

Arquitecturas de muestreo compresivo para tareas de detección y clasificación de imágenes espectrales de cultivos

Ferley Medina Rojas, master Telemática¹, Henry Arguello Fuentes, PhD Electrical and Computer Engineering², Cristina Gómez Santa María, PhD Ingeniería³
¹Universidad Cooperativa de Colombia sede Neiva, Colombia, ferley.medina@campusucc.edu.co
²Universidad Industrial de Santander sede Bucaramanga, Colombia, henarfu@uis.edu.co
³Universidad Pontificia Bolivariana sede Medellín, Colombia, cristina.gomez@upb.edu.co

Resumen—La agricultura de precisión hace uso de la tecnología para mejorar la producción de los cultivos. Con una imagen espectral SI, se representa información en alta resolución espectral, de los materiales o la vegetación presente en la superficie de la tierra. El alto volumen de información que generan las SI, fomentan el uso del muestreo compresivo CS.

La teoría del CS se ha adoptado para hacer un muestreo eficiente de las señales, disminuyendo la cantidad de medidas impuestas por el criterio de Nyquist. CS, se adoptó como un protocolo de muestreo de imágenes espectrales, y se han desarrollado una serie de arquitecturas basadas en este principio, entre las que cabe mencionar CASSI, SSCSI, SCCSI y HYA. éstas, permiten simultáneamente el muestreo y la compresión de las imágenes. Con las cuales se pueden realizar las tareas de detección y clasificación de objetivos en cultivos.

Este trabajo, describe las características de estas arquitecturas, como un primer paso para determinar la de mayor calidad en el uso de la agricultura de precisión.

Palabras claves— Agricultura de precisión, imágenes espectrales, detección y clasificación de objetivos.

Abstract— Precision agriculture makes use of technology to improve crop production. With a spectral image SI, spectral high-resolution information of the materials or vegetation present on the surface of the earth is represented. The high volume of information generated by ISs encourages the use of CS compression sampling.

The CS theory has been adopted to make an efficient sampling of the signals, decreasing the amount of measures imposed by the Nyquist criterion. CS, was adopted as a sampling protocol for spectral images, and a series of architectures based on this principle have been developed, among which CASSI, SSCSI, SCCSI and HYA. These allow simultaneous sampling and compression of the images. With which you can perform the tasks of detection and classification of objectives in crops.

This work describes the characteristics of these architectures as a first step to determine the highest quality in the use of precision agriculture.

Keywords— precision agriculture, spectral imaging, detection and classification of objectives.

I. INTRODUCTION

La agricultura de precisión utiliza tecnología para la colección y procesamiento de datos desde diferentes dispositivos electrónicos, ópticos algunos como sensores, cámaras y de sistemas geográficos de posicionamiento (GPS) para realizar las labores culturales focalizadas de un cultivo justo a tiempo, con las dosis requeridas de los insumos para hacer el seguimiento de las mismas [1].

En los cultivos se miden la deficiencias de nutrientes, condiciones del suelo, detección de las plagas o malezas de forma temprana, disponibilidad de agua en el suelo [2], [3], [4], [5].

Las imágenes espectrales se usan en los cultivos de remolacha para establecer patrones de las enfermedades que lo atacan, mediante la obtención del espectro del pixel de cada imagen en una escena para identificar el color, tamaño y ubicación de las manchas en las hojas del cultivo que son los síntomas para determinar el estado y avance de los posibles ataques de las enfermedades. El uso del algoritmo de máquina de soporte vectorial permite la clasificación no lineal de los datos obtenidos para hacer una predicción temprana de las enfermedades antes de que sus síntomas afloren en su totalidad, logrando un tratamiento oportuno para una mayor producción y rentabilidad del cultivo [6]. Sin embargo, al hacer una revisión del estado del arte no se ha encontrado un estudio que compare las arquitectura de muestreo compresivo CASSI, SSCSI, SCCSI y HYCA en las tareas de detección y clasificación de objetivos en los cultivos.

En este trabajo, se presenta las características de cuatro de las arquitecturas de muestreo compresivo utilizadas para la toma de imágenes espectrales, como un principio a lo que sería las tareas de detección y clasificación de objetivos en cultivos..

II. IMÁGENES ESPECTRALES

Las imágenes espectrales (SI, de su sigla en inglés) son una concatenación de imágenes bidimensionales que contienen información de una escena a lo largo del

espectro electromagnético en alta resolución espectral, de los materiales o la vegetación presente en la superficie de la tierra [7], espacio [8], y cuerpo humano [9]. La información contenida en una SI corresponde a datos de radiancia y reflectancia de la superficie, que pueden ser observados como una dispersión de puntos en un espacio Euclidiano L-dimensional, donde L es el número de bandas espectrales. Las SI son usadas en las áreas del medio ambiente [10], minería [11], geología [12], [10], caracterización del suelo [13], [14]. Especialmente, en la agricultura para el monitoreo, seguimiento y control del periodo vegetativo de los cultivos (desde la siembra hasta determinar el punto de recolección de la cosecha) e identificación de malezas, plagas, enfermedades o deficiencias de nutrientes [15], [16]. Un píxel perteneciente a una SI se considera como un vector $v = [v_1, v_2, \dots, v_L]$, que contiene uno o varios espectros mezclados de diferentes materiales presentes en una escena [17]. Es posible medir la similitud entre los dos espectros, detectar y clasificar un objetivo explorando los datos contenidos en la L-dimensión espacial aplicando algoritmos de detección y clasificación [18].

Las L bandas de una imagen espectral forman un cubo de datos, cuyas dimensiones corresponden a la combinación de información espacial (x, y) y espectral L de la escena. Los sensores SI tienen la capacidad de adquirir la información espectral de los materiales que conforman los diversos objetos en una escena, que poseen un comportamiento espectral específico de acuerdo a su composición [18]. La figura 2.1 muestra la clasificación de las imágenes espectrales de acuerdo al número de bandas que contiene. La figura 1(a) muestra una imagen RGB, que pertenecen al rango visible del espectro; la figura 1(b) muestra una imagen multiespectral, que contiene información en decenas de bandas; y la figura 1(c) muestra una imagen hiperespectral, que contiene más de 100 bandas [19]. El volumen de la información generada en el muestreo tradicional de las SI demanda memoria, ancho de banda y recuperación de la información. El muestreo compresivo (CS, de su sigla en inglés) es una teoría que ha sido estudiada para hacer eficiente el muestreo de la señal y reducir la redundancia de las medidas tomando como ventaja la correlación entre las medidas [20].




Fig. 1 (a) Imagen RGB, (b) imagen multiespectral (menos de 10 bandas), (c) imagen hiperespectral (mayor de 100 bandas).

A. Muestreo compresivo

El muestreo compresivo establece que el criterio de muestreo de Nyquist [21], [22], puede ser superado [23], por la compresión y el muestreo de forma simultánea. Esta teoría es basada en los principios de dispersión e incoherencia [24]. De esta manera, se calcula un conjunto de coeficientes dispersos en alguna base (por ejemplo Wavelet), que corresponde a una señal $f = \{f \in \mathbb{R}^{M \cdot N \cdot L} \mid [f_1, \dots, f_{M \cdot N}, \dots, f_{M \cdot N \cdot L}]^T\}$, que representa la imagen espectral, donde M y N representan la resolución espacial y L la resolución espectral, lo que permite recuperar la señal sin distorsión [20].

El muestreo compresivo puede ser modelado como un conjunto de proyecciones lineales de f a través de la matriz de medidas $H = [\Phi_1, \Phi_2, \Phi_3, \dots, \Phi_{M \cdot N \cdot L}]$, con $\Phi_i \in \mathbb{R}$. También, se puede expresar como:

$$\mathbf{g} = \sum_i^w \Phi_i \mathbf{f}_i = \mathbf{H} \mathbf{f} \quad (1)$$

Dispersión de las señales

Una señal dispersa de tamaño N, puede ser representada en el vector $s \in \mathbb{R}^N$, donde K es el factor de dispersión si $\|s\|_0 = |\{s\}| = |s(k) \neq 0: k = \{1, \dots, N\}| \leq K$, donde s contiene elementos no ceros de la señal en algún dominio transformado. La mayoría de señales no son de naturaleza dispersa, sin embargo, pueden ser transformadas como una representación dispersa [26]:

$$\mathbf{f} = \Psi \mathbf{s} \quad (2)$$

donde $\Psi \in \mathbb{R}^N \times N$ es la representación de la base. La figura 2 muestra un ejemplo de una imagen que se puede representar según la ecuación (2). La figura 2 (a) muestra una imagen de 165×370 píxeles, la figura (b) muestra la secuencia de los coeficientes Wavelet de la imagen de la figura 2.2(a), en donde solo en el 5% de las posiciones se concentran los coeficientes más representativos de la imagen, y la figura (c) muestra la imagen de la figura (a) recuperada con el 5% de la secuencia de los coeficientes Wavelet de mayor valor absoluto. Las transformaciones

dispersas están dadas por diccionarios tales como Wavelet, Coseno discreto, Fourier o imágenes de entrenamiento.




Fig. 2 (a) Imagen RGB, (b) secuencia de los coeficientes de transformación Wavelet de la figura (a) en valores absolutos ordenados de mayor a menor, (c) imagen de la figura (a) recuperada con el 5% de los coeficientes de la figura (b).

Muestreo incoherente

La incoherencia en el muestreo compresivo está dada por el grado de correlación entre los elementos de las bases \mathbf{H} y Ψ . La existencia de la correlación significa que existe un alto grado de coherencia entre las dos bases, que está dada por:

$$\mu(\mathbf{H}, \Psi) = \sqrt{N} \cdot \max_{1 \leq k, j \leq N} |h\phi k, \psi j i|, \quad (3)$$

donde el valor mínimo y máximo están definidos por

$\mu(\mathbf{H}, \Psi) \in [1, \sqrt{N}]$. Si al calcular (3) se obtiene el máximo valor, la señal \mathbf{f} no puede ser muestreada. Para resolver esta dificultad, se recurre al muestreo aleatorio [27], [28-39].

Aplicaciones del muestreo compresivo

El muestreo compresivo ha sido aplicado con éxito en el muestreo de señales, se destacan aplicaciones en el muestreo de imágenes como la cámara de único píxel, para la detección de imágenes de resonancia magnética y de radar [20]; imágenes médicas y espectrales en el dominio compresivo [40]; detección de anomalías en imágenes espectrales [41]. En los últimos años, el muestreo compresivo [42] se adoptó como un protocolo de muestreo de imágenes espectrales, y se han desarrollado una serie de arquitecturas basadas en este principio, entre las que cabe mencionar CASSI (del inglés Coded aperture snapshot spectral imaging), SSCSI (del inglés spatial spectral encoded compressive hyperspectral imaging), SCCSI (del inglés snapshot colored compressive spectral imager) y HYCA (del inglés hyperspectral coded aperture)

III. ARQUITECTURAS DE MUESTREO COMPRESIVO EN IMÁGENES ESPECTRALES

El sistema de captura en las arquitecturas de muestreo compresivo puede ser modelado algebraicamente como $\mathbf{g} = \mathbf{H}\mathbf{f}$, donde \mathbf{H} es la matriz de muestreo que caracteriza el sistema. Los parámetros de la matriz de muestreo, depende de lo específico de las arquitecturas tales como CASSI, SSCSI, SCCSI o HYCA. En esta sección, se describe el modelo de muestreo de cada arquitectura.

A. Sistema de adquisición comprimida HIS

El Sistema de adquisición comprimida de imágenes espectrales (CASSI) basado en aperturas codificadas, representadas por $T(x, y)$, modula una escena espacio-espectral $f_0(x, y, \lambda)$. El campo codificado resultante $f_1(x, y, \lambda)$, se dispersa con el elemento dispersivo $\alpha(\lambda)$, esto es:

$$f_2(x, y, \lambda) = \iint T(x', y') f_0(x', y', \lambda) \times h(x - x' - s_1 \lambda, y - y') dx' dy', \quad (4)$$

donde $T(x', y')$ representa la función de transmisión de la apertura codificada, $h(x - x' - s_1 \lambda, y - y')$ es la respuesta al impulso óptico del sistema y $s_1 \lambda$ es la dispersión inducida por el elemento dispersivo, asumida como dispersión lineal. Las medidas comprimidas son adquiridas cuando el campo $f_2(x, y, \lambda)$ se integra en el sensor. La densidad espectral en frente del detector está dada por

$$\mathbf{g}(x, y) = \int_{\Lambda} f_2(x, y, \lambda) d\lambda, \quad \text{donde } \Lambda \text{ rango espectral del detector, la respuesta óptica al impulso del sistema se asume como lineal e ideal, la densidad espectral resultante es:}$$

$$g(x, y) = \int f_0(x + s_1 \lambda, y, \lambda) T(x + s_1 \lambda, y) d\lambda. \quad (5)$$

La apertura codificada $T(x, y)$ puede ser representada como un arreglo pixelado espacialmente. Asumiendo que el píxel de la apertura codificada tiene tamaño Δ_x y $t_{n', m'}$ representa un valor binario (0) bloqueo y (1) desbloqueo, la apertura codificada se puede expresar como,

$$T(x, y) = \sum_{n', m'} t_{n', m'} \text{rect} \left(\frac{x}{\Delta_x} - n', \frac{y}{\Delta_y} - m' \right). \quad (6)$$

La escena espacio espectral se representa mediante $F_{n', m', k}$ tal que $n' \in \{0, \dots, N-1\}$ es el índice en x , $m' \in \{0, \dots, N-1\}$ es el índice en y , $k \in \{0, \dots, L-1\}$ es

el índice en la longitud de onda. Las medidas discretas en el sensor se pueden expresar como:

$$G_{n,m} = \sum_{k=0}^{L-1} F_{(n-k),m,k} T_{(n-k),m} + \omega_{n,m}, \quad (7)$$

donde, $G_{n,m}$ es la intensidad en la (n,m) posición del detector G con dimensiones $(N+L-1) \times N, n \in \{0, \dots, N-1\}$, el cubo espectral \mathbf{F} tiene tamaño $N \times N \times L, (n-k)$, está definido entre $1 \leq (n-k) \leq N$ en otros casos $(n-k)=0, T_{n,m}$ es el (n,m) valor en el modulador espacial y ω representa el ruido del sistema [39], [43],[44].

B. Codificación compresiva en el espacio espectral para imágenes hiperespectrales

Mediante la codificación compresiva en el espacio espectral para imágenes hiperespectrales (SSCSI) se reconstruye una imagen hiperespectral de alta resolución a partir de un único sensor, para lo cual, el diseño de la cámara óptica está fundamentado en el muestreo de la imagen hiperespectral codificada en espacio y espectro [45].

El muestreo de la imagen hiperespectral codificada en espacio y espectro está dado por $o(x, y, \lambda)$, para imágenes hiperespectrales en tres dimensiones, $i(x,y)$ es la imagen del sensor formada por la proyección de las imágenes hiperespectrales a largo de la dimensión del espectro sobre el dominio Ω_λ :

$$i(x, y) = \int_{\Omega_\lambda} o(x, y, \lambda) d\lambda. \quad (8)$$

El aprendizaje de los átomos y diccionarios sobre todas las imágenes hiperespectrales, se basan en un gran conjunto de muestras de aprendizaje de todos los píxeles en sus tres dimensiones, las muestras se eligen por un número aleatorio de parches desde una colección de formación de las imágenes hiperespectrales. Los diccionarios se resuelven por un problema de optimización:

$$\min_{\Psi, \mathbf{A}} \|\mathbf{T} - \Psi \mathbf{A}\|_2^2; \text{ s.t. } \forall i = 1, \dots, o, \|\mathbf{s}_i\|_0 \leq K, \quad (9)$$

donde $\mathbf{T} \in \mathbb{R}^{N \times o}$ es un conjunto de entrenamiento de o parches, $\mathbf{A} = [s_1, \dots, s_o] \in \mathbb{R}^{q \times o}$ es una matriz que contiene en sus columnas los vectores K dispersos s_i .

C. Sistema de adquisición de imágenes multiespectrales con detectores basados en filtros ópticos

Los patrones espectrales compresivos de imágenes instantáneas (SCCSI) reemplazan la matriz de plano focal (FPA) por los detectores con patrones de filtros ópticos. Adicionalmente, un elemento dispersivo permite captar la información tanto espacial como espectral de la fuente origen en una sola toma [46].

Esta arquitectura posee un arreglo de filtros ópticos en el detector, con distinta respuesta espectral, que permite obtener componentes espectrales específicos en cada píxel. De esta manera, el esquema de codificación es enriquecido, permitiendo que el problema de reconstrucción sea mejor condicionado. Su reducido número de elementos ópticos, lo hace un sistema compacto que genera una reducción de costos considerable y facilidades en su implementación.

En el sistema SCCSI, la imagen multiespectral $f_0(x, y, \lambda)$, primero se dispersa espectralmente por un elemento dispersivo, generando el campo $f_1(x, y, \lambda)$ dado por:

$$f_1(x, y, \lambda) = \iint f_0(x', y', \lambda) h(x' - x, y' - y - s_1(\lambda)) dx' dy', \quad (10)$$

donde $s_1(\lambda)$ es la dispersión y h es la respuesta al impulso del sistema, f_1 se codificada por la matriz de filtros ópticos $C(x, y, \lambda)$, ubicada en el detector FPA, para obtener una versión codificada y dispersa de la señal original, expresada como:

$$f_2(x, y) = f_1(x, y, \lambda) C(x, y, \lambda), \quad (11)$$

donde la salida del sistema $f_2(x, y)$ se obtiene integrando el producto de f_1 y el arreglo de filtros ópticos sobre el rango espectral del detector Λ .

D. Código de apertura hiperespectral

El método basado en el código de apertura hiperespectral (HYCA) se apoya en las características de las imágenes hiperespectrales; la baja dimensionalidad del espacio a la cual pertenece el vector hiperespectral que está compuesto por proyecciones aleatorias Gaussianas o Bernoulli i.i.d., y la alta correlación entre las dimensiones espaciales y espectrales de los componentes del cubo de datos [47]. El cubo de datos se define como $\mathbf{F} \in \mathbb{R}^{L \times N \times N}$.

El vector de las medidas $\mathbf{g} \in \mathbb{R}^M$ se modela como:

$$\mathbf{g} = H(\mathbf{F}) + w, \quad (12)$$

donde $\mathbf{H}:\mathbb{R}^{N \times N \times L} \rightarrow \mathbb{R}^M$ es un operador que calcula los M productos internos entre el vector hiperespectral y los elementos de \mathbf{F} y w el nivel de ruido. Como H es un operador lineal, entonces se tiene que $H(\mathbf{F}) = \mathbf{H}\mathbf{f}$, donde $\mathbf{f} := \text{vec}(\mathbf{F})$ es el vector formado de las columnas de \mathbf{F} , y $\mathbf{H} \in \mathbb{R}^{M(N \times N \times L)}$, es la matriz que modela del operador lineal H .

Como el objetivo del muestreo compresivo es recuperar \mathbf{f} , $\mathbf{f} = \Psi\mathbf{s}$, la recuperación de la imagen se plantea como:

$$\min_{\mathbf{s}} \|\mathbf{s}\|_0 \text{ subjecto } a \|\mathbf{g} - \mathbf{H}\Psi\mathbf{s}\| \leq \delta, \quad (13)$$

donde $\delta \geq 0$ y depende del tamaño de n . La matriz \mathbf{H} se construye como:

$$\mathbf{H} := \text{bdiag}(\mathbf{H}_1, \dots, \mathbf{H}_{N \times N}), \quad (14)$$

donde $\text{bdiag}(\cdot)$ es el bloque de diagonales, $\mathbf{H}_i \in \mathbb{R}^{sh \times L}$ es la matriz que mide cada píxel a lo largo de su longitud espectral (L) y sh es el número de veces que se mide cada píxel.

IV. OPERACIONES EN IMAGENES ESPECTRALES

Dentro de las operaciones posibles están la detección, y clasificación, que se encargan de la extracción de la información partir de las muestras [48-56].

A. Detección

La detección consiste en probar, por medio de la estadística, una de las hipótesis H_0 o H_1 acerca de un objetivo, es decir que el objetivo está ausente o presente en las medidas. Las hipótesis están dadas por:

$$\begin{aligned} H_0 : \mathbf{g} &= w \\ H_1 : \mathbf{g} &= \mathbf{f} + w, \end{aligned} \quad (15)$$

donde $w \sim N(0, s^2 I_N)$ es ruido Gaussiano i.i.d. Dados

$$\begin{aligned} P_F &= \Pr(H_1 \text{ es seleccionado cuando } H_0 \text{ es verdadero}) \\ P_D &= \Pr(H_1 \text{ es seleccionado cuando } H_1 \text{ es verdadero}), \end{aligned} \quad (16)$$

denotan la tasa de falsa alarma y la tasa de detección, respectivamente [51].

B. Clasificación

La clasificación decide la clase a la cual pertenece un píxel [38], además, se refiere a poder distinguir entre $\mathbf{H}(\mathbf{S}_0 + w)$ y $\mathbf{H}(\mathbf{S}_1 + w)$ definido por la hipótesis

$$H_i : \mathbf{g} = \mathbf{H}(\mathbf{f}_i + w), \quad (17)$$

para $i=1,2,\dots,R$, en donde \mathbf{f}_i es la señal conocida, con $\mathbf{f}_i \in \mathbf{S}$, $R = |\mathbf{f}|$ y \mathbf{S} es la clase [39].

IV. CONCLUSIONES

Las arquitecturas de muestreo compresivo tienen características propias en el momento de tomar la imagen, CASSI blanco y negro bloquea o desbloquea un elemento; SSCSI de color con una máscara de codificación espectral; SCCSI tiene un arreglo de filtros ópticos a color y HYCA teórica con una longitud de atenuación espectral.

(3.14)

REFERENCES

- [1] P. S. Gorbea, "Tendencias Transdisciplinarios en los Estudios Métricos de la Información y su Relación con la Gestión de la Información y del Conocimiento," *Perspectivas em Gestão & Conhecimento*, vol. 3, no. 1, pp. 13-27, 2013.
- [2] L. W.S., V. A. Y. C., H. M., D. M. and C. L. , "Sensing technologies for precision specialty crop production," *Computers and Electronics in Agriculture*, vol. 74, no. 1, pp. 2-33, 2010.
- [3] G. Rub, R. Kruse, M. Schneider and P. Wagner, "Data mining with neural networks for wheat yield prediction," *Computer science Vol 5077*, pp. 47-56, 2008.
- [4] M. Karamouz, B. Zahraie, R. Kerachian and A. Eslami, "Crop Pattern and Conjunctive Use Management: a Case Study," *Irrigation and Drainage, volumen 59 issue 2*, pp. 161-173, 2010.
- [5] TRumpfam, A.-K. Mahleinb, U. Steinerbm, E.-C. Oerkeb, H.-W. Dehneb and L. Plümera, "Early detection and classification of plant diseases with Support vector machines based on hyperspectral reflectance," *Computers and electronics in agriculture, vol 74 issue 1*, pp. 91-99, 2010.
- [6] Rojas, F. M; Arguello, H,F; Gómez, C,S . Diseño de Patrones de Estratificación de Cultivos en el Departamento del Huila Colombia, Minería de Datos para una Agricultura de Precisión. 14 th LACCEI International Multi-Conference for Engineering, Education, and Technology: "Engineering Innovations for Global Sustainability", 20-22 July 2016, San José, Costa Rica <http://www.laccei.org/LACCEI2016-SanJose/RefereedPapers/RP104.pdf>
- [7] M. K. Griffin, S. May-Hsu, H. K. Burke, S. M. Orloff, and C. a. Upham, "Examples of EO-1 Hyperion data analysis," *Lincoln Laboratory Journal*, vol. 15, no. 2, pp. 271-298, 2005.
- [8] J. Gustin, D. Grodent, L. C. Ray, B. Bonfond, E. J. Bunce, J. D. Nichols, and N. Ozak, "Characteristics of north jovian aurora from STIS FUV spectral images," *Icarus*, vol. 268, pp. 215-241, 2016.
- [9] G. Lu and B. Fei, "Medical hyperspectral imaging: a review." *Journal of biomedical optics*, vol. 19, no. 1, p. 10901, 2014. [Online]. Available: <http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=3895860&tool=pmcentrez&rendertype=abstract>
- [10] G. Mishne, R. Talmon, I. Cohen, and S. Member, "Graph-Based Supervised Automatic Target Detection," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 53, no. 5, pp. 2738-2754, 2015. [Online]. Available: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6954458>
- [11] H. Soydan, A. Koz, H. Azebne Düzgün, and A. Aydin Alatan, "Hydrocarbon microseepage mapping using signature based target detection techniques," U. Michel, K. Schulz, M. Ehlers, K. G. Nikolakopoulos, and D. Civco, Eds., Oct. 2015,

- p. 964401. [Online]. Available: <http://proceedings.spiedigitallibrary.org/proceeding.aspx?doi=10.1117/12.2195105> Manuscript Templates for Conference Proceedings, IEEE. http://www.ieee.org/conferences_events/conferences/publishing/templates.html
- [12] A. Camacho-Velasco, C. A. Vargas-García, F. A. Rojas-Morales, S. F. Castillo-Castelblanco, and H. Arguello-Fuentes, "Aplicaciones y retos del sensado remoto hiperespectral en la geología colombiana Applications and challenges of hyperspectral remote sensing in the colombian geology Aplicacões e de saftios do sensoriamento remoto hiperespectral na geologia colombiana," *Revista Facultad de Ingeniería (Fac. Ing.)*, vol. 24, no. 40, pp. 17–29, 2015.
- [13] S. Ozturk, Y. E. Esin, and Y. Artan, "Object Detection in Rural Areas using Hyperspectral Imaging," p. 96432M, Oct. 2015. [Online]. Available: <http://proceedings.spiedigitallibrary.org/proceeding.aspx?doi=10.1117/12.2195326>
- [14] A. Backhaus, F. Bollenbeck, and U. Seiffert, "Robust classification of the nutrition state in crop plants by hyperspectral imaging and artificial neural networks," in 2011 3rd Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing (WHISPERS). IEEE, Jun. 2011, pp. 1–4. [Online]. Available: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6080898>
- [15] S. M. Arafat, M. A. Aboelghar, and E. F. Ahmed, "Crop Discrimination Using Field Hyper Spectral Remotely Sensed Data," *Advances in Remote Sensing*, vol. 02, no. 02, pp. 63–70, 2013. [Online]. Available: <http://www.scirp.org/journal/PaperInformation.aspx?PaperID=32668&#abstract>
- [16] C. C. D. Lelong, J. M. Roger, S. Brégand, F. Dubertret, M. Lanore, N. a. Sitorus, D. a. Raharjo, and J. P. Caliman, "Evaluation of oil-palm fungal disease infestation with canopy hyperspectral reflectance data," *Sensors*, vol. 10, no. 1, pp. 734–747, 2010.
- [17] M. Golbabae, S. Arberet, and P. Vandergheynst, "Compressive Source Separation: Theory and Methods for Hyperspectral Imaging," *IEEE Transactions on Image Processing*, vol. 22, no. 12, pp. 5096–5110, Dec. 2013. [Online]. Available: <http://www.ncbi.nlm.nih.gov/pubmed/24043385> <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6595593>
- [18] A. Zare, J. Bolton, J. Chanussot, and P. Gader, "Foreword to the Special Issue on Hyperspectral Image and Signal Processing," *Selected Topics in Applied Earth Observations and Remote Sensing*, *IEEE Journal of*, vol. 7, no. 6, pp. 1841–1843, 2014. [Online]. Available: <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6870524>
- [19] E. Adam, O. Mutanga, and D. Rugege, "Multispectral and hyperspectral remote sensing for identification and mapping of wetland vegetation: A review," *Wetlands Ecology and Management*, vol. 18, no. 3, pp. 281–296, 2010. [Online]. Available: <http://www.springerlink.com/index/10.1007/s11273-009-9169-z>
- [20] R. G. Baraniuk, "Compressive sensing," *IEEE Signal Processing Magazine*, pp. 118–124, 2007.
- [21] H. Nyquist, "Certain topics in telegraph transmission theory," *American Institute of Electrical Engineers, Transactions of the*, vol. 47, pp. 617–644, 1928.
- [22] H. Morteza, "Reducing adc sampling rate with compressive sensing," *ArXiv Preprint arXiv:1503.00311*, pp. 1–8, 2015.
- [23] K. Hayashi, M. Nagahara, and T. Tanaka, "A user's guide to compressed sensing for communications systems," *IEICE Transactions on Communications*, vol. E96-B, no. 3, pp. 685–712, 2013.
- [24] G. R. Arce, D. J. Brady, L. Carin, H. Arguello, and D. S. Kittle, "Compressive Coded Aperture Spectral Imaging: An Introduction," *IEEE Signal Processing Magazine*, vol. 31, no. 1, pp. 105–115, Jan. 2014. [Online]. Available: <http://proceedings.spiedigitallibrary.org/proceeding.aspx?articleid=812490> <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6678264>
- [25] S. Foucart and H. Rauhut, *A Mathematical Introduction to Compressive Sensing*. New York: Springer, 2013.
- [26] D. L. Donoho, "Compressed sensing," *IEEE Transactions on Information Theory*, vol. 52, no. 4, pp. 1289–1306, 2006.
- [27] J. A. Tropp, "Greed is good: Algorithmic results for sparse approximation," *IEEE Transactions on Information Theory*, vol. 50, no. 10, 2004.
- [28] S. S. Chen, D. L. Donoho, and M. a. Saunders, "Atomic Decomposition by Basis Pursuit," *SIAM Journal on Scientific Computing*, vol. 20, no. 1, pp. 33–61, 1998.
- [28] Y. Chen, N. M. Nasrabadi, and T. D. Tran, "Hyperspectral Image Classification Using Dictionary- Based Sparse Representation," *IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING*, vol. 49, no. 10, 2, pp. 3973–3985, 2011.
- [29] K. Grochenig, *Foundations of time-frequency analysis*. Springer Science & Business Media, 2013.
- [30] F. Krahermer, D. Needell, and R. Ward, "COMPRESSIVE SENSING WITH REDUNDANT DICTIONARIES AND STRUCTURED MEASUREMENTS," pp. 1–21, 2015.
- [31] Q. Wei, J. Bioucas-Dias, N. Dobigeon, and J.-Y. Tourneret, "Hyperspectral and Multispectral Image Fusion Based on a Sparse Representation," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 53, no. 7, pp. 3658–3668, 2015.
- [32] M. Aharon, M. Elad, and A. Bruckstein, "K-SVD: An algorithm for designing overcomplete dictionaries for sparse representation," *IEEE Transactions on Signal Processing*, vol. 54, no. 11, pp. 4311–4322, 2006.
- [33] V. M. Patel and R. Chellappa, "Sparse Representations, Compressive Sensing and dictionaries for pattern recognition," *1st Asian Conference on Pattern Recognition, ACPR 2011*, no. 5, pp. 325–329, 2011.
- [34] Y. Sun, G. Gu, X. Sui, Y. Liu, and C. Yang, "Single image super-resolution using compressive sensing with a redundant dictionary," *IEEE Photonics Journal*, vol. 7, no. 2, pp. 1–1, 2015. [Online]. Available: http://www.ieee.org/publications_standards/publications/rights/index.html <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=7055220>
- [35] J. Cao, Y. Zhao, X. Lai, M. E. H. Ong, C. Yin, Z. X. Koh, and N. Liu, "Landmark recognition with sparse representation classification and extreme learning machine," *Journal of the Franklin Institute*, vol. 352, no. 10, pp. 4528–4545, Oct. 2015.
- [36] E. Candes and M. Wakin, "An Introduction To Compressive Sampling," *IEEE Signal Processing Magazine*, vol. 25, no. 2, 2008.
- [37] D. Manolakis, E. Truslow, M. Pieper, T. Cooley, and M. Brueggeman, "Detection Algorithms in Hyperspectral Imaging Systems: An Overview of Practical Algorithms," *Signal Processing Magazine, IEEE*, vol. 31, no. 1, pp. 24–33, 2014.
- [38] A. Ramirez, H. Arguello, G. R. Arce, and B. M. Sadler, "Spectral image classification from optimal coded-aperture compressive measurements," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 52, pp. 3299–3309, 2014.

- [39] H. Kwon and N. M. Nasrabadi, "A comparative analysis of kernel subspace target detectors for hyper-spectral imagery," *Eurasip Journal on Advances in Signal Processing*, vol. 2007, 2007.
- [40] F. Sierra-Pajuelo, A. Paz-Gallardo, and A. Plaza, "Performance Optimizations for an Automatic Target Generation Process in Hyperspectral Analysis," in *Architecture of Computing Systems. Proceedings. ARCS 2015-The 28th International Conference on*, 2015, pp. 1–6.
- [41] K. Bryan and T. Leise, "Making Do with Less: An Introduction to Compressed Sensing," *SIAM Review*, vol. 55, no. 3, pp. 547–566, 2013. [Online]. Available: <http://epubs.siam.org/doi/abs/10.1137/110837681>
- [42] H Arguello and G. R. Arce, "Code aperture optimization for spectrally agile compressive imaging." *Journal of the Optical Society of America. A, Optics, image science, and vision*, vol. 28, no. 11, pp. 2400–13, 2011. [Online]. Available: <http://josaa.osa.org/abstract.cfm?URI=josaa-28-11-2400>
- [43] H. Arguello and G. Arce, "Code aperture design for compressive spectral imaging," in *18th European Signal Processing Conference*, no. 1, 2010, pp. 1434–1438.
- [44] M. E. Gehm, R. John, D. J. Brady, R. M. Willett, and T. J. Schulz, "Single-shot compressive spectral imaging with a dual-disperser architecture." *Optics express*, vol. 15, no. 21, pp. 14 013–14027, 2007.
- [45] X. Lin, Y. Liu, J. Wu, and Q. Dai, "Spatial-spectral encoded compressive hyperspectral imaging," *ACM Trans. Graph.*, vol. 33, no. 6, pp. 233:1—233:11, 2014. [Online]. Available: <http://doi.acm.org/10.1145/2661229.2661262>
<http://doi.acm.org/10.1145/2661229.2661262>
- [46] C. Correa, H. Arguello, and G. Arce, "Compressive spectral imaging with colored-patterned detectors," in *ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings*, 2014, pp. 7789–7793. [Online]. Available: <http://www.scopus.com/inward/record.url?eid=2-s2.0-84905245176&partnerID=40&md5=31e2fa11f1dd23fa650b6676e8c13a1d>
- [47] G. Martin, J. M. Bioucas-Dias, and A. Plaza, "Hyca: A new technique for hyper-spectral compressive sensing," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 53, no. 5, pp. 2819–2831, 2015. [Online]. Available: <http://ieeexplore.ieee.org>
<http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=6964803>
- [49] M. A. T. Figueiredo, R. D. Nowak, and S. J. Wright, "Gradient projection for sparse reconstruction: Application to compressed sensing and other inverse problems," *IEEE Journal on Selected Topics in Signal Processing*, vol. 1, no. 4, pp. 586–597, 2007.
- [50] J. M. Bioucas-Dias and M. A. T. Figueiredo, "A new TwIST: Two-step iterative shrinkage/thresholding algorithms for image restoration," *IEEE Transactions on Image Processing*, vol. 16, no. 12, pp. 2992–3004, 2007.
- [51] S. J. Wright, R. D. Nowak, and M. A. T. Figueiredo, "Sparse reconstruction by separable approximation," *IEEE Transactions on Signal Processing*, vol. 57, no. 7, pp. 2479–2493, 2009.
- [52] A. N. Indiana's. (1992) Indiana's indian pines dataset. [Online]. Available: <https://engineering.purdue.edu/biehl/MultiSpec/hyperspectral.html>
- [53] Grupo de Inteligencia Computacional de la Universidad del País Vasco (UPV/EHU), "Hyperspectral Remote Sensing Scenes," 2014. [Online]. Available:[http://www.ehu.eus/ccwintco/index.php?title=Hyperspectral Remote Sensing Scenes](http://www.ehu.eus/ccwintco/index.php?title=Hyperspectral%20Remote%20Sensing%20Scenes)
- [54] M. A. Davenport, P. T. Boufounos, M. B. Wakin, and R. G. Baraniuk, "Signal processing with compressive measurements," *IEEE Journal on Selected Topics in Signal Processing*, vol. 4, no. 2, pp. 445–460, 2010.
- [55] D. Manolakis and G. Shaw, "Detection algorithms for hyperspectral imaging applications," *Signal Processing Magazine, IEEE*, vol. 19, no. 1, pp. 29–43, 2002.
- [56] W. Gross, J. Boehler, H. Schilling, W. Middelmann, J. Weyermann, P. Wellig, R. Oechslein, and M. Kneubuehler, "Assessment of target detection limits in hyperspectral data," K. U. Stein and R. H. M. A. Schleijsen, Eds., Oct. 2015, p. 96530J. [Online]. Available: <http://proceedings.spiedigitallibrary.org/proceeding.aspx?doi=10.1117/12.2192197>