

Adquisición Compresiva (Compressed Sensing)

Carlos Fernández Granda

Departamento de Ingeniería Eléctrica
Universidad de Stanford

19/7/2011

- 1 Ejemplo Introdutorio
- 2 Principios Básicos
- 3 Adquisición Aleatorizada
- 4 Isometrías Restringidas
- 5 Aplicaciones, Referencias y Perspectivas Futuras

- 1 Ejemplo Introdutorio
- 2 Principios Básicos
- 3 Adquisición Aleatorizada
- 4 Isometrías Restringidas
- 5 Aplicaciones, Referencias y Perspectivas Futuras

Imagen por Resonancia Magnética

- **Modelo** : Medimos la transformada de Fourier de una sección del cuerpo del paciente.

Imagen por Resonancia Magnética

- **Modelo** : Medimos la transformada de Fourier de una sección del cuerpo del paciente.
- **Problema** : Duración prolongada del proceso de medida.

Imagen por Resonancia Magnética

- **Modelo** : Medimos la transformada de Fourier de una sección del cuerpo del paciente.
- **Problema** : Duración prolongada del proceso de medida.
 - Incómodo para el paciente.

Imagen por Resonancia Magnética

- **Modelo** : Medimos la transformada de Fourier de una sección del cuerpo del paciente.
- **Problema** : Duración prolongada del proceso de medida.
 - Incómodo para el paciente.
 - Limita ciertas aplicaciones (imágenes cardiacas).

Imagen por Resonancia Magnética

- **Modelo** : Medimos la transformada de Fourier de una sección del cuerpo del paciente.
- **Problema** : Duración prolongada del proceso de medida.
 - Incómodo para el paciente.
 - Limita ciertas aplicaciones (imágenes cardiacas).
- Sin embargo, con frecuencia la imagen es **compresible**.

Compresión mediante Wavelets

- **Transformada wavelet** : Descomposición en una base de funciones con distintos niveles de resolución.

Compresión mediante Wavelets

- **Transformada wavelet** : Descomposición en una base de funciones con distintos niveles de resolución.
- Muchas imágenes naturales son dispersas (*sparse*) en estas bases.

Compresión mediante Wavelets

- **Transformada wavelet** : Descomposición en una base de funciones con distintos niveles de resolución.
- Muchas imágenes naturales son dispersas (*sparse*) en estas bases.





Imagen original



Coeficientes Wavelet

Compresión mediante Wavelets

Si eliminamos un 90% de los coeficientes de la decomposición, la calidad apenas se resiente.




Imagen original




Imagen comprimida

Aliasing

- Estamos midiendo información muy redundante.

Aliasing

- Estamos midiendo información muy redundante.
- ¿Por qué no submuestrear?

Aliasing

- Estamos midiendo información muy redundante.
- ¿Por qué no submuestrear?
- Porque lo dice Nyquist (y Shannon).

Aliasing

- Estamos midiendo información muy redundante.
- ¿Por qué no submuestrear?
- Porque lo dice Nyquist (y Shannon).
- El submuestreo produce solapamientos (*aliasing*).




Imagen original



Submuestreo 50%

Adquisición compresiva

- **Paso 1** : Aleatorizamos el submuestreo.

Adquisición compresiva

- **Paso 1** : Aleatorizamos el submuestreo.
- **Paso 2** : Al reconstruir penalizamos la norma ℓ_1 de la transformada wavelet de la imagen.

Adquisición compresiva

- **Paso 1** : Aleatorizamos el submuestreo.
- **Paso 2** : Al reconstruir penalizamos la norma ℓ_1 de la transformada wavelet de la imagen.





Imagen original



Submuestreo 33%

- 1 Ejemplo Introdutorio
- 2 Principios Básicos**
- 3 Adquisición Aleatorizada
- 4 Isometrías Restringidas
- 5 Aplicaciones, Referencias y Perspectivas Futuras

Motivación para la Adquisición Compresiva

- Paradigma clásico de tratamiento de señales :

Motivación para la Adquisición Compresiva

- Paradigma clásico de tratamiento de señales :
 - 1 Muestrear proporcionalmente al **ancho de banda**.

Motivación para la Adquisición Compresiva

- Paradigma clásico de tratamiento de señales :
 - 1 Muestrear proporcionalmente al **ancho de banda**.
 - 2 Comprimir.

Motivación para la Adquisición Compresiva

- Paradigma clásico de tratamiento de señales :
 - 1 Muestrear proporcionalmente al **ancho de banda**.
 - 2 Comprimir.
- En aplicaciones modernas como tratamiento de imágenes o vídeo, las dimensiones de las señales son gigantescas.

Motivación para la Adquisición Compresiva

- Paradigma clásico de tratamiento de señales :
 - 1 Muestrear proporcionalmente al **ancho de banda**.
 - 2 Comprimir.
- En aplicaciones modernas como tratamiento de imágenes o vídeo, las dimensiones de las señales son gigantescas.
- Invertimos mucho esfuerzo en medir información redundante para luego desecharla.

Motivación para la Adquisición Compresiva

- Paradigma clásico de tratamiento de señales :
 - 1 Muestrear proporcionalmente al **ancho de banda**.
 - 2 Comprimir.
- En aplicaciones modernas como tratamiento de imágenes o vídeo, las dimensiones de las señales son gigantescas.
- Invertimos mucho esfuerzo en medir información redundante para luego desecharla.
- Paradigma de la adquisición compresiva :

Motivación para la Adquisición Compresiva

- Paradigma clásico de tratamiento de señales :
 - 1 Muestrear proporcionalmente al **ancho de banda**.
 - 2 Comprimir.
- En aplicaciones modernas como tratamiento de imágenes o vídeo, las dimensiones de las señales son gigantescas.
- Invertimos mucho esfuerzo en medir información redundante para luego desecharla.
- Paradigma de la adquisición compresiva :
 - 1 Muestrear proporcionalmente a la **complejidad**.

Motivación para la Adquisición Compresiva

- Paradigma clásico de tratamiento de señales :
 - 1 Muestrear proporcionalmente al **ancho de banda**.
 - 2 Comprimir.
- En aplicaciones modernas como tratamiento de imágenes o vídeo, las dimensiones de las señales son gigantescas.
- Invertimos mucho esfuerzo en medir información redundante para luego desecharla.
- Paradigma de la adquisición compresiva :
 - 1 Muestrear proporcionalmente a la **complejidad**.
- Las muestras son una versión comprimida de la señal, medimos y comprimimos **a la vez**.

Motivación para la Adquisición Compresiva

- Paradigma clásico de tratamiento de señales :
 - 1 Muestrear proporcionalmente al **ancho de banda**.
 - 2 Comprimir.
- En aplicaciones modernas como tratamiento de imágenes o vídeo, las dimensiones de las señales son gigantescas.
- Invertimos mucho esfuerzo en medir información redundante para luego desecharla.
- Paradigma de la adquisición compresiva :
 - 1 Muestrear proporcionalmente a la **complejidad**.
- Las muestras son una versión comprimida de la señal, medimos y comprimimos **a la vez**.
- Precio a pagar :

Motivación para la Adquisición Compresiva

- Paradigma clásico de tratamiento de señales :
 - 1 Muestrear proporcionalmente al **ancho de banda**.
 - 2 Comprimir.
- En aplicaciones modernas como tratamiento de imágenes o vídeo, las dimensiones de las señales son gigantescas.
- Invertimos mucho esfuerzo en medir información redundante para luego desecharla.
- Paradigma de la adquisición compresiva :
 - 1 Muestrear proporcionalmente a la **complejidad**.
- Las muestras son una versión comprimida de la señal, medimos y comprimimos **a la vez**.
- Precio a pagar :
 - Pequeño incremento en la tasa de compresión.

Motivación para la Adquisición Compresiva

- Paradigma clásico de tratamiento de señales :
 - 1 Muestrear proporcionalmente al **ancho de banda**.
 - 2 Comprimir.
- En aplicaciones modernas como tratamiento de imágenes o vídeo, las dimensiones de las señales son gigantescas.
- Invertimos mucho esfuerzo en medir información redundante para luego desecharla.
- Paradigma de la adquisición compresiva :
 - 1 Muestrear proporcionalmente a la **complejidad**.
- Las muestras son una versión comprimida de la señal, medimos y comprimimos **a la vez**.
- Precio a pagar :
 - Pequeño incremento en la tasa de compresión.
 - Condiciones sobre el proceso de muestreo.

Sistema Indeterminado de Ecuaciones

$$\mathbf{A} \quad \mathbf{x} = \mathbf{b}$$

$(\mathbf{m} \times \mathbf{n})$

- La matriz \mathbf{A} modela el submuestreo lineal de una señal \mathbf{x} .

Sistema Indeterminado de Ecuaciones

$$\begin{matrix} \mathbf{A} \\ (\mathbf{m} \times \mathbf{n}) \end{matrix} \mathbf{x} = \mathbf{b}$$

- La matriz \mathbf{A} modela el submuestreo lineal de una señal \mathbf{x} .
- Modelo útil para muchas aplicaciones.

Sistema Indeterminado de Ecuaciones

$$\mathbf{A} \mathbf{x} = \mathbf{b}$$

($\mathbf{m} \times \mathbf{n}$)

- La matriz \mathbf{A} modela el submuestreo lineal de una señal \mathbf{x} .
- Modelo útil para muchas aplicaciones.
- **Problema** : ¿Cuál es el **mínimo** número de muestras \mathbf{m} necesario para reconstruir \mathbf{x} ?

Sistema Indeterminado de Ecuaciones

$$\mathbf{A} \mathbf{x} = \mathbf{b}$$

$(\mathbf{m} \times \mathbf{n})$

- La matriz \mathbf{A} modela el submuestreo lineal de una señal \mathbf{x} .
- Modelo útil para muchas aplicaciones.
- **Problema** : ¿Cuál es el **mínimo** número de muestras \mathbf{m} necesario para reconstruir \mathbf{x} ?
 $\mathbf{m} = \mathbf{n}$ proporcional a la resolución (si A es invertible).

Sistema Indeterminado de Ecuaciones

$$\boxed{\begin{matrix} \mathbf{A} \\ (\mathbf{m} \times \mathbf{n}) \end{matrix}} \quad \boxed{\mathbf{x}} = \boxed{\mathbf{b}}$$

- **Hipótesis** : \mathbf{x} es **s-disperso**, sólo un subconjunto \mathbf{T} de s índices de \mathbf{x} es distinto de cero.

Sistema Indeterminado de Ecuaciones

$$A \mathbf{x} = \mathbf{b}$$

- **Hipótesis** : \mathbf{x} es **s-disperso**, sólo un subconjunto T de s índices de \mathbf{x} es distinto de cero.

Sistema Indeterminado de Ecuaciones

$$A \mathbf{x} = \mathbf{b}$$

- **Hipótesis** : \mathbf{x} es **s-disperso**, sólo un subconjunto \mathbf{T} de s índices de \mathbf{x} es distinto de cero.
- ¿Cuál es el **m** mínimo en este caso si conocemos \mathbf{T} ?

Sistema Indeterminado de Ecuaciones

$$\begin{array}{c}
 \boxed{\mathbf{A}_T} \\
 (\mathbf{m} \times \mathbf{s})
 \end{array}
 \begin{array}{c}
 \boxed{\mathbf{x}_T} \\
 =
 \end{array}
 \begin{array}{c}
 \boxed{\mathbf{b}}
 \end{array}$$

- **Hipótesis** : \mathbf{x} es **s-disperso**, sólo un subconjunto \mathbf{T} de s índices de \mathbf{x} es distinto de cero.
- ¿Cuál es el \mathbf{m} mínimo en este caso si conocemos \mathbf{T} ?
 $\mathbf{m} = s$ proporcional a la complejidad (si \mathbf{A}_T es invertible).

Sistema Indeterminado de Ecuaciones

$$\boxed{\begin{matrix} \mathbf{A} \\ (\mathbf{m} \times \mathbf{n}) \end{matrix}} \quad \boxed{\mathbf{x}} = \boxed{\mathbf{b}}$$

- **Hipótesis** : \mathbf{x} es **s-disperso**, sólo un subconjunto \mathbf{T} de s índices de \mathbf{x} es distinto de cero.
- ¿Cuál es el \mathbf{m} mínimo en este caso si conocemos \mathbf{T} ?
 $\mathbf{m} = s$ proporcional a la complejidad (si $A_{\mathbf{T}}$ es invertible).
- En muchas aplicaciones, la hipótesis es válida, pero **no conocemos \mathbf{T}** .

Proceso de Adquisición Aleatorio

- Nuestro objetivo es reducir la dimensionalidad de la señal de manera **no adaptativa**.

Proceso de Adquisición Aleatorio

- Nuestro objetivo es reducir la dimensionalidad de la señal de manera **no adaptativa**.
- **Problema** : ¿Qué matrices **A** permiten hacer esto ?

Proceso de Adquisición Aleatorio

- Nuestro objetivo es reducir la dimensionalidad de la señal de manera **no adaptativa**.
- **Problema** : ¿Qué matrices \mathbf{A} permiten hacer esto ?
- **Problema relacionado** : Reducir la dimensionalidad de varias señales conservando las distancias entre ellas.

Proceso de Adquisición Aleatorio

- Nuestro objetivo es reducir la dimensionalidad de la señal de manera **no adaptativa**.
- **Problema** : ¿Qué matrices \mathbf{A} permiten hacer esto ?
- **Problema relacionado** : Reducir la dimensionalidad de varias señales conservando las distancias entre ellas.

Según el **Lema de Johnson-Lindenstrauss** basta con proyectar de **manera aleatoria**.

Proceso de Adquisición Aleatorio

- Nuestro objetivo es reducir la dimensionalidad de la señal de manera **no adaptativa**.
- **Problema** : ¿Qué matrices **A** permiten hacer esto ?
- **Problema relacionado** : Reducir la dimensionalidad de varias señales conservando las distancias entre ellas.

Según el **Lema de Johnson-Lindenstrauss** basta con proyectar de **manera aleatoria**.

- Utilizamos matrices aleatorias, por ejemplo $A_{ij} \sim \mathcal{N}(0,1)$.

Proceso de Adquisición Aleatorio

- Nuestro objetivo es reducir la dimensionalidad de la señal de manera **no adaptativa**.
- **Problema** : ¿Qué matrices **A** permiten hacer esto ?
- **Problema relacionado** : Reducir la dimensionalidad de varias señales conservando las distancias entre ellas.

Según el **Lema de Johnson-Lindenstrauss** basta con proyectar de **manera aleatoria**.

- Utilizamos matrices aleatorias, por ejemplo $A_{ij} \sim \mathcal{N}(0,1)$.
- Sorprendentemente, esto nos permite reconstruir cualquier **x** **s**-disperso con alta probabilidad a partir de **m = C s log(n)** muestras.

Reconstrucción Mediante Optimización

- A partir de \mathbf{A} y \mathbf{b} , ¿cómo reconstruimos \mathbf{x} sin conocer \mathbf{T} ?

Reconstrucción Mediante Optimización

- A partir de \mathbf{A} y \mathbf{b} , ¿cómo reconstruimos \mathbf{x} sin conocer \mathbf{T} ?
- Idealmente, resolveríamos el siguiente problema de optimización :

$$\min_{\mathbf{x}} \|\mathbf{x}\|_0 \text{ sujeto a } \mathbf{Ax} = \mathbf{b}$$

$\|\mathbf{x}\|_0 =$ número de elementos de \mathbf{x} distintos de cero.

Reconstrucción Mediante Optimización

- A partir de \mathbf{A} y \mathbf{b} , ¿cómo reconstruimos \mathbf{x} sin conocer \mathbf{T} ?
- Idealmente, resolveríamos el siguiente problema de optimización :

$$\min_{\mathbf{x}} \|\mathbf{x}\|_0 \text{ sujeto a } \mathbf{A}\mathbf{x} = \mathbf{b}$$

$\|\mathbf{x}\|_0 =$ número de elementos de \mathbf{x} distintos de cero.

- Este problema es **NP-complejo** (*NP-hard*).

Reconstrucción Mediante Optimización

- A partir de \mathbf{A} y \mathbf{b} , ¿cómo reconstruimos \mathbf{x} sin conocer \mathbf{T} ?
- Idealmente, resolveríamos el siguiente problema de optimización :

$$\min_x \|\mathbf{x}\|_0 \text{ sujeto a } \mathbf{Ax} = \mathbf{b}$$

$\|\mathbf{x}\|_0$ = número de elementos de \mathbf{x} distintos de cero.

- Este problema es **NP-complejo** (*NP-hard*).
- En su lugar, resolvemos :

$$\min_x \|\mathbf{x}\|_1 \text{ sujeto a } \mathbf{Ax} = \mathbf{b}$$

$$\|\mathbf{x}\|_1 = \sum_{i=1}^n |x_i|$$

Reconstrucción Mediante Optimización

- A partir de \mathbf{A} y \mathbf{b} , ¿cómo reconstruimos \mathbf{x} sin conocer \mathbf{T} ?
- Idealmente, resolveríamos el siguiente problema de optimización :

$$\min_x \|\mathbf{x}\|_0 \text{ sujeto a } \mathbf{A}\mathbf{x} = \mathbf{b}$$

$\|\mathbf{x}\|_0$ = número de elementos de \mathbf{x} distintos de cero.

- Este problema es **NP-complejo** (*NP-hard*).
- En su lugar, resolvemos :

$$\min_x \|\mathbf{x}\|_1 \text{ sujeto a } \mathbf{A}\mathbf{x} = \mathbf{b}$$

$$\|\mathbf{x}\|_1 = \sum_{i=1}^n |x_i|$$

- Este problema es resoluble de manera **eficiente** (reformulable como un programa lineal).

Intuición Geométrica


- La restricción $Ax = b$ define un hiperplano aleatorio de dimensión m .

Intuición Geométrica


- La restricción $Ax = b$ define un hiperplano aleatorio de dimensión m .
- La solución es el punto en el que el hiperplano es tangente a la bola inducida por la norma que minimizamos.

Intuición Geométrica

- La restricción $Ax = b$ define un hiperplano aleatorio de dimensión m .
- La solución es el punto en el que el hiperplano es tangente a la bola inducida por la norma que minimizamos.
- Si la bola es puntiaguda, la solución estará próxima a los ejes.




Norma ℓ_2 : $\|x\|_2 = \sqrt{\sum_{i=1}^n |x_i|^2}$




Norma ℓ_1 : $\|x\|_1 = \sum_{i=1}^n |x_i|$

Intuición Geométrica

- La restricción $Ax = b$ define un hiperplano aleatorio de dimensión m .
- La solución es el punto en el que el hiperplano es tangente a la bola inducida por la norma que minimizamos.
- Si la bola es puntiaguda, la solución estará próxima a los ejes.



Norma ℓ_2 : $\|x\|_2 = \sqrt{\sum_{i=1}^n |x_i|^2}$




Norma ℓ_1 : $\|x\|_1 = \sum_{i=1}^n |x_i|$

- La bola ℓ_1 es la bola **convexa** más puntiaguda.

- 1 Ejemplo Introductorio
- 2 Principios Básicos
- 3 Adquisición Aleatorizada**
- 4 Isometrías Restringidas
- 5 Aplicaciones, Referencias y Perspectivas Futuras


Muestras Aleatorizadas



- Interpretamos cada muestra como el producto de la señal dispersa x con un vector de muestreo a :

$$b_k = \langle a(k), x \rangle$$


Muestras Aleatorizadas



- Interpretamos cada muestra como el producto de la señal dispersa \mathbf{x} con un vector de muestreo \mathbf{a} :

$$b_k = \langle \mathbf{a}(k), \mathbf{x} \rangle$$


Muestras Aleatorizadas



- Interpretamos cada muestra como el producto de la señal dispersa x con un vector de muestreo a :

$$b_k = \langle a(k), x \rangle$$


Muestras Aleatorizadas



- Interpretamos cada muestra como el producto de la señal dispersa x con un vector de muestreo a :

$$b_k = \langle a(k), x \rangle$$

Muestras Aleatorizadas



- Interpretamos cada muestra como el producto de la señal dispersa x con un vector de muestreo a :

$$b_k = \langle a(k), x \rangle$$

- Reconstruimos minimizando la norma ℓ_1 dadas las muestras.

Reconstrucción por Optimización Convexa

- Utilizamos vectores aleatorios \mathbf{a} .

Reconstrucción por Optimización Convexa

- Utilizamos vectores aleatorios \mathbf{a} .
- Deben cumplir dos condiciones :

Incoherencia : $\max_{1 \leq k \leq n} |a_k|^2 \leq \mu$

Isotropía : $\mathbb{E}(\mathbf{a}\mathbf{a}^*) = \mathbf{I}$

Reconstrucción por Optimización Convexa

- Utilizamos vectores aleatorios \mathbf{a} .
- Deben cumplir dos condiciones :

Incoherencia : $\max_{1 \leq k \leq n} |a_k|^2 \leq \mu$

Isotropía : $\mathbb{E}(\mathbf{a}\mathbf{a}^*) = \mathbf{I}$

Teorema [Candès, Plan 2010]

Un vector s -disperso \mathbf{x} fijo es recuperable por minimización de la norma ℓ_1 con probabilidad $1 - 1/n - e^{-\beta}$ si el número de muestras satisface :

$$m \geq C \mu s \log n$$

Reconstrucción por Optimización Convexa

- Utilizamos vectores aleatorios \mathbf{a} .
- Deben cumplir dos condiciones :

$$\text{Incoherencia : } \max_{1 \leq k \leq n} |a_k|^2 \leq \mu$$

$$\text{Isotropía : } \mathbb{E}(\mathbf{a}\mathbf{a}^*) = \mathbf{I}$$

Teorema [Candès, Plan 2010]

Un vector s -disperso \mathbf{x} fijo es recuperable por minimización de la norma ℓ_1 con probabilidad $1 - 1/n - e^{-\beta}$ si el número de muestras satisface :

$$m \geq C \mu s \log n$$

- Muestreo proporcional a la complejidad si la incoherencia μ es $\mathbf{O}(1)$ con alta probabilidad.

Incoherencia

- Si conociésemos \mathbf{T} , podríamos elegir cada vector de muestreo de tal manera que $\mathbf{b}_k = \mathbf{x}_k$ para todo \mathbf{k} en \mathbf{T} .

Incoherencia

- Si conociésemos \mathbf{T} , podríamos elegir cada vector de muestreo de tal manera que $\mathbf{b}_k = \mathbf{x}_k$ para todo \mathbf{k} en \mathbf{T} .
- Este muestreo es **altamente coherente**, la energía estaría concentrada en un solo coeficiente (incoherencia $\mathbf{O}(n)$).

Incoherencia

- Si conociésemos \mathbf{T} , podríamos elegir cada vector de muestreo de tal manera que $\mathbf{b}_k = \mathbf{x}_k$ para todo \mathbf{k} en \mathbf{T} .
- Este muestreo es **altamente coherente**, la energía estaría concentrada en un solo coeficiente (incoherencia $\mathbf{O}(n)$).
- Si **no** conocemos \mathbf{T} esto es **desastroso**, con alta probabilidad necesitamos casi n muestras para recuperar la señal.

Incoherencia

- Si conociésemos \mathbf{T} , podríamos elegir cada vector de muestreo de tal manera que $\mathbf{b}_k = \mathbf{x}_k$ para todo \mathbf{k} en \mathbf{T} .
- Este muestreo es **altamente coherente**, la energía estaría concentrada en un solo coeficiente (incoherencia $\mathbf{O}(n)$).
- Si **no** conocemos \mathbf{T} esto es **desastroso**, con alta probabilidad necesitamos casi n muestras para recuperar la señal.
- La energía de los vectores de muestreo debe estar **bien distribuida** para detectar coeficientes no nulos de \mathbf{x} en **cualquier** posición.

Isotropía

- La incoherencia **no** es suficiente.

Isotropía

- La incoherencia **no** es suficiente.
- Por ejemplo, si **a** es constante, nunca podremos reconstruir **x**.

Isotropía

- La incoherencia **no** es suficiente.
- Por ejemplo, si **a** es constante, nunca podremos reconstruir **x**.
- Los vectores de muestreo deben cubrir **todas** las direcciones posibles.

Isotropía

- La incoherencia **no** es suficiente.
- Por ejemplo, si **a** es constante, nunca podremos reconstruir **x**.
- Los vectores de muestreo deben cubrir **todas** las direcciones posibles.
- La condición de isotropía asegura que no favorecemos **ninguna dirección específica** al muestrear.

Vectores de Muestreo Válidos

- Vectores iid gaussianos $\mathcal{N}(0, \mathbf{I})$.

Vectores de Muestreo Válidos

- Vectores iid gaussianos $\mathcal{N}(0, \mathbf{I})$.
- Vectores con entradas de signo aleatorio ± 1 con prob. $1/2$.

Vectores de Muestreo Válidos

- Vectores iid gaussianos $\mathcal{N}(0, \mathbf{I})$.
- Vectores con entradas de signo aleatorio ± 1 con prob. $1/2$.
- Filas aleatorias de la Transformada Discreta de Fourier.

Vectores de Muestreo Válidos

- Vectores iid gaussianos $\mathcal{N}(0, \mathbf{I})$.
- Vectores con entradas de signo aleatorio ± 1 con prob. $1/2$.
- Filas aleatorias de la Transformada Discreta de Fourier.
- Filas aleatorias de cualquier transformada ortogonal incoherente.

Condición de Optimalidad

- Problema de optimización con restricciones lineales :

$$\min_x f(x) \text{ sujeto a } Ax = b$$

Condición de Optimalidad

- Problema de optimización con restricciones lineales :

$$\min_x f(x) \text{ sujeto a } Ax = b$$

- Si la función de coste es **diferenciable** y **convexa**, x es la solución si y sólo si el gradiente en x es **perpendicular** al núcleo de \mathbf{A} .

Condición de Optimalidad

- Problema de optimización con restricciones lineales :

$$\min_x f(x) \text{ sujeto a } Ax = b$$

- Si la función de coste es **diferenciable** y **convexa**, x es la solución si y sólo si el gradiente en x es **perpendicular** al núcleo de \mathbf{A} .
- La norma ℓ_1 no es diferenciable, pero la condición de optimalidad se puede generalizar.

Condición de Optimalidad

- Problema de optimización con restricciones lineales :

$$\min_x f(x) \text{ sujeto a } Ax = b$$

- Si la función de coste es **diferenciable** y **convexa**, x es la solución si y sólo si el gradiente en x es **perpendicular** al núcleo de \mathbf{A} .
- La norma ℓ_1 no es diferenciable, pero la condición de optimalidad se puede generalizar.
- Un **subgradiente** g de una función f en x es un vector que satisface :

$$f(x + h) \geq f(x) + \langle g, h \rangle$$

Condición de Optimalidad

- Problema de optimización con restricciones lineales :

$$\min_x f(x) \text{ sujeto a } Ax = b$$

- Si la función de coste es **diferenciable** y **convexa**, x es la solución si y sólo si el gradiente en x es **perpendicular** al núcleo de \mathbf{A} .
- La norma ℓ_1 no es diferenciable, pero la condición de optimalidad se puede generalizar.
- Un **subgradiente** g de una función f en x es un vector que satisface :

$$f(x + h) \geq f(x) + \langle g, h \rangle$$

- Si la función de coste es **convexa**, x es la solución si y sólo si existe un subgradiente en x **perpendicular** al núcleo de \mathbf{A} .

Certificado Dual

- Basta con encontrar un subgradiente de la norma ℓ_1 en el **vector s-disperso original** \mathbf{x} perpendicular al núcleo de \mathbf{A} .

Certificado Dual

- Basta con encontrar un subgradiente de la norma ℓ_1 en el **vector s-disperso original** \mathbf{x} perpendicular al núcleo de \mathbf{A} .
- Llamamos a dicho vector un **certificado dual** porque está relacionado con el problema dual y certifica que tenemos una solución.

Certificado Dual

- Basta con encontrar un subgradiente de la norma ℓ_1 en el **vector s-disperso original** \mathbf{x} perpendicular al núcleo de \mathbf{A} .
- Llamamos a dicho vector un **certificado dual** porque está relacionado con el problema dual y certifica que tenemos una solución.
- Originalmente, esta era la parte más complicada de la demostración.

Certificado Dual

- Basta con encontrar un subgradiente de la norma ℓ_1 en el **vector s-disperso original** \mathbf{x} perpendicular al núcleo de \mathbf{A} .
- Llamamos a dicho vector un **certificado dual** porque está relacionado con el problema dual y certifica que tenemos una solución.
- Originalmente, esta era la parte más complicada de la demostración.
- Se puede simplificar enormemente aplicando una generalización de la Desigualdad de Chernoff para matrices.

Extensión a Matrices de Bajo Rango

- Estas ideas se pueden extender a la reconstrucción de matrices de bajo rango a partir de un pequeño número de coeficientes.

Extensión a Matrices de Bajo Rango

- Estas ideas se pueden extender a la reconstrucción de matrices de bajo rango a partir de un pequeño número de coeficientes.
- La reconstrucción sólo es posible si la energía de la matriz está muy distribuida (condición de **incoherencia**).

Extensión a Matrices de Bajo Rango

- Estas ideas se pueden extender a la reconstrucción de matrices de bajo rango a partir de un pequeño número de coeficientes.
- La reconstrucción sólo es posible si la energía de la matriz está muy distribuida (condición de **incoherencia**).
- Los coeficientes son medidos uniformemente al azar (condición de **isotropía**).

Extensión a Matrices de Bajo Rango

- Estas ideas se pueden extender a la reconstrucción de matrices de bajo rango a partir de un pequeño número de coeficientes.
- La reconstrucción sólo es posible si la energía de la matriz está muy distribuida (condición de **incoherencia**).
- Los coeficientes son medidos uniformemente al azar (condición de **isotropía**).
- Una matriz de bajo rango tiene **valores singulares dispersos**, por lo que minimizamos su norma ℓ_1 .

Extensión a Matrices de Bajo Rango

- Estas ideas se pueden extender a la reconstrucción de matrices de bajo rango a partir de un pequeño número de coeficientes.
- La reconstrucción sólo es posible si la energía de la matriz está muy distribuida (condición de **incoherencia**).
- Los coeficientes son medidos uniformemente al azar (condición de **isotropía**).
- Una matriz de bajo rango tiene **valores singulares dispersos**, por lo que minimizamos su norma ℓ_1 .
- Esto es una norma matricial válida llamada **norma nuclear**.

Extensión a Matrices de Bajo Rango

- Estas ideas se pueden extender a la reconstrucción de matrices de bajo rango a partir de un pequeño número de coeficientes.
- La reconstrucción sólo es posible si la energía de la matriz está muy distribuida (condición de **incoherencia**).
- Los coeficientes son medidos uniformemente al azar (condición de **isotropía**).
- Una matriz de bajo rango tiene **valores singulares dispersos**, por lo que minimizamos su norma ℓ_1 .
- Esto es una norma matricial válida llamada **norma nuclear**.
- La demostración también se basa en la construcción de un **certificado dual** válido correspondiente a la matriz original.

- 1 Ejemplo Introdutorio
- 2 Principios Básicos
- 3 Adquisición Aleatorizada
- 4 Isometrías Restringidas**
- 5 Aplicaciones, Referencias y Perspectivas Futuras


Condicionamiento de Submatrices

$$\begin{array}{|c|} \hline \mathbf{A} \\ \hline \end{array} \quad \begin{array}{|c|} \hline \mathbf{x} \\ \hline \end{array} = \begin{array}{|c|} \hline \mathbf{b} \\ \hline \end{array}$$

$(\mathbf{m} \times \mathbf{n})$

- En la práctica el proceso de adquisición añade **ruido** a las medidas **b**.

Condicionamiento de Submatrices



- En la práctica el proceso de adquisición añade **ruido** a las medidas b .
- Para una matriz A concreta, ¿que condición garantiza que podamos reconstruir cualquier x s -disperso de manera **estable**?

Condicionamiento de Submatrices

$$\begin{array}{c}
 \boxed{\mathbf{A}_T} \quad \boxed{\mathbf{x}_T} = \boxed{\mathbf{b}} \\
 (\mathbf{m} \times \mathbf{s})
 \end{array}$$

- En la práctica el proceso de adquisición añade **ruido** a las medidas \mathbf{b} .
- Para una matriz \mathbf{A} concreta, ¿que condición garantiza que podamos reconstruir cualquier \mathbf{x} \mathbf{s} -disperso de manera **estable**?
- Como mínimo, la matriz \mathbf{A}_T debe estar bien condicionada para cualquier \mathbf{T} .

Constante de Isometría Restringida

- **Constante de Isometría Restringida** : Mínima constante δ_s tal que para **todo** vector x s -disperso :

$$(1 - \delta_s) \|x\|_2^2 \leq \|Ax\|_2^2 \leq (1 + \delta_s) \|x\|_2^2$$

Constante de Isometría Restringida

- **Constante de Isometría Restringida** : Mínima constante δ_s tal que para **todo** vector x s -disperso :

$$(1 - \delta_s) \|x\|_2^2 \leq \|Ax\|_2^2 \leq (1 + \delta_s) \|x\|_2^2$$

Lema

Si $\delta_{2s} < 1$, \mathbf{A} es invertible cuando actúa sobre vectores s -dispersos.

Constante de Isometría Restringida

- **Constante de Isometría Restringida** : Mínima constante δ_s tal que para **todo** vector x s -disperso :

$$(1 - \delta_s) \|x\|_2^2 \leq \|Ax\|_2^2 \leq (1 + \delta_s) \|x\|_2^2$$

Lema

Si $\delta_{2s} < 1$, \mathbf{A} es invertible cuando actúa sobre vectores s -dispersos.

Demostración : Sea y tal que $Ax=Ay$:

$$\|x - y\|_2 \leq \frac{1}{\sqrt{1 - \delta_{2s}}} \|A(x - y)\|_2 = 0$$

Constante de Isometría Restringida

- **Constante de Isometría Restringida** : Mínima constante δ_s tal que para **todo** vector x s -disperso :

$$(1 - \delta_s) \|x\|_2^2 \leq \|Ax\|_2^2 \leq (1 + \delta_s) \|x\|_2^2$$

Lema

Si $\delta_{2s} < 1$, \mathbf{A} es invertible cuando actúa sobre vectores s -dispersos.

Demostración : Sea y tal que $Ax=Ay$:

$$\|x - y\|_2 \leq \frac{1}{\sqrt{1 - \delta_{2s}}} \|A(x - y)\|_2 = 0$$

- **No** implica que \mathbf{A} se pueda invertir de manera **eficiente**.

Minimización de la Norma ℓ_1

Teorema [Candès, Romberg, Tao 2006]

Si $\delta_{2s} < \sqrt{2} - 1$, todo vector s -disperso x es la solución del problema de optimización :

$$\min_y \|y\|_1 \text{ sujeto a } Ay = Ax$$

Minimización de la Norma ℓ_1

Teorema [Candès, Romberg, Tao 2006]

Si $\delta_{2s} < \sqrt{2} - 1$, todo vector s -disperso x es la solución del problema de optimización :

$$\min_y \|y\|_1 \text{ sujeto a } Ay = Ax$$

Acotar la Constante de Isometría Restringida de una matriz **garantiza** que es apta para la adquisición compresiva de **cualquier** señal dispersa.

Señales Compresibles y Medidas Ruidosas

- En la práctica :

Señales Compresibles y Medidas Ruidosas

- En la práctica :
 - 1 las señales rara vez son **exactamente** dispersas.

Señales Compresibles y Medidas Ruidosas

- En la práctica :
 - ① las señales rara vez son **exactamente** dispersas.
 - ② el proceso de adquisición añade **ruido** a las medidas.

Señales Compresibles y Medidas Ruidosas

- En la práctica :
 - ① las señales rara vez son **exactamente** dispersas.
 - ② el proceso de adquisición añade **ruido** a las medidas.
- En este caso resolvemos :

$$\min_y \|y\|_1 \text{ sujeto a } \|Ay - b\|_2 \leq \sigma$$

Señales Compresibles y Medidas Ruidosas

- En la práctica :
 - ① las señales rara vez son **exactamente** dispersas.
 - ② el proceso de adquisición añade **ruido** a las medidas.
- En este caso resolvemos :

$$\min_y \|y\|_1 \text{ sujeto a } \|Ay - b\|_2 \leq \sigma$$

- Definimos x_s como la mejor aproximación s -dispersa de x .

Señales Compresibles y Medidas Ruidosas

- En la práctica :
 - ① las señales rara vez son **exactamente** dispersas.
 - ② el proceso de adquisición añade **ruido** a las medidas.
- En este caso resolvemos :

$$\min_y \|y\|_1 \text{ sujeto a } \|Ay - b\|_2 \leq \sigma$$

- Definimos \mathbf{x}_s como la mejor aproximación s -dispersa de \mathbf{x} .
- Idealmente, el error de estimación al recuperar \mathbf{x} sería proporcional al error de aproximación $\|\mathbf{x} - \mathbf{x}_s\|$ y al nivel de ruido σ .

Señales Compresibles y Medidas Ruidosas

Teorema [Candès, Romberg, Tao 2006]

Si $\delta_{2s} < \sqrt{2} - 1$, para cualquier señal x y ruido z tal que $\|z\|_2 \leq \sigma$, la solución del problema de optimización :

$$\hat{x} = \min_y \|y\|_1 \text{ sujeto a } \|Ay - (Ax + z)\|_2 \leq \sigma$$

satisface

$$\|x - \hat{x}\|_2 \leq C_0 \frac{\|x - x_s\|_1}{\sqrt{s}} + C_1 \sigma$$

Constante de Isometría Restringida de Matrices Aleatorias

- **Buenas noticias** : La RIC nos asegura la reconstrucción estable y eficiente de señales aproximadamente compresibles.

Constante de Isometría Restringida de Matrices Aleatorias

- **Buenas noticias** : La RIC nos asegura la reconstrucción estable y eficiente de señales aproximadamente compresibles.
- **Malas noticias** : Calcular la RIC de una matriz **A** concreta es NP-complejo.

Constante de Isometría Restringida de Matrices Aleatorias

- **Buenas noticias** : La RIC nos asegura la reconstrucción estable y eficiente de señales aproximadamente compresibles.
- **Malas noticias** : Calcular la RIC de una matriz **A** concreta es NP-complejo.
- Sin embargo, $\delta_{2s} < \sqrt{2} - 1$ con alta probabilidad si :

Constante de Isometría Restringida de Matrices Aleatorias

- **Buenas noticias** : La RIC nos asegura la reconstrucción estable y eficiente de señales aproximadamente compresibles.
- **Malas noticias** : Calcular la RIC de una matriz **A** concreta es NP-complejo.
- Sin embargo, $\delta_{2s} < \sqrt{2} - 1$ con alta probabilidad si :
 - **A** es **gaussiana** ($A_{ij} \sim \mathcal{N}(0,1)$) o **binaria** ($A_{ij} = \pm 1$ con prob. 1/2) y $m = O(s \log(n/s))$

Constante de Isometría Restringida de Matrices Aleatorias

- **Buenas noticias** : La RIC nos asegura la reconstrucción estable y eficiente de señales aproximadamente compresibles.
- **Malas noticias** : Calcular la RIC de una matriz \mathbf{A} concreta es NP-complejo.
- Sin embargo, $\delta_{2s} < \sqrt{2} - 1$ con alta probabilidad si :
 - \mathbf{A} es **gaussiana** ($A_{ij} \sim \mathcal{N}(0,1)$) o **binaria** ($A_{ij} = \pm 1$ con prob. 1/2) y $m = O(s \log(n/s))$
 - \mathbf{A} consta de filas **aleatorias** de la transformada discreta de Fourier y $m = O(s (\log n)^4)$

Constante de Isometría Restringida de Matrices Aleatorias

- **Buenas noticias** : La RIC nos asegura la reconstrucción estable y eficiente de señales aproximadamente compresibles.
- **Malas noticias** : Calcular la RIC de una matriz \mathbf{A} concreta es NP-complejo.
- Sin embargo, $\delta_{2s} < \sqrt{2} - 1$ con alta probabilidad si :
 - \mathbf{A} es **gaussiana** ($A_{ij} \sim \mathcal{N}(0,1)$) o **binaria** ($A_{ij} = \pm 1$ con prob. 1/2) y $m = O(s \log(n/s))$
 - \mathbf{A} consta de filas **aleatorias** de la transformada discreta de Fourier y $m = O(s (\log n)^4)$
- Las matrices aleatorias nos permiten submuestrear proporcionalmente a la complejidad de la señal.

RIC de una Matriz Gaussiana

- Definición de valor singular mínimo de una matriz :

$$\sigma_{\min} = \min_{\|x\|_2 \leq 1} \|Mx\|_2$$

RIC de una Matriz Gaussiana

- Definición de valor singular mínimo de una matriz :

$$\sigma_{\min} = \min_{\|x\|_2 \leq 1} \|Mx\|_2$$

- Debemos acotar el valor singular mínimo de **toda** submatriz de A con s columnas.

RIC de una Matriz Gaussiana

- Definición de valor singular mínimo de una matriz :

$$\sigma_{\min} = \min_{\|x\|_2 \leq 1} \|Mx\|_2$$

- Debemos acotar el valor singular mínimo de **toda** submatriz de A con s columnas.
- Para ello :

RIC de una Matriz Gaussiana

- Definición de valor singular mínimo de una matriz :

$$\sigma_{\min} = \min_{\|x\|_2 \leq 1} \|Mx\|_2$$

- Debemos acotar el valor singular mínimo de **toda** submatriz de A con s columnas.
- Para ello :
 - Acotamos la probabilidad de que σ_{\min} supere $\sqrt{1 - \delta_s}$ para una submatriz fija.

RIC de una Matriz Gaussiana

- Definición de valor singular mínimo de una matriz :

$$\sigma_{\min} = \min_{\|x\|_2 \leq 1} \|Mx\|_2$$

- Debemos acotar el valor singular mínimo de **toda** submatriz de A con s columnas.
- Para ello :
 - Acotamos la probabilidad de que σ_{\min} supere $\sqrt{1 - \delta_s}$ para una submatriz fija.
 - Aplicamos la desigualdad de Boole multiplicando por el número de submatrices con s columnas : $\binom{n}{s}$.

- 1 Ejemplo Introdutorio
- 2 Principios Básicos
- 3 Adquisición Aleatorizada
- 4 Isometrías Restringidas
- 5 Aplicaciones, Referencias y Perspectivas Futuras**

Aplicaciones

- Geofísica (adquisición de datos sísmicos).

Aplicaciones

- Geofísica (adquisición de datos sísmicos).
- Imagen médica (resonancia magnética, tomografía por rayos X).

Aplicaciones

- Geofísica (adquisición de datos sísmicos).
- Imagen médica (resonancia magnética, tomografía por rayos X).
- Óptica (cámara de un solo píxel).

Aplicaciones

- Geofísica (adquisición de datos sísmicos).
- Imagen médica (resonancia magnética, tomografía por rayos X).
- Óptica (cámara de un solo píxel).
- Genética (diseño de microarrays de ADN).

Referencias

- Precedentes :

Referencias

- Precedentes :
 - [Linear inversion of band-limited reflection seismograms](#)
Santosa, Symes 1986

Referencias

- Precedentes :
 - [Linear inversion of band-limited reflection seismograms](#)
Santosa, Symes 1986
 - [Atomic Decomposition by Basis Pursuit](#)
Chen, Donoho, Saunders 1995

Referencias

- Precedentes :
 - [Linear inversion of band-limited reflection seismograms](#)
Santosa, Symes 1986
 - [Atomic Decomposition by Basis Pursuit](#)
Chen, Donoho, Saunders 1995
 - [Regression shrinkage and selection via the lasso](#)
Tibshirani 1996

Referencias

- Precedentes :
 - [Linear inversion of band-limited reflection seismograms](#)
Santosa, Symes 1986
 - [Atomic Decomposition by Basis Pursuit](#)
Chen, Donoho, Saunders 1995
 - [Regression shrinkage and selection via the lasso](#)
Tibshirani 1996
- Demostración basada en certificado dual :

Referencias

- Precedentes :
 - [Linear inversion of band-limited reflection seismograms](#)
Santosa, Symes 1986
 - [Atomic Decomposition by Basis Pursuit](#)
Chen, Donoho, Saunders 1995
 - [Regression shrinkage and selection via the lasso](#)
Tibshirani 1996
- Demostración basada en certificado dual :
 - [Robust Uncertainty Principles : Exact Signal Reconstruction from Highly Incomplete. Frequency Information](#)
Candès, Romberg, Tao 2005

Referencias

- Precedentes :
 - [Linear inversion of band-limited reflection seismograms](#)
Santosa, Symes 1986
 - [Atomic Decomposition by Basis Pursuit](#)
Chen, Donoho, Saunders 1995
 - [Regression shrinkage and selection via the lasso](#)
Tibshirani 1996
- Demostración basada en certificado dual :
 - [Robust Uncertainty Principles : Exact Signal Reconstruction from Highly Incomplete. Frequency Information](#)
Candès, Romberg, Tao 2005
 - [A probabilistic and RIPless theory of compressed sensing](#)
Candès, Plan 2010

Referencias

- Matrices de bajo rango :

Referencias

- Matrices de bajo rango :
 - [Exact matrix completion via convex optimization](#)
Candès, Recht 2008

Referencias

- Matrices de bajo rango :
 - [Exact matrix completion via convex optimization](#)
Candès, Recht 2008
 - [Recovering low-rank matrices from few coefficients in any basis](#)
Gross 2011

Referencias

- Matrices de bajo rango :
 - [Exact matrix completion via convex optimization](#)
Candès, Recht 2008
 - [Recovering low-rank matrices from few coefficients in any basis](#)
Gross 2011
- Demostración basada en constante de isometría restringida :

Referencias

- Matrices de bajo rango :
 - [Exact matrix completion via convex optimization](#)
Candès, Recht 2008
 - [Recovering low-rank matrices from few coefficients in any basis](#)
Gross 2011
- Demostración basada en constante de isometría restringida :
 - [Decoding by linear programming](#)
Candès, Tao 2006

Referencias

- Matrices de bajo rango :
 - [Exact matrix completion via convex optimization](#)
Candès, Recht 2008
 - [Recovering low-rank matrices from few coefficients in any basis](#)
Gross 2011
- Demostración basada en constante de isometría restringida :
 - [Decoding by linear programming](#)
Candès, Tao 2006
- Otros enfoques :

Referencias

- Matrices de bajo rango :
 - [Exact matrix completion via convex optimization](#)
Candès, Recht 2008
 - [Recovering low-rank matrices from few coefficients in any basis](#)
Gross 2011
- Demostración basada en constante de isometría restringida :
 - [Decoding by linear programming](#)
Candès, Tao 2006
- Otros enfoques :
 - [Compressed Sensing](#)
Donoho 2005

Referencias

- Matrices de bajo rango :
 - [Exact matrix completion via convex optimization](#)
Candès, Recht 2008
 - [Recovering low-rank matrices from few coefficients in any basis](#)
Gross 2011
- Demostración basada en constante de isometría restringida :
 - [Decoding by linear programming](#)
Candès, Tao 2006
- Otros enfoques :
 - [Compressed Sensing](#)
Donoho 2005
 - [Compressed Sensing over \$\ell_p\$ -balls : Minimax Mean Square Error](#)
Donoho, Johnstone, Maleki, Montanari 2010

Perspectivas Futuras

- Construcción determinística de isometrías restringidas.

Perspectivas Futuras

- Construcción determinística de isometrías restringidas.
- Relajación de las condiciones sobre el proceso de adquisición.

Perspectivas Futuras

- Construcción determinística de isometrías restringidas.
- Relajación de las condiciones sobre el proceso de adquisición.
- Extensión a señales dispersas en diccionarios redundantes.

Perspectivas Futuras

- Construcción determinística de isometrías restringidas.
- Relajación de las condiciones sobre el proceso de adquisición.
- Extensión a señales dispersas en diccionarios redundantes.
- Extensión a otros objetos de baja complejidad como tensores.

Gracias

