

# How to globally solve non-convex optimization problems involving an approximate $\ell_0$ penalization.

A. Marmin, M. Castella, J.C. Pesquet.  
ICASSP 2019. IEEE.

Seminario de Optimización y Aprendizaje Automático.

Matías Valdés - IMERL - Fing

15/05/25

# Regresión lineal esparsa

# Regresión lineal esparsa

Buscamos una solución esparsa de:

$$\arg \min_{x \in \mathbb{R}^n} \frac{1}{2} \|Ax - b\|_2^2, \quad A \in \mathbb{R}^{m \times n}, \quad b \in \mathbb{R}^m.$$

# Regresión lineal esparsa

Buscamos una solución esparsa de:

$$\arg \min_{x \in \mathbb{R}^n} \frac{1}{2} \|Ax - b\|_2^2, \quad A \in \mathbb{R}^{m \times n}, \quad b \in \mathbb{R}^m.$$

Situación ideal (penaliza soluciones poco esparsas):

$$\arg \min_{x \in \mathbb{R}^n} \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \lambda \|x\|_0 \right\}, \quad \|x\|_0 = \#\{i \in \{1, \dots, n\} / x_i \neq 0\}.$$

# Regresión lineal esparsa

Buscamos una solución esparsa de:

$$\arg \min_{x \in \mathbb{R}^n} \frac{1}{2} \|Ax - b\|_2^2, \quad A \in \mathbb{R}^{m \times n}, \quad b \in \mathbb{R}^m.$$

Situación ideal (penaliza soluciones poco esparsas):

$$\arg \min_{x \in \mathbb{R}^n} \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \lambda \|x\|_0 \right\}, \quad \|x\|_0 = \#\{i \in \{1, \dots, n\} / x_i \neq 0\}.$$

Difícil de resolver.

# Regresión lineal esparsa

Buscamos una solución esparsa de:

$$\arg \min_{x \in \mathbb{R}^n} \frac{1}{2} \|Ax - b\|_2^2, \quad A \in \mathbb{R}^{m \times n}, \quad b \in \mathbb{R}^m.$$

Situación ideal (penaliza soluciones poco esparsas):

$$\arg \min_{x \in \mathbb{R}^n} \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \lambda \|x\|_0 \right\}, \quad \|x\|_0 = \#\{i \in \{1, \dots, n\} / x_i \neq 0\}.$$

Difícil de resolver. Alternativa **convexa** (que fomenta esparsidad):

$$\arg \min_{x \in \mathbb{R}^n} \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \lambda \|x\|_1 \right\}, \quad \|x\|_1 := \sum_{i=1}^n |x_i| \quad \text{convexa.}$$

# Regresión lineal esparsa

Buscamos una solución esparsa de:

$$\arg \min_{x \in \mathbb{R}^n} \frac{1}{2} \|Ax - b\|_2^2, \quad A \in \mathbb{R}^{m \times n}, \quad b \in \mathbb{R}^m.$$

Situación ideal (penaliza soluciones poco esparsas):

$$\arg \min_{x \in \mathbb{R}^n} \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \lambda \|x\|_0 \right\}, \quad \|x\|_0 = \#\{i \in \{1, \dots, n\} / x_i \neq 0\}.$$

Difícil de resolver. Alternativa **convexa** (que fomenta esparsidad):

$$\arg \min_{x \in \mathbb{R}^n} \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \lambda \|x\|_1 \right\}, \quad \|x\|_1 := \sum_{i=1}^n |x_i| \quad \text{convexa.}$$

No es una buena aproximación de  $\ell_0$ . En particular penaliza soluciones con coordenadas grandes (bias en soluciones).

# Alternativa: aproximaciones no convexas de $\ell_0$

$$\min_{x \in \mathbb{R}^n} \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \sum_{i=1}^n R(x_i) \right\}.$$

## Alternativa: aproximaciones no convexas de $\ell_0$

$$\min_{x \in \mathbb{R}^n} \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \sum_{i=1}^n R(x_i) \right\}.$$

Buscamos  $R$  que se aproxime a  $\ell_0$ .

## Alternativa: aproximaciones no convexas de $\ell_0$

$$\min_{x \in \mathbb{R}^n} \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \sum_{i=1}^n R(x_i) \right\}.$$

Buscamos  $R$  que se aproxime a  $\ell_0$ . Le pedimos que:

## Alternativa: aproximaciones no convexas de $\ell_0$

$$\min_{x \in \mathbb{R}^n} \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \sum_{i=1}^n R(x_i) \right\}.$$

Buscamos  $R$  que se aproxime a  $\ell_0$ . Le pedimos que:

- fomente la esparsidad,

## Alternativa: aproximaciones no convexas de $\ell_0$

$$\min_{x \in \mathbb{R}^n} \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \sum_{i=1}^n R(x_i) \right\}.$$

Buscamos  $R$  que se aproxime a  $\ell_0$ . Le pedimos que:

- fomente la esparsidad,
- no penalice valores grandes de las coordenadas,

## Alternativa: aproximaciones no convexas de $\ell_0$

$$\min_{x \in \mathbb{R}^n} \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \sum_{i=1}^n R(x_i) \right\}.$$

Buscamos  $R$  que se aproxime a  $\ell_0$ . Le pedimos que:

- fomente la esparsidad,
- no penalice valores grandes de las coordenadas,
- sea continua (estabilidad del modelo).

# Alternativa: aproximaciones no convexas de $\ell_0$

$$\min_{x \in \mathbb{R}^n} \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \sum_{i=1}^n R(x_i) \right\}.$$

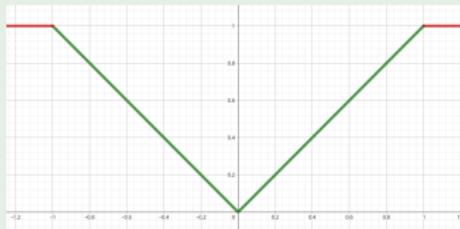
Buscamos  $R$  que se aproxime a  $\ell_0$ . Le pedimos que:

- fomente la esparsidad,
- no penalice valores grandes de las coordenadas,
- sea continua (estabilidad del modelo).

## Example (Capped $\ell_1$ )

$$R(x) = \begin{cases} |x|, & |x| \leq \lambda \\ \lambda, & |x| > \lambda \end{cases} =$$

$$= |x|1_{\{|x| \leq \lambda\}} + \lambda 1_{\{|x| > \lambda\}}.$$



# Ejemplos de funciones de penalización

\* Capped  $\ell_p$ :

$$R(x) = |x|^p \mathbf{1}_{\{|x| \leq \lambda\}} + \lambda^p \mathbf{1}_{\{|x| > \lambda\}}, \quad p > 0$$

# Ejemplos de funciones de penalización

\* Capped  $\ell_p$ :

$$R(x) = |x|^p \mathbf{1}_{\{|x| \leq \lambda\}} + \lambda^p \mathbf{1}_{\{|x| > \lambda\}}, \quad p > 0$$

\* Smoothly Clipped Absolute Deviation (SCAD) [Fan, Li, 2001]:

$$R(x) = \lambda|x|\mathbf{1}_{\{|x| \leq \lambda\}} - \left( \frac{\lambda^2 - 2\gamma\lambda|x| + x^2}{2(\gamma - 1)} \right) \mathbf{1}_{\{\lambda < |x| \leq \gamma\lambda\}} + \frac{(\gamma + 1)\lambda^2}{2} \mathbf{1}_{\{|x| > \gamma\lambda\}}$$

# Ejemplos de funciones de penalización

\* Capped  $\ell_p$ :

$$R(x) = |x|^p \mathbf{1}_{\{|x| \leq \lambda\}} + \lambda^p \mathbf{1}_{\{|x| > \lambda\}}, \quad p > 0$$

\* Smoothly Clipped Absolute Deviation (SCAD) [Fan, Li, 2001]:

$$R(x) = \lambda|x| \mathbf{1}_{\{|x| \leq \lambda\}} - \left( \frac{\lambda^2 - 2\gamma\lambda|x| + x^2}{2(\gamma - 1)} \right) \mathbf{1}_{\{\lambda < |x| \leq \gamma\lambda\}} + \frac{(\gamma + 1)\lambda^2}{2} \mathbf{1}_{\{|x| > \gamma\lambda\}}$$

\* Minimax Concave Penalty (MCP) [Zhang, 2010]:

$$R(x) = \left( \lambda|x| - \frac{x^2}{2\gamma} \right) \mathbf{1}_{\{|x| \leq \gamma\lambda\}} + \frac{\gamma\lambda^2}{2} \mathbf{1}_{\{|x| > \gamma\lambda\}}, \quad \gamma > 0$$

# Ejemplos de funciones de penalización

\* Capped  $\ell_p$ :

$$R(x) = |x|^p \mathbf{1}_{\{|x| \leq \lambda\}} + \lambda^p \mathbf{1}_{\{|x| > \lambda\}}, \quad p > 0$$

\* Smoothly Clipped Absolute Deviation (SCAD) [Fan, Li, 2001]:

$$R(x) = \lambda|x| \mathbf{1}_{\{|x| \leq \lambda\}} - \left( \frac{\lambda^2 - 2\gamma\lambda|x| + x^2}{2(\gamma - 1)} \right) \mathbf{1}_{\{\lambda < |x| \leq \gamma\lambda\}} + \frac{(\gamma + 1)\lambda^2}{2} \mathbf{1}_{\{|x| > \gamma\lambda\}}$$

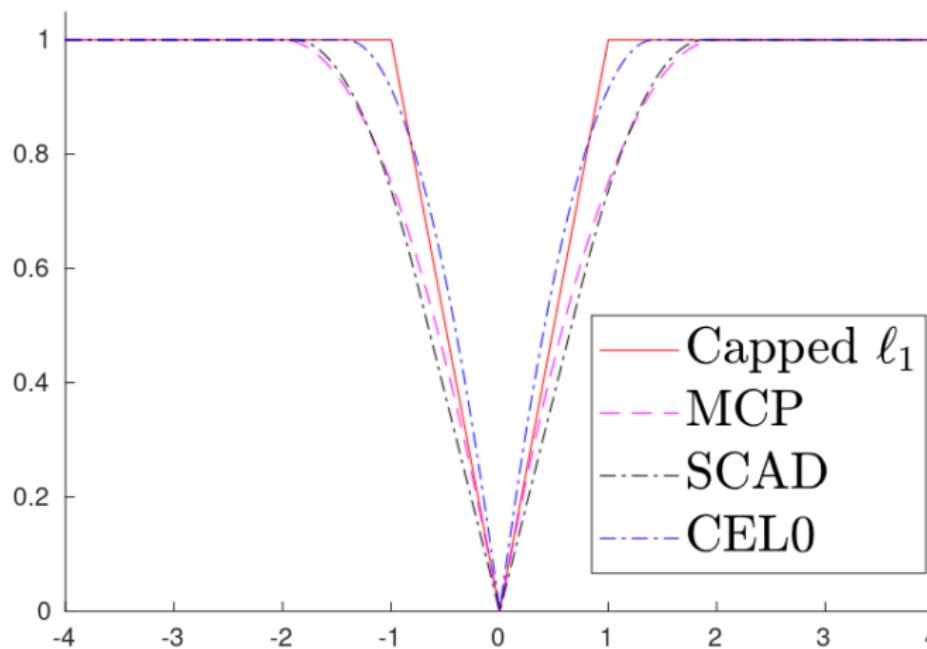
\* Minimax Concave Penalty (MCP) [Zhang, 2010]:

$$R(x) = \left( \lambda|x| - \frac{x^2}{2\gamma} \right) \mathbf{1}_{\{|x| \leq \gamma\lambda\}} + \frac{\gamma\lambda^2}{2} \mathbf{1}_{\{|x| > \gamma\lambda\}}, \quad \gamma > 0$$

\* Continuous Exact  $\ell_0$  (CEL0) [Soubies, Blanc, Aubert, 2015]:

$$R(x) = \lambda - \frac{\gamma^2}{2} \left( |x| - \frac{\sqrt{2\lambda}}{\gamma} \right)^2 \mathbf{1}_{\left\{ |x| \leq \frac{\sqrt{2\lambda}}{\gamma} \right\}}, \quad \gamma > 0$$

# Ejemplos de funciones de penalización



**Fig. 1.** Examples of continuous relaxation of  $\ell_0$  penalization ( $\lambda = 1$ ,  $\gamma_{\text{SCAD}} = 2.5$ ,  $\gamma_{\text{MCP}} = 2$ ,  $\gamma_{\text{CELO}} = 1$ ).

# Funciones de penalización

Los ejemplos anteriores son funciones polinomiales a trozos.

# Funciones de penalización

Los ejemplos anteriores son funciones polinomiales a trozos.

Idea del artículo:

# Funciones de penalización

Los ejemplos anteriores son funciones polinomiales a trozos.

Idea del artículo:

$$\min_{x \in \mathbb{R}^n} \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \sum_{i=1}^n R(x_i) \right\}.$$

# Funciones de penalización

Los ejemplos anteriores son funciones polinomiales a trozos.

Idea del artículo:

$$\min_{x \in \mathbb{R}^n} \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \sum_{i=1}^n R(x_i) \right\}.$$

- ① Reemplazar la penalización polinomial a trozos  $R$  por un polinomio y ciertas restricciones polinomiales.

# Funciones de penalización

Los ejemplos anteriores son funciones polinomiales a trozos.

Idea del artículo:

$$\min_{x \in \mathbb{R}^n} \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \sum_{i=1}^n R(x_i) \right\}.$$

- ① Reemplazar la penalización polinomial a trozos  $R$  por un polinomio y ciertas restricciones polinomiales.
- ② Esto da un problema de optimización polinomial, para el que existen métodos de optimización **global**.

# Funciones de penalización

Los ejemplos anteriores son funciones polinomiales a trozos.

Idea del artículo:

$$\min_{x \in \mathbb{R}^n} \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \sum_{i=1}^n R(x_i) \right\}.$$

- ① Reemplazar la penalización polinomial a trozos  $R$  por un polinomio y ciertas restricciones polinomiales.
- ② Esto da un problema de optimización polinomial, para el que existen métodos de optimización **global**.
- ③ Resolver el problema de optimización polinomial.

# Penalización polinomial a trozos

Una función polinomial a trozos es de la forma:

$$R(x) = \sum_{i=1}^N g_i(x)1_{\{\sigma_{i-1} \leq x < \sigma_i\}}, \quad x \in \mathbb{R};$$

con  $g_i$  polinomios, y  $\sigma_i$  una secuencia creciente de escalares:

$$-\infty \leq \sigma_0 < \sigma_1 < \dots < \sigma_{N-1} < \sigma_N \leq \infty.$$

# Penalización polinomial a trozos

Una función polinomial a trozos es de la forma:

$$R(x) = \sum_{i=1}^N g_i(x) 1_{\{\sigma_{i-1} \leq x < \sigma_i\}}, \quad x \in \mathbb{R};$$

con  $g_i$  polinomios, y  $\sigma_i$  una secuencia creciente de escalares:

$$-\infty \leq \sigma_0 < \sigma_1 < \dots < \sigma_{N-1} < \sigma_N \leq \infty.$$

Example (Capped  $\ell_p$  con  $\lambda = 1$ :  $R(x) = |x|^p 1_{\{|x| \leq 1\}} + 1_{\{|x| > 1\}}$ )

# Penalización polinomial a trozos

Una función polinomial a trozos es de la forma:

$$R(x) = \sum_{i=1}^N g_i(x) 1_{\{\sigma_{i-1} \leq x < \sigma_i\}}, \quad x \in \mathbb{R};$$

con  $g_i$  polinomios, y  $\sigma_i$  una secuencia creciente de escalares:

$$-\infty \leq \sigma_0 < \sigma_1 < \dots < \sigma_{N-1} < \sigma_N \leq \infty.$$

Example (Capped  $\ell_p$  con  $\lambda = 1$ :  $R(x) = |x|^p 1_{\{|x| \leq 1\}} + 1_{\{|x| > 1\}}$ )

$$\sigma_0 = -\infty, \sigma_1 = -1, \sigma_2 = 0, \sigma_3 = 1, \sigma_4 = \infty.$$

# Penalización polinomial a trozos

Una función polinomial a trozos es de la forma:

$$R(x) = \sum_{i=1}^N g_i(x) 1_{\{\sigma_{i-1} \leq x < \sigma_i\}}, \quad x \in \mathbb{R};$$

con  $g_i$  polinomios, y  $\sigma_i$  una secuencia creciente de escalares:

$$-\infty \leq \sigma_0 < \sigma_1 < \dots < \sigma_{N-1} < \sigma_N \leq \infty.$$

Example (Capped  $\ell_p$  con  $\lambda = 1$ :  $R(x) = |x|^p 1_{\{|x| \leq 1\}} + 1_{\{|x| > 1\}}$ )

$$\sigma_0 = -\infty, \sigma_1 = -1, \sigma_2 = 0, \sigma_3 = 1, \sigma_4 = \infty.$$

$$g_0(x) = 1, \quad g_1(x) = (-x)^p, \quad g_2(x) = x^p, \quad g_3(x) = 1.$$

# Penalización polinomial a trozos

Una función polinomial a trozos es de la forma:

$$R(x) = \sum_{i=1}^N g_i(x) 1_{\{\sigma_{i-1} \leq x < \sigma_i\}}, \quad x \in \mathbb{R};$$

con  $g_i$  polinomios, y  $\sigma_i$  una secuencia creciente de escalares:

$$-\infty \leq \sigma_0 < \sigma_1 < \dots < \sigma_{N-1} < \sigma_N \leq \infty.$$

Example (Capped  $\ell_p$  con  $\lambda = 1$ :  $R(x) = |x|^p 1_{\{|x| \leq 1\}} + 1_{\{|x| > 1\}}$ )

$$\sigma_0 = -\infty, \sigma_1 = -1, \sigma_2 = 0, \sigma_3 = 1, \sigma_4 = \infty.$$

$$g_0(x) = 1, \quad g_1(x) = (-x)^p, \quad g_2(x) = x^p, \quad g_3(x) = 1.$$

$$R(x) = 1_{\{-\infty \leq x < -1\}} + (-x)^p 1_{\{-1 \leq x < 0\}} + x^p 1_{\{0 \leq x < 1\}} + 1_{\{1 \leq x < \infty\}}.$$

# Forma polinomial equivalente

## Proposición

*Polinomial a trozos  $\Leftrightarrow$  polinomio y restricciones polinomiales.*

# Forma polinomial equivalente

## Proposición

*Polinomial a trozos  $\Leftrightarrow$  polinomio y restricciones polinomiales.*

Se definen  $z^{(i)}$ , tales que:

$$z^{(i)} = \begin{cases} 1, & \sigma_i \leq x \\ 0, & \sigma_i > x \end{cases} = 1_{\{\sigma_i \leq x\}}, \quad \forall i = 1, \dots, N.$$

# Forma polinomial equivalente

## Proposición

*Polinomial a trozos  $\Leftrightarrow$  polinomio y restricciones polinomiales.*

Se definen  $z^{(i)}$ , tales que:

$$z^{(i)} = \begin{cases} 1, & \sigma_i \leq x \\ 0, & \sigma_i > x \end{cases} = 1_{\{\sigma_i \leq x\}}, \quad \forall i = 1, \dots, N.$$

Se cumple:  $z^{(i)} = 1_{\{\sigma_i \leq x\}} \Leftrightarrow \begin{cases} z^{(i)} (1 - z^{(i)}) = 0, \\ (z^{(i)} - \frac{1}{2}) (x - \sigma_i) \geq 0 \end{cases}$ .

# Forma polinomial equivalente

## Proposición

*Polinomial a trozos  $\Leftrightarrow$  polinomio y restricciones polinomiales.*

Se definen  $z^{(i)}$ , tales que:

$$z^{(i)} = \begin{cases} 1, & \sigma_i \leq x \\ 0, & \sigma_i > x \end{cases} = 1_{\{\sigma_i \leq x\}}, \quad \forall i = 1, \dots, N.$$

Se cumple:  $z^{(i)} = 1_{\{\sigma_i \leq x\}} \Leftrightarrow \begin{cases} z^{(i)} (1 - z^{(i)}) = 0, \\ (z^{(i)} - \frac{1}{2}) (x - \sigma_i) \geq 0 \end{cases}$ .

Por otro lado:  $1_{\{\sigma_{i-1} \leq x < \sigma_i\}} = z^{(i-1)} (1 - z^{(i)}).$

# Forma polinomial equivalente

## Proposición

*Polinomial a trozos  $\Leftrightarrow$  polinomio y restricciones polinomiales.*

Se definen  $z^{(i)}$ , tales que:

$$z^{(i)} = \begin{cases} 1, & \sigma_i \leq x \\ 0, & \sigma_i > x \end{cases} = 1_{\{\sigma_i \leq x\}}, \quad \forall i = 1, \dots, N.$$

Se cumple:  $z^{(i)} = 1_{\{\sigma_i \leq x\}} \Leftrightarrow \begin{cases} z^{(i)}(1 - z^{(i)}) = 0, \\ (z^{(i)} - \frac{1}{2})(x - \sigma_i) \geq 0 \end{cases}$ .

Por otro lado:  $1_{\{\sigma_{i-1} \leq x < \sigma_i\}} = z^{(i-1)}(1 - z^{(i)})$ . Por lo tanto:

$$R(x) = \sum_{i=1}^N g_i(x) 1_{\{\sigma_{i-1} \leq x < \sigma_i\}} = \sum_{i=1}^N g_i(x) z^{(i-1)}(1 - z^{(i)});$$

con  $z^{(i)}$  tal que:  $z^{(i)}(1 - z^{(i)}) = 0$ , y  $(z^{(i)} - \frac{1}{2})(x - \sigma_i) \geq 0$ ,  $\forall i$ .



# Ejemplo: Capped $\ell_p$ con $\lambda = 1$

# Ejemplo: Capped $\ell_p$ con $\lambda = 1$

Recordar:

$$z^{(i)} = \begin{cases} 1, & \sigma_i \leq x \\ 0, & \sigma_i > x \end{cases} = 1_{\{\sigma_i \leq x\}}.$$

# Ejemplo: Capped $\ell_p$ con $\lambda = 1$

Recordar:

$$z^{(i)} = \begin{cases} 1, & \sigma_i \leq x \\ 0, & \sigma_i > x \end{cases} = 1_{\{\sigma_i \leq x\}}.$$

En el caso general, esto implica:

$$\sigma_0 = -\infty \Rightarrow z^{(0)}(x) = 1, \quad \forall x, \quad \sigma_N = \infty \Rightarrow z^{(N)}(x) = 0, \quad \forall x.$$

# Ejemplo: Capped $\ell_p$ con $\lambda = 1$

Recordar:

$$z^{(i)} = \begin{cases} 1, & \sigma_i \leq x \\ 0, & \sigma_i > x \end{cases} = 1_{\{\sigma_i \leq x\}}.$$

En el caso general, esto implica:

$$\sigma_0 = -\infty \Rightarrow z^{(0)}(x) = 1, \quad \forall x, \quad \sigma_N = \infty \Rightarrow z^{(N)}(x) = 0, \quad \forall x.$$

Para Capped  $\ell_p$ , con  $\lambda = 1$ :  $R(x) = |x|^p 1_{\{|x| \leq 1\}} + 1_{\{|x| > 1\}} \Leftrightarrow$

$$R(x) = (1 - z^{(1)}) + (-x)^p z^{(1)} (1 - z^{(2)}) + x^p z^{(2)} (1 - z^{(3)}) + z^{(3)}$$

$$z^{(i)}(1 - z^{(i)}) = 0, \quad (z^{(i)} - 0.5)(x - \sigma_i) \geq 0, \quad \forall i = 1, 2, 3$$

# Optimización polinomial

Usando lo anterior (en cada coordenada  $x_t$ ), el problema original

$$\arg \min_{x \in \mathbb{R}^n} \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \sum_{t=1}^n R(x_t) \right\},$$

equivale a un problema de optimización polinomial:

# Optimización polinomial

Usando lo anterior (en cada coordenada  $x_t$ ), el problema original

$$\arg \min_{x \in \mathbb{R}^n} \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \sum_{t=1}^n R(x_t) \right\},$$

equivale a un problema de optimización polinomial:

$$\arg \min_{x,z} \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \sum_{t=1}^n \sum_{i=1}^N g_i(x_t) z_t^{(i-1)} \left(1 - z_t^{(i)}\right) \right\}, \quad s.t.$$

$$z_t^{(i)} \left(1 - z_t^{(i)}\right) = 0, \quad \left(z_t^{(i)} - \frac{1}{2}\right) (x_t - \sigma_i) \geq 0, \quad \forall i = 1 : N, t = 1 : n.$$

# Optimización polinomial

Usando lo anterior (en cada coordenada  $x_t$ ), el problema original

$$\arg \min_{x \in \mathbb{R}^n} \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \sum_{t=1}^n R(x_t) \right\},$$

equivale a un problema de optimización polinomial:

$$\arg \min_{x,z} \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \sum_{t=1}^n \sum_{i=1}^N g_i(x_t) z_t^{(i-1)} \left(1 - z_t^{(i)}\right) \right\}, \quad s.t.$$

$$z_t^{(i)} \left(1 - z_t^{(i)}\right) = 0, \quad \left(z_t^{(i)} - \frac{1}{2}\right) (x_t - \sigma_i) \geq 0, \quad \forall i = 1 : N, t = 1 : n.$$

Existen métodos para estimar un mínimo global:

# Optimización polinomial

Usando lo anterior (en cada coordenada  $x_t$ ), el problema original

$$\arg \min_{x \in \mathbb{R}^n} \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \sum_{t=1}^n R(x_t) \right\},$$

equivale a un problema de optimización polinomial:

$$\arg \min_{x,z} \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \sum_{t=1}^n \sum_{i=1}^N g_i(x_t) z_t^{(i-1)} \left(1 - z_t^{(i)}\right) \right\}, \quad s.t.$$

$$z_t^{(i)} \left(1 - z_t^{(i)}\right) = 0, \quad \left(z_t^{(i)} - \frac{1}{2}\right) (x_t - \sigma_i) \geq 0, \quad \forall i = 1 : N, t = 1 : n.$$

Existen métodos para estimar un mínimo global:

- RLT: Reformulation Linearization Technique (LPs con B.B.).

# Optimización polinomial

Usando lo anterior (en cada coordenada  $x_t$ ), el problema original

$$\arg \min_{x \in \mathbb{R}^n} \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \sum_{t=1}^n R(x_t) \right\},$$

equivale a un problema de optimización polinomial:

$$\arg \min_{x,z} \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \sum_{t=1}^n \sum_{i=1}^N g_i(x_t) z_t^{(i-1)} \left(1 - z_t^{(i)}\right) \right\}, \quad s.t.$$

$$z_t^{(i)} \left(1 - z_t^{(i)}\right) = 0, \quad \left(z_t^{(i)} - \frac{1}{2}\right) (x_t - \sigma_i) \geq 0, \quad \forall i = 1 : N, t = 1 : n.$$

Existen métodos para estimar un mínimo global:

- RLT: Reformulation Linearization Technique (LPs con B.B.).
- Lasserre-Parrilo (sucesión de SDPs, asociadas a SOS).

# Simulaciones: modelo

Se generan datos usando el modelo  $y = Ax + w$ , con:

# Simulaciones: modelo

Se generan datos usando el modelo  $y = Ax + w$ , con:

- $w$  ruido gaussiano blanco,

## Simulaciones: modelo

Se generan datos usando el modelo  $y = Ax + w$ , con:

- $w$  ruido gaussiano blanco,

- $A$  matriz de tipo banda Toeplitz:  $A =$

$$\begin{pmatrix} a_2 & a_1 & 0 & 0 \\ a_3 & a_2 & a_1 & 0 \\ 0 & a_3 & a_2 & a_1 \\ 0 & 0 & a_3 & a_2 \\ 0 & 0 & 0 & a_3 \end{pmatrix}$$

## Simulaciones: modelo

Se generan datos usando el modelo  $y = Ax + w$ , con:

- $w$  ruido gaussiano blanco,

- $A$  matriz de tipo banda Toeplitz:  $A =$

$$\begin{pmatrix} a_2 & a_1 & 0 & 0 \\ a_3 & a_2 & a_1 & 0 \\ 0 & a_3 & a_2 & a_1 \\ 0 & 0 & a_3 & a_2 \\ 0 & 0 & 0 & a_3 \end{pmatrix}$$

(correspondiente a un filtro de convolución gaussiana),

## Simulaciones: modelo

Se generan datos usando el modelo  $y = Ax + w$ , con:

- $w$  ruido gaussiano blanco,

- $A$  matriz de tipo banda Toeplitz:  $A = \begin{pmatrix} a_2 & a_1 & 0 & 0 \\ a_3 & a_2 & a_1 & 0 \\ 0 & a_3 & a_2 & a_1 \\ 0 & 0 & a_3 & a_2 \\ 0 & 0 & 0 & a_3 \end{pmatrix}$   
(correspondiente a un filtro de convolución gaussiana),
- $x \in \mathbb{R}^n$ ,  $n = 200$ , con coordenadas  $x_t \sim U[6/10, 1]$ .

## Simulaciones: modelo

Se generan datos usando el modelo  $y = Ax + w$ , con:

- $w$  ruido gaussiano blanco,

- $A$  matriz de tipo banda Toeplitz:  $A =$

$$\begin{pmatrix} a_2 & a_1 & 0 & 0 \\ a_3 & a_2 & a_1 & 0 \\ 0 & a_3 & a_2 & a_1 \\ 0 & 0 & a_3 & a_2 \\ 0 & 0 & 0 & a_3 \end{pmatrix}$$

(correspondiente a un filtro de convolución gaussiana),

- $x \in \mathbb{R}^n$ ,  $n = 200$ , con coordenadas  $x_t \sim U[6/10, 1]$ .

Parámetro  $\gamma$  de las funciones de penalización  $R(x_t)$ :

- MCP:  $\gamma = 0.5$ ; SCAD:  $\gamma = 2.1$ ;
- CEL0: norma de la columna  $t$  de  $A$  (para cada  $x_t$ ).

# Compara con tres algoritmos de optimización local:

# Compara con tres algoritmos de optimización local:

- Forward-Backward (FB): criterio “greedy” para incorporar (forward) o quitar (backward) coordenadas no nulas al modelo, según variación de la función objetivo.

# Compara con tres algoritmos de optimización local:

- Forward-Backward (FB): criterio “greedy” para incorporar (forward) o quitar (backward) coordenadas no nulas al modelo, según variación de la función objetivo.
- Iteratively Re-weighted  $\ell_1$  (IRL1):

$$x^{(k)} = \arg \min_x \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \lambda \|W^{(k)}x\|_1 \right\},$$

$$w_t^{(k+1)} = \frac{1}{|x_t^{(k)}| + \epsilon}, \quad \forall t = 1, \dots, n.$$

# Compara con tres algoritmos de optimización local:

- Forward-Backward (FB): criterio “greedy” para incorporar (forward) o quitar (backward) coordenadas no nulas al modelo, según variación de la función objetivo.
- Iteratively Re-weighted  $\ell_1$  (IRL1):

$$x^{(k)} = \arg \min_x \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \lambda \|W^{(k)}x\|_1 \right\},$$

$$w_t^{(k+1)} = \frac{1}{|x_t^{(k)}| + \epsilon}, \quad \forall t = 1, \dots, n.$$

- Descenso por Coordenadas (CD).

# Compara con tres algoritmos de optimización local:

- Forward-Backward (FB): criterio “greedy” para incorporar (forward) o quitar (backward) coordenadas no nulas al modelo, según variación de la función objetivo.
- Iteratively Re-weighted  $\ell_1$  (IRL1):

$$x^{(k)} = \arg \min_x \left\{ \frac{1}{2} \|Ax - b\|_2^2 + \lambda \|W^{(k)}x\|_1 \right\},$$

$$w_t^{(k+1)} = \frac{1}{|x_t^{(k)}| + \epsilon}, \quad \forall t = 1, \dots, n.$$

- Descenso por Coordenadas (CD).

El algoritmo propuesto utiliza orden de jerarquía SDP  $k = 3$ .

# Resultados experimentales

- Tres condiciones iniciales: aleatoria, cero, y el valor real  $\bar{x}$ .

# Resultados experimentales

- Tres condiciones iniciales: aleatoria, cero, y el valor real  $\bar{x}$ .
- Compara métodos evaluando sol. en:  $\frac{1}{2}\|Ax - b\|_2^2 + \frac{1}{10}\|x\|_0$ .

# Resultados experimentales

- Tres condiciones iniciales: aleatoria, cero, y el valor real  $\bar{x}$ .
- Compara métodos evaluando sol. en:  $\frac{1}{2}\|Ax - b\|_2^2 + \frac{1}{10}\|x\|_0$ .

**Table 1.** Optimal criterion value depending on initial point.

$\Psi_\lambda$ Alg.	Capped $\ell_1$	SCAD	MCP	CELO
Proposed ( $k = 3$ )	<b>3.725</b>	<b>3.506</b>	<b>2.749</b>	<b>4.425</b>
<i>Random</i> $x_{\text{init}}$				
FB	4.372	3.759	3.194	4.638
IRL1	7.052	4.632	3.381	6.926
CD	4.099	3.927	3.520	4.638
$x_{\text{init}} = 0$				
FB	4.208	3.763	3.149	4.638
IRL1	4.839	4.566	3.013	6.879
CD	5.455	4.371	3.717	5.316
$x_{\text{init}} = \bar{x}$				
FB	3.867	3.639	2.871	4.637
IRL1	4.766	4.567	2.914	6.874
CD	4.093	3.639	3.015	5.365

# Resultados experimentales

- Tres condiciones iniciales: aleatoria, cero, y el valor real  $\bar{x}$ .
- Compara métodos evaluando sol. en:  $\frac{1}{2}\|Ax - b\|_2^2 + \frac{1}{10}\|x\|_0$ .

**Table 1.** Optimal criterion value depending on initial point.

$\Psi_\lambda$ Alg.	Capped $\ell_1$	SCAD	MCP	CELO
Proposed ( $k = 3$ )	<b>3.725</b>	<b>3.506</b>	<b>2.749</b>	<b>4.425</b>
<i>Random</i> $x_{\text{init}}$				
FB	4.372	3.759	3.194	4.638
IRL1	7.052	4.632	3.381	6.926
CD	4.099	3.927	3.520	4.638
$x_{\text{init}} = 0$				
FB	4.208	3.763	3.149	4.638
IRL1	4.839	4.566	3.013	6.879
CD	5.455	4.371	3.717	5.316
$x_{\text{init}} = \bar{x}$				
FB	3.867	3.639	2.871	4.637
IRL1	4.766	4.567	2.914	6.874
CD	4.093	3.639	3.015	5.365

- Resultado de métodos locales varía con la condición inicial.

# Resultados experimentales

- Tres condiciones iniciales: aleatoria, cero, y el valor real  $\bar{x}$ .
- Compara métodos evaluando sol. en:  $\frac{1}{2}\|Ax - b\|_2^2 + \frac{1}{10}\|x\|_0$ .

**Table 1.** Optimal criterion value depending on initial point.

$\Psi_\lambda$ Alg.	Capped $\ell_1$	SCAD	MCP	CELO
Proposed ( $k = 3$ )	<b>3.725</b>	<b>3.506</b>	<b>2.749</b>	<b>4.425</b>
<i>Random</i> $x_{\text{init}}$				
FB	4.372	3.759	3.194	4.638
IRL1	7.052	4.632	3.381	6.926
CD	4.099	3.927	3.520	4.638
$x_{\text{init}} = 0$				
FB	4.208	3.763	3.149	4.638
IRL1	4.839	4.566	3.013	6.879
CD	5.455	4.371	3.717	5.316
$x_{\text{init}} = \bar{x}$				
FB	3.867	3.639	2.871	4.637
IRL1	4.766	4.567	2.914	6.874
CD	4.093	3.639	3.015	5.365

- Resultado de métodos locales varía con la condición inicial.
- El método propuesto es siempre el de menor valor.

# Optimización polinomial con Lasserre-Parrilo (2001)

# Optimización polinomial con Lasserre-Parrilo (2001)

En todo problema de optimización, el valor mínimo **global** cumple:

$$p^* := \min_{x \in K} p(x) = \left\{ \max_{x, \lambda} \lambda, \quad \text{s.a: } p(x) - \lambda \geq 0, \quad x \in K \right\}.$$

# Optimización polinomial con Lasserre-Parrilo (2001)

En todo problema de optimización, el valor mínimo **global** cumple:

$$p^* := \min_{x \in K} p(x) = \left\{ \max_{x, \lambda} \lambda, \quad \text{s.a: } p(x) - \lambda \geq 0, \quad x \in K \right\}.$$

Problema polinomial: minimizar polinomio  $p$ , en conjunto factible

$$K := \{x \in \mathbb{R}^n / p_i(x) \geq 0\}, \quad \text{con } p_i \text{ polinomios.}$$

# Optimización polinomial con Lasserre-Parrilo (2001)

En todo problema de optimización, el valor mínimo **global** cumple:

$$p^* := \min_{x \in K} p(x) = \left\{ \max_{x, \lambda} \lambda, \quad \text{s.a: } p(x) - \lambda \geq 0, \quad x \in K \right\}.$$

Problema polinomial: minimizar polinomio  $p$ , en conjunto factible

$$K := \{x \in \mathbb{R}^n / p_i(x) \geq 0\}, \quad \text{con } p_i \text{ polinomios.}$$

Theorem (Putinar, 1993)

*Si  $q$  es polinomio positivo en  $K = \{x \in \mathbb{R}^n / p_i(x) \geq 0\}$ , entonces:*

$$q = s_0 + s_1 p_1 + \dots + s_m p_m, \quad \text{con } s_i \text{ suma de cuadrados (SOS).}$$

# Optimización polinomial con Lasserre-Parrilo (2001)

En todo problema de optimización, el valor mínimo **global** cumple:

$$p^* := \min_{x \in K} p(x) = \left\{ \max_{x, \lambda} \lambda, \quad \text{s.a: } p(x) - \lambda \geq 0, \quad x \in K \right\}.$$

Problema polinomial: minimizar polinomio  $p$ , en conjunto factible

$$K := \{x \in \mathbb{R}^n / p_i(x) \geq 0\}, \quad \text{con } p_i \text{ polinomios.}$$

## Theorem (Putinar, 1993)

*Si  $q$  es polinomio positivo en  $K = \{x \in \mathbb{R}^n / p_i(x) \geq 0\}$ , entonces:*

$$q = s_0 + s_1 p_1 + \dots + s_m p_m, \quad \text{con } s_i \text{ suma de cuadrados (SOS).}$$

Relajación en SOS:

$$p_k := \max_{x, \lambda} \lambda, \quad \text{s.a: } p(x) - \lambda = s_0 + s_1 p_1(x) + \dots + s_m p_m(x);$$

con  $s_i$  suma de cuadrados, y  $\deg(s_i p_i) \leq 2k$ .

# Optimización polinomial con Lasserre-Parrilo (2001)

Relajación SOS (de orden  $2k$ ):

$$p_k := \max_{x, \lambda} \lambda, \quad \text{s.a: } p(x) - \lambda = s_0 + s_1 p_1(x) + \dots + s_m p_m(x);$$

con  $s_i$  suma de cuadrados, y  $\deg(s_i p_i) \leq 2k$ .

# Optimización polinomial con Lasserre-Parrilo (2001)

Relajación SOS (de orden  $2k$ ):

$$p_k := \max_{x, \lambda} \lambda, \quad \text{s.a: } p(x) - \lambda = s_0 + s_1 p_1(x) + \dots + s_m p_m(x);$$

con  $s_i$  suma de cuadrados, y  $\deg(s_i p_i) \leq 2k$ .

- $p_k$  es cota inferior de  $p^*$  (por ser relajación),

# Optimización polinomial con Lasserre-Parrilo (2001)

Relajación SOS (de orden  $2k$ ):

$$p_k := \max_{x, \lambda} \lambda, \quad \text{s.a: } p(x) - \lambda = s_0 + s_1 p_1(x) + \dots + s_m p_m(x);$$

con  $s_i$  suma de cuadrados, y  $\deg(s_i p_i) \leq 2k$ .

- $p_k$  es cota inferior de  $p^*$  (por ser relajación),
- $p_k$  es creciente con el orden  $k$  de la relajación.

# Optimización polinomial con Lasserre-Parrilo (2001)

Relajación SOS (de orden  $2k$ ):

$$p_k := \max_{x, \lambda} \lambda, \quad \text{s.a: } p(x) - \lambda = s_0 + s_1 p_1(x) + \dots + s_m p_m(x);$$

con  $s_i$  suma de cuadrados, y  $\deg(s_i p_i) \leq 2k$ .

- $p_k$  es cota inferior de  $p^*$  (por ser relajación),
- $p_k$  es creciente con el orden  $k$  de la relajación.
- Problema SDP surge de la condición de suma de cuadrados.

# SOS expresada como Programación Semidefinida (SDP)

# SOS expresada como Programación Semidefinida (SDP)

- Optimización lineal (LP):

$$\min_{x \in \mathbb{R}^n} c^T x, \quad \text{s.a: } a_j^T x = b_j, \quad j = 1, \dots, m, \quad x_i \geq 0, \quad \forall i.$$

# SOS expresada como Programación Semidefinida (SDP)

- Optimización lineal (LP):

$$\min_{x \in \mathbb{R}^n} c^T x, \quad \text{s.a: } a_j^T x = b_j, \quad j = 1, \dots, m, \quad x_i \geq 0, \quad \forall i.$$

- Optimización Semidefinida (SDP):

$$\min_{X \in \mathbb{R}^{n \times n}} \text{tr}(C^T X), \quad \text{s.a: } \text{tr}(A_j^T X) = b_j, \quad j = 1, \dots, m, \quad X \succcurlyeq 0.$$

# SOS expresada como Programación Semidefinida (SDP)

- Optimización lineal (LP):

$$\min_{x \in \mathbb{R}^n} c^T x, \quad \text{s.a: } a_j^T x = b_j, \quad j = 1, \dots, m, \quad x_i \geq 0, \quad \forall i.$$

- Optimización Semidefinida (SDP):

$$\min_{X \in \mathbb{R}^{n \times n}} \text{tr}(C^T X), \quad \text{s.a: } \text{tr}(A_j^T X) = b_j, \quad j = 1, \dots, m, \quad X \succcurlyeq 0.$$

- Ejemplo de SDP:  $n = 3, m = 1$ :

$$\min_{X \in \mathbb{R}^{3 \times 3}} x_{11} + 4x_{12} + 6x_{13} + 9x_{22} + 7x_{33}, \quad \text{s.a.}$$

$$x_{11} + 2x_{13} + 3x_{22} + 14x_{23} + 5x_{33} = 11, \quad X = \begin{pmatrix} x_{11} & x_{12} & x_{13} \\ x_{12} & x_{22} & x_{23} \\ x_{13} & x_{23} & x_{33} \end{pmatrix} \succcurlyeq 0.$$

# SOS expresada como Programación Semidefinida (SDP)

- Optimización lineal (LP):

$$\min_{x \in \mathbb{R}^n} c^T x, \quad \text{s.a: } a_j^T x = b_j, \quad j = 1, \dots, m, \quad x_i \geq 0, \quad \forall i.$$

- Optimización Semidefinida (SDP):

$$\min_{X \in \mathbb{R}^{n \times n}} \text{tr}(C^T X), \quad \text{s.a: } \text{tr}(A_j^T X) = b_j, \quad j = 1, \dots, m, \quad X \succcurlyeq 0.$$

- Ejemplo de SDP:  $n = 3, m = 1$ :

$$\min_{X \in \mathbb{R}^{3 \times 3}} x_{11} + 4x_{12} + 6x_{13} + 9x_{22} + 7x_{33}, \quad \text{s.a.}$$

$$x_{11} + 2x_{13} + 3x_{22} + 14x_{23} + 5x_{33} = 11, \quad X = \begin{pmatrix} x_{11} & x_{12} & x_{13} \\ x_{12} & x_{22} & x_{23} \\ x_{13} & x_{23} & x_{33} \end{pmatrix} \succcurlyeq 0.$$

SDP es **convexo**. Solución global con métodos de punto interior.

# SOS expresada como Programación Semidefinida (SDP)

# SOS expresada como Programación Semidefinida (SDP)

- Sea  $[x]_k$  vector con monomios de  $n$  variables y grado  $\leq k$ .

# SOS expresada como Programación Semidefinida (SDP)

- Sea  $[x]_k$  vector con monomios de  $n$  variables y grado  $\leq k$ .
- Por ejemplo, para  $n = 2$  variables, y grado  $\leq k = 3$ :

$$[x]_3 = [1, x_1, x_2, x_1^2, x_1x_2, x_2^2, x_1^3, x_1^2x_2, x_1x_2^2, x_2^3]^T.$$

# SOS expresada como Programación Semidefinida (SDP)

- Sea  $[x]_k$  vector con monomios de  $n$  variables y grado  $\leq k$ .
- Por ejemplo, para  $n = 2$  variables, y grado  $\leq k = 3$ :

$$[x]_3 = [1, x_1, x_2, x_1^2, x_1 x_2, x_2^2, x_1^3, x_1^2 x_2, x_1 x_2^2, x_2^3]^T.$$

## Theorem

Polinomio  $p$  de  $n$  variables y grado  $\leq 2k$  es suma de cuadrados si y solo si

$$p(x) = [x]_k^T M [x]_k;$$

para alguna matriz  $M \in \mathbb{R}^{N \times N}$  semi-definida positiva,  $N := C_k^{n+k}$ .

# SOS expresada como Programación Semidefinida (SDP)

- Sea  $[x]_k$  vector con monomios de  $n$  variables y grado  $\leq k$ .
- Por ejemplo, para  $n = 2$  variables, y grado  $\leq k = 3$ :

$$[x]_3 = [1, x_1, x_2, x_1^2, x_1 x_2, x_2^2, x_1^3, x_1^2 x_2, x_1 x_2^2, x_2^3]^T.$$

## Theorem

Polinomio  $p$  de  $n$  variables y grado  $\leq 2k$  es suma de cuadrados si y solo si

$$p(x) = [x]_k^T M [x]_k;$$

para alguna matriz  $M \in \mathbb{R}^{N \times N}$  semi-definida positiva,  $N := C_k^{n+k}$ .

- Igualando coeficientes de cada monomio, se obtienen restricciones lineales en  $M_{ij}$ .

# SOS expresada como Programación Semidefinida (SDP)

- Sea  $[x]_k$  vector con monomios de  $n$  variables y grado  $\leq k$ .
- Por ejemplo, para  $n = 2$  variables, y grado  $\leq k = 3$ :

$$[x]_3 = [1, x_1, x_2, x_1^2, x_1 x_2, x_2^2, x_1^3, x_1^2 x_2, x_1 x_2^2, x_2^3]^T.$$

## Theorem

*Polinomio  $p$  de  $n$  variables y grado  $\leq 2k$  es suma de cuadrados si y solo si*

$$p(x) = [x]_k^T M [x]_k;$$

*para alguna matriz  $M \in \mathbb{R}^{N \times N}$  semi-definida positiva,  $N := C_k^{n+k}$ .*

- Igualando coeficientes de cada monomio, se obtienen restricciones lineales en  $M_{ij}$ .
- Recuperar  $p$  como SOS usando  $M = LL^T$  (Choleski):  

$$p(x) = [x]_k^T (LL^T) [x]_k = \|L^T [x]_k\|_2^2 = \sum_i (L^T [x]_k)_i^2.$$

# Referencias

- ① How to globally solve non-convex optimization problems involving an approximate  $\ell_0$  penalization. Marmin, Castella, Pesquet (2019). ICASSP 2019.
- ② Adaptive Forward-Backward Greedy Algorithm for Learning Sparse Representations. Zhang (2011). IEEE Transactions on Information Theory.
- ③ Enhancing sparsity by reweighted  $\ell_1$  minimization. Candès, Wakin, Boyd. (2008). Journal of Fourier Anal. Appl.
- ④ Coordinate descent algorithms for nonconvex penalized regression, with applications to biological feature selection. Breheny & Huang (2011). Annals of applied statistics.
- ⑤ Global optimization with polynomials and the problem of moments. Lasserre (2001).
- ⑥ Structured semidefinite programs and semialgebraic geometry methods in robustness and optimization. Parrilo (2000). California Institute of Technology.
- ⑦ The Lasserre hierarchy for polynomial optimization: A tutorial. Etienne de Klerk (2016).
- ⑧ SOS and SDP relaxation of polynomial otimization problems. Kojima (2010).
- ⑨ Sum of Squares. Parrilo & Lall (2003). IEEE Conference on Decision and Control.
- ⑩ The moment-SOS hierarchy. Lasserre. ICM2018.