

基于小波域隐马尔可夫树模型的 超声图象贝叶斯去噪

孙俊喜 赵永明 陈亚珠

(上海交通大学生命科学技术学院生物医学仪器研究所, 上海 200030)

摘要 提出了一种新的医学超声图象去噪方法。首先,原始超声图象经对数变换,其乘性散粒噪声变为了加性噪声;然后再经小波变换后,基于隐马尔可夫树模型,应用贝叶斯方法去除加性噪声;最后,经小波逆变换和指数变换恢复去噪后的原始超声图象。测试结果表明,此方法在有效去除噪声的同时,能保留原始图象的细节边缘。针对超声图象还对几种去噪算法作出定性比较,并对去噪性能给出定量分析,实验结果表明,该方法是可行的。

关键词 计算机图象处理(520.6040) 隐马尔可夫树模型 散粒噪声 小波分解

中图分类号: TP391 **文献标识码**: A **文章编号**: 1006-8961(2003)06-0657-07

Bayesian Denoising of Ultrasound Image Based on Wavelet Domain Hidden Markov Tree Model

SUN Jun-xi, ZHAO Yong-ming, CHEN Ya-zhu

(Institute of Biomedical Instrument, School of life science & Technology, Shanghai Jiaotong University, Shanghai 200030)

Abstract One of the hot key in medical image processing is how to suppressing speckle noise in ultrasound image. The low quality of ultrasound imaging brings some difficulty to sequential image processing and image analysis due to the effect of its inherent speckle noise. In this paper, a speckle suppression method for medical ultrasound image is presented. First, the logarithmic transform of the original image is analyzed into the multiscale wavelet domain. Then, the wavelet domain multiscale representation of image is regarded as Hidden Markov Tree model. The model is trained by the efficient EM algorithm, which is called Baum-welch algorithm. Speckle noise of ultrasound image is reduced by Bayesian estimator based on Hidden Markov model. Finally, the invert discrete wavelet transform and the exponent transform of the estimated wavelet coefficients obtain the denoised image in turn. Performance of the proposed method has been tested on ultrasound image. The results show the method effectively reduces the speckle while preserving the edges of the original image. Current state-of-the-art methods, such as soft and hard thresholding, are applied on actual ultrasound medical images and compared with the novel method. The achieved performance improvement is quantified. The experiment results show the proposed method is feasible and reasonable.

Keywords Computer image processing, Hidden markov tree model, Speckle noise, Wavelet decomposition

0 前言

最近20年来,超声成像技术在医学诊断领域获得了广泛的应用,相对于其他成像技术,它具有成本低、使用方便、无损检测、实时成像等优点。然而,由

于超声图象中固有的散粒噪声的存在,使得超声图象质量较低,给后续处理和分析带来困难。所以,如何有效地去除散粒噪声是超声图象特征提取、分析和识别的重要预处理环节。经典的超声图象去噪方法主要采用均值滤波、中值滤波和维纳滤波技术。实际上,均值滤波是线性低通滤波,并不适合去除超声

基金项目:上海市科技发展基金资助(994419027)

收稿日期:2002-04-01;改回日期:2002-11-18

图象的散粒噪声,因为它在去除高频噪声的同时,也模糊了图象边缘. 中值滤波作为非线性方法虽然能有效地去除散粒噪声,但其本质仍没有脱离低通滤波的范畴,会造成边缘细节的丢失. 经典的维纳滤波器利用图象和噪声的功率谱密度进行滤波,尽管它在最小均方差意义上降噪效果是最优的^[1],但由于它的局限性——仅适用于加性噪声,对超声图象的乘性散粒噪声,去除效果往往不佳. 为解决乘性噪声对图象的污染问题, Jain 使用同态滤波的方法^[2],通过对原始超声图象做对数变换,把乘性的散粒噪声转变为加性噪声,然后再采用维纳滤波技术去除加性噪声,最后,通过指数变换,获得去噪后的超声图象. 上述经典超声图象去噪方法大多采用单一尺度滤波,在滤除噪声的同时往往模糊了图象边缘或造成图象细节的丢失.

近年来,基于小波域的超声图象多尺度去噪技术受到了医学图象处理工作者的关注^[3~6]. 因为图象的小波分解紧紧抓住了图象的统计特性,使图象在小波域中表示大大简化. 这种去噪方法通常包括小波变换、小波系数分类为信号或噪声、小波反变换 3 个步骤. Zong 等^[3,6]采用同态滤波技术和小波分解相结合来去除超声图象散粒噪声,经对数变换和小波变换后,在细尺度采用小波软阈值^[7,8],同时沿图象细节边缘采用非线性处理,提高了图象的对比度. Xiang 和 Zhang 也利用小波阈值法去除超声图象噪声^[4],他们在所有尺度使用相同的阈值来获得最大的信噪比输出. Hao 等^[5]把原始超声图象通过自适应滤波分成两部分;首先对这两部分分别进行多尺度小波分解;然后采用软阈值去噪后,再转换到空域;最后把空间域表示的这两部分图象相加,从而得到去噪超声图象.

上述基于小波域收敛法的超声图象去噪技术存在以下缺点:

- (1) 作为一个重要的设计参数,阈值的选取往往受到主观因素的干扰;
- (2) 忽略了小波系数的统计分布;
- (3) 阈值操作属于点操作,没有考虑相邻小波系数的相互影响.

本文基于小波域隐马尔可夫树^[9,10],提出了一种新的医学超声图象去噪方法,该方法对一系列超声图象进行测试,结果表明,此方法能显著去除噪声,同时还能保留原始图象的细节边缘.

1 散粒噪声统计特性及小波域隐马尔可夫树模型

1.1 散粒噪声统计特性

散粒噪声是超声相干源和超声相关检波器作用于和超声波长尺寸相近的组织时产生的一种物理现象. Goodman 认为,当成像的采样频率大到可以忽略像素点之间的相互影响时,散粒噪声被认为是乘性复噪声,同时噪声的实部和虚部是满足独立、相同分布的零均值高斯随机变量^[11]. Arsenaut 指出,被乘性散粒噪声污染的图象经对数变换,散粒噪声近似于加性满足正态分布的高斯噪声^[12]. Jain 提出了如下被散粒噪声污染的图象数学模型^[2]

$$f(i, j) = x(i, j) \times q(i, j) \quad (1)$$

其中, $x(\cdot)$ 是有待恢复的、未知的真实图象, $f(\cdot)$ 是实际观测到的、被噪声污染的图象, $q(\cdot)$ 是乘性散粒噪声, i, j 代表像素的空间位置, $(i, j) \in \mathbf{R}^2$. 为区分散粒噪声 $q(\cdot)$ 和真实图象 $x(\cdot)$, 对式(1)两边取对数,得到

$$\tilde{f}(i, j) = \tilde{x}(i, j) + \tilde{q}(i, j) \quad (2)$$

$\tilde{f}(\cdot)$, $\tilde{x}(\cdot)$ 和 $\tilde{q}(\cdot)$ 分别是 $f(\cdot)$, $x(\cdot)$ 和 $q(\cdot)$ 的对数表示. 由前述可知, $q(\cdot)$ 在对数尺度上,可以近似为加性的零均值高斯白噪声.

1.2 小波域多尺度隐马尔可夫树模型

图象二进制离散小波变换在空域和频域刻画如图 1 所示, 图象每一方向 $D=HH, HL, LH$ 的小波系数都对应一四叉树结构, 如图 1 虚线所示, 从图 1 知, 小波系数的四叉树结构是嵌套的. 为叙述方便, 约定: 大写字母表示随机变量, 相应的小写字母表示该变量的具体实现. 给定方向 D , 当尺度为 k 时, 有 $N_k \times N_k$ 个小波系数随机变量集合




图 1 图象 3 尺度正交离散小波变换空/频表示 (虚线表示 HH 方向的四叉树结构)

$Y^{(k)} = \{Y_{i,j}^{(k)}\}$, 对应状态集合 $S^{(k)} = \{S_{i,j}^{(k)}\}$, $i, j = 1, \dots, N_k$, $H, N_k = N/2^k$, 尺度 $k = 1, \dots, K$, 分解的最大尺度 $K = \log_2 N$. $Y_{[i/2], [j/2]}^{(k+1)}$ 表示 $Y_{i,j}^{(k)}$ 的父节点, 符号 $[x]$ 表示小于 x 的最大整数.

对小波系数随机变量 Y 满足有严重拖尾的非高斯分布, 而高斯混合模型能够很好地逼近这种非高斯分布密度^[9,10]. 状态变量 S 可能取值 $m = 0, \dots, M-1$, 其概率分布函数为 $P_S(m)$, 则有 $f_Y(Y = y) = \sum_{m=0}^{M-1} P_S(m) f(Y = y | S = m)$, M 是状态变量 S 可能的最大状态数. 其中 $f(Y = y | S = s)$ 满足高斯分布, 即

$$f(Y = y | S = m) \sim N(\mu_m, \xi_m)$$

其中, μ 和 ξ 分别表示均值和方差.

高斯混合模型由以下参数集合 $\theta = \{P_S(m), \mu_m, \xi_m | m = 0, \dots, M-1\}$ 决定. 考察图象小波域特性, 假定

- (1) $P(S_{i,j}^{(k)} | S_{i,j}^{(q)}) = h, r = 1, \dots, N_q; q = k+1, \dots, K) = (P_S^{(k)} | S_{[i/2], [j/2]}^{(k+1)})$, 即当前节点状态只和其父节点状态有关, 而与其他节点状态无关.
- (2) $f(Y_{i,j}^{(k)} | S_{i,j}^{(k)}, i, j = 1, \dots, N_k) = f(Y_{i,j}^{(k)} | S_{i,j}^{(k)})$, 即当前节点小波系数观测值仅和当前节点状态有关.

由此, 可通过建立隐马尔可夫树模型来表示不同尺度小波系数之间的关系, 如图 2 所示.




图 2 HMT 模型

(白色节点代表该点状态随机变量 S , 黑色节点表示该点小波系数随机变量 Y)

对给定方向 D 的隐马尔可夫四叉树模型在尺度为 k 时, 有下列模型参数:

- (1) $\mu_m^{(k)}, \xi_m^{(k)}$ 高斯混合模型参数.
- (2) $\pi_m^{(k)} = P(S_m^{(k)} = m)$ 根节点状态变量 $S^{(K)}$ 的概率分布函数.
- (3) $a_{k,k+1}^{n,m} = P(S_{i,j}^{(k)} = n | S_{[i/2], [j/2]}^{(k+1)} = m)$ 父节点状态到子节点状态的转移概率.

这些参数写成集合形式为

$$\lambda^{(k)} = \{\mu_m^{(k)}, \xi_m^{(k)}, \pi_m^{(k)}, a_{k,k+1}^{n,m}\}, m, n = 0, \dots, M-1$$

2 小波域隐马尔可夫树贝叶斯去噪

2.1 图象贝叶斯去噪问题描述

用 T 表示正交小波变换, 则式(2)的小波变换记作

$$y = w + n \tag{3}$$

其中, $y = T(\tilde{f}), w = T(\tilde{x}), n = T(\tilde{q})$. y, w, n 分别代表观测图象, 真实图象和散粒噪声经对数变换后的小波系数, 则超声图象贝叶斯去噪问题描述为: 在给定 y 的前提下, 按照某种准则估计真实图象的小波系数. 超声图象去噪法流程如图 3 所示.




图 3 超声图象去噪方法流程图

由于正交小波变换近似 Karhunen-Loeve 变换, 它具有去相关性, 所以零均值高斯噪声 q 经正交小波变换后成为零均值高斯白噪声. 因此, 给定方向 D 和小波分解的尺度 k , 可以假定噪声方差是一常数 σ_n^2 , 给定观测图象小波系数随机变量 $Y_{i,j}^{(k)}$ 取值, 则真实图象的小波系数随机变量 $W_{i,j}^{(k)}$ 的后验均值估计

$$\begin{aligned} E(W_{i,j}^{(k)} | Y_{i,j}^{(k)} = y) &= \sum_w w P(W_{i,j}^{(k)} = w | Y_{i,j}^{(k)} = y) \\ &= \sum_w w \sum_S P(W_{i,j}^{(k)} = w, S_{i,j}^{(k)} = s | Y_{i,j}^{(k)} = y) \\ &= \sum_w w \sum_S P(W_{i,j}^{(k)} = w | S_{i,j}^{(k)} = s, Y_{i,j}^{(k)} = y) P(S_{i,j}^{(k)} = s | Y_{i,j}^{(k)} = y) \\ &= \sum_S E(W_{i,j}^{(k)} | S_{i,j}^{(k)} = s, Y_{i,j}^{(k)} = y) P(S_{i,j}^{(k)} = s | Y_{i,j}^{(k)} = y) \\ &= \sum_S P(S_{i,j}^{(k)} = s | Y_{i,j}^{(k)} = y) \frac{\xi_{k,i,j,s}^2 - \sigma_n^2}{\xi_{k,i,j,s}^2} y \end{aligned}$$

$\xi_{k,i,j,m}^2$ 是观测图象小波系数随机变量 $Y_{i,j}^{(k)}$ 的方差, 其中, k 表示尺度, i, j 表示空间位置, m 表示状态. σ_n^2 是噪声的方差, $E(W | Y = y, \lambda)$ 可以获得对 W 的最小均方误差估计. 为计算 $P(S_{i,j}^{(k)} | Y_{i,j}^{(k)} = y, \lambda^{(k)})$ 和 $\xi_{k,i,j,m}^2$, 需要使用 EM 算法.

2.2 隐马尔可夫树模型训练

为保证有足够的训练数据, 假定在同一尺度, 同一方向, 不同的小波系数有相同

的高斯混合模型参数. 为计算方便, 采用 2-状态高斯混合模型表示小波系数的直方图统计分布(图 4). 其中“0”表示低能量状态, “1”表示高能量状态.

首先对每一方向在尺度 $k=1, \dots, K$ 内进行 EM 计算, 以获得 $Y^{(k)}$ 的高斯混合模型的参数 $\lambda^{(k)} = \{P_{S_v^{(k)}}(m), \mu_m^{(k)}, \xi_m^{(k)}, \pi_m^{(k)}, a_{v, \rho(v)}^{n, m}\}, m, n=0, 1$.




图 4 超声图象(经过对数变换)

图 4 中, 图 4(b) 为小波系数统计分布模型. 实际代表小波系数的实际分布, “+”代表高斯分布曲线, “-”代表两状态高斯混合分布曲线, 图 4(a) 和图 4(c) 分别是图 4(b) 拖尾部分的放大显示. 此处小波采用 4 阶 Daubechies 小波, 分解尺度为频段 HH.

2.2.1 EM 算法

隐马尔可夫模型中的前向-后向算法实际和 EM 算法中的 E 步操作是一致的. 为叙述方便, 以单棵隐马尔可夫树为例. 首先, 引入下列概念: 从根节点为 v 的树 $T_v^{(k)}$ 中去除树 $T_{\rho(v)}^{(k-1)}$, 记作 $T_{v, \rho(v)}^{(k, k-1)}$, 其中 $T_{v, \rho(v)}$ 表示空树, $\rho(v)$ 表示节点 v 的父节点. 为不失问题的一般性, 对 Y 排序; Y_1 是整棵树的根节点随机变量, 这样 T_1 代表待研究的整棵树. 给定方向 D , 设尺度为 k 时, 隐马尔可夫树 $\lambda^{(k)}$ 的小波系数观测集合 $y^{(k)} = \{y_{i, \rho(i)}^{(k)}\}$, 对应状态值集合 $S^{(k)} = \{S_{v, \rho(v)}^{(k, k-1)}\}$, 且 $S_{v, \rho(v)} \in \{0, 1\}$, 其中尺度 $l=1, \dots, k$. E 步操作的基本任务是给定隐马尔可夫四叉树的参数集合 $\lambda^{(k)}$, 计算状态概率

$$P(S_v^{(k)}=m | Y^{(k)}=y, \lambda^{(k)}) \text{ 和}$$

$$P(S_v^{(k)}=n, S_{\rho(v)}^{(k+1)}=m | Y^{(k)}=y, \lambda^{(k)})$$

对根节点为 v 的 T_v 树, 引入下面中间变量

$$\beta_v^{(k)}(m) = f(T_{v, \rho(v)}^{(k, k-1)} | S_v^{(k)}=m, \lambda^{(k)})$$

$$\beta_{v, \rho(v)}^{(k, k-1)}(m) = f(T_{v, \rho(v)}^{(k, k-1)} | S_{\rho(v)}^{(k+1)}=m, \lambda^{(k)})$$

$$\beta_{\rho(v), v}^{(k+1, k)}(m) = f(T_{\rho(v), v}^{(k+1, k)} | S_{\rho(v)}^{(k+1)}=m, \lambda^{(k)})$$

$$a_v^{(k)}(m) = P(S_v^{(k)}=m, T_{1, v} | \lambda^{(k)})$$

$$a_{v, \rho(v)}^{n, m} = P(S_v^{(k)}=n | S_{\rho(v)}^{(k+1)}=m)$$

给定状态变量 $S_v^{(k)}$, 树 $T_v^{(k)}$ 和 $T_{\rho(v), v}^{(k+1, k)}$ 是相互独立的, 则

$$P(S_v^{(k)}=m, T_1 | \lambda^{(k)}) = \alpha_v^{(k)}(m) \beta_v^{(k)}(m)$$

$$P(S_v^{(k)}=n, S_{\rho(v)}^{(k+1)}=m, T_1 | \lambda^{(k)}) =$$

$$\alpha_{\rho(v)}^{(k+1)}(m) \beta_{\rho(v), v}^{(k+1, k)}(m) \beta_v^{(k)}(n) a_{v, \rho(v)}^{n, m}$$

$$f(T_1 | \lambda^{(k)}) = \sum_{m=0}^1 P(S_v^{(k)}=m, T_1 | \lambda^{(k)}) =$$

$$\sum_{m=0}^1 \alpha_v^{(k)}(m) \beta_v^{(k)}(m)$$

$$P(S_v^{(k)}=m | T_1, \lambda^{(k)}) = \frac{\alpha_v^{(k)}(m) \beta_v^{(k)}(m)}{\sum_{m=0}^{M-1} \alpha_v^{(k)}(m) \beta_v^{(k)}(m)}$$

$$P(S_v^{(k)}=n, S_{\rho(v)}^{(k+1)}=m | T_1, \lambda^{(k)}) =$$

$$\frac{\alpha_{\rho(v)}^{(k+1)}(m) \beta_{\rho(v), v}^{(k+1, k)}(m) \beta_v^{(k)}(n) a_{v, \rho(v)}^{n, m}}{\sum_{m=0}^{M-1} \alpha_v^{(k)}(m) \beta_v^{(k)}(m)}$$

2.2.2 E 步算法

算法描述如下:

初始化 给 λ 赋初值 $\lambda^{(0)}$;

后向算法:

在最细尺度 $k=1$, 给定状态变量 $S_v^{(1)}=m$, 计算

$$\beta_v^{(k)}(m) = f(y_v^{(k)}, \mu_{v, m}^{(k)}, \xi_{v, m}^{(k)}, \pi_{v, m}^{(k)}), m=0, 1$$

(1) 在尺度 k , 给定状态变量 $S_v^{(k)}=m$, 计算

$$\beta_{\rho(v), v}^{(k+1, k)}(m) = \sum_{n=0}^1 \alpha_{\rho(v), v}^{n, m} \beta_v^{(k)}(n)$$

$$\beta_{v, \rho(v)}^{(k, k-1)}(m) = f(y_{\rho(v)}^{(k+1)}, \mu_{\rho(v), m}^{(k+1)}, \xi_{\rho(v), m}^{(k+1)}, \pi_{\rho(v), m}^{(k+1)}) \prod_{v \in \rho(v)} \beta_{\rho(v), v}^{(k+1, k)}(m)$$

$$\beta_{\rho(v),v}^{(k+1)}(m) = \beta_{\rho(v)}^{(k+1)}(m) / \beta_{\rho(v),v}^{(k+1)}(m)$$

(2) 令 $k = k + 1$

(3) 若 $k = K$, 则停止, 否则, 转第 1 步
前向算法:

(1) 在最粗尺度 $k = K$, 给定状态变量 $S_v^{(K)} = m$,

计算 $a_v^{(K)}(m) = P_{S_v}(m), m = 0, 1$

(2) 令尺度 $k = k - 1$, 给定状态变量 $S_v^{(k)} = m$, 计算

$$a_v^{(k)}(m) = \sum_{n=0}^1 a_{\rho(v)}^{(k+1)}(n) a_{v,\rho(v)}^{m,n} \beta_{\rho(v),v}^{(k+1)}(n)$$

(3) 若 $k = 1$, 则停止, 否则, 转第 1 步

2.2.3 M 步算法

经过 E 步计算, 状态概率 $P(S_v^{(k)} = m | Y^{(k)} = y, \lambda^{(k)})$ 和 $P(S_v^{(k)} = m, S_{\rho(v)}^{(k+1)} = n | Y^{(k)} = y, \lambda^{(k)})$ 已知后, M 步的最大似然参数更新形式如下(此处 $v = (i, j)$)

$$P_{S_v}^{(k)}(m) = \frac{1}{N_k} \sum_{i=0}^{N_k-1} \sum_{j=0}^{N_k-1} P(S_v^{(k)} = m | Y^{(k)} = y, \lambda^{(k)})$$

$$a_{v,\rho(v)}^{m,n} = \frac{1}{N_k \cdot P_{S_v}^{(k)}(m)} \times$$

$$\sum_{i=0}^{N_k-1} \sum_{j=0}^{N_k-1} P(S_v^{(k)} = n, S_{\rho(v)}^{(k+1)} = m | Y^{(k)} = y, \lambda^{(k)})$$

$$\mu_{v,m}^{(k)} = \frac{1}{N_k \cdot P_{S_v}^{(k)}(m)} \sum_{i=0}^{N_k-1} \sum_{j=0}^{N_k-1} y_v^{(k)} P(S_v^{(k)} = n | Y^{(k)} = Y, \lambda^{(k)})$$

$$\xi_{v,v,m}^{(k)} = \frac{1}{N_k \cdot P_{S_v}^{(k)}(m)} \times$$

$$\sum_{i=0}^{N_k-1} \sum_{j=0}^{N_k-1} (y_v^{(k)} - \mu_{v,m}^{(k)})^2 P(S_v^{(k)} = n | Y^{(k)} = y, \lambda^{(k)})$$

重复 E 步算法和 M 步算法直至收敛, 则隐马尔可夫

模型训练完毕.

2.3 算法实现

(1) 对 f 作对数变换得到 \tilde{f} ;

(2) 对 \tilde{f} 作正交离散小波变换得到 y ;

(3) 初始化训练参数 $P_{S_v}(0) = P_{S_v}(1) = 0.5, \mu_0^{(k)} = \mu^{(k)} = 0, \xi_{i,1}^2 = 2\sigma_{v_i}^2, \xi_{i,0}^2 = 0.5\sigma_{v_i}^2, \sigma_{v_i}^2$, 取作 1 尺度 HH 方向的小波系数随机变量 $Y^{(1)}$ 的方差, $a_{i,m}^{(k+1)} = 0.5$, 其中 $n, m = 0, 1$;

(4) 重复各以下算法, 直到收敛

后向算法: 计算 $\beta_v^{(k)}(m)$

前向算法: 计算 $a_v^{(k)}(m)$

M 步算法: 更新参数 $\lambda^{(k)}$;

(5) 后验期望估计 $w = E(W | Y = y, \lambda)$;

(6) 对 w 作小波逆变换 w^{-1} ;

(7) 对 w^{-1} 作指数变换, 得到真实图象 x 的最小均方误差估计 \hat{x} .

3 实验结果及讨论

采用阿洛卡 SSD-1000 超声诊断设备(电子凸阵探头 UST-979-3.5)获得尺寸为 $640 \times 480 \times 256$ 器官图象. 为处理方便, 截取 256×256 大小的感兴趣区域, 如图 5(a)所示. 根据 1.1 节所述散粒噪声的数学模型, 生成 3 种不同方差(分别为 5%, 10%, 20%)的零均值复高斯随机场(实部和虚部分别满足独立、同一高斯分布), 提取模值后作用于原始超声图象.




图 5 各种超声图象去噪方法结果比较

用本文方法和中值滤波、同态维纳滤波以及小波域软、硬阈值法对图 5(b)去噪的结果如图 5(c)~(g)所示. 针对固定图象, 每种方法, 都作了多次实验, 以求获得该方法的最佳处理效果. 为有效地去除噪声, 同时又较好地保留边缘特征, 中值滤波和同态维纳滤波都采用了 3×3 窗口. 基于小波的去噪方法, 全部使用 4 阶正交 Daubechies 小波, 因为它有去相关特性.

软阈值取作 1.5ξ , 硬阈值取作 2.5ξ , 其中 ξ 是对小波系数标准偏差的估计. 另外, 由于离散二进制正交小波变换的时变特性, 会造成图象恢复时的“伪影”现象, 因此采用“Cycle CSping”算法^[13], 位移取作 6, 小波分解的最大尺度取为 5. 从图 5 看到, 中值滤波和同态维纳滤波丢失了较多的图象细节, 软、硬阈值法造成了过度平滑, 显而易见, 本文方法在有效去除噪

声的同时,较好地保留了图象的细节。

使用信号和均方误差的比值作为对乘性噪声污染图象去噪效果的定量评价^[14]

$$I/MSE = -10 \log_{10} \left\{ \sum_i (\hat{I}_i - I_i)^2 / \sum_i I_i^2 \right\}$$

其中: I 为原始图象; \hat{I} 为去噪后的图象; i 为图象像素序号。

考虑到医学超声图象去噪不仅要关注去噪的效果,而且也要考虑去噪方法对细节边缘的保持程度。因为这些细节特征常常是医学诊断的直接依据。采

用文献[5]、[15]中的相关测度 β

$$\beta = \frac{\Gamma(\Delta I - \overline{\Delta I}, \Delta \hat{I} - \overline{\Delta \hat{I}})}{\sqrt{\Gamma(\Delta I - \overline{\Delta I}, \Delta I - \overline{\Delta I}) \cdot \Gamma(\Delta \hat{I} - \overline{\Delta \hat{I}}, \Delta \hat{I} - \overline{\Delta \hat{I}})}}$$

评价去噪方法对细节边缘的保持程度。

$$\text{式中 } \Gamma(t_1, t_2) = \sum_i t_1(i) \cdot t_2(i)$$

ΔI 和 $\Delta \hat{I}$ 分别是 I 和 \hat{I} 高通滤波的结果。 β 值越大,边缘保持效果就越好。每种去噪方法的 β 和 I/MSE 如表 1 所示。

表 1 5 种超声图象去噪方法性能比较

评价准则	加噪图象	中值滤波法	同态维纳滤波法	小波软阈值法	小波硬阈值法	本文方法
β	0.4564	0.2460	0.3952	0.574	0.4820	0.5903
$I/MSE(\text{dB})$	13.9627	17.9068	18.6429	19.3706	19.5178	20.1961
β	0.3074	0.1516	0.3092	0.3799	0.3295	0.3950
$I/MSE(\text{dB})$	10.0079	14.9601	15.9490	16.2852	16.3220	16.3393
β	0.1863	0.1005	0.2001	0.2342	0.2167	0.3270
$I/MSE(\text{dB})$	7.0195	11.2833	12.4175	12.4964	13.0650	13.7078

观察表 1, 可以看到, 基于小波域的超声图象多尺度去噪要优于单一尺度的中值滤波和同态维纳滤波方法, 同时它较好地保留了图象的边缘, 而本文所用方法在一定程度上要优于软、硬阈值算法, 这主要是由于本文采用的方法, 更好地考虑了像素点间的相互影响, 而不再采用单一的阈值操作。实验表明, 本文采用的超声图象去噪方法是可行的。由于使用 EM 算法训练隐马尔可夫树的参数, 所以, 处理速度受到影响, 但对于离线超声图象处理, 速度并不是主要的。

参 考 文 献

- 1 邓必鑫. 信号分析基础[M]. 北京: 北京理工大学出版社, 1994, 400~406.
- 2 Jain K. Fundamental of digital image processing [M]. Englewood Cliffs, NJ USA: Prentice-Hall, 1989.
- 3 Zong Xuli, Laine A F, Geiser E A. Speckle reduction and contrast enhancement of echocardiograms via multiscale nonlinear processing[J]. IEEE Transactions on Medical Imag, 1998, 17(4): 532~540.
- 4 Xiang S H, Zhang Y T. Maximization of the signal to-noise ratio for two dimensional medical ultrasound transducer sensitivity improvement by denoising wavelets [A]. In: Proceedings of International Conference Biomedical Engineering [C], Hong Kong, 1996; 3~5.
- 5 Hao Xiao-hui, Gao Shang-kai, Gao Xiao-rong. A novel multiscale nonlinear Thrtesholding method for ultrasonic speckle suppressing[J]. IEEE Transactions on Medical Imag, 1999, 18(9): 787~794.

- 6 Zong X, Geiser E A, Laine A F et al. Homomorphic wavelet shrinkage and feature emphasis for speckle reduction and enhancement of echocardiographic images[A]. In: Proceedings of SPIE, Medical Imaging: Image Processing[C]. Newport Beach, USA 1996, 2710: 658~667.
- 7 Donoho L. Denoising by soft-thresholding [J]. IEEE Transactions on Information Theory, 1995, 41(3): 613~627.
- 8 Donoho D L, Johnstone I. Adapting to unknown smoothness via wavelet shrinkage [J]. J. Amer. Statistical Assoc. 1995, 90(432): 1200~1224.
- 9 Crouse Matthew S, Nowak Robert D, Baraniuk Richard G. Wavelet-based statistical signal processing using hidden markov models [J]. IEEE Transactions on Signal Processing, 1998, 46(4): 886~902.
- 10 Romberg J K, Hyeokho Choi, Baraniuk R G. Bayesian tree-structured image modeling using wavelet-domain hidden Markov models [J]. IEEE Transactions on Image Processing, 2001, 10(7): 1056~1068.
- 11 Goodman J W. Some fundamental properties of speckle [J]. J. Opt. Soc. Amer. 1976, 66(11): 1145~1150.
- 12 Asernaut H H, April G. Properties of speckle integrated with a finite aperture and logarithmically transform [J]. J. Opt. Soc. Am., 1976, 66(11): 1160~1163.
- 13 Coifman R R, Donoho D L. Translation-invariant de-noising [A]. In: Wavelets and Statistics [A], Antoniadis A. and Oppenheim G., Eds. Lecture Notes in Statistics. New York, Berlin, Germany: Springer-Verlag, 1995, 103: 125~150.
- 14 Gagnon L, Jouan A. Speckle filtering of SAR images-A comparative study between complex-wavelet based and standard filters [A]. In: SPIE Proc [C]. Washington, USA 1997, 3169,

80~91.

- 15 Sattar F, Floreyby L, Salomonsson G *et al.* Image enhancement based on a nonlinear multiscale method[J]. IEEE Transactions on Image Processing, 1997, 6(1):888~895.



孙俊喜 1971 年生, 讲师, 目前在上海交通大学生物医学工程系攻读博士学位, 研究方向为医学图象处理、模式识别。



赵永明 1976 年生, 目前在上海交通大学生物医学工程系攻读博士学位, 研究方向为医学图象处理。

陈亚珠 1936 年生, 教授, 博士生导师, 中国工程院院士。主要从事 HIFU 技术和医学图象导引治疗的研究。