

Total variation regularization with Chambolle Algorithm:

[Rudin92] propôs filtrar imagem minimizando a variação total (total variation). A suposição é que a imagem sem ruído é constante por regiões.

[Chambolle04] propôs um algoritmo (entre muitos) para essa minimização.

Uma descrição didática desse algoritmo para sinais 1-D (com código Matlab) encontra-se em [Selesnick09].

Transparências didáticas sobre compressive sensing em [Tao].

A tese [Ozgen2012] é uma boa tese sobre compressive sensing em tomografia.

=====

Minimização de TV é muito usada em compressive sampling ou compressed sensing.

A gradiente de uma imagem discreta f é [Chambolle04]:

$$\nabla f(x, y) = \left[\frac{\partial f(x, y)}{\partial x}, \frac{\partial f(x, y)}{\partial y} \right]$$

com:

$$\frac{\partial f(x, y)}{\partial x} = \begin{cases} f(x+1, y) - f(x, y) & \text{para } x < N \\ 0 & \text{para } x = N \end{cases}$$

$$\frac{\partial f(x, y)}{\partial y} = \begin{cases} f(x, y+1) - f(x, y) & \text{para } y < N \\ 0 & \text{para } y = N \end{cases}$$

```

IMGCPX grad(IMGDBL a)
{ IMGCPX d( a.nl(), a.nc(), CPX(0.0,0.0) );
  for (int x=0; x<a.nx()-1; x++)
    for (int y=0; y<a.ny()-1; y++)
      d.atN(x,y) = CPX( a.atN(x+1,y)-a.atN(x,y), a.atN(x,y+1)-a.atN(x,y) );
  return d;
}

```

A divergente (divergence) de uma campo vetorial diferenciável p é [Wikipedia]:

$$\text{div } p(x, y) = \frac{\partial p_x(x, y)}{\partial x} + \frac{\partial p_y(x, y)}{\partial y}$$

Se p for campo vetorial discreta [Chambolle04]:

$$\text{div } p(x, y) = \begin{bmatrix} p_x(x, y) - p_x(x-1, y), & \text{se } 1 < x < N \\ p_x(x, y), & \text{se } x = 1 \\ -p_x(x-1, y), & \text{se } x = N \end{bmatrix} + \begin{bmatrix} p_y(x, y) - p_y(x, y-1), & \text{se } 1 < y < N \\ p_y(x, y), & \text{se } y = 1 \\ -p_y(x, y-1), & \text{se } y = N \end{bmatrix}$$

```

IMGDBL div(IMGCPX a)
{ IMGDBL d(a.nx(),a.ny());
  for (int x=0; x<a.nx(); x++)
    for (int y=0; y<a.ny(); y++) {
      double tx;
      if (x==0) tx=real(a.atN(x,y));
      else if (x==a.nx()-1) tx=-real(a.atN(x-1,y));
      else tx=real(a.atN(x,y))-real(a.atN(x-1,y));

      double ty;
      if (y==0) ty=imag(a.atN(x,y));
      else if (y==a.ny()-1) ty=-imag(a.atN(x,y-1));
      else ty=imag(a.atN(x,y))-imag(a.atN(x,y-1));

      d.atN(x,y) = tx+ty;
    }
  return d;
}

```

A variação total (total variation) de uma imagem suave f é definida [Peyre10]:

$$J(f) = \int \|\nabla f(x)\| dx$$

A variação total de uma imagem discreta f é definida [Chambolle04]:

$$J(f) = \sum_{1 \leq x, y \leq N} \|\nabla f(x, y)\|$$

```

double somatoria(IMGDBL a)
{ double d=0.0;
  for (int i=0; i<a.n(); i++) d+=a.atf(i);
  return d;
}

double J(IMGDBL f)
{ IMGDBL m=abs(grad(f));
  return somatoria(m);
}

```

Suponha que uma imagem f_o foi contaminada pelo ruído w gerando a imagem $y=f_o+w$. Queremos atenuar ruído da observação y . O objetivo é achar f que minimize [Peyre10]:

$$\min_f E(f) = \frac{1}{2} \|y - f\|^2 + \lambda J(f)$$

Isto é feito iterativamente com campo vetorial G .

$$G^{(l+1)} = \text{Proj}(G^{(l)} - \tau \nabla(\text{div}(G^{(l)}) - y/\lambda)$$

O valor inicial de G é zero.

Proj (clip) significa saturar os valores em -1 e +1.

```

IMGCPX clip(IMGCPX a)
{ IMGCPX d=a;
  for (int i=0; i<a.n(); i++) {
    double re=real(a(i)); double im=imag(a(i));
    if (re<-1.0) re=-1.0;
    if (re>1.0) re=1.0;
    if (im<-1.0) im=-1.0;
    if (im>1.0) im=1.0;
    d(i)=CPX(re,im);
  }
  return d;
}

```

Na teoria, deve-se ter $\tau \leq 1/8$ para obter a convergência. [Chambolle04] nota que na prática resultado melhor foi obtido com $\tau=1/4$. Nos meus testes, usando $\tau=1/4$ e λ adaptativo (tv3), o algoritmo ou oscila ou diverge. Algoritmo com λ fixo parece funcionar bem com $\tau=1/4$.

A imagem restaurada é $y - \lambda \text{div}(G)$.

```

IMGDBL tv1(IMGDBL y, double lambda, int nit)
{ double tau = 1.0/8.0;
  IMGCPX G(y.nl(),y.nc(),0.0);
  IMGCPX dG;
  for (int i=0; i<nit; i++) {
    dG = grad( div(G) - (1.0/lambda)*y );
    G = clip( G + tau*dG );
  }
  return y - lambda*div(G);
}

```

Se quiser obter as imagens restauradas intermediárias da iteração:

```

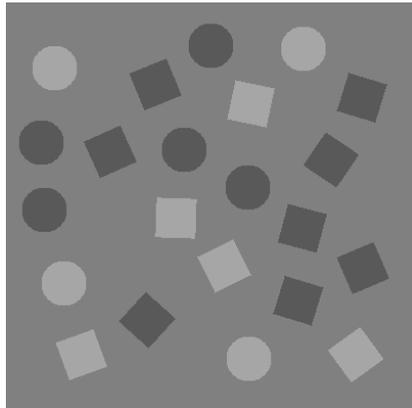
IMGDBL tv2(IMGDBL y, double lambda, int nit)
{ double tau = 1.0/8.0;
  IMGCPX G(y.nl(),y.nc(),0.0);
  IMGCPX dG;
  IMGDBL f;
  for (int i=0; i<nit; i++) {
    f = y - lambda*div(G);
    dG = grad( (-1.0/lambda)*f );
    G = clip( G + tau*dG );
  }
  f = y - lambda*div(G); // pode eliminar
  return f;
}

```

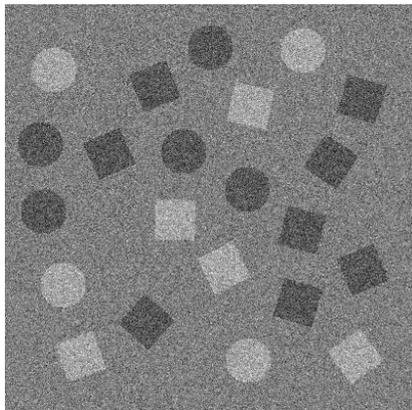
Chamando:

```
IMGDBL y=f0;  
double sigma=0.1;  
for (int l=0; l<f0.nl(); l++)  
    for (int c=0; c<f0.nc(); c++)  
        y(l,c)=f0(l,c)+sigma*mygauss();  
IMGDBL a2=tv2(y, 0.2, 500);
```

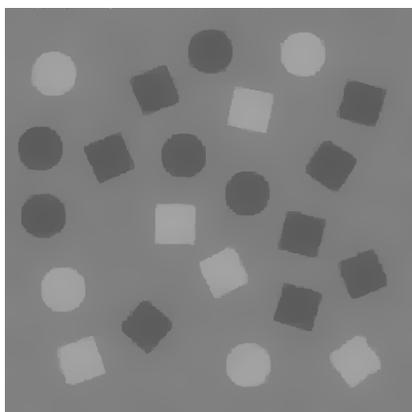
Obtém:



original



ruidosa



restaurada com lambda fixo

É possível calcular automaticamente λ a partir do desvio-padrão σ do ruído w .

$$\lambda^{(l+1)} = \lambda^{(l)} \frac{N\sigma}{\|f - y\|}$$

onde N é o lado da imagem. Se imagem não for quadrada, $N = \sqrt{m}$ onde m é o número de pixels da imagem. O valor inicial de λ pode ser qualquer número positivo.

```
IMGDBL tv3(IMGDBL y, double sigma, int nit)
{ double tau = 1.0/8.0;
  IMGCPX G(y.nl(), y.nc(), 0.0);
  IMGCPX dG;
  IMGDBL f;
  double lambda=0.2;
  for (int i=0; i<nit; i++) {
    f = y - lambda*div(G);
    dG = grad( (-1.0/lambda)*f );
    G = clip( G + tau*dG );
    double d=comprimento(f-y); // Na 1a vez, d=0
    if (d>epsilon) lambda = lambda * sigma * sqrt(double(f.n())) / d;
  }
  f = y - lambda*div(G); // pode eliminar
  return f;
}
```

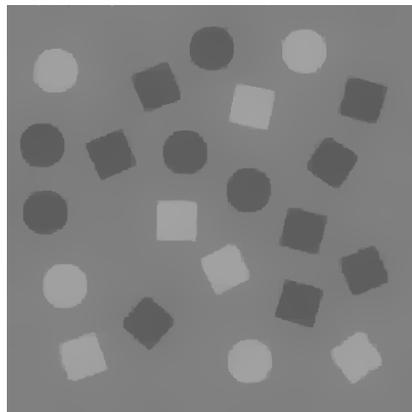


Imagem restaurada com cálculo automático de λ a partir de σ .

Referências bibliográficas:

[Chambolle04] A. Chambolle, "An Algorithm for Total Variation Minimization and Applications," *Journal of Mathematical Imaging and Vision*, vol. 20, 2004, pp. 89-97.

[Peyre10] "Total Variation Regularization with Chambolle Algorithm," http://www.ceremade.dauphine.fr/~peyre/numerical-tour/tours/denoisingadv_3_chambollealgo/#16

[Rudin92] L. Rudin, S. Osher, and E. Fatemi, "Nonlinear total variation based noise removal algorithms," *Physica D: Nonlinear Phenomena*, vol. 60, 1992, pp. 259-268.

[Selesnick09] I. Selesnick, I. Bayram, "Total Variation Filtering," vol. 1, 2009, pp. 1-8.
<http://passthru.cnx.org/plone/content/m31292/1.1/>

[Tao] <http://www.math.hkbu.edu.hk/~ttang/UsefulCollections/compressed-sensing1.pdf>

[Ozgen2012] Özgen, C. (2012). *COMPRESSED SENSING BASED COMPUTERIZED TOMOGRAPHY IMAGING* (Doctoral dissertation, MIDDLE EAST TECHNICAL UNIVERSITY).
<https://etd.lib.metu.edu.tr/upload/12614170/index.pdf>

Atenuação de ruído gaussiano (C:\haepi\filtro\tv\tvart):

Vamos tentar achar o filtro mais adequado para filtrar uma imagem constante por regiões contaminada por ruído gaussiano.

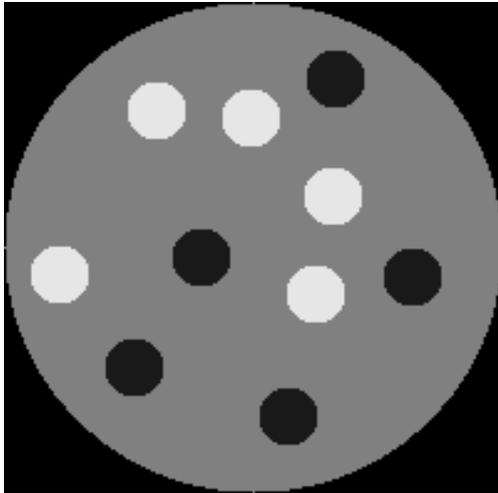
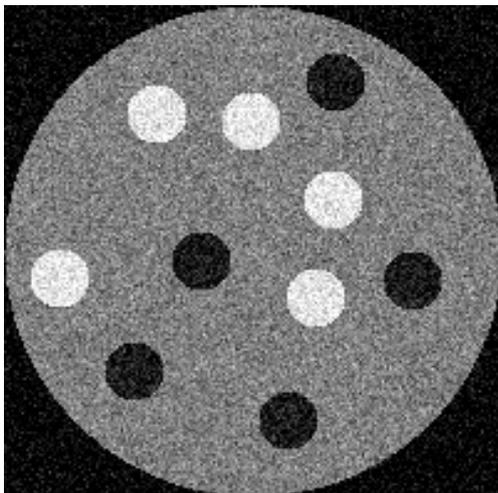


imagem original "fantom.tga"

Vamos colocar ruído gaussiano com desvio-padrão 0.1:

```
img ruidogag fantom.tga ruido10.tga 0.1 7
```

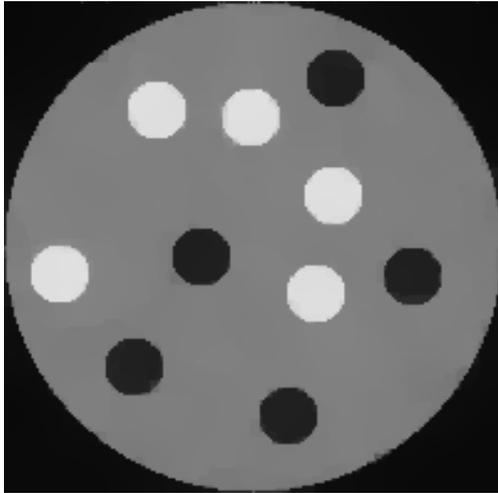


ruido10.tga

MAE (max=100%).....:	6.99%
RMSE (max=100%).....:	9.29%
PSNR considering highest=255.....:	20.6416 dB

1) TV com sigma:

img tv ruido10.tga ruido10tv.tga sigma 200 0.09

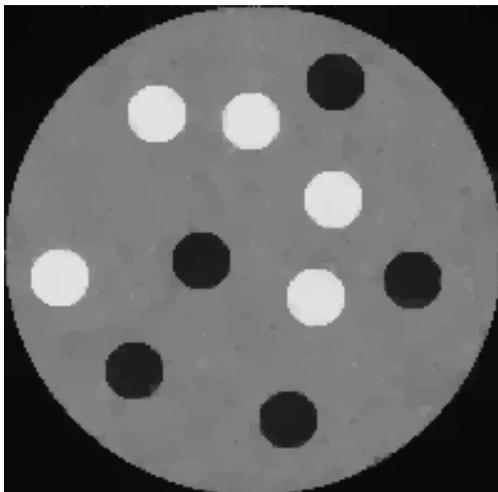


MAE (max=100%).....:	1.99%
RMSE (max=100%).....:	2.97%
PSNR considering highest=255.....:	30.5402 dB

Interessante que o melhor resultado não foi obtido com $\sigma=0.1$, mas com $\sigma=0.09$.

2) TV com lambda:

img tv ruido10.tga ruido10la.tga lambda 200 0.075

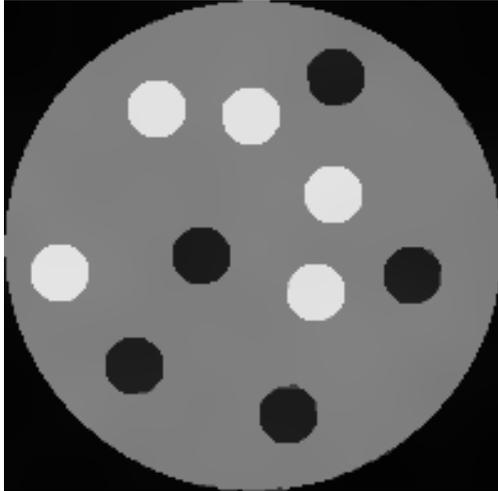


MAE (max=100%).....:	1.93%
RMSE (max=100%).....:	2.84%
PSNR considering highest=255.....:	30.9403 dB

O resultado é quase igual ao TV com sigma. O problema é que tem que chutar lambda sem saber o que representa. A qualidade visual é pior.

3) Difusão anisotrópica intercalado com poucas medianas:

```
img ad ruido10.tga ruido10ad.tga 200 0.055 t 1 3 50  
(AD ent.tga sai.tga maxt sigma [metodo lambda eemediana cdqto])
```

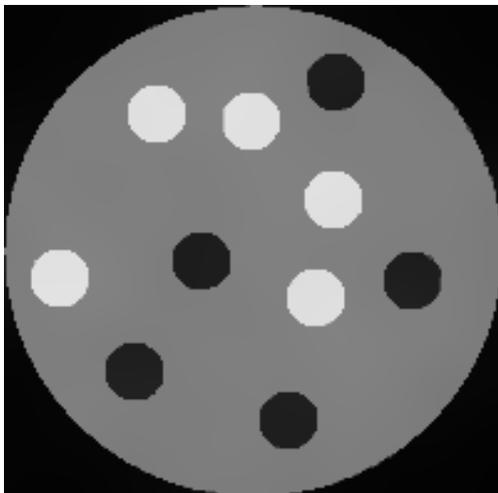


MAE (max=100%).....:	0.96%
RMSE (max=100%).....:	2.24%
PSNR considering highest=255.....:	33.0011 dB

A qualidade é melhor do que TV, tanto medido quando perceptual.

4) Mediana + TV + AD:

```
img tv ruido10.tga ruido10me.tga mla 200 0.045 3 200 0.055  
(TV ent.pgm sai.pgm metodo nit param [tee maxt sigma])
```



MAE (max=100%).....:	1.21%
RMSE (max=100%).....:	2.14%
PSNR considering highest=255.....:	33.3900 dB

Praticamente idêntico ao item (3). Não há vantagem em usar TV

Conclusão: AD é melhor que TV para eliminar ruído gaussiano.

Atenuação de ruído gaussiano + sal-pimenta (C:\haepi\filtro\tv\tvart):

Vamos tentar achar o filtro mais adequado para filtrar uma imagem constante por regiões contaminada por ruído gaussiano + ruído sal e pimenta.

Este tipo de contaminação é comum em diferentes áreas. Por exemplo, na tomografia.

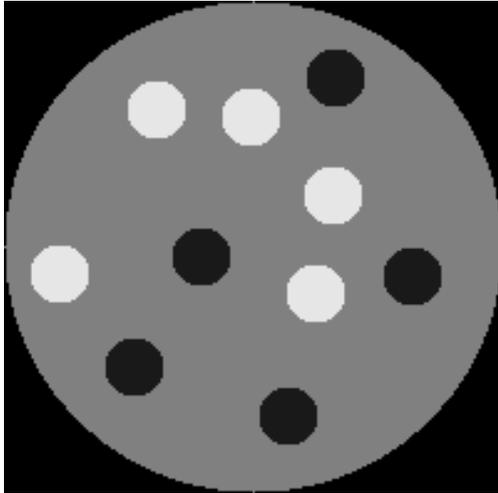
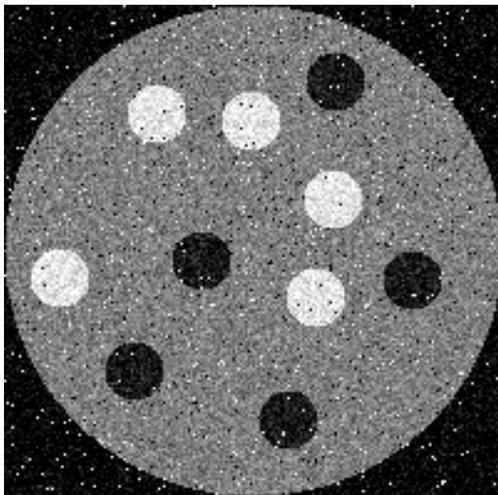


imagem original "fantom.tga"

Vamos colocar ruído gaussiano com desvio-padrão 0.1 e sal-e-pimenta estragando 1 em 40 pixels:

```
img ruidogag fantom.tga ruigs14.tga 0.1 8  
img ruidospg ruigs14.tga ruigs14.tga 40 8
```

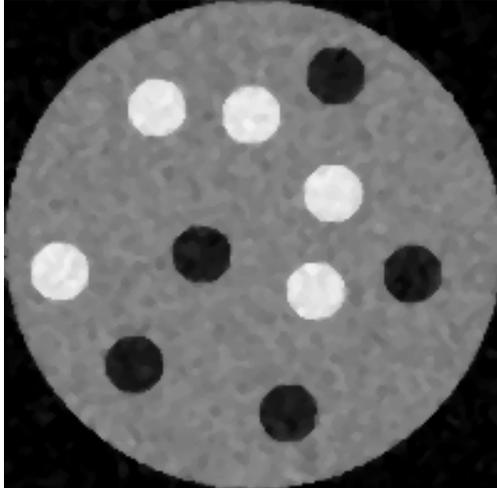


ruigs14.tga

MAE (max=100%)	8.04%
RMSE (max=100%)	12.81%
PSNR considering highest=255	17.8497 dB

1) Usar 4 vezes filtro mediana 3x3:

```
img medianag ruigs14.tga ruigs14mg.tga 3 3
img medianag ruigs14mg.tga ruigs14mg.tga 3 3
img medianag ruigs14mg.tga ruigs14mg.tga 3 3
img medianag ruigs14mg.tga ruigs14mg.tga 3 3
img distg fantom.tga ruigs14mg.tga
```

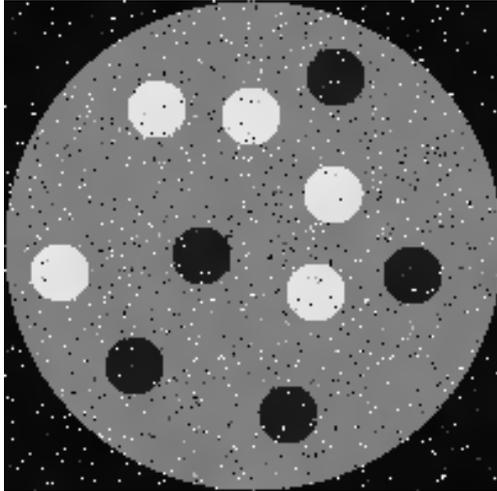


MAE (max=100%).....:	2.24%
RMSE (max=100%).....:	3.71%
PSNR considering highest=255.....:	28.6188 dB

Elimina bem ruído sal-pimenta. Não consegue eliminar ruído gaussiano.

2) Difusão anisotrópica:

```
img ad ruigs14.tga ruigs14a1.tga 50 0.1 t 1 1  
img distg fantom.tga ruigs14a1.tga
```

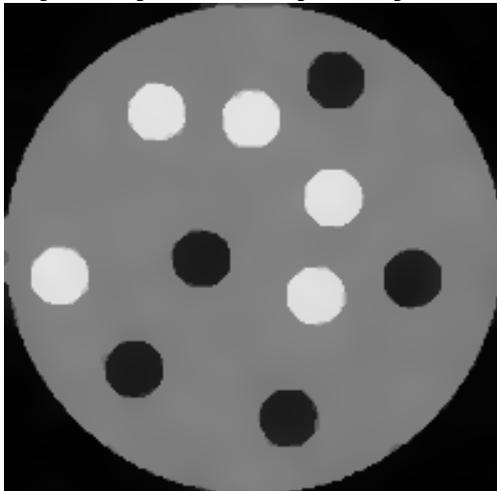


MAE (max=100%).....:	2.73%
RMSE (max=100%).....:	9.55%
PSNR considering highest=255.....:	20.4032 dB

Elimina bem ruído gaussiano. Não elimina ruído sal-pimenta.

3) Difusão anisotrópica intercalado com filtro mediano:

```
img ad ruigs14.tga ruigs14ad.tga 50 0.03 t 1 3  
img distg fantom.tga ruigs14ad.tga
```

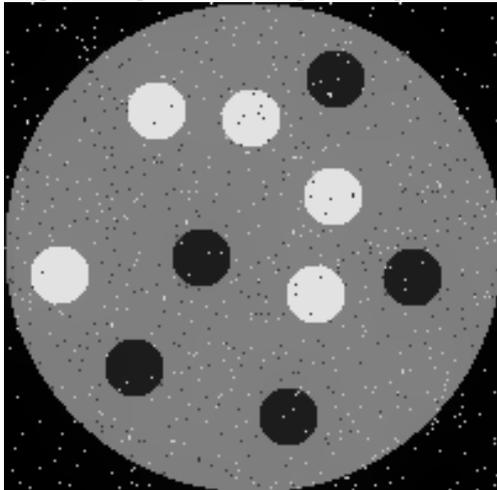


MAE (max=100%).....:	1.28%
RMSE (max=100%).....:	3.19%
PSNR considering highest=255.....:	29.9305 dB

Elimina bem ruído gaussiano e ruído sal-pimenta. PSNR é o mais alto até agora.

4) TV com lambda:

```
img tv ruigs14.tga ruigs14la.tga lambda 200 0.2  
img distg fantom.tga ruigs14la.tga
```

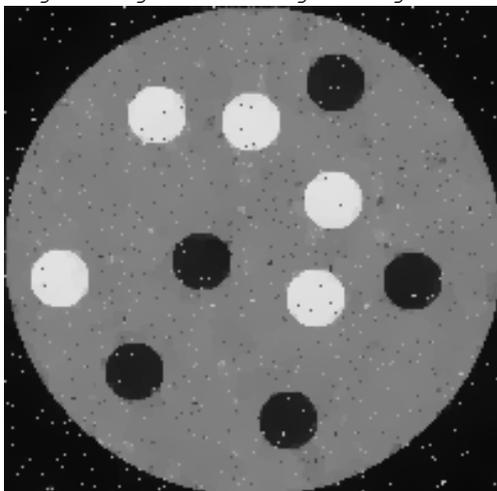


```
MAE (max=100%).....: 2.97%  
RMSE (max=100%).....: 4.61%  
PSNR considering highest=255.....: 26.7291 dB
```

Elimina bem ruído gaussiano. Não consegue eliminar ruído sal-pimenta. O parâmetro lambda tem que ser ajustado sem ter ideia do que representa.

5) TV com sigma:

```
img tv ruigs14.tga ruigs14tv.tga sigma 200 0.1  
img distg fantom.tga ruigs14tv.tga
```

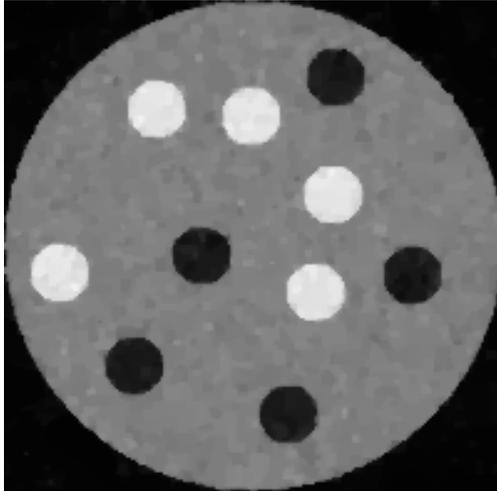


```
MAE (max=100%).....: 2.62%  
RMSE (max=100%).....: 5.60%  
PSNR considering highest=255.....: 25.0395 dB
```

Elimina bem ruído gaussiano. Não consegue eliminar ruído sal-pimenta. O parâmetro sigma é fácil de ajustar, se conhecer o desvio-padrão do ruído.

7) mediana + TV com lambda:

```
img tv ruigs14.tga ruigs14mt.tga mla 200 0.03 3 0 0.0
img distg fantom.tga ruigs14mt.tga
```

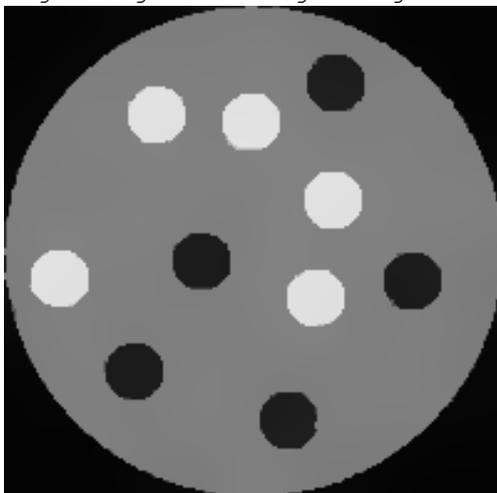


```
MAE (max=100%).....: 1.91%
RMSE (max=100%).....: 3.29%
PSNR considering highest=255.....: 29.6473 dB
```

Executando filtro mediana antes de TV, consegue eliminar ruído sal-pimenta e gaussiana. PSNR ficou bem alto. Mas há variação de nível de cinza de fundo.

8) mediana + TV com lambda + AD

```
img tv ruigs14.tga ruigs14me.tga mla 200 0.03 3 200 0.05
img distg fantom.tga ruigs14me.tga
```



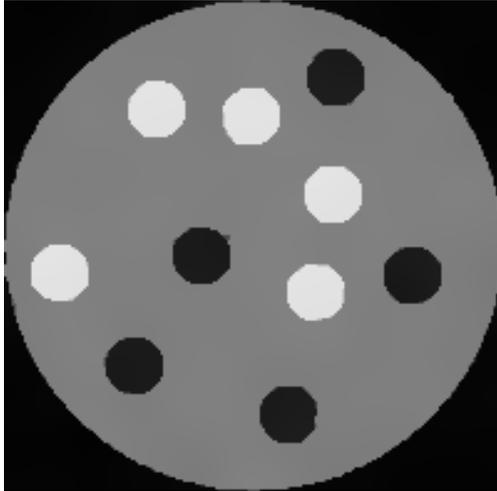
```
MAE (max=100%).....: 1.16%
RMSE (max=100%).....: 2.59%
PSNR considering highest=255.....: 31.7453 dB
```

Executando filtro mediana+TV+AD, consegue eliminar ruído sal-pimenta e gaussiana. Obteve o maior PSNR.

9) Difusão anisotrópica intercalado com poucas medianas

```
img ad ruigs14.tga ruigs14a2.tga  
img distg fantom.tga ruigs14a2.tga
```

```
150 0.05 t 1 3 80
```



```
MAE (max=100%).....: 0.98%  
RMSE (max=100%).....: 2.49%  
PSNR considering highest=255.....: 32.0783 dB
```

Elimina bem ruído gaussiano e ruído sal-pimenta. PSNR é o mais alto até agora. Não apresenta ruídos.

Conclusão: AD intercalado com medianas é a melhor solução. Não valeu a pena usar TV.