

Deconvolución de imágenes: Aplicaciones de la SVD

Pablo Musé

`pmuse@fing.edu.uy`

Departamento de Procesamiento de Señales
Instituto de Ingeniería Eléctrica
Facultad de Ingeniería

5 de noviembre de 2012

Motivación

Todas las **imágenes** que adquirimos con un cámara, telescopio, microscopio, etc, son (en mayor o menor medida) **borrosas**

Causas extrínsecas

Mala utilización de la cámara, características de la escena


- ▶ Captura fuera de foco
- ▶ Solo cierto rango de profundidades en foco
- ▶ Vibración o movimiento de la cámara
- ▶ Movimiento de la escena




Causas intrínsecas a la cámara

Fenómenos ópticos y de construcción


- ▶ Difracción de la luz
- ▶ Aberraciones de los lentes
- ▶ Promediado en los captores



Difracción



Formación de imagen



Point Spread Function

Modelo de formación de la imagen (niveles de gris)

- ▶ **Dominio de la imagen:** $\Omega \subset \mathbb{R}^2$, típicamente **rectángulo**.
- ▶ **Imagen “verdadera”:** $f : \Omega \subset \mathbb{R}^2 \rightarrow \mathbb{R}$.
- ▶ **Point spread function** - respuesta a un fuente puntual, respuesta del sistema de adquisición: $h : \Omega \subset \mathbb{R}^2 \rightarrow \mathbb{R}$.
- ▶ **Ruido de adquisición** (fotónico, térmico, cuantificación): n (carácter aleatorio, cierto conocimiento estadístico).

Imagen observada o adquirida

$$g = h * f + n$$

En imágenes digitales

u, h, v, n definidos en una grilla rectangular de $L \times M = N$ pixels,
 $g(i, j) = (h * f)(i, j) + n(i, j)$.




vectorización \rightarrow $\mathbf{g} = \mathbf{A}\mathbf{f} + \mathbf{n}$, con $\mathbf{f}, \mathbf{g}, \mathbf{n} \in \mathbb{R}^{N \times 1}$, $\mathbf{A} \in \mathbb{R}^{N \times N}$.

Ejemplos de PSF y efectos




Original



Gaussiana isotrópica



Movimiento



Deconvolución

Objetivo

Dada la imagen observada g , recuperar la imagen original f .

Dos versiones del problema

- ▶ **Deconvolución ciega:** h es desconocido y se estima conjuntamente con f .
- ▶ **Deconvolución no ciega:** conocemos h (se calibra previamente; ejemplos: microscopía, astronomía). **HOY**

Solución naïve

$$\mathbf{f}_{\text{naïve}} = \mathbf{A}^{-1}\mathbf{g} = \mathbf{A}^{-1}\mathbf{A}\mathbf{f} + \mathbf{A}^{-1}\mathbf{n} = \mathbf{f} + \mathbf{A}^{-1}\mathbf{n}.$$



¿Tiene sentido? ¿Andará bien?

Solución naïve: resultados

Original f



Point spread function h



$h * f$



$$\mathbf{n} \sim \mathcal{N}(0, \sigma^2 \mathbf{I}_N)$$


$g(\sigma = 0)$




$f_{\text{naïve}}$



$g(\sigma = 0.01)$



$f_{\text{naïve}}$



Análisis de la solución naïve (1)

Descomposición SVD de $\mathbf{A} \in \mathbb{R}^{N \times N}$

$$\boxed{\mathbf{A} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^T}, \text{ donde } \mathbf{U}^T\mathbf{U} = \mathbf{I}_N, \quad \mathbf{V}^T\mathbf{V} = \mathbf{I}_N,$$

$$\mathbf{\Sigma} = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_n), \quad \sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_N \geq 0.$$

Suponemos por ahora que $\sigma_N > 0$. Entonces $\boxed{\mathbf{A}^{-1} = \mathbf{V}\mathbf{\Sigma}^{-1}\mathbf{U}^T}$.

Representación útil

$$\mathbf{A} = [\mathbf{u}_1 \ \mathbf{u}_2 \ \dots \ \mathbf{u}_N] \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_N) \begin{bmatrix} \mathbf{v}_1^T \\ \mathbf{v}_2^T \\ \vdots \\ \mathbf{v}_N^T \end{bmatrix} = \sum_{i=1}^N \sigma_i \mathbf{u}_i \mathbf{v}_i^T$$


$$\text{Idem: } \mathbf{A}^{-1} = \sum_{i=1}^N \frac{1}{\sigma_i} \mathbf{v}_i \mathbf{u}_i^T$$

Análisis de la solución naïve (2)

$$\mathbf{f}_{\text{naïve}} = \mathbf{A}^{-1} \mathbf{g} = \sum_{i=1}^N \frac{1}{\sigma_i} \mathbf{v}_i \mathbf{u}_i^T \mathbf{g} = \sum_{i=1}^N \left(\frac{\mathbf{u}_i^T \mathbf{g}}{\sigma_i} \right) \mathbf{v}_i$$

Es una expansión en la base de los vectores singulares derechos

Desvectorizando: $f_{\text{naïve}}(m, n) = \sum_{i=1}^N \left(\frac{\mathbf{u}_i^T \mathbf{g}}{\sigma_i} \right) v_i(m, n).$



Seis componentes v_i de la base de vectores singulares derechos para la PSF Gaussiana

Análisis de la solución naïve (3)

Error de estimación

$$\mathbf{f}_{\text{naïve}} - \mathbf{f} = \mathbf{A}^{-1}\mathbf{n} = \sum_{i=1}^N \left(\frac{\mathbf{u}_i^T \mathbf{n}}{\sigma_i} \right) \mathbf{v}_i$$

Características del problema de deconvolución

- ▶ Usualmente $|\mathbf{u}_i^T \mathbf{n}|$ pequeños y del mismo orden de magnitud $\forall i$.
- ▶ Los valores singulares decaen a valores cercanos a cero \Rightarrow **cond(A) = σ_1/σ_N muy grande, problema mal condicionado.**
- ▶ Los vectores singulares correspondientes a σ_i chicos generalmente representan información de alta frecuencia.

Consecuencia del enfoque naïf

Cuando i crece, $\frac{\mathbf{u}_i^T \mathbf{n}}{\sigma_i}$ crece rápidamente (excitación del ruido) amplificando los \mathbf{v}_i de alta frecuencia.

Regularización por filtrado espectral

El principio

Veremos dos métodos simples que conducen a una mejor restauración, basados en el principio de considerar pesos w_i de forma que

$$\mathbf{f}_{\text{estimado}} = \sum_{i=1}^N w_i \left(\frac{\mathbf{u}_i^T \mathbf{g}}{\sigma_i} \right) \mathbf{v}_i, \quad \text{con } \frac{w_i}{\sigma_i} \longrightarrow 0 \text{ si } \sigma_i \rightarrow 0.$$

- ▶ Truncado de la SVD
- ▶ Regularización de Tikhonov

Truncado de la SVD (TSVD)

Para algún $k < N$, $w_i = 1$ si $i \leq k$, $w_i = 0$ si $i > k$:

$$f_{\text{TSVD}} = \sum_{i=1}^k \left(\frac{\mathbf{u}_i^T \mathbf{g}}{\sigma_i} \right) \mathbf{v}_i = [\mathbf{v}_1 \ \mathbf{v}_2 \ \dots \ \mathbf{v}_k] (\text{diag}(\sigma_1, \sigma_2, \dots, \sigma_k))^{-1} \begin{bmatrix} \mathbf{u}_1^T \\ \mathbf{u}_2^T \\ \vdots \\ \mathbf{u}_N^T \end{bmatrix}.$$

Regularización de Tikhonov

$$\forall i = 1, 2, \dots, N, \quad w_i = \frac{\sigma_i^2}{\sigma_i^2 + \lambda} \quad \text{con } \lambda > 0.$$

$$\mathbf{f}_\lambda = \sum_{i=1}^N \frac{\sigma_i}{\sigma_i^2 + \lambda} (\mathbf{u}_i^T \mathbf{g}) \mathbf{v}_i.$$

Interpretación

- ▶ \mathbf{f}_λ es la solución al problema $\min_{\mathbf{f}} \{ \|\mathbf{A}\mathbf{f} - \mathbf{g}\|_2^2 + \lambda \|\mathbf{f}\|_2^2 \}$.
- ▶ El segundo término impide que $\|\mathbf{f}\|_2^2 = \sum_{i=1}^N \frac{(\mathbf{u}_i^T \mathbf{g})^2}{\sigma_i^2}$ crezca demasiado
- ▶ λ se llama **parámetro de regularización**: controla el compromiso entre ajuste al dato observado y la regularidad de la solución frente a ruido.

Resultados

Dato g



Original f



TSVD ($k = 1798$, $\text{tol} = 0.5$)



TSVD ($k = 6040$, $\text{tol} = 0.1$)



Tikhonov ($\lambda = 0.0016$)



Tikhonov ($\lambda = 0.01$)

