52
256	29.13	28.12	30.52	28.68	30.63	28.90	30.63	30.17
512	30.25	29.15	31.71	30.16	31.86	30.23	31.86	32.11
1 024	31.69	30.01	33.21	31.53	33.32	32.09	33.32	34.71

表2 与快速小波结合后的算法比较

Table 2 Compared with the algorithm of FWT combination

码书尺寸	SOFM-C + FWT		FSOFM + FWT		MSOFM + FWT		RSOFM-C + FWT	
	Lena	Boat	Lena	Boat	Lena	Boat	Lena	Boat
64	30.11	28.37	31.73	29.10	31.96	29.32	33.24	31.56
256	32.46	31.77	33.21	32.22	33.50	32.58	36.00	34.69
512	33.59	32.71	34.60	33.61	34.77	33.82	37.55	35.59
1 024	34.67	33.19	36.41	34.62	36.47	34.78	39.28	37.01

由表2可得,将SOFM、FSOFM、FSOFM及RSOFM-C 4种方法与快速小波变换相结合可以进一步的提高重构图像的质量,结合后的RSOFM-C算法相比其他3种方法取得了更高的PSNR幅值。

表3为本文算法与JPEG2000^[19-20]以及SOFM + FWT算法压缩性能的对比,码书尺寸为1 024,由实验数据可以表明,该仿真实验获得的压缩效果要远优于前两种算法,获得的压缩比超过前两种算法的2.5倍以上,并且本文算法的PSNR也比前者更高。

表4为4种算法在相同条件下的训练时间以及总体运算时间的对比,由表4可得SOFM-C算法的

表3 压缩性能比较

Table 3 The compression performance comparison

方法	Lena		Boat	
	PSNR/dB	压缩比	PSNR/dB	压缩比
JPEG2000	32.56	19.72	31.87	18.93
SOFM + FWT	34.67	20.56	33.11	19.70
RSOFM-C + FWT	39.28	52.18	36.28	49.10

表 4 4 种方法之间的训练时间及总体时间对比
Table 4 The contrast between the four methods of training time and total time

	SOFM-C	FSOFM	MSOFM	RSOFM-C	/s
训练时间	352	254	287	171	
总运算时间	387	289	311	187	

运算时间约为 RSOFM-C 算法的 2 倍左右,这说明了 RSOFM-C 算法的学习速度要更快一些。实验使用 Lena 的灰度图像,训练样本个数为 $3 \times 4\ 096$,码书尺寸为 1 024。

图 8 和图 9 分别为 Lena 和 Boat 的重构图像对比。可以看到,SOFM 算法的 Lena 灰度图像中在脸部和肩部而 Boat 灰度图像的船体细节部分产生了较为明显的分块现象,而本文算法则消除了此种现象。



图 8 Lena 重构图像对比
Fig. 8 Lena reconstruction image contrast




图 9 Boat 重构图像对比
Fig. 9 Boat reconstruction image contrast

图 10 为 Lena 和 Boat 灰度图像经本文算法得到的残差图像,这两幅图像是由原始图像减去量化图像得到的,残差图像经过熵编码器进行熵编码形成码流,具体编码方式采用了哈夫曼(Huffman)编码^[21],主要利用信号的统计冗余性将输入的信息变换成码流,码流经信道传输后经反熵编码形成重构的残差图像。




图 10 RSOFM-C 残差图像
Fig. 10 The residual image of RSOFM-C

图 11 为 Mallat 塔式分解法得到的分解图像, 采用三级分解将低频信号与高频信号分离, 其中高频信号携带大量的细节信息, 本文主要对低频信号进行基于神经网络的矢量量化处理, 形成量化图像。




图 11 FWT 三级分解图 (Lena)

Fig. 11 Triple decomposition figure of FWT

4.7 多中间层的 RSOFM-C 神经网络

图 12 为 RSOFM-C 中间层层数与 PSNR 的关系图, 图 13 为中间层层数与训练时间的关系图。实验使用 Lena 图像, 训练矢量个数为 3×4096 , 码书尺寸为 1024。




图 12 RSOFM-C 中间层层数与 PSNR 的关系

Fig. 12 The relationship between RSOFM-C interlayer amount and the PSNR

由图 12 可得, RSOFM-C 算法的中间层数的增加并没有显著提高 PSNR, 而图 13 中, 随着层数的增




图 13 RSOFM-C 中间层层数与训练时间的关系

Fig. 13 The relationship between RSOFM-C interlayer amount and the training time

加, 所需要的训练时间大幅增加。

图 14(a) 为单中间层的 RSOFM-C 神经网络经本文算法得到的重构图像, 与此相对图 14(b) 为 3 个中间层的 RSOFM-C 的重构图像, 可以看到两幅图的重构质量几乎没有差别。



(a) 单中间层

(b) 3个中间层

图 14 不同中间层数的 Lena 重构图像对比

Fig. 14 Lena reconstruction image with different interlayer amount contrast

综上, 多中间层 RSOFM-C 神经网络需要的训练时间太长, 重构质量和 PSNR 又与单中间层的 RSOFM-C 神经网络相比几乎没有提高, 而单中间层完全可以满足实验要求, 因此无需在神经网络中引入多中间层。

5 结 论

在 SOFM-C 神经网络矢量量化算法的基础上对其改进提出了 RSOFM-C 算法, 引入了中间神经元的概念, 设置了中间权矢量 P_j 和 P_{j-1} , 通过中间权矢量

来控制神经元的权值变化,保证了神经网络的拓扑不变性,获得了更好的码书,并将神经网络矢量量化算法应用于快速小波变换方法中,根据 DPCM 中的差值信号编码方法,将此算法与快速小波变换相结合形成一种新的压缩方法。通过实验仿真,此复合压缩算法在不降低峰值信噪比的情况下压缩比提高了 2.5 倍以上,并且明显减少了 SOFM 和 SOFM-C 算法产生的图像分块现象,在保证高压压缩比的同时,保证了图像的重构质量。结果表明,提出的引入中间神经元的快速小波压缩方法,具有高压压缩比、高保真、速度快等优点,可以有效地压缩图像。今后的研究重点是本文算法在多光谱以及高光谱图像上的应用,在保证压缩比及图像重构质量的同时缩短训练时间。

参考文献 (References)

- [1] Coates A, Andrew Y N. The importance of encoding versus training with sparse coding and vector quantization [C] // Proceedings of the 28th International Conference on Machine Learning. Stanford University, Stanford, CA, USA: Omnipress, 2011: 921-928.
- [2] Hou X, Research of model of quantum learning vector quantization neural network [C] // Proceedings of Electronic and Mechanical Engineering and Information Technology. Xi'an, China: IEEE, 2011: 3893-3896.
- [3] Kohonen T. Self-Organizing Maps [M]. Berlin, German: Springer, 2001.
- [4] Bebis G, Georgiopoulos M, Lobo N V. Using self-organizing maps to learn geometric hash functions for model-based object recognition [J]. IEEE Transactions on Neural Networks, 1998, 9(5): 560-570.
- [5] Li H S, Quan Z Y. Frequency sensitive self-organizing feature maps algorithm for vector quantization of images [J]. Journal on Communications, 1995, 16(2): 59-64. [黎洪松, 全子一. 图像矢量量化-频率敏感自组织特征映射算法 [J]. 通信学报, 1995, 16(2): 59-64.]
- [6] Wang W, Cai D J, Wan F G. Modified kohonen self-organization neural network and adaptive vector quantization of images [J]. Journal on Communications, 1992, 13(5): 16-21. [王卫, 蔡德钧, 万发贵. 改进的 Kohonen 网络及图像自适应矢量量化 [J]. 通信学报, 1992, 13(5): 16-21.]
- [7] Ma Y, Ruan Y. Vector quantization based on the improved self-organizing feature mapping neural networks [J]. Computer Engineering and Science, 2011, 33(12): 126-129. [马勇, 阮洋. 基于改进的 SOFM 神经网络的矢量量化方法 [J]. 计算机工程与科学, 2011, 33(12): 126-129.]
- [8] Singh A V, Murthy K S. Neuro-curvelet model for efficient image compression using vector quantization [C] // Proceedings of International Conference on VLSI. Berlin: Springer, 2013, 258: 179-185.
- [9] Hong M H. Vector quantization using the firefly algorithm for image compression [J]. Expert Systems with Applications, 2012, 39(1): 1078-1091.
- [10] Agarwal R, Sarma S V. An analytical study of relay neuron's reliability: dependence on input and model parameters [C] // Proceedings of IEEE 2011 Annual International Conference. Boston, MA, USA: IEEE, 2011: 2426-2429.
- [11] Ji J, Li X, Xu S X. Image reconstruction algorithm based on the curvelet gaussian scale mixture model [J]. Journal of Image and Graphics, 2013, 18(10): 1247-1254. [纪建, 李晓, 许双星. 曲波域高斯混合尺度模型的图像压缩重构 [J]. 中国图象图形学报, 2013, 18(10): 1247-1254.] [DOI: 10.11834/jig.20131004]
- [12] Mavridis D. Color quantization using principal components for initialization of Kohonen SOFM [J]. IEEE Transactions on Image Processing, 2009, 11(4): 1633-1636.
- [13] Adams M D, Kossentini F. Reversible integer-to-integer wavelet transform for image compression: performance evaluation and analysis [J]. IEEE Transactions on Image Processing, 2007, 9(6): 1010-1024.
- [14] Mao Z H, Steve G M. Dynamics of winner-take-all competition in recurrent neural networks with lateral inhibition [J]. IEEE Transactions on Neural Networks, 2007, 18(1): 55-69.
- [15] Franco J, Bernabé G, Fernández J. Parallel 3D fast wavelet transform on many core GPUs and multi-core CPUs [J]. Computer Science, 2010, 1(1): 1101-1110.
- [16] Reichel J, Menegaz G. Integer wavelet transform for embedded lossy to lossless image compression [J]. IEEE Transactions on Image Processing, 2001, 10(3): 383-392.
- [17] Chang C L, Geriod B. Direction Adaptive discrete wavelet transform for image compression [J]. IEEE Transactions on Image Processing, 2007, 16(5): 1289-1302.
- [18] Pearlman W A, Islam A, Negara N, et al. Efficient low complexity image coding with a set-partitioning embedded block coder [J]. IEEE Transactions on Circuits System video Technology, 2004, 11: 1219-1235.
- [19] Lin J Y, Smith M. New perspectives and improvements on the symmetric extension filter bank for sub-band wavelet image compression [J]. IEEE Transactions on Image Processing, 2008, 17(2): 177-189.
- [20] Gonzalez R C, Woods R E. Digital Image Processing Using MATLAB Second Edition [M]. Beijing, China: Electronic Industry Press, 2013.
- [21] Liang Z W, Ma X D, Dai X H. Improved JPEG2000 algorithm using a novel 97 wavelet [J]. Journal of Image and Graphics, 2008, 13(5): 853-857. [梁志伟, 马旭东, 戴先中. 一种新 97 小波改进的 JPEG2000 算法 [J]. 中国图象图形学报, 2008, 13(5): 853-857.] [DOI: 10.11834/jig.20080502]