

# 基于剪切波变换的改进全变分散斑去噪方法

邱岳<sup>1</sup>, 唐晨<sup>1\*</sup>, 徐敏<sup>1</sup>, 黄圣鉴<sup>1</sup>, 雷振坤<sup>2</sup>

<sup>1</sup>天津大学电气自动化与信息工程学院, 天津 300072;

<sup>2</sup>大连理工大学工业装备结构分析国家重点实验室, 辽宁 大连 116023

**摘要** 在散斑去噪过程中保持图像边缘纹理特征,是光学相干层析图像处理技术的难题。散斑去噪过程中的散斑残留和边缘纹理模糊是该难题的主要诱导因素。为解决这一难题,提出一种基于剪切波变换的改进全变分散斑去噪方法。该方法结合剪切波变换和传统全变分模型,对不同图像区域采用针对性的去噪策略,兼顾散斑去噪与纹理保留,提高了光学相干层析图像的噪声抑制效果。对不同生理、病理状态下的视网膜光学相干层析图像进行测试,结果表明:该方法通过采用区域针对性策略改进了噪声抑制能力,通过引入剪切波变换方法提高了边缘纹理保持能力,进而同时实现散斑去除和纹理保留。此外,与其他散斑去噪方法进行对比,验证了该方法的有效性。

**关键词** 图像处理; 散斑去噪; 边缘纹理保护; 光学相干层析; 剪切波变换; 全变分

中图分类号 T391.4

文献标志码 A

doi: 10.3788/LOP57.021003

## Shearlet-Transform-Based Improved Total Variation Speckle Denoising Method

Qiu Yue<sup>1</sup>, Tang Chen<sup>1\*</sup>, Xu Min<sup>1</sup>, Huang Shengjian<sup>1</sup>, Lei Zhenkun<sup>2</sup>

<sup>1</sup> School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China;

<sup>2</sup> State Key Laboratory of Structural Analysis for Industrial Equipment, Dalian University of Technology, Dalian, Liaoning 116023, China

**Abstract** In the field of optical coherence tomography, reducing the speckle noise while protecting the textural features of image edge is difficult mainly because of the speckle residue and textural blur of edge in the speckle denoising process. To solve this problem, this study proposes a shearlet-transform-based improved total variation speckle denoising method. By combining the shearlet transform with the traditional total variation model, as well as a targeted denoising strategy applied on different image regions, the proposed method reduces the speckle noise without disturbing the texture in the image, and further improves the speckle-noise suppression in the original optical coherence tomography image. The proposed method is tested on many retinal optical coherence tomography images under different physiological and pathological conditions. Results show that the regional targeted strategy in the proposed method improves the ability of speckle-noise suppression, while the shearlet transform improves the ability of the edge texture protection, resulting in simultaneous speckle reduction and texture protection. The effectiveness of the proposed method is also confirmed in comparison with other common speckle denoising methods.

**Key words** image processing; speckle denoising; edge texture protection; optical coherence tomography; shearlet transform; total variation

**OCIS codes** 100.2980; 110.6150; 200.3050

收稿日期: 2019-05-27; 修回日期: 2019-06-13; 录用日期: 2019-06-26

基金项目: 国家自然科学基金(11772081)

\* E-mail: tangchen@tju.edu.cn

# 1 引言

光学相干层析成像技术(OCT)是一种新兴的体内断层成像技术,对体内微小结构具有高分辨率是这一技术的主要优点,被广泛应用于医学成像与临床诊断领域<sup>[1-4]</sup>。因采用了光学相干成像技术,该技术始终无法避免散斑噪声的出现<sup>[5]</sup>。散斑噪声实质是一种外观呈颗粒状的乘性噪声,它的引入导致所得图像的纹理细节严重模糊,图像的对比度严重下降,从而进一步导致图像分割、图像识别的精度明显下降,产生误诊等严重后果。可见,散斑滤除抑制对医学诊断尤其眼科视网膜诊断具有重要意义。

通常,散斑去噪方法可分为空间域方法和变换域方法。在空间域方法中,基于扩散的方法通过非线性各向异性扩散过程和非线性复杂扩散过程,在去除散斑噪声方面取得了较好的效果<sup>[6-8]</sup>,然而在高散斑噪声情况下会出现过拟合现象,造成细节信息的丢失。基于全变分(TV)的方法也是空间域方法中非常成功的一种<sup>[9]</sup>,它以平滑内部结构和保护边缘部分见长,但由于无法反映足够多的信号和噪声信息,容易导致“阶梯”效应。并且,该方法对于图像不同区域的去噪效果存在较大差异,会影响整体的去噪结果。此外,基于稳健性主成分分析的算法同样对滤除散斑噪声有良好的适用性<sup>[10]</sup>,它通过基于稳健性主成分分析算法的低秩矩阵恢复模型,将OCT原始图像分解成散斑噪声图像和样品截面图像的最佳估计,在抑制散斑噪声方面取得了良好的效果。

在变换域方法中,一种重要的散斑去噪方法,如小波变换方法<sup>[11]</sup>,通过采用多尺度变化方法将原始图像分解为不同特征图,再通过使用系数收缩技术获得了良好的去噪效果。近年来,在小波变换方法的基础上又发展了许多改进算法,例如自适应小波变换<sup>[12]</sup>、曲波变换(Curvelet)<sup>[13]</sup>、轮廓波变换<sup>[14]</sup>、剪切波变换<sup>[15-16]</sup>等方法。由于没有充分考虑图像的空间信息冗余,此类方法容易使图像纹理中出现伪影划痕现象,严重影响了去噪效果。另外,基于窗函数滤波的方法也开始被应用到散斑去噪领域<sup>[17]</sup>,该方法将系统的全光谱信号分为多个光谱信号,利用窗函数对每个分立的光谱信号进行滤波,单独进行常规数据处理,然后将处理后的各个分光谱进行平均合成,以达到降低散斑噪声的目的。

对于人的视网膜图像,同时做到有效的噪声

滤除和良好的细节信息保护成为了一个亟待解决的难题。为了解决这个问题,本文在剪切波变换的方法中引入传统的TV去噪模型,提出了一种基于剪切波变换的改进全变分散斑去噪方法(SITV)。赋予去噪项、保边项和保真项不同的权重,使得去除噪声和保留边缘细节二者之间达到一个良好的平衡状态。在具体的计算过程中,使用了基于分裂Bregman迭代的快速数值算法。此外,对视网膜图像的不同区域分别赋予更有针对性的去噪策略,进一步提高了图像的去噪效果。在本文方法的作用下,不仅视网膜图像的区分度、平滑程度、对比度等去噪指标有了明显提升,而且图像的边缘锐利程度也得到了增强。本文选用三组不同的视网膜图像进行实验,通过对本文方法、自适应复合扩散方法(ACD)以及Curvelet方法进行比较可知,所提出的方法不仅能有效去除散斑噪声,同时还可以保留图像的纹理信息,提升了原始图像的质量。

## 2 基本原理

### 2.1 SITV方法的模型

为了尽可能地保留图像的结构细节,提出了一种基于剪切波变换的改进式全变分散斑去噪方法。本模型包括三项:去噪正则项、加权保边正则项和加权保真项。给三项分配不同权重,使滤除噪声和保护细节之间达到较好的平衡状态。

本文算法的原型为TV方法<sup>[9]</sup>,该方法中对去噪结果的求解实质上可看作是各向异性TV最小值优化问题,可表示为

$$i_{dn} = \min_i \{ (\| \nabla_x i \|_1 + \| \nabla_y i \|_1) + \mu \cdot \frac{1}{2} \| i - i_n \|_2^2 \}, \quad (1)$$

式中: $i_n$ 和 $i_{dn}$ 分别为原始噪声图像和去噪结果图;算子 $\| \cdot \|_1$ 和 $\| \cdot \|_2$ 分别为L1范数和L2范数; $\nabla_x i$ 和 $\nabla_y i$ 分别为 $i$ 在 $x$ 和 $y$ 方向上的梯度; $\| \nabla_x i \|_1 + \| \nabla_y i \|_1$ 为 $i$ 的全变分范数,即传统的全变分模型,作为本模型中的去噪正则项,起到滤除图像中散斑噪声的作用。

(1)式中, $\mu \cdot \frac{1}{2} \| i - i_n \|_2^2$ 这一项为本算法中的加权保真项,代表原图和去噪图像之间的加权欧氏距离,通过调整去噪参数 $\mu$ ,可以起到更好的散斑噪声抑制效果。

为了在去噪的同时对图像的边缘纹理特征进行

保护,本算法引入了剪切波变换方法<sup>[15-16]</sup>,即在(1)式的基础上增加加权保边正则项,表达式为

$$\mathbf{i}_{\text{dn}} = \min_i \{ (\| \nabla_x \mathbf{i} \|_1 + \| \nabla_y \mathbf{i} \|_1) + \mu \cdot \frac{1}{2} \| \mathbf{i} - \mathbf{i}_n \|_2^2 + \lambda \cdot \sum_j \| \text{SH}_j(\mathbf{i}) \|_1 \}, \quad (2)$$

式中: $\lambda \cdot \sum_j \| \text{SH}_j(\mathbf{i}) \|_1$ 为保边正则项,通过调整保边参数 $\lambda$ ,可以在噪声抑制的同时实现对边缘特征的保护。其中, $\text{SH}_j(\mathbf{i})$ 为对 $\mathbf{i}$ 进行剪切波变换后得到的第 $j$ 幅子带复原图像,为图像提供了更多几何信息。

通常,利用(2)式所示的去噪方法可以简单便捷地实现对视网膜 OCT 图像的去散斑处理。然而,在去散斑处理过程中,该方法对不同区域的 OCT 图像采用了均等处理的方式,故很难同时实现不同图像区域的最优去噪效果。为了有效解决上述难题,本算法通过使用 FCM(fuzzy C-means)聚类方法<sup>[18]</sup>对上述去噪方法进行改进,将视网膜图像准确分割为背景部分、低密度纹理部分、高密度纹理部分,并对不同部分的图像分配适当的权重,以有针对性地控制去噪过程中 TV 去噪方法对不同区域图像的扩散演化程度,从而实现针对不同区域图像的针对性去噪,表达式为

$$\mathbf{i}_{\text{dn}} = \min_i \{ M \cdot (\| \nabla_x \mathbf{i} \|_1 + \| \nabla_y \mathbf{i} \|_1) + \mu \cdot \frac{1}{2} \| \mathbf{i} - \mathbf{i}_n \|_2^2 + \lambda \cdot \sum_j \| \text{SH}_j(\mathbf{i}) \|_1 \}, \quad (3)$$

式中: $M = \delta_1 \cdot M_1 + \delta_2 \cdot M_2 + \delta_3 \cdot M_3$ , $M_1$ 、 $M_2$ 和 $M_3$ 是通过 FCM 聚类方法分成的三个区域,分别为视网膜图像的背景区域、高密度纹理区域和低密度纹理区域; $\text{SH}_j(\mathbf{i})$ 表示对 $\mathbf{i}$ 进行剪切波变换后得到的第 $j$ 幅子带复原图像。本文中通过给每个区域赋予不同的系数—— $\delta_1 = 10$ 、 $\delta_2 = 0.075$ 、 $\delta_3 = 0.5$ ,实现对图像不同区域的针对性去噪处理。

## 2.2 基于分裂 Bregman 迭代的快速数值算法

用 $\mathbf{d}_x$ 、 $\mathbf{d}_y$ 和 $\mathbf{d}_{\text{SH}_j}$ 这些辅助变量来替换(3)式中的 $\nabla_x \mathbf{i}$ 、 $\nabla_y \mathbf{i}$ 和 $\text{SH}_j(\mathbf{i})$ , (3)式可以转化为用约束优化问题的形式表示:

$$\mathbf{i}_{\text{dn}} = \min_i \{ M \cdot (\| \mathbf{d}_x \|_1 + \| \mathbf{d}_y \|_1) + \mu \cdot \frac{1}{2} \| \mathbf{i} - \mathbf{i}_n \|_2^2 + \lambda \cdot \sum_j \| \mathbf{d}_{\text{SH}_j} \|_1 \}, \quad \text{s.t.} \begin{cases} \mathbf{d}_x = \nabla_x \mathbf{i} \\ \mathbf{d}_y = \nabla_y \mathbf{i} \\ \mathbf{d}_{\text{SH}_j} = \text{SH}_j(\mathbf{i}) \end{cases}, \quad (4)$$

使用多个惩罚函数项,将(4)式转化为非约束的多元形式,表达式为

$$(\mathbf{i}_{\text{dn}}, \mathbf{d}_x, \mathbf{d}_y, \mathbf{d}_{\text{SH}_j}) = \min_{\mathbf{i}, \mathbf{d}_x, \mathbf{d}_y, \mathbf{d}_{\text{SH}_j}} \left[ M \cdot (\| \mathbf{d}_x \|_1 + \| \mathbf{d}_y \|_1) + \mu \cdot \frac{1}{2} \| \mathbf{i} - \mathbf{i}_n \|_2^2 + \lambda \cdot \sum_j \| \mathbf{d}_{\text{SH}_j} \|_1 + M \cdot \left( \eta' \cdot \frac{1}{2} \| \mathbf{d}_x - \nabla_x \mathbf{i} \|_2^2 + \eta' \cdot \frac{1}{2} \| \mathbf{d}_y - \nabla_y \mathbf{i} \|_2^2 \right) + \lambda \eta'' \cdot \frac{1}{2} \sum_j \| \mathbf{d}_{\text{SH}_j} - \text{SH}_j(\mathbf{i}) \|_2^2 \right], \quad (5)$$

式中: $\eta'$ 和 $\eta''$ 为惩罚因子,分别起到调整 $\mathbf{d}_x$ 、 $\mathbf{d}_y$ 和 $\mathbf{d}_{\text{SH}_j}$ 准确度的作用。

为了更有效地对该模型进行运算,引入了 Bregman 迭代方法<sup>[19-20]</sup>。于是,(5)式可以表示成

$$(\mathbf{i}^{k+1}, \mathbf{d}_x^{k+1}, \mathbf{d}_y^{k+1}, \mathbf{d}_{\text{SH}_j}^{k+1}) = \min_{\mathbf{i}, \mathbf{d}_x, \mathbf{d}_y, \mathbf{d}_{\text{SH}_j}} \left[ M \cdot (\| \mathbf{d}_x \|_1 + \| \mathbf{d}_y \|_1) + \mu \cdot \frac{1}{2} \| \mathbf{i} - \mathbf{i}_n \|_2^2 + \lambda \cdot \sum_j \| \mathbf{d}_{\text{SH}_j} \|_1 + M \cdot \left( \eta' \cdot \frac{1}{2} \| \mathbf{d}_x - \nabla_x \mathbf{i} - \mathbf{b}_x^k \|_2^2 + \eta' \cdot \frac{1}{2} \| \mathbf{d}_y - \nabla_y \mathbf{i} - \mathbf{b}_y^k \|_2^2 \right) + \lambda \eta'' \cdot \frac{1}{2} \sum_j \| \mathbf{d}_{\text{SH}_j} - \text{SH}_j(\mathbf{i}) - \mathbf{b}_{\text{SH}_j}^k \|_2^2 \right], \quad (6)$$

其中

$$\begin{cases} \mathbf{b}_x^{k+1} = \mathbf{b}_x^k + (\nabla_x \mathbf{i}^{k+1} - \mathbf{d}_x^{k+1}) \\ \mathbf{b}_y^{k+1} = \mathbf{b}_y^k + (\nabla_y \mathbf{i}^{k+1} - \mathbf{d}_y^{k+1}) \\ \mathbf{b}_{\text{SH}_j}^{k+1} = \mathbf{b}_{\text{SH}_j}^k + [\text{SH}_j(\mathbf{i}^{k+1}) - \mathbf{d}_{\text{SH}_j}^{k+1}] \end{cases}, \quad (7)$$

式中: $k$ 表示第 $k$ 次迭代, $\mathbf{b}_x^k$ 、 $\mathbf{b}_y^k$ 和 $\mathbf{b}_{\text{SH}_j}^k$ 都通过 Bregman 迭代方法取得合适的值。

对于上述多元问题,很难用(6)式同时求得每一个问题的解。因此,采取分裂技术<sup>[19-20]</sup>按顺序依次解决问题的策略。去噪过程可表示为

$$\mathbf{i}^{k+1} = \min_i \left[ \mu \cdot \frac{1}{2} \|\mathbf{i} - \mathbf{i}_n\|_2^2 + M \cdot \left( \eta' \cdot \frac{1}{2} \|\mathbf{d}_x^k - \nabla_x \mathbf{i} - \mathbf{b}_x^k\|_2^2 + \eta' \cdot \frac{1}{2} \|\mathbf{d}_y^k - \nabla_y \mathbf{i} - \mathbf{b}_y^k\|_2^2 \right) + \lambda \eta'' \cdot \frac{1}{2} \sum_j \|\mathbf{d}_{\text{SH}_j}^k - \text{SH}_j(\mathbf{i}) - \mathbf{b}_{\text{SH}_j}^k\|_2^2 \right], \quad (8)$$

然后,基于上述去噪结果,利用

$$\begin{cases} \mathbf{d}_x^{k+1} = \min_{\mathbf{d}_x} \left\{ \|\mathbf{d}_x\|_1 + \eta' \cdot \frac{1}{2} \|\mathbf{d}_x - \nabla_x \mathbf{i}^{k+1} - \mathbf{b}_x^k\|_2^2 \right\} \\ \mathbf{d}_y^{k+1} = \min_{\mathbf{d}_y} \left\{ \|\mathbf{d}_y\|_1 + \eta' \cdot \frac{1}{2} \|\mathbf{d}_y - \nabla_y \mathbf{i}^{k+1} - \mathbf{b}_y^k\|_2^2 \right\} \\ \mathbf{d}_{\text{SH}_j}^{k+1} = \min_{\mathbf{d}_{\text{SH}_j}} \left\{ \sum_j \|\mathbf{d}_{\text{SH}_j}\|_1 + \eta'' \cdot \frac{1}{2} \sum_j \|\mathbf{d}_{\text{SH}_j} - \text{SH}_j(\mathbf{i}^{k+1}) - \mathbf{b}_{\text{SH}_j}^k\|_2^2 \right\} \end{cases} \quad (9)$$

对辅助参数进行更新。然后,用(7)式进行迭代补偿,直到得到最好的去噪结果。

通常来说,(8)式有最优条件<sup>[19-20]</sup>,表达式为

$$(\mu E + M \eta' \Delta + \lambda \eta'' E) \mathbf{i}^{k+1} = \mu \mathbf{i}_n + M \eta' [\nabla_x^T (\mathbf{d}_x^k - \mathbf{b}_x^k) + \nabla_y^T (\mathbf{d}_y^k - \mathbf{b}_y^k)] + \lambda \eta'' \text{SH}_j^* (\mathbf{d}_{\text{SH}_j}^k - \mathbf{b}_{\text{SH}_j}^k), \quad (10)$$

式中: $E$ 和 $\Delta$ 分别为恒等算子和拉普拉斯算子; $\nabla_x^T$ 和 $\nabla_y^T$ 分别是 $\nabla_x$ 和 $\nabla_y$ 的转置; $\text{SH}_j^*$ 为 $\text{SH}_j$ 的伴随矩阵。在这种最优条件下,(10)式中的去噪结果可以表示为

$$\mathbf{i}^{k+1} = \mathcal{F}^{-1} \left\{ \frac{\mathcal{F} \{ \mu \mathbf{i}_n + M \eta' [\nabla_x^T (\mathbf{d}_x^k - \mathbf{b}_x^k) + \nabla_y^T (\mathbf{d}_y^k - \mathbf{b}_y^k)] + \lambda \eta'' \text{SH}_j^* (\mathbf{d}_{\text{SH}_j}^k - \mathbf{b}_{\text{SH}_j}^k) \}}{\mathcal{F}(\mu E + M \eta' \Delta + \lambda \eta'' E)} \right\}, \quad (11)$$

式中: $\mathcal{F}$ 和 $\mathcal{F}^{-1}$ 分别为二维傅里叶变换和二维傅里叶逆变换。

(9)式的解可以表示为

$$\begin{cases} \mathbf{d}_x^{k+1} = \text{shrink}(\nabla_x \mathbf{i}^{k+1} + \mathbf{b}_x^k, 1/\eta') \\ \mathbf{d}_y^{k+1} = \text{shrink}(\nabla_y \mathbf{i}^{k+1} + \mathbf{b}_y^k, 1/\eta') \\ \mathbf{d}_{\text{SH}_j}^{k+1} = \text{shrink}[\text{SH}_j(\mathbf{i}^{k+1}) + \mathbf{b}_{\text{SH}_j}^k, 1/\eta''] \end{cases}, \quad (12)$$

式中, $\text{shrink}(x, \sigma) = \text{sgn}(x) \cdot \max(|x| - \sigma, 0)$ 。

### 2.3 算法流程

综上所述,对本算法的主要步骤进行总结,如图1所示。

## 3 实验与讨论

为了对本算法的效果进行评价,从公共数据库<sup>[21]</sup>中选取了三幅OCT图像作为测试样本。这三幅图像包括一幅正常人的视网膜图像,以及两幅处于不同病理状态的人的视网膜图像。同时,为了更好地作定量和定性的分析,本节对ACD算法,Curvelet算法及本算法的原型——TV算法,与本算法的去噪效果进行比较。

本实验是在普通的计算机(3.2 GHz CPU, 4 GB

---

Algorithm: Shearlet-based Improved Total Variation Speckle Denoising Method

---

Step 1: Input the original image  $\mathbf{i}_n$

Step 2: Initialize  $\mathbf{i}^0 = \mathbf{i}_n, \mathbf{d}_x^0 = \mathbf{0}, \mathbf{b}_x^0 = \mathbf{0}, \mathbf{d}_y^0 = \mathbf{0}, \mathbf{b}_y^0 = \mathbf{0}, \mathbf{d}_{\text{SH}_j}^0 = \mathbf{0}, \mathbf{b}_{\text{SH}_j}^0 = \mathbf{0}$ ;

Step 3: Set the values of parameters  $\mu, \lambda, \eta, \eta''$ ;

Step 4: Utilize FCM clustering method to divide the image into three parts:  $M_1, M_2, M_3$ , and then obtain the value of  $M$ ;

Step 5: Compute the noise-free image  $\mathbf{i}_{k+1}$  by calculating equation (11);

Step 6: Determine whether the results meet the requirements, if no, turn to Step 7; if yes, turn to Step 10;

Step 7: Update the variables  $\mathbf{d}_x^{k+1}, \mathbf{d}_y^{k+1}, \mathbf{d}_{\text{SH}_j}^{k+1}$  by calculating equation (12);

Step 8: Update the variables  $\mathbf{b}_x^{k+1}, \mathbf{b}_y^{k+1}, \mathbf{b}_{\text{SH}_j}^{k+1}$  by utilizing the noise-free image  $\mathbf{i}_{k+1}$  and the updated variables  $\mathbf{d}_x^{k+1}, \mathbf{d}_y^{k+1}, \mathbf{d}_{\text{SH}_j}^{k+1}$  with the equation (7);

Step 9: Return to Step 4;

Step 10: Output the denoising result  $\mathbf{i}_{k+1}$ .

---

图1 算法流程图

Fig. 1 Flow chart of algorithm



内存)上进行的,使用 MATLAB R2015a 实现算法。

### 3.1 评价参数

为了更加充分地定性评价散斑去除能力,本文不仅展示了实验测试所得的去噪结果,还同时提供了所对应的图像直方图和局部纹理放大图。此外,在定量评价方面,本文使用了四个评价量化指标:信噪比(SNR),等效视数(ENL),对比度(CNR)以及边缘区域的互相关系数 $\gamma$ 。评价指标的定义方式为

$$R_{SN} = 10 \lg [\max(I^2) / \sigma_n^2], \quad (13)$$

$$L_{EN} = \frac{1}{H} \left( \sum_{h=1}^H \mu_h^2 / \sigma_h^2 \right), \quad (14)$$

$$R_{CN} = \frac{1}{R} \left[ \sum_{r=1}^R (\mu_r - \mu_n) / \sqrt{\sigma_r^2 + \sigma_n^2} \right], \quad (15)$$

$$\gamma = \frac{1}{E} \cdot$$

$$\sum_{e=1}^E \frac{\sum_{i,j \in M_e} (I - \bar{I}) \cdot (I_0 - \bar{I}_0)}{\sqrt{\sum_{i,j \in M_e} (I - \bar{I})^2 \cdot \sum_{i,j \in M_e} (I_0 - \bar{I}_0)^2}}, \quad (16)$$

式中: $\mu_n$ 和 $\sigma_n^2$ 分别为噪声区域的均值和方差; $\mu_h$ 和 $\sigma_h^2$ 分别为第 $h$ 个同质感兴趣区域的均值和方差; $\mu_r$ 和 $\sigma_r^2$ 分别为第 $r$ 个同质与非同质感兴趣区域 $M_e$ 的均值和方差; $I_0$ 为第 $e$ 个边缘感兴趣区域的含噪原图, $I$ 为其对应的去噪图像, $\bar{I}_0$ 和 $\bar{I}$ 分别为 $I_0$ 和 $I$ 在 $3 \times 3$ 邻域内的均值图像。

具体地,在给定的4个评价指标中,SNR用于评估本实验中背景噪声区域的去噪能力,数值越

高代表去噪结果图的质量越好。ENL是衡量同质区域平滑度的指标,值越高说明噪声的抑制效果越好。CNR表示图像中前景目标和背景噪声间的对比度大小,在本实验中用来评价视网膜组织部分跟噪声部分的分离效果,数值越高越好。此外,为了对边缘区域信息的保留能力进行评价,实验引入了指标 $\gamma$ ,其数值越大,代表越多的边缘纹理信息得到了保留。

### 3.2 结果与讨论

本实验选取了三幅人的视网膜OCT图像作为实验图,如图2(a)~(c)所示(512 pixel  $\times$  512 pixel)。三幅图像分别代表了视网膜的三种不同生理和病理状态,其中图2(a)为没有任何视网膜积液和水肿的正常视网膜图像,图2(b)为糖尿病性黄斑水肿(DME)视网膜图像,图2(c)为包含多个玻璃疣(Drusen)的早期黄斑变性视网膜图像。

针对3.1节所述的不同评价方法和指标,在图1中用不同的候选矩形框作标记,以便于对结果进行更充分的定性分析和更准确的定量分析。其中,两个实线框0-1和0-2用于估计噪声的感兴趣区域(ROD)。实线框1-19用于计算CNR的数值,而在这19个矩形框中,标注于边缘区域的1-11则被用来计算 $\gamma$ 的值,剩下的8个实线框12-19被用来计算ENL的值。此外,引入V1~V4四个虚线框,它们选自视网膜图像中有代表性的区域,以便于将感兴趣区域放大,更加清楚地对结果进行定性比较分析。




图2 人的视网膜OCT图像。(a)正常的视网膜图像;(b)DME视网膜图像;(c)Drusen视网膜图像

Fig. 2 OCT B-scan images of human retina. (a) Normal retina image; (b) DME retina image; (c) Drusen retina image

第一组实验中,对于正常的噪声视网膜原图,即图3(a0),用于对比的ACD算法的参数取值为 $T=3$ , $K_{\min}=2$ , $K_{\max}=28$ , $\theta=\pi/30$ , $a=0.25$ , $b=0.75$ ( $T$ 表示扩散时间, $K_{\min}$ 和 $K_{\max}$ 表示用来计算阈值 $K$ 的参数, $\theta$ 表示用来计算扩散系数的方向角, $a$ 和 $b$ 表

示用来计算自适应时间步长的参数),Curvelet算法中的分解尺度个数选择为6,TV算法的参数取值为 $\mu=1$ , $\eta'=0.1$ ,本文提出的算法参数取为 $\mu=1$ , $\lambda=1$ , $\eta'=0.1$ , $\eta''=100$ 。图3(a1)~(a4)分别是4种方法的去噪结果图,同时4个定量评价指标的值也呈

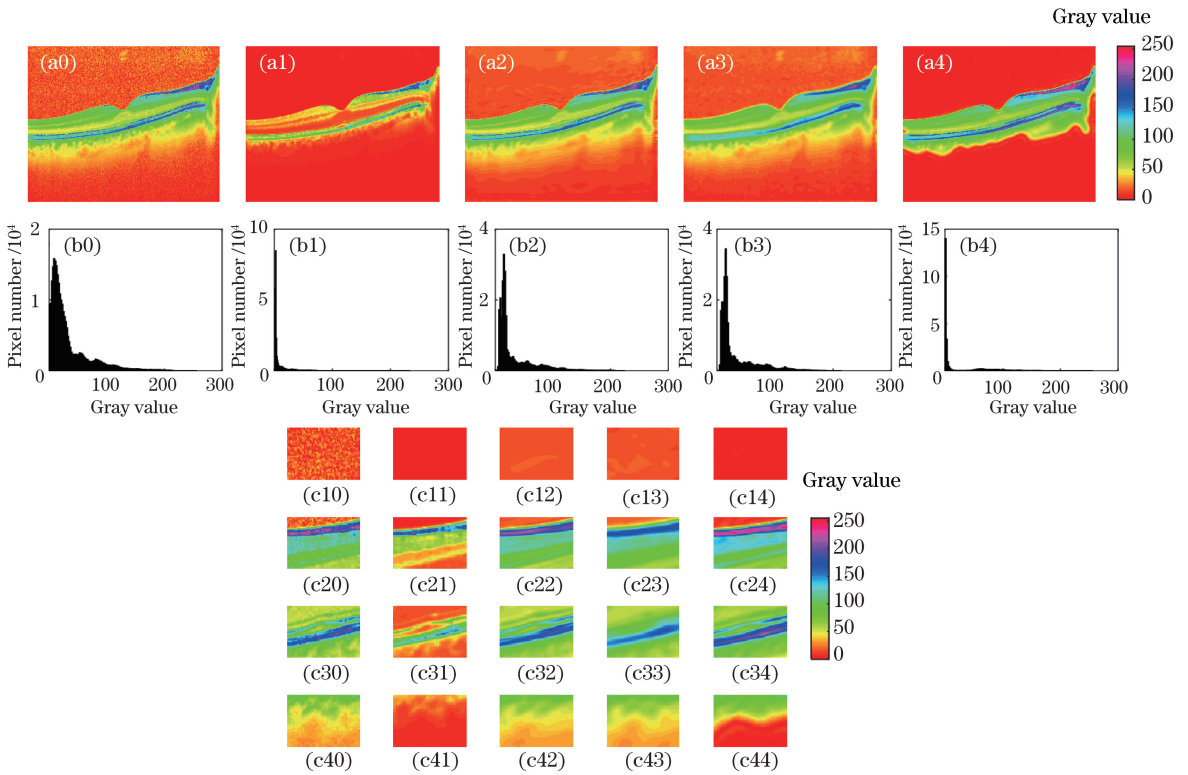


图3 正常视网膜图像的散斑去噪。(a0)~(a4) OCT 含噪原图, ACD, Curvelet, TV、本文方法的去噪结果图; (b0)~(b4)图(a0)~(a4)对应的直方图; (c10)~(c44)图(a0)~(a4)对应的放大感兴趣区域 V1~V4

Fig. 3 Speckle denoising of normal retina image. (a0)~(a4) Original OCT image with noise and images after speckle denoising by ACD, Curvelet, TV, and proposed method; (b0)~(b4) histograms corresponding to images in Figs. 3(a0)~(a4); (c10)~(c44) enlarged ROIs V1~V4 corresponding to images in Figs. 3(a0)~(a4)

现在表 1 中, 每项指标的最佳结果都用加粗的方式进行了标注。同另外三种方法比较, 本文方法得到的 ENL 和 CNR 都是最高的, 分别为 1346.8 和 13.2754, 显示出了在提高图像平滑度和对比度方面优于其他三种方法。从表 1 中可知 SNR 和  $\gamma$  的值分别是 48.9451 和 0.9932, 证明本方法在噪声去除和边缘部分细节的保留这两方面做到了很好的平衡。此外, TV 算法的 ENL 和 CNR 值都仅次于本方法, 但 SNR 的值为 4 种算法最低, 证明其无法兼顾不同区域的去噪效果, 相比之下本方法更好地兼顾了背景部分和组织部分的去噪效果。

为了让结果的比较更加直观明显, 本实验同样给出了图 3(a0)~(a4) 五幅图像所对应的灰度直方图, 如图 3(b0)~(b4)。在 ACD 算法对应的图 3(b1) 中, 直方图整体呈现窄带单峰分布, 峰值较高, 且峰值点对应的横坐标灰度值非常接近 0。这表明 ACD 算法的去噪能力较强, 但从图中也可看到灰度值越高, 像素数目变得越少, 证明 ACD 算法在去噪的同时也带来了过多的细节丢失。Curvelet 算法对应的图 3(b2) 中, 直方图呈现宽带单峰分布, 峰值较低, 峰值点对应

表 1 正常视网膜图像实验的评价指标

Table 1 Metrics of normal retina image experiment

Method	SNR /dB	ENL	CNR	$\gamma$
Original	30.6061	444.4000	4.1625	—
ACD	<b>53.6106</b>	280.1000	5.8835	0.9832
Curvelet	41.9111	1055.8000	8.9445	<b>0.9976</b>
TV	39.9483	1182.3000	11.6104	0.9866
Proposed	48.9451	<b>1346.8000</b>	<b>13.2754</b>	0.9932

的横坐标灰度值在 15~20 之间, 并且相比 ACD 算法, 灰度值为 50 以上的像素点的数目仍相当可观。由此可知 Curvelet 方法更侧重保留细节和纹理特征, 去噪的能力则没有 ACD 算法强。本文的算法对应的直方图集合了其他三幅直方图的特点, 有灰度值接近 0 的高峰值点, 并且在灰度值 30~120 区域内也有一定的像素数目, 故本方法不仅有 ACD 算法的良好去噪能力, 同时也可以像 Curvelet 算法一样尽可能多地保留纹理信息、避免边缘模糊的现象。

为了进一步比较验证四种算法的效果, 实验选取了 V1~V4 四个不同的区域, 连同原图和去噪结果图一起呈现在图 3(c) 中, 从图中可以清晰明显地看到纹理细节。对于选取的背景区域 V1, 可以清楚

地看到本文算法实现了和 ACD 算法同样的去噪效果。对于选取的低密度纹理部分 V2 和高密度纹理部分 V3, 本文算法在保证去噪效果的同时, 和 Curvelet 算法一样都没有带来纹理的丢失, 同样有着较高的对比度。而对于边界组织区域 V4, 本方法不仅和 ACD 算法一样展现了良好的去噪能力, 同时还有着比另外三种方法更强的细节信息保留能力和边缘锐化能力。

综上所述, 对于第一组实验中正常的视网膜图像, 本文提出的算法集合了 ACD 算法和 Curvelet 算法的优点, 可同时在去除噪声和保留纹理信息两个方面取得明显有效的结果, 并且相较于 TV 算法, 针对不同图像区域均实现了良好的去噪效果。

在第二组实验——DME 视网膜图像实验中, 用

于对比的 ACD 算法的参数取值为  $T=3, K_{\min}=2, K_{\max}=28, \theta=\pi/30, a=0.25, b=0.75$ , Curvelet 算法中的分解尺度个数选择为 6, TV 算法的参数取值为  $\mu=1, \eta'=0.12$ , 本文提出的算法参数取为  $\mu=1, \lambda=1, \eta'=0.12, \eta''=100$ 。同第一组实验类似, 给出含噪原图和四种方法的去噪结果图如图 4(a0)~(a4)所示, 对应的灰度直方图和放大的感兴趣区域分别呈现在图 4(b)和(c)中。另外, 表 2 汇总了四种方法对应的评价指标的数值, 每项指标的最优结果同样用加粗的形式标注出来。从表 2 可以看到, 本文算法得到的 SNR, ENL, CNR 的值分别为 46.7891, 649.1049, 8.6647, 均为最大值; 而  $\gamma$  的数值为 0.9927, 大小仅次于 Curvelet 算法。故本文算法可以在有效地滤除噪声的同时, 保留尽可能多的边缘纹理信息。

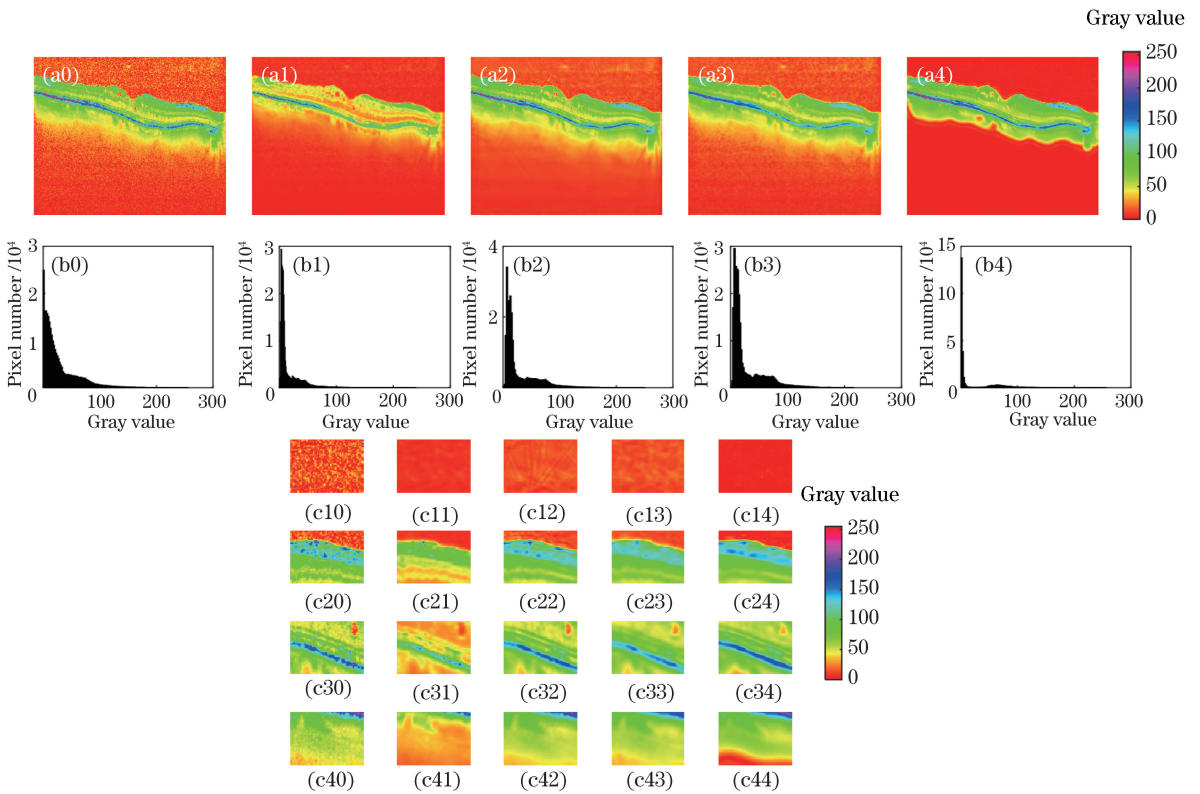


图 4 DME 视网膜图像的散斑去噪。(a0)~(a4) OCT 含噪原图, ACD、Curvelet、TV 本文方法的去噪结果图;

(b0)~(b4)图(a0)~(a4)对应的直方图;(c10)~(c44)图(a0)~(a4)对应的放大感兴趣区域 V1~V4

Fig. 4 Speckle denoising of DME retina image. (a0)~(a4) Original OCT image with noise and images after speckle denoising by ACD, Curvelet, TV, and proposed method; (b0)~(b4) histograms corresponding to images in Figs. 4 (a0)~(a4); (c10)~(c44) enlarged ROIs V1~V4 corresponding to images in Figs. 4(a0)~(a4)

在第三组实验——Drusen 视网膜图像实验中, 用于对比的 ACD 算法的参数取值为  $T=4, K_{\min}=2, K_{\max}=28, \theta=\pi/30, a=0.25, b=0.75$ , Curvelet 算法中的分解尺度个数选择为 6, TV 算法的参数取

值为  $\mu=1, \eta'=0.15$ , 本文提出的算法参数取为  $\mu=1, \lambda=1, \eta'=0.15, \eta''=100$ 。图 5(a0)~(a3)含噪声原图和四种方法的去噪结果图, 图 5(b0)~(b3)为对应的灰度直方图, 图 5(c)为放大的感兴趣区域。



表 2 DME 视网膜图像实验的评价指标

Table 2 Metrics of DME retina image experiment

Method	SNR /dB	ENL	CNR	$\gamma$
Original	29.7433	84.7522	2.9804	—
ACD	44.1283	160.8477	4.3571	0.9924
Curvelet	40.7001	287.3323	5.4275	<b>0.9953</b>
TV	37.9425	550.2359	6.3173	0.9885
Proposed	<b>46.7891</b>	<b>649.1049</b>	<b>8.6647</b>	0.9927

同时,表 3 列出了四项评价指标的具体数值,加粗的项代表该评价指标的最优结果。从表 3 可以看到,本文算法得到的 ENL, CNR,  $\gamma$  的值分别为 940.0124, 9.4148, 0.9934, 均为最大值;而 SNR 的数值为 43.1048, 大小仅次于 ACD 算法。故本文算法可以有效地提高图像的平滑度、对比度,有效地保护边缘部分的细节,并且同时实现良好的去噪效果。

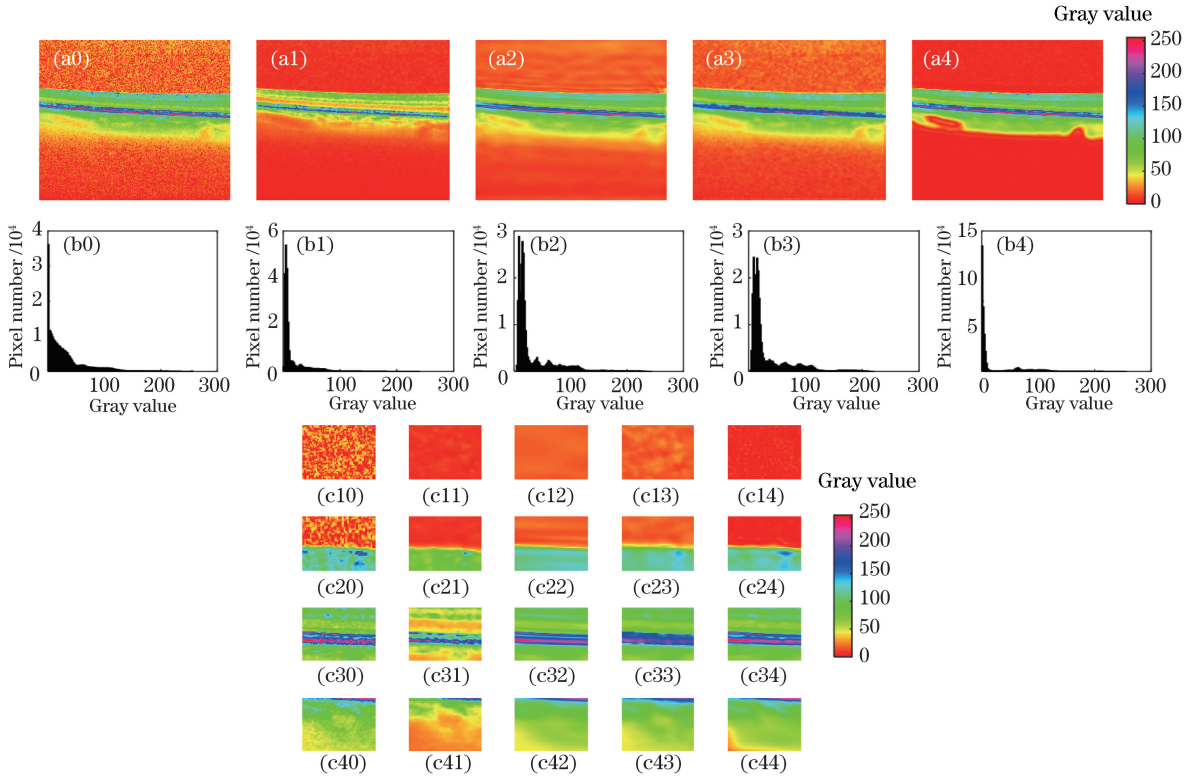


图 5 Drusen 视网膜图像的散斑去噪。(a0)~(a4) OCT 含噪原图,ACD,Curvelet,TV 本文方法的去噪结果图;

(b0)~(b4) 分别为图(a0)~(a4)对应的直方图;(c10)~(c44) 分别为图(a0)~(a4)对应的放大感兴趣区域 V1~V4

Fig. 5 Speckle denoising of Drusen retina image. (a0)–(a4) Original OCT image and images after speckle denoising by

ACD, Curvelet, TV, and proposed method; (b0)–(b4) histograms corresponding to images in Figs. 5(a0)–(a4);

(c10)–(c44) enlarged ROIs V1–V4 corresponding to images in Figs. 5(a0)–(a4)

表 3 Drusen 视网膜图像实验的评价指标

Table 3 Metrics of Drusen retina image experiment

Method	SNR /dB	ENL	CNR	$\gamma$
Original	26.8779	201.5903	3.1580	—
ACD	44.5433	305.3331	5.6349	0.9908
Curvelet	42.5725	881.4277	8.2796	0.9930
TV	38.2609	922.4089	9.2466	0.9906
Proposed	43.1048	940.0124	9.4148	0.9934

法进一步提高了滤除噪声的能力,同时实现了滤除散斑噪声,保护了纹理细节,有效提高了图像的可识别性、平滑程度、对比度和边缘锐利程度,为医学诊断和病理分析的准确率提高提供了更多机会和更多可能性。

### 参 考 文 献

[1] Huang D, Swanson E A, Lin C P, et al. Optical coherence tomography [J]. Science, 1991, 254 (5035): 1178-1181.

[2] Drexler W, Morgner U, Ghanta R K, et al. Ultrahigh-resolution ophthalmic optical coherence tomography[J]. Nature Medicine, 2001, 7(4): 502-

## 4 结 论

本文提出一种基于剪切波变换的改进全变分散斑去噪方法,采用本文方法和其他常见方法对原始图像不同区域进行了针对性去噪,结果表明所提方

507.

- [3] Swanson E A. Optical coherence tomography: principles, instrumentations, and applications[C] // Technical Digest. Summaries of papers presented at the Conference on Lasers and Electro-Optics. Postconference Edition. CLEO' 99. Conference on Lasers and Electro-Optics (IEEE Cat. No. 99CH37013), May 28-28, 1999, Baltimore, MD, USA. New York: IEEE, 1999: 312.
- [4] Chen J B, Zeng Y G, Yuan Z L, et al. Optical coherence tomography based on dynamic speckle[J]. Acta Optica Sinica, 2018, 38(1): 0111001.  
陈俊波, 曾亚光, 袁治灵, 等. 基于动态散斑的光学相干层析成像技术[J]. 光学学报, 2018, 38(1): 0111001.
- [5] Schmitt J M, Xiang S H, Yung K M. Speckle in optical coherence tomography [J]. Journal of Biomedical Optics, 1999, 4(1): 95-105.
- [6] Yu Y J, Acton S T. Speckle reducing anisotropic diffusion [J]. IEEE Transactions on Image Processing, 2002, 11(11): 1260-1270.
- [7] Salinas H M, Fernandez D C. Comparison of PDE-based nonlinear diffusion approaches for image enhancement and denoising in optical coherence tomography [J]. IEEE Transactions on Medical Imaging, 2007, 26(6): 761-771.
- [8] Bernardes R, Maduro C, Serranho P, et al. Improved adaptive complex diffusion despeckling filter[J]. Optics Express, 2010, 18(23): 24048-24059.
- [9] Rudin L I, Osher S, Fatemi E. Nonlinear total variation based noise removal algorithms[J]. Physica D: Nonlinear Phenomena, 1992, 60: 259-268.
- [10] Yuan Z L, Chen J B, Huang W Y, et al. Speckle noise reduction of optical coherence tomography based on robust principle component analysis algorithm[J]. Acta Optica Sinica, 2018, 38(5): 0511002.  
袁治灵, 陈俊波, 黄伟源, 等. 基于稳健性主成分分析算法的光学相干层析成像去除散斑噪声的研究[J]. 光学学报, 2018, 38(5): 0511002.
- [11] Deng J X, Liang Y M. Noise reduction with wavelet transform in optical coherence tomographic images [J]. Acta Optica Sinica, 2009, 29(8): 2138-2141.  
邓菊香, 梁艳梅. 光学相干层析图像的小波去噪方法研究[J]. 光学学报, 2009, 29(8): 2138-2141.
- [12] Adler D C, Ko T H, Fujimoto J G. Speckle reduction in optical coherence tomography images by use of a spatially adaptive wavelet filter[J]. Optics Letters, 2004, 29(24): 2878-2880.
- [13] Jian Z P, Yu Z X, Yu L F, et al. Speckle attenuation in optical coherence tomography by curvelet shrinkage [J]. Optics Letters, 2009, 34(10): 1516-1518.
- [14] Guo Q, Dong F M, Sun S F, et al. Image denoising algorithm based on contourlet transform for optical coherence tomography heart tube image [J]. IET Image Processing, 2013, 7(5): 442-450.
- [15] Easley G, Labate D, Lim W Q. Sparse directional image representations using the discrete shearlet transform[J]. Applied and Computational Harmonic Analysis, 2008, 25(1): 25-46.
- [16] Lim W Q. The discrete shearlet transform: a new directional transform and compactly supported shearlet frames [J]. IEEE Transactions on Image Processing, 2010, 19(5): 1166-1180.
- [17] Chen Y, Li Z L, Nan N, et al. Speckle noise reduction in Fourier domain polarization-sensitive coherence tomography by split-spectrum [J]. Acta Optica Sinica, 2018, 38(8): 0811004.  
陈艳, 李中梁, 南楠, 等. 偏振频域光学相干层析成像中散斑噪声降低方法[J]. 光学学报, 2018, 38(8): 0811004.
- [18] Bezdek J C, Ehrlich R, Full W. FCM: the fuzzy c-means clustering algorithm [J]. Computers & Geosciences, 1984, 10(2/3): 191-203.
- [19] Goldstein T, Osher S. The split Bregman method for L1-regularized problems [J]. SIAM Journal on Imaging Sciences, 2009, 2(2): 323-343.
- [20] Lu B B, Wang L R, Wang Y M, et al. Anisotropic total variation guided filtering and its Split Bregman algorithm [J]. Laser & Optoelectronics Progress, 2017, 54(5): 051005.  
芦碧波, 王乐蓉, 王永茂, 等. 各向异性全变分引导滤波及其 Split Bregman 方法[J]. 激光与光电子学进展, 2017, 54(5): 051005.
- [21] Kermany D S, Goldbaum M, Cai W J, et al. Identifying medical diagnoses and treatable diseases by image-based deep learning [J]. Cell, 2018, 172(5): 1122-1131.