

# Restauração de Imagem e redução de ruído

# Aplicações

---

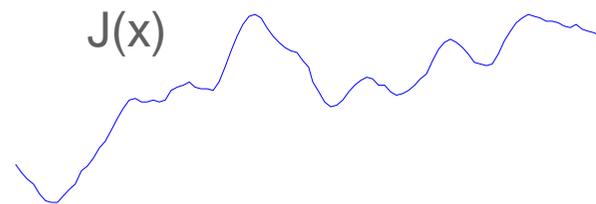
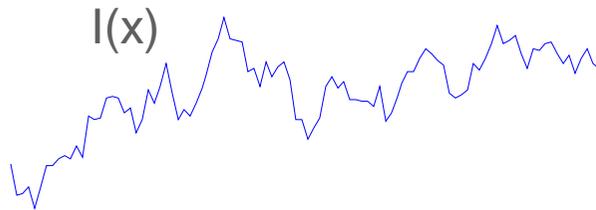
- imagem médica
- recuperação de imagens degradadas
- super-resolução
- compressive sensing

# Degradação de imagem

---



$$J(x, y) = \int_0^{\Delta x} I(x + d, y) dd$$



há perda de informação

# Modelo

---

$$J = T(I) + W$$

I imagem ideal :  $I \in \mathbb{R}^{MN \times 1}$   
J imagem observada:  $J \in \mathbb{R}^{MN \times 1}$   
W imagem de ruído:  $W \in \mathbb{R}^{MN \times 1}$

T(.) operador  $T: \mathbb{R}^{MN \times 1} \rightarrow \mathbb{R}^{MN \times 1}$

modelo linear

$$J = HI + W$$

# Problema

---

**Problema [restauração]:** dada a imagem  $J=T(I)+W$ , obter a imagem  $I$

**Problema [redução de ruído]:** dada a imagem  $J=I+W$ , obter a imagem  $I$

dificuldades:

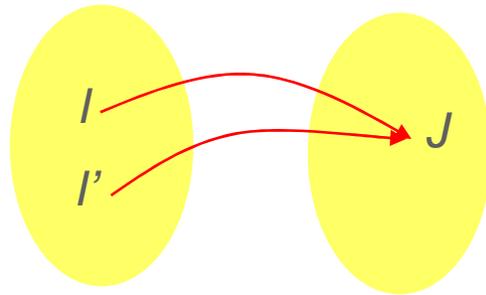
$T$  é não invertível ou mal condicionado numericamente ( $J=T(I)$  tem um número infinito de soluções)

Não há critério para separar  $T(I)$  de  $W$ ?

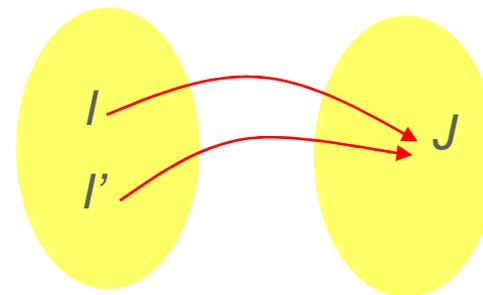
problema inverso

# Problema inversos

---



não invertível



mal condicionado

# Solução

---

## métodos determinísticos

como a equação  $T(I)=J$  tem um número infinito de soluções, impõem-se condições adicionais (suavidade) à solução.

métodos de regularização

## métodos probabilísticos

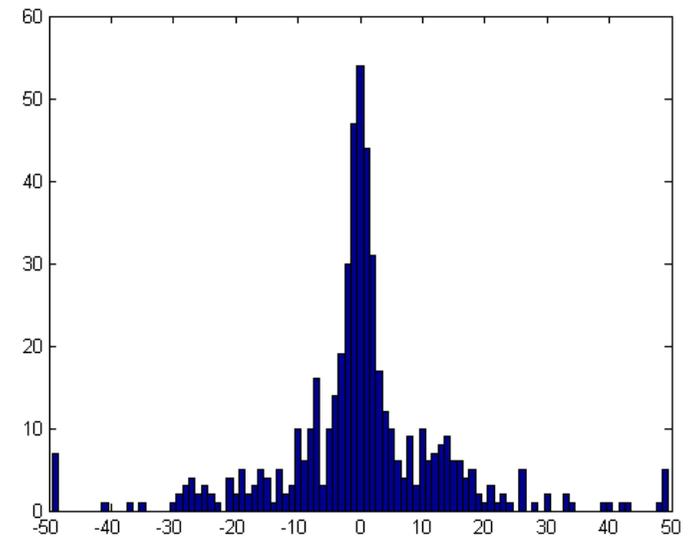
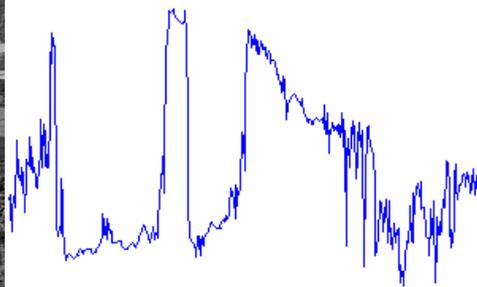
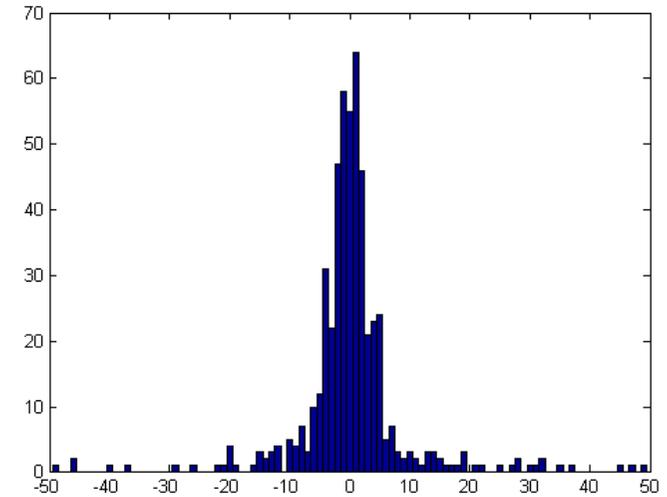
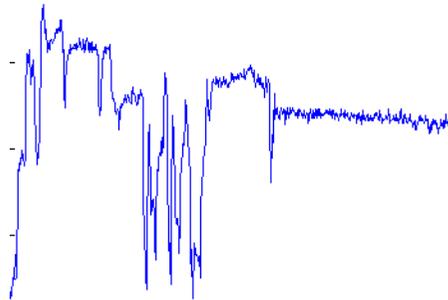
interpretar o cálculo de  $I$  como um problema de inferência estatística

# Condição de suavidade

---



primeira diferença



# Regularização de Tikhonov

---

ajuste do modelo aos dados

$$\varepsilon = \|J - HI\|^2$$

as duas normas estão definidas em espaços diferentes e podem ser diferentes

condição de suavidade

$$\delta = \|DI\|^2$$

a escolha mais comum é a norma euclidiana ( $l^2$ ).

pretende-se minimizar a condição de suavidade sob a hipótese de  $\varepsilon$  ser pequeno.

$$E = \|J - HI\|^2 + \lambda \|DI\|^2$$

$\lambda$  mede o compromisso entre o ajuste aos dados e suavidade.

# Solução com norma $l^2$

---

$$E = (J - HI)^T (J - HI) + \lambda I^T D^T D I$$

derivando

$$\frac{dE}{dI} = -2H^T (J - HI) + 2\lambda D^T D I = 0$$

$$(H^T H + \lambda D^T D)I = H^T J$$

sistema linear de equações (de muito grande dimensão)

# Algoritmo recursivo

---

Como resolver um sistema de grande dimensão  $Mx=y$  ?

$$y = Mx$$

$$x = x + \alpha(y - Mx)$$

## Recursão

$$x^t = x^{t-1} + \alpha(y - Mx^{t-1})$$

$$x^t = \alpha y + (I - \alpha M)x^{t-1}$$

$$x^t = Tx^{t-1}$$

$$Tx = \alpha y + (I - \alpha M)x$$

Nota: em problemas de restauração a multiplicação de  $x$  por  $M$  é uma operação de filtragem.

# Convergência

---

Há garantia de convergência se o operador T for uma contracção.

$$\|Tx - Tx'\| < k \|x - x'\| \quad k < 1$$

Se for usada a norma  $l^2$  então a condição anterior é equivalente a

$$\max_i |1 - \alpha \lambda_i(M)| < 1$$

Ver detalhes em Katsaggelos, Iterative image restoration algorithms, 1998.

## Algoritmo recursivo (2)

---

Pode haver dificuldade de convergência se  $M$  tiver valores próprios positivos e negativos. Essa dificuldade pode ser ultrapassada fazendo

$$M^T y = M^T Mx$$

$$x = x + \alpha M^T (y - Mx)$$

### Recursão

$$x^t = x^{t-1} + \alpha(M^T y - M^T Mx^{t-1})$$

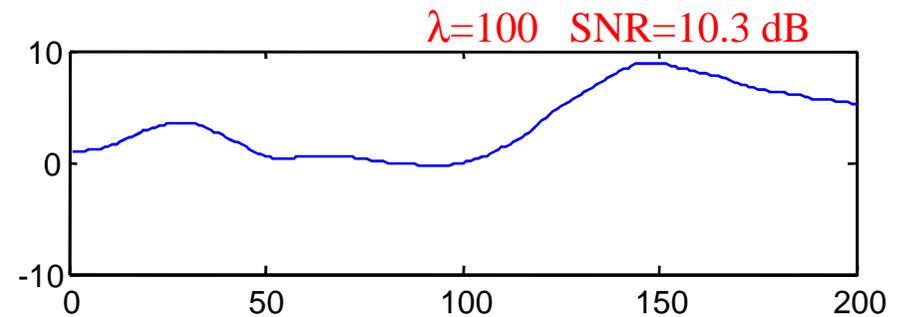
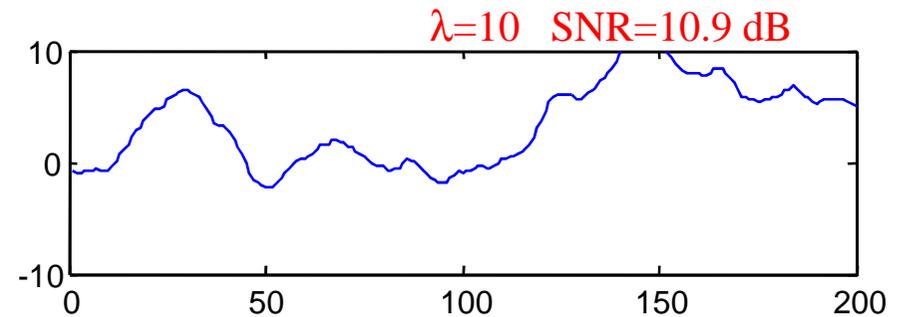
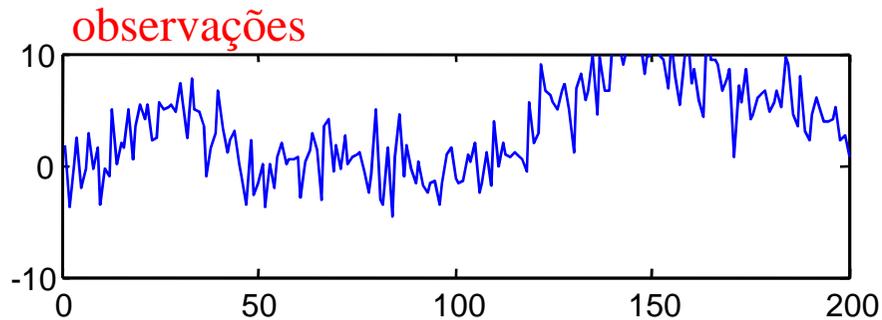
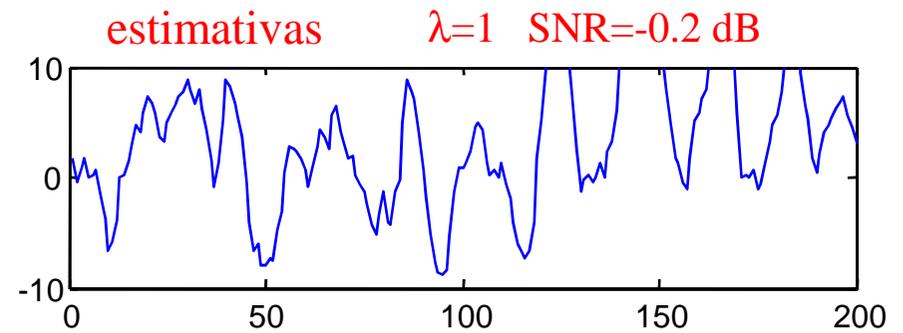
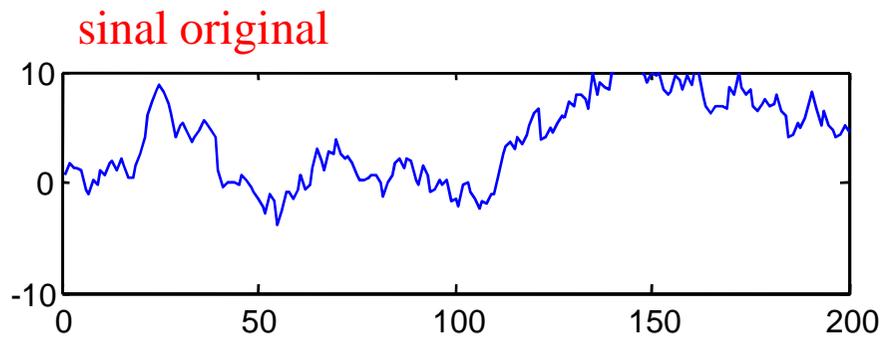
$$x^t = \alpha M^T y + (I - \alpha M^T M)x^{t-1}$$

### Convergência

$$\max_i |1 - \alpha \lambda_i(M^T M)| < 1$$

# Exemplo

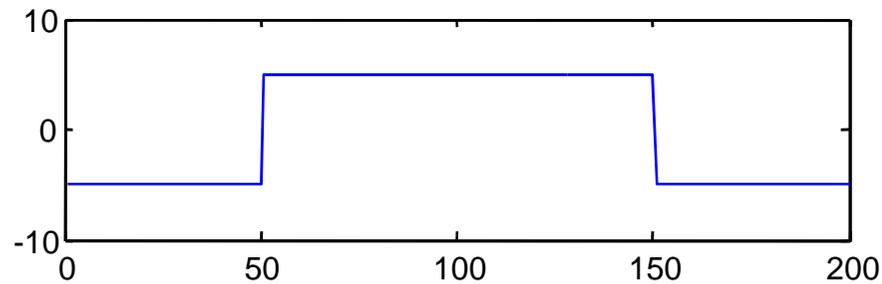
---



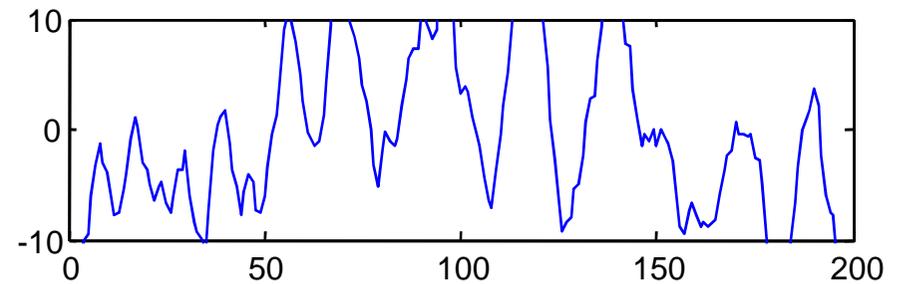
# Transições abruptas

---

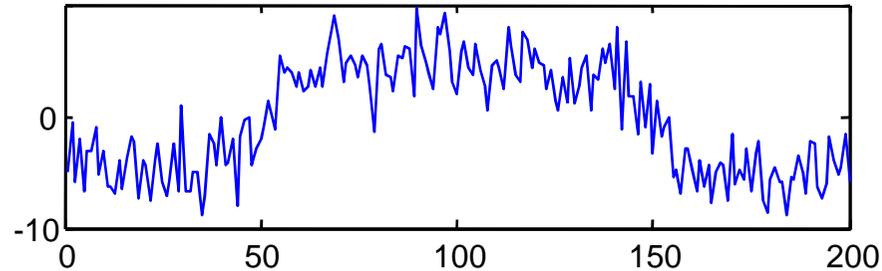
sinal original



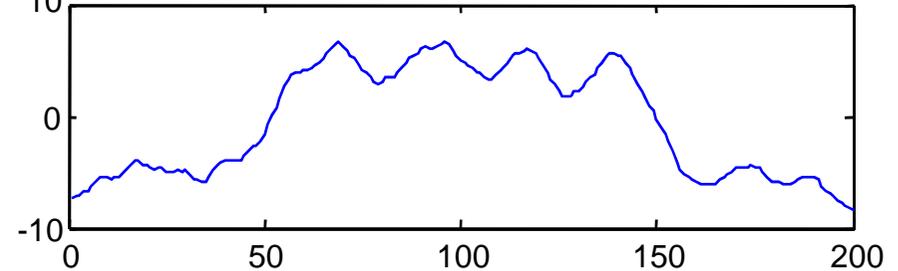
estimativas  $\lambda=1$  SNR=-1.2 dB



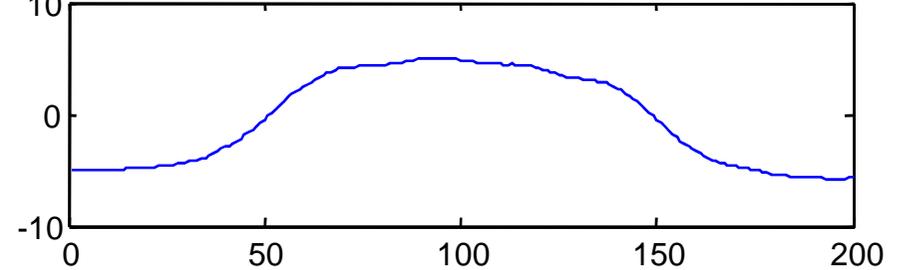
observações



$\lambda=10$  SNR=9.8 dB

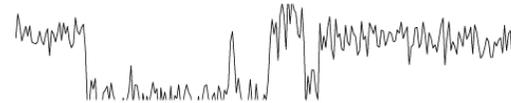


$\lambda=100$  SNR=8.7dB





SNR=13.0dB



$\alpha=1$   
SNR=17.6dB



$\alpha=8$   
SNR=18.5dB



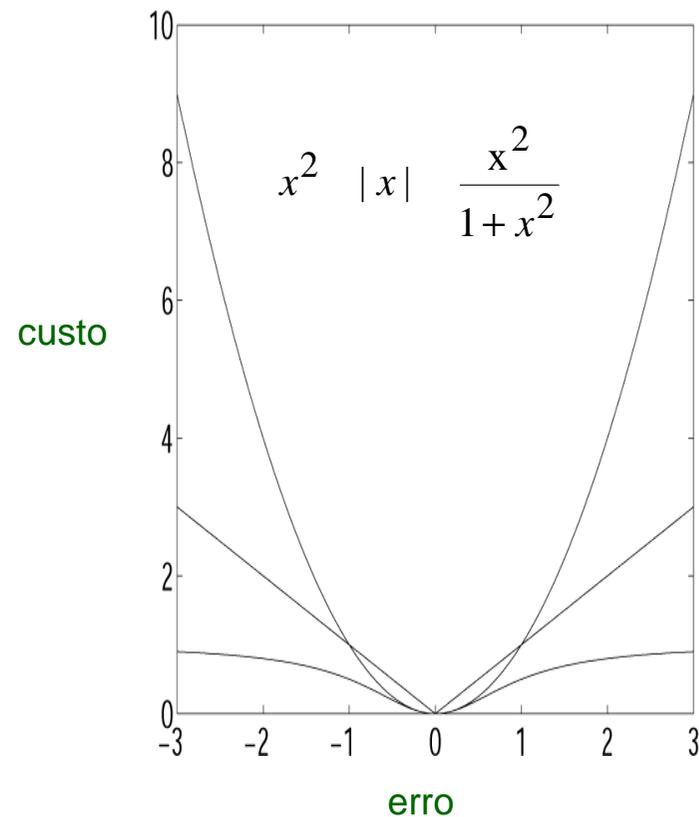
# Preservação de contornos

---

Os métodos anteriores reduzem o ruído **destruindo os contornos**.

Será possível reduzir o ruído preservando os contornos?

**Ideia:** transições de grande amplitude devem autorizadas.



# Regularização com norma $l_1$

---

Energia (caso 1D)

$$E = \|J - HI\|^2 + \lambda \sum_{i=2}^n |l(i) - l(i-1)| + \rho |l(1)|$$

$J \in \mathbb{R}^n$ ,  $l \in \mathbb{R}^m$   
A matriz  $m \times n$ ,

norma em J: euclidiana

norma  $l_1$

A minimização de E é um problema de **otimização não linear**.

Conversão num problema quadrático

$$E = \|J - HI\|^2 + \lambda \sum_{i=2}^n w(i) l^2(i) + \rho w(1) l(1)^2,$$

$$w(i) = \frac{1}{|l(i) - l(i-1)| + \varepsilon}, \quad i > 1 \quad \text{e} \quad w(1) = \frac{1}{|l(1)| + \varepsilon}$$

Os pesos dependem do sinal reconstruído !

recursão

# Regularização: norma l1

---

Algoritmo recursivo

$$(H^T H + \lambda Q^j) I^j = H^T J \quad j = 1, 2, 3, \dots$$

em que

$$Q^j = \begin{bmatrix} w_2^j + \rho & -w_2^j & 0 & 0 & \dots & 0 \\ -w_2^j & w_2^j + w_3^j & -w_3^j & 0 & \dots & 0 \\ 0 & -w_3^j & w_3^j + w_4^j & -w_4^j & & \\ \dots & & & \dots & \dots & \\ \dots & & & \dots & \dots & \\ 0 & & 0 & -w_{n-1}^j & w_{n-1}^j + w_n^j & -w_n^j \\ 0 & & 0 & 0 & -w_n^j & -w_n^j \end{bmatrix}$$

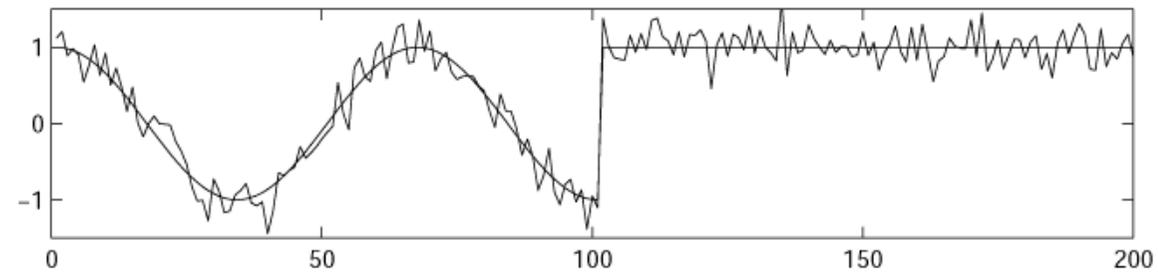
$$w_i^j = \frac{1}{|l_i^j - l_{i-1}^j| + \epsilon} \quad i > 1$$

$$w_1^j = \frac{1}{|l_1^j| + \epsilon}$$

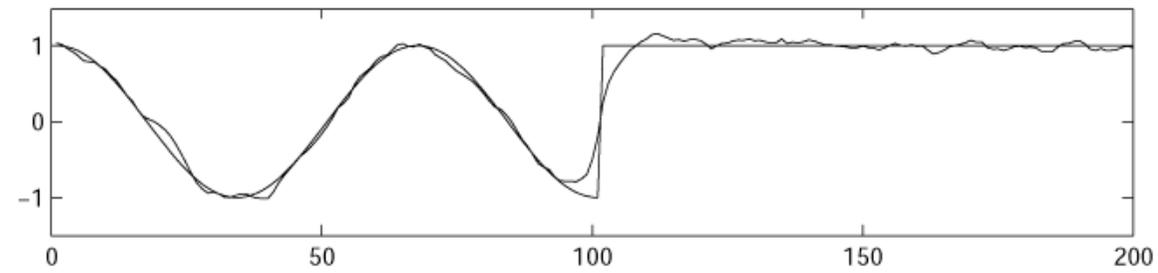
# Exemplo

---

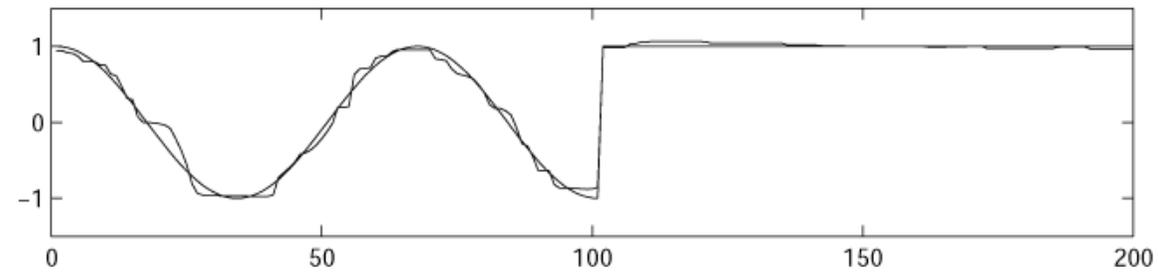
observações



norma euclidiana  
SNR=17dB



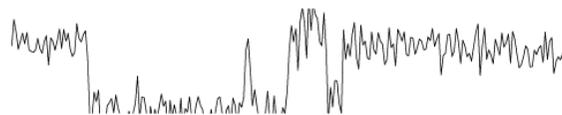
norma  $l_1$   
SNR=21.7dB



# Exemplo

---

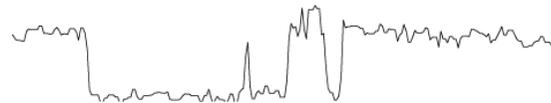
original



norma euclidiana  
SNR=18,6dB



norma  $l_1$   
SNR=19.3dB



# Redução de ruído: método de máxima verosimilhança

---

Admitamos que a degradação é linear e que o ruído é branco e gaussiano.

$$J = I + W \quad W \sim N(0, \sigma^2)$$

$I$  representa a imagem ou a matriz identidade dependendo do contexto.

Pretende-se estimar  $I$  dado  $J$ .

## Função de verosimilhança logarítmica

$$l(I) = \log p(J | I)$$

$$l(I) = \log \prod_{ij} p(J_{ij} | I_{ij}) = \sum_{ij} \log p(J_{ij} | I_{ij})$$

$$l(I) = C - \frac{1}{2\sigma^2} E(I) \quad E(I) = \sum_{ij} (J_{ij} - I_{ij})^2$$

solução (desilusão)

$$\hat{I} = J$$

# Crítica ao método de MV

---

Pretende-se decompor  $J$  na soma de  $I+W$ . Há infinitas maneiras de o fazer.

O método de máxima verosimilhança sugere a decomposição  $\hat{I}=J$  e  $W=0$  porque só usa um modelo para o ruído e não usa nenhum modelo para o sinal  $I$ .

Esta opção é a habitual nos métodos clássicos (não-bayesianos) de estimação: não se sabe nada acerca dos parâmetros antes de se observarem os dados.

**Solução:** usar um modelo para o sinal  $I$

Questão: como modelar a dependência entre pixels consecutivos?

# Modelo de Imagem (prior)

---

Um modelo simples consiste em admitir-se que as primeiras diferenças

$$\delta_1(m,n) = I(m,n) - I(m-1,n) \quad \delta_2(m,n) = I(m,n) - I(m,n-1)$$

têm distribuição normal  $N(0, \sigma_0^2)$  e são independentes

Seja  $D$  o operador que transforma o vector de imagem  $I$  no vector de primeiras diferenças

$$\delta = DI \quad \delta \sim N(0, \sigma_0^2 I)$$

Assim

$$p(\delta) = C e^{-\frac{1}{2\sigma_0^2} \delta^T \delta} \quad p(I) = C' e^{-\frac{1}{2\sigma_0^2} I^T D^T D I}$$

# Redução de ruído: método MAP

---

**Critério:** achar a imagem mais provável, maximizando

$$p(I | J) = K p(J | I)p(I)$$

modelo dos dados (gaussiano):  $p(J | I) = C e^{-\frac{1}{2\sigma^2}\|J-I\|^2}$

modelo da imagem (gaussiano):  $p(I) = C' e^{-\frac{1}{2\sigma_0^2}\|DI\|^2}$

Distribuição a posteriori:  $p(I | J) = c e^{-\frac{1}{2\sigma^2}\|J-I\|^2} e^{-\frac{1}{2\sigma_0^2}\|DI\|^2}$

# Redução de ruído: método MAP

---

Critério a otimizar

$$\log p(I | J) = C - \frac{1}{\sigma^2} \| J - I \|^2 - \frac{1}{\sigma_0^2} \| DI \|^2$$

otimização

$$\frac{d}{dI} \log p(I | J) = 0 \quad \Rightarrow \quad \frac{1}{\sigma^2} (J - I)^T (J - I) + \frac{1}{\sigma_0^2} I^T D^T DI = 0$$

$$\frac{2}{\sigma^2} (I - J) + \frac{2}{\sigma_0^2} D^T DI = 0 \quad \left( I + \frac{\sigma^2}{\sigma_0^2} D^T D \right) \hat{I} = J$$

matriz identidade

Conduz à resolução de um sistema linear de equações com tantas equações como pixels observados.

Não é realizável !!!

# Algoritmo recursivo

---

Critério a minimizar

$$\sum_x (J(x) - I(x))^2 + \alpha \sum_{x,y \in V} (I(x) - I(y))^2 \quad \alpha = \frac{\sigma^2}{\sigma_0^2}$$

Derivando em relação a  $I(x_0)$  vem

$$(I(x_0) - J(x_0)) + \alpha \sum_{y \in V_{x_0}} (I(x_0) - I(y)) = 0$$

$$(1 + \alpha N_x) I(x_0) = J(x_0) + \alpha \sum_{y \in V_{x_0}} I(y)$$

$$I(x_0) = \frac{J(x_0) + \alpha N_x \bar{I}(x_0)}{1 + \alpha N_x}$$

$$\bar{I}(x_0) = \frac{1}{N_{x_0}} \sum_{y \in V_{x_0}} I(y)$$

média na vizinhança 4 de  $x_0$

# Restauração de imagem: método MAP

---

**Critério:** achar a imagem mais provável, maximizando

$$p(I | J) = K p(J | I)p(I)$$

modelo dos dados (gaussiano):  $p(J | I) = C e^{-\frac{1}{2\sigma^2}\|J-HI\|^2}$

modelo da imagem (gaussiano):  $p(I) = C' e^{-\frac{1}{2\sigma_0^2}\|DI\|^2}$

Distribuição a posteriori:  $p(I | J) = c e^{-\frac{1}{2\sigma^2}\|J-HI\|^2} e^{-\frac{1}{2\sigma_0^2}\|DI\|^2}$

# Restauração de imagem: método MAP

---

Critério a otimizar

$$\log p(I | J) = C - \|J - MI\|^2 - \alpha \|DI\|^2$$

otimização

$$\frac{d}{dI} \log p(I | J) = 0 \Rightarrow (J - MI)^T (J - MI) + \alpha I^T D^T DI = 0$$

$$(M^T MI - M^T J) + \alpha D^T DI = 0$$

$$(M^T M + \alpha D^T D) \hat{I} = M^T J$$