

Modelos dispersos para el procesamiento de señales y aprendizaje de máquinas

Alejandro Weinstein

Escuela de Ingeniería Biomédica
Universidad de Valparaíso

28 de Agosto de 2013

¿Qué es una señal dispersa?

Definición

Una señal $x \in \mathbb{R}^N$ es K -dispersa ($K < N$) si a lo más K coeficientes son distintos de zero. Formalmente

$$\|x\|_0 \leq K$$

Ejemplo: $N = 10$, $K = 2$

$$x = [0 \quad 0 \quad 3.14 \quad 0 \quad 0 \quad 0 \quad 0 \quad -2.71 \quad 0 \quad 0]$$

En general nos interesan los casos en que $K \ll N$

¿Qué es una señal dispersa?

Definición

Una señal es aproximadamente K -dispersa si, dado $\epsilon > 0$

$$\|x - x_K\|_2 \leq \epsilon,$$

donde x_K es igual a x en las K posiciones más grande (en magnitud), y cero en el resto.

Ejemplo: $N = 10$, $K = 2$

$$x = [-0.02 \quad 0.1 \quad 3.14 \quad -0.03 \quad -0.01 \quad 0.01 \quad -0.02 \quad -2.71 \quad 0.02 \quad 0.03]$$

$$x_K = [0 \quad 0 \quad 3.14 \quad 0 \quad 0 \quad 0 \quad 0 \quad -2.71 \quad 0 \quad 0]$$

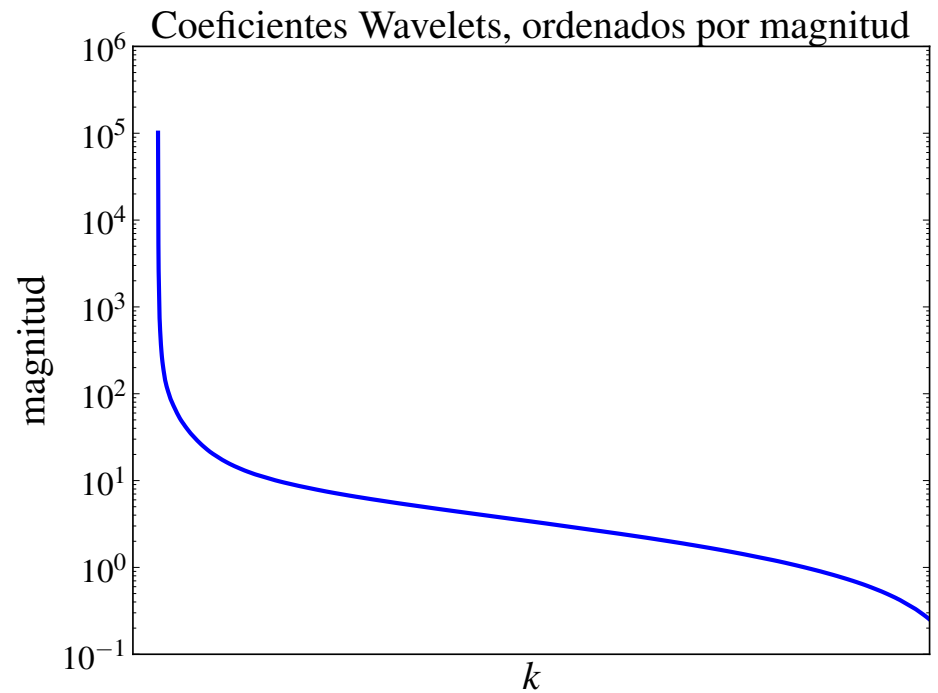
$$\|x - x_K\|_2 = 0.12$$

¿Por qué señales dispersas?

Imagen original, 614400 pixels



Aproximacion usando 10 % de los coeficientes



Usando la dispersión como modelo

“Esencialmente, todos los modelos son incorrectos, pero algunos modelos son útiles.”

George Box

Compressive Sensing (CS)

Es posible diseñar sistemas de adquisición que tome un número de mediciones muy por debajo del tamaño de la señal


Útil cuando cada medición es:

- ▶ Cara
- ▶ Lenta

Ejemplo: MRI

CS aprovecha dos hechos:

- ▶ Las imágenes médicas se pueden comprimir
- ▶ En MRI cada medición contiene información de todas las muestras



Original


Wavelets

Compress (10%)

(M. Lustig et al., "Compressed Sensing MRI")

Usando CS es posible reducir el tiempo de escaneo de una angiografía 3D de 22 a 4.4 segundos

Ejemplo: cámara de 1 píxel



La cámara de 1 pixel seis años después

InView Technology compressive sensing workstation includes objective lens

01/23/2013

Posted by Lee Mather
Associate Editor



The InView 220 includes a sensor and sensor controller for development and testing of **compressive sensing** algorithms. The sensor includes an objective lens, a 1920×1080 TI DMD with a mirror update rate of 10 kHz, a 4×8 SWIR detector array, and an analog-to-digital converter.


InView Technology
Austin, TX

<http://www.laserfocusworld.com/articles/2013/01/inview-technology-compressive-sensing-workstation.html>

¿Cómo funciona?

$$\left. \begin{array}{l} x = \Psi \alpha \\ y = \Phi x \end{array} \right\} \Rightarrow y = \underbrace{\Phi \Psi}_A \alpha$$

Dado y y A queremos recuperar α



- ▶ El sistema es indeterminado
- ▶ De las ∞ soluciones, elegimos la más dispersa

¿Cómo funciona?

Queremos resolver

$$\begin{array}{ll} \underset{\alpha}{\text{minimize}} & \|\alpha\|_0 \\ \text{subject to} & A\alpha = y \end{array}$$

pero es muy difícil (NP-hard)

En vez, relajamos el problema original y resolvemos



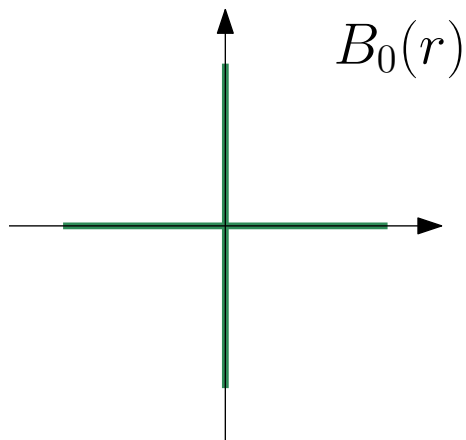
$$\begin{array}{ll} \underset{\alpha}{\text{minimize}} & \|\alpha\|_1 \\ \text{subject to} & A\alpha = y \end{array}$$

Existen condiciones bajo las cuales ambos problemas son equivalentes


Interpretación geométrica

$$\text{Norma } p: \|x\|_p = \left(\sum_{i=1}^n |x_i|^p \right)^{\frac{1}{p}}$$


Bola p de diámetro r : $B_p(r) = \{x \in \mathbb{R}^n : \|x\|_p < r\}$



Interpretación geométrica



minimize $\|\alpha\|_2$
subject to $A\alpha = y$

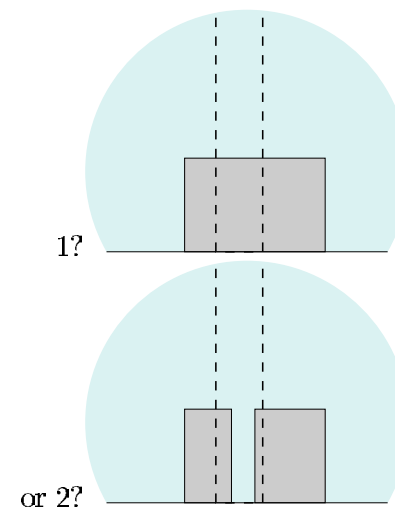



minimize $\|\alpha\|_1$
subject to $A\alpha = y$

Otro punto de vista

Se puede pensar en CS como una instancia de la navaja de Occam:

“Entre todas las explicaciones que se ajustan a los datos acepta la más simple”



CS en presencia de ruido

Si las observaciones son ruidosas:

$$y = \Phi x + \eta, \quad \|\eta\|_2 \leq \epsilon$$

podemos recuperar la señal resolviendo

$$\begin{array}{ll} \underset{\alpha}{\text{minimize}} & \|\alpha\|_1 \\ \text{subject to} & \|A\alpha - y\|_2 \leq \epsilon \end{array}$$

Garantía teórica

Bajo ciertas condiciones, es posible demostrar que

$$\|x^* - x\|_2 \leq \frac{C_0 \|x - x_K\|_1}{\sqrt{K}} + C_1 \epsilon,$$

donde

x^* : Señal recuperada

C_0, C_1 : Constantes

K : Nivel de dispersión

x_K : Mejor K -aproximación de x

Garantía teórica

$$\left. \begin{array}{l} x = \Psi \alpha \\ y = \Phi x \end{array} \right\} \Rightarrow y = \underbrace{\Phi \Psi}_A \alpha$$

Ψ : Base de representación

Φ : Base de muestreo


Coherencia entre la base de representación y muestreo:

$$\mu(\Phi, \Psi) = \sqrt{n} \max_{1 \leq j, k \leq n} |\langle \phi_j, \psi_k \rangle|$$

Garantía teórica

Necesitamos pares Φ, Ψ con baja coherencia. Ejemplo:

- ▶ Tiempo y frecuencia
- ▶ Frecuencia y wavelets
- ▶ Aleatorio y cualquier base fija



Más allá de modelos dispersos



(a) ℓ_1/ℓ_2 -norm ball without overlaps:
 $\Omega(\mathbf{w}) = \|\mathbf{w}_{\{1,2\}}\|_2 + |\mathbf{w}_3|$



(b) ℓ_1/ℓ_2 -norm ball with overlaps:
 $\Omega(\mathbf{w}) = \|\mathbf{w}_{\{1,2,3\}}\|_2 + |\mathbf{w}_1| + |\mathbf{w}_2|$

- ▶ Señales dispersas agrupadas
- ▶ Minimizar la complejidad de Kolgomorov o Minimum Description Length (MDL)
- ▶ Dictionary learning

Aprendizaje de máquinas

El problema que uno resuelve en CS se puede escribir como

$$\underset{x}{\text{minimize}} \quad \frac{1}{2} \|Ax - y\|_2^2 + \lambda \|x\|_1$$


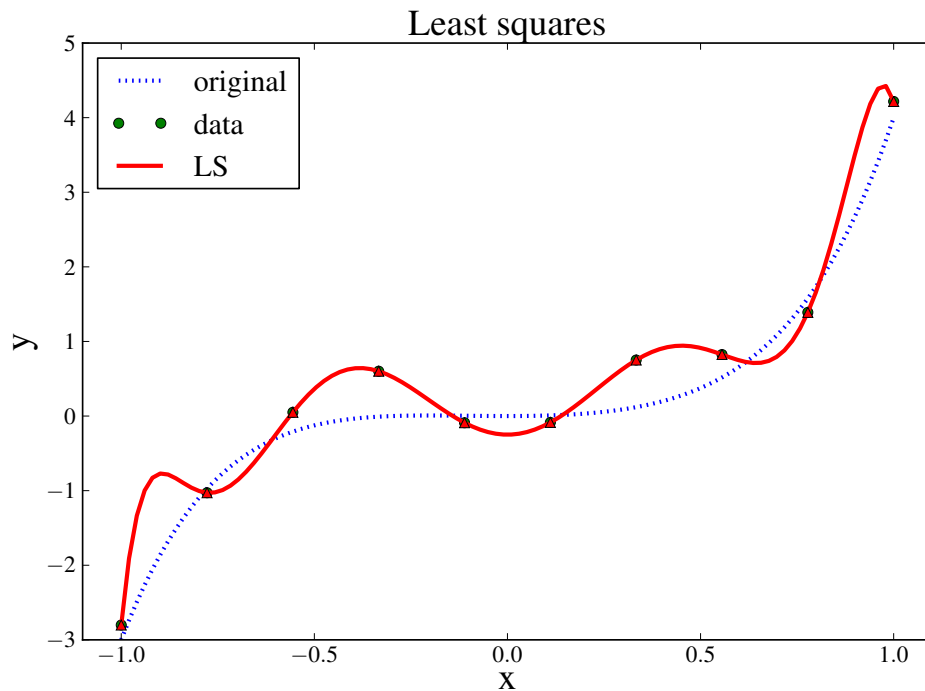
En aprendizaje de máquinas/estadística esta formulación se conoce como **lasso** (*least absolute shrinkage and selection operator*).

Lasso: Ejemplo

Observamos 10 datos en el intervalo $[-1, 1]$ generados por

$$y = 2x^5 + 1.5x^3 + 0.5x^2 + \eta, \eta \sim \mathcal{N}(0, 0.4^2)$$

Asumimos que los datos siguen un polinomio de a lo mas grado 10



$$\begin{aligned}\hat{y}_{LS} = & -54x^{10} + 3.1x^9 + 39x^8 \\ & - 3.2x^7 + 77x^6 + 2.4x^5 - 84x^4 \\ & + 3x^3 + 24x^2 - 0.01x - 0.8\end{aligned}$$

$$\hat{y}_{LASSO} = 2.6x^5 + 1.5x^3 + 0.01$$

Graph Lasso

Dadas las muestras $y_1, \dots, y_n \sim \mathcal{N}(\sigma_p, \mu)$, *Graph Lasso* estima la covarianza como

$$\hat{\Sigma}^{-1} = \operatorname{argmax}_{X \succ 0} \left\{ \underbrace{\log \det X - \operatorname{tr}(SX)}_{\text{log-likelihood}} - \underbrace{\lambda \|X\|_1}_{\text{penalización}} \right\},$$

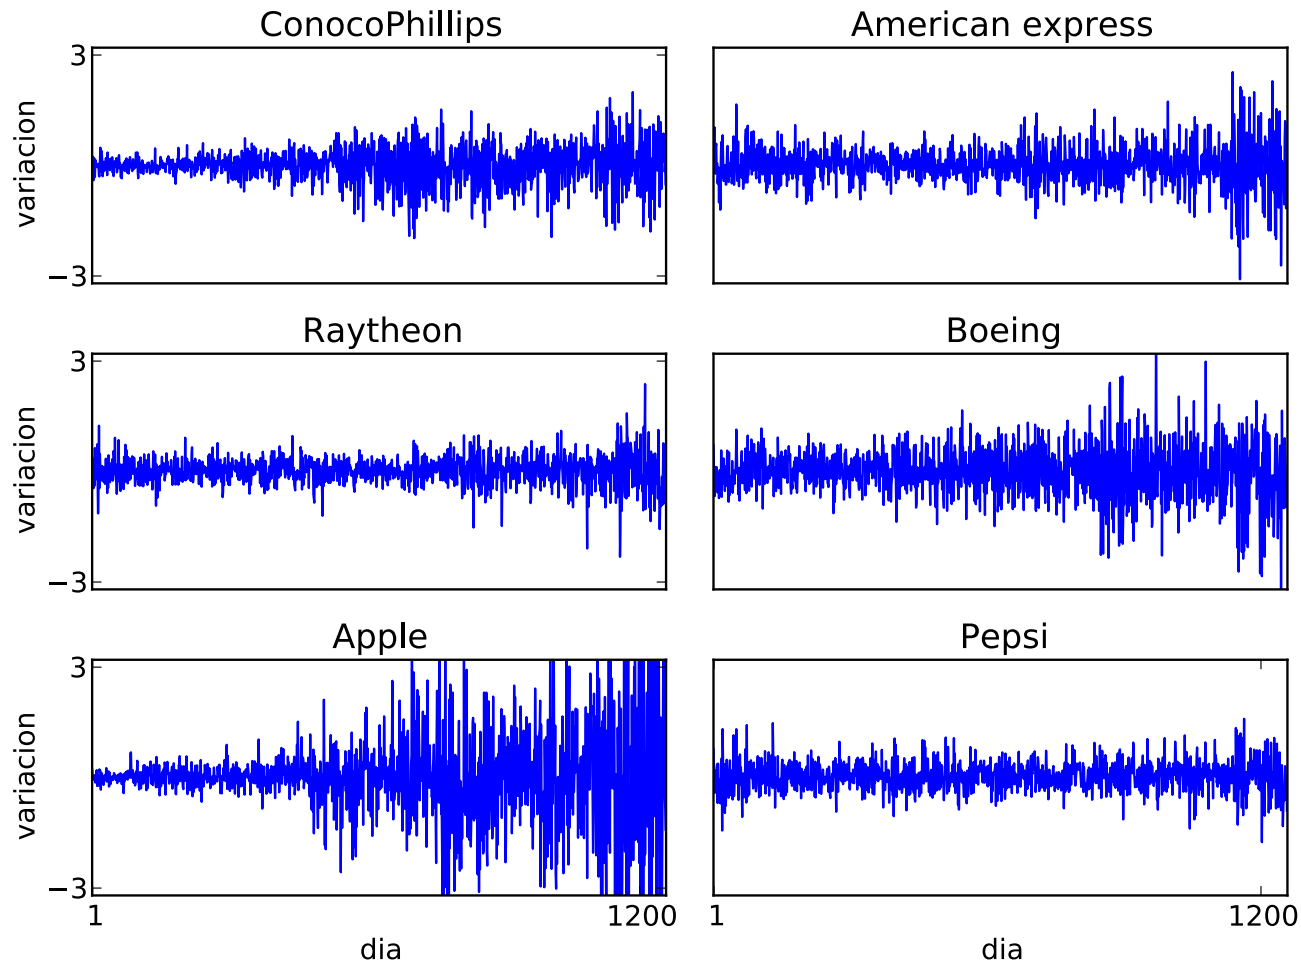
con

$$S := \frac{1}{n} \sum_{k=1}^n (y_k - \mu)(y_k - \mu)^T, \quad \|X\|_1 = \sum_{i,j} \operatorname{abs}(x_{ij})$$

Notar que $x_{ij} = 0$ implica que las variables x_i y x_j son condicionalmente independientes.

Ejemplo Graph Lasso: Correlación entre acciones

Dada la variación diaria de 61 acciones durante 5 años queremos encontrar posibles estructuras entre las acciones



Ejemplo Graph Lasso: Correlación entre acciones

