

# Processamento de Imagens

## Introdução

Mylène Christine Queiroz de Farias

Departamento de Engenharia Elétrica  
Universidade de Brasília (UnB)  
Brasília, DF 70910-900

[mylene@unb.br](mailto:mylene@unb.br)


29 de Março de 2016

Aula 07: Restauração e Reconstrução




- Modelos e Tipos de Ruídos;
- Técnicas de Restauração
- Degradações Lineares
- Estimação da Função Degradação
- Filtragem Inversa

# Modelo do Processo de degradação e restauração



$$g(x, y) = h(x, y) * f(x, y) + \eta(x, y)$$

# modelo do processo de degradação e restauração



$$G(u, v) = H(u, v) \cdot F(u, v) + N(u, v)$$

- Ruído Gaussiano:

$$p(z) = \frac{1}{\sqrt{2\pi}\sigma} e^{-(z-\mu)^2/2\sigma^2}$$

- Ruído Rayleigh:

$$p(z) = \begin{cases} \frac{2}{b}(z-1)e^{-(z-a)^2/b}, & \text{para } z \geq a \\ 0, & \text{caso contrário} \end{cases} \quad (1)$$

- Ruído Erlang:

$$p(z) = \begin{cases} \frac{a^b z^{b-1}}{(b-1)!} e^{-az}, & \text{para } z \geq 0 \\ 0, & \text{caso contrário} \end{cases} \quad (2)$$

- Ruído Exponencial:

$$p(z) = \begin{cases} ae^{-az}, & \text{para } z \geq 0 \\ 0, & \text{caso contrário} \end{cases} \quad (3)$$







- Ruído Uniforme:

$$p(z) = \begin{cases} \frac{1}{(b-a)}, & \text{para } b \leq z \leq a \\ 0, & \text{caso contrário} \end{cases} \quad (4)$$

- Ruído Impulsivo:

$$p(z) = \begin{cases} P_a, & \text{para } z = a \\ P_b, & \text{para } z = b \\ 0, & \text{caso contrário} \end{cases} \quad (5)$$

# FDPs dos Principais Tipos de Ruído




a	b	c
d	e	f

**FIGURE 5.2** Some important probability density functions.


# Exemplos



# Exemplos



# Exemplos



Exponential

Uniform

Salt & Pepper

## Maneiras de Extrair Ruído


- espectro
- domínio espacial
- analisando o padrão de ruído (fonte conhecida)
- analisando sub-regiões da imagem




a  
b

**FIGURE 5.5**  
(a) Image  
corrupted by  
sinusoidal noise.  
(b) Spectrum  
(each pair of  
conjugate  
impulses  
corresponds to  
one sine wave).  
(Original image  
courtesy of  
NASA.)

---



# Análise de Regiões



a b c

**FIGURE 5.6** Histograms computed using small strips (shown as inserts) from (a) the Gaussian, (b) the Rayleigh, and (c) the uniform noisy images in Fig. 5.4.

## Filtragem

- domínio da frequência
- domínio espacial

$$g(x, y) = f(x, y) + \eta(x, y)$$

$$G(u, v) = F(u, v) + N(u, v)$$

- Ruído Aditivo – Filtragem espacial;
- Filtros espaciais semelhantes ao do capítulo anterior.

- Média Aritmética:

$$\hat{f}(x, y) = \frac{1}{mn} \sum_{(s,t) \in S_{x,y}} g(s, t)$$

- Mediana:

$$\hat{f}(x, y) = \text{Mediana}_{(s,t) \in S_{x,y}} \{g(s, t)\}$$

- Média Geométrica:

$$\hat{f}(x, y) = \left[ \prod_{(s,t) \in S_{x,y}} g(s, t) \right]^{mn}$$

- Média Harmônica:

$$\hat{f}(x, y) = \frac{mn}{\sum_{(s,t) \in S_{x,y}} \frac{1}{g(s,t)}}$$

- Média Contra-Harmônica:

$$\hat{f}(x, y) = \frac{\sum_{(s,t) \in S_{x,y}} g(s,t)^{Q+1}}{\sum_{(s,t) \in S_{x,y}} g(s,t)^Q}$$

- Máximo e Mínimo:

$$\hat{f}(x, y) = \max_{(s,t) \in S_{x,y}} \{g(s, t)\}$$

$$\hat{f}(x, y) = \min_{(s,t) \in S_{x,y}} \{g(s, t)\}$$

- Ponto Médio:

$$\hat{f}(x, y) = \frac{1}{2} [\max_{(s,t) \in S_{x,y}} \{g(s, t)\} + \min_{(s,t) \in S_{x,y}} \{g(s, t)\}]$$

- Média Alfa-Podada:

$$\hat{f}(x, y) = \frac{1}{mn-d} \sum_{(s,t) \in S_{x,y}} g(s, t)$$

Apaga-se os  $d/2$  menores e os  $d/2$  maiores valores na vizinhana  $S_{x,y}$ .


a b  
c d

**FIGURE 5.7**

- (a) X-ray image.  
(b) Image corrupted by additive Gaussian noise. (c) Result of filtering with an arithmetic mean filter of size  $3 \times 3$ . (d) Result of filtering with a geometric mean filter of the same size.


(Original image courtesy of Mr. Joseph E. Pascente, Lixi, Inc.)

O filtro média geométrica causou menos borrado.




original

Ruído Gaussiano



Média  $3 \times 3$







Média Geométrica  $3 \times 3$


a  
b  
c  
d

**FIGURE 5.8**


- (a) Image corrupted by pepper noise with a probability of 0.1. (b) Image corrupted by salt noise with the same probability. (c) Result of filtering (a) with a  $3 \times 3$  contra-harmonic filter of order 1.5. (d) Result of filtering (b) with  $Q = -1.5$ .



$Q > 0$ , afinamento  
e borramento  
das áreas escuras




$Q < 0$ , afinamento  
e borramento  
das áreas claras



Contra-harmônico,  $Q = 1.5$

Contra-harmônico,  $Q = -1.5$


# Contra-Harmônicos com Valores Trocados




a  
b  
c  
d

**FIGURE 5.10**


- (a) Image corrupted by salt-and-pepper noise with probabilities  $P_a = P_b = 0.1$ .  
(b) Result of one pass with a median filter of size  $3 \times 3$ .  
(c) Result of processing (b) with this filter.  
(d) Result of processing (c) with the same filter.




## Filtrando com max e min




Max filter 3x3



Min filter 3x3





Detalhes em preto diminuíram.





Detalhes em branco diminuíram.

Ruído uniforme





Ruído uniforme +  
pimenta-e-sal

Filtro média



Filtro média geométrica

Filtro mediana



Filtro alpha-podado  
 $d=5$

- Mudam a cada região adaptando-se de acordo com a estatística da imagem
- Maior custo computacional
  - Média nível médio de intensidade
  - Variância contraste médio
- Região Sxy:
  - Valor  $g(x,y)$ , variância, média, ruído

$$g(x, y) = f(x, y) + \eta(x, y)$$

- Se  $\sigma_\eta^2 = 0$ , o filtro deve retornar  $g(x, y)$
- Se a variância local  $\sigma_L^2$  é maior que  $\sigma_\eta^2$ , o filtro deve retornar  $g(x, y)$  (bordas)
- Se as variâncias forem semelhantes, um filtro de média aritmética deve ser aplicado:

$$\hat{f}(x, y) = g(x, y) - \frac{\sigma_\eta^2}{\sigma_L^2} [g(x, y) - m_L], \quad \sigma_\eta^2 \ll \sigma_L^2$$

# Filtro Adaptativo (Mediana)

$z_{min}$  = mínimo valor de cinza em  $S_{x,y}$

$z_{max}$  = máximo valor de cinza em  $S_{x,y}$

$z_{med}$  = valor mediano de cinza em  $S_{x,y}$

$z_{xy}$  = valor de cinza nas coordenadas  $(x, y)$

$S_{max}$  = máximo tamanho para  $S_{x,y}$

Nível A:

$$A_1 = z_{med} - z_{min}$$

$$A_2 = z_{med} - z_{max}$$

IF  $A_1 > 0$  e  $A_2 < 0$ , vá para o nível B

ELSE aumente o tam. janela

IF tam. janela  $\leq S_{max}$  repita Nível A

ELSE saída =  $z_{xy}$

Nível B:

$$B_1 = z_{xy} - z_{min}$$

$$B_2 = z_{xy} - z_{max}$$


IF  $B_1 > 0$  e  $B_2 < 0$ , saída =  $z_{xy}$


ELSE saída =  $z_{med}$

a b  
c d

**FIGURE 5.13**

- (a) Image corrupted by additive Gaussian noise of zero mean and variance 1000.  
(b) Result of arithmetic mean filtering.  
(c) Result of geometric mean filtering.  
(d) Result of adaptive noise reduction filtering. All filters were of size  $7 \times 7$ .





a b c

**FIGURE 5.14** (a) Image corrupted by salt-and-pepper noise with probabilities  $P_a = P_b = 0.25$ . (b) Result of filtering with a  $7 \times 7$  median filter. (c) Result of adaptive median filtering with  $S_{\max} = 7$ .

# Filtrando com Filtro Notch Ótimo

$$g(x, y) = f(x, y) + \eta(x, y)$$

$$N(u, v) = H_{NP}(u, v) \cdot G(u, v)$$

# Filtrando com Filtro Notch Ótimo

$$g(x, y) = f(x, y) + \eta(x, y)$$

$$N(u, v) = H_{NP}(u, v) \cdot G(u, v)$$

$$\eta(x, y) = TF^{-1}(H_{NP}(u, v) \cdot G(u, v))$$

# Filtrando com Filtro Notch Ótimo

$$g(x, y) = f(x, y) + \eta(x, y)$$

$$N(u, v) = H_{NP}(u, v) \cdot G(u, v)$$

$$\eta(x, y) = TF^{-1} (H_{NP}(u, v) \cdot G(u, v))$$

$$\hat{f}(x, y) = f(x, y) - w(x, y)\eta(x, y)$$

Escolher  $w(x, y)$  de forma a minimizar a variância da estimativa.

# Filtrando com Filtro Notch Ótimo

$$g(x, y) = f(x, y) + \eta(x, y)$$

$$N(u, v) = H_{NP}(u, v) \cdot G(u, v)$$

$$\eta(x, y) = TF^{-1} (H_{NP}(u, v) \cdot G(u, v))$$

$$\hat{f}(x, y) = f(x, y) - w(x, y)\eta(x, y)$$

Escolher  $w(x, y)$  de forma a minimizar a variância da estimativa.

$$\sigma^2(x, y) = \frac{1}{(2a+1)(2b+1)} \sum_{s=-a}^a \sum_{t=-b}^b [\hat{f}(x+s, y+t) - \bar{f}(x, y)]^2$$

$$\bar{f}(x, y) = \frac{1}{(2a+1)(2b+1)} \sum_{s=-a}^a \sum_{t=-b}^b \hat{f}(x+s, y+t)$$

$$w(x+s, y+t) = w(x, y)$$

$$\overline{w(x+s, y+t)\eta(x, y)} = w(x+s, y+t)\overline{\eta(x, y)}$$

# Filtrando com Filtro Notch Ótimo

Para minimizar  $\sigma^2(x, y)$ , resolvemos:

$$\frac{\partial \sigma^2(x, y)}{\partial w(x, y)} = 0$$

O resultado é:


$$w(x, y) = \frac{\overline{g(x, y) \cdot \eta(x, y)} - \overline{g(x, y)} \cdot \overline{\eta(x, y)}}{\overline{\eta^2(x, y)} - \overline{\eta(x, y)}^2}$$

Logo, basta utilizar o resultado acima para obter  $\hat{f}(x, y)$ :


$$\hat{f}(x, y) = f(x, y) - w(x, y)\eta(x, y)$$



original




Espectro deslocado




Espectro sem deslocamento

$$a=b=15$$



Espectro do Ruído



Ruído no domínio  
espacial



Processada

$$g(x, y) = H[f(x, y)] + \eta(x, y)$$

$$\boxed{\text{Se } \eta(x, y) = 0 \implies g(x, y) = H[f(x, y)]}$$

Como o sistema é linear

$$\boxed{H[a \cdot f_1(x, y) + b \cdot f_2(x, y)] = a \cdot H[f_1(x, y)] + b \cdot H[f_2(x, y)]}$$

Como o sistema é invariante no tempo

$$\boxed{H[f(x - \alpha, y - \beta)] = g(x - \alpha, y - \beta)}$$

# Degradações Lineares e Invariantes no Tempo

$$g(x, y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(\alpha, \beta) h(x - \alpha, y - \beta) d\alpha d\beta + \eta(x, y)$$

Se  $\eta(x, y) = 0$

$$g(x, y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(\alpha, \beta) h(x - \alpha, y - \beta) d\alpha d\beta$$

$$G(u, v) = H(u, v)F(u, v) + N(u, v)$$

$$g(x, y) = h(x, y)h(x, y) + \eta(x, y)$$

# Estimação da Degradação

- Observação:

$$H_s(u, v) = \frac{G_s(u, v)}{\hat{F}(u, v)}$$

- Experimentação:

$$H_s(u, v) = \frac{G(u, v)}{A}$$

- Modelagem Matemática:

$$H(u, v) = e^{-k(u^2+v^2)^{5/6}}$$


modelo de degradação proposto por Hufnagel e Stanley (1964), baseado em turbulência atmosférica.

# Experimentação

a b

**FIGURE 5.24**

Degradation estimation by impulse characterization.  
(a) An impulse of light (shown magnified).  
(b) Imaged (degraded) impulse.



# Modelos Matemáticos

## Modelo de turbulência atmosférica

$$H(u, v) = e^{-k(u^2 + v^2)^{5/6}}$$



$k=0,0025$

$k=0,001$



$k=0,00025$

# Modelo de Borrado (Movimento)

$$g(x, y) = \int_0^T f(x - x_0(t), y - y_o(t)) dt$$

## Modelo de Borrado (Movimento)

$$g(x, y) = \int_0^T f(x - x_0(t), y - y_o(t)) dt$$

$$\begin{aligned} G(u, v) &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} g(x, y) e^{-j2\pi(ux+uy)} dx dy \\ &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \left[ \int_0^T f[x - x_0(t), y - y_o(t)] dt \right] e^{-j2\pi(ux+uy)} dx dy \end{aligned}$$

## Modelo de Borrado (Movimento)

$$g(x, y) = \int_0^T f(x - x_0(t), y - y_o(t)) dt$$

$$\begin{aligned} G(u, v) &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} g(x, y) e^{-j2\pi(ux+uy)} dx dy \\ &= \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \left[ \int_0^T f[x - x_0(t), y - y_o(t)] dt \right] e^{-j2\pi(ux+uy)} dx dy \end{aligned}$$

$$\begin{aligned} G(u, v) &= \int_0^T \left[ \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f[x - x_0(t), y - y_o(t)] e^{-j2\pi(ux+uy)} dx dy \right] dt \\ G(u, v) &= \int_0^T F(u, v) e^{-j2\pi[ux_o(t)+uy_o(t)]} dt \\ &= F(u, v) \int_0^T e^{-j2\pi[ux_o(t)+uy_o(t)]} dt \end{aligned}$$

# Modelo de Borrado (Movimento)

$$G(u, v) = \int_0^T \left[ \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f[x - x_o(t), y - y_o(t)] e^{-j2\pi(ux+uy)} dx dy \right] dt$$
$$G(u, v) = \int_0^T F(u, v) e^{-j2\pi[ux_o(t)+uy_o(t)]} dt$$
$$= F(u, v) \int_0^T e^{-j2\pi[ux_o(t)+uy_o(t)]} dt$$

# Modelo de Borrado (Movimento)

$$G(u, v) = \int_0^T \left[ \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f[x - x_o(t), y - y_o(t)] e^{-j2\pi(ux+uy)} dx dy \right] dt$$
$$G(u, v) = \int_0^T F(u, v) e^{-j2\pi[ux_o(t)+uy_o(t)]} dt$$
$$= F(u, v) \int_0^T e^{-j2\pi[ux_o(t)+uy_o(t)]} dt$$

$$H(u, v) = \int_0^T e^{-j2\pi[ux_o(t)+uy_o(t)]} dt$$

# Modelo de Borrado (Movimento)

$$G(u, v) = \int_0^T \left[ \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f[x - x_o(t), y - y_o(t)] e^{-j2\pi(ux+uy)} dx dy \right] dt$$

$$\begin{aligned} G(u, v) &= \int_0^T F(u, v) e^{-j2\pi[ux_o(t)+uy_o(t)]} dt \\ &= F(u, v) \int_0^T e^{-j2\pi[ux_o(t)+uy_o(t)]} dt \end{aligned}$$

$$H(u, v) = \int_0^T e^{-j2\pi[ux_o(t)+uy_o(t)]} dt$$

$$G(u, v) = H(u, v)F(u, v)$$

# Exemplo

$$H(u, v) = \int_0^T e^{-j2\pi[u x_o(t) + u y_o(t)]} dt$$

# Exemplo

$$H(u, v) = \int_0^T e^{-j2\pi[u x_o(t) + u y_o(t)]} dt$$

- Movimento na direção  $x$ :  $x_0(t) = \frac{a \cdot t}{T}$

# Exemplo

$$H(u, v) = \int_0^T e^{-j2\pi[u x_o(t) + u y_o(t)]} dt$$

- Movimento na direção  $x$ :  $x_o(t) = \frac{a \cdot t}{T}$

$$\begin{aligned} H(u, v) &= \int_0^T e^{-j2\pi u x_o(t)} dt \\ &= \int_0^T e^{\frac{-j2\pi u \cdot at}{T}} dt \\ &= \frac{T}{\pi u a} \sin(\pi u a) e^{-j\pi u a} \end{aligned}$$

# Exemplo

$$H(u, v) = \int_0^T e^{-j2\pi[ux_o(t) + uy_0(t)]} dt$$


- Movimento na direção  $x$ :  $x_0(t) = \frac{a \cdot t}{T}$

$$\begin{aligned} H(u, v) &= \int_0^T e^{-j2\pi u x_o(t)} dt \\ &= \int_0^T e^{\frac{-j2\pi u \cdot at}{T}} dt \\ &= \frac{T}{\pi ua} \sin(\pi ua) e^{-j\pi ua} \end{aligned}$$

Ou, mais genericamente: (borrado em ambas as direções)

$$H(u, v) = \frac{T}{\pi(ua+vb)} \sin(\pi(ua + vb)) e^{-j\pi(ua+vb)}$$

# Digital Image Processing



$$H(u, v) = \frac{T}{\pi(ua + vb)} \sin[\pi(ua + vb)] e^{-j\pi(ua + vb)}$$

Borrando a imagem  
com  $a=b=0,1$   
 $T=1$

- Se conhecemos a degradação, podemos restaurar a imagem diretamente?

- Se conhecemos a degradação, podemos restaurar a imagem diretamente?

$$\hat{F}(u, v) = \frac{G(u, v)}{H(u, v)}$$

$$G(u, v) = H(u, v)F(u, v) + N(u, v)$$

$$\hat{F}(u, v) = F(u, v) + \frac{N(u, v)}{H(u, v)}$$

- Se conhecemos a degradação, podemos restaurar a imagem diretamente?

$$\hat{F}(u, v) = \frac{G(u, v)}{H(u, v)}$$

$$G(u, v) = H(u, v)F(u, v) + N(u, v)$$

$$\hat{F}(u, v) = F(u, v) + \frac{N(u, v)}{H(u, v)}$$

- Mesmo se conhecermos a degradação, não recuperaremos o sinal original completamente ...
- E se  $H(u, v)$  tiver valor nulos?

- Se conhecemos a degradação, podemos restaurar a imagem diretamente?

$$\hat{F}(u, v) = \frac{G(u, v)}{H(u, v)}$$

$$G(u, v) = H(u, v)F(u, v) + N(u, v)$$

$$\hat{F}(u, v) = F(u, v) + \frac{N(u, v)}{H(u, v)}$$

- Mesmo se conhecermos a degradação, não recuperaremos o sinal original completamente ...
- E se  $H(u, v)$  tiver valor nulos?
- Opção: Limitar os valores do filtro em torno de  $(0,0)$ .



Filtragem inversa



Filtragem inversa  
Raio limitado a 40



Filtragem inversa  
Raio limitado a 70



Filtragem inversa  
Raio limitado a 85

$$e^2 = E \left[ (f - \hat{f})^2 \right] \quad (6)$$

$$\begin{aligned} \hat{F}(u, v) &= \left[ \frac{H^*(u, v)S_f(u, v)}{S_f(u, v)|H(u, v)|^2 + S_\eta(u, v)} \right] G(u, v) \\ &= \left[ \frac{H^*(u, v)}{|H(u, v)|^2 + S_\eta(u, v)/S_f(u, v)} \right] G(u, v) \\ &= \left[ \frac{1}{H(u, v)} \frac{|H(u, v)|^2}{|H(u, v)|^2 + S_\eta(u, v)/S_f(u, v)} \right] G(u, v) \end{aligned}$$

$H(u, v)$  = degradation function

$H^*(u, v)$  = complex conjugate of  $H(u, v)$

$|H(u, v)|^2 = H^*(u, v)H(u, v)$

$S_\eta(u, v) = |N(u, v)|^2$  = power spectrum of the noise [see Eq. (4.2-20)]

$S_f(u, v) = |F(u, v)|^2$  = power spectrum of the undegraded image.

$$\hat{F}(u, v) = \left[ \frac{1}{H(u, v)} \frac{|H(u, v)|^2}{|H(u, v)|^2 + K} \right] G(u, v)$$



a b c

**FIGURE 5.28** Comparison of inverse and Wiener filtering. (a) Result of full inverse filtering of Fig. 5.25(b). (b) Radially limited inverse filter result. (c) Wiener filter result.


# Filtro de Wiener

Borrado de movimento  
+ ruído Gaussiano  
Média = 0, var = 650

corrompida



Filtragem inversa



Wiener



var é diminuída de 1  
ordem de magnitude



var é diminuída de 5  
ordens de magnitude

