# INTERFERENCE MAP PROCESSING THROUGH COMPRESSIVE SENSING

# PROCESAMIENTO DE MAPAS DE INTERFERENCIA A TRAVÉS DE SENSADO COMPRESIVO

**MSc. Fabián Chaparro Becerra I**
**PhD (c). Jeison Marín, II**
**PhD. José Ignacio Martinez, III**
**PhD. Manuel Ricardo Pérez, IV**
**PhD. Carlos Fajardo, V**
**PhD. Diego Méndez, VI**

**Universidad Santo Tomás I**
**…**
**Universidad Rey Juan Carlos**
**Pontificia Universidad Javeriana IV, VI**
**…**
william.chaparro@usantoto.edu.co, jeison.marin@upb.edu.co,
joseignacio.martinez@urjc.es, manuel.perez@javeriana.edu.co,
carlos.fajardo@unad.edu.co, diego-mendez@unad.edu.co

**Abstract:** Interference map processing allow to find a way for design, organize and management the electromagnetic spectrum and with it the services and resources that allow to achieve high values of quality of service in the wireless networks. This work lets to understand the interference map processing through compressive sensing technique, it allows to reduce the analysis data below Nyquist-Shannon theorem and it rebuilt with a reconstruction algorithm without significant losses. For this purpose, it was developed a compressive sensing background, a explanation of building interference maps with sparsity techniques and finally the evaluation of reconstruction algorithms to achieve the performance comparison to find the best.

**Keywords:** Compressive sensing, sparsity, reconstruction

**Resumen:** Procesamiento de mapas de interferencia permite encontrar un método para diseñar, organizar y administrar el espectro electromagnético (EE). Lo anterior conlleva que los servicios y recursos en el EE alcancen altos valores en términos de calidad de servicio en redes de comunicación inalámbrica. Este trabajo permite entender el procesamiento de mapas de interferencia a través de la técnica de sensado compresivo, permitiendo reducir el análisis de información en cantidades por debajo del teorema de Nyquist/Shannon. Su posterior reconstrucción se logra con el uso de un algoritmo de reconstrucción sin pérdidas altamente significativas. Para este propósito, se ha desarrollado una revisión literaria de sensado compresivo para entender sus principios y sus alcances, particularmente en la construcción y uso de mapas de interferencia con la técnica de esparcidad; finalmente, se presentan algunas técnicas de reconstrucción en la evaluación del sistema propuesto

**Palabras clave:** Sensado compresivo, esparcidad, reconstrucción.

## 1. INTRODUCCIÓN

Servicios de comunicación inalámbrica crecen día a día, investigaciones académicas y de la industria requieren nuevos conceptos y formas para mejorar el uso del espectro radioeléctrico; por ejemplo, para aplicaciones de radio cognitiva y de regulaciones en el uso del espectro o en el ciclo útil de uso de frecuencias, de esta forma, se presenta la importancia de las mediciones, el monitoreo y control en diversos ambientes para el uso de redes inalámbricas. Cada día los dispositivos son mas eficientes, con mayores capacidades de procesamiento e inteligentes, esto facilita su uso para recolectar información, procesarla y con ello, la capacidad de obtener información de respuestas apropiadas que permitan definir modelos de mejoramiento para ser introducidos en el esquema de las redes inalámbricas.

Un parámetro importante a tener en cuenta es la interferencia. Cuando no tenemos control sobre esquemas de interferencia co-canal o inter-canal, nuestro sistema inalámbrico o el de terceros podría no funcionar de manera apropiada, lo cual ocasionaría una degradación y pérdidas significativas en cualquiera de los servicios y plataformas de red afectadas.

Una manera de contrarrestar este problema es a través del diseño de mapas de interferencia con la información de nuestros servicios. Conocer y entender este problema es el primer paso para evitar la interferencia en nuestro sistema y en los servicios de terceros.

Conocer la disponibilidad del espectro permite encontrar un canal de frecuencia para ser usado en el transporte de información, por esta razón, la medición debe estar enfocada a evitar interferencia entre canales o entre diferentes servicios que hagan uso de la misma frecuencia. Una adecuada medición debe estar enfocada en evaluar el estado de uso del espectro y la disponibilidad de bandas de frecuencia para otros servicios (Höyhtyä et al., 2016). Los mapas de interferencia ofrecen información importante en términos de eficiencia y de precisión para uso del espectro y su respectivo uso en un ambiente operacional. Los mapas de interferencia muestran un nivel específico de interferencia sobre un área de interés en una correspondiente banda de frecuencia (Höyhtyä et al., 2016), para ello es posible obtenerlos a partir de una combinación de medidas de múltiples estaciones con sus coordenadas y su localización a través del área de operaciones (Naranjo, Ravanshid, Viering, Bauch, & Model, n.d.).

La tasa de operación de bandas de frecuencia estudia una banda específica o un agrupamiento de bandas usando parámetros adaptados, por ejemplo, conociendo el uso de las bandas celulares o el uso de radios inalámbricos públicos.

Por otro lado, a través de los mapas de interferencia conocer el mapa de densidad espectral que define toda la información acerca de la distribución de potencia de radio en los dominios de tiempo, espacio y frecuencia de cada banda de frecuencia de interés. La información es almacenada en un servidor para análisis y procesamiento. Con esta información, se podrían parametrizar diferentes fuentes de radiación y los usuarios que están tratando de usar los mismos espacios de frecuencia para administrar políticas de acceso y de esta manera evitar colisiones de acceso, pérdida de paquetes y principalmente evitar la interferencia entre usuarios (Alaya-feki, Jemaa, Houze, & Moulines, 2008). Para construir un mapa de interferencia es necesario emplear una muestra de la señal en el dominio de la frecuencia durante un intervalo de tiempo y espacio específico, con esto, se necesitan de unos “detectores” instrumentos que nos dan muestras de información de mediciones del espectro que permiten construir los mapas de interferencia.

La detección permite encontrar la señal sin interferencia, con ruido y parámetros funcionales adicionales como la cobertura, la capacidad y la calidad de servicio en la red. Todo lo anterior con características de información de geo-localización, atenuación de señal, relación señal a ruido (SNR), potencia total recibida, mejor estación base de servicio y eficiencia (Alaya-feki et al., 2008).

En la literatura se encuentras diversas formas de hacer detección; la detección de energía es una forma general que utiliza la medición de ocupación del espectro, no requiere información preliminar de las señales y toma una decisión en función de la medición del nivel de potencia y de la sensitividad con un nivel mínimo del SNR con alta confiabilidad.

El mapa de interferencia puede ser clasificado por sus objetivos y métodos de construcción, los objetivos son *i)* evitar la interferencia intra-sistema, *ii)* evitar la interferencia inter-sistema, *iii)* estimar la cobertura y *iv)* modelo de generación espacial y en los métodos de construcción encontramos *i)* medición de interferencia entre pares, *ii)* medición de cobertura y *iii)* mapa de densidad espectral de

potencia; más información en capítulo III de (Höyhtyä et al., 2016).

Sensado compresivo (CS) es una técnica para crear y recuperar señales con bajo ruido, a través del uso de menos muestras que las necesarias en el teorema de muestreo de Shannon- Nyquist (Qian, Guo, Li, & Sun, 2015)(Candes & Wakin, 2008). Esta técnica utiliza una función que representa la señal original en una señal sparse a través de una adecuada representación sparse. La señal original puede ser representada en un vector que tiene tamaño Nx1, donde N es igual a (1).

$$n_x n\ [rows] x [columns] \quad (1)$$

el cual pertenece a la matriz de información de la señal original.

Para encontrar la mejor solución de CS para análisis de imágenes espectrales, se ha estudiado la relación entre las bases matemáticas de las transformadas, la esparcidad, la esparcidad con ruido y algunos algoritmos de reconstrucción. Este documento está organizado así: en la sección II se presenta un resumen de los conceptos de sensado compresivo (CS), en la sección III los factores que influyen en la interferencia con la información de los mapas de esparcidad, sección IV se presentan los algoritmos de reconstrucción y en la sección V las conclusiones del artículo.

## 2. SENSADO COMPRESIVO

En esta sección se presenta la técnica de sensado compresivo y los referentes que fueron utilizados en este documento.

Artículos de literatura académica referencian CS como una herramienta utilizada en diferentes aplicaciones, por ejemplo, en (Feng, Valaee, & Tan, 2009) describen su uso en una plataforma de localización precisa fundamentada en el uso de transmisores sparse en un ambiente inalámbrico. En (Tropp & Gilbert, 2007) presentan un algoritmo para solucionar problemas que utilizan CS. En (Jayawickrama, Dutkiewicz, Oppermann, Fang, & Ding, 2013) y (Jayawickrama, Dutkiewicz, Fang, & Mueck, 2013) usan CS en cartografía de espectro para descubrir agujeros en el espacio, en (Jamali-rad, Ramezani, & Leus, 2012) lo usan para desarrollo de un algoritmo de localización con el uso de la técnica de correlación cruzada de las señales analizadas de diferentes puntos de acceso.

En (Krishnan & Vaze, n.d.) utilizan CS para procesamiento digital de imágenes, estimación de canal inalámbrico, tratamiento de señales de radar y comunicaciones de radio cognitiva, particularmente en el análisis de asignación de mediciones de ocupación y de asignación de espectro radioeléctrico a través del procesamiento de información representado en señales sparse en múltiples dominios de tiempo, frecuencia y espacio; el estudio se fundamenta en estos mecanismos que permitirán mejorar las futuras generaciones de redes inalámbricas donde se resalta CS como un mecanismo teórico y práctico que facilita la recuperación de cualquier señal proveniente de unas pocas muestras de la información original.

CS es un método para construir una señal sparse, la resultante es un vector que tiene unas pocas muestras de la señal original y con estas bajo el uso de métodos de reconstrucción algorítmicos se puede nuevamente reconstruir la señal original con alta precisión y con pocas pérdidas.

Para mejorar CS, la señal original es transformada en una base de representación común a través del uso de transformadas como la del coseno discreto (DCT), la de Wavelet, Fourier o la de Kronecker, principalmente. Estas transformadas permiten tener las muestras de la señal original en un dominio común y de esta forma reducir la variabilidad y dispersión de los datos originales.

La técnica de CS permite reducir la señal de la información por debajo de las condiciones representadas en el teorema de Shannon-Nyquist (Candes & Wakin, 2008)(Sharma, Lagunas, Chatzinotas, & Ottersten, 2016), todo condensado en el uso de técnicas de procesamiento y de esparcidad, principalmente. La esparcidad – sparse- se representa por "*s*" que representa el vector original discreto $S \in R^N$. $s$ tiene un factor de ensanchado $k$ y $s$ tiene elementos diferentes de cero de la señal original (los datos más representativos). Las señales con baja dispersión (factor $k$ alto) pueden convertir una señal con amplia dispersión a través de transformaciones lineales $f$ por $f=s$ y $f \in R^{NxN}$, representando los datos de una de las transformadas (DCT, Fourier, Wavelet o Kronecker).

Una señal *k-dispersa* donde $f \in R^N$ tiene muestras con CS para obtener una señal $g \in R^M$ donde M << N. Las muestras pueden ser representadas en una matriz de la forma $g = f$ y $\in R^{MxN}$, llamado sistema de matriz de muestras. Si $f$ no es conocido, es posible encontrar un sistema indeterminado de ecuaciones lineales que

conllevaría infinitas soluciones. Por este propósito, el sistema podría desarrollarse como un problema de optimización que podría convertirse en un problema matemático complejo no convexo o solucionarse a través de la utilización de *g* y de una matriz de sensado con algoritmos referenciados en la literatura como ”Iterative Hard Thresholding” (IHT), ”Orthogonal Matching Pursuit” (OMP), ”GradientP rojection for Sparse Reconstruction” (GPSR) o ”Two step Iterative Shrinkage/Thresholding” (Twist). (Candes & Wakin, 2008) (S. Kim, Anese, Member, & Giannakis, 2011)(S.-J. Kim, Dall’Anese, & Giannakis, 2011)(Marin, Betancur, & Arguello, n.d.). Estos algoritmos son usados en el presente documento para resolver el vector de reconstrucción de la señal original.

Sensado compresivo es usado para modelar información, CS permite representar a una señal con menores muestras de su representación original. Si una señal o una base de su representación puede ser representada como una señal sparse, entonces, es posible utilizar esta técnica para representar los valores espectrales con pocas muestras de la señal original (por debajo de lo requerido por el teorema de Shannon-Nyquist), posteriormente la técnica permite recuperar con altos valores de precisión la señal original a través de pertinentes algoritmos de reconstrucción. Esto permite encontrar ventajas en redes de comunicación inalámbrica por tanto el procesar menor cantidad de información en los equipos trasciende en ahorro de consumo energético, de ancho de banda y en tiempos de transmisión, principalmente.

Por las razones mencionadas, el proceso de sensado compresivo en la construcción de mapas de interferencia facilita la reducción de carga útil de información para ser procesada y con ello el tiempo de procesamiento y el consumo de energía. Una frecuencia puede ser representada por una componente espectral y a su vez ser vista como una dispersión, los puntos de una imagen espectral puedes ser representados como un vector donde el mismo represente la radiancia y la reflectancia con algunas longitudes de onda. Un caso especial que se puede tomar como ejemplo para entender lo acá presentado es analizando una imagen con las tres componentes principales (roja, verde y azul-RGB). Las bandas espectrales altas tienen un número grande de pixeles y acá es importante preguntar el por qué es importante trabajar con un número alto de información dentro de una señal? Es importante por qué ello implica mayor precisión, calidad y confiabilidad en la información procesada, sin embargo, ello implica un problema en términos de procesamiento computacional consecuente con el alto consumo energético, almacenamiento y retardos de procesamiento, principalmente. Debido a estos inconvenientes, es necesario reducir la cantidad de información que se encuentra representada en una imagen espectral. En años recientes han aparecido métodos para adquirir y procesar menos información a través de CS, permitiendo reducir la redundancia de información y administrar las tareas de procesamiento con menor dispersión a través de la transformación en bases de representación común (Wavelet, Kronecker, Coseno Discreto y Fourier, principalmente).

Una señal sparse representada en una transformada con pocas muestras (por debajo de los parámetros del teorema de Nyquist) y que pueda reconstruirse con alto grado de similitud con respecto a la original es el objetivo primordial de CS. En nuestro contexto, se necesita la construcción de un modelo de ocupación espectral a través del uso de mapas de interferencia con CS. Algunas áreas de aplicación para alcanzar este objetivo son: control de potencia, radio cognitiva, eficiencia energética, decisiones inteligentes y decisión de uso de recursos.

## 3. ESPARCIDAD EN MAPAS DE INTERFERENCIA

En la presente sección son descritos los conceptos y uso en este artículo del método de esparcidad en mapas de interferencia.

Un modelo multi-espectral con información acerca del manejo de la potencia con referencia satelital GPS a diferentes frecuencias es el objetivo de alcanzar bajo el uso de una alta compresión de los datos mediante sensado compresivo. Este modelo tiene una ocupancia espectral conocida como mapas de radio frecuencia o densidad espectral de potencia o de interferencia (Alaya-feki et al., 2008)(Riihij, 2012)(Bazerque, Member, Mateos, Member, & Giannakis, 2011). El modelo utiliza la cartografía con un nivel de la información de interferencia en un área geográfica para ser usada en la interpolación de los algoritmos que predecirán la potencia utilizada en determinada área geográfica; sin embargo, está técnica por sí sola no incluye la técnica de compresión para el muestreo de los datos en donde cada mapa es construido y analizado de manera independiente.

El modelo utiliza una dispersión espectral y espacial que representa los mapas como un cubo multi-espectral, permitiendo la adaptación de las técnicas multi-espectrales para el procesamiento de imágenes y así explotar las características de

compresión y de reconstrucción de la información. En el modelo planteado se reduce la información en dos etapas, en el muestreo espacial y en el momento de procesamiento de las muestras. La respuesta es un arreglo 2D con los cuales se construye el cubo con información de la potencia en el dominio del espacio y en diferentes bandas espectrales. La información de los mapas de potencia en una frecuencia singular es conocida como mapas espectrales de potencia (PSM).

Una señal sparse representa una señal con componentes que tiene muestras iguales a cero, por ejemplo, cuando se considera una señal que tiene *n* muestras y tiene *m* muestras diferentes de cero (donde $m << n$), entonces la señal es *m*-sparse y se considera una señal con alta esparcidad por su alto número de muestras iguales a cero.

La esparcidad en mapas de interferencia facilita la reducción de información beneficiando el tiempo de procesamiento, el uso de ancho de banda, consumo energético, principalmente. Si tenemos una señal con 2048 muestras y 80 son diferentes de cero (la señal es 80 sparse, equivalente a una señal con alta esparcidad), ahora, cuando usamos sensado compresivo, 512 componentes de la señal son muestreadas de los 2048 originales, representando un factor de compresión de 4, con estos datos de compresión es posible recuperar la información original con bajas pérdidas a través de algoritmos de reconstrucción como IHT, OMP, GPSR y Twist, principalmente.

Si utilizamos mayor número de muestras de la señal original, mayor precisión y calidad será alcanzada, sin embargo, mayores recursos de computo serán necesarios, por lo tanto, el objetivo primordial consiste en diseñar un sistema que pueda ajustarse a las necesidades particulares de cada aplicación.

Para el procesamiento de la información de nuestros datos hemos evaluado el grado de esparcidad con respecto a la representación de los datos en sus resultantes de operación de las transformadas Wavelet, Kronecker y Coseno Discreto. La figura 1 muestra la relación de valores de la señal a ruido pico (PSNR) con respecto al porcentaje de esparcidad. Es posible ver que al incrementar la esparcidad, la transformada Wavelet alcanza los mejores resultados en donde los valores mínimos del índice PSNR varían entre -80 a -90 dB.

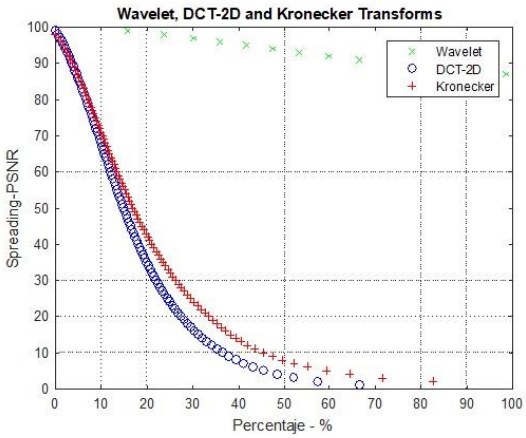



Fig 1. Relación señal a ruido pico (PSNR) contra porcentaje de esparcidad

Los coeficientes de las transformadas base de representación se muestran en la figura 2, en esta figura, es posible observar que la transformada Wavelet genera los mejores resultados por qué representan los datos con menor varianza y con ello beneficia que mayor número de muestras sean sparse, permitiendo, obtener mejores resultados en la aplicación de la técnica de sensado compresivo y a través de su transformada inversa recuperar la señal reconstruida con alta similitud a la señal original.

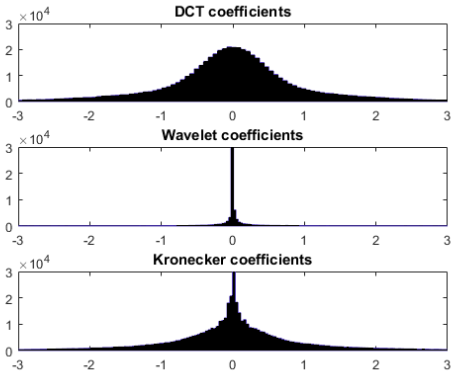



Fig 2. Distribución de coeficientes

## 4. ALGORITMOS DE RECONSTRUCCIÓN

En esta sección se presentan los algoritmos de reconstrucción utilizados en el presente documento.

Las técnicas de reconstrucción y sus algoritmos son herramientas que permiten construir una señal a partir del uso de pocas muestras de la señal original. Para el escenario de este artículo esas pocas muestras son el vector resultante del uso de la técnica de sensado compresivo y en donde las técnicas de reconstrucción son algoritmos matemáticos especializados. En la literatura científica y académica se encuentran

diferentes herramientas disponibles como los algoritmos IHT, OMP, GPSR y Twist, para nuestro estudio estas técnicas fueron evaluadas y comparadas para encontrar la mejor solución posible en la construcción de mapas de interferencia. Para el proceso de evaluación y comparación fueron tomados los vectores de las señales sparse y una matriz de muestreo definida a partir de las muestras de la señal original, factores particulares de cada algoritmo fueron implementados y las salidas fueron una relación entre la señal reconstruida y la señal original dada por la relación señal a ruido (PSNR) entregada por las dos fuentes de entrada con respecto al número de muestras reconstruidas (M). La salida puede observarse en la figura 3. La salida observada en esta figura 3 permite encontrar en el algoritmo Twist con el mejor índice de reconstrucción con respecto al número de muestras reconstruidas.

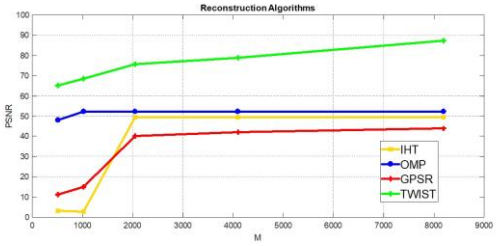



Fig. 3 Algoritmos de reconstrucción

De manera transversal el sistema fue evaluado con una fuente de ruido Gaussiano alterno y los resultados parametrizan nuevamente a Twist como la mejor herramienta de reconstrucción para las señales provenientes de la construcción de mapas espectrales de interferencia.

## 5. CONCLUSIONES

Este proceso permite presentar una solución adecuada para el análisis de imágenes espectrales a través del uso de sensado compresivo, hemos estudiado la relación entre transformadas de bases matemáticas, esparcidad, esparcidad con ruido y algunos algoritmos de reconstrucción representativos en la literatura científica, fue presentado un resumen del funcionamiento y modo de operación de sensado compresivo, interferencia en mapas de esparcidad y algoritmos de reconstrucción en el trabajo de la construcción de mapas espectrales de interferencia.

## 5. AGRADECIMIENTOS

Los autores desean agradecer el apoyo brindado por la Gobernación de Boyacá, beca 733 de Colciencias, a la Universidad Rey Juan Carlos, Universidad Santo Tomás, Pontificia Universidad Javeriana, a todos ellos por su financiación y respaldo.

## REFERENCIAS

Alaya-feki, A. H., Jemaa, S. Ben, Houze, P., & Moulines, E. (2008). Informed spectrum usage in cognitive radio networks: Interference cartography.

Bazerque, J. A., Member, S., Mateos, G., Member, S., & Giannakis, G. B. (2011). Group-Lasso on Splines for Spectrum Cartography, *59*(10), 4648–4663.

Candes, E. J., & Wakin, M. B. (2008). An Introduction To Compressive Sampling. *IEEE Signal Processing Magazine*, *25*(2), 21–30. https://doi.org/10.1109/MSP.2007.914731

Feng, C., Valaee, S., & Tan, Z. (2009). Multiple Target Localization Using Compressive Sensing.

Höyhtyä, M., Member, S., Mämmelä, A., Member, S., Eskola, M., Matinmikko, M., … Member, S. (2016). Spectrum Occupancy Measurements : A Survey and Use of Interference Maps, *18*(4), 2386–2414.

Jamali-rad, H., Ramezani, H., & Leus, G. (2012). Sparse Multi-Target Localization Using Cooperative Access Points, 353–356.

Jayawickrama, B. A., Dutkiewicz, E., Fang, G., & Mueck, M. (2013). Downlink Power Allocation Algorithm for Licence-exempt LTE Systems Using Kriging and Compressive Sensing Based Spectrum Cartography, 3766–3771.

Jayawickrama, B. A., Dutkiewicz, E., Oppermann, I., Fang, G., & Ding, J. (2013). Improved performance of spectrum cartography based on compressive sensing in cognitive radio networks. *2013 IEEE International Conference on Communications (ICC)*, 5657–5661. https://doi.org/10.1109/ICC.2013.6655495

Kim, S.-J., Dall'Anese, E., & Giannakis, G. B. (2011). Cooperative Spectrum Sensing for Cognitive Radios Using Kriged Kalman Filtering. *IEEE Journal of Selected Topics in Signal Processing*, *5*(1), 24–36. https://doi.org/10.1109/JSTSP.2010.2053016

Kim, S., Anese, E. D., Member, S., & Giannakis, G. B. (2011). Cooperative Spectrum Sensing for Cognitive Radios Using Kriged Kalman Filtering, *5*(1), 24–36.

Krishnan, B. S., & Vaze, R. (n.d.). On White-Space Detection , Localization and Coverage.

Marin, J., Betancur, L., & Arguello, H. (n.d.).

Modelo de Muestreo Comprimido Multiespectral para Radio Cognitiva Compressed Sensing Multiespectral Model for Cognitive Radio Networks, (70).

Naranjo, J. D., Ravanshid, A., Viering, I., Bauch, G., & Model, A. R. A. N. I. (n.d.). Interference Map Estimation Using Spatial Interpolation of MDT Reports in Cognitive Radio Networks, *2*, 1496–1501.

Qian, P., Guo, Y., Li, N., & Sun, B. (2015). Multiple Target Localization and Power Estimation in Wireless Sensor Networks using Compressive Sensing, 1–5.

Riihij, J. (2012). Demonstrating Radio Environment Map Construction from Massive Data Sets, 266–267.

Sharma, S. K., Lagunas, E., Chatzinotas, S., & Ottersten, B. (2016). Application of Compressive Sensing in Cognitive Radio Communications: A Survey. *IEEE Communications Surveys & Tutorials*, *18*(3), 1838–1860. https://doi.org/10.1109/COMST.2016.2524443

Tropp, J. a, & Gilbert, A. C. (2007). Via Orthogonal Matching Pursuit. *IEEE Transactions on Information Theory*, *53*(12), 4655–4666. https://doi.org/10.1109/TIT.2007.909108