

doi: 10.3969/j.issn.0490-6756.2018.02.017

基于灰度 DAG 熵最大化量化分辨率医学图像增强

宋璐¹, 冯艳平², 卫亚博³

(1. 陕西中医药大学医学技术学院, 咸阳 712046; 2. 郑州职业技术学院电气电子工程系, 郑州 450121;
3. 平顶山学院电气工程系, 平顶山 467000)

摘要: 为提高医学图像增强的清晰度和对比度, 并提高计算效率, 提出一种基于灰度有向无环图(DAG)熵最大化量化分辨率医学图像色调增强算法。首先, 采用简单的分段自回归(PAR)模型进行图像目标恢复, 并考虑到模数转换的误差利用全最小二乘算法进行PAR模型参数估计, 获得高分辨率图像恢复直方图模型; 其次, 针对可能存在的对比度过低问题, 将上述获得的最小二乘算法约束优化问题, 建模为DAG中的最大权重路径问题, 构建了色调保持最大熵图像增强过程约束优化模型, 并通过DAG图Monge定理特性实现计算复杂度的降低; 通过上述两个步骤, 实现了医学图像增强过程中图像细节和对比度的同步增强, 仿真实验显示所提算法可提供更为有效的医学图像增强效果。

关键词: 图像增强; 有向无环图; 分段自回归; 最小二乘; 色调保持; 最大熵

中图分类号: TP391 **文献标识码:** A **文章编号:** 0490-6756(2018)02-0316-07

Gray level DAG maximum entropy based on quantization resolution for medical image tone enhancement

SONG Lu¹, FENG Yan-Ping², WEI Ya-Bo³

(1. Department of medical technology, Shaanxi University of Chinese Medicine, Xianyang 712046, China;
2. Department of Electrical and Electronic Engineering, Zhengzhou Technical College, Zhengzhou 450121, China;
3. Department of electrical engineering, Pingdingshan college, Pingdingshan 467000, China;)

Abstract: In order to improve the medical image sharpness and contrast, and improve the computational efficiency, the authors proposed the gray level DAG maximum entropy based on quantization resolution for Medical image tone enhancement. Firstly, the authors used a simple piecewise autoregressive (Piecewise Autoregressive PAR) image target model for recovery, and took into account the error of analog to digital conversion to use least squares algorithm to estimate PAR model parameter, which obtain high resolution image histogram restoration model; Secondly, aiming at the problem of low contrast may exist, the least squares algorithm for constrained optimization problems was modeled in DAG, which constructed a hue preserving constraint optimization model of maximum entropy image enhancement, and the characteristics of the DAG figure Monge theorem was used to reduce the computational complexity; Through the above two steps, the image details and contrast enhancement in the process of medical image enhancement are realized. The simulation results show that the proposed algorithm can provide more effective medical image enhancement effect.

Keywords: Image enhancement; Directed acyclic graph; Piecewise autoregressive; Least squares; Color retention; Maximum entropy

收稿日期: 2017-01-03

基金项目: 中医药行业科研专项(201207002)

作者简介: 宋璐(1984—), 女, 陕西咸阳人, 讲师, 硕士生, 研究方向为电子技术以及数字图像处理. E-mail: songlult@21cn.com

1 引言

在图像增强中, 对视觉信号呈现进行改进以满足特定任务用户需要。在所有图像处理和计算机视觉研究中, 图像增强在技术上要求最严格。这主要是因为良好图像表示的评价标准具有一定主观性, 对于不同的应用程序存在差异。由于缺乏通用性和严谨性, 许多图像增强技术鲁棒性不强, 存在一定副作用。在这项研究中, 我们着手引入一个新的更具原则性的图像增强方法^[1,2]。

对于用户来说, 在大多数应用中图像增强的主要目的是使图像特征和细节更加醒目。图像增强技术大致可分为两类: 过滤器技术和直方图技术。例如, 在过滤器技术方面, 文献[3]使用高通滤波器锐化图像的边缘和纹理; 文献[4]利用同态滤波和双边滤波获得图像的增强效果; 文献[5]提出著名的 Retinex 算法, 使用高斯滤波器来模拟视网膜和人眼视觉皮层的协作处理。在直方图技术方面, 文献[6]提出局部约束直方图均衡技术; 文献[7]提出直方图调整技术寻求直方图均衡化与线性映射最佳融合; 文献[8]提出将输入直方图分解成多个子直方图, 并在每个子直方图上独立进行图像增强, 可提高增强效果。文献[9]提出迭代分解技术进行直方图分区和递归计算; 文献[10]基于高斯混合模型的输入直方图, 提出了更通用的划分准则, 等。此类文献还有很多, 不再赘述。过滤器技术通过提高高频成分实现图像对比度的提高, 但不能保持相邻像素值相对排序, 从而容易出现“光晕”现象。直方图增强技术因为使用单调传递函数来映射的灰度级输入图像, 并重塑输出直方图, 像素的强度等级得以保存, 因此可避免“光晕”现象。但其未考虑图像信号模数转换的量化误差问题, 同时在算法设计中算法的计算复杂度过高, 影响了在实际环境中的应用效果。

在医学图像增强算法设计中, 特别是对于对比度和清晰度有特殊要求, 因为熵指标作为图像信号信息的统计度量, 可预测图像处理过程所表现出的丰富细节。因此, 本文考虑使用熵指标, 提出基于灰度 DAG 熵最大化量化分辨率医学图像色调增强算法。通过边缘最大权重算法构建图模型, 并充分考虑模数转换的量化误差问题, 同时通过 Monge 定理实现算法计算复杂度的降低。

2 高分辨率量化转换

2.1 医学图像恢复

在最大熵医学图像增强方法中, 输入直方图须有相比显示更多的灰度级。对于具有相同位深度显示的输入图像, 需增加像素值量化分辨率。目标是从观测离散图像 $J(x, y)$ 估计模拟图像信号 $I(x, y)$ 的连续光流振幅值, 并将 $I(x, y)$ 量化为更高的分辨率。真实图像 I 与观测图像 J 之间的关系为

$$I(x, y) = J(x, y) + e_q(x, y) \quad (1)$$

其中, $e_q(x, y)$ 是独立误差项, 主要是模拟量化误差。量化误差在量化区间 $[-\delta, \delta]$ 内具有均匀分布, 其中 δ 是量化步长。

为实现高动态范围采集图像 I 的像素幅值恢复, 需利用自然图像先验知识。考虑到图像增强是实时显示的, 采用简单的分段自回归(Piecewise Autoregressive, PAR) 模型进行图像目标恢复^[11,12]。

$$I(x, y) = \sum_{(i, j) \in S(x, y)} \alpha_{i,j} I(x+i, y+j) + e_m \quad (2)$$

其中, $\alpha_{i,j}$ 为模型参数; (x, y) 为像素位置; $S(x, y)$ 是像素 (x, y) 的局部邻域; e_m 是模型拟合高斯误差。综合式(1)~(2)可得

$$I = A(J + e_q) + e_m = AJ + \eta\alpha_i \quad (3)$$

其中, 矩阵 A 包含 PAR 模型参数, 矩阵 A 的第 i 行为在像素位置 $(i, :)$ 的参数估计向量 α_i ; $\eta\alpha_i = Ae_q + e_m$ 是复合误差项。根据中心极限定理, 参数 $\eta\alpha_i$ 和 Ae_q 满足高斯分布。因此, 连续亮度图像 I 的最佳估计, 可通过求解以下约束最小二乘问题获得

$$\begin{aligned} I &= \operatorname{argmin}_I \|I - AI\|_2^2 \\ \text{s. t. } I - J_\infty &\leq \delta \end{aligned} \quad (4)$$

其中, I_∞ 约束 $\|I - J\|_\infty \leq \delta$ 用于限制可行解空间, $1 \geq \delta$ 为松弛误差边界 δ , 其反映传感器噪声影响。如果 e_q 仅由模数转换引起, 然后连续图像 I 恢复应满足 $I \in [J - \delta, J + \delta]$, 即 $\delta = 1$ 。更一般情形, e_q 还包括成像传感器噪声和可能压缩噪声等。由于这些误差在统计学上是独立的, 因此公式(4)的推导不受影响, 但是应该使用松弛解空间 $[J - \hat{\delta}, J + \hat{\delta}]$ 。例如, 如果传感器/压缩噪声是方差为 σ 的零均值高斯分布, 则可设定 $\hat{\delta} = \min(\delta, 3\sigma)$, 其为 95% 置信区间的高斯样本。

2.2 PAR 模型参数的全最小二乘估计

上述量化分辨率转换技术成功的关键是对

PAR 模型参数 α 的估计。假设二维信号 I 在 (x, y) 附近的局部区域 $N(x, y)$ 是平稳的, 自适应模型参数的 $I(x, y)$ 可使用在局部区域 $N(x, y)$ 输入图像 j 的样本进行估计。令 n 和 k 分布为固定邻域 $N(x, y)$ 和 PAR 模型集 $S(x, y)$ 的维度。线性方程(2)可用矩阵形式进行表示

$$C\alpha = b \quad (5)$$

其中, $b \in R(n)$ 是在 $N(x, y)$ 中心像素位置的向量, $C \in R^{n \times k}$ 是由 $S(x, y)$ 中心的 k 邻居像素构成的行向量组成的图像矩阵。如前所述, 模型估计误差 $C\alpha - b$ 满足高斯分布, 因此在位置 (x, y) 处的 PAR 模型参数可通过以下最小二乘问题求解估计, 如下式。

$$\hat{\alpha} = \underset{\alpha}{\operatorname{argmin}} | \alpha | \| C\alpha - b \|_2^2 \quad (6)$$

其具有封闭形式的解决方案:

$$\hat{\alpha} = (C^T C)^{-1} C^T b \quad (7)$$

然而, 式(7)所示最小二乘模型解只考虑了估计误差 e_m , 而忽略了模数转换的误差 e_q , 对此这里对公式(2)进行扩展:

$$I = J + e_q = A(J + e_q) + e_m \quad (8)$$

从式(8)可看出, e_q 影响式(5)中训练集矩阵 C 和观测向量 b 。在这种情况下, 可利用全最小二乘技术(5)对 PAR 模型参数估计性能进行提高, 形式为

$$\{\hat{\alpha}_T, \Delta C, \Delta b\} = \underset{\alpha, \Delta C, \Delta b}{\operatorname{argmin}} [\Delta C, \Delta b]_F \quad (9)$$

$$\text{s. t. } (C + \Delta C)\alpha = (b + \Delta b)$$

其中, 下标 F 表示 Frobenius 范数, ΔC 和 Δb 分别是由 e_q 和 $e_q - e_m$ 造成的扰动。假设数据矩阵的奇异值分解 $[A, b]$ 为

$$[A, b] = [U_A, U_b] \begin{bmatrix} \sum_A & 0 \\ 0 & \sum_b \end{bmatrix} \begin{bmatrix} V_{AA} & V_{Ab} \\ V_{bA} & V_{bb} \end{bmatrix}^T \quad (10)$$

其中, 矩阵根据 A 和 b 的维度分别被划分为 k 和 1。对式(9)所示一般总体最小二乘问题的封闭解为:

$$\hat{\alpha}_T = -V_{Ab} V_{bb}^{-1} \quad (11)$$

以上基于 PAR 的图像恢复方法不是唯一的选择; 它可以被替换为其他恢复方法, 如稀疏信号处理, 仅需生成一个实值的亮度图像。剩下的任务是通过全局变换函数 $T(\cdot)$ 增强输入图像 J , 将图像 I 量化恢复为 K 离散等级, 典型光电显示器中 $K=255$ 。

3 基于灰度 DAG 熵最大化色调增强

第 2 节所示恢复图像 I 可能对比度过低, 需进

行加强。在图像增强需要对如下两个感知质量标准进行平衡: 细节清晰和色调平滑。第一个标准可通过熵最大化或直方图均衡化实现, 变换为

$$k = T(i) = K \int_0^i P_I(t) dt \quad (12)$$

其中, P_I 是恢复图像 I 灰度等级的概率密度函数。 K 是输出灰度级的数量。然而, 直方图均衡化的灰度变换可映射到一个大的连续范围的单一输出灰度级, 产生假轮廓伪影。为解决该问题, 这里施加色调失真约束熵最大化解决方案, 从而构成图像增强的约束优化问题。

该算法的输入是恢复图像的直方图 I ; 灰度级变换 T 可由有序的整数向量 $s = (s_1, s_2, \dots, s_{K-1})$ 定义, 这样所有的输入灰度级 $i \in [s_k, s_{k+1})$ 映射到输出级 k , 可表示为 $T(s_k, s_{k+1}) = k, 0 \leq k < K$, 其中 $s_0 = 0, s_K = N$ 。区间的大小为:

$$\epsilon_k = s_{k+1} - s_k \quad (13)$$

可以看作是色调失真, 因为太多的输入灰度级映射成一个单一的输出灰度使轮廓具有阴影区域。图 I 中落入区间 $[i, j)$ 的灰度等级概率可表示为 $P[i, j)$ 。则色调保持最大熵图像增强(TPEM)过程可归结为以下约束优化问题:

$$\begin{aligned} \max & \sum_{k=0}^{K-1} -P[s_k, s_{k+1}) \log P[s_k, s_{k+1}) \\ \text{s. t. } & s_{k+1} - s_k \leq \tau \forall k \end{aligned} \quad (14)$$

其中, τ 是色调失真的上界。式(4)所示问题可建模为有向无环图(Directed Acyclic Graph, DAG)中的最大权重路径问题, 可表示为 $G(V, E)$, 如图 1 所示。

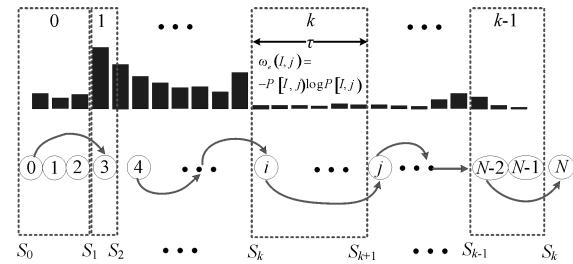


图 1 问题模型

Fig. 1 Problem model

设 DAG 顶点集 V 是输入直方图灰度级, 标记为 $0, 1, \dots, N$ 。一对灰色等级 i 和 j , $i < j$, 如果 $[i, j)$ 中的灰度级被允许通过函数 T 映射到输出灰度级 k , 即 $T(i, j) = k$, 则包含边 $e(i, j) \in E$, 其权重幅值为:

$$\omega_e(i, j) = -P[i, j) \log P[i, j) \quad (15)$$

在上述 DAGG(V, E) 结构中, 如果 $j - i > \tau$

则通过不允许从节点 i 到节点 j 的任何边缘施加色调失真的上限. 优化问题(14)的解决方案对应于一个从节点 0 到节点 n 的 k 条边的路径, 使得边缘权重的总和最大, 可表示为

$$\hat{L}(N, K) = \operatorname{argmax}_{k=0}^K \omega_e(s_k, s_{k+1}) \quad (16)$$

给出灰度等级变换 T 和 n 元组 $s = (s_1, s_2, \dots, s_{K-1})$ 之间的一一对应关系, 则有 (N, K) 种可能变换. 优化设计问题(16)可以递归分解为如下子问题

$$\begin{aligned} \hat{L}(N, K) &= \operatorname{argmax}_s \sum_{k=0}^{K-1} \omega_e(s_k, s_{k+1}) + \\ \omega_e(s_{K-1}, s_K) &= \operatorname{argmax}_{s_{K-1}} \hat{L}(s_{K-1}, K-1) + \\ \omega_e(s_{K-1}, s_K) \end{aligned} \quad (17)$$

上述动态规划算法时间复杂度为 $O(KN^2)$, 当 N 值较大时, 算法计算复杂度较高. 而图 $G(V, E)$ 满足 Monge 定理^[15], 可将上述动态规划算法时间复杂度降为 $O(N\sqrt{K\log N} + N\log N)$.

定理 1 (Monge 定理) 对于 $i < i' < j < j'$, 如果以下条件满足:

$$\omega_e(i, j) + \omega_e(i', j') > \omega_e(i, j') + \omega_e(i', j) \quad (18)$$

则权重 DAG 满足 Monge 定理.

证明 令

$$\theta_1 = \omega_e(i, j) + \omega_e(i', j') \quad (19)$$

$$\theta_2 = \omega_e(i, j') + \omega_e(i', j) \quad (20)$$

令 p_1, p_2 和 p_3 分别为概率 $P[i, i']$ 、 $P[i', j]$ 和 $P[j, j']$ 的速记符号, 定义 $h(p) = -p \log p$. 则可得

$$\begin{aligned} \theta_1 &= h(p_1 + p_2) + h(p_2 + p_3) = \\ &h\left(\frac{p_1 + 2p_2 + p_3}{2} - \frac{p_3 - p_1}{2}\right) + \\ &h\left(\frac{p_1 + 2p_2 + p_3}{2} + \frac{p_3 - p_1}{2}\right) = \\ &h(m - p_-) + h(m + p_-) \end{aligned} \quad (21)$$

$$\begin{aligned} \theta_2 &= h(p_2) + h(p_1 + p_2 + p_3) = \\ &h\left(\frac{p_1 + 2p_2 + p_3}{2} - \frac{p_3 + p_1}{2}\right) + \\ &h\left(\frac{p_1 + 2p_2 + p_3}{2} + \frac{p_3 + p_1}{2}\right) = \\ &h(m - p_+) + h(m + p_+) \end{aligned} \quad (22)$$

其中, $m = \frac{p_1 + 2p_2 + p_3}{2}$, $p_- = \frac{p_3 - p_1}{2}$, $p_+ = \frac{p_3 + p_1}{2}$. 因为, 当且仅当函数 $f(p) = h(m - p) + h(m + p)$ 对于 $p \in (0, m)$ 是单调递减的, 则 p_1 ,

$p_2, p_3 > 0, p_- < p_+ < m, \theta_1 > \theta_2$ 成立. 对 $f(p)$ 导数:

$$\frac{df(p)}{dp} = \log(m - p) - \log(m + p) \leqslant 0 \quad (23)$$

则可得 $\theta_1 = f(p_-) > f(p_+) = \theta_2$, 进而可得 DAG $G(V, E)$ 满足 Monge 定理. 可知求解 K 边最大权重问题(16)的计算复杂度为 $O(N\sqrt{K\log N} + N\log N)$. TPEM 动态规划算法伪代码见算法 1 所示.

算法 1 TPEM 动态规划算法伪代码

输入: 图像的高分辨率直方图 P , 最大的色调失真约束 τ ;

输出: 转换函数 T 的切割点 $\{s = (s_1, s_2, \dots, s_{K-1})\}$;

//DAG 模型构建

For $0 \leqslant i \leqslant N$ do

For $0 \leqslant j \leqslant \tau$ do

$\omega_e(i, j) = -P[i, j] \log P[i, j]$

Endfor

Endfor

//初始化

1) 利用 $N \times K$ 矩阵 L 存储子问题的中间权重 $\hat{L}(n, k)$.

2) 利用 $N \times K$ 矩阵 C 存储 $\hat{L}(n, k)$ 的倒数第二切割点 s_{K-1} .

For $0 \leqslant n \leqslant N$ do

$L(n, 1) = \omega_e(0, n)C(n, 1) = 0$;

Endfor

//动态规划

For $1 \leqslant k \leqslant K$ do

For $k \leqslant n \leqslant N$ do

通过公式(17)计算 $\hat{L}(n, k)$ 和 s_{k-1} ;

$L(n, k) = \hat{L}(n, k)C(n, k) = s_{k-1}$;

Endfor

Endfor

//遍历 C 来输出 s 的最终决策

$s_K = N$

For $k = K-1, k \geqslant 0, k--$ do

$s_K = C(s_{k+1}, k)$;

Endfor

Return s

上述算法中, 涉及到两个 TPEM 参数设置: 色调失真上限 τ 和量化精度 N , 这两个参数密切相关. 如图 1 所示, $\tau \leqslant \frac{N}{K}$ 意味着顶点 N 不能通过 K

边缘从节点 0 到达,这将导致不可行解。 $\tau = \frac{N}{K}$ 意味着顶点 N 仅存在一条通过 K 边缘从节点 0 到达的路径,这是对输入直方图的均匀量化,图像未发生任何变化。无约束 TPEM($\tau = N$)达到熵最大化,但是会导致色调失真,通过实验发现 $\tau = 1.5 \frac{N}{K}$ 可最大化均衡熵最大化和低色调失真。

4 实验分析

为验证所提图像增强技术的有效性,选取如下三个对比算法进行实验分析:(1) 经典的多尺度 Retinex 技术^[13];(2) 基于二阶统计量的 OCTM 技术^[14]。参数设置为: $K = 256, \tau = 1.5 \frac{N}{K} = 24$ 。测试对象选取 4 组医学图像。

4.1 视觉效果对比

图像质量主要包括两个方面:保真度和清晰度。选取的几种对比算法图像增强效果见图 2(a)~图 2(d)所示。

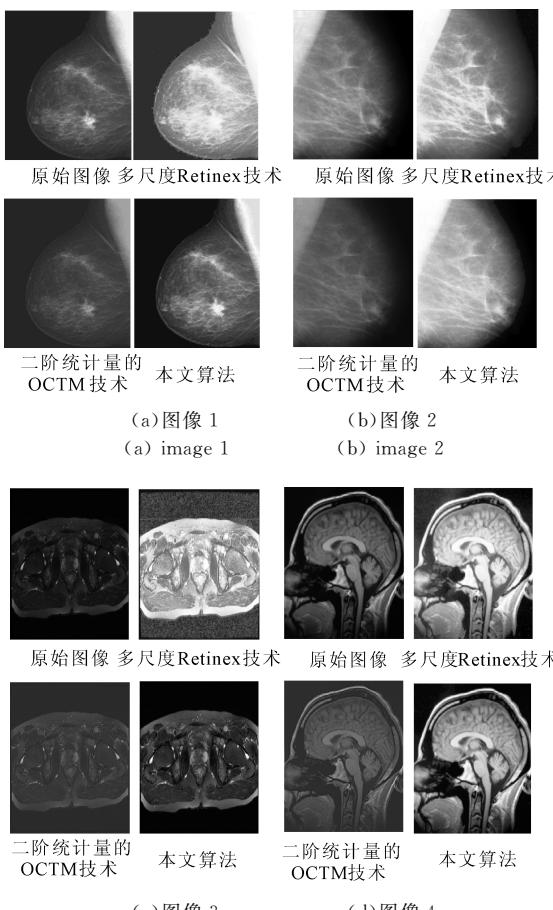


图 2 视觉对比效果
Fig. 2 Visual contrast effect

从主观视觉评价的角度来看,本文提出的图像增强方法具有较高的亮度,无失真,其视觉效果优于一般方法。而对比算法均存在不同程度的缺陷,例如多尺度 Retinex 技术随可提高图像的亮度效果,甚至比本文算法亮度效果更好,但对比度相对较差,而二阶统计量的 OCTM 技术获得的增强图像存在亮度不足问题,对比度较差,只有本文算法可兼顾图像增强后的清晰度和对比度。

4.2 客观指标评价

为实现客观性能对比,这里选取熵和对比度改善指数指标(CII)。

$$CII = \frac{C_{\text{processed}}}{C_{\text{original}}} \quad (24)$$

$$\begin{cases} E = - \sum_{i=1}^M \sum_{j=1}^N p_{ij} \ln p_{ij} \\ p_{ij} = \frac{f(i,j)}{\sum_{i=1}^M \sum_{j=1}^N f(i,j)} \end{cases} \quad (25)$$

指标 CII 计算过程如下:图像被划分为 3×3 的小碎片, $C_{\text{processed}}$ 是所有 3×3 小图像对比度增强图像对比度均值。 C_{original} 对应的原图像对比度均值。每个 3×3 小块图像的对比度可定义为:

$$\text{contrast} = \frac{\max - \min}{\max + \min} \quad (26)$$

其中,max 和 min 分别为 3×3 小碎片图像的最大和最小灰度值。选取的几种对比算法所得图像熵对比情况见表 1 所示。

表 1 图像增强熵对比

Tab. 1 Comparison of image enhancement entropy

算法	图像 1	图像 2	图像 3	图像 4
原始图像	6.6873	7.186	6.787	7.015
多尺度 Retinex 技术	7.353	7.564	7.358	7.426
二阶 OCTM 技术	7.866	7.883	7.762	7.794
本文算法	7.882	7.863	7.797	7.844

根据表 1 图像增强熵对比结果可知,在图 1~图 3 所示四幅医学图像色调增强算法中,本文选取的三种对比算法均可较为理想的实现熵值增加,这体现了三种算法在图像增强过程中,可有效提高亮度效果。同时可看出,本文算法相对于多尺度 Retinex 技术和二阶统计量 OCTM 技术,可获得更高的熵值增强效果,这从定量角度给出了所提方法在图像亮度增强上的性能优势。

选取的几种对比算法所得图像对比度改善指数指标(CII)对比情况见表 2 所示。

表 2 图像对比度改善指数指标对比

Tab. 2 Comparison of image contrast improvement index

算法	图像 1	图像 2	图像 3	图像 4
原始图像	1.000	1.000	1.000	1.000
多尺度 Retinex 技术	1.962	2.326	0.718	1.644
二阶 OCTM 技术	2.402	1.889	2.205	2.118
本文算法	4.201	4.497	4.812	2.815

根据表 2 对比度改善指数指标对比结果可知, 在图 1~图 3 所示四幅医学图像色调增强算法中, 本文选取的三种对比算法均可较为理想的实现对比度改善指数增加, 这体现了三种算法在图像增强上是有效的。同时可看出, 本文算法相对于多尺度

Retinex 技术和二阶统计量 OCTM 技术, 可获得更高的对比度改善指数增强效果, 这从定量角度给出了所提方法在图像对比度增强上的性能优势。

4.3 矩阵灰度频率对比

增强效果也可以通过矩阵灰度频率进行对比, 这里灰度频率定义为该像素强度下的发生频率, 可对图像中像素强度分布进行表征。仍然选取多尺度 Retinex 技术和二阶统计量 OCTM 技术作为对比算法。原始图像、OCTM 增强图像和本文算法的矩阵灰度频率对比情况见图 3 所示。实验对象选取图 2(a)~图 2(d) 的医学图像 1~4。

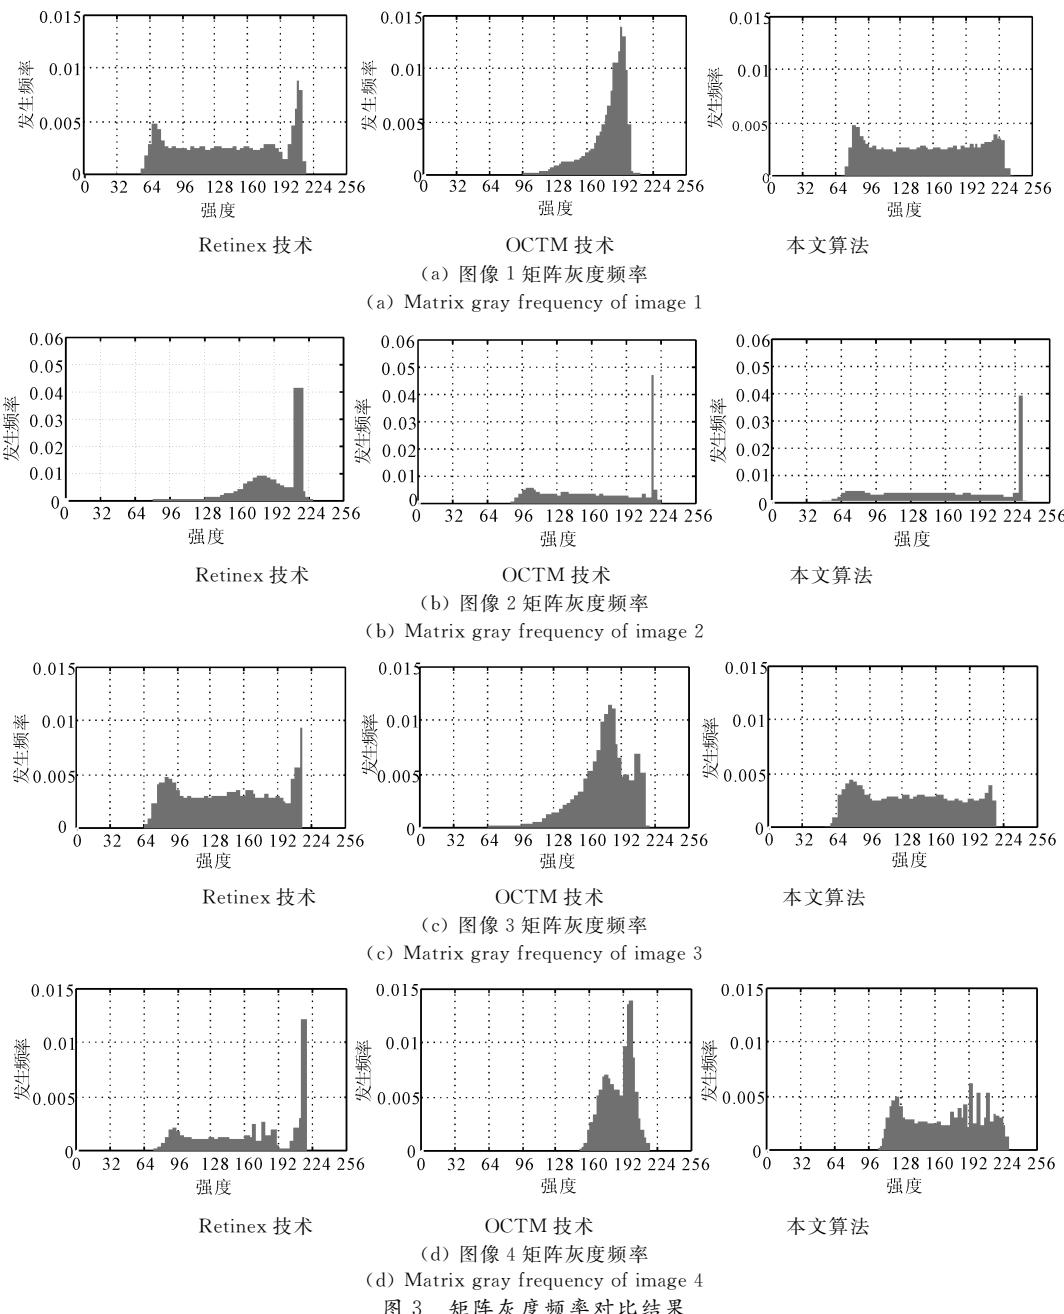


Fig. 3 Strong contrast of matrix histogram

根据图 3 结果可知,多尺度 Retinex 技术、二阶统计量 OCTM 技术以及本文算法所获得的图像增强矩阵灰度频率存在一定差异,其中多尺度 Retinex 技术和本文算法所得的光强等级分布变宽,低层光强等级分布概率增大,说明图像亮度得到提高,可参照图 2 实验结果。而在发生频率幅值上,本文算法明显高于多尺度 Retinex 技术和二阶统计量 OCTM 技术,这表明本文算法的增强对比度效果更佳,可参照图 2 实验结果。

5 结 论

本文提出基于灰度有向无环图熵最大化量化分辨率医学图像色调增强算法。主要贡献有三个:(1)提出基于全最小二乘算法的新的量化分辨率转换技术,对输入直方图进行预处理获得高分辨率图像恢复直方图模型;(2)构建 DAG 图像增强模型,提出色调保持算法得到全局最优解,实现图像增强对比度的提高;(3)利用 DAG 的 Monge 定理特性,降低算法的计算复杂度。未来的研究工作主要是将 TPEM 技术从图像领域向视频领域进行延伸。

参考文献:

- [1] 戴霞,李辉,杨红雨,等.基于虚拟图像金字塔序列融合的快速图像增强算法[J].计算机学报,2014,37: 602.
- [2] Zeng T, Zhang T, Tian W M, et al. Space-surface bistatic SAR image enhancement based on repeat-pass coherent fusion with beidou-2/compass-2 as illuminators [J]. IEEE Geosci Remote S, 2016, 13: 1832.
- [3] Kwon S, Lee H, Lee S. Image enhancement with Gaussian filtering in time-domain microwave imaging system for breast cancer detection[J]. Electron Lett, 2016, 52: 342.
- [4] Faraji M R, Qi X J. Face recognition under varying illumination based on adaptive homomorphic eight local directional patterns [J]. IET Comput Vis, 2015, 9: 390.
- [5] 蒋伟,李小龙,刘亚威.基于有理数阶偏微分的图像增强新模型[J].四川大学学报:自然科学版,2016, 53: 47.
- [6] Li C Y, Guo J C, Cong R M, et al. Underwater Image Enhancement by Dehazing With Minimum Information Loss and Histogram Distribution Prior [J]. IEEE Trans Imag Process, 2016, 25: 5664.
- [7] 张玉,王正勇,滕奇志,等.自适应分数阶微分的图像增强及应用[J].四川大学学报:自然科学版,2015, 52: 93.
- [8] Liu B, Jin W Q, Chen Y , et al. Contrast enhancement using non-overlapped sub-blocks and local histogram projection[J]. IEEE Trans Consum Electr, 2011, 57: 12158080.
- [9] Ren J, Liu J Y, Guo Z M. Context-aware sparse decomposition for image denoising and super-resolution [J]. IEEE Trans Imag Process, 2013, 22: 1456.
- [10] Pyun K, Lim J, Won C S, et al. Image segmentation using hidden markov gauss mixture models[J]. IEEE Trans Imag Process, 2007, 16: 1902.
- [11] 任杰,刘家瑛,白蔚,等.基于隐式分段自回归模型的图像插值算法[J].软件学报,2012, 23: 1248.
- [12] Baragona R, Battaglia F, Cucina D. Fitting piecewise linear threshold autoregressive models by means of genetic algorithms[J]. Comput Stat Data An, 2004, 47: 277.
- [13] Shukri D S, Asmuni H, Othman R M , et al. An improved multiscale retinex algorithm for motion-blurred iris images to minimize the intra-individual variations [J]. Pattern Recogn Lett, 2013, 34: 1071.
- [14] Xu H, Zhai G, Wu X, et al. Generalized equalization model for image enhancement[J]. IEEE Trans Multimedia, 2013, 16: 68.
- [15] Golin M, Zhang Y. A dynamic programming approach to length-limited huffman coding: space reduction with the monge property[J]. IEEE Trans Inform Theory, 2010, 56: 3918.