

MAPAS ESPECTRALES DE POTENCIA EN SMART CITIES PARA GESTIÓN DEL ESPECTRO DE RADIO: BIG DATA Y COMPRESIÓN

Ph.D (c) Jeison Marín Alfonso

Octavo Congreso de Ingeniería de Sistemas
e Ingeniería Electrónica
INNOVACIÓN TECNOLÓGICA:
RETOS EN LA ERA DIGITAL
Octubre 26 de 2018






- 1 Cartografía de Interferencia
- 2 Muestreo Compresivo
- 3 Aplicación Para la Compresión de Mapas Espectrales

Contenido

- 1 Cartografía de Interferencia
- 2 Muestreo Compresivo
- 3 Aplicación Para la Compresión de Mapas Espectrales

Mapas Espectrales de Potencia

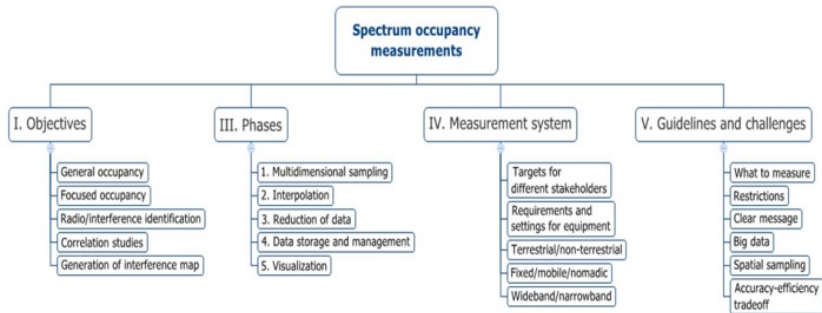


Fuente: Spectrum Occupancy
Measurements: A Survey

and Use of Interference Maps. 2016.

IEEE COMMUNICATIONS SURVEYS & TUTORIALS, VOL. 18, NO.
4, FOURTH QUARTER 2016

Mapas Espectrales de Potencia



Fuente: Spectrum Occupancy Measurements: A Survey and Use of Interference Maps. 2016.
 IEEE COMMUNICATIONS SURVEYS & TUTORIALS, VOL. 18, NO. 4, FOURTH QUARTER 2016

Problema Big Data

¿Cuántos Datos se Necesitan para construir un mapa espectral?

$$D_{\text{tot}} = \frac{T_m}{T_s} \cdot \frac{F_m}{F_s} \cdot \frac{A_m}{A_s} \cdot D_s$$

T_m = Tiempo de Medición.

F_m = Ancho de Banda.

A_m = Área Geográfica.

F_s = Resolución en Frecuencia.

T_s y A_s = Intervalos de muestreo en los dominios temporales y espaciales.

D_s = Tamaño en bytes del dato.

Ejemplo:

Un área geográfica de 20 Km^2 en un rango de frecuencia de 0.3 a 3Ghz. La resolución en frecuencia de 100 Khz, y el intervalo de muestreo en el dominio espacial es de 100m x 100m, y un tiempo de muestreo de 1s, con datos de 2 bytes.

En este caso se necesitaría 968 Tera bytes para guardar los datos de una semana de mediciones.

Fuente: Spectrum Occupancy Measurements: A Survey and Use of Interference Maps. 2016.


IEEE COMMUNICATIONS SURVEYS & TUTORIALS, VOL. 18, NO. 4, FOURTH QUARTER 2016

Contenido

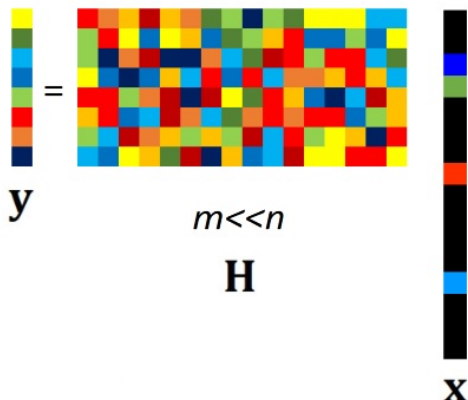
- 1 Cartografía de Interferencia
- 2 Muestreo Compresivo
- 3 Aplicación Para la Compresión de Mapas Espectrales

Representación Matricial - Sistema Compresado

Sistema Ideal



Sistema compresado



El objetivo del muestreo compresivo es calcular x conociendo la matriz de sensado H y las muestras adquiridas y

Enfoque como sistema de ecuaciones lineales

$\mathbf{H}\mathbf{x} = \mathbf{y}$, se puede ver como un sistema de ecuaciones lineales, donde el vector de medidas corresponde al vector solución y la matriz de muestreo son los coeficientes.

$$\begin{array}{rcl}
 x_2 + x_3 - 2x_4 & = & -3 \\
 x_1 + 2x_2 - x_3 & = & 2 \\
 2x_1 + 4x_2 + x_3 - 3x_4 & = & -2 \\
 x_1 - 4x_2 - 7x_3 - x_4 & = & -19
 \end{array}
 \quad \Rightarrow \quad
 \begin{array}{l}
 x_1 = -1, \quad x_2 = 2, \\
 x_3 = 1, \quad x_4 = 3.
 \end{array}$$

$$\begin{array}{cccc}
 \left[\begin{array}{cccc}
 0 & 1 & 1 & -2 \\
 1 & 2 & -1 & 0 \\
 2 & 4 & 1 & -3 \\
 1 & -4 & -7 & -1
 \end{array} \right] & \left[\begin{array}{c}
 -1 \\
 2 \\
 1 \\
 3
 \end{array} \right] & = & \left[\begin{array}{c}
 -3 \\
 2 \\
 -2 \\
 -19
 \end{array} \right] \\
 \mathbf{H} & \mathbf{x} & & \mathbf{y}
 \end{array}$$

Sistema Compreso como Sistema de Ec. Indeterminado

Un sistema compreso, se podría representar como un sistema de ecuaciones lineales indeterminado. Un sistema de ecuaciones lineales es indeterminado si el sistema tiene más incógnitas que ecuaciones y puede no tener solución o tener infinitas soluciones.

Dado $\mathbf{H} \in \mathbb{R}^{m \times n}$, $\mathbf{y} \in \mathbb{R}^m$, $\mathbf{x} \in \mathbb{R}^n$ y $m < n$.

$$\mathbf{y} = \mathbf{H} \mathbf{x}$$

$m \ll n$

$$\begin{aligned} x_1 + x_5 + x_7 &= 1 \\ 3x_1 + x_5 - x_7 &= 3 \end{aligned}$$

$$\begin{aligned} \mathbf{H}'\mathbf{x}' = \mathbf{y} &\rightarrow \left[\begin{array}{ccc|c} 1 & 1 & 1 & 1 \\ 3 & 1 & -1 & 3 \end{array} \right] \\ &= \left[\begin{array}{ccc|c} 1 & 1 & 1 & 1 \\ 0 & -2 & -4 & 0 \end{array} \right] \\ &= \left[\begin{array}{ccc|c} 1 & 0 & -1 & 1 \\ 0 & 1 & 2 & 0 \end{array} \right] \end{aligned}$$

Solución:

$$\begin{aligned} x_1 &= 1 + x_7 \\ x_5 &= -2x_7 \\ x_7 &\text{ variable libre} \end{aligned}$$

Sistema Compreso como Sistema de Ec. Indeterminado

Es posible que un sistema de ecuaciones indeterminado tenga soluciones exactas si algunas de estas soluciones equivalen a cero.

Dado $\mathbf{H} \in \mathbb{R}^{m \times n}$, $\mathbf{y} \in \mathbb{R}^m$, $\mathbf{x} \in \mathbb{R}^n$ y $m < n$.

$$\begin{aligned}x_1 + x_5 + x_7 &= 1 \\3x_1 + x_5 - x_7 &= 3\end{aligned}$$

Matriz de Muestreo Conocida

$$\mathbf{H}\mathbf{x} = \mathbf{y} \rightarrow \begin{bmatrix} 1 & 1 & 1 \\ 3 & 1 & -1 \end{bmatrix} \begin{bmatrix} x_1 \\ x_5 \\ x_7 \end{bmatrix} = \begin{bmatrix} 1 \\ 3 \end{bmatrix}$$

Medidas Originales: Pueden ser infinitas posibles

Muestras que tenemos

Pero si sabemos de antemano que una de las medidas es cero:

si $\Rightarrow x_1 = 0$

$$\mathbf{H}\mathbf{x} = \mathbf{y} \rightarrow \begin{bmatrix} 1 & 1 & 1 \\ 3 & 1 & -1 \end{bmatrix} \begin{bmatrix} 0 \\ x_5 \\ x_7 \end{bmatrix} = \begin{bmatrix} 1 \\ 3 \end{bmatrix}$$

$$\begin{aligned}x_5 + x_7 &= 1 \\x_5 - x_7 &= 3 \\x_5 &= 2 \\x_7 &= -1.\end{aligned}$$

Como la cantidad de incógnitas diferente de cero es igual al número de filas de \mathbf{H} , existe una solución exacta.

Sistema Compreso como Sistema de Ec. Indeterminado

Esto se puede extender a un vector de medidas mas amplio, donde la mayoría de sus elementos equivale a cero.

$$\mathbf{Hx} = \mathbf{y} \rightarrow \begin{bmatrix} 1 & 5 & 1 & -6 & 1 & -4 & 1 & -2 & 4 \\ 3 & 9 & -8 & -7 & 1 & 7 & -1 & 5 & 2 \end{bmatrix} \begin{matrix} x_1 \\ x_2 \\ x_3 \\ x_4 \\ x_5 \\ x_6 \\ x_7 \\ x_8 \\ x_9 \end{matrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix} = \begin{bmatrix} 1 \\ 3 \end{bmatrix}$$

$\mathbf{H} \in \mathbb{R}^{2 \times 9}$

$\mathbf{y} \in \mathbb{R}^{2 \times 1}$

$\mathbf{x} \in \mathbb{R}^{9 \times 1}$

Vector de Medidas donde la mayoría de sus componentes es cero. \Rightarrow

Concepto de norma y esparcidad

La norma ℓ_p de un vector $x = [x_1, \dots, x_n]^T \in \mathbb{R}^n$ es definida para $p \geq 1$ como

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

La Norma ℓ_0 corresponde al número de elementos diferentes de cero del vector \mathbf{x} :

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

Una señal $\mathbf{x} \in \mathbb{R}^n$ es dispersa (*sparse*) si la mayoría de sus elementos son exactamente igual a cero:

$$\|\mathbf{x}\|_0 \ll n$$

Se dice que una señal \mathbf{x} es *k-dispersa* (*k-sparse*) cuando tiene al menos k elementos diferentes de cero:

$$\|\mathbf{x}\|_0 \leq k$$

Conversión a otra base de representación

Si la señal original no es *sparse*, o es *k-sparse* donde *k* es muy alto, se hace una transformación:

$$\mathbf{F} = \Psi \mathbf{x}$$

$$\Psi \in \mathbb{R}^{n \times n}$$



Transformada Wavelet
Transformada de Fourier
Transformada DCT
Transformada Kronecker

$$\mathbf{F} \in \mathbb{R}^n$$

Señal en otra base de representación

Conversión a otra base de representación

Por lo tanto se tiene una nueva matriz de sensado \mathbf{A} que incluye la proyecciones sobre la nueva base de representación:

$$\mathbf{y} = \mathbf{H}\mathbf{x} \Leftrightarrow \mathbf{y} = \mathbf{H}\mathbf{F} \Leftrightarrow \mathbf{y} = \mathbf{H}\mathbf{\Psi}\mathbf{x}$$

$\underbrace{\hspace{2em}}$
No sparse
 $\underbrace{\hspace{2em}}$
sparse
 $\mathbf{y} = \mathbf{A}\mathbf{x}$

$$\mathbf{A} = \mathbf{H}\mathbf{\Psi}$$

La nueva matriz de muestreo incluye las proyecciones sobre la nueva base de representación

Ejemplo de análisis de esparcidad

Usando la imagen autumn.tif de matlab, utilizando la transformada discreta de coseno 2D:

Imagen Original



DCT2D: Coef. Vectorizados y organizados de mayor a menor.
%coef=0.1%





Imagen Esparcificada, #%muestras NZ=1%
PSNR=23.9964



Gráfico de Porcentaje de Esparcidad Vs PSNR



Concepto de Muestreo Compresivo

Sistema Lineal Base

$$\mathbf{Ax} = \mathbf{y}$$

Donde $\mathbf{A} \in \mathbb{R}^{m \times n}$, $\mathbf{x} \in \mathbb{R}^n$, $\mathbf{y} \in \mathbb{R}^m$

- \mathbf{A} y \mathbf{y} son conocidos.
- Se llamará a \mathbf{y} un *vector de medidas*, y \mathbf{A} una *matriz de sensado*.
- En el caso que $n > m$ el sistema por lo general corresponde a un sistema de ecuaciones lineales indeterminado.

El Muestreo Compresivo es un método para obtener una solución única de un sistema lineal de ecuaciones indeterminado tomando ventaja que se sabe de antemano que la solución es una señal dispersa (*sparse*).

Reconstrucción de la señal por optimización ℓ_1

Problema de optimización ℓ_0

$$\hat{\mathbf{x}}_{\ell_0} = \arg \min_{\mathbf{x}} \|\mathbf{x}\|_0 \quad \text{sujeto a} \quad \mathbf{Ax} = \mathbf{y}$$

Sin embargo este problema no es sencillo de resolver debido a la naturaleza discreta y no convexa de la norma ℓ_0 .

Problema de optimización ℓ_1

$$\hat{\mathbf{x}}_{\ell_1} = \arg \min_{\mathbf{x}} \|\mathbf{x}\|_1 \quad \text{sujeto a} \quad \mathbf{Ax} = \mathbf{y}$$

Problema de optimización ℓ_1 cuando las mediciones incluyen ruido

$$\hat{\mathbf{x}}_{\ell_1} = \arg \min_{\mathbf{x}} \|\mathbf{x}\|_1 \quad \text{sujeto a} \quad \|\mathbf{Ax} - \mathbf{y}\|_2 \leq \epsilon$$

Ejemplos de reconstrucción con algoritmos Greedy: IHT

Algorithm : *Iterative Hard Thresholding* (IHT)

input : Vector de mediciones $\mathbf{y} \in \mathbb{R}^M$ Matriz de muestreo $\Phi \in \mathbb{R}^{M \times N}$ Dispersión K , parámetro de regularización μ
y máximo número de iteraciones *maxiter*.**output:** Vector disperso $\hat{\mathbf{x}} \in \mathbb{R}^N$ 1: Inicializar el vector $\hat{\mathbf{x}}^0 = \mathbf{0}$ 2: **for** $i = 0$ to *maxiter* **do**3: $\hat{\mathbf{x}}^{i+1} = H_K(\hat{\mathbf{x}}^i + \mu \Phi^T(\mathbf{y} - \Phi \hat{\mathbf{x}}^i)) \rightarrow H_K(\cdot)$ es el operador thresholding4: **end for**

Ejemplos de reconstrucción con algoritmos Greedy: OMP

Algorithm : *Orthogonal Matching Pursuit* (OMP)

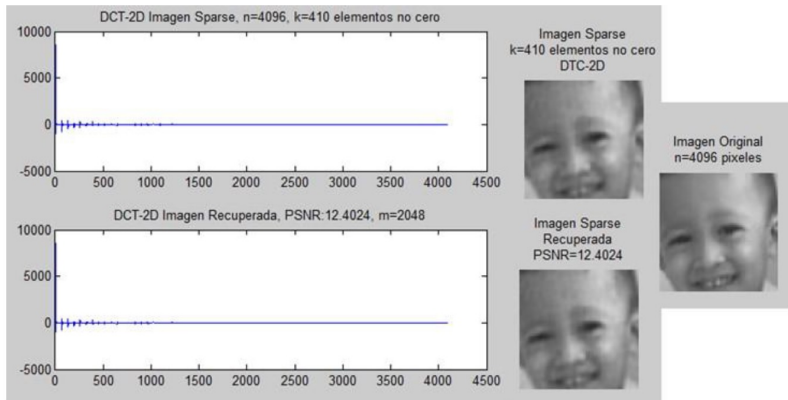
input : Vector de mediciones $\mathbf{y} \in \mathbb{R}^M$
 Matriz de mediciones $\Phi \in \mathbb{R}^{M \times N}$
 Dispersión K

output: Vector disperso $\hat{\mathbf{x}} \in \mathbb{R}^N$

- 1: Inicializar los vectores $\hat{\mathbf{x}}^0 = \mathbf{0}$,
 $\mathbf{r}^0 = \mathbf{y}$ y $\Lambda_0 = \emptyset$
 - 2: **for** $i = 1$ to K **do**
 - 3: proj = $\Phi^T \mathbf{r}^{i-1}$
 - 4: $\Lambda_i = \Lambda_{i-1} \cup \text{supp}(H_1(\text{proj}))$
 - 5: $\hat{\mathbf{x}}_{\Lambda_i}^i = \Phi_{\Lambda_i}^\dagger \mathbf{y}$, $\hat{\mathbf{x}}_{\Lambda_i^c}^i = \mathbf{0}$
 - 6: $\mathbf{r}^i = \mathbf{y} - \Phi \hat{\mathbf{x}}^i$
 - 7: **end for**
-

Ejemplos de reconstrucción con algoritmos Greedy: OMP

Se probó el algoritmo usando una imagen de 64×64 , con $n=4096$ y $m=2048$, con 5% de esparcidad, en DCT-2D.



Resumen de problemas y algoritmos de solución

Cuadro 1: Problemas y Algoritmos de Solución

Problema	Algoritmo
$\min_{\mathbf{x}} \ \mathbf{x}\ _1$ subject to $\mathbf{Ax} = \mathbf{y}$	LP
$\min_{\mathbf{x}} \ \mathbf{x}\ _1$ subject to $\ \mathbf{Ax} - \mathbf{y}\ _2 \leq \epsilon$	NESTA SPGL1
$\min_{\mathbf{x}} \left(\frac{1}{2} \ \mathbf{Ax} - \mathbf{y}\ _2^2 + \lambda \ \mathbf{x}\ _1 \right)$	FISTA FPC Bregman GPSR TwIST C-SALSA
$\min_{\mathbf{x}} \ \mathbf{Ax} - \mathbf{y}\ _2^2$ subject to $\ \mathbf{x}\ _1 \leq t$	SPGL1

Algunos Link de Interes

Implementación en MATLAB

Algunos de los algoritmos se encuentran disponibles en la red:

- GPSR: <http://www.lx.it.pt/~mtf/GPSR/>
- TwIST: <http://www.lx.it.pt/~bioucas/TwIST/TwIST.htm>
- C-SALSA: <http://cascais.lx.it.pt/~mafonso/salsa.html>

Contenido


- 1 Cartografía de Interferencia
- 2 Muestreo Compresivo
- 3 Aplicación Para la Compresión de Mapas Espectrales

Aplicaciones en Telecomunicaciones de Muestreo Compresivo

COMPRESSIVE SENSING / COMMUNICATIONS

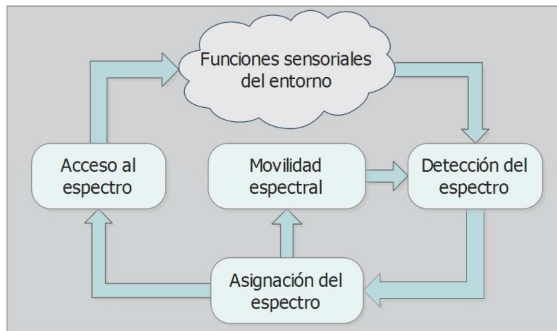
ANTENAS 4,17%	CHANNEL 33,33%	OFDM 12,50%
COGNITIVE RADIO 8,33%	MIMO 4,17%	MULTIMEDIA 4,2%
MULTIUSER 4,17%	NETWORK RECONSTRUCTION 4,17%	SENSOR NETWORKS 12,50%
UWB 6,94%	M2M / P2P 2,78%	OTHERS: CDMA, MOBILE, ETC 2,78%

Retos hacia 5G



Fuente: P. Demestichas, A. Georgakopoulos, D. Karvounas, K. Tsagkaris, V. Stavroulaki, Jianmin Lu, Chunshan Xiong, and Jing Yao. 5g on the horizon: Key challenges for the radio-access network. Vehicular Technology Magazine, IEEE, 8(3), 47-53, 2013.

Funciones principales en la gestión espectral



Fuente: BORDON, J. Y MONTEJO La Radio Cognitiva y su Impacto en el Uso Eficiente del Espectro de Radio Revista de Ingeniería Electrónica Automática y Comunicaciones, 2015, 42-55.

Sensado Espectral usando Muestreo Compresivo

Gestión eficiente del espectro

Procesos de búsqueda espectral y transferencia de información de control rápidos, para garantizar niveles de velocidad y calidad aceptables a los usuarios secundarios.



Radio cognitiva

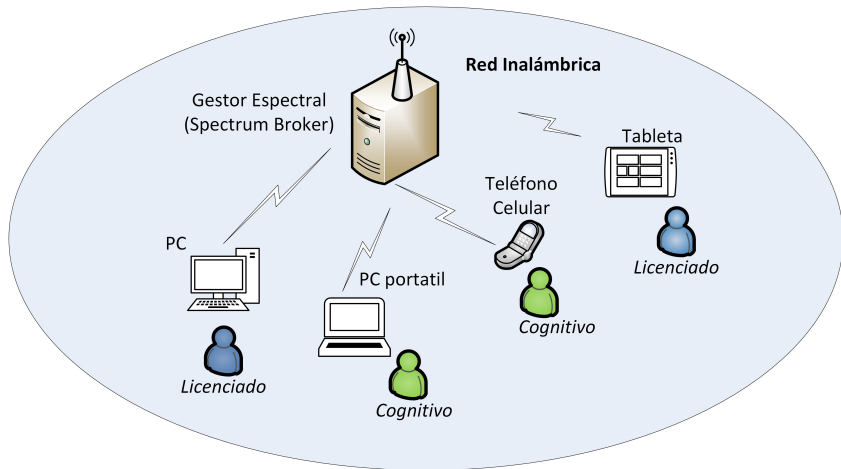
Asignación del espectro en forma eficiente, pero requiere procesamiento de gran cantidad de datos.



Muestreo compresivo

Procesamiento de datos durante el muestreo espectral para la identificación y asignación de recursos disponibles usando la técnica de muestreo compresivo

Escenario base: Ciudades y Dispositivos Inteligentes



Tendencias según CISCO



Figura 1: Crecimiento global de dispositivos inteligentes. Fuente: Cisco VNI Mobile, 2016

Sensado Urbano en Ciudades Inteligentes

Urban Sensing Using Mobile Phone Network Data: A Survey of Research

FRANCESCO CALABRESE

IBM Research-Ireland, Dublin, Ireland

Urban Sensing: Big data analysis and visualization

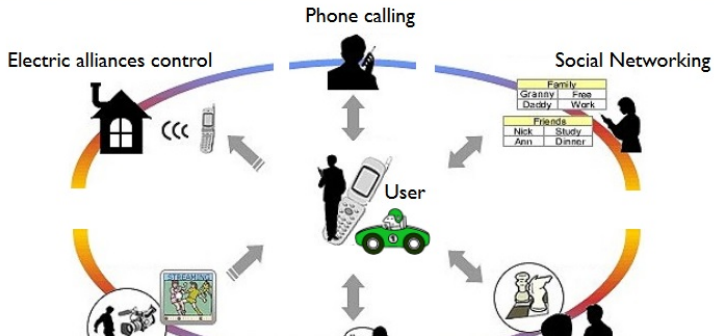
(2012-2015) Urban Sensing aimed at developing a software platform that could be used by urban designers, planners and managers and other city stakeholders that wanted to analyse large amount of data (e.g., open data or data coming from social media platforms like Facebook, Twitter, FourSquare and Flickr) and extract indicators for various areas of their cities (e.g., transportation, liveability, tourism, etc.).

Company: T-Connect (overall project coordination by Accurat)

My role: I contributed to the user requirements definition and to the design and implementation of the software platform.

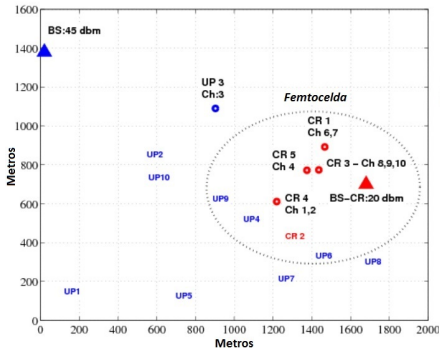
Sensado Urbano en Ciudades Inteligentes

Urban Sensing with Smartphones





- ▶ 10 million mobile users generate sensor data updates and queries with the rate of 1KB/sec per user
 - ▶ Bandwidth required : >80Gbps, Storage space required: > 36TB/hr





Escenario base: Ciudades y Dispositivos Inteligentes



● Usuario Cognitivo ● Usuario Licenciado



Ejemplo de Muestreo Compresivo aplicado a una señal espectral



Muestreo Compresivo Multiespectral para Cartografía de interferencia

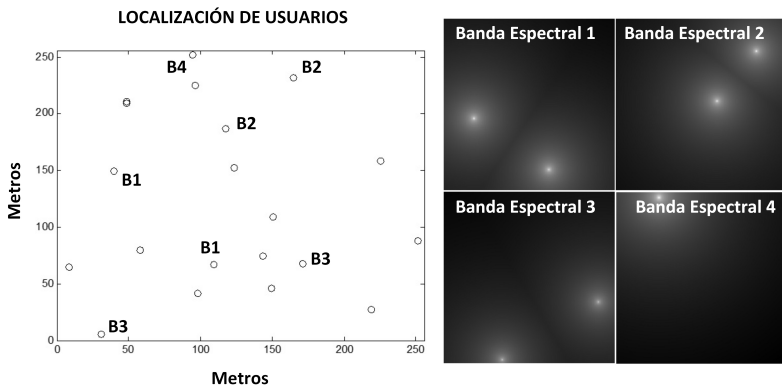



Figura 2: Las muestras de potencia medida por SDR's ubicados en posiciones geográficas conocidas pueden ser modeladas como imágenes espectrales


Cartografía de interferencia

Una imagen 2D por cada frecuencia de transmisión




Cartografía de interferencia

El cubo se construye con la información de espectro sensado enviada por los SDR's



Cartografía de interferencia


Un servidor central define que muestras son enviadas por los SDR's mediante matrices de diezmo




Cartografía de interferencia: Diseño del sistema

Con base en muestras espectrales se construyen cubos espectrales de cartografía experimental.



Adquisición de la Señal



USRP B200mini

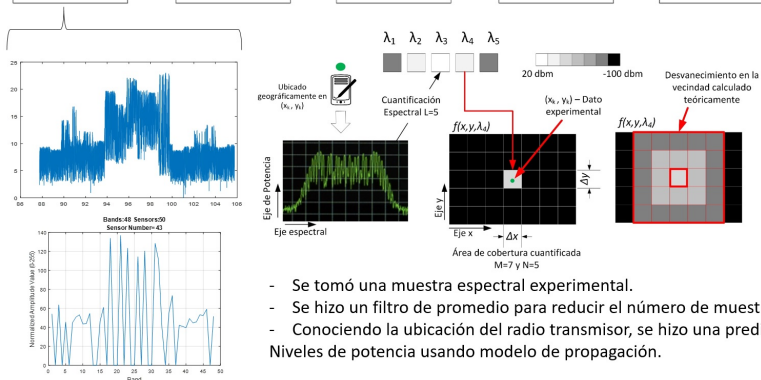



Suavizado y reducción de bandas



Cartografía de interferencia: Diseño del sistema

La construcción de mapas de cartografía de interferencia tiene definida unas etapas que se aplican en el diseño.




- Se tomó una muestra espectral experimental.
- Se hizo un filtro de promedio para reducir el número de muestras.
- Conociendo la ubicación del radio transmisor, se hizo una predicción Niveles de potencia usando modelo de propagación.


Cartografía de interferencia: Diseño del sistema

Ejemplo de cubo multiespectral con 8 bandas y datos experimentales:

- Ejemplo con 50 radios o sensores, ubicados aleatoriamente en 8 bandas.
- Se generan 50 señales con la distribución de probabilidad de la original experimental



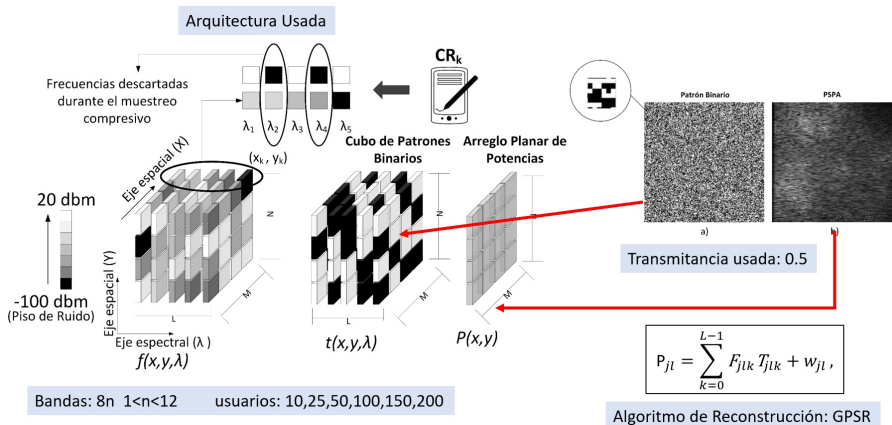
Mapas espectrales: Cartografía espectral



Cada punto es una señal, y se predice la potencia en otros puntos con modelos de propagación, identificando los radios que están transmitiendo.

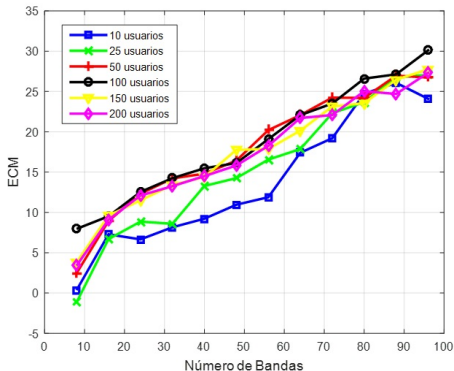


Cartografía de interferencia: Diseño del sistema

Se diseñó una arquitectura de implementación multispectral basada en patrones binarios:



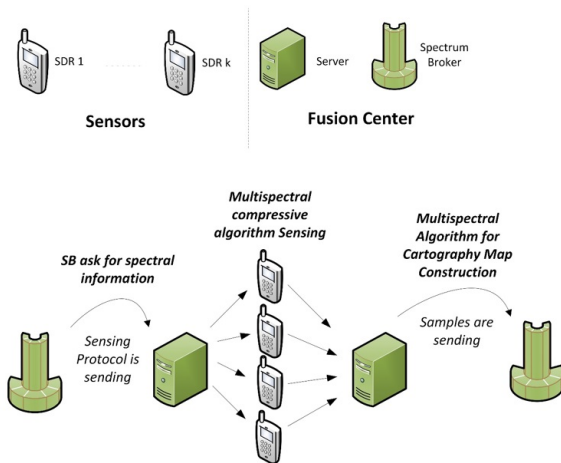
Cartografía de interferencia: Resultados

Se aplican los algoritmos de reconstrucción al PSPA:



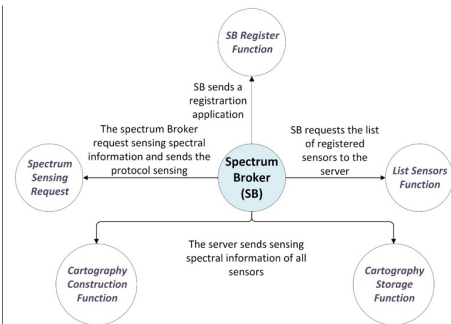
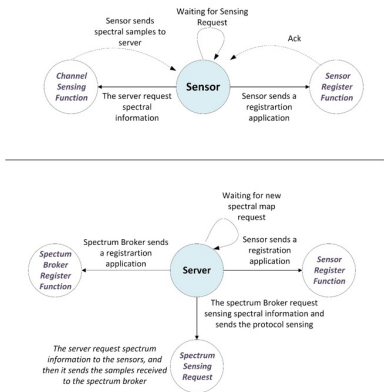
Cartografía de interferencia: Implementación

Finalmente se propone una arquitectura de implementación:



Cartografía de interferencia: Implementación

Se especifican la funciones de cada equipo:



Revisión de trabajos

- Q. Zhao and B. M. Sadler. A survey of dynamic spectrum access. IEEE Signal Processing Magazine, 24(3), 79-89, May 2007.
- I.F. Akyildiz, Won-Yeol Lee, Mehmet C. Vuran, and S. Mohanty. A survey on spectrum management in cognitive radio networks. Communications Magazine, IEEE, 46(4), 40-48, 2008.
- E.Z. Tragos, S. Zeadally, A.G. Fragkiadakis, and V.A. Siris. Spectrum assignment in cognitive radio networks: A comprehensive survey. Communications Surveys Tutorials, IEEE, 15(3), 1108-1135, 2013.
- P. Saad Qaisar. Compressive sensing: From theory to applications, a survey. JOURNAL OF COMMUNICATIONS AND NETWORKS, 15, 443-455, 2013.
- Claudia V. Correa, Henry Arguello, and Gonzalo R. Arce. Snapshot colored compressive spectral imager. J. Opt. Soc. Am. A, 32(10), 1754-1763, Oct 2015.

Revisión de trabajos

- T. Chen, M. Matinmikko, X. Chen, X. Zhou, and P. Ahokangas. Software defined mobile networks: concept, survey, and research directions. IEEE Communications Magazine, 53(11),126-133, November 2015.
- J. Lunden, V. Koivunen, and H. V. Poor. Spectrum exploration and exploitation for cognitive radio: Recent advances. IEEE Signal Processing Magazine, 32(3),123-140, May 2015.
- K. G. M. Thilina, E. Hossain and D. I. Kim, DCCC-MAC: A Dynamic Common-Control-Channel-Based MAC Protocol for Cellular Cognitive Radio Networks, in IEEE Transactions on Vehicular Technology, vol. 65, no. 5, pp. 3597-3613, May 2016.
- S. K. Sharma, E. Lagunas, S. Chatzinotas and B. Ottersten, Application of Compressive Sensing in Cognitive Radio Communications: A Survey, in IEEE Communications Surveys and Tutorials, vol. 18, no. 3, pp. 1838-1860, thirdquarter 2016.

¡Muchas Gracias!, ¿Preguntas?

Contacto: Jeison Marín Alfonso.

Email 1: jmarin@correo.uts.edu.co