

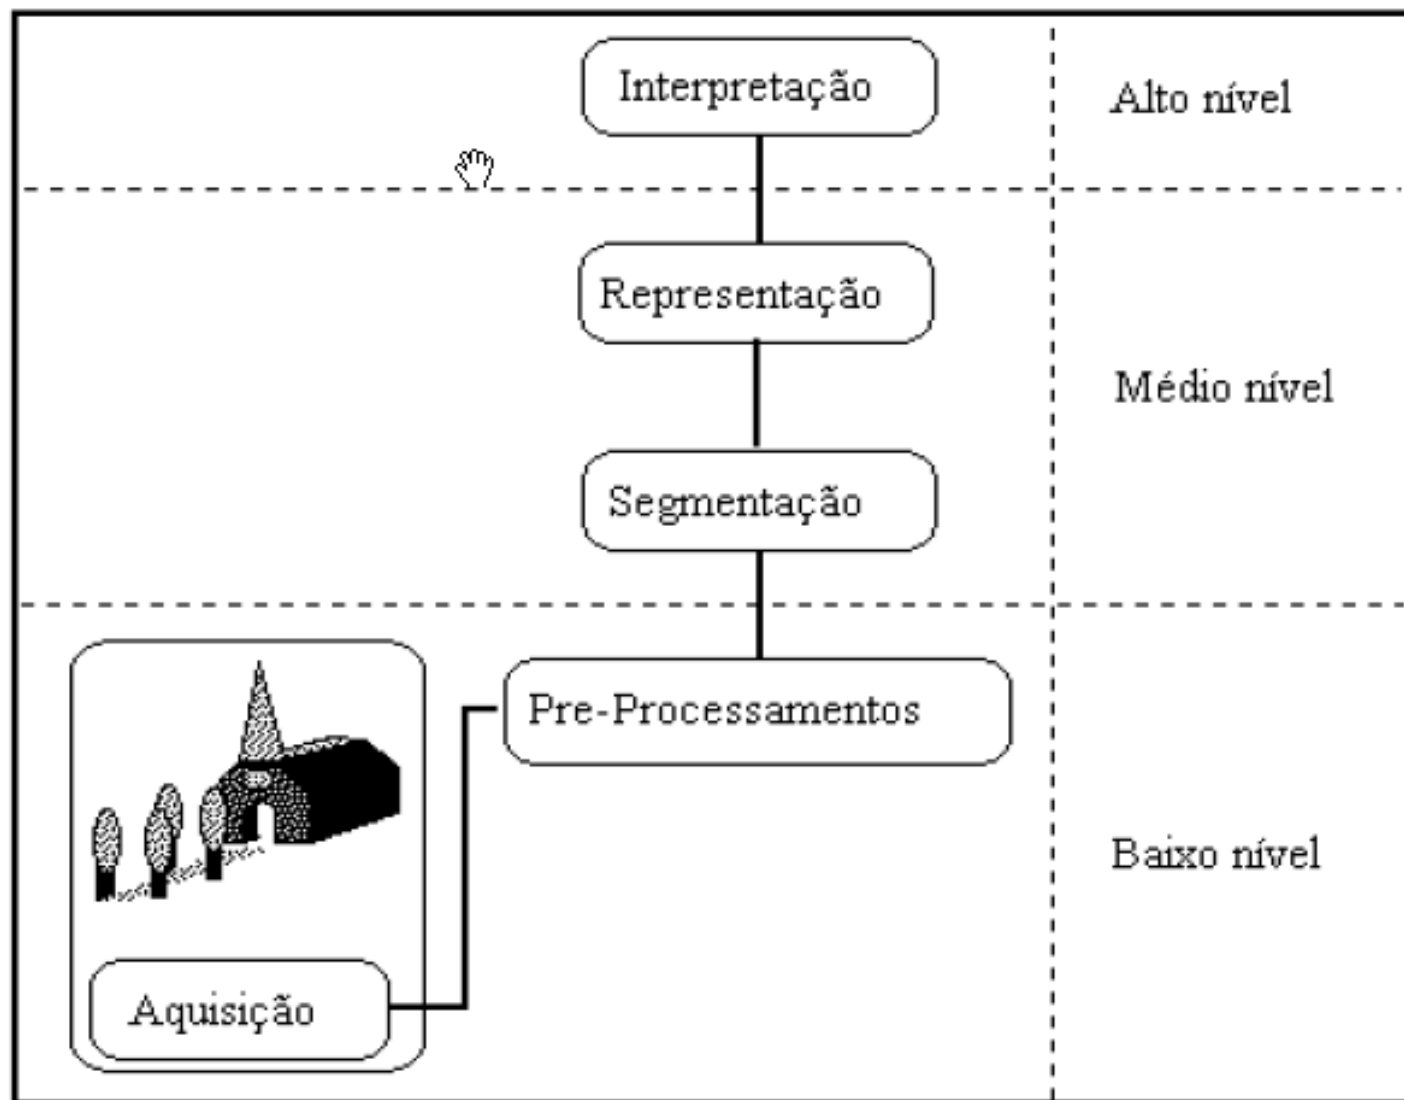
# Processamento de Imagens

SCC0251

Pré-processamento

Material baseado nos livros do Sonka e do Gonzalez

<http://www.icaen.uiowa.edu/~dip/LECTURE/lecture.html>



# Propriedades de uma Imagem digital

- Vizinhança
- Conectividade
- Medição de Distância
- Operações Lógicas e Aritméticas

# Vizinhança

- $N_4(p)$  : pixel  $p$   $(x,y)$  com 4 vizinhos
  - $(x+1,y)$ ,  $(x-1,y)$ ,  $(x,y+1)$  e  $(x,y-1)$
  - 4-vizinhança
- $N_8(p)$  : pixel  $p$   $(x,y)$  com 8 vizinhos
  - Os acima +
  - $(x+1,y+1)$ ,  $(x-1,y-1)$ ,  $(x-1,y+1)$  e  $(x+1,y-1)$
  - 8-vizinhança
- Vizinhança diagonal

# Conectividade

- Importante para estabelecer limites de regiões e objetos em uma imagem
  - 4-conectividade: pixels  $p$  e  $q$  são 4-conectados se  $q \in N_4(p)$
  - 8-conectividade: pixels  $p$  e  $q$  são 8-conectados se  $q \in N_8(p)$

# Distâncias

- Dados pixels  $p(x,y)$ ;  $q(s,t)$  e  $z(u,v)$
- Distância  $D$ 
  - $D(p,q) \geq 0$  (positividade)  $D(p,q) = 0$ , se somente se  $p=q$ )
  - $D(p,q) = D(q,p)$  (simetria)
  - $D(p,z) \leq D(p,q) + D(q,z)$  (desigualdade triangular)

# Distâncias

- Euclidiana:  $D_e(p, q) = \sqrt{(x - s)^2 + (y - t)^2}$
- Distância  $D_4$  (city-block/Manhattan):  
$$|x - s| + |y - t|$$
- Distância  $D_8$  (tab. xadrez):  
$$\max(|x - s|, |y - t|)$$

		*				
		*	3,3			
			*	*		
						*

Para o pixel de coordenadas  $(x,y) = (3,3)$ , compute as 3 distâncias para os pixels vizinhos marcados






# Operações Aritméticas e Lógicas

- Soma, subtração, multiplicação, divisão
  - Operações úteis, por exemplo, para filtrar ruído!
- AND, OR, XOR
  - Identificação de máscaras
- Transformações geométricas
  - Registro de imagens!

# Registro de Imagens

- Alinhar duas ou mais imagens de uma cena
- Dadas duas imagens, qual a transformação geométrica que leva a imagem de entrada na imagem de saída?
- Problema: estimar a função de transformação e utilizá-la para registrar as 2 imagens
  - Imagem de entrada: a que queremos transformar
  - Imagem de referência: em relação à qual queremos registrar a entrada


# Registro de imagens



# Pré-processamento

- Não aumenta o conteúdo de informação em uma imagem
- Às vezes, diminui o conteúdo
- O melhor pré-processamento é o não pré-processamento
  - concentrar-se no processo de aquisição de imagens
- É, mesmo assim, útil por eliminar informações redundantes

# Pré-processamento

- Melhorar a qualidade da imagem (dados) suprimindo distorções indesejadas e ou realçando certas características importantes para o processamento posterior
  - {note que transformações geométricas (rotação, escala, translação, etc.) são classificadas como pré-processamento}
- 4 categorias  tamanho da vizinhança considerada no cálculo do novo nível cinza

# 4 Categorias

- Transformações de brilho (histograma, etc.)
- Transformações geométricas (distorções)
- Métodos de filtragem espacial que consideram uma vizinhança local a cada pixel (suavização, filtros)
- Restauração (requer conhecimento sobre a imagem investigada)

# Transformadas de brilho do pixel

- Dependem exclusivamente da propriedade do próprio pixel
- Há duas classes de transformadas
  - Correção de brilho (*brightness correction*)
  - transformada de nível de cinza (*grey-scale transformation*)

# Transformadas

- Correção de brilho (*position-dependent*)
  - modifica o brilho do pixel levando em conta o seu brilho original e sua posição na imagem
- Transformada de nível de cinza
  - modifica o brilho do pixel sem considerar sua posição na imagem (equalização do histograma, por exemplo)



# Correção de Brilho

- Foto-sensitividade do sensor não é uniforme (câmeras CCD, por exemplo)
  - Na prática, dispositivos de aquisição e digitalização atenuam mais a luz quanto mais longe esta está do eixo óptico
- Iluminação desigual dos objetos também é fonte de degradação

# Correção da degradação

(quando sistemática e estável)

$$g(x,y) = f(x,y) \cdot h(x,y)$$

*$g(x,y)$ : imagem obtida, com degradação*

*$h(x,y)$ : coeficiente de erro*

*$f(x,y)$ : imagem original (ideal) não degradada (desejada)*

$$f(x,y) = g(x,y) \cdot h^{-1}(x,y)$$

*$h(x,y)$  estimado ao capturar uma imagem  $g(x,y)$  de brilho conhecido (imagem com brilho constante  $c$ )*


# Transformadas

- Correção de brilho (*position-dependent*)
  - modifica o brilho do pixel levando em conta o seu brilho original e sua posição na imagem
- Transformada de nível de cinza
  - modifica o brilho do pixel sem considerar sua posição na imagem (equalização do histograma, por exemplo)

# Transformadas do nível de cinza

$$q = T(p)$$

(4.3)



*Thresholding*  
(limiarização)

*Piecewise  
Linear  
Function:*

Realce de  
contraste na  
faixa  $(p_1, p_2)$

Transformada  
negativa

$T$ : Transformação

$p$ : pixel original (brilho original)


$q$ : novo valor

# Histogramas em Imagens Digitais

$$p_r(r_k) = n_k / n \quad \text{onde}$$

- $0 \leq r_k \leq 1$
- $k = 0, 1, \dots, L-1$ , onde  $L$  é o nro de níveis de cinza da imagem
- $n$  = nro total de pixels na imagem
- $p_r(r_k)$  = probabilidade do  $k$ -ésimo nível de cinza
- $n_k$  = nro de pixels cujo nível de cinza corresponde a  $k$

# Histograma em imagens digitais



# Propriedades de Histogramas

- O histograma não preserva a informação espacial da distribuição dos pixels, pois registra apenas a quantidade de pixels com um determinado nível de cinza, mas não a sua posição na imagem

- Área do histograma = área da imagem  $\int_0^{\infty} H(p) dp = \text{Área da Imagem}$

- Imagens distintas podem apresentar histogramas idênticos





- Os histogramas podem ser utilizados para fins de reconhecimento de padrões

# Técnicas de processamento com Histogramas

- Ajuste de brilho e contraste
- Equalização / Refinamento Imagem
- Segmentação
- Mapas de pseudocores



# Ajustes de brilho




- Brilho
  - Pode ser realizado através da soma/subtração pontual na intensidade dos pixels

# Histograma




Original



Mean: 20.51  
Std Dev: 51.80  
Median: 0  
Pixels: 54040

Level:  
Count:  
Percentile:


Contraste reduzido 50%



Mean: 20.29  
Std Dev: 27.53  
Median: 14  
Pixels: 54040

Level:  
Count:  
Percentile:




Brilho aumentado 50%






Mean: 78.29  
Std Dev: 27.53  
Median: 64  
Pixels: 54040

Level:  
Count:  
Percentile:

# Algumas transformações contraste lineares




# Outras transformações lineares







# Ajustes de contraste não lineares

- Escala logarítmica de contraste
$$s = c \log(1+p) \text{ [Gonzalez \& Woods, 1993]}$$
- aplica uma escala logarítmica e normaliza o resultado para o histograma 256
- Esta técnica apresenta bons resultados para aumentar o contraste de imagens
- Ferramentas de processamento permitem que o usuário ‘desenhe’ a função logarítmica



# Exemplos escala log









# Ajustes de brilho e contraste

- Escala exponencial de contraste


$$s = c \exp(1+p)$$

- Similar à técnica logarítmica, no entanto é empregada em imagens com muito brilho

# Exemplos escala exponencial




# Expansão de histograma




(a)



(b)




(a)




(b)

# Função para transformação de *contrast stretching*




$$S = \frac{1}{\left(1 + \frac{m}{(p+\epsilon)}\right)^E}$$


# Compressão de histograma




(a)



(b)



(a)





(b)

# Equalização de Histograma

- Cria uma imagem com níveis de cinza igualmente distribuídos ao longo da escala de cinza
- Muitas vezes melhora a qualidade visual da imagem
- Utiliza função auxiliar (ou de transformação)
  - cdf: função de distribuição acumulada, por exemplo

# Equalização



# Equalização

- Histograma acumulado
- Função de distribuição acumulada  
(*cumulative distribution function*)

$$S_k = T(r_k) = \sum n_j/n = \sum p_r(r_j) \quad (0 \leq j \leq k)$$



# Histograma

Nível de Cinza ( $r_k$ )	$n_k$	$P_r(r_k)$
0	1120	0,068
1/7 (0,142)	3214	0,196
2/7 (0,285)	4850	0,296
3/7 (0,428)	3425	0,209
4/7 (0,571)	1995	0,122
5/7 (0,714)	784	0,048
6/7 (0,857)	541	0,033
1	455	0,028
<b>TOTAL</b>	<b>16384</b>	<b>1</b>

Fazendo-se somas sucessivas com a função **cdf**, teremos:

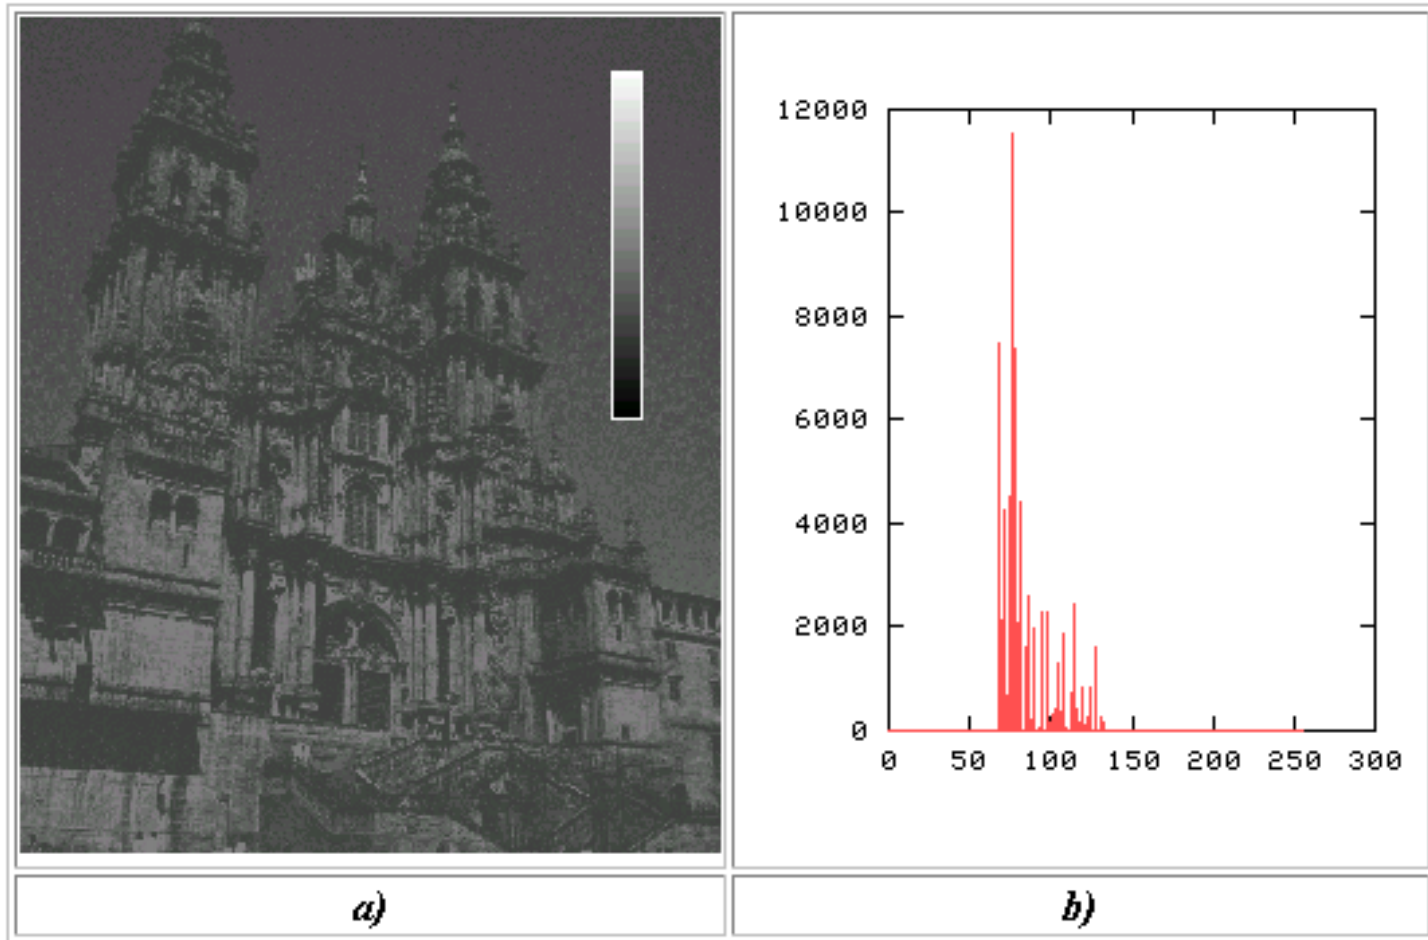
$$S_0 = 0.068, S_1=0.264, S_2=0.560, \dots S_6=0,972, S_7=1,000$$

# Equalização

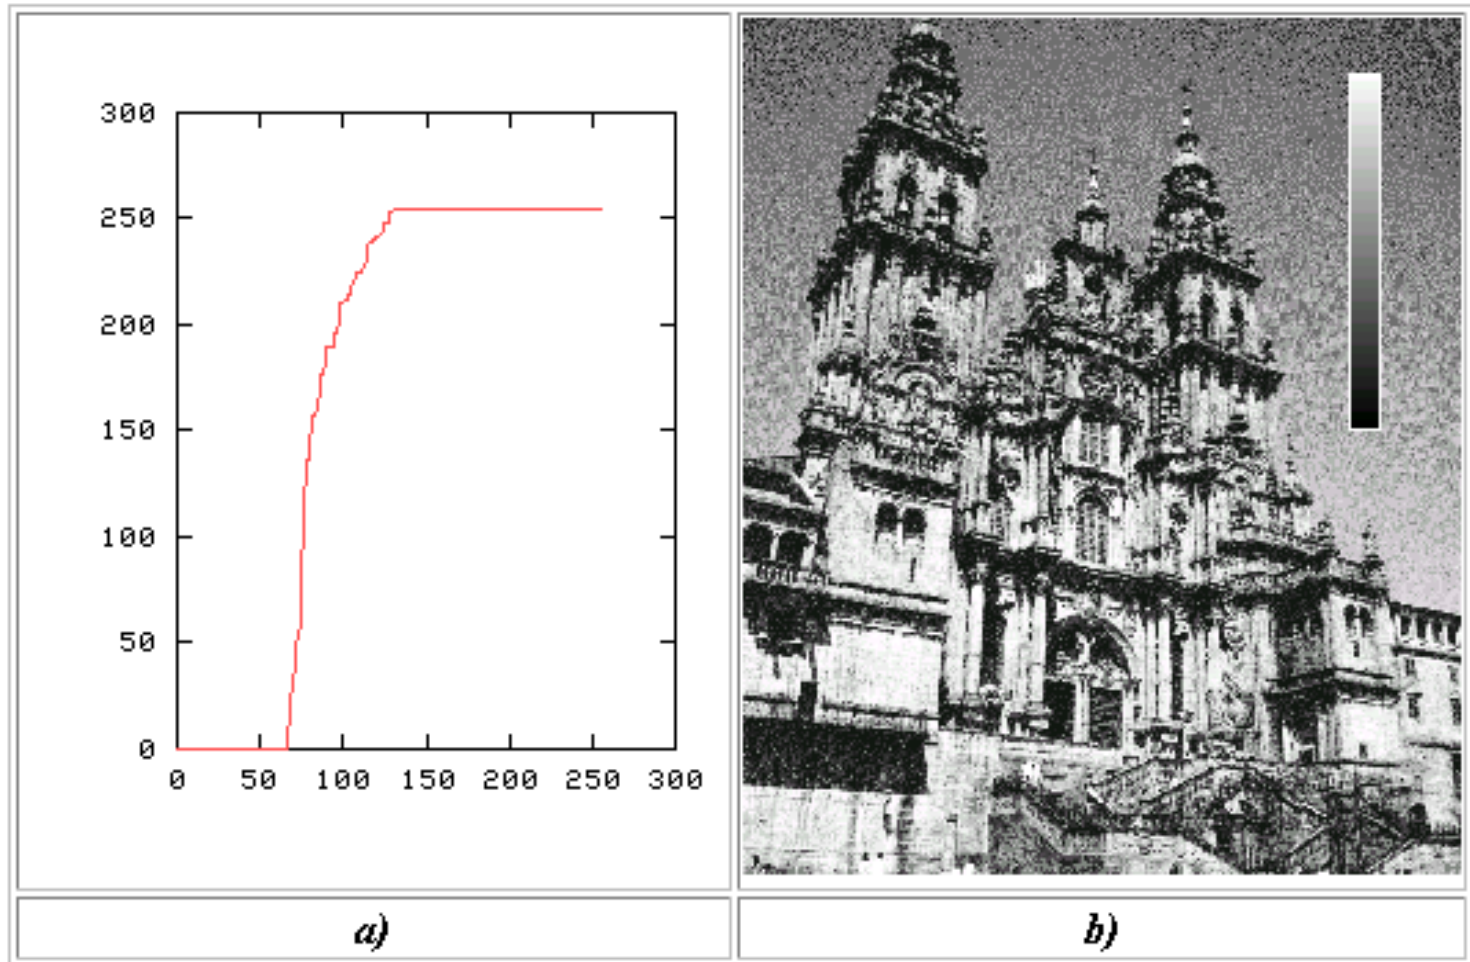
- Imagem quantizada com 8 níveis de cinza
  - cada valor  $s_j$  deverá ser arredondado para o valor válido mais próximo
    - $s_0 \approx 0$ ,  $s_1 \approx 2/7$ ,  $s_2 \approx 4/7$ ,  $s_3 \approx 5/7$
    - $s_4 \approx 6/7$ ,  $s_5 \approx 1$ ,  $s_6 \approx 1$ ,  $s_7 \approx 1$

# Após equalização

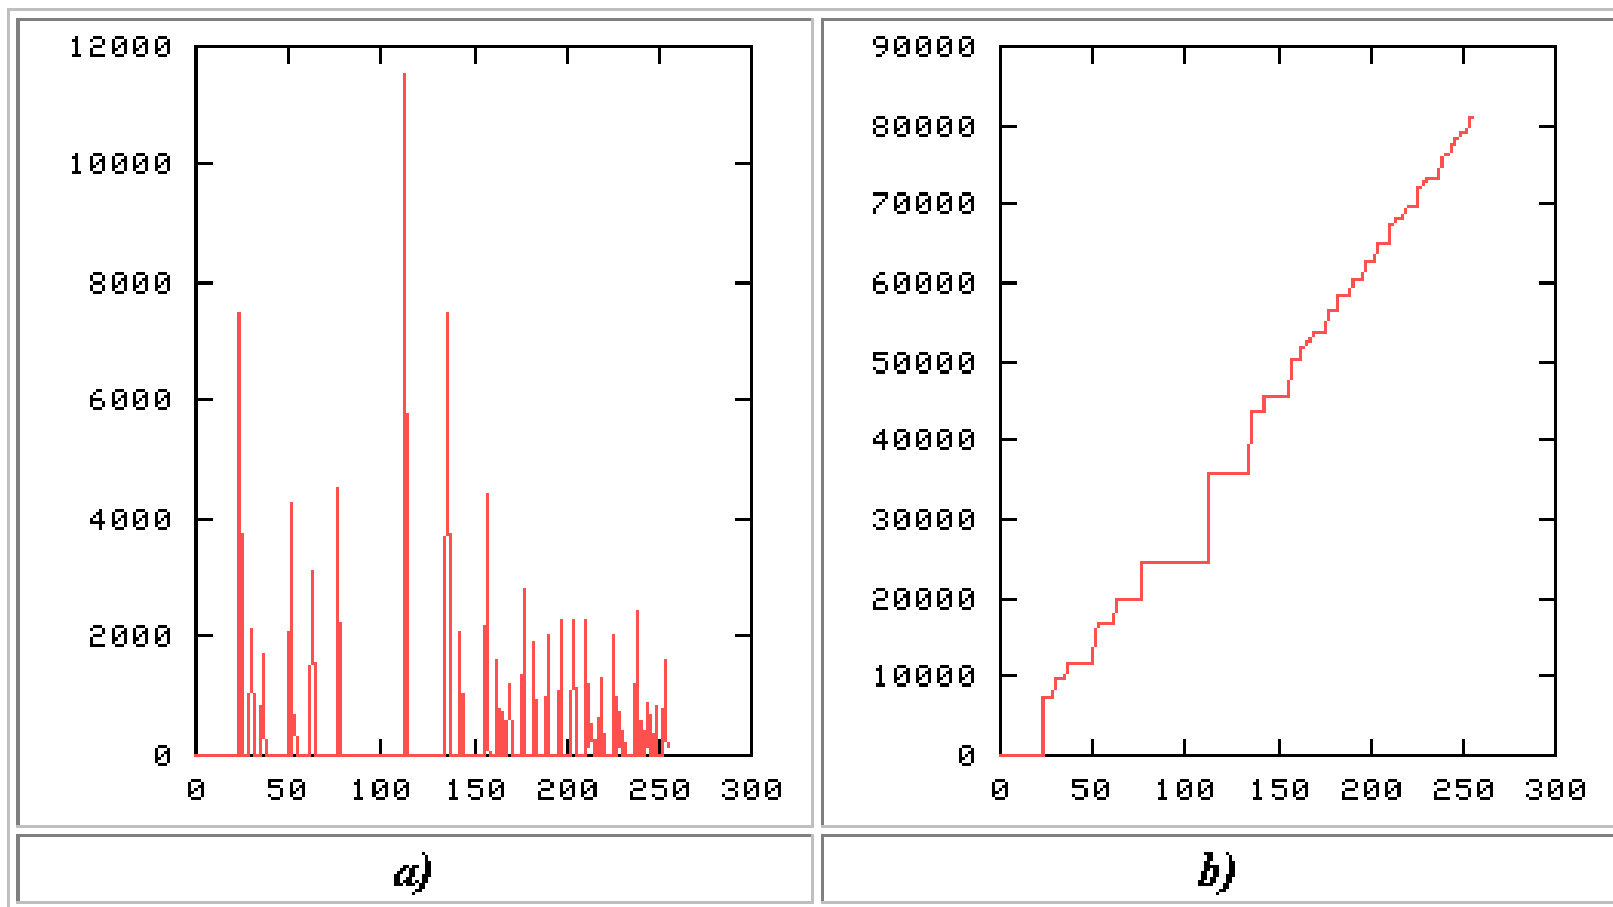
Nível de Cinza ( $r_k$ )	$n_k$	$P_T(r_k)$
0	1120	0,068
1/7	0	0,000
2/7	3214	0,196
3/7	0	0,000
4/7	4850	0,296
5/7	3425	0,209
6/7	1995	0,122
1	1780	0,109
<b>TOTAL</b>	<b>16384</b>	<b>1</b>



a) Imagem Original  
b) Histograma




- a) Histograma acumulado da imagem original  
b) Imagem equalizada

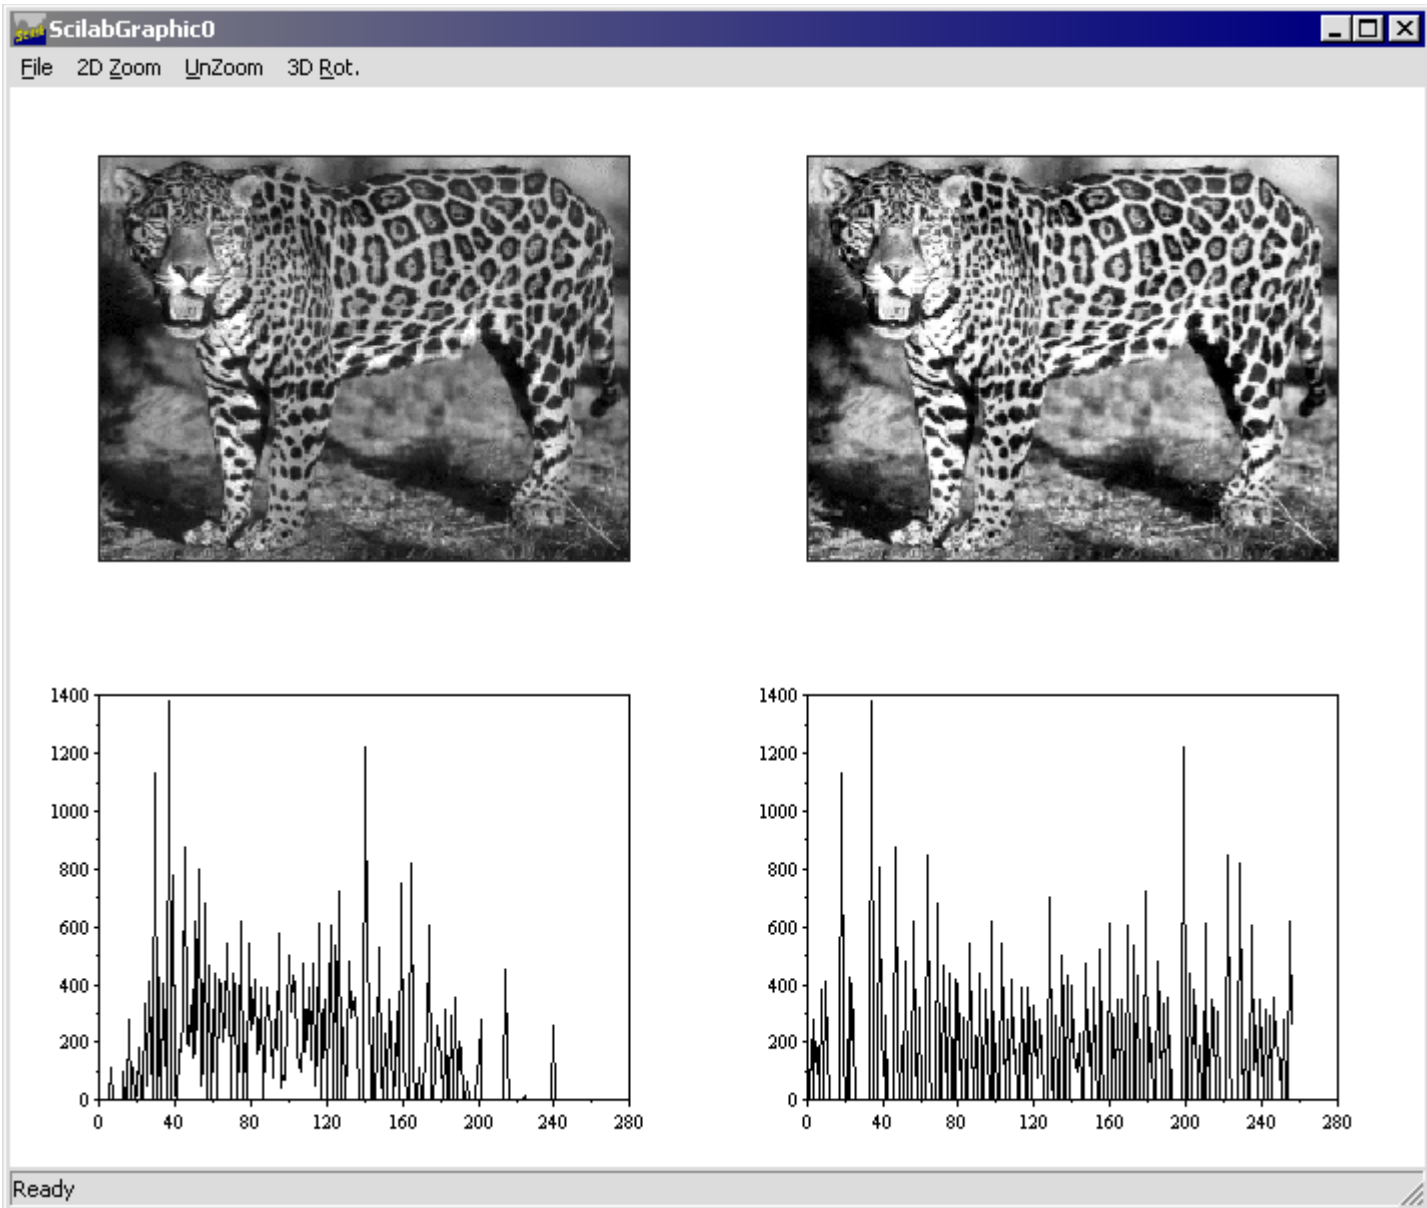


a) Histograma da imagem equalizada (devido à discretização, não gera valores constantes)

b) aproximação a uma reta

# Mais exemples







# 4 Categorias

- Transformações de brilho (histograma, etc.)
- Transformações geométricas (distorções)
- Métodos de filtragem espacial que consideram uma vizinhança local a cada pixel (suavização, filtros)
- Restauração (requer conhecimento sobre a imagem investigada)

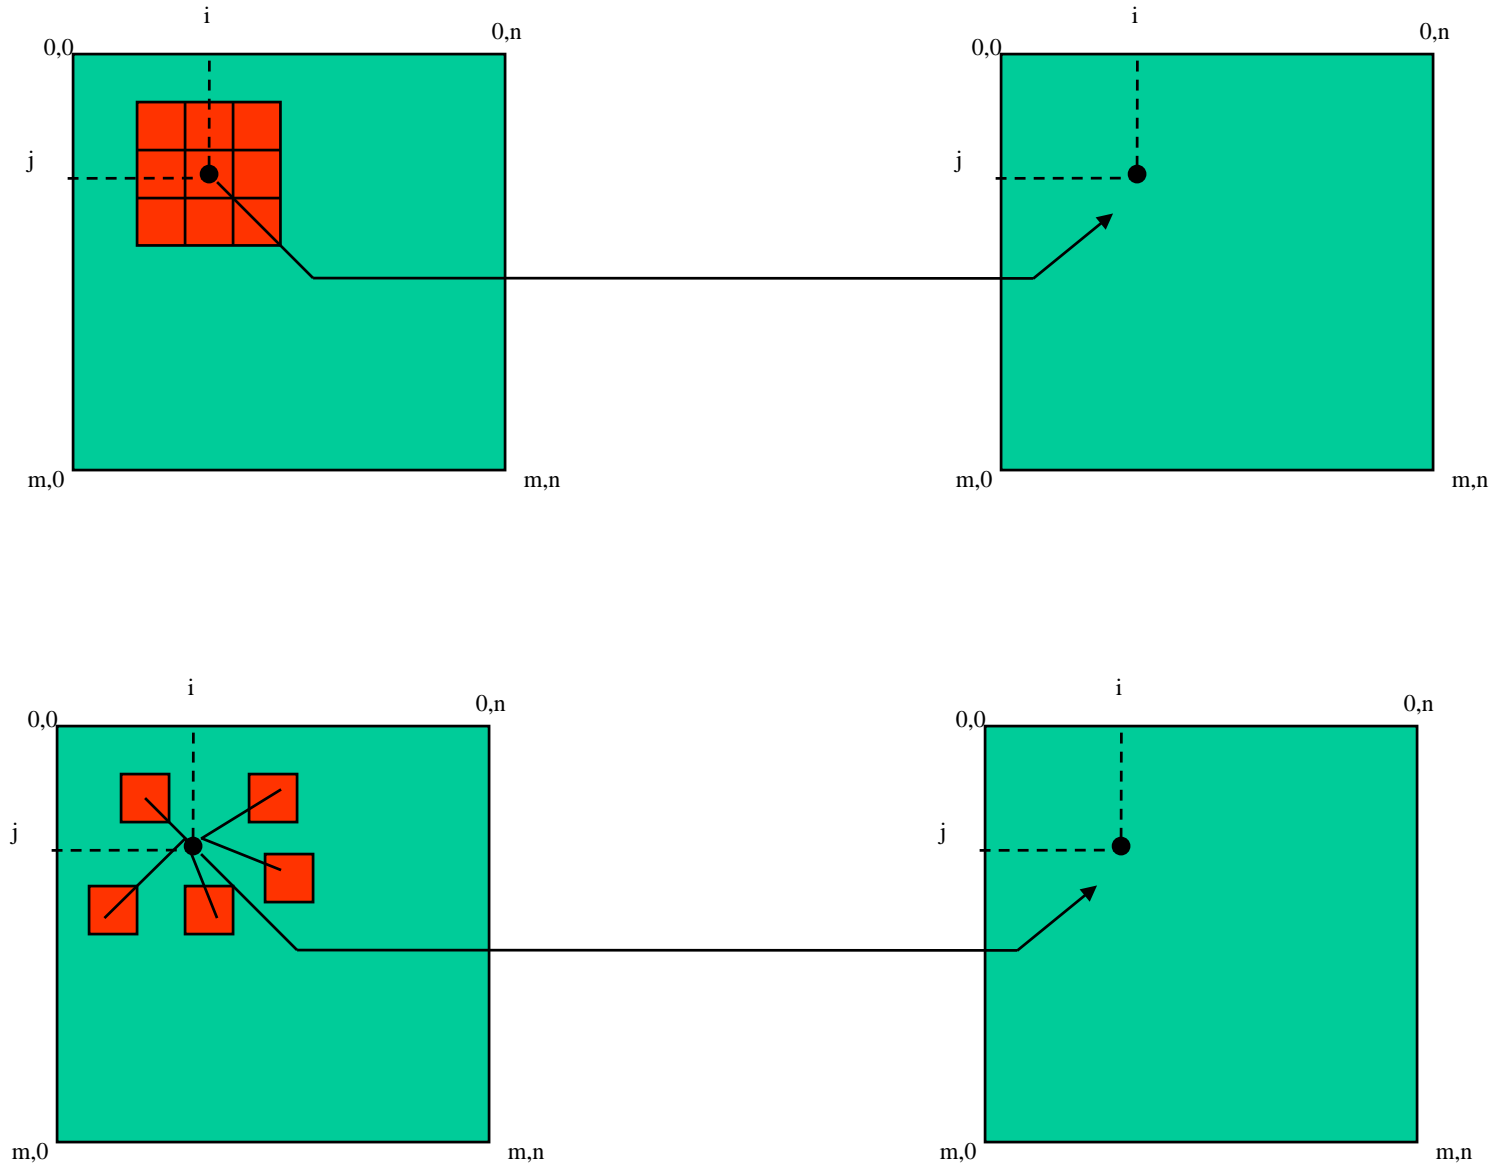
# Pré-processamento local

- Utiliza uma vizinhança de poucos pixels para produzir novas intensidades de pixel
- Duas categorias de técnicas
  - **suavização** (*smoothing*): suprimir ruído ou pequenas flutuações nas imagens (supressão de altas frequências)
  - **operadores de gradiente**: derivadas locais das funções de imagem. Por quê? Derivadas são maiores em regiões de rápidas mudanças (supressão de baixas frequências)
- Qual domínio? Espacial ou da Frequência

# Filtros digitais no domínio do espaço

- Definição
  - Também conhecidos como operadores locais
  - Os filtros locais são técnicas baseadas na **convolução** de *templates* (janelas, matrizes, máscaras) ou tuplas (conjunto de pixels)
  - Uma grande variedade de filtros digitais pode ser implementada por meio da convolução no domínio espacial

# Templates x tuplas



# Convolução de gabaritos (*templates*)

- Se  $T(x,y)$  é um gabarito ( $m \times n$ ) e  $I(x,y)$  é a Imagem ( $M \times N$ )
- A convolução de  $T \otimes I$  é dada por:


$$T \otimes I(x,y) = \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} T(i,j) I(x+i, y+j)$$

- Ou ainda ....

# Alguns conceitos importantes

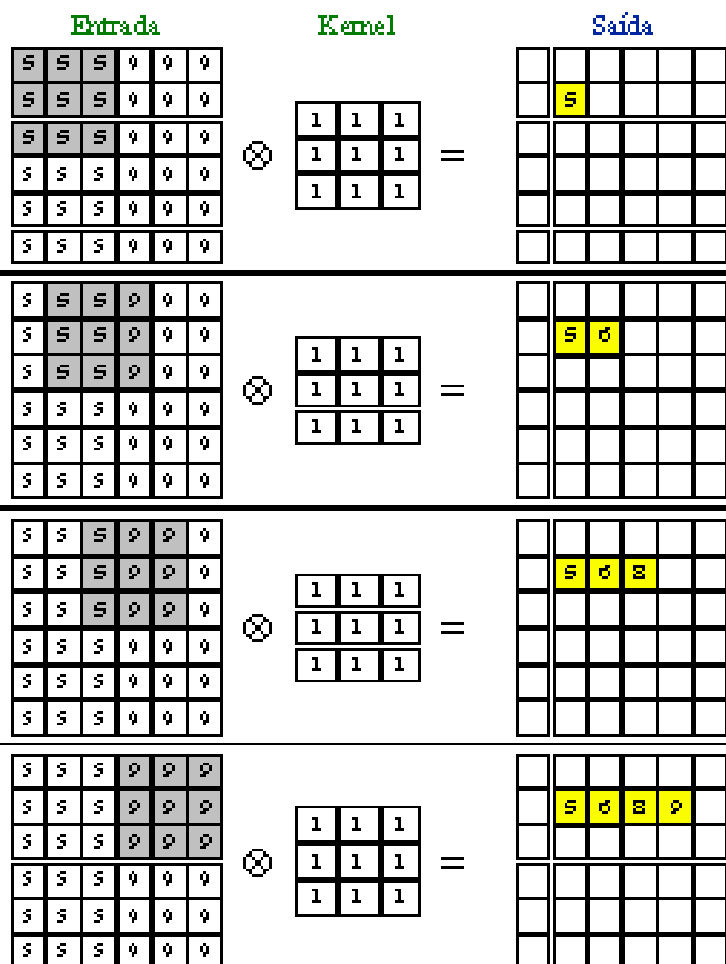
Convolução discreta  $g(x) = f(x) * h(x) = \sum_{\forall k} h(x - k)f(k)$

$h(x)$ : resposta de impulso (*impulse response*), *kernel*, máscara, filtro ou *template*

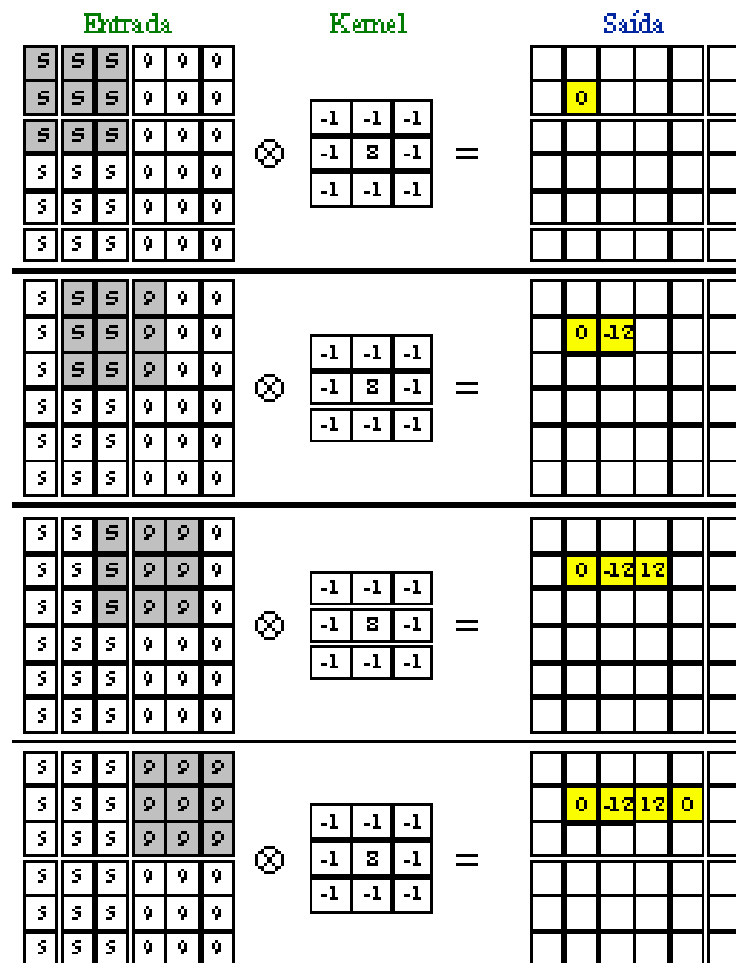


# Exemplos de convolução

## Filtro Passa-baixa




## Filtro Passa-alta



# Tratamento das extremidades da imagem

- Convolução aperiódica
  - Não considera os pontos da imagem onde o gabarito não se encaixa na imagem



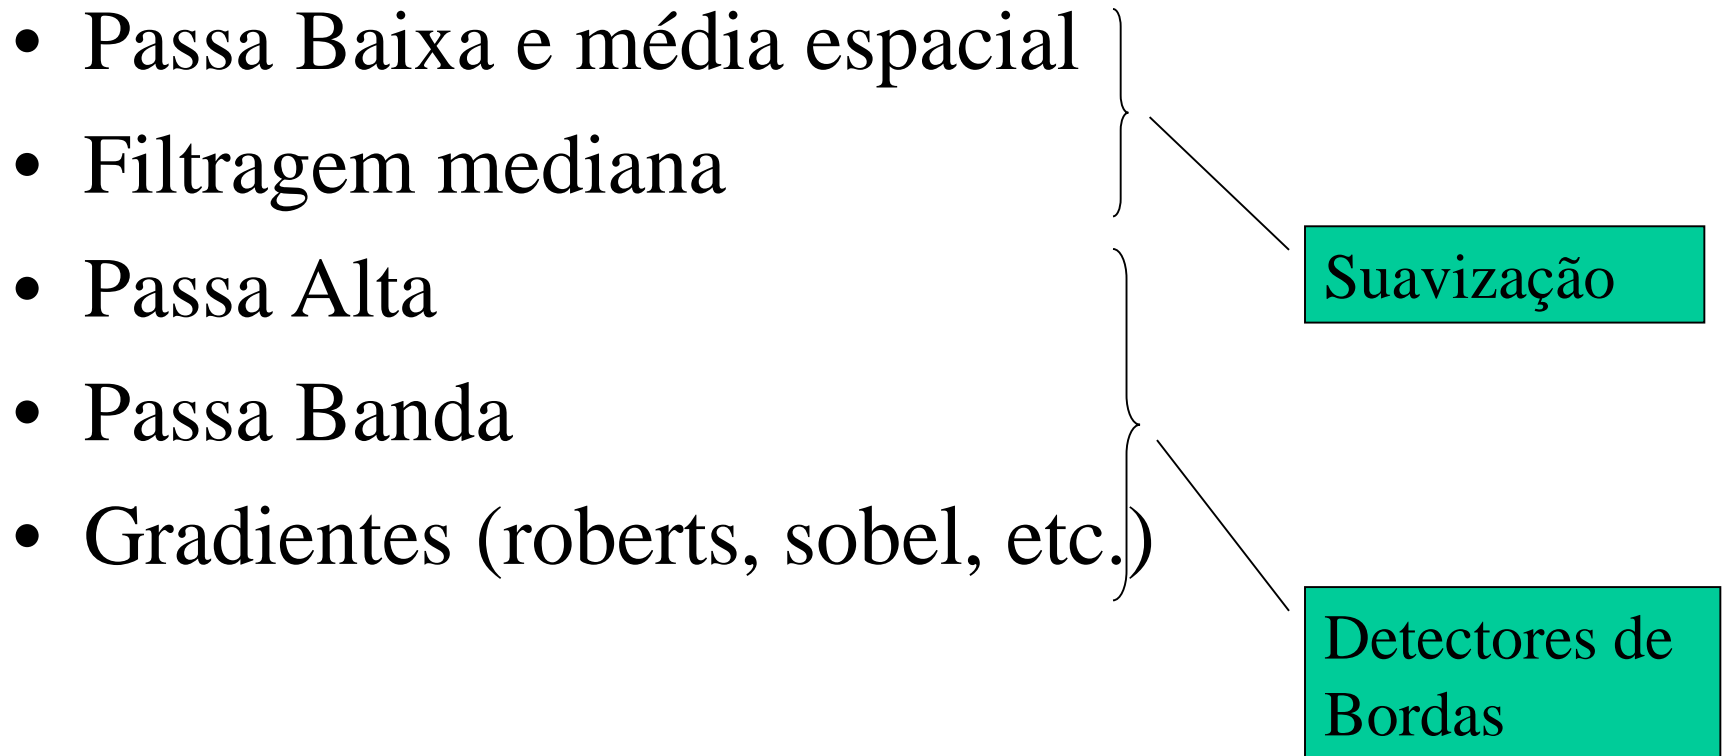
- Convolução Periódica
  - O gabarito é deslocado sobre as extremidades da Imagens como se estas fosses adjacentes
- Gabarito Truncado
  - Quando o gabarito não se encaixa na imagem o gabarito é truncado



# Convolução x Custo Computacional

- O custo computacional da convolução é alto
  - Em uma imagem  $M \times M$  e um *template*  $N \times N$  são realizadas  $M^2 \times N^2$ .
  - Se a imagem é de  $512 \times 512$  e o gabarito é de  $16 \times 16$ , são necessárias 67.108.864 multiplicações
  - Computação paralela

# Filtros Digitais – gabarito



# Filtro Passa-Baixa

- Suavização ("*Smoothing*") da imagem
- Redução do efeito de ruído e detalhes irrelevantes
- Maior a máscara, maior efeito de borramento

$\begin{bmatrix} 1/9 & 1/9 & 1/9 \\ 1/9 & 1/9 & 1/9 \\ 1/9 & 1/9 & 1/9 \end{bmatrix}$	$\begin{bmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{bmatrix} * 1/16$	$\begin{bmatrix} 1 & 1 & 1 \\ 1 & 2 & 1 \\ 1 & 1 & 1 \end{bmatrix} * 1/10$
---	--	--

# Filtro Passa-Baixa


- Filtro Gaussiano

- “semelhante” ao filtro da média. A máscara representa o formato de uma Gaussiana.

1/256	4/256	6/256	4/256	1/256
4/256	16/256	24/256	16/256	4/256
6/256	24/256	36/256	24/256	6/256
4/256	16/256	24/256	16/256	4/256
1/256	4/256	6/256	4/256	1/256

- Curiosidade: como gerar uma máscara de convolução espacial Gaussiana?  
<http://www.lcad.icmc.usp.br/~jbatista/procimg/gaussian.c>

# Filtro Passa-Baixa



# Filtro Média : Exemplo



Original



Filtragem de média 3x3



Filtragem de média 5x5



# Filtro de Mediana

- Os filtros de mediana permitem, tal como os filtros de média, reduzir o ruído das imagens sem, no entanto, esbater as arestas e os contornos das mesmas
- O valor mediano de um conjunto é aquele para o qual existem metade dos valores menores que ele e metade maiores que ele
- Este tipo de filtro é particularmente adaptado à remoção de ruído impulsivo que aparece em regiões limitadas da imagem

# Filtro de Mediana



Original



Filtrado com  
Mediana 3x3



# Filtro de Mediana: Exemplo




Imagem original



Imagem com ruído adicionado  
(20%)



Imagem depois de filtrada com  
um filtro de mediana 3x3

# Comparação Mediana/Média




Imagem com ruído adicionado  
(20%)



Imagem depois de filtrada com  
um filtro de mediana 3x3



Imagem depois de filtrada com  
um filtro de média

# Comparação Mediana/Média



ruído



Média 3x3





Mediana 3x3

# Observações

- *Edges* (arestas/bordas): pixels nos quais há uma mudança brusca na intensidade
- *Boundary* (contorno): linha fechada formada pelas bordas de um objeto


# O que causa mudanças na intensidade?

- Eventos Geométricos
  - Descontinuidades no contorno ou orientação da superfície e/ou cor da superfície e textura
- Eventos não geométricos
  - Mudança de iluminação
  - Luz especular
  - Sombras



# Descritores de Borda

- **Normal**: vetor unitário na direção da mudança máxima de intensidade
- **Direção**: vetor unitário perpendicular à normal
- **Posição**: posição na imagem em que a borda está localizada
- **“Strength”**: relacionado ao contraste local ao longo da normal





# Tipos de bordas

- Degrau (*step*)
- Rampa (*ramp*)
- Platô (*ridge*)
- Telhado (*roof*)

# Borda de grau (*step edge*)



- A intensidade muda abruptamente de um valor (de um lado) para um outro valor (para o lado oposto da descontinuidade)






# Borda rampa (*ramp edge*)

- Um degrau em que a mudança de intensidade não é instantânea, mas ocorre em uma distância finita




# Borda platô *Ridge edge*

- Mudança abrupta de intensidade, voltando ao ponto de partida após curta distância (geralmente causada por linhas na imagem)



# Borda Telhado (*roof edge*)

- Um *ridge edge* ocorre quando a mudança de intensidade não é instantânea, ocorrendo numa distância finita (geralmente causada pela intersecção de duas superfícies)



# Filtros detectores de bordas

- Realçam detalhes, produzindo uma "agudização" ("*sharpening*") da imagem, isto é, as transições entre regiões diferentes tornam-se mais nítidas. Estes filtros podem ser usados para realçar certas características presentes na imagem, tais como bordas, linhas curvas ou manchas, mas enfatizam o ruído existente na imagem.

# Principais etapas na detecção de bordas

- Suavização: eliminar ruídos desnecessários
- Agudização (*Enhancement*): aplicar filtro para realçar a qualidade das bordas na imagem
- Detecção: determinar que bordas devem ser descartadas (ruído) e quais devem ser mantidas
  - Limiarização na “strength” da borda !
- Localização: determinar local exato da bordas

# Tratamento matemático de arestas

- Derivadas: representam mudanças em funções contínuas, assim operadores que descrevem arestas podem ser expressos em termos de derivadas parciais
- Mudanças na função imagem podem ser representadas pelo Gradiente
- Uma aresta é uma variável vetorial, com magnitude e direção

# Detectores de Borda


- Os detectores de bordas são baseados em diferenciação, sendo que pode-se considerar derivadas de primeira ordem ou de segunda ordem
- gradiente  $\rightarrow$  borda  $\rightarrow$  módulo do vetor
- laplaciano  $\rightarrow$  borda  $\rightarrow$  cruzamento por zero

# Detecção de bordas por derivadas

- Pontos que estão nas bordas podem ser localizados

(1) detectando-se um local maxima ou minima da primeira derivada

(2) detectando-se os zero-crossings da segunda derivada





# Detecção de borda usando 1ª Derivada – 1D

$$f'(x) = \lim_{h \rightarrow 0} \frac{f(x+h) - f(x)}{h} \approx f(x+1) - f(x) \quad (h=1) \quad \text{mask:} \quad \begin{bmatrix} -1 & 1 \end{bmatrix}$$

$$\text{mask } M = [-1, 0, 1] \quad (\text{centrada em } x)$$

Borda degrau para cima

$S_1$			12	12	12	12	12	24	24	24	24	24
$S_1$	$\otimes$	$M$	0	0	0	0	12	12	0	0	0	0

Borda degrau para baixo

$S_2$			24	24	24	24	24	12	12	12	12	12
$S_2$	$\otimes$	$M$	0	0	0	0	-12	-12	0	0	0	0

Borda rampa

$S_3$			12	12	12	12	15	18	21	24	24	24
$S_3$	$\otimes$	$M$	0	0	0	3	6	6	6	3	0	0

Borda telhado

$S_4$			12	12	12	12	24	12	12	12	12	12
$S_4$	$\otimes$	$M$	0	0	0	12	0	-12	0	0	0	0

# Detecção de borda usando 2ª Derivada – **1D**


$$f''(x) = \lim_{h \rightarrow 0} \frac{f'(x+h) - f'(x)}{h} \approx f'(x+1) - f'(x) = \\ f(x+2) - 2f(x+1) + f(x) \quad (h=1)$$

Substituindo  $x+1$  por  $x$  (ou seja, centrando em  $x$ ):

$$f''(x) \approx f(x+1) - 2f(x) + f(x-1)$$

$$\text{mask:} \quad [1 \quad -2 \quad 1]$$

# Detecção de borda usando 2ª Derivada – 1D



# Detecção de borda usando 2ª Derivada – 1D

Borda degrau para cima

$S_1$			12	12	12	12	12	24	24	24	24	24
$S_1$	$\otimes$	$M$	0	0	0	0	-12	12	0	0	0	0

Borda degrau para baixo

$S_2$			24	24	24	24	24	12	12	12	12	12
$S_2$	$\otimes$	$M$	0	0	0	0	12	-12	0	0	0	0

Borda em rampa

$S_3$			12	12	12	12	15	18	21	24	24	24
$S_3$	$\otimes$	$M$	0	0	0	-3	0	0	0	3	0	0


Borda telhado

$S_4$			12	12	12	12	24	12	12	12	12	12
$S_4$	$\otimes$	$M$	0	0	0	-12	24	-12	0	0	0	0

# Considerações sobre bordas e derivadas

- Primeira ordem
  - Produzem bordas mais espessas
  - A magnitude da resposta é menor, pois é menos agressiva na hora de facilitar as mudanças bruscas
- Segunda ordem
  - Realçam mais os detalhes (incluindo ruídos!)
  - Nas rampas ou degraus, apresenta sinais opostos (efeito borda dupla)
  - Sinal pode ser usado para determinar se uma borda é uma transição de claro p/ escuro (derivada negativa) ou escuro/claro (derivada positiva)

# O Gradiente



$$|\text{grad } g(x, y)| = \sqrt{\left(\frac{\partial g}{\partial x}\right)^2 + \left(\frac{\partial g}{\partial y}\right)^2}$$

$$\psi = \text{arg}\left(\frac{\partial g}{\partial x}, \frac{\partial g}{\partial y}\right)$$

- Em PI as derivadas de primeira ordem são implementadas utilizando-se a magnitude do gradiente
- A direção do gradiente é perpendicular à aresta e dá sempre a direção de crescimento da função: menor p/ maior intensidade !

# Detecção de Borda com 1ª Derivada – **2D**

## Gradiente

- O Gradiente é definido como:

$$\frac{\partial f}{\partial x} = \lim_{h \rightarrow 0} \frac{f(x+h, y) - f(x, y)}{h} \qquad \frac{\partial f}{\partial y} = \lim_{h \rightarrow 0} \frac{f(x, y+h) - f(x, y)}{h}$$

- Aproximação do gradiente por diferenças finitas:


$$\frac{\partial f}{\partial x} = \frac{f(x+h_x, y) - f(x, y)}{h_x} = f(x+1, y) - f(x, y), \quad (h_x=1)$$

$$\frac{\partial f}{\partial y} = \frac{f(x, y+h_y) - f(x, y)}{h_y} = f(x, y+1) - f(x, y), \quad (h_y=1)$$

# Detecção de Borda com 1ª Derivada – **2D**

## Gradiente

- Na notação de coordenadas de pixel,  $j$  corresponde à direção  $x$  e  $i$  à direção negativa  $y$



-1	1
----	---

1
-1

$$f(x+1, y) - f(x, y) \rightarrow \frac{\partial f}{\partial x} = f(i, j+1) - f(i, j)$$

$$f(x, y+1) - f(x, y) \rightarrow \frac{\partial f}{\partial y} = f(i, j) - f(i+1, j)$$



# Observações sobre Gradiente

- Como os componentes do vetor gradiente são derivadas, estes são operadores lineares
- A magnitude, no entanto, não é linear (potência e raiz quadrada)
- As derivadas parciais são anisotrópicas, ou seja, não são invariantes a rotações. Mas a magnitude é invariante à rotação (isotrópica)

# Operadores de primeira ordem

- Roberts
- Sobel
- Prewitt
- Kirsh

# Operador baseado na 1ª Derivada – **2D** Roberts


$$\frac{\partial f}{\partial x} = f(i, j) - f(i + 1, j)$$

$$\frac{\partial f}{\partial y} = f(i, j) - f(i, j + 1)$$


$$M_x = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix} \quad M_y = \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix}$$

$M_x$  e  $M_y$  são aproximações em  $i + \frac{1}{2}$  e  $j + \frac{1}{2}$

# Operadores de Roberts



# Operadores de Roberts



# Operador baseado na 1ª Derivada – 2D

## Outra aproximação

- Considere o arranjo de pixels ao redor de  $(i, j)$ :

$$\begin{array}{ccc} a_0 & a_1 & a_2 \\ a_7 & [i, j] & a_3 \\ a_6 & a_5 & a_4 \end{array}$$

- As derivadas parciais podem ser computadas como:

$$\begin{aligned} M_x &= (a_2 + ca_3 + a_4) - (a_0 + ca_7 + a_6) \\ M_y &= (a_6 + ca_5 + a_4) - (a_0 + ca_1 + a_2) \end{aligned}$$

- A constante  $c$  implica que a ênfase foi dada ao pixel mais próximo ao centro da máscara

# Operador baseado na 1ª Derivada – **2D** Prewitt

- Setando  $c = 1$ , temos o operador Prewitt !

$$M_x = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix} \quad M_y = \begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix}$$

$M_x$  e  $M_y$  são aproximações em (i ,j)

# Operador baseado na 1ª Derivada – **2D** Sobel

- Fazendo  $c = 2$ , temos Sobel:

$$M_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix} \quad M_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix}$$

$M_x$  e  $M_y$  são aproximações em (i ,j)



# Sobel

$a$	$b$	$c$
$d$	$e$	$f$
$g$	$h$	$i$

$$S_x = (c + 2f + i) - (a + 2d + g)$$

$$S_y = (g + 2h + i) - (a + 2b + c)$$

$$S = \sqrt{S_x^2 + S_y^2}$$


Ou numa versão simplificada:

$$S = |S_x| + |S_y|$$

# Gradiente Sobel


$S_x$

$S_y$




Bordas = thresholding  $\left| \vec{\nabla} g \right|$

# Operadores de Sobel



# Operadores de Sobel



# Operadores de Sobel




# Comparação

Roberts



Original





Sobel 102


# Questões práticas sobre filtros

- Balanço entre supressão-localização de ruído
  - Filtros maiores reduzem ruído, mas pioram a localização (adicionam incertezas sobre a localização das arestas) e vice-versa

Filtro menor



Filtro maior




# Questões práticas sobre filtros


- Como escolher o limiar ?




Baixo threshold



Magnitude do gradiente





Alto threshold





# Questões práticas sobre filtros

- Afinamento e “linking” normalmente são operações necessárias !



# Detectores de borda com 2ª Derivada – **2D**

## **Laplaciano**

$$\nabla^2 f = \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2}$$

$$\frac{\partial^2 f}{\partial x^2} = f(i, j+1) - 2f(i, j) + f(i, j-1)$$

$$\frac{\partial^2 f}{\partial y^2} = f(i+1, j) - 2f(i, j) + f(i-1, j)$$

$$\nabla^2 f = -4f(i, j) + f(i, j+1) + f(i, j-1) + f(i+1, j) + f(i-1, j)$$

máscara:

0	1	0
1	-4	1
0	1	0



# Detectores de borda com 2ª Derivada – **2D**

## **Exemplo Laplaciano**

detect zero-crossings

5	5	5	5	5	5
5	5	5	5	5	5
5	5	10	10	10	10
5	5	10	10	10	10
5	5	5	10	10	10
5	5	5	5	10	10

-	-	-	-	-	-
-	0	-5	-5	-5	-
-	-5	10	5	5	-
-	-5	10	0	0	-
-	0	-10	10	0	-
-	-	-	-	-	-



a	b
c	d

**FIGURE 10.21**

(a) Three-dimensional plot of the *negative* of the LoG. (b) Negative of the LoG displayed as an image. (c) Cross section of (a) showing zero crossings. (d)  $5 \times 5$  mask approximation to the shape in (a). The negative of this mask would be used in practice.

0	0	-1	0	0
0	-1	-2	-1	0
-1	-2	16	-2	-1
0	-1	-2	-1	0
0	0	-1	0	0

## Detectores de borda com 2ª Derivada – **2D** **Propriedades Laplaciano**

- É um operador isotrópico (não diferencia direções)
- Fácil de implementar (basta uma máscara)
- Não dá informação sobre a direção da borda
- Mais sensível ao ruído (i.e., deriva duas vezes!)

# Detectores de borda com 2ª Derivada – 2D Laplaciano do Gaussiano (LoG)

- Para reduzir o efeito do ruído, a imagem é primeiramente suavizada com um filtro passa-baixa
- No caso do LoG, este filtro é uma Gaussiana


$$G(x, y) = e^{-\frac{x^2+y^2}{2\sigma^2}}$$

$\sigma$  controla a suavização

- Pode ser mostrado que:

$$\nabla^2[f(x, y) * G(x, y)] = \nabla^2 G(x, y) * f(x, y)$$

$$\nabla^2 G(x, y) = \left(\frac{r^2 - \sigma^2}{\sigma^4}\right)e^{-r^2/2\sigma^2}, \quad (r^2 = x^2 + y^2)$$



# LoG

- Aplicado o filtro LoG, deve-se encontrar o cruzamento por zero
  - Vizinhança 3 x 3 centrado em  $p$ . Um cruzamento por zero em  $p$  ocorre quando os sinais de pelo menos dois de seus pixels vizinhos opostos são diferentes! (esquerda/direita; cima/baixo e duas diagonais)
  - Pode-se ainda considerar um limiar entre a diferença absoluta dos vizinhos
- Quanto ao filtro Gaussiano:
  - 99,7% do volume sob uma superfície de uma gaussiana 2D situa-se entre  $\pm 3\sigma$  ao redor da média.
  - O tamanho do filtro discreto LoG  $n \times n$  deve ser tal que  $n$  seja o menor inteiro ímpar  $\geq 6\sigma$

# Detectores de borda com 2ª Derivada – 2D

## Exemplo Laplaciano of Gaussiano (LoG)

5 × 5 Laplacian of Gaussian mask


0	0	-1	0	0
0	-1	-2	-1	0
-1	-2	16	-2	-1
0	-1	-2	-1	0
0	0	-1	0	0

17 × 17 Laplacian of Gaussian mask


0	0	0	0	0	0	-1	-1	-1	-1	-1	0	0	0	0	0	0
0	0	0	0	-1	-1	-1	-1	-1	-1	-1	-1	-1	0	0	0	0
0	0	-1	-1	-1	-2	-3	-3	-3	-3	-3	-2	-1	-1	-1	0	0
0	0	-1	-1	-2	-3	-3	-3	-3	-3	-3	-3	-2	-1	-1	0	0
0	-1	-1	-2	-3	-3	-3	-2	-3	-2	-3	-3	-3	-2	-1	-1	0
0	-1	-2	-3	-3	-3	0	2	4	2	0	-3	-3	-3	-2	-1	0
-1	-1	-3	-3	-3	0	4	10	12	10	4	0	-3	-3	-3	-1	-1
-1	-1	-3	-3	-2	2	10	18	21	18	10	2	-2	-3	-3	-1	-1
-1	-1	-3	-3	-3	4	12	21	24	21	12	4	-3	-3	-3	-1	-1
-1	-1	-3	-3	-2	2	10	18	21	18	10	2	-2	-3	-3	-1	-1
-1	-1	-3	-3	-3	0	4	10	12	10	4	0	-3	-3	-3	-1	-1
0	-1	-2	-3	-3	-3	0	2	4	2	0	-3	-3	-3	-2	-1	0
0	-1	-1	-2	-3	-3	-3	-2	-3	-2	-3	-3	-3	-2	-1	-1	0
0	0	-1	-1	-2	-3	-3	-3	-3	-3	-3	-3	-2	-1	-1	0	0
0	0	-1	-1	-1	-2	-3	-3	-3	-3	-3	-2	-1	-1	-1	0	0
0	0	0	0	-1	-1	-1	-1	-1	-1	-1	-1	-1	0	0	0	0
0	0	0	0	0	0	-1	-1	-1	-1	-1	0	0	0	0	0	0



convolution result



zero-crossings





a	b
c	d

**FIGURE 10.22**

(a) Original image of size  $834 \times 1114$  pixels, with intensity values scaled to the range  $[0, 1]$ . (b) Results of Steps 1 and 2 of the Marr-Hildreth algorithm using  $\sigma = 4$  and  $n = 25$ . (c) Zero crossings of (b) using a threshold of 0 (note the closed-loop edges). (d) Zero crossings found using a threshold equal to 4% of the maximum value of the image in (b). Note the thin edges.

# Detector de borda Canny

- “Taxonomicamente” este operador deveria estar junto aos operadores de primeira derivada, mas devido à sua “boniteza” foi deixado para o final
  - Marr Hildreth (1980)
  - Canny (1986)
    1. Baixa taxa de erro: encontrar todas as bordas
    2. Boa localização: bordas detectadas o mais próximo das bordas reais
    3. Resposta única: retorna um único ponto de borda (nro. de máximos locais deve ser mínimo)

# Detector de borda Canny

- Atacando os critérios taxa de erro e localização
  - Canny mostrou que uma boa aproximação para um detector ótimo de bordas de degrau é a primeira derivada de uma Gaussiana
    - Análise baseada em bordas do tipo degrau (*step-edges*) corrompidas por ruído branco Gaussiano
    - (ruído branco : ruído com espectro de frequência contínuo e uniforme sobre uma banda específica)
    - (ruído branco Gaussiano: ruído branco em que a distribuição dos valores de amplitude é Gaussiano)
- Critério única resposta
  - Aproximação numérica

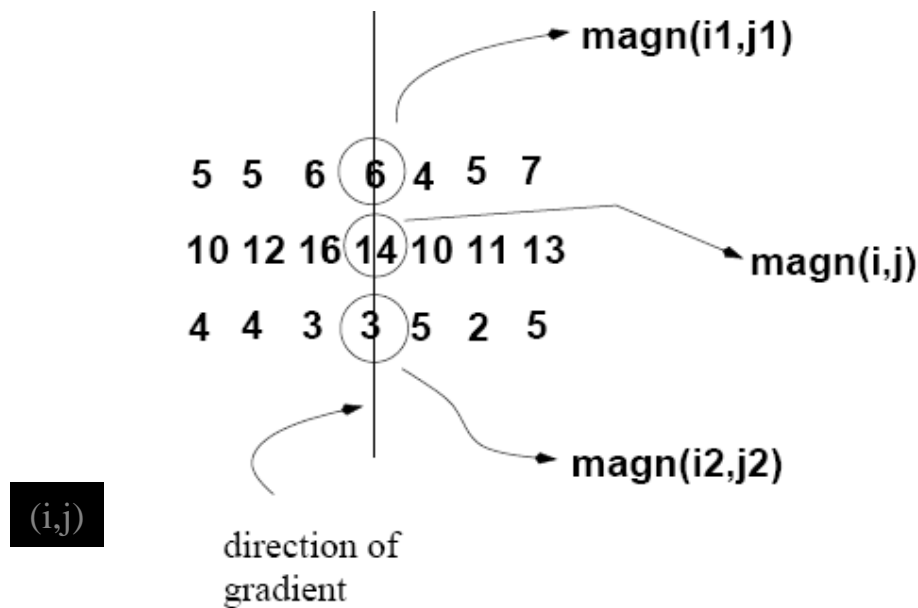
# Canny - Etapas

1. Suavizar uma imagem  $f$  por uma Gaussiana
  - $F_s(x,y) = f(x,y) * G(x,y)$
2. Para cada pixel, computar a magnitude  $M(x,y)$  e a direção do gradiente  $\alpha(x,y)$ 
  - Usar qqr filtro de primeira derivada visto antes
  - $M(x,y)$  fatalmente conterá cristas largas em torno dos máximos locais. Para afinar estas cristas utiliza algoritmo de supressão dos não máximos, afinando  $M(x,y)$
3. Limiarizar  $M(x,y)$  e analisar conectividade

# Canny

## *Non-maxima suppression*




### Supressão dos não máximos



#### Algorithm

For each pixel (x,y) do:

```
if  $\text{magn}(i, j) < \text{magn}(i_1, j_1)$  or  $\text{magn}(i, j) < \text{magn}(i_2, j_2)$ 
  then  $I_N(i, j) = 0$ 
else  $I_N(i, j) = \text{magn}(i, j)$ 
```



**FIGURE 10.24** (a) Two possible orientations of a horizontal edge (in gray) in a  $3 \times 3$  neighborhood. (b) Range of values (in gray) of  $\alpha$ , the direction angle of the *edge normal*, for a horizontal edge. (c) The angle ranges of the edge normals for the four types of edge directions in a  $3 \times 3$  neighborhood. Each edge direction has two ranges, shown in corresponding shades of gray.

# Canny - Etapas

1. Suavizar uma imagem  $f$  por uma Gaussiana
  - $F_s(x,y) = f(x,y) * G(x,y)$
2. Para cada pixel, computar a magnitude  $M(x,y)$  e a direção do gradiente  $\alpha(x,y)$ 
  - Usar qqr filtro de primeira derivada visto antes
  - $M(x,y)$  fatalmente conterá cristas largas em torno dos máximos locais. Para afinar estas cristas utiliza algoritmo de supressão dos não máximos, afinando  $M(x,y)$
3. Limiarizar  $M(x,y)$  e analisar conectividade

# Canny

## Limiarização por histerese/*edge linking*

- Usar dois limiares
  - Um limiar baixo  $t_l$  (obtem  $I_1$ )
  - Um limiar alto  $t_h$  (obtem  $I_2$  normalmente,  $t_h = 2t_l$ )

### *Algorithm*

1. Produce two thresholded images  $I_1(i, j)$  and  $I_2(i, j)$ .


(note: since  $I_2(i, j)$  was formed with a high threshold, it will contain fewer false edges but there might be gaps in the contours)

2. Link the edges in  $I_2(i, j)$  into contours

2.1 Look in  $I_1(i, j)$  when a gap is found.

2.2 By examining the 8 neighbors in  $I_1(i, j)$ , gather edge points from  $I_1(i, j)$  until the gap has been bridged to an edge in  $I_2(i, j)$ .





a	b
c	d

**FIGURE 10.25**


(a) Original image of size  $834 \times 1114$  pixels, with intensity values scaled to the range  $[0, 1]$ .

(b) Thresholded gradient of smoothed image.

(c) Image obtained using the Marr-Hildreth algorithm.

(d) Image obtained using the Canny algorithm.

Note the significant improvement of the Canny image compared to the other two.



a	b
c	d

**FIGURE 10.26**

(a) Original head CT image of size  $512 \times 512$  pixels, with intensity values scaled to the range  $[0, 1]$ .  
 (b) Thresholded gradient of smoothed image.

(c) Image obtained using the Marr-Hildreth algorithm.

(d) Image obtained using the Canny algorithm.

(Original image courtesy of Dr. David R. Pickens, Vanderbilt University.)

# Exemplo – qual o efeito de $\sigma$ ?

(left:Sobel, middle: thresh=35, right: thersh=50)




(Canny - left: $\sigma=1$ , middle:  $\sigma=2$ , right:  $\sigma=3$ )




# Exemplo – qual o efeito de $\sigma$ ?

(Canny - 7x7 Gaussian, more details)




(Canny - 31x31 Gaussian, less details)




# Processamento multi-escala (*scale space*)

- Um problema prático com qqr detector de borda é a questão da escolha da escala de suavização (o valor de  $\sigma$  na Gaussiana)
- Em muitas aplicações é desejável processar imagens em várias escalas
  - talvez combinar os resultados
- Determinamos quais bordas são mais significativas em termos da faixa de escalas sobre as quais elas serão evidentes

# Processamento multi-escala



# Processamento multi-escala



(Canny edges at multiple scales of smoothing,  $\sigma=0.5, 1, 2, 4, 8, 16$ )

# Bibliografia

- Gonzalez & Woods, Processamento Digital de Imagens, 3ª. Edição (caps. 3 e 10)
- Sonka, Image Processing, Analysis and Machine Vision