

Compressed Sensing

Algoritmo Re-Weighted l_1 con pesos actualizados resolviendo un problema dual

Matías Valdés

Director de tesis: Marcelo Fiori

12 de abril de 2019

Problema a resolver

Minimización l_1

Algoritmo RW/l_1

Metodología RW/l_1 propuesta

Algoritmo RW/l_1 subgradiente

Resultados experimentales

Metodología RW -LASSO

Resultados con ruido

Conclusiones

Problema a resolver

- ▶ Sistema lineal $\Phi x = b$ con infinitas soluciones
- ▶ Hallar solución mayor cantidad coordenadas nulas: más “esparsa”

- ▶ $\Phi \in \mathbb{R}^{m \times n}$, $m < n \Rightarrow \Phi = \begin{pmatrix} \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \end{pmatrix}$

- ▶ Problema de optimización equivalente:

$$\begin{array}{ll} \operatorname{argmin} & \|x\|_0 \\ \Phi x = & b \\ x \in & \mathbb{R}^n \end{array} \quad (P_0)$$

- ▶ (Pseudo)norma l_0 cuenta coordenadas no nulas:

$$\|x\|_0 := \#\{i / x_i \neq 0\}$$

- ▶ Señales k -esparasas: $\Sigma_k = \{x \in \mathbb{R}^n / \|x\|_0 \leq k\}$

Problema a resolver

Minimización l_1

Algoritmo RW l_1

Metodología RW l_1 propuesta

Algoritmo RW l_1 subgradiente

Resultados experimentales


Metodología RW-LASSO

Resultados con ruido


Conclusiones

Motivación: adquisición señales esparsas

Proceso usual realiza n medidas $x^* \in \mathbb{R}^n$ y luego comprime



CS sensa y comprime en único paso: m medidas $b = \Phi x^*$



Recuperar x^* a partir de $b = \Phi x^*$ requiere resolver (P_0)

Problema a resolver

Minimización l_1

Algoritmo RW/ l_1

Metodología RW/ l_1 propuesta

Algoritmo RW/ l_1 subgradiente

Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones

Surgimiento del área

- ▶ CS surge como tal con trabajos de Donoho [2006] y de Candès, Romberg y Tao [2005, 2006]



- ▶ Recuperación con minimización l_1 :
 - ▶ Década 1970 recuperar señales esparsas en Sismología
 - ▶ 1990 primeros resultados teóricos sobre desempeño
- ▶ Recuperación con algoritmos “Greedy” (1993):
 - ▶ Matching Pursuit (MP) y
 - ▶ Orthogonal Matching Pursuit (OMP) utilizado en actualidad (con sus variantes)

Problema a resolver

Minimización l_1

Algoritmo RW/l_1

Metodología RW/l_1 propuesta

Algoritmo RW/l_1 subgradiente

Resultados experimentales


Metodología RW -LASSO

Resultados con ruido


Conclusiones

Desarrollo impulsado por gran cantidad de aplicaciones:

- ▶ Imagenología médica
- ▶ Conversión A/D
- ▶ Detección por RADAR
- ▶ Corrección errores
- ▶ Cámaras digitales
- ▶ Radioastronomía
- ▶ Comunicación inalámbrica



(a) full sampling



(b) 39% sampling,
SNR=32.2

Problema a resolver

Minimización l_1

Algoritmo RW/ l_1

Metodología RW/ l_1 propuesta

Algoritmo RW/ l_1 subgradiente

Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones

Complejidad del problema (P_0)

$$\begin{aligned} \operatorname{argmin} \quad & \|x\|_0 \\ \Phi x = & b \end{aligned} \quad (P_0)$$

- ▶ ¿Cómo hallar solución x^* de (P_0)?
 - ▶ Si conocemos soporte S , basta resolver $\Phi_S x = b$
- ▶ Si no conocemos soporte S :
 - ▶ probar todos los soportes, de todos los tamaños k , comenzando con $k = 1$
- ▶ Pero hay C_k^n posibles soportes de tamaño k
- ▶ Complejidad combinatoria y podría tardar demasiado:
 - ▶ $n = 100$ y $k = 15$: $C_{15}^{100} \simeq 2.53 \times 10^{17}$ soportes
 - ▶ cada prueba $1\mu s \Rightarrow$ hasta 8000 años en hallar solución
- ▶ \nexists algoritmo resolver (P_0) tiempo polinomial: NP-difícil

Problema a resolver

Minimización l_1

Algoritmo RW l_1

Metodología RW l_1 propuesta

Algoritmo RW l_1 subgradiente

Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones

Minimización l_1 ("Basis Pursuit")

- ▶ Se reemplaza (pseudo)norma l_0 por norma l_1 :

$$\begin{array}{ll} \operatorname{argmin} & \|x\|_1 = \operatorname{argmin} \sum_{i=1}^n |x_i| \\ \Phi x = b & \Phi x = b \\ x \in \mathbb{R}^n & x \in \mathbb{R}^n \end{array} \quad (P_1)$$

- ▶ Problema convexo \Rightarrow solución en tiempo polinomial




Figure: Norma l_2 solución menos esparsa

Problema a resolver

Minimización l_1

Algoritmo RW/ l_1

Metodología RW/ l_1 propuesta

Algoritmo RW/ l_1 subgradiente

Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones

Equivalencia (P_1) y (P_0): condición suficiente

Definition (Propiedad de Isometría Restringida (RIP))

$\Phi \in \mathbb{R}^{m \times n}$ cumple RIP de orden k si $\exists \delta_k \in [0, 1]$ tal que:

$$(1 - \delta_k) \|x\|_2^2 \leq \|\Phi x\|_2^2 \leq (1 + \delta_k) \|x\|_2^2, \forall x \in \Sigma_k$$

Theorem (Candès y Tao)

Si Φ cumple RIP $2k$, con $\delta_{2k} < \sqrt{2} - 1$ y $b = \Phi x^*$, $x^* \in \Sigma_k$:

1. (P_0) tiene solución k -esparsa única x^*
2. Si \hat{x} solución de (P_1) $\Rightarrow \hat{x} = x^*$

Problema a resolver

Minimización l_1

Algoritmo RW/ l_1

Metodología RW/ l_1 propuesta

Algoritmo RW/ l_1 subgradiente

Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones

Equivalencia (P_1) y (P_0): Φ Gaussiana

Theorem (Condición necesaria)

Si Φ RIP orden k , con $\delta_k \in (0, 1) \Rightarrow m \geq C_\delta k \log\left(\frac{n}{k}\right)$

Theorem (Candès y Tao)

$\Phi \in \mathbb{R}^{m \times n}$, con $\Phi_{ij} \sim N(0, 1)$ iid. Dados $\epsilon, \gamma \in (0, 1)$ y

$$m \geq \frac{2}{\gamma^2} \left(k \ln\left(e \frac{n}{k}\right) + \log\left(\frac{2}{\epsilon}\right) \right)$$

Con probabilidad $\geq 1 - \epsilon$, $\bar{\Phi} = \frac{1}{\sqrt{m}}\Phi$ cumple RIP con:

$$\delta_k \leq 2c\gamma + c^2\gamma^2, \quad c = 1 + \frac{1}{\sqrt{2 \ln\left(e \frac{n}{k}\right)}}$$

Problema a resolver

Minimización l_1

Algoritmo RW l_1

Metodología RW l_1 propuesta

Algoritmo RW l_1 subgradiente

Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones

Problema Weighted l_1 (l_1 con pesos)

- ▶ n pesos $w_i \geq 0$, problema Weighted l_1 asociado:

$$\hat{x} \in \underset{\substack{\Phi x = b \\ x \in \mathbb{R}^n}}{\operatorname{argmin}} \sum_{i=1}^n w_i |x_i| \quad (P_1 W)$$

- ▶ Objetivo: pesos w_i tales que $\hat{x} = x^*$, solución de (P_0)
- ▶ Caso ideal: si se conoce solución x^* de (P_0) , tomar:

$$w_i = \frac{1}{|x_i^*|} \in [0, \infty]$$

- ▶ Con esto: $x_i^* = 0 \Rightarrow$ "costo" $w_i = +\infty \Rightarrow \hat{x}_i = 0$

Problema a resolver

Minimización l_1

Algoritmo RW l_1

Metodología RW l_1 propuesta

Algoritmo RW l_1 subgradiente

Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones

Ejemplo en que $P_1 \not\Rightarrow P_0$ pero $P_1 W \Rightarrow P_0$




Figure: (a) x^* no es solución P_1 ; (b) x^* solución $P_1 W$

Problema a resolver

Minimización l_1

Algoritmo RW l_1

Metodología RW l_1 propuesta

Algoritmo RW l_1 subgradiente

Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones

Algoritmo RW_{l_1} de Candès, Wakin y Boyd [2008]

- ▶ Caso no ideal en que no se conoce x^*
- ▶ Caso ideal $w_i = \frac{1}{|x_i^*|}$ sugiere:

$$w_i^{k+1} = \frac{1}{|x_i^{k+1}|}$$

- ▶ Si w^k estimación pesos \Rightarrow candidato a x^* :

$$x^{k+1} \in \underset{\substack{\Phi x = b \\ x \in \mathbb{R}^n}}{\operatorname{argmin}} \sum_{i=1}^n w_i^k |x_i|, \quad \forall k \geq 0$$

- ▶ En la práctica $w_i^{k+1} = \frac{1}{|x_i^{k+1}| + \epsilon}$, $\epsilon > 0$ (algoritmo CWB)

Problema a resolver

Minimización l_1

Algoritmo RW_{l_1}

Metodología RW_{l_1} propuesta

Algoritmo RW_{l_1} subgradiente

Resultados experimentales

Metodología RW -LASSO

Resultados con ruido

Conclusiones

- ▶ Basada en relajación Lagrangeana
- ▶ Dada $x^* \in \Sigma_k$, solución de (P_0) , se define primal ideal:

$$\hat{x} \in \underset{\substack{\Phi x = b \\ |x_i| \leq |x_i^*|, \forall i}}{\operatorname{argmin}} \quad 0 \quad (P)$$

- ▶ Problema de factibilidad: se busca cumplir restricciones
- ▶ \hat{x} solución de $(P) \Rightarrow \|\hat{x}\|_0 \leq \|x^*\|_0 \Rightarrow \hat{x}$ solución (P_0)
- ▶ Problema convexo pero ideal

Problema a resolver

Minimización l_1

Algoritmo RW_{l_1}

Metodología RW_{l_1} propuesta

Algoritmo RW_{l_1} subgradiente

Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones

Relajación restricciones ideales

- ▶ Relajando restricciones ideales $|x_i| \leq |x_i^*|$, lagrangeano:

$$L(x, w) := 0 + \sum_{i=1}^n w_i (|x_i| - |x_i^*|) = \sum_{i=1}^n w_i |x_i| - \sum_{i=1}^n w_i |x_i^*|$$

- ▶ Función dual asociada:

$$d(w) := \min_{\substack{\Phi x = b \\ x \in \mathbb{R}^n}} L(w, x) =$$

$$= \left(\min_{\substack{\Phi x = b \\ x \in \mathbb{R}^n}} \sum_{i=1}^n w_i |x_i| \right) - \sum_{i=1}^n w_i |x_i^*|$$

- ▶ Problema "Weighted l_1 ", w_i multiplicadores Lagrange

Problema a resolver

Minimización l_1

Algoritmo RW l_1

Metodología RW l_1 propuesta

Algoritmo RW l_1 subgradiente

Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones

Metodología propuesta para actualizar pesos

- ▶ Pesos $w_i \geq 0$ son multiplicadores Lagrange \Rightarrow
- ▶ Estimar w_i con algoritmos para estimar multiplicadores
- ▶ Alternativamente, estimar w_i como soluciones del dual:

$$\begin{aligned} & \operatorname{argmax} && d(w) && (D) \\ & w \geq 0 \\ & w \in \mathbb{R}^n \end{aligned}$$

- ▶ Maximización cóncava (\Leftrightarrow minimización convexa)
- ▶ Función objetivo $d(w)$ no siempre diferenciable
- ▶ Algoritmo subgradiente para resolver (D)

Problema a resolver

Minimización l_1

Algoritmo RW/ l_1

Metodología RW/ l_1 propuesta

Algoritmo RW/ l_1 subgradiente

Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones

Soluciones del dual (ideal) D

Proposición

Hay dualidad fuerte: $d^* = f^* = 0$

- ▶ $w = \vec{0}$ solución dual pero no devuelve solución de (P_0) :

$$\hat{x} \in \underset{\Phi x = b}{\operatorname{argmin}} \sum_{i=1}^n 0|x_i| = \underset{\Phi x = b}{\operatorname{argmin}} 0 = \{\Phi x = b\}$$

Proposición

Sea $\hat{w} \geq 0 / \hat{w}_i = 0 \Leftrightarrow x_i^* \neq 0$ (soporte disjunto). Entonces:

- ▶ \hat{w} solución del dual y
- ▶ $\hat{x} \in \underset{\Phi x = b}{\operatorname{argmin}} \sum_{i=1}^n \hat{w}_i |x_i|$ solución de (P_0)

Problema a resolver

Minimización l_1

Algoritmo RW/l₁

Metodología RW/l₁ propuesta

Algoritmo RW/l₁ subgradiente

Resultados experimentales

Metodología RW-LASSO

Resultados con ruido


Conclusiones

Algoritmo subgradiente (busca solución dual)

- ▶ “Ascenso” por (sub)gradiente en función dual cóncava:

$$\begin{cases} w^{k+1} = w^k + \alpha_k g^k, \alpha_k > 0, g^k \in \partial d(w^k) \\ w^{k+1} = \max\{0, w^{k+1}\} \end{cases}$$

- ▶ Puede no ser de ascenso: $d(w^{k+1}) < d(w^k), \forall \alpha_k > 0$



- ▶ Siempre es posible elegir paso tal que \forall solución w^* :

$$\forall k \geq 0, \exists \alpha_k > 0 / \|w^{k+1} - w^*\| < \|w^k - w^*\|$$

Problema a resolver

Minimización l_1

Algoritmo RW/ l_1

Metodología RW/ l_1 propuesta

Algoritmo RW/ l_1 subgradiente

Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones

Algoritmo subgradiente (busca solución dual)

- ▶ ¿Cómo hallar un subgradiente de $d(w)$ en cada paso?

Theorem (Subgradiente de función dual en \hat{w})

$$\hat{x} \in \underset{\Phi x = b}{\operatorname{argmin}} \sum_{i=1}^n \hat{w}_i |x_i| \Rightarrow g(\hat{x}) = |\hat{x}| - |x^*| \in \partial d(\hat{w})$$

Metodología + Subgradiente:

- ▶ $x^{k+1} \in \underset{\Phi x = b}{\operatorname{argmin}} \sum_{i=1}^n w_i^k |x_i|$
- ▶ $g^k = |x^{k+1}| - |x^*|$ subgradiente dual en w^k
- ▶ $w^{k+1} = \max\{w^k + \alpha_k g^k, 0\}, \alpha_k > 0$

Problema a resolver

Minimización l_1

Algoritmo RW/ l_1

Metodología RW/ l_1 propuesta

Algoritmo RW/ l_1 subgradiente

Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones

Restricciones no ideales

- ▶ Restricciones ideales: $g_i(x) = |x_i| - |x_i^*|$
- ▶ En la práctica no se conoce solución x^* de (P_0)
- ▶ Reemplazar x^* por estimación x^{k+1} (“amplificada”):

$$g_i^k(x) = |x_i| - (1 + \epsilon_k) |x_i^{k+1}|, \quad \epsilon_k > 0$$

Donde:

$$x^{k+1} \in \underset{\Phi x = b}{\operatorname{argmin}} \sum_{i=1}^n w_i^k |x_i|$$

- ▶ Cada paso tiene asociado problema primal no ideal:

$$\underset{\Phi x = b}{\operatorname{argmin}} \quad 0 \quad (P^k)$$
$$|x_i| \leq (1 + \epsilon_k) |x_i^{k+1}|, \quad \forall i$$

Problema a resolver

Minimización l_1

Algoritmo RW l_1

Metodología RW l_1 propuesta

Algoritmo RW l_1 subgradiente

Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones

Modelo utilizado

- ▶ $\Phi \in \mathbb{R}^{m \times n}$ matriz de medida aleatoria
- ▶ $n = 256$, $m = 100$ y entradas independientes:

$$\Phi_{ij} \sim N\left(0, \sigma = \frac{1}{\sqrt{m}}\right), \forall i, j$$

- ▶ Soporte x^* : sorteo k indices S_k
- ▶ Valores soporte:

$$x_i^* \sim N\left(0, \sigma = \frac{1}{\sqrt{k}}\right), \forall i \in S_k$$

- ▶ Término independiente: $b = \Phi x^* \in \mathbb{R}^m$
- ▶ Convergencia si: $\|x^{\max\text{Iter}} - x^*\|_\infty \leq 1 \times 10^{-3}$

Problema a resolver

Minimización l_1

Algoritmo RW/ l_1

Metodología RW/ l_1 propuesta

Algoritmo RW/ l_1 subgradiente


Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones

Resultados ($m = 100$ fijo, $k \in [15, 55]$)



- ▶ Existe región de transición de fase
- ▶ En minimización l_1 : si $n \rightarrow \infty \Rightarrow$ ancho región $\rightarrow 0$

Problema a resolver

Minimización l_1

Algoritmo RWI1

Metodología RWI1 propuesta

Algoritmo RWI1 subgradiente





Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones

Resultados ($m = 100$ fijo, $k \in [15, 55]$)



Problema a resolver

Minimización l_1

Algoritmo RWI1

Metodología RWI1 propuesta

Algoritmo RWI1 subgradiente

Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones

Medidas b afectadas por ruido Gaussiano aditivo:

$$b = \Phi x^* + z, \quad z_i \sim N(0, \sigma^2) \text{ independientes}$$

Se busca resolver:

$$\underset{\| \Phi x - b \|_2 \leq \eta}{\operatorname{argmin}} \quad \|x\|_0 \quad (P_0^\eta)$$

Problema Weighted l_1 asociado:

$$\underset{\| \Phi x - b \|_2 \leq \eta}{\operatorname{argmin}} \quad \sum_{i=1}^n w_i |x_i| \quad (P_1^\eta W)$$

Problema a resolver

Minimización l_1

Algoritmo RW l_1

Metodología RW l_1 propuesta

Algoritmo RW l_1 subgradiente

Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones

Problema W-LASSO (sustituye a Weighted l_1)

- ▶ Problema primal ideal:

$$\begin{aligned} & \operatorname{argmin} && 0 \\ & \frac{1}{2} \|\Phi x - b\|_2^2 \leq \frac{\eta^2}{2} \\ & |x_i| \leq |x_i^*|, \forall i \end{aligned}$$

- ▶ Relajando restricciones ideales:

$$d(w) = \left(\min_{\frac{1}{2} \|\Phi x - b\|_2^2 \leq \frac{\eta^2}{2}} \sum_{i=1}^n w_i |x_i| \right) - \sum_{i=1}^n w_i |x_i^*|$$

- ▶ Problema Weighted l_1 restricciones cuadráticas
- ▶ w_i multiplicadores de Lagrange como antes

Problema a resolver

Minimización l_1

Algoritmo RW l_1

Metodología RW l_1 propuesta

Algoritmo RW l_1 subgradiente

Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones

Problema W-LASSO (sustituye a Weighted l_1)

- ▶ Relajando ambas restricciones:

$$d(w, \lambda) = \left(\min_{x \in \mathbb{R}^n} \frac{\lambda}{2} \|\Phi x - b\|_2^2 + \sum_{i=1}^n w_i |x_i| \right) +$$
$$- \left(\frac{\lambda}{2} \eta^2 + \sum_{i=1}^n w_i |x_i^*| \right) \text{ Weighted LASSO}$$

- ▶ Restricciones ideales $g_i(x) = |x_i| - |x_i^*|$ por:

$$g_i^k(x) = |x_i| - (1 + \epsilon_k) |x_i^{k+1}|, \epsilon_k > 0$$

- ▶ $x^{k+1} \in \operatorname{argmin}_{x \in \mathbb{R}^n} \frac{\lambda}{2} \|\Phi x - b\|_2^2 + \sum_{i=1}^n w_i^k |x_i|$

- ▶ Resolver W-LASSO en cada paso (antes Weighted l_1)

Problema a resolver

Minimización l_1

Algoritmo RW l_1

Metodología RW l_1 propuesta

Algoritmo RW l_1 subgradiente

Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones

- ▶ Φ y x^* igual que sin ruido ($m = 128$, $n = 256$)
- ▶ Medidas $b = \Phi x^* + z$, $z_i \sim N(0, \sigma^2)$ iid
- ▶ $N_p = 300$ pruebas con $k = 38$ fijo
- ▶ Mejora respecto solución de l_1 con ruido:

$$a = 100 \times \left(1 - \frac{\|x^{RW} - x^*\|_2}{\|x_{l_1} - x^*\|_2} \right) \%$$

Problema a resolver

Minimización l_1

Algoritmo RW/ l_1

Metodología RW/ l_1 propuesta

Algoritmo RW/ l_1 subgradiente



Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones

Resultados con ruido



- ▶ RW-LASSO: +32% minimización l_1 y +40% RW l_1

Problema a resolver

Minimización l_1

Algoritmo RW l_1

Metodología RW l_1 propuesta

Algoritmo RW l_1 subgradiente

Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones

- ▶ CS y minimización l_1 con resultados más relevantes
- ▶ Problema Weighted l_1 y algoritmo RW/l_1 de CWB

- ▶ Nueva **metodología** actualizar pesos RW/l_1 Lagrange
- ▶ **Algoritmo** RW/l_1 subgradiente alternativo a CWB
- ▶ Misma metodología con ruido: algoritmo RW-LASSO

Problema a resolver

Minimización l_1

Algoritmo RW/l_1

Metodología RW/l_1 propuesta

Algoritmo RW/l_1 subgradiente

Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones

- ▶ Desempeño RW problema CS aleatorio Φ Gaussiana
- ▶ Sin ruido:
 - ▶ RW/l_1 de CWB y subgradiente desempeño similar
 - ▶ Interpretación pesos multiplicadores Lagrange
- ▶ Con ruido Gaussiano:
 - ▶ RW-LASSO propuesto mejora considerable a RW/l_1

Problema a resolver

Minimización l_1

Algoritmo RW/l_1

Metodología RW/l_1 propuesta

Algoritmo RW/l_1 subgradiente


Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones

Equivalencia (P_1) y (P_0): Φ Gaussiana



Problema a resolver

Minimización l_1

Algoritmo RW l_1

Metodología RW l_1 propuesta

Algoritmo RW l_1 subgradiente

Resultados experimentales

Metodología RW-LASSO



Resultados con ruido

Conclusiones

Ejemplo en que $P_1 \not\Rightarrow P_0$

$$\Phi = \begin{pmatrix} 2 & 1 & 1 \\ 1 & 1 & 2 \end{pmatrix}, \quad b = \begin{pmatrix} 1 \\ 1 \end{pmatrix}, \quad x^* = (0, 1, 0)$$

- ▶ Otra solución de $\Phi x = b$: $\hat{x} = (\frac{1}{3}, 0, \frac{1}{3})$
- ▶ $\|\hat{x}\|_1 = \frac{2}{3} < 1 = \|x^*\|_1 \Rightarrow x^*$ no es solución de (P_1)



Problema a resolver

Minimización l_1

Algoritmo RW/ l_1

Metodología RW/ l_1 propuesta

Algoritmo RW/ l_1 subgradiente

Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones

Algoritmo Gradiente Proximal (GP)

- ▶ Problema convexo: $\operatorname{argmin}_{x \in \mathbb{R}^n} f(x) + g(x)$
- ▶ g continua, no necesariamente diferenciable
- ▶ Gradiente Proximal: $x^{k+1} = \operatorname{Prox}_{\alpha g}(x^k - \alpha \nabla f(x^k))$
- ▶ Operador proximal de $h : \mathbb{R}^n \rightarrow \mathbb{R}$:

$$\operatorname{Prox}_{\alpha h}(v) := \operatorname{argmin}_{x \in \mathbb{R}^n} \left\{ h(x) + \frac{1}{2\alpha} \|x - v\|_2^2 \right\} : \mathbb{R}^n \rightarrow \mathbb{R}^n$$

- ▶ GP Acelerado (Nesterov):

1. Punto intermedio:

$$y^k = x^k + r_k(x^k - x^{k-1}), \forall k \geq 1, r_k = \frac{k}{k+3} \in [0, 1)$$

2. GP a punto intermedio:

$$x^{k+1} = \operatorname{prox}_{\alpha g}(y^k - \alpha \nabla f(y^k)), \forall k \geq 1$$

Problema a resolver

Minimización l_1

Algoritmo RW l_1

Metodología RW l_1 propuesta

Algoritmo RW l_1 subgradiente

Resultados experimentales

Metodología RW-LASSO


Resultados con ruido

Conclusiones

GPA para W-LASSO: algoritmo W-FISTA

$$g(x) = \|Wx\|_1 = \sum_{i=1}^n w_i |x_i| = \sum_{i=1}^n g_i(x_i)$$

$$(\text{prox}_{\alpha g}(x))_i = \text{prox}_{\alpha g_i}(x_i) = \begin{cases} x_i - \alpha w_i & x_i \geq \alpha w_i \\ 0 & |x_i| \leq \alpha w_i \\ x_i + \alpha w_i & x_i \leq -\alpha w_i \end{cases}$$



$$f(x) = \frac{\lambda}{2} \|\Phi x - b\|_2^2 \Rightarrow \nabla f(x) = \lambda \Phi^T (\Phi x - b)$$

Problema a resolver

Minimización l_1

Algoritmo RW l_1

Metodología RW l_1 propuesta

Algoritmo RW l_1 subgradiente

Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones

Algorithm 1 RW-LASSO subgradiente (no ideal y con ruido)

```
1:  $x^1 \in \operatorname{argmin}_{x \in \mathbb{R}^n} \frac{\lambda^0}{2} \|\Phi x - b\|_2^2 + \sum_{i=1}^n w_i^0 |x_i|$  {W-LASSO}
2:
3:  $k = 0$ 
4: while  $k < \max\text{Iter}$  do
5:    $g_i^k = g_i^k(x^{k+1}) = |x_i^{k+1}| - (1 + \epsilon_k) |x_i^{k+1}|$ 
6:    $w_i^{k+1} = \max(0, w_i^k + \alpha_k g_i^k)$ 
7:
8:    $g_\lambda^k = g_\lambda(x^{k+1}) = \frac{1}{2} (\|\Phi x^{k+1} - b\|_2^2 - \eta^2)$ 
9:    $\lambda^{k+1} = \max(0, \lambda^k + \alpha_k g_\lambda^k)$ 
10:
11:    $k = k + 1$ 
12:
13:    $x^0 = x^k$ 
14:    $x^{k+1} \in \operatorname{argmin}_{x \in \mathbb{R}^n} \frac{\lambda^k}{2} \|\Phi x - b\|_2^2 + \sum_{i=1}^n w_i^k |x_i|$ 
15:
16: end while
17: return  $x^{k+1}$ 
```

Problema a resolver

Minimización l_1

Algoritmo RW l_1

Metodología RW l_1 propuesta

Algoritmo RW l_1 subgradiente

Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones

Unicidad de soluciones de (P_0)

Theorem

k -unicidad $\Leftrightarrow \text{spark}(\Phi) > 2k$

- ▶ Cálculo del spark es un problema NP-difícil
- ▶ Como $m \leq n \Rightarrow \text{rg}(\Phi) \leq m \Rightarrow \text{spark}(\Phi) \leq m + 1$

Corollary

Se requieren $m \geq 2k$ medidas para tener k -unicidad

Theorem

Si Φ satisface RIP $2k$, con $\delta_{2k} < 1 \Rightarrow$ se tiene k -unicidad

No es necesario RIP con $\delta_{2k} < 1$ para tener k -unicidad:

$$\Phi = \begin{pmatrix} 2 & 1 & 1 \\ 1 & 1 & 2 \end{pmatrix}$$

Problema a resolver

Minimización l_1

Algoritmo RW/ l_1

Metodología RW/ l_1 propuesta

Algoritmo RW/ l_1 subgradiente

Resultados experimentales

Metodología RW-LASSO

Resultados con ruido


Conclusiones

Marco teórico CWB (algoritmo MM)

- ▶ CWB surge de aplicar MM a buscar soluciones de:

$$\begin{aligned} \operatorname{argmin}_{x \in \mathbb{R}^n} \sum_{i=1}^n \ln(|x_i| + \epsilon) &= \operatorname{argmin}_{x, u \in \mathbb{R}^n} \sum_{i=1}^n \ln(u_i + \epsilon) \\ \Phi x &= b \\ |x_i| &\leq u_i, \forall i \end{aligned}$$

- ▶ $\ln\left(\frac{|x_i|}{\epsilon} + 1\right)$ se parece a (pseudo)norma l_0 :



Problema a resolver

Minimización l_1

Algoritmo RW l_1

Metodología RW l_1 propuesta

Algoritmo RW l_1 subgradiente

Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones

Marco teórico CWB (algoritmo MM)

- ▶ Función objetivo cóncava $g(x, u) = \sum_{i=1}^n \ln(u_i + \epsilon)$
- ▶ Algoritmo MM:

$$(x^{k+1}, u^{k+1}) \in \underset{\substack{x, u \in \mathbb{R}^n \\ \Phi x = b \\ |x_i| \leq u_i, \forall i}}{\operatorname{argmin}} \sum_{i=1}^n \left(\frac{1}{u_i^k + \epsilon} \right) u_i \quad (1)$$

- ▶ Eliminando variable auxiliar:

$$x^{k+1} \in \underset{\substack{x \in \mathbb{R}^n \\ \Phi x = b}}{\operatorname{argmin}} \sum_{i=1}^n \left(\frac{1}{|x_i^k| + \epsilon} \right) |x_i| \quad (2)$$

Problema a resolver

Minimización l_1

Algoritmo RW l_1

Metodología RW l_1 propuesta

Algoritmo RW l_1 subgradiente

Resultados experimentales

Metodología RW-LASSO

Resultados con ruido

Conclusiones