Detectando Bordas: Filtros Passa Alta

Prof. Dr. Geraldo Braz Junior

Baseado nas notas de aula de Fei-Fei Li e *A Practical Introduction to Computer Vision with OpenCV* by Kenneth Dawson-Howe

Porque contornos são importantes?

Porque contornos são importantes?

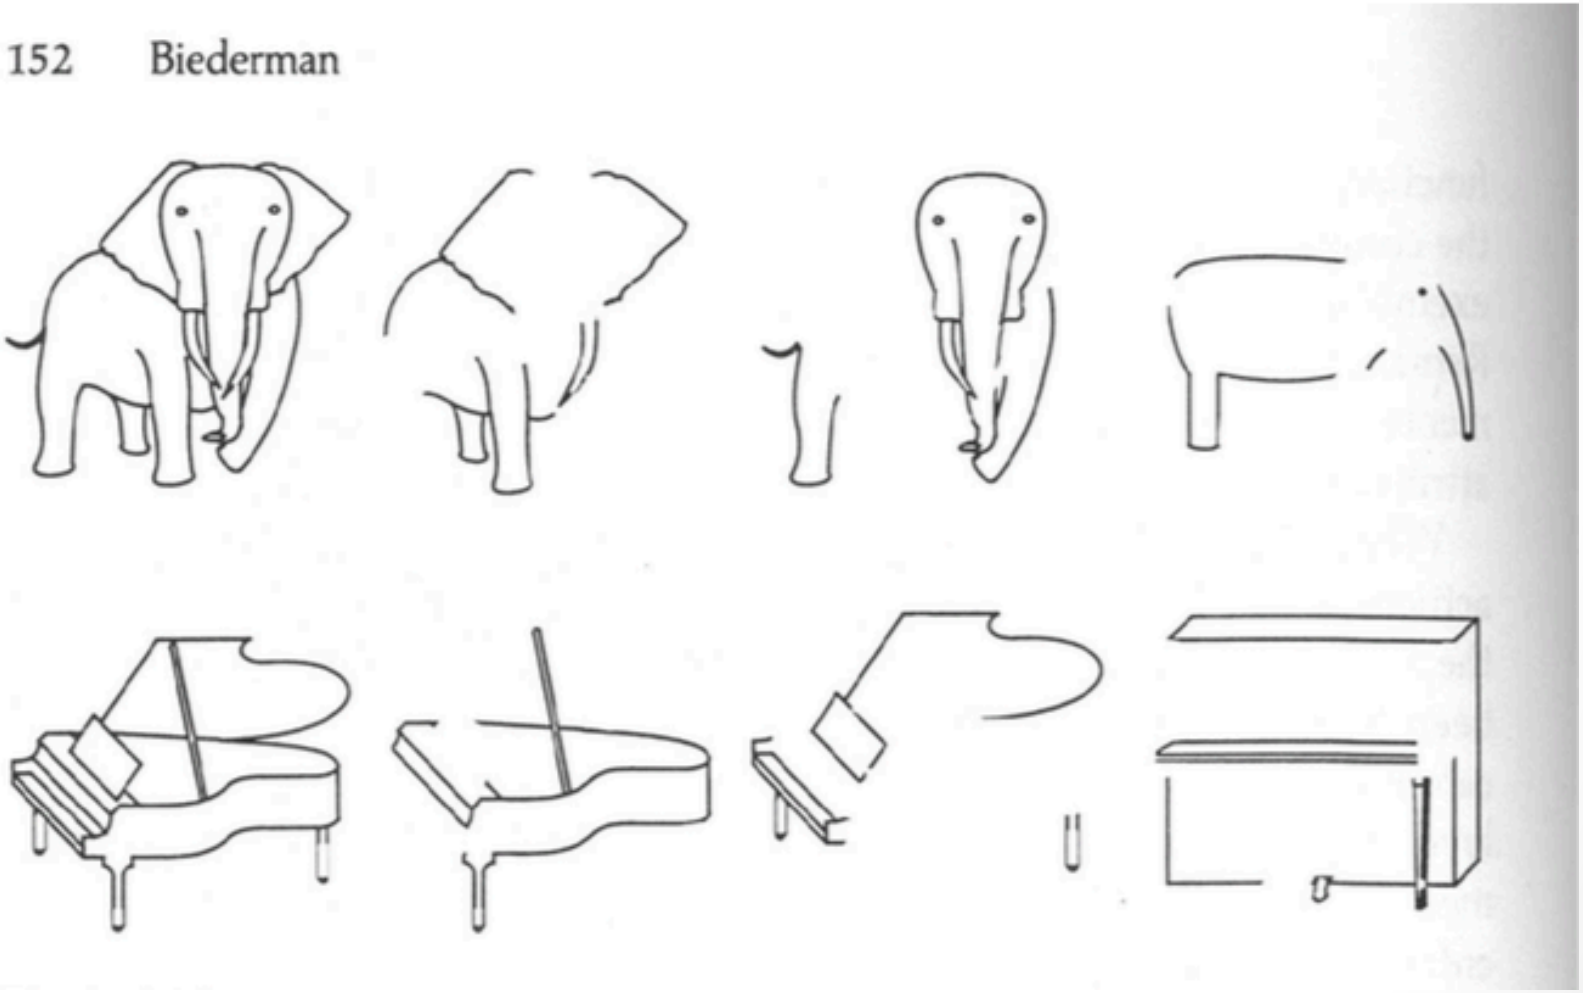

Detecção de Bordas

- Busca identificar descontinuidades repentinas na imagem
  - Edges
- Para humanos, as bordas (e formas) possuem a maioria da informação semântica presente numa imagem
- Representação mais compacta do que pixels

- Objetivo máximo:
  - Detectar bordas com a máxima precisão

Na visão, qual o papel?

- Extrair informação
- Reconhecimento de objetos
- Recuperar geometria
- ….

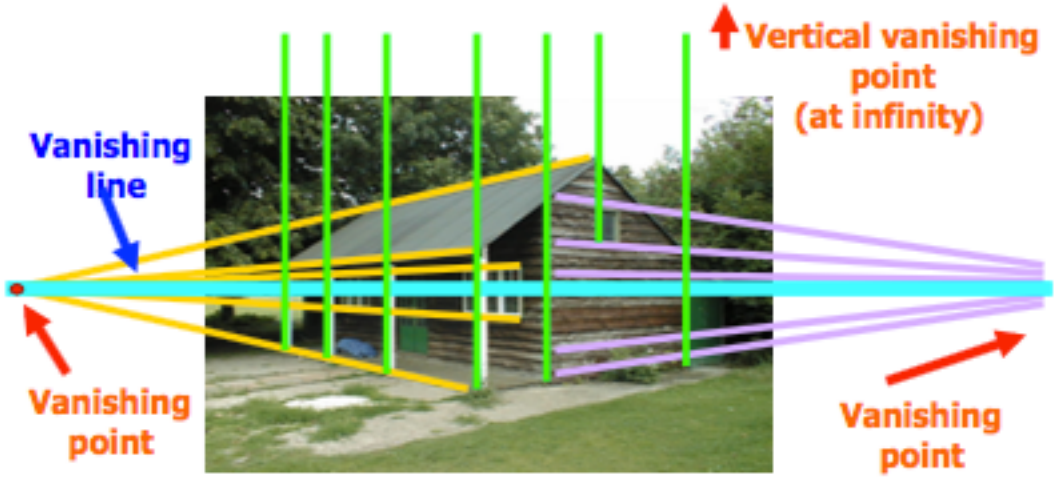

Origens da detecção de bordas

- Descontinuidade de superfície
- Descontinuidade de profundidade
- Descontinuidade de cor de superfície
- Descontinuidade de iluminação

Descontinuidade de Superfície

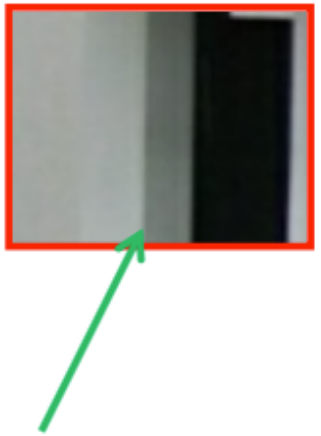

Descontinuidade de Profundidade

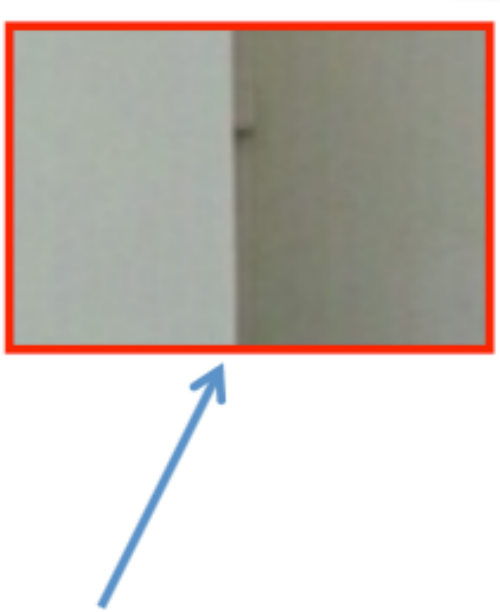

Descontinuidade de Superfície

O que são bordas?

- Local na imagem onde aconteceu rápida mudança de tonalidades

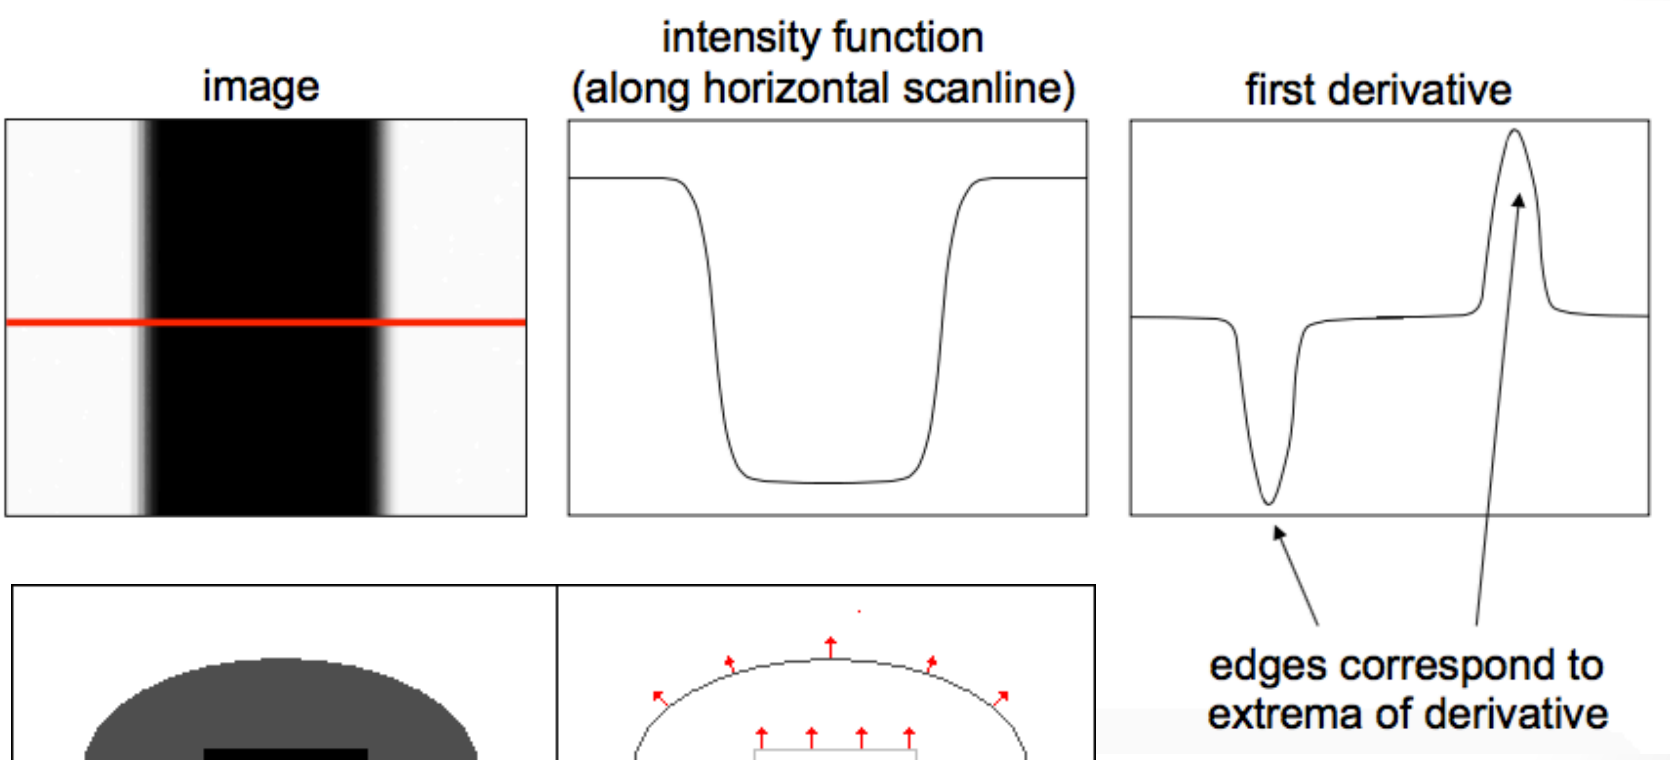

Gradiente de uma imagem

- O gradiente de uma imagem é a derivada no ponto

$$\nabla f = [\frac{\partial f}{\partial x}, \frac{\partial f}{\partial y}]$$

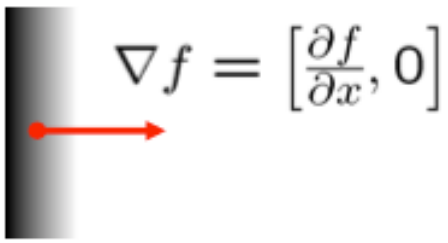

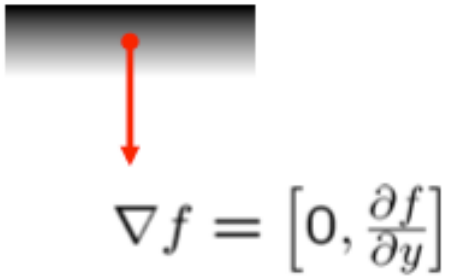

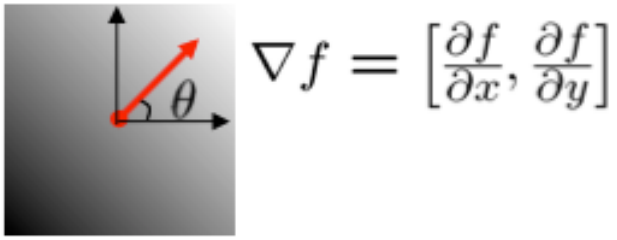

Gradiente de uma imagem

- A força (magnitude) de um gradiente é dado por:

$$\|\nabla f\| = \sqrt{\left(\frac{\partial f}{\partial x}\right)^2 + \left(\frac{\partial f}{\partial y}\right)^2}$$

  - Representa a força direcional num ponto (x,y)
- A orientação do gradiente é dada por:

$$\theta = \tan^{-1}\left(\frac{\partial f}{\partial y} / \frac{\partial f}{\partial x}\right)$$

  - Representa a orientação da borda no ponto (x, y)

Gradiente de uma imagem

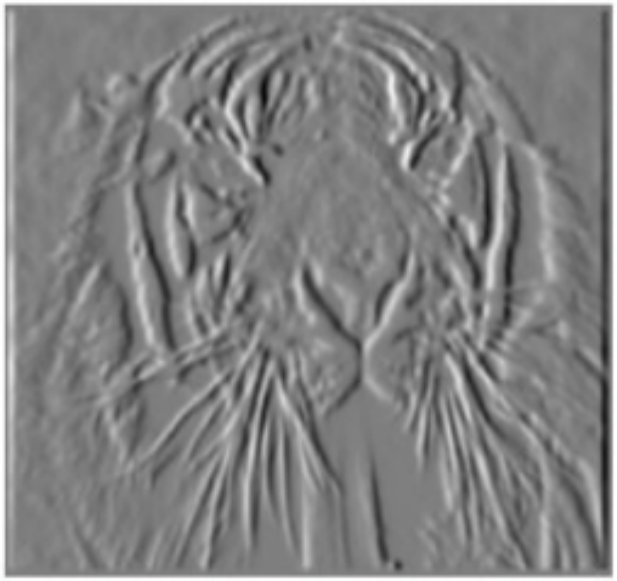

X

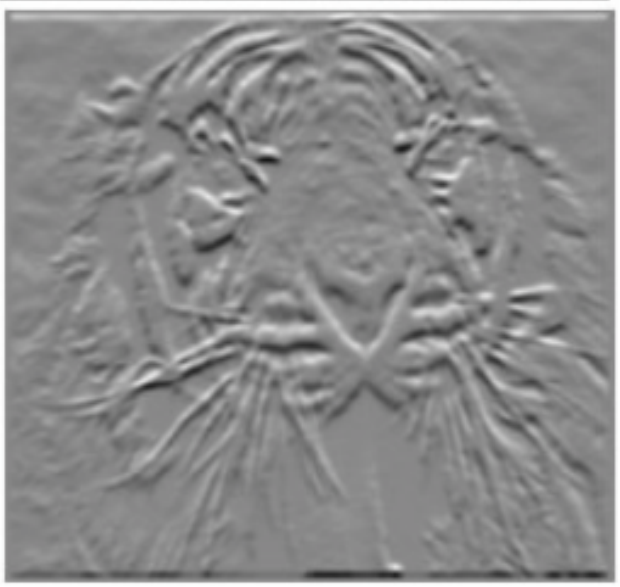

Y

Magnitude do gradiente

Efeitos causados por ruídos

- Onde está o contorno?

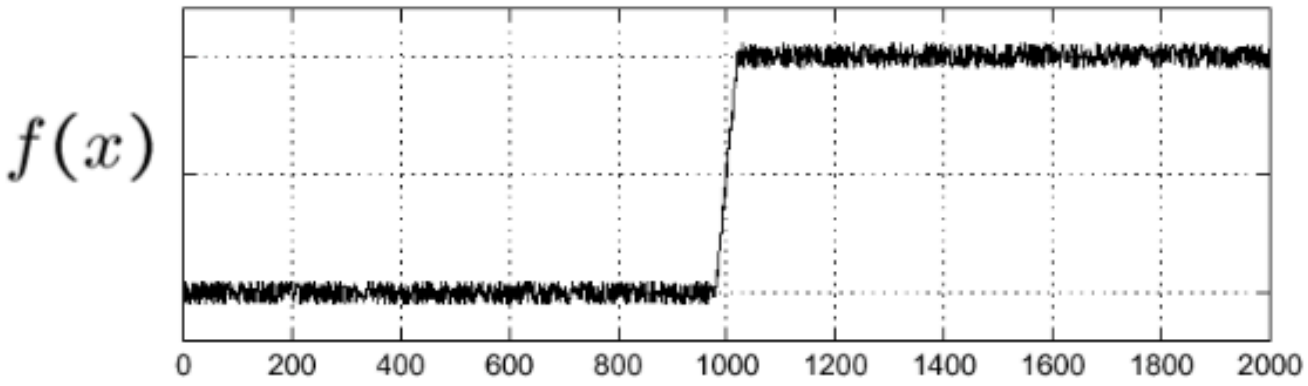

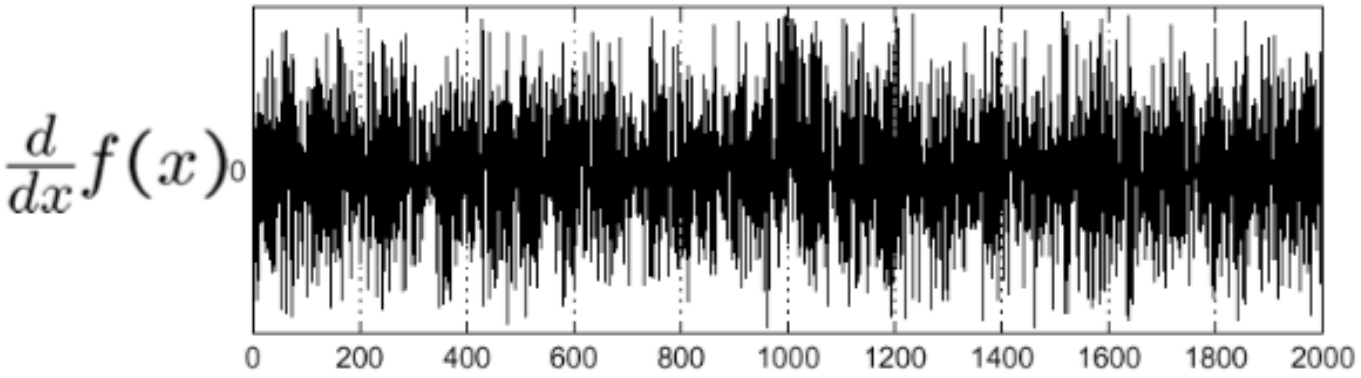

Efeito dos ruídos: o que fazer?

- O ruído faz com que bordas não sejam corretamente obtidas:
  - Pixels muito próximos possuem comportamentos aleatório
  - Mudanças súbitas de cor

- O que pode ser feito?
  - Remover ruídos com filtros passa baixa

Filtre Primeiro: Gaussiano

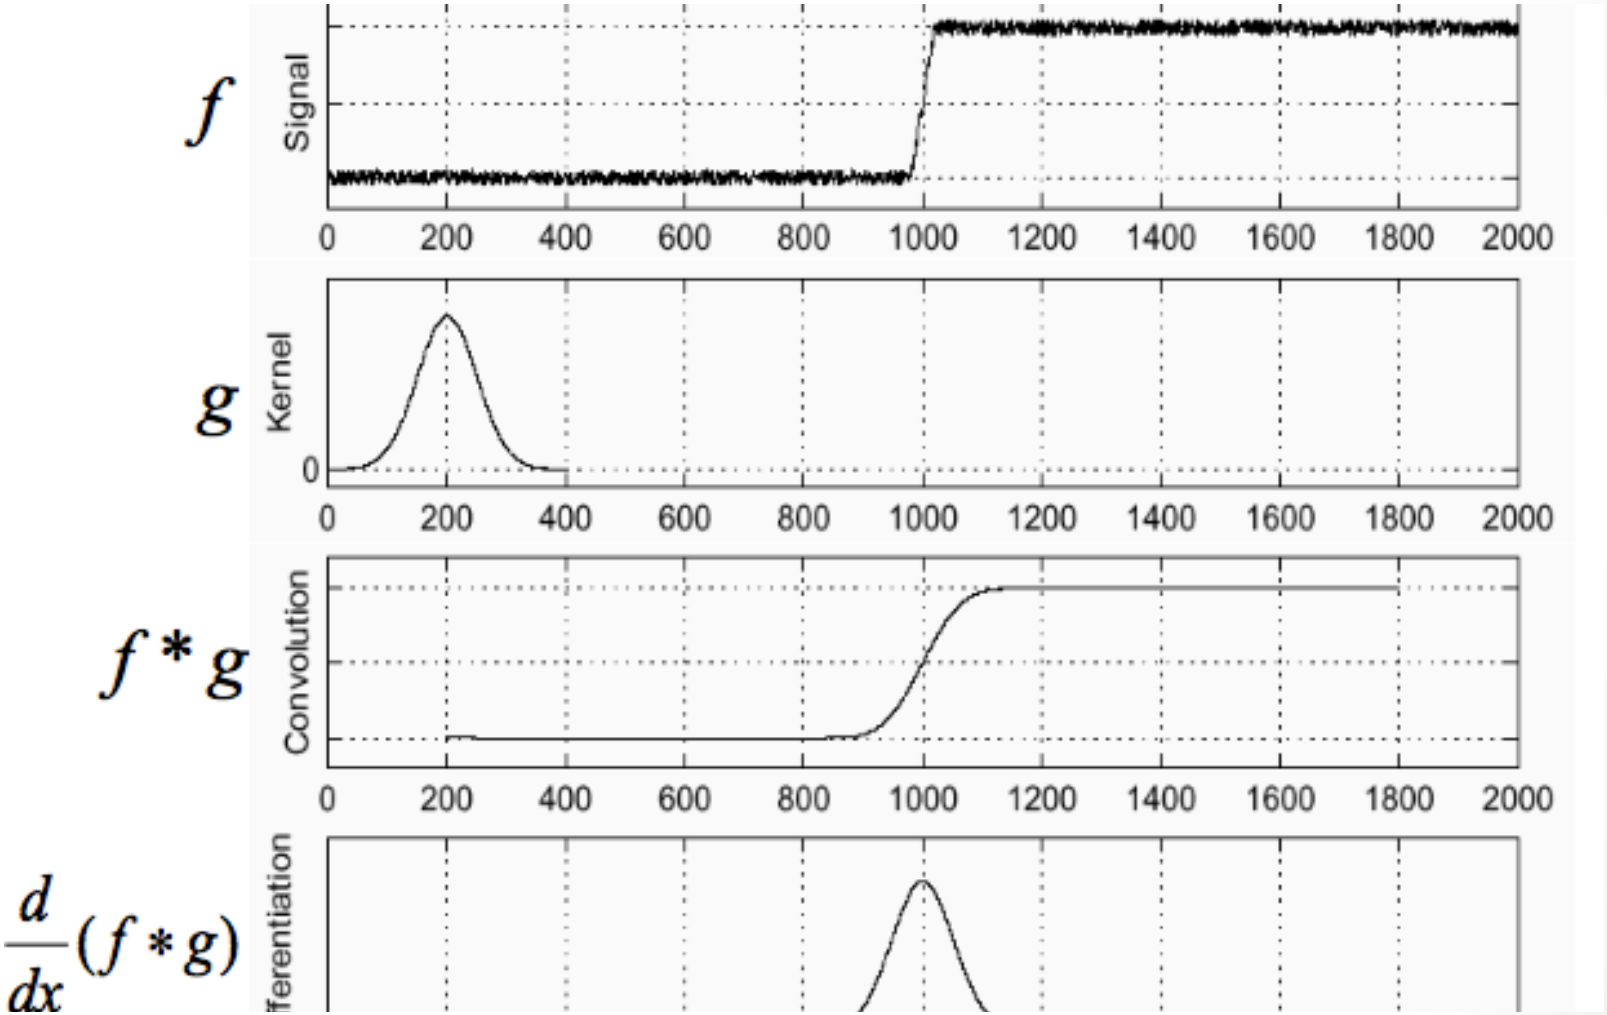

Custo associado

- A medida que se suaviza, as bordas também podem ser eliminadas! Cuidado

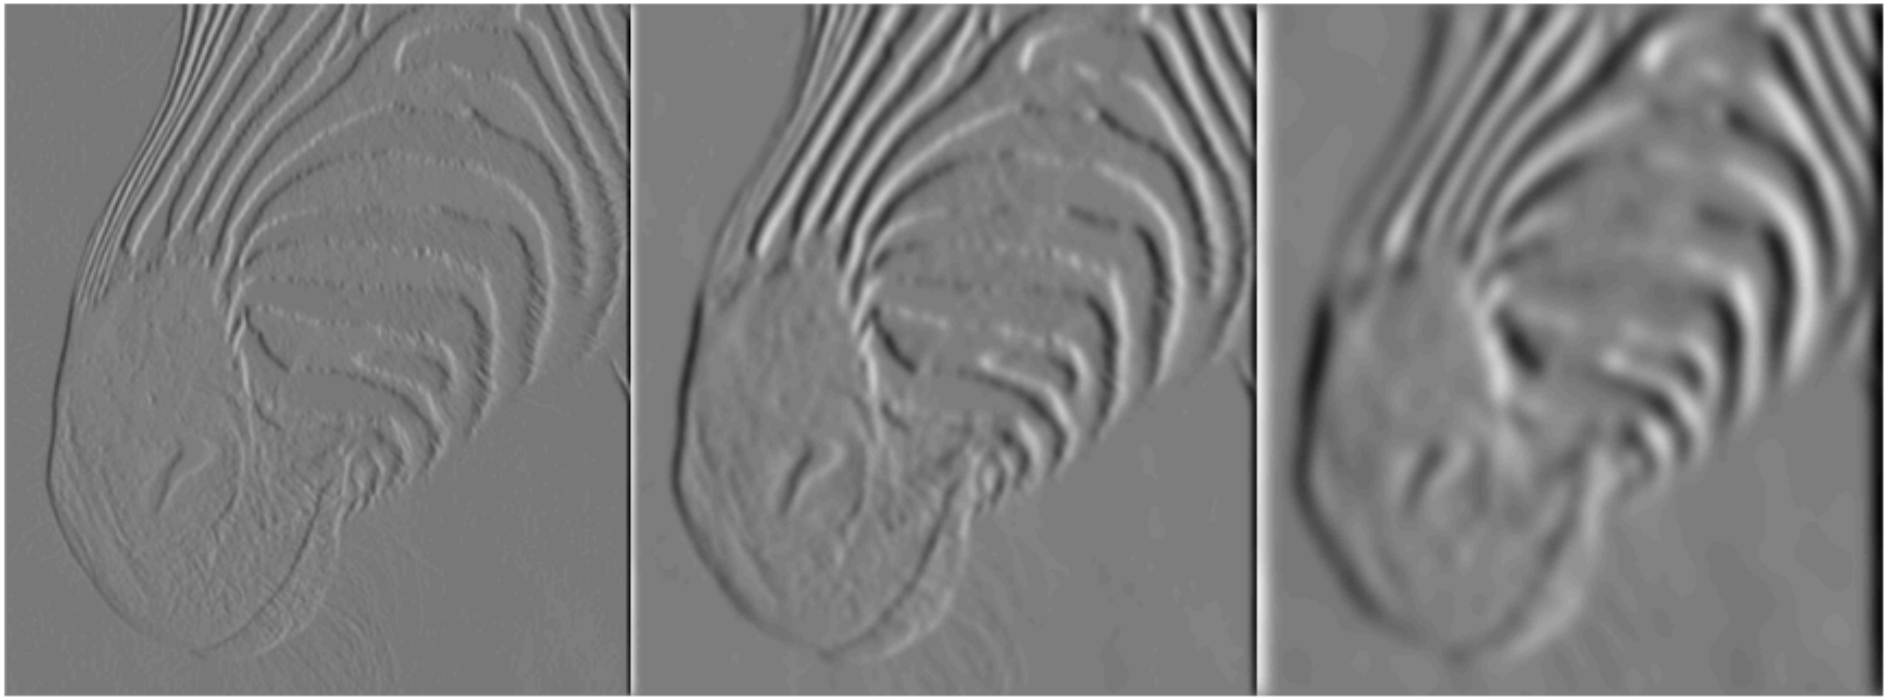

1 pixel 3 pixels 7 pixels

Implementação de Detectores de Borda

- Somente o gradiente?

Gera contornos grossos, mas

este não é o verdadeiro contorno

O que seria um bom detector?

- Precisa satisfazer 3 propriedades:
  - detecção: minimizar falso positivos
  - localização: devem estar ou ser a própria borda
  - resposta atômica: o mínimo possível de contornos

Quais as opções?

a) Roberts
b) Prewitt
c) Sobel
d) Canny
e) Laplaciano

Roberts: primeira derivada

- Método simples
  - Sensível a ruído
  - Melhor aplicado em imagens binárias
- Máscaras

$$h_1(i,j) = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix} \quad h_2(i,j) = \begin{bmatrix} 0 & 1 \\ -1 & 0 \end{bmatrix}$$

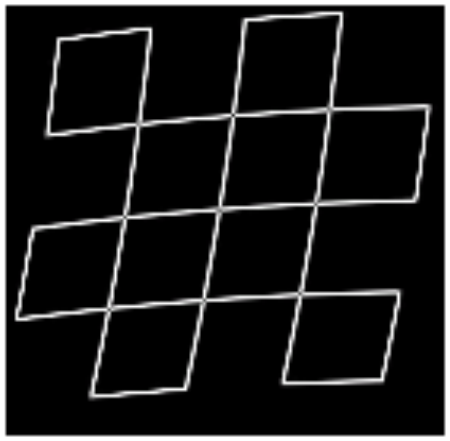

Prewitt: primeira derivada, compass

- Derivadas parciais realizadas nas 8 direções básicas

$$h_1(i,j) = \begin{bmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix} \quad h_2(i,j) = \begin{bmatrix} 0 & 1 & 1 \\ -1 & 0 & 1 \\ -1 & -1 & 0 \end{bmatrix} \quad h_3(i,j) = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix} \quad h_4(i,j) = \begin{bmatrix} -1 & -1 & 0 \\ -1 & 0 & 1 \\ 0 & 1 & 1 \end{bmatrix}$$

$$h_5(i,j) = \begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix} \quad h_6(i,j) = \begin{bmatrix} 0 & -1 & -1 \\ 1 & 0 & -1 \\ 1 & 1 & 0 \end{bmatrix} \quad h_7(i,j) = \begin{bmatrix} 1 & 0 & -1 \\ 1 & 0 & -1 \\ 1 & 0 & -1 \end{bmatrix} \quad h_8(i,j) = \begin{bmatrix} 1 & 1 & 0 \\ 1 & 0 & -1 \\ 0 & -1 & -1 \end{bmatrix}$$

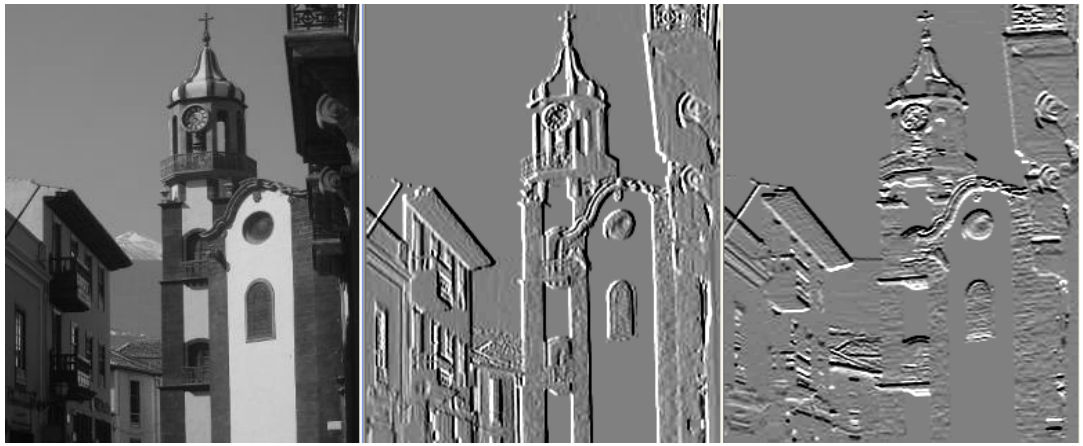

H3 H1

Sobel: primeira derivada, compass (H / V)

$$h_1(i,j) = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix} \quad h_3(i,j) = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}$$

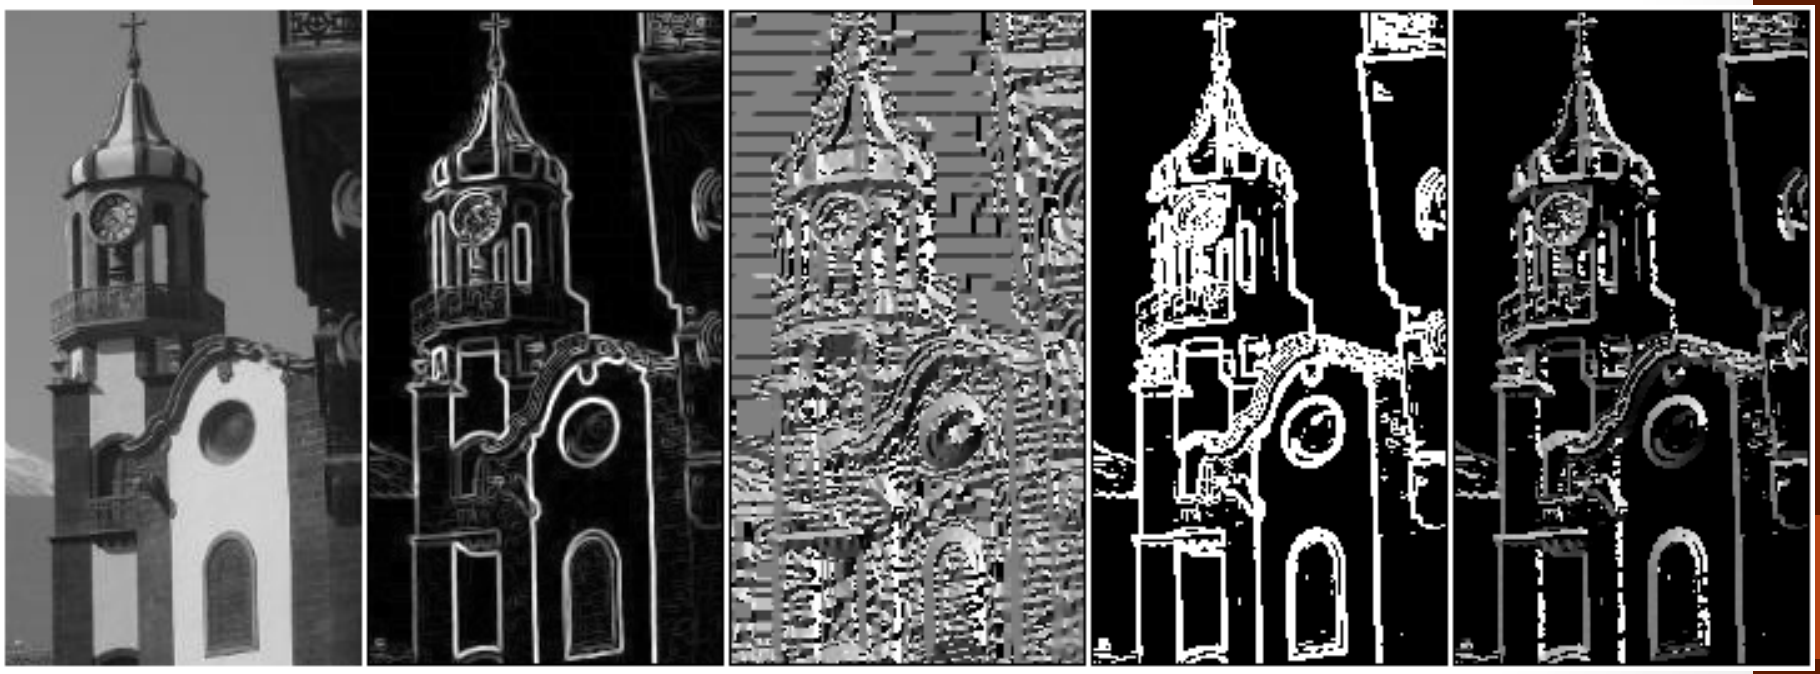

Canny

- Baseado em sucessivas Gaussianas (ou usando gaussianas como complementar)
- Canny demonstra que a primeira derivada da gaussiana aproxima com alta precisão a **detecção** de bordas, com as propriedades de **localização** e **atomicidade**
- Primeira derivada de uma gaussiana, poque?

$$\frac{d}{dx}(f * g) = f * \frac{d}{dx} g$$

Primeira Derivada de uma Gaussiana

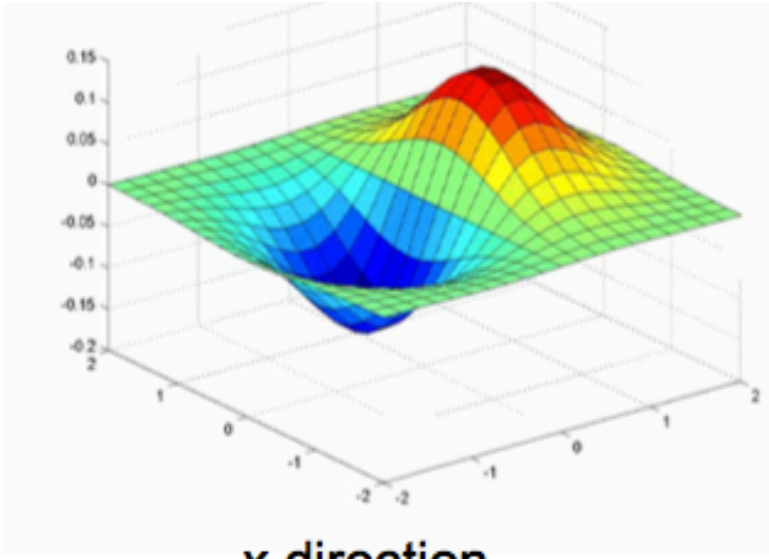

x-direction

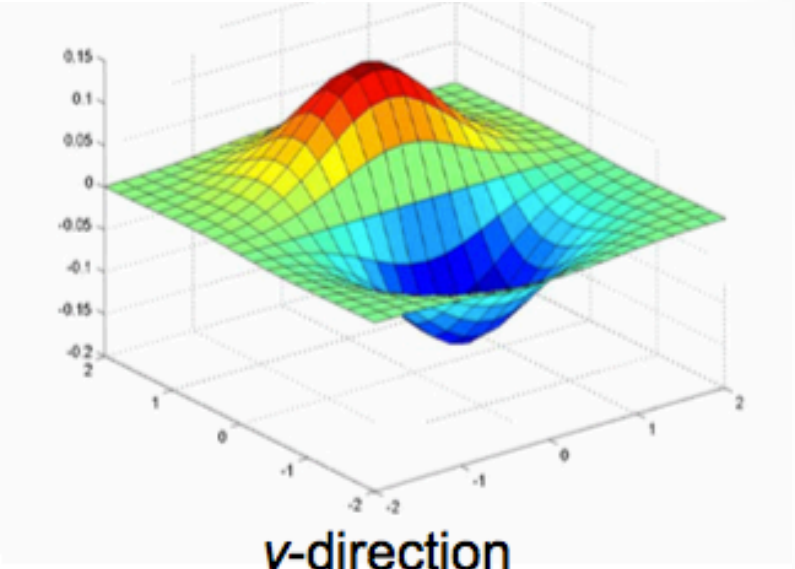

y-direction

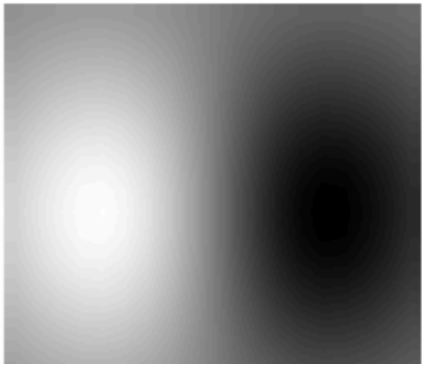

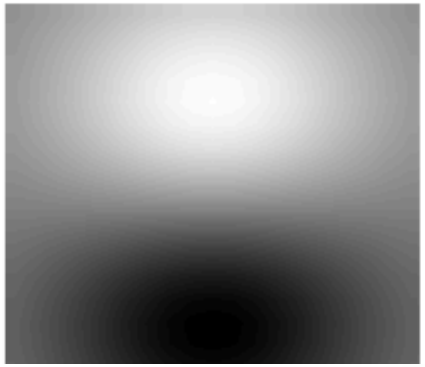

Passo a Passo do Canny

1. Filtre x, y com as derivadas do Gaussiano
2. Obtenha magnitude e orientação
3. Aplique a regra **Non-Maximum-Suppression**
4. **Threshold** e **hysteresis**
   - Defina duas faixas: inferior e superior
   - Use o superior para iniciar os contornos e o inferior para garantir continuidade

Gradiente por gaussiana

X-Derivative of Gaussian

Y-Derivative of Gaussian

Gradient Magnitude

Orientações

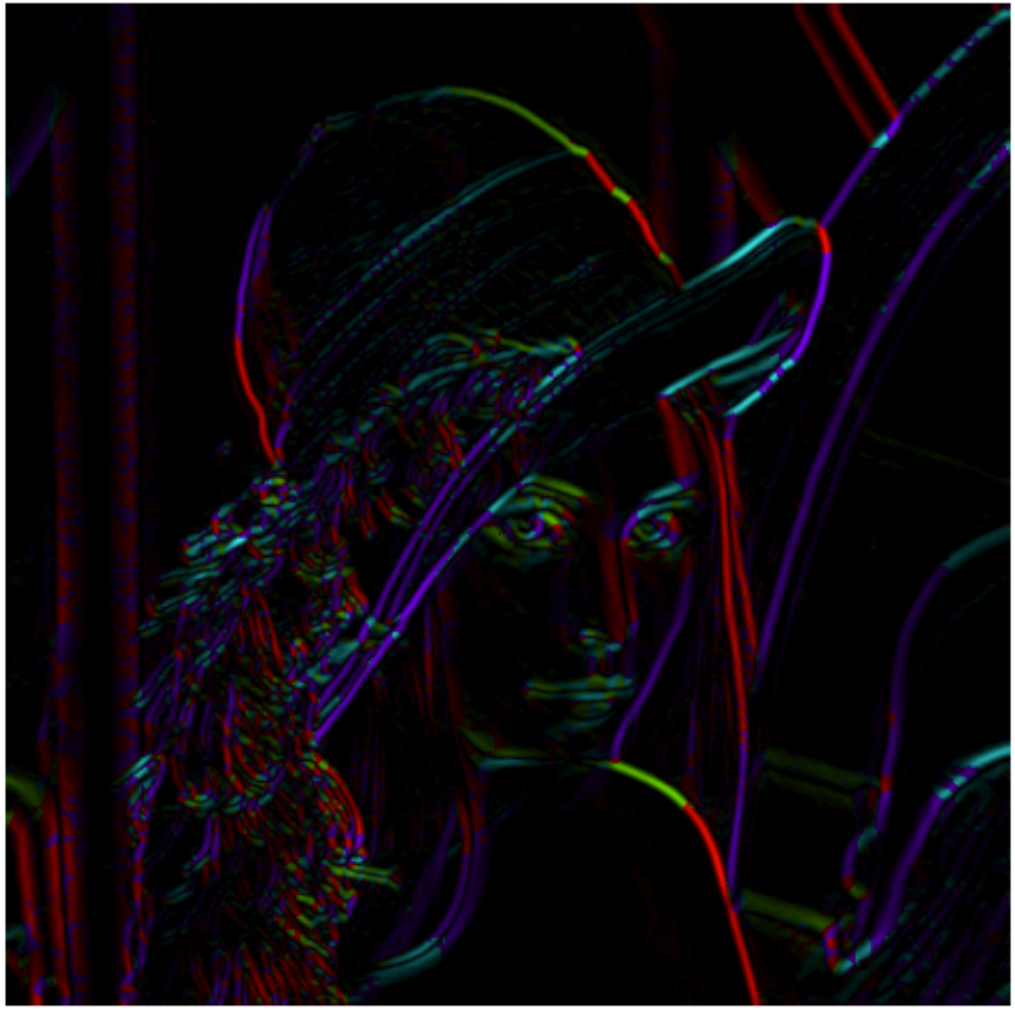

Non-Maximum-Suppression

- Quantize as orientações dada pelos contornos
- Para cada pontos Q
  - Obtenha dois pontos ortogonais (P e R)
  - Se o Q for menor que P e R
    - Elimine Q

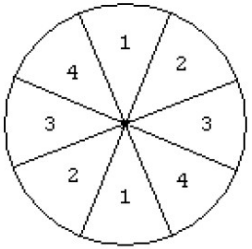

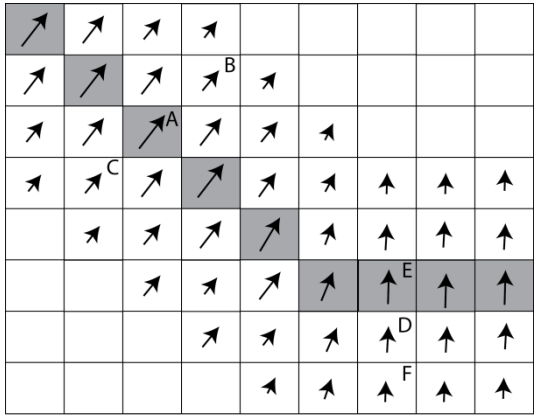

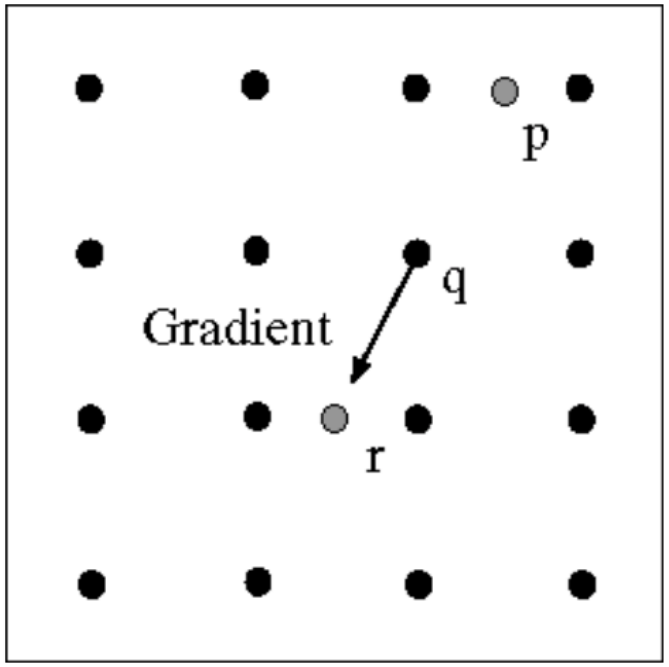

Non-Maximum-Suppression

Antes

Depois

Thresholding por Hysteresis

- Elimina valores baixos e altos
- Objetivo é **remover** pixels **fracos** demais e **fortes** demais

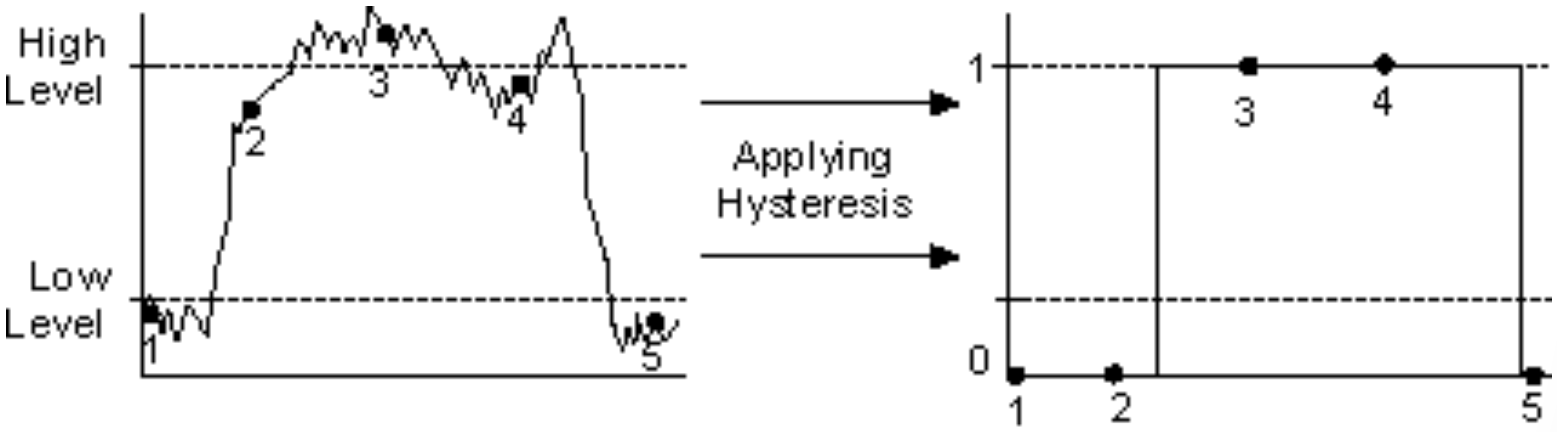

- Use os pixels de alto valor para começar o contorno e pixels de baixo valor para continuá-los

Resultado do Canny

Efeitos do Kernel Gaussiano

- Quanto **maior o desvio, menor será a quantidade de detalhes capturada**

original

Canny with $\sigma = 1$

Canny with $\sigma = 2$

Outro exemplo

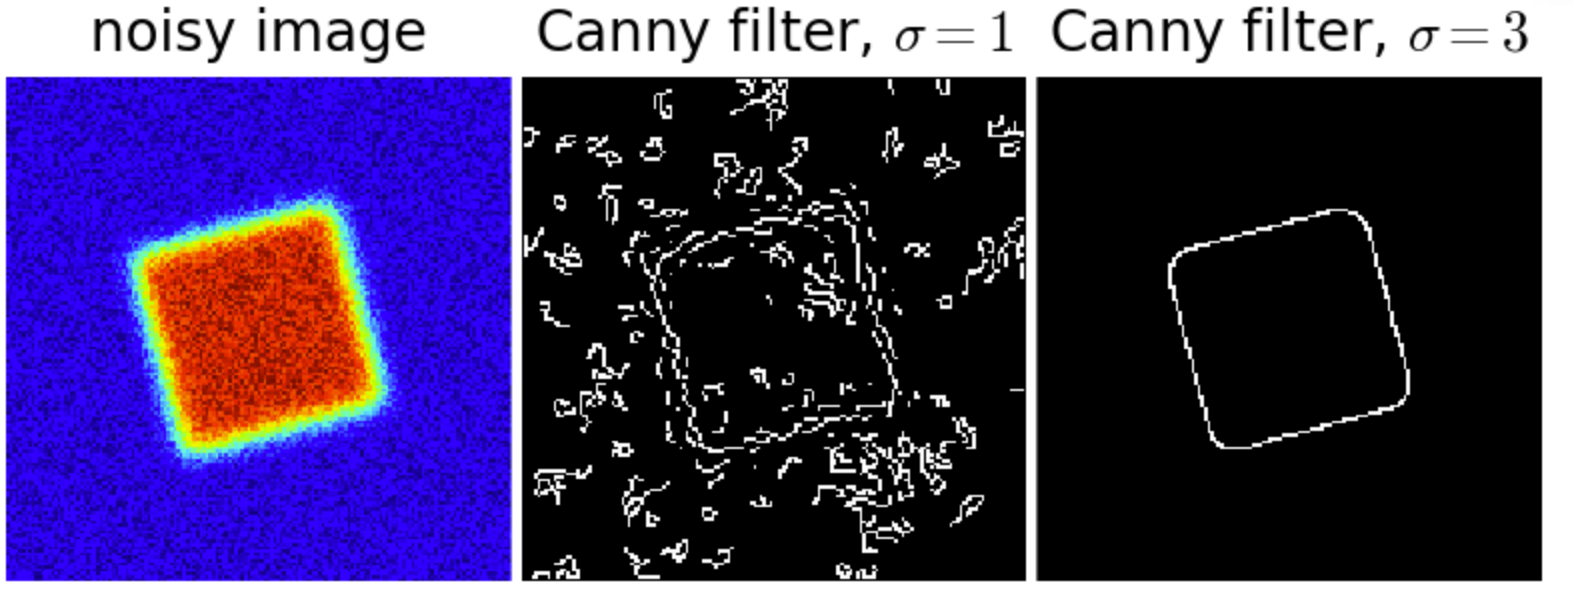

Laplaciano: derivada segunda

- Mede a curvatura de uma imagem
- Independente de orientação
- Determina a magnitude do gradiente
- Zero-Crossing

$$laplace\,(I) = \frac{\partial^2 I}{\partial x^2} + \frac{\partial^2 I}{\partial y^2}$$

$$h(i,j) = \begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix} \quad h(i,j) = \begin{bmatrix} 2 & -1 & 2 \\ -1 & -4 & -1 \\ 2 & -1 & 2 \end{bmatrix}$$

Laplaciano

- Transição gradual entre **curvatura positiva** (quando a intensidade está chegando no seu limite) e curvatura negativa
- A transição é um bom indicador que existe uma borda
- Janela 2x2

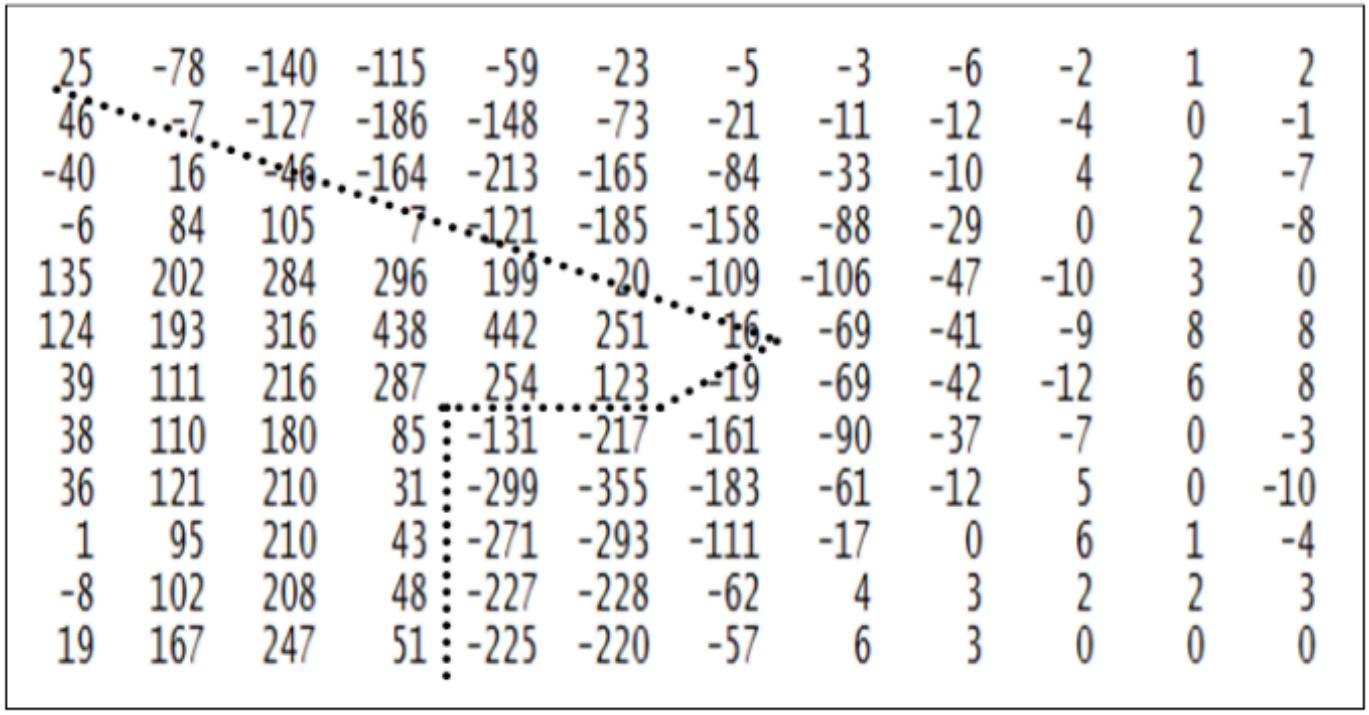

25	-78	-140	-115	-59	-23	-5	-3	-6	-2	1	2
46	-7	-127	-186	-148	-73	-21	-11	-12	-4	0	-1
-40	16	-46	-164	-213	-165	-84	-33	-10	4	2	-7
-6	84	105	7	-121	-185	-158	-88	-29	0	2	-8
135	202	284	296	199	20	-109	-106	-47	-10	3	0
124	193	316	438	442	251	16	-69	-41	-9	8	8
39	111	216	287	254	123	-19	-69	-42	-12	6	8
38	110	180	85	-131	-217	-161	-90	-37	-7	0	-3
36	121	210	31	-299	-355	-183	-61	-12	5	0	-10
1	95	210	43	-271	-293	-111	-17	0	6	1	-4
-8	102	208	48	-227	-228	-62	4	3	2	2	3
19	167	247	51	-225	-220	-57	6	3	0	0	0

Laplaciano

- Para aumentar a precisão pode ser obtido sobre a função Gaussiana

$$h(i,j) = c\left(\frac{i^2 + j^2 - \sigma^2}{\sigma^4}\right) e^{-\frac{i^2+j^2}{2\sigma^2}}$$

- Filtro Mexican Hat

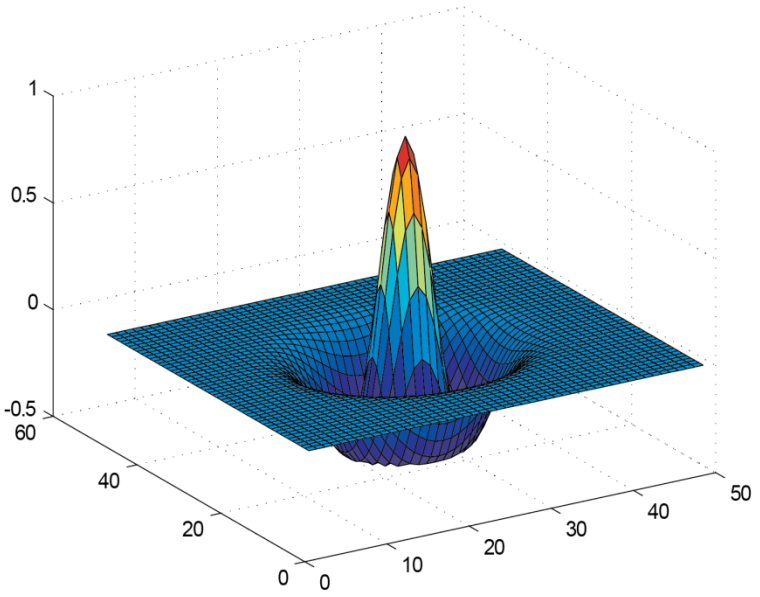

Laplaciano

- Pros e Contras do Laplaciano com Gaussiano (Semelhança com Canny?)