

**MEJORAMIENTO DE LA CALIDAD DE IMÁGENES HIPERESPECTRALES
POR MÉTODOS DE SUPERRESOLUCIÓN**

MIGUEL ANGEL MARQUEZ CASTELLANOS

**UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FÍSICO-MECÁNICAS
ESCUELA DE INGENIERÍA DE SISTEMAS E INFORMÁTICA
BUCARAMANGA**

2015

**MEJORAMIENTO DE LA CALIDAD DE IMÁGENES HIPERESPECTRALES
POR MÉTODOS DE SUPERRESOLUCIÓN**

MIGUEL ANGEL MARQUEZ CASTELLANOS

**Trabajo de Grado para optar el título de
Ingeniero de Sistemas**

Director

HENRY ARGUELLO FUENTES

Ingeniero electricista, Ph.D.

Codirector

CÉSAR AUGUSTO VARGAS GARCÍA

Ingeniero de sistemas, Ph.D. (c).

UNIVERSIDAD INDUSTRIAL DE SANTANDER

FACULTAD DE INGENIERÍAS FÍSICO-MECÁNICAS

ESCUELA DE INGENIERÍA DE SISTEMAS E INFORMÁTICA

BUCARAMANGA

2015

AGRADECIMIENTOS

El autor expresa su agradecimiento:

Al profesor HENRY ARGUELLO FUENTES, director del proyecto por sus enseñanzas y acompañamiento; por ofrecerme la oportunidad de trabajar en este proyecto.

A CESAR AUGUSTO VARGAS GARCIA, codirector del proyecto por su guía, por sus recomendaciones y por su paciencia; por ser tanto mi tutor como mi amigo.

A Dios porque ha estado conmigo a cada paso que doy, cuidándome y dándome fortaleza para continuar.

A mi padre por su apoyo, amistad, consejos y amor; quien a lo largo de mi vida ha velado por mi bienestar y educación siendo mi apoyo en todo momento.

A mi madre por su amor, comprensión y soporte, en momentos importantes.

A mis abuelos, los cuales me han acompañado, cuidado y amado, dándole sentido y felicidad a mis días.

A mis hermanas, por ser la luz que alumbran mis días.

A todas las personas que han hecho parte de mi formación, brindándome su apoyo y cariño. A todos aquellos que han aportado a mi crecimiento como persona y profesional. A mis compañeros, amigos y profesores del colegio POLITECNICO y la UIS, gracias por brindarme su amistad y compartir conmigo tristezas y alegrías.

Tanto a mis padres y abuelos, agradezco que hayan depositado su entera confianza en cada reto que se me ha presentado, sin dudar en mis capacidades. Son ellos quienes me dan la fuerza espiritual que necesito para lograr mis metas.

MIGUEL ANGEL MARQUEZ CASTELLANOS

CONTENIDO

	pág.
INTRODUCCIÓN	12
1. CONCEPTOS BÁSICOS	15
1.1. ESPECTRO ELECTROMAGNÉTICO	15
1.2. IMÁGENES HIPERESPECTRALES	16
1.3. ESPECTRÓMETROS	18
1.4. SUPERRESOLUCIÓN (SR)	19
1.4.1. Superresolución por una sola imagen	20
1.4.2. Superresolución por múltiples imágenes	21
1.4.3. Superresolución por entrenamiento de diccionarios	22
1.4.4. Superresolución en imágenes hiperespectrales	23
2. METODOS TRADICIONALES DE SUPERRESOLUCIÓN	25
2.1. SUPERRESOLUCIÓN POR SIMILITUD ENTRE VECINOS LOCALES (NLM)	25
2.1.1. Filtro NLM para la eliminación de ruido	26
2.1.2. NLM por minimización de energía	28
2.1.3. Método de superresolución NLM	29
2.1.4. Seudocódigo NLM	31
2.2. REGRESIÓN DE NÚCLEOS DE DIRECCIÓN (STEERING KERNEL REGRESSION -SKR)	34
2.2.1. Datos adaptados a los núcleos de regresión	34
2.2.2. Seudocódigo SKR	39
3. MÉTODO DE SUPERRESOLUCIÓN PROPUESTO	41
3.1. PLANTEAMIENTO MATEMÁTICO	41
3.2. ALGORITMO PROPUESTO DE SR PARA HSI	46
4. SIMULACIONES Y RESULTADOS	48
4.1. PARÁMETROS EXPERIMENTALES	49
4.2. RESULTADOS	49
4.2.1. Resultados cualitativos	52
4.2.2. Resultados cuantitativos	56
5. CONCLUSIONES	59
6. RECOMENDACIONES	60
CITAS BIBLIOGRAFICAS	61
BIBLIOGRAFIA	64

LISTA DE TABLAS

	pág.
Tabla 1: Algoritmo de superresolución NLM.	33
Tabla 2: Algoritmo de superresolución SKR.	40
Tabla 3: Algoritmo de superresolución propuesto.	47
Tabla 4: Resultados PSNR.	57

LISTA DE FIGURAS

	pág.
Figura 1: Representación de la longitud de onda.	15
Figura 2: Esquema de una imagen hiperespectral.	16
Figura 3: Esquema elementos del espectrómetro.	18
Figura 4: Ejemplo imagen de baja y alta resolución.	19
Figura 5: Superresolución por una sola imagen.	21
Figura 6: Superresolución por múltiples imágenes.	22
Figura 7: Superresolución por diccionarios.	23
Figura 8: Ejemplo de una estructura local.	27
Figura 9: Efecto relleno cero en el espacio.	29
Figura 10: Estructuras locales de baja y alta resolución.	30
Figura 11: Estructura núcleos SKR.	35
Figura 12: Efecto matrices de orientación SKR.	37
Figura 13: Matriz de reducción espacio-espectral.	41
Figura 14: Matriz tridimensional de desenfoque Gaussiano.	42
Figura 15: Efecto relleno cero en el espectro.	43
Figura 16: Matriz de reducción espacial para HSI's.	44
Figura 17: Esquema de aumento espectral de una HSI de LR.	45
Figura 18: Imagen hiperespectral Legos.	50
Figura 19: Imagen hiperespectral de la ciudad de Ribeira.	51
Figura 20: Representación firmas espectrales.	51
Figura 21: Reconstrucción bandas espectrales Legos.	53
Figura 22: Reconstrucción fragmentos de la HSI' Legos.	54
Figura 23: Reconstrucción fragmentos de la HSI de Ribeira.	55
Figura 24: Tiempos CPU.	58

RESUMEN

TÍTULO: MEJORAMIENTO DE LA CALIDAD DE IMÁGENES HIPERESPECTRALES POR MÉTODOS DE SUPER-RESOLUCIÓN*

AUTOR: Miguel Angel Marquez Castellanos **

PALABRAS Imagen hiperespectral; dimensión espacial-espectral;

CLAVE: interpolación tridimensional; muestreo hiperespectral.

DESCRIPCIÓN

Las imágenes hiperespectrales (HSI) son una concatenación de imágenes bidimensionales que toman diferentes longitudes de onda y proporcionan información de gran importancia en aplicaciones aéreas, espaciales, detección de objetos, agricultura y exploración de recursos naturales. En todas estas aplicaciones es primordial obtener la máxima resolución posible, tanto a nivel espacial como espectral. Una forma de conseguir HSI de alta resolución (HR) es mediante la implementación de espectrómetros hiperespectrales. Las desventajas de esta solución son el aumento exponencial en los costos de adquisición relacionados con el detector y el ruido inherente en las imágenes, generado por diferentes factores como: lentes, atmosfera, iluminaciones secundarias, imperfecciones ópticas, etc. Por otro lado, los detectores son proporcionales al tamaño de la imagen deseada y no es posible construir cámaras de resolución arbitraria.

Una alternativa para aumentar la resolución de las HSI es implementando técnicas de superresolución (SR), las cuales se basan en la recuperación de una HSI de HR a partir de una versión de baja resolución. Una de las principales deficiencias de los métodos tradicionales de SR en imágenes hiperespectrales, es la restauración de la imagen hiperespectral como un conjunto de imágenes bidimensionales no relacionadas, ignorando información inherente en las bandas espectrales adyacentes que son esenciales para una óptima reconstrucción.

En este trabajo se propone un método rápido y eficiente para la reconstrucción de HSI, mediante el uso de matrices de reducción espacio-espectral e interpolaciones cúbicas recurrentes. El método propuesto supera la implementación tradicional de las técnicas de SR, mediante el uso de la información concurrente en el vecindario de espectros adyacentes. Las simulaciones muestran que el método desarrollado supera los métodos tradicionales de SR para HSI existentes en la literatura. Específicamente se obtienen mayores niveles de relación señal a ruido pico (PSNR), tanto en la dimensión espectral como en la espacial.

* Proyecto de grado

** Facultad de Ingenierías Físico – Mecánicas. Escuela de Ingeniería de Sistemas e Informática.

Director: Henry Arguello Fuentes

ABSTRACT

TITLE: QUALITY IMPROVEMENTS OF HYPERSPECTRAL IMAGING VIA SUPER-RESOLUTION METHODS*

AUTHORS: Miguel Angel Marquez Castellanos**

KEYWORDS: Hyperspectral imaging; spatial-spectral dimension; three-dimensional interpolation; hyperspectral downsampling.

DESCRIPTION:

Hyperspectral images (HSI) are concatenation of two-dimensional images that entails different wavelengths. It provides information of vital importance in applications such as: aerial, space imagery, remote sensing, agricultural, and natural resource exploration. In all these applications, is important obtain the highest resolution in the spatial and spectral dimension. One way to achieve high-resolution hyperspectral imaging is using hyperspectral spectrometers. However, this solution have two important disadvantages: 1) the exponentially increased by production cost related with the detector, and 2) the inherent noise in images generated various factors such as atmospheric scattering, imperfect imaging optics, secondary illumination, changing viewing angles, and sensor noise. Furthermore, the detector is proportional to the size of the desired image and it is impractical to construct arbitrary resolution cameras.

An alternative to increase the resolution of the HSI's is implementing super-resolution methods (SR), which are based on recover a HR-HSI from a low-resolution version. One of the main shortcomings of traditional methods of SR in hyperspectral image is the restoration of the hyperspectral image as a set of two-dimensional images doesn't relate. This paper presents a fast and efficient method for the reconstruction of HSI, using spatial-spectral matrices and three-dimensional interpolations. The method outperforms the traditional implementation of SR techniques, using concurrent information in the neighborhood of adjacent spectra. Simulations show that the developed method outperforms the traditional methods of SR for HSI in the literature. Specifically higher levels of peak signal to noise ratio (PSNR) are obtained in both the spectral and spatial dimension.

* Research degree Project.

** Faculty of Physical-Mechanical Engineering. School Systems Engineering and Computer Science. Director: Henry Arguello Fuentes.

INTRODUCCIÓN

Cualquier objeto físico en una escena refleja, adsorbe y emite radiación electromagnética de acuerdo a su composición molecular. Tradicionalmente, la luz del sol es utilizada para identificar cualquier material. Esta detección es realizada en función de la energía contenida a lo largo de la longitud de onda en un determinado rango espectral [22]. La fracción de radiación indecente reflejada por una superficie (reflectancia) permite obtener información espectral y espacial de un objeto sin tener contacto físico con él, utilizando la técnica de adquisición llamada teledetección (remote sensing) [1]. En términos generales, la teledetección se refiere a la implementación de sensores que recopilan información espacial y espectral. Este tipo de dato se conoce como imagen hiperespectral (HSI) y es comúnmente representado como un cubo de datos [2].

Las HSI están compuestas por un conjunto de imágenes bidimensionales que contienen información de diferentes longitudes de onda en un cierto rango espectral. Las HSI están organizadas en un conjunto de bandas bidimensionales concatenadas que representan la distribución espacial de una escena. Los píxeles hiperespectrales en las HSI están constituidos por vectores que contienen todos los píxeles situados en la misma ubicación espacial. Los datos contenidos en estos vectores corresponden a la intensidad de luz en diferentes bandas espectrales [6]. Si se grafica la firma espectral de un píxel hiperespectral en función de la longitud de onda, el resultado es el promedio espectral de todos los materiales contenidos. En contraste, los valores de todos los píxeles contenidos en la misma banda espectral representan la distribución espacial de la reflectancia de una escena en su correspondiente longitud de onda.

Las imágenes hiperespectrales han tenido un gran impacto en aplicaciones civiles y militares que involucran la identificación de materiales, detección de anomalías, y sensado remoto [21]-[24]. Por lo tanto, las HSI han sido utilizados en una gama de aplicaciones de gran alcance, tales como la teledetección, imágenes espaciales, exploración de recursos naturales, detección y exploración de minerales, clasificación de terrenos, farmacéutica, y la vigilancia militar [3]-[9]. En todas estas aplicaciones es de vital importancia obtener la más alta resolución en la dimensión espacial y espectral.

Tradicionalmente los espectrómetros son implementados para capturar HSI. Los cuales proporcionan un conjunto de imágenes bidimensionales que contienen información sobre una amplia gama del espectro electromagnético (rango visible e infrarrojo cercano) [10]-[12]. Las técnicas convencionales para la captura de imágenes espectrales son el pushbroom y whiskbroom [27]. Estas técnicas de captura realizan un barrido espacial de toda la escena en función de su dimensión espectral; seguidamente capturan los datos en las dimensiones restantes para formar el cubo de datos. En particular, un sensor pushbroom captura la escena línea por línea, mientras que un sensor whiskbroom lo hace pixel por pixel. Las desventajas de estas técnicas son el tiempo de sensado, los costos de adquisición relacionados con el detector y los ruidos generados por diferentes fenómenos físicos como: la atmosfera, el movimiento de la cámara, el desenfoque de los lentes o iluminaciones secundarias. El uso de técnicas de mejoramiento de resolución por post-procesamiento ha atraído la atención de los investigadores como una mejor alternativa.

Actualmente los métodos de superresolución son técnicas post-procesamiento que permiten mejorar la resolución espacial de imágenes de baja resolución [13]-[16]. Siendo esta un área de investigación muy activa, debido a que permiten la implementación de sensores de bajo costo en los espectrómetros

hiperespectrales. Las técnicas tradicionales de superresolución se encuentran clasificadas en: superresolución basado en una sola imagen [14], en múltiples imágenes [18] y en entrenamiento de diccionarios [25]. Sin embargo, los métodos tradicionales de superresolución restauran las imágenes hiperespectrales como un conjunto de imágenes bidimensionales no relacionadas. Generando que se ignore información espectral de vital importancia para una reconstrucción óptima de las bandas espectrales [19]-[20].

El presente proyecto de grado propone un algoritmo para la reconstrucción de imágenes hiperespectrales de baja resolución, basándose en métodos tradicionales de superresolución de una sola imagen [13], [14], [18], [19]. En el capítulo 1 se introducen conceptos fundamentales que permiten el desarrollo del proyecto de grado. En el capítulo 2 se presentan dos modelos tradicionales de superresolución. En el capítulo 3 se muestra el proceso de diseño del algoritmo de superresolución para imágenes hiperespectrales. En el capítulo 4 se exponen simulaciones y resultados obtenidos.

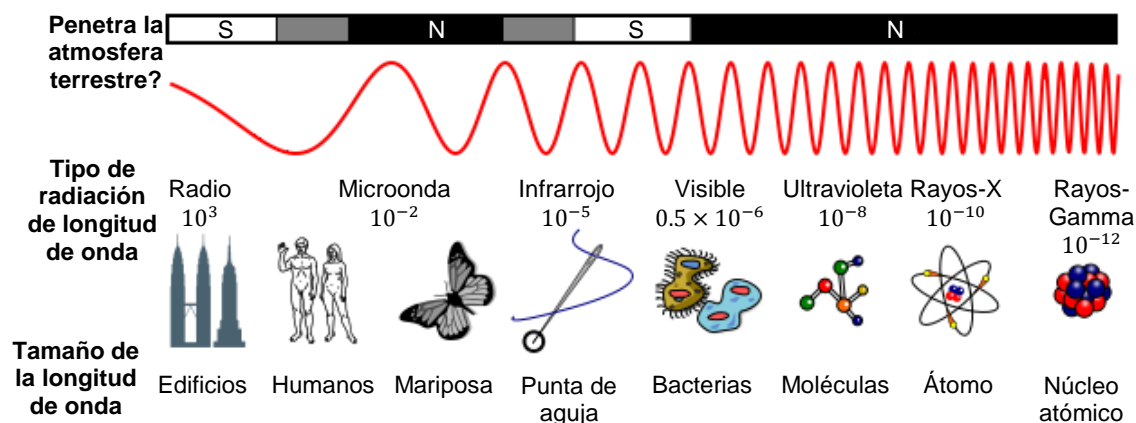
1. CONCEPTOS BÁSICOS

1.1. ESPECTRO ELECTROMAGNÉTICO

A partir de las relaciones encontradas por Faraday entre la luz, el magnetismo y la electricidad. Maxwell probó que el comportamiento de la electricidad y el magnetismo son parte de una sola interacción electromagnética. Esta interacción es representada como la vibración de los campos eléctricos y magnéticos. Generando ondas electromagnéticas las cuales se caracterizan por propagarse en el vacío con una rapidez igual a la de la luz y ser doblemente transversales. Una propiedad básica de las ondas electromagnéticas es su longitud de onda (Fig.1), la cual es definida como la distancia entre crestas o depresiones consecutivas de las ondas.

La luz es una mezcla de ondas electromagnéticas que al pasar a través de un prisma, se descompone en longitudes de onda o colores que la integra. Cuando la luz choca contra un objeto, diferentes materiales del objeto reflejan ciertas longitudes de onda más fuertes que otros, dando a cada material un patrón de color característico de su composición molecular [11]. Este patrón de colores representa la firma espectral de dicho material y permite su detección y

Figura1: Representación la longitud de onda




Fuente:[en línea] <http://www.revista.unam.mx/vol.10/num10/art61/imagenes/fig1a.jpg>

clasificación. Al capturar y almacenar todas las firmas espectrales que componen una escena se genera una imagen hiperespectral.

1.2. IMÁGENES HIPERESPECTRALES

Las imágenes hiperespectrales (HSI) son un conjunto de imágenes bidimensionales que contienen información espectral de un determinado rango de la longitud de onda [1], [26]. Cada pixel de una imagen hiperespectral contiene intensidades de luz (fotón de luz) de una escena a lo largo del espectro electromagnético, proporcionando una cantidad más detallada de información que las imágenes tradicionales RGB. Los píxeles hiperespectrales en las HSI están constituidos por vectores que contienen todos los píxeles situados en la misma ubicación espacial. Las entradas de estos vectores corresponden a la intensidad de luz en diferentes bandas espectrales [6]. Si se grafica la firma espectral de un pixel hiperespectral en función de la longitud de onda, el resultado es el promedio espectral de todos los materiales contenidos como se muestra en la Figura.1(a). En contraste, los valores de todos los píxeles contenidos en la misma banda espectral representan la distribución espacial de la reflectancia de una escena en su correspondiente longitud de onda. Por lo tanto, las HSI permiten clasificar y caracterizar objetos de una escena basándose en sus propiedades espectrales [5]-[9]. Matemáticamente se define a las HSI como $Y \in R^{N \times M \times L}$ donde NM representa la dimensión

Figura 2: Ejemplo de una imagen hiperespectral y su respectivo esquema tridimensional.



espacial y L es la profundidad espectral (Fig.1).

El conjunto de datos hiperespectrales contienen tres puntos de vista en términos de un esquema de representación de datos o un espacio de representación:

- a. Dimensión espacial: La resolución de muestreo espacial se presenta en las muestras como datos que se relacionan en sentido geométrico, o más correctamente, geográfico. Un uso clave de las imágenes en el procesamiento multiespectral es servir como un medio para el analista para asociar puntos de datos multiespectrales (píxeles) con lugares específicos (punto) en la escena.
- b. Dimensión espectral: Los píxeles en las imágenes hiperespectrales contienen datos en función de la longitud de onda como un aspecto portador de información y están representados por vectores cuyas entradas corresponden a la intensidad en diferentes bandas espectrales. La información contenida en la longitud de onda tiene la característica de que es a menudo directamente interpretable y permite identificar el contenido de un píxel individual. Esto proporciona una simplicidad fundamental que es importante desde el punto de vista de complejidad computacional.
- c. Dimensión temporal: Corresponde a la colección de múltiples imágenes hiperespectrales de una misma escena a través del tiempo. Esto es un importante mecanismo de estudio para detectar los cambios físicos en una escena.

Para la captura de imágenes hiperespectrales es necesario realizar un barrido de la escena a lo largo del espectro electromagnético. Este proceso es realizado por espectrómetros, los cuales capturan un número finito de bandas


espectrales. Las cuales contienen aspectos importantes de un objeto y permiten su clasificación.

1.3. ESPECTRÓMETROS

Los espectrómetros son actualmente implementados en diversas aplicaciones civiles o militares, con el fin de identificar las firmas espectrales de una amplia gama de materiales en el espectro electromagnético. Tradicionalmente, la luz del sol es utilizada para identificar cualquier material en función de la energía contenida a lo largo de la longitud de onda en un determinado rango espectral. La implementación de dispersores ópticos (prismas o rejillas) en los espectrómetros permiten dividir la luz en múltiples bandas de la longitud de onda y la energía contenida en cada banda es censada por un único detector. El uso de cientos o incluso miles de detectores permite a los espectrómetros realizar mediciones de bandas espectrales con una precisión de $0,01[\mu m]$.

Hasta hace poco las cámaras estaban restringidas a la captura de un conjunto muy pequeño de bandas espectrales por restricciones de los detectores, requisitos de almacenamiento y procesamiento de datos. Recientes avances en estas áreas han permitido el diseño de cámaras CCD que tienen rangos y resoluciones espectrales que permiten detectar la mayor variedad de objetos con un alto rendimiento [36]. Sin embargo, la captura de HSI de HR aumenta

Figura 3: Diagrama esquemático de los elementos básicos de un espectrómetro



Fuente:[en línea] http://chemwiki.ucdavis.edu/Physical_Chemistry/Kinetics/Reaction_Rates/


exponencialmente los costos de implementación. Por lo tanto los investigadores han puesto su atención en una familia de métodos de post-procesamiento de imágenes, la superresolución.

1.4. SUPERRESOLUCIÓN (SR)

La superresolución es un término utilizado para describir un conjunto de técnicas orientadas al mejoramiento de la calidad de una imagen. El problema de superresolución consiste en recuperar una imagen de alta resolución $X \in \mathbb{R}^{s_1 N \times s_2 M}$ (Figura 1.b) a partir de una versión baja resolución $Y \in \mathbb{R}^{N \times M}$ (Figura 1.a). Donde $N \times M$ representa la dimensión espacial de la imagen y $s_1, s_2 \in \mathbb{R}$ son los factores de superresolución en la dimensión N y M , respectivamente. Matemáticamente se consideran a las imágenes de baja resolución como el resultado del muestreo de una imagen de alta resolución:

$$y = \mathbf{D}\mathbf{H}x + \varepsilon, \quad (1)$$

Figura 4: Imagen de baja resolución y alta resolución



Fuente:[en línea] http://people.irisa.fr/Olivier.Le_Meur/publi/2014_ICIP_Julio/

donde y y x representan las imágenes bidimensionales de baja y de alta resolución, respectivamente. \mathbf{H} es la matriz de ruido espacial y \mathbf{D} es la matriz de reducción espacial. Para realizar el proceso de reconstrucción, se plantea un problema de mínimos cuadrados

$$\hat{x} = \arg \min_x \|y - \mathbf{D}\mathbf{H}x\|_2^2, \quad (2)$$

la solución de la ecuación 2 es dada por

$$\hat{x} = \mathbf{H}^T \mathbf{D}^T (\mathbf{D}\mathbf{H}\mathbf{H}^T \mathbf{D}^T)^{-1} y. \quad (3)$$

Sin embargo, este método conduce a una reconstrucción de imágenes de baja calidad. Para aumentar la calidad, varios métodos de superresolución incorporan un término de regularización en el proceso de reconstrucción con el fin de mejorar la calidad de la imagen obtenida en la ecuación 3. Por consiguiente la ecuación 3 puede ser reformulada como


$$\hat{x} = \arg \min_x \|y - \mathbf{D}\mathbf{H}x\|_2^2 + \mu F(x), \quad (4)$$

donde $F(x)$ es el término de regularización y μ es el parámetro que regula el error de reconstrucción. Las técnicas de superresolución se pueden clasificar en tres familias de métodos: (i) SR basada en estructuras locales que aprovechan la redundancia de información, (ii) SR basada en la combinación y procesamiento de varias imágenes de LR y (iii) SR basada en el entrenamiento de diccionarios (Machine Learning -ML).

1.4.1. Superresolución por una sola imagen: Los métodos de superresolución por una sola imagen, se basan en la reconstrucción de imágenes de baja resolución mediante el uso de estructuras locales (Fig.5). Esta familia de métodos se basa en la hipótesis de que las imágenes están compuestas por la intersección de conjuntos de estructuras locales. Las estructuras locales están formadas por un pixel central y sus pixeles adyacentes; los cuales contienen redundancia de información que permite la restauración de la imagen.

Esta familia de métodos es implementada en diversas aplicaciones militares y civiles. Ya que no es fácil obtener más de una de imagen de una misma escena. Estas estructuras locales se estudiarán más a fondo en la sección 2.

Figura 5: Representación esquemática que ilustra el proceso de superresolución con una sola imagen.

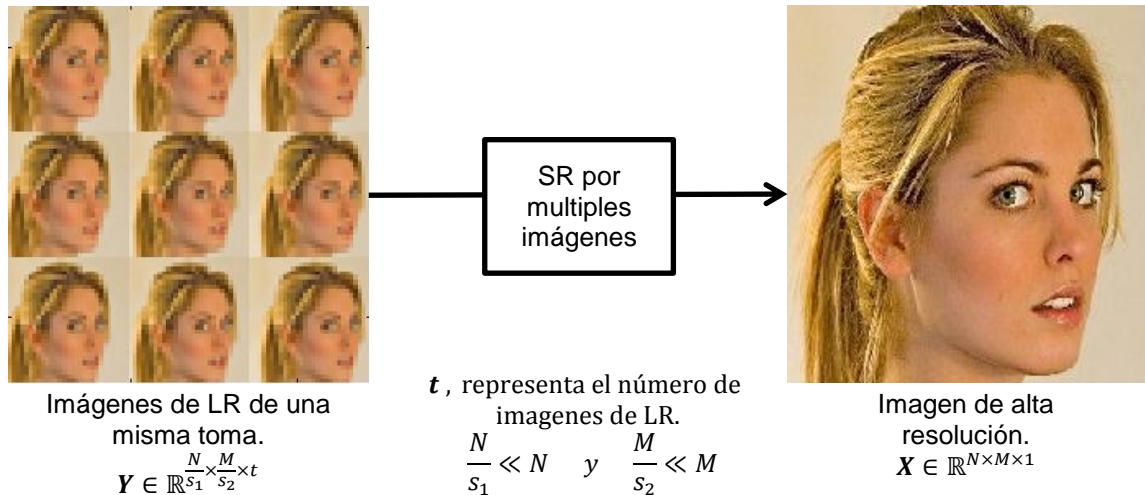


Fuente:[en línea] <http://www.intechopen.com/source/html/38300/media/image6.jpeg>

1.4.2. Superresolución por múltiples imágenes: Los métodos de superresolución por múltiples imágenes se basan en la reconstrucción de imágenes de baja resolución mediante el uso de un conjunto de imágenes de LR (Fig.6). Estas imágenes de baja resolución tienen desalineación de sub-píxeles y se derivan de una misma escena. Esta familia de métodos se basa en la hipótesis de que las imágenes contienen detalles perdidos de alta frecuencia; los cuales son recuperados mediante la implementación de filtros tridimensionales. Los filtros tridimensionales procesan la información contenida en las estructuras locales de las múltiples imágenes de LR (las cuales son adyacentes a la estructura local principal).

Sin embargo, en las aplicaciones prácticas no es fácil obtener un número adecuado de imágenes de una misma escena. La noción de filtro tridimensional es retomada en la sección 3, para la implementación de método propuesto.

Figura 6: Representación esquemática que ilustra el proceso de superresolución por múltiples imágenes.



Fuente:[en línea] <http://cyber.felk.cvut.cz/teaching/dpext/detail.phtml?id=1735&l=>

1.4.3. Superresolución por entrenamiento de diccionarios: Los métodos de superresolución por aprendizaje de diccionarios se basan en la reconstrucción de imágenes de baja resolución mediante la sustitución de estructuras locales. Esta sustitución se basa en la hipótesis de que para cada estructura local de baja resolución tiene una versión de alta resolución. Estas versiones de alta resolución son extraídas de una base de datos de imágenes de HR. A partir de las estructuras de HR extraídas, se generan sus respectivas versiones de LR. El proceso de extracción, creación y almacenamiento de las estructuras locales de HR y LR se le conoce como entrenamiento de diccionario. Las estructuras de LR sintéticas son implementadas para buscar estructuras similares en la imagen de baja resolución. Seguidamente las estructuras similares son reemplazadas por su versión de HR contenida en el diccionario.

Una de las desventajas fundamentales de este método, es el entrenamiento de diccionarios para un tipo específico de escena. La implementación de un diccionario no proporciona los mismos resultados en todas las imágenes. Por lo tanto, cada conjunto de escenas similares tiene una base de datos de imágenes de alta resolución. Este proceso es representado en la figura 7.

1.4.4. **Superresolución en imágenes hiperespectrales:** En el enfoque convencional, las HSI de LR se dividen en imágenes bidimensionales de LR y su reconstrucción es considerada como un sub-problema de superresolución de imágenes independientes.

Figura 7: Representación esquemática del proceso de superresolución por entrenamiento de diccionarios.



Fuente:[en línea] https://users.soe.ucsc.edu/~priyam/publi_img/local_global_sr.jpg

Siendo $\mathbf{X}_k \in \mathbb{R}^{s_1 N \times s_2 M}$, $k = 1, \dots, s_3 L$ y $\mathbf{Y}_j \in \mathbb{R}^{N \times M}$, $j = 1, \dots, L$ las imágenes hiperespectrales de alta y baja resolución, respectivamente. También se representa $\mathbf{x}_k \in \mathbb{R}^{s_1 s_2 NM \times 1}$ y $\mathbf{y}_j \in \mathbb{R}^{NM \times 1}$ como la versión vectorial individual de las bandas espectrales de alta y baja resolución, respectivamente. L representa la resolución espectral y $s_3 \in \mathbb{R}$ es el factor de superresolución en la dimensión espectral. El enfoque tradicional de superresolución en imágenes hiperespectrales consiste en resolver el conjunto de ecuaciones

$$\mathbf{y}_j = \mathbf{D}\mathbf{H}\mathbf{x}_j + \boldsymbol{\varepsilon}, \quad j = 1, \dots, L, \quad (5)$$

usando métodos como regresión del núcleo de direcciones (steering kernel regression -SKR) o similitud entre vecinos locales (non local means -NLM),

para obtener una versión de HR de cada banda espectral j . Las bandas restantes $s_3L - L$ son interpoladas usando un interpolador cúbico. Estos métodos ignoran la información espectral la cual es un parámetro decisivo para obtener una óptima reconstrucción. Por lo tanto se consideran a los métodos tradicionales de superresolución para imágenes hiperespectrales como un problema mal planteado.

2. METODOS TRADICIONALES DE SUPERRESOLUCIÓN

2.1. SUPERRESOLUCIÓN POR SIMILITUD ENTRE VECINOS LOCALES (NLM)

El método NLM fue propuesto intuitivamente como una técnica de eliminación de ruido que se destaca por ser simple y eficaz para la restauración de imágenes. Este método se basa en la implementación de estructuras adyacentes que tienen como núcleo un conjunto de píxeles localizados en diferentes ubicaciones de la imagen. Estas estructuras son utilizadas como múltiples observaciones que permiten la restauración. La eliminación de ruido en imágenes por el método NLM se obtiene mediante la sustitución de todos los píxeles por un promedio ponderado del píxel cuyo valor está siendo determinado.

Por su simplicidad y eficacia, se han realizado diferentes trabajos para implementación del filtro NLM en métodos de superresolución. Este método conduce a un aumento de escala de la imagen usando una interpolación Lanczos [31]-[32], seguido por el procesamiento de NLM. Sin embargo extensos experimentos indican que este método intuitivo no proporciona resultados de superresolución. Por esta razón, una profunda comprensión del filtro NLM es requerida para la obtención de un método de superresolución exitoso.

Con el fin de obtener una mejor comprensión del método SR por NLM, se propone redefinirlo como un problema de minimización que implementa una función de penalización.

2.1.1. Filtro NLM para la eliminación de ruido: El filtro NLM es una efectiva técnica para la eliminación de ruido. El cual se basa en la suposición de que una imagen puede ser representada por la intercepción de varias estructuras locales (vecindarios). Estas estructuras contienen un conjunto de píxeles adyacentes a un núcleo (píxel central). Por lo tanto la eliminación de ruido de cada píxel es realizado por la asignación de pesos a cada píxel adyacente del píxel a restaurar. Donde cada peso refleja la probabilidad de que este píxel y el píxel a restaurar tuvieran el mismo valor antes de la degradación de ruido adictivo. Aunque no tiene el mejor rendimiento en la eliminación, este método es muy simple de entender y poner en práctica. Una fórmula que describe este filtro es

$$\hat{x}[k, l] = \frac{\sum_{(i,j) \in N(k,l)} w[k, l, i, j] y[i, j]}{\sum_{(i,j) \in N(k,l)} w[k, l, i, j]}, \quad (6)$$

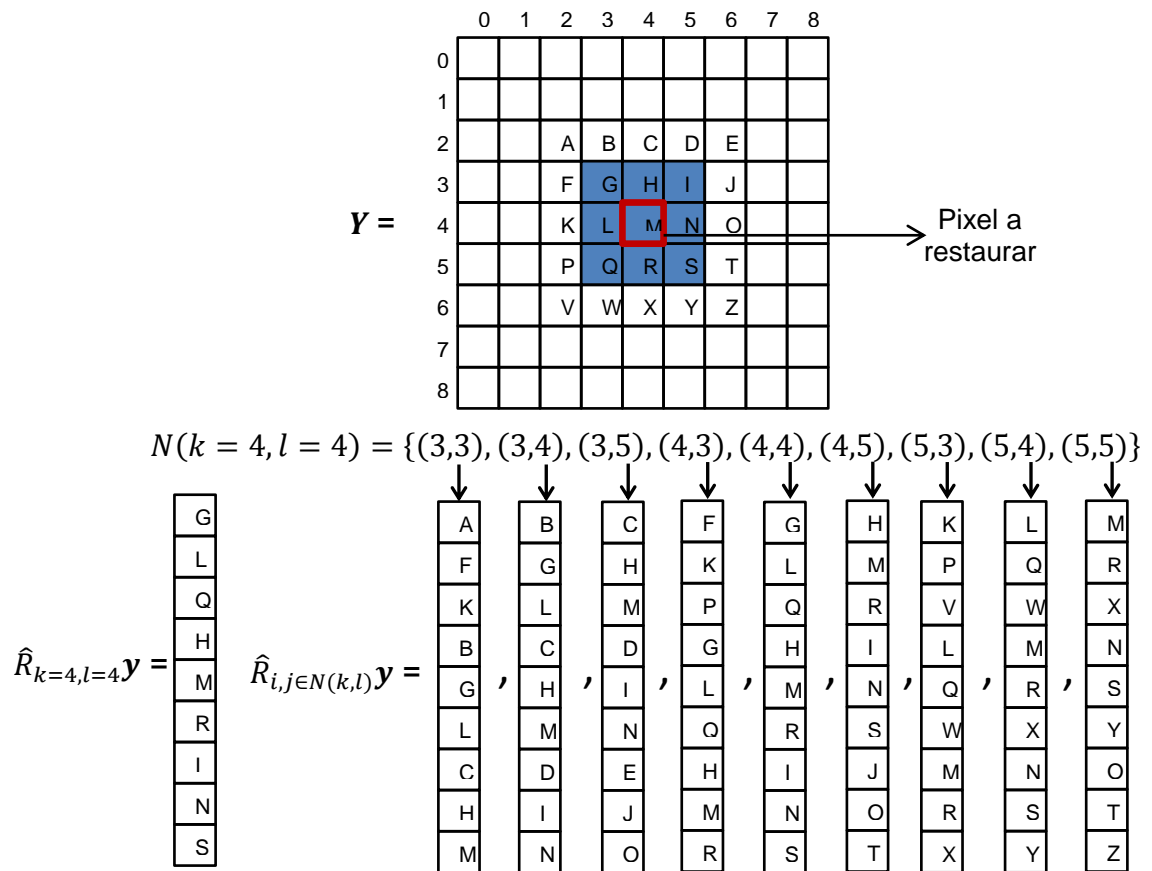
donde $y[i, j]$ es la imagen con ruido, $N(k, l)$ representa el vecindario del píxel $y[k, l]$, $w[k, l, i, j]$ representa el peso del píxel $[i, j]$ en el vecindario y $\hat{x}[i, j]$ representa la imagen restaurada. El concepto de estructuras locales es representado en la figura 8.

Los pesos en el filtro NLM son calculados mediante la distancia euclidiana entre dos estructuras locales de una imagen centrada en torno a los dos píxeles implicados. Se define a $\hat{R}_{k,l}$ como un operador que extrae un conjunto píxeles de tamaño predeterminado ($q \times q$) de una imagen (en su representación vectorial), la expresión $\hat{R}_{k,l}y$ da como resultado un vector de tamaño q^2 que representa el parche extraído. Matemáticamente, se define a la función de pesos como

$$w[k, l, i, j] = e^{\left\{ \frac{\|\hat{R}_{k,l}y - \hat{R}_{i,j}y\|^2}{2\sigma^2} \right\}} f\left(\sqrt{(k-i)^2 + (l-j)^2}\right). \quad (7)$$

Existen diferentes maneras de elegir una función de pesos $w[k,l,i,j]$ y las implementadas anteriormente (distancias radiométricas y euclidianas) son solo una opción. Por ejemplo, el filtro de núcleos de dirección (steering kernel), tiene en cuenta la correlación entre las posiciones de pixel y su valor. Este tipo de filtros es estudiado detalladamente en la sección 2.2.

Figura 8: Ejemplo de una estructura local con centro en el pixel $y(k = 4, l = 4)$ y de tamaño $q = 3 (3 \times 3)$.



Todos los pixeles contenidos en la estructura local de la Figura.8 son representados por la función $N(k,l)$, la cual permite al factor $\hat{R}_{i,j \in N(k,l)} \mathbf{y}$ obtener todas las estructuras locales contenidas en la estructura local principal. Este conjunto de estructuras locales son implementados para la restauración del pixel principal, el cual se encuentra representado por los bordes rojos.

2.1.2. NLM por minimización de energía: El filtro NLM fue presentado intuitivamente como una formula algorítmica (ecuación 5). Este filtro puede ser derivado por la minimización de una función de penalización adecuadamente definida. Siguiendo la lógica y los pasos dados en [28] y [29], se presenta una función de dicha penalización. Esto será útil cuando se toma el siguiente paso de la generalización de estos métodos a un algoritmo de reconstrucción de superresolución, como se muestra en secciones posteriores.

La función de penalización con la cual se empieza refleja dos características importantes: 1) la proximidad entra la imagen reconstruida y las de entrada; y 2) cada estructura local resultante en la imagen tenga similitudes a otras estructuras locales en sus cercanías. Sin embargo, no se espera que todos los pixeles contenidos en el conjunto de estructuras locales adyacentes aporten información vital para la restauración. Por lo tanto se le asigna a cada pixel de las estructuras locales un peso que representa su similitud a la estructura local principal. Al unir estas dos características, se plantea una máxima probabilidad a posteriori (MAP) de la forma

$$\epsilon^2(\mathbf{x}) = \frac{1}{2} \sum_{(k,l) \in \Omega} \sum_{(i,j) \in N(k,l)} w[k, l, i, j] \|R_{k,l}\mathbf{x} - R_{i,j}\mathbf{y}\|_2^2, \quad (8)$$

donde \mathbf{x} y \mathbf{y} son la representación vectorial de X y Y , respectivamente. Ω representa todos los pixeles contenidos en la imagen a restaurar. Al obtener el término de minimización, se derivar en función de X , para obtener

$$\frac{\partial \epsilon^2(\mathbf{x})}{\partial \mathbf{x}} = 0 = \sum_{(k,l) \in \Omega} \sum_{(i,j) \in N(k,l)} w[k, l, i, j] R_{k,l}^T \times (R_{k,l}\mathbf{x} - R_{i,j}\mathbf{y}). \quad (9)$$

Despejando la constante X y se obtiene

$$\hat{\mathbf{x}} = \left(\sum_{(k,l) \in \Omega} \bar{w}[k, l] R_{k,l}^T R_{k,l} \right)^{-1} \left(\sum_{(k,l)} R_{k,l}^T \sum_{(i,j) \in N(k,l)} w[k, l, i, j] R_{i,j}\mathbf{y} \right). \quad (10)$$

La ecuación 10 se alinea perfectamente con el filtro NLM descrito en la ecuación 5, por lo cual se obtiene

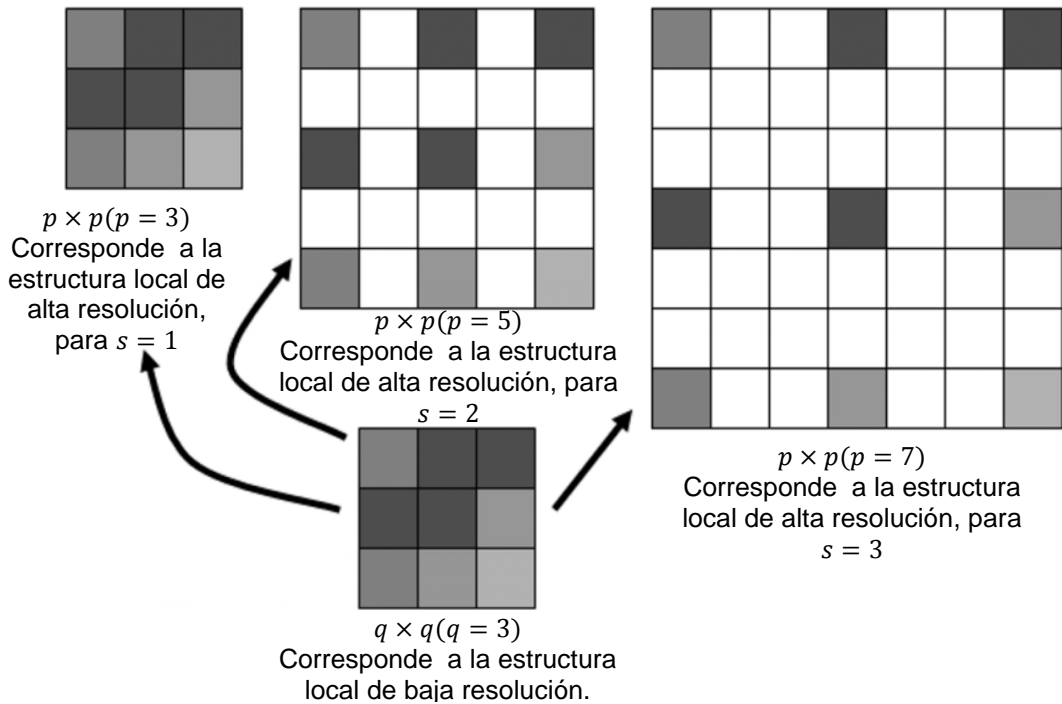
$$\hat{x}[k, l] = \frac{\sum_{(i,j) \in N(k,l)} w[k, l, i, j] y[i, j]}{\sum_{(i,j) \in N(k,l)} w[k, l, i, j]} \quad (11)$$

(12)

2.1.3. Método de superresolución NLM: El desarrollo de este método se basa en la implementación de un método de penalización y minimización adecuado. Para obtener un óptimo método de superresolución, se divide el problema en dos partes – la primera es la eliminación de ruido de la imagen de entrada y el segundo es el aumento de escala y la eliminación de ruido de la imagen resultante. Dado que se pretende explotar el conocimiento adquirido en secciones anteriores, se define una función inicial de penalización basada en la ecuación 4 y 5

$$Z[k, l] = \sum_{(k,l) \in \Omega} \sum_{(i,j) \in N^L(k,l)} w[k, l, i, j] \times \| \mathbf{D}_p \mathbf{R}_{k,l}^H \mathbf{H} \mathbf{x} - \mathbf{R}_{i,j}^L \mathbf{y} \|_2^2 \quad (13)$$

Figura 9: Relación entre tamaños de las estructuras locales q y $p = (q - 1)s + 1$



<http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=4694003>

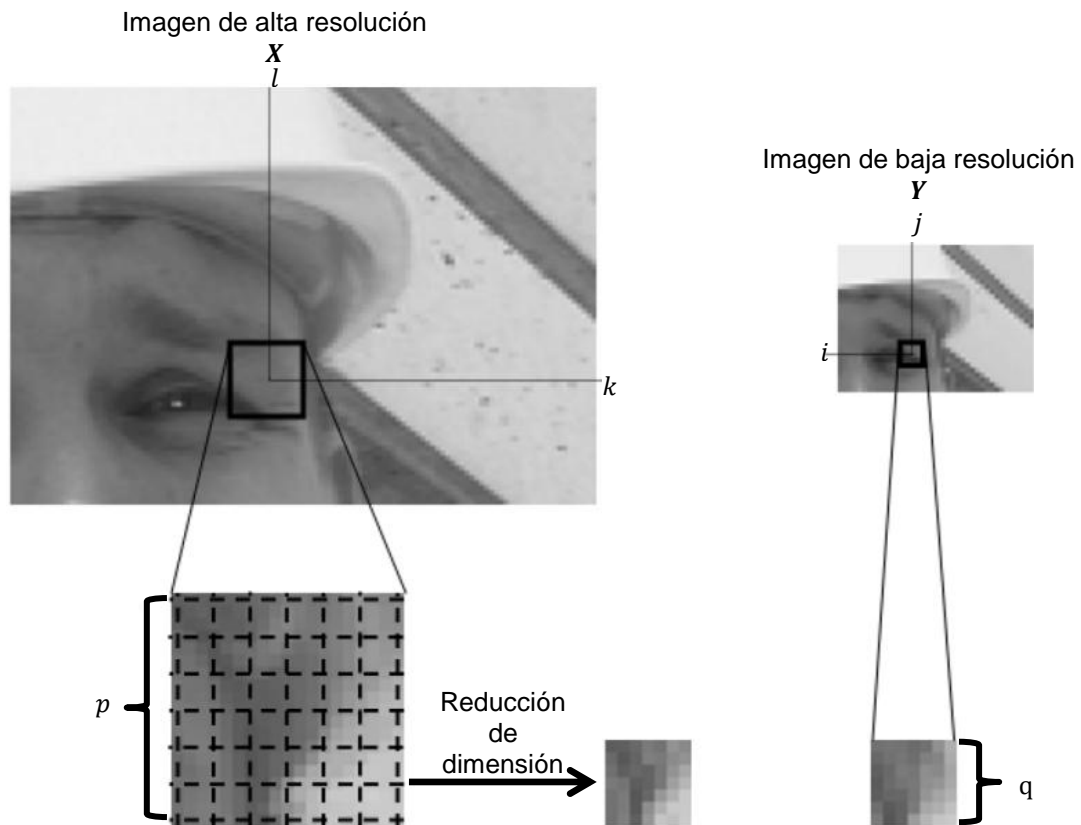
El termino $(i, j) \in N(k, l)$ ya no es aplicable como antes, dado que ahora (i, j) y (k, l) son pixeles en diferentes resoluciones. Por lo tanto, se introduce la notación N^L que se refiere a la estructura local con centro en (k, l) de una imagen de baja resolución.

Una vez calculado, se usa la versión vectorial de Z para estimar x por minimización

$$\hat{x} = \arg \min_x \|z - Hx\|_2^2 + \lambda TV(x), \quad (14)$$

donde z es la representación vectorial de la matriz Z , H representa la la matriz de desenfoque gaussiano, x es la representación vectorial de la imagen X y λ

Figura 10: Ejemplo de extracción de una estructura local en una imagen de alta y de baja resolución, con centro en los puntos $X(k, l)$ y $Y(i, j)$ respectivamente.



Fuente: [Online] <http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=4694003>

es el parámetro de regularización. El parámetro de variación total TV representa la función de regularización de la eliminación de ruido [32].

En la tabla 1 se describe el desarrollo de las ecuaciones 12 y 13. Mediante la implementación del algoritmo de NLM de SR propuesto en [18].

2.1.4. Seudocódigo NLM: En esta sección se presenta el diseño del algoritmo NLM de SR propuesto en [18]. El cual contiene una complejidad computacional similar a la de sus métodos homólogos de NLM, con adición de un proceso de eliminación de desenfoque.

La estructura del algoritmo NLM de SR se basa en la estimación de una imagen de HR $\hat{x} \in \mathbb{R}^{s_1 N \times s_2 M}$ a partir de una versión de LR inicial $y^0 \in \mathbb{R}^{N \times M}$. Para este proceso se debe establecer los factores de superresolución s_1 y s_2 a los cuales se desea aumentar la resolución de N y M , respectivamente. Seguidamente se define el tamaño de las estructuras locales de baja y alta resolución q y p , respectivamente. La estimación inicial de la imagen de HR x^0 , se realiza mediante la implementación de una interpolación de factor s_1 y s_2 a la imagen inicial de LR y^0 . Basada en esta estimación inicial de HR se crea $z = x^0$, la cual será implementada para el cálculo de la matriz de pesos. El objetivo de la matriz de pesos $w[k, l, i, j]$ es reflejar la probabilidad de que el pixel $Z[k, l]$ y el pixel $y[i, j]$ procedan de la misma posición. El cálculo de los pesos se basa en la similitud y la distancia geométrica f que poseen las estructuras locales de dos pixeles. Para la restauración de la imagen inicial de HR por el método NLM es necesario crear dos matrices auxiliares U y V . Las cuales almacenan la suma de todos los pesos y la suma de cada peso multiplicado por los pixel, respectivamente. Al obtener estas dos matrices, se procede a realizar una normalización la cual da como resultado la imagen restaurada de HR en su representación matricial Z . Por último se plantea un

problema de minimización implementando las variables x^0 y z , el cual está definido en la ecuación (13).

Tabla 1: Algoritmo de Superresolución NLM

Objetivo: Estimar la imagen de alta resolución \hat{x}

Entradas:

- Imagen inicial de baja resolución y .
- Factor de aumento de resolución s_1 y s_2 .
- Tamaño de la estructura local de baja resolución q .
- Tamaño de la estructura local de alta resolución p .

Pre-procesamiento:

- Calcular la imagen de alta resolución inicial x^0 mediante una interpolación.

Inicialización:

- Se crea la variable $z = x^0$, que es la representación vectorial de Z .
- Se crea e inicializa en ceros las matrices auxiliares V y U , con dimensiones iguales a X^0 .

Iteración: Para cada pixel de la imagen (k, l) y sus respectivos pixeles contenidos en su estructura local (i, j) .

- Calcular los pesos:

$$w[k, l, i, j] = e^{-\frac{\|\hat{R}_{(k,l)z} - \hat{R}_{(i,j) \in N^L(k,l)} y\|_2^2}{2\sigma^2}}.$$

- Acumular entradas:

$$V[k, l] = V[k, l] + w[k, l, i, j] (\mathbf{R}_{k,l}^H)^T \mathbf{D}_p^T \mathbf{R}_{i,j}^L Y.$$

- Acumular pesos:

$$U[k, l] = U[k, l] + w[k, l, i, j] \mathbf{D}_p^T \mathbf{R}_{i,j}^L \mathbf{1}.$$

Normalización:

$$Z[k, l] = \frac{V[k, l]}{U[k, l]}.$$

Eliminación de ruido: Por minimización

$$\hat{x} = \underset{x}{\operatorname{argmin}} \|z - Hx^0\|_2^2 + \lambda TV(x^0) \quad w.r.t. \ x,$$

Resultado: Imagen de alta resolución \hat{x} .

2.2. REGRESIÓN DE NÚCLEOS DE DIRECCIÓN (STEERING KERNEL REGRESSION -SKR)

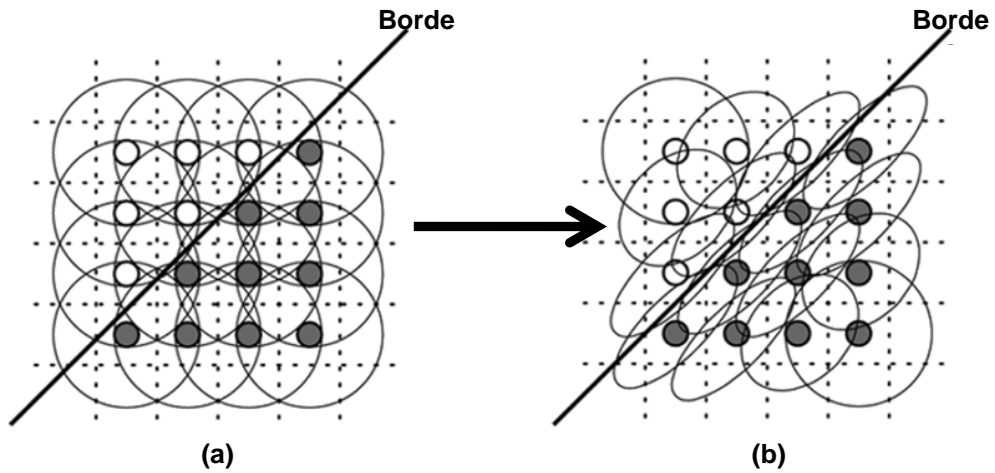
La regresión de núcleos de direcciones es uno de los métodos de filtrado local más implementado para la reconstrucción de imágenes. Debido a su auto-adaptación a las estructuras locales y su robustez a los ruidos. Este método no-paramétrico se basa en la manipulación de los datos para realizar una aproximación de las estructuras locales. Estas aproximaciones son realizadas por una función regresión [33]-[34], que permite modelar la estructura natural de los datos. La implementación de una estructura no-paramétrica tiene tres ventajas principales sobre las estructura paramétricas. La primera es la adaptación de los problemas como una estimación de características locales de datos, a diferencia de una estructura paramétrica que tiene una implementación más global. La segunda, es que la asignación de pesos por los métodos no-paramétricos no requiere que los datos tengan una estructura de muestreo regular o igualmente espaciada; si las muestras son adyacentes al pixel a restaurar, el marco es válido. En tercer lugar, el enfoque es viable para la eliminación de ruido, e interpolación de datos.

Con la aparición relativamente reciente de los métodos de aprendizaje automático (machine learning), los métodos de regresión de núcleos (steering kernel) han llegado a ser bien conocidos e implementados para los problemas de detección y clasificación. Sin embargo, estas ideas no son ampliamente reconocidas o utilizados en la literatura de imágenes y video.

2.2.1. Datos adaptados a los núcleos de regresión: El método de SKR propone extraer las características radiales que poseen los conjuntos de pixeles adyacentes a los núcleos. Donde las características radiales son aquellas que definen la longitud, el ángulo de inclinación y el radio del vecindario (Fig.11). Estas características permiten determinar de forma más detallada el aspecto y la distribución de las estructuras locales [35]. Los

métodos tradicionales basan el diseño de las estructuras locales únicamente en función de la cantidad y la ubicación de los píxeles.

Figura 11: Propagación del núcleo en un conjunto de datos muestreados de manera uniforme.



Fuente: [Artículo] Kernel regression for image processing and reconstruction, Figura 8.

En la Figura.11 (a) representa la estructura de los núcleos en los métodos clásicos, dependen únicamente de la cantidad de píxeles contenidos en la estructura local. Figura.11 (b) representa la estructura de los datos adaptados permite a los núcleos extenderse con respecto al borde.

El enfoque SKR permite adaptar las estructuras locales a las características de la imagen, tales como los bordes (Fig.11).

Como método local, el SKR calcula el peso de regresión a partir de una estructura local de píxeles con núcleo en el píxel a restaurar. Por lo general se representa como

$$\hat{x}[k, l] = \arg \min_{z(x[k, l])} \sum_{(i, j) \in N(k, l)} [y[i, j] - z(x[k, l])]^2 w^k[k, l], \quad (15)$$

donde $N(k, l)$ representa el conjunto de pixeles contenidos en la estructura local del pixel a restaurar $x[k, l]$, $z(x[k, l])$ es una función de regresión general, $y[i, j]$ representa la imagen de baja resolución y $w^k[k, l, i, j]$ es la matriz de pesos que refleja la similitud entre el pixel a reconstruir y los pixeles contenidos en su estructura local $x[k, l]$ y $x[i, j]$. Normalmente, se toma al gradiente en consideración y análisis mediante el cálculo de la similitud radial entre dos pixeles dentro de una estructura local. El núcleo de direcciones que se adopta en el método SKR se define como

$$w^k[k, l] = \frac{\sqrt{\det(C([k, l]))}}{2\pi h^2} e^{-\frac{(x[k, l]-x[i, j])^T C[k, l](x[k, l]-x[i, j])}{2h^2}}, \quad (16)$$

donde h es un parámetro de suavizado que controla el rango de soporte del núcleo de direcciones y $C[k, l]$ es la matriz simétrica de covarianza del gradiente (symmetric gradient covariance) para el pixel $x[k, l]$ en la dirección vertical y horizontal [35]. La estructura de borde local está relacionada con el gradiente de covarianza (o equivalente a la orientación localmente dominante), donde una estimación aproximada de esta matriz de covarianza puede obtenerse como

$$C[k, l] \approx \begin{bmatrix} \sum_{(i, j) \in N(k, l)} z_{x_1}(x[i, j])z_{x_1}(x[i, j]) & \sum_{(i, j) \in N(k, l)} z_{x_1}(x[i, j])z_{x_2}(x[i, j]) \\ \sum_{(i, j) \in N(k, l)} z_{x_1}(x[i, j])z_{x_2}(x[i, j]) & \sum_{(i, j) \in N(k, l)} z_{x_2}(x[i, j])z_{x_2}(x[i, j]) \end{bmatrix}, \quad (17)$$

donde $z_{x_1}(\cdot)$ y $z_{x_2}(\cdot)$ son la primera derivada en función de las direcciones x_1 y x_2 . Con el fin de obtener una forma más conveniente de expresar la matriz de covarianza, esta es descompuesta en tres componentes (equivalentes a la descomposición de valores propios) los cuales son


$$C[k, l] = \gamma[k, l] \mathbf{U}_{\theta[k, l]} \mathbf{\Lambda}_{\theta[k, l]} \mathbf{U}_{\theta[k, l]}^T \quad (18)$$

$$\mathbf{U}_{\theta[k, l]} = \begin{bmatrix} \cos(\theta[k, l]) & \sin(\theta[k, l]) \\ -\sin(\theta[k, l]) & \cos(\theta[k, l]) \end{bmatrix}$$

$$\Lambda_{\theta[k,l]} = \begin{bmatrix} \sigma[k,l] & 0 \\ 0 & \sigma[k,l]^{-1} \end{bmatrix}.$$

Donde $\mathbf{U}_{\theta[k,l]}$ representa la matriz de rotación y $\Lambda_{\theta[k,l]}$ es la matriz de elongación. La matriz de covarianza está compuesta por tres parámetros $\gamma[k,l]$, $\theta[k,l]$ y $\sigma[k,l]$, los cuales son los parámetros de escalado, rotación y elongación, respectivamente. La figura 9 explica esquemáticamente como estos parámetros afectan a la difusión de los núcleos. En primer lugar, el núcleo circular es alargado por la matriz de elongación $\Lambda_{\theta[k,l]}$, y sus ejes semi-menores y mayores están dados por $\sigma[k,l]$. En segundo lugar, el núcleo

Figura 12: Representación esquemática que ilustra los efectos de la matriz de orientación y sus componentes ($C[k,l] = \gamma[k,l]\mathbf{U}_{\theta[k,l]}\Lambda_{\theta[k,l]}\mathbf{U}_{\theta[k,l]}^T$) en tamaño y la forma del núcleo de regresión.



Fuente: [Artículo] Kernel regression for image processing and reconstruction, Figura 9.

alargado es girado por la matriz $\mathbf{U}_{\theta[k,l]}$. Finalmente, el núcleo es escalado por el parámetro de escala $\gamma[k,l]$.

Se define a los parámetros de escalamiento, elongación y rotación de la siguiente manera. A raíz de trabajos anteriores, se determinó que la orientación dominante de las dimensiones de gradientes locales es el vector singular

correspondiente al valor singular más pequeño de la matriz de gradientes locales. Matemáticamente se expresa como

$$G[k, l] = \begin{bmatrix} \cdot & \cdot \\ z_{x_1}(x[i, j]) & z_{x_2}(x[i, j]) \\ \cdot & \cdot \\ \cdot & \cdot \end{bmatrix} = U[k, l]S[k, l]V^T[k, l], \quad (19)$$

$x[i, j] \in N(k, l)$

donde $U[k, l]S[k, l]V^T[k, l]$ es la descomposición de valores singulares truncados de $G[k, l]$ y $S[k, l]$ es una matriz diagonal 2×2 que representa la energía en las direcciones dominantes. A continuación, la segunda columna de la matriz ortogonal de 2×2 $V[k, l]$, $v_2 = [v_1, v_2]^T$, define el ángulo de orientación dominante $\theta[k, l]$

$$\theta[k, l] = \arctan\left(\frac{v_1}{v_2}\right). \quad (20)$$

El parámetro de elongación es representado matemáticamente como

$$\sigma[k, l] = \frac{s_1 + \lambda'}{s_2 + \lambda'}, \quad \lambda' \geq 0 \quad (21)$$

donde λ' es un parámetro de “regularización” para la elongación de núcleo, que amortigua el efecto del ruido. Finalmente, el parámetro de escalado $\gamma[k, l]$ es definido por

$$\gamma[k, l] = \left(\frac{s_1 s_2 + \lambda''}{M}\right)^{\frac{1}{2}}, \quad (22)$$

donde λ'' es un parámetro de “regularización”, que amortigua el efecto del ruido y mantiene a $\gamma[k, l]$ de convertirse en cero y M es el número de píxeles contenidos en la estructura local.

2.2.2. seudocódigo SKR: En esta sección se presenta el diseño del algoritmo SKR de SR propuesto en [14]. El cual contiene una complejidad computacional superior a la de los métodos de NLM.

La estructura del algoritmo SKR de SR se basa en la estimación de una imagen de HR $\hat{x} \in \mathbb{R}^{s_1 N \times s_2 M}$ a partir de una versión de LR inicial $y^0 \in \mathbb{R}^{N \times M}$. Para este proceso se debe establecer los factores de superresolución s_1 y s_2 a los cuales se desea aumentar la resolución de N y M , respectivamente. Seguidamente se define el tamaño de las estructuras locales de alta resolución p . La estimación inicial de la imagen de HR x^0 , se realiza mediante la implementación de una interpolación de factor s_1 y s_2 a la imagen inicial de LR y^0 . Basada en la estimación inicial de HR se calcula la matriz de pesos $w^k[i, j]$. El objetivo de la matriz de pesos es reflejar la probabilidad de que el pixel $x[k, l]$ y el pixel $x[i, j]$ procedan de la misma posición. El cálculo de los pesos se basa en la similitud y la distribución de los pixeles contenidos en las estructuras locales. Esta estructura es definida por la matriz de covarianza \mathcal{C} , la cual estima la distribución natural de los pixeles. La matriz de covarianza es obtenida por la ecuación (18). Al obtener la estimación inicial de HR y la matriz de covarianza, se procede a calcular el peso asignado al pixel $x[i, j]$ respecto a $x[k, l]$, mediante la ecuación (15). Por último se plantea un problema de minimización implementando las variables x^0 y w^k , el cual está definido en la ecuación (14).

Tabla 2: Algoritmo de superresolución SKR

Objetivo: Estimar la imagen de alta resolución \hat{X}

Entradas:

- Imagen inicial de baja resolución Y .
- Factor de aumento de resolución s .
- Tamaño de la estructura local de alta resolución p .

Pre-procesamiento:

- Calcular la imagen de alta resolución inicial x^0 mediante interpolación Lanczos.

Iteración: Para cada pixel de la imagen (k, l) y sus respectivos pixeles contenidos en su estructura local $(i, j) \in N(k, l)$, la cual contiene $p^2 \in \mathbb{R}$ pixeles.

- Calcular la matriz de covarianza:

$$C[k, l] = \gamma[k, l] \mathbf{U}_{\theta[k, l]} \mathbf{\Lambda}_{\theta[k, l]} \mathbf{U}_{\theta[k, l]}^T.$$

- Calculo de la matriz de pesos:

$$w^k[k, l] = \sum_{(i, j) \in N(k, l)} \frac{\sqrt{\det(C([k, l]))}}{2\pi h^2} e^{-\frac{(x[k, l] - x[i, j])^T C[k, l] (x[k, l] - x[i, j])}{2h^2}},$$

Eliminación de ruido: Por minimización

$$\hat{x}[k, l] = \arg \min_{z(x[k, l])} \sum_{(i, j) \in N(k, l)} [x^0[k, l] - z(x[k, l])]^2 w^k[k, l],$$

Resultado: Imagen de alta resolución \hat{x} .

3. MÉTODO DE SUPERRESOLUCIÓN PROPUESTO

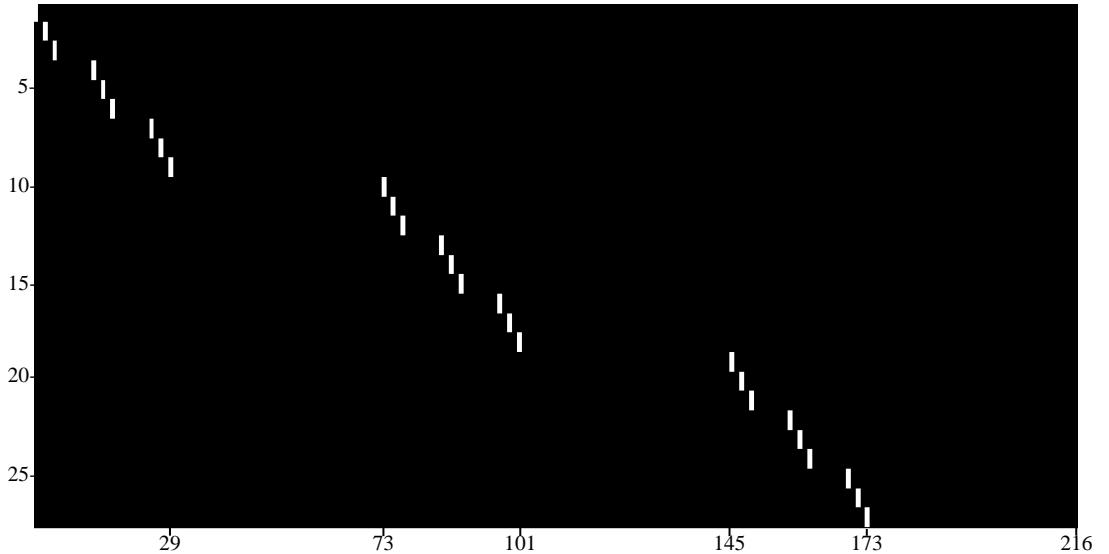
3.1. PLANTEAMIENTO MATEMÁTICO

En este trabajo se retoma el problema de superresolución para imágenes hiperespectrales, proponiendo un enfoque de superresolución espacio-espectral [19]. Para esto se plantea la superresolución propuesta en la ecuación 1 y se adapta para imágenes hiperespectrales; a diferencia de los métodos tradicionales de superresolución para HSI (ecuación 5) [13], [14], [18] este enfoque toma la imagen completa. Esto se expresa matemáticamente como

$$\mathbf{y}_H = \mathbf{D}_H \mathbf{H}_H \mathbf{x}_H + \boldsymbol{\varepsilon}_H, \quad (23)$$


donde $\mathbf{y}_H \in \mathbb{R}^{NML \times 1}$ es la representación vectorial de una imagen hiperespectral de baja resolución, $\mathbf{x}_H \in \mathbb{R}^{s_1 s_2 s_3 NML \times 1}$ es la representación vectorial de una imagen hiperespectral de alta resolución, $\mathbf{D}_H \in \mathbb{R}^{NML \times s_1 s_2 s_3 NML}$ es la matriz de reducción espacial y espectral, $\mathbf{H}_H \in \mathbb{R}^{NML \times NML}$

Figura 13: Ejemplo de una matriz de reducción espacio-espectral $\mathbf{D}_H \in \mathbb{R}^{27 \times 216}$ para una imagen hiperespectral $\mathbf{X}_H \in \mathbb{R}^{3s_2 \times 3s_2 \times 3s_3}$, con un factor de superresolución de $s_1 = s_2 = s_3 = 2$.



es la matriz desenfoque (describe la mezcla de los pixeles en cada banda espectral, los pixeles en diferentes bandas espectrales no interactúan) y

Figura 14: Ejemplo de una matriz de desenfoque $\mathbf{H}_H \in \mathbb{R}^{216 \times 216}$ el cual su efecto es equivalente a un filtro Gaussiano pasa-bajo simétrico, para una imagen hiperespectral $\mathbf{X}_H \in \mathbb{R}^{3s_2 \times 3s_2 \times 3s_3}$, con un factor de superresolución de $s_1 = s_2 = s_3 = 2$.



$\boldsymbol{\varepsilon}_H \in \mathbb{R}^{NML \times 1}$ es la representación vectorial del ruido gaussiano generado por los sistemas de captura. Un ejemplo de las matrices \mathbf{D}_H y \mathbf{H}_H son ilustradas en las figuras 13 y 14, respectivamente.

La señal \mathbf{x}_H puede ser estimada mediante un problema de minimización

$$\hat{\mathbf{x}}_H = \arg \min_{\mathbf{x}_H} \|\mathbf{y}_H - \mathbf{D}_H \mathbf{H}_H \mathbf{x}_H\|_2^2, \quad (24)$$


o una aproximación por el uso del método de gradiente descendiente tal como

$$\mathbf{x}_H^{t+1} = \mathbf{x}_H^t + \tau (\mathbf{D}_H \mathbf{H}_H)^T (\mathbf{y}_H - \mathbf{D}_H \mathbf{H}_H \mathbf{x}_H). \quad (25)$$

Al obtener una solución de \mathbf{x}_H por medio de la ecuación (14), se puede observar que esta solución esta extremadamente mal planteada debido a que

el producto de $\mathbf{D}_H^T \mathbf{y}_H$ genera una HSI con relleno de ceros en su espectro y la matriz \mathbf{H}_H^T solo usa la información contenida en cada banda espectral por separado. Dado que la señal a restaurar x_H^{t+1} es una imagen hiperespectral con bandas espectrales rellenas de solo ceros, esta imagen es inconsistente con los requerimientos de una imagen de alta resolución. Una representación de la imagen restaurada con relleno cero en sus bandas espectrales es ilustrada en la figura 15.

Figura 15: Reconstrucción de una imagen hiperespectral de baja resolución en su versión vectorial $\mathbf{y}_H \in \mathbb{R}^{27 \times 1}$ mediante la ecuación 23.



En la Figura.15 la matriz de reducción transpuesta $\mathbf{D}_H^T \in \mathbb{R}^{216 \times 27}$ al ser multiplicada por la HSI de LR $\mathbf{D}_H \mathbf{y}_H$, proporciona como resultado una imagen hiperespectral de “alta resolución” con relleno de ceros en sus bandas espectrales \mathbf{X}_H .

La implementación de la ecuación (21) para restaurar HSI de LR tiene una intuición correcta, por lo tanto se parte de esta ecuación para plantear el nuevo método de superresolución de una sola imagen para HSI de baja resolución. Para realizar este planteamiento se realizaran cuatro pasos principales. El primer paso es redefinir la ecuación (21) mediante la implementación de una

interpolación cubica $\Psi \in \mathbb{R}^{s_1 s_2 s_3 NML \times NML}$, para obtener una aproximación inicial de superresolución de las bandas espectrales


$$\Psi y_H = \Psi D_H H_H x_H + \Psi \varepsilon_H. \quad (26)$$

El segundo paso consiste en la reducción de la resolución espacial de la ecuación 24, para disminuir la complejidad computacional del método y disminuir el ruido. Este proceso es representado por la matriz $D_b \in \mathbb{R}^{s_3 NML \times s_1 s_2 s_3 NML}$, (figura 16), el cual es representado matemáticamente como

$$D_b \Psi y_H = D_b \Psi D_H H_H x_H + D_b \Psi \varepsilon_H. \quad (27)$$

La implementación de estos dos pasos elimina el efecto de relleno de ceros, disminuye la complejidad computacional del método, disminuye el ruido inherente en la imagen y permite integrar la información espacial y espectral.

Figura 16: Ejemplo de una matriz de reducción espacio $D_b \in \mathbb{R}^{54 \times 216}$ para una imagen hiperespectral $X_H \in \mathbb{R}^{3s_2 \times 3s_2 \times 3s_3}$, con un factor de superresolución de $s_1 = s_2 = 2$ y $s_3 = 1$



Estos dos procesos son representados en la figura 17. En tercer paso se plantea un problema optimización de la ecuación 25


$$\hat{x}_H = \arg \min_{x_H} \|\mathbf{D}_b \Psi y_H - \mathbf{D}_b \Psi \mathbf{D}_H \mathbf{H}_H x_H\|_2^2. \quad (28)$$

Por último, para obtener una solución de la ecuación 26, se reformula de forma concisa usando el método de gradiente descendente

$$x_H^{t+1} = x_H^t + \tau (\mathbf{D}_b \Psi \mathbf{D}_H \mathbf{H}_H)^T (\mathbf{D}_b \Psi y_H - \mathbf{D}_b \Psi \mathbf{D}_H \mathbf{H}_H x_H). \quad (29)$$

El objetivo del algoritmo planteado (algoritmo III) es encontrar la imagen \hat{X}_H en su representación vectorial \hat{x}_H la cual satisface las condiciones de la ecuación 25. Además, la imagen de alta resolución \hat{X}_H puede ser encontrada en función de su versión de baja resolución Y_H . De la ecuación 26 se puede observar que hay tres procedimientos claves para obtener una solución óptima local \hat{x}_H : la primera, es el cálculo del aumento de resolución espacial-espectral de la imagen hiperespectral de baja resolución de entrada usando una interpolación tridimensional Ψ . El segundo consiste en reducir la resolución espacial usando la matriz de reducción \mathbf{D}_b ; y el otro es la minimización basado en el gradiente descendente para la actualización x_H^{t+1} . La carga computacional del método podría ser reducida por realizar una sola vez el cálculo de $(\mathbf{D}_b \Psi \mathbf{D}_H \mathbf{H}_H)^T \mathbf{D}_b \Psi y_H$ antes de entrar al método iterativo.

Figura 17: Aumento de resolución espacial y espectral, y disminución de la dimensión espacial.



3.2. ALGORITMO PROPUESTO DE SR PARA HSI

En esta sección se presenta el diseño del algoritmo de SR propuesto. El cual contiene una complejidad computacional inferior a la de los métodos de NLM y SKR.

Una descripción detallada del método propuesto se encuentra en la tabla 3. La estructura del algoritmo de SR propuesto se basa en la estimación de una imagen de HR $\hat{x}_H \in \mathbb{R}^{s_1 N \times s_2 M}$ a partir de una versión de LR inicial $y^0 \in \mathbb{R}^{N \times M}$, que satisfaga las restricciones planteadas en la ecuación (27). Para este proceso se debe establecer los factores de superresolución s_1 , s_2 y s_3 a los cuales se desea aumentar la resolución de N , M y L respectivamente. La estimación inicial de la imagen de HR x_H^0 , se realiza mediante la implementación de una interpolación cubica Ψ , de factor s_1 , s_2 y s_3 a la imagen inicial de LR y_H . Posteriormente se procede a realizar la disminución de resolución espacial $N \times M$, usando la matriz D_b ; y por último se resuelve la minimización (ecuación (27)), mediante el gradiente descendente para obtener el reajuste de x_H^{t+1} .

Tabla 3: Algoritmo de Superresolución espacio-espectral propuesto

Objetivo: Estimar la imagen de alta resolución \hat{X}

Entradas:

- Imagen inicial de baja resolución Y .
- Factor de aumento de resolución s_1, s_2, s_3 .

Pre-procesamiento:

- Iniciar variable $t = 0$.
- Realizar la estimación inicial de la HSI de HR x_H^0 , usando la interpolación tridimensional.

$$x_H^0 = \Psi y_H$$

Iteración: Se repite el proceso t veces

- Actualizar la imagen hiperespectral x_H^t , usando

$$x_H^{t+1} = x_H^t + \tau(\mathbf{D}_b \Psi \mathbf{D}_H \mathbf{H}_H)^T (\mathbf{D}_b \Psi y_H - \mathbf{D}_b \Psi \mathbf{D}_H \mathbf{H}_H x_H).$$

- Actualización de $t = t + 1$

Resultado: Imagen de alta resolución \hat{X} .

4. SIMULACIONES Y RESULTADOS

Con el fin de comparar la efectividad del algoritmo propuesto se realizaron comparaciones de imágenes hiperespectrales de baja resolución restauradas por el método propuesto y por dos métodos tradicionales de superresolución [NLM]-[SKR]. Para este proyecto se usaron 2 imágenes hiperespectrales. La primera HSI es una imagen de Legos con una resolución espacial de 512×512 píxeles y $L = 24$ bandas espectrales. La segunda HSI es una imagen de la ciudad de Ribeira con una resolución espacial de 1000×1000 píxeles y $L = 32$ bandas espectrales.

La imagen de legos fue adquirida usando una lámpara Xenon como fuente de luz y un monocromador visible que abarca la gama espectral entre 450 nm y 650 nm . La intensidad de la imagen fue capturada usando una cámara CCD AVT Marling F0033B, que captura una resolución de 512×512 píxeles, con tamaño de píxel de $9,9 \mu\text{m}$ y 24 bits de profundidad de píxel. La imagen hiperespectral resultante X_H tiene 512×512 píxeles en la resolución espacial y $L = 24$ bandas espectrales.

La imagen de la ciudad de Ribeira fue adquirida mediante una cámara de bajo ruido Peltier con un filtro de cristal líquido sintonizable de rápido montaje en frente de la lente, junto con un filtro de bloqueo de infrarrojos los cuales proporcionan una resolución espacial de 1344×1024 píxeles (Hamamatsu Photonics). La longitud de onda de pico de transmisión varía en pasos de 10 nm en un rango de $400 - 720 \text{ nm}$. La imagen hiperespectral resultante X_H tiene 1000×1000 píxeles en la resolución espacial y $L = 32$ bandas espectrales [36].

4.1. PARÁMETROS EXPERIMENTALES

Para obtener resultados cuantitativos y cualitativos de las restauraciones, se crea imágenes hiperespectrales de baja resolución sintéticas implementando la ecuación (21). La HSI de LR es creada a partir de multiplicar la imagen hiperespectral de HR inicial en su representación vectorial x_H (Legos o ciudad de Ribeira) por una matriz de desenfoque gaussiano H_H de tamaño 11×11 con desviación estándar $\sigma = 1,5$ y por una matriz de reducción de la resolución espacio-espectral D_H con factor de reducción igual a 2, en las tres dimensiones.

En el algoritmo de SR se implementaron los siguientes parámetros para la obtención de una óptima reconstrucción: una matriz de desenfoque gaussiano H_H de tamaño 5×5 con desviación estándar de $\sigma = 1,5$, un factor de restricción de ruido $\tau = 7,5$, parámetros de superresolución $s_1 = s_2 = s_3 = 2$ y un factor iterativo de $t = 7$. Estas simulaciones son realizadas en un computador con procesador Intel core2 Quad 2.67 GHz y con 8 Gb de memoria RAM.

4.2. RESULTADOS

Para probar la metodología desarrollada en la sección 3, se realizaron reconstrucciones de imágenes de baja resolución mediante los métodos NLM, SKR y el algoritmo propuesto. Por lo cual el nivel de reconstrucción de cada método es medido en función del nivel de la relación señal a ruido de pico (PSNR), obtenido, el cual es una aproximación a la percepción humana de la calidad de reconstrucción. Matemáticamente es representado por

$$PSNR = 10 \log_{10} \left(\frac{(\max_{X_H} X_H)^2}{MSE} \right), \quad (30)$$

donde $(\max_{X_H} X_H) \in \mathbb{R}$ representa la máxima intensidad contenida en la imagen HSI de HR original y el error cuadrático medio (MSE) es el error cuadrático medio que mide el promedio de los errores al cuadrado, es decir, la diferencia entre el estimador y lo que se estima. Matemáticamente se representa al MSE como


$$MSE = \frac{1}{n} \sum_{r=1}^n (X_{Hr} - \hat{X}_{Hr})^2, \quad n = 1, \dots, NML, \quad (31)$$

donde X_H representa la imagen hiperespectral de alta resolución original, \hat{X}_H representa la imagen hiperespectral de alta resolución reconstruida por alguno de los métodos de superresolución y $n \in \mathbb{R}$ representa el número de píxeles contenido en la imagen de alta resolución. Las imágenes espectrales poseen valores de intensidad de luz, por ende, son representadas como un conjunto de imágenes en escala de grises. Consecuentemente, las imágenes espectrales

Figura 18: Representación en formato RGB de la imagen hiperespectral de legos.



Figura 19: Representación en formato RGB de la imagen hiperespectral de ciudad Ribeira.




Fuente:[Base de datos online] http://personalpages.manchester.ac.uk/staff/david.foster/Hyperspectral_images_of_natural_scenes_04.html

que se utilizan en este proyecto se ilustran en la Figura 18 y 19 han sido presentadas en un formato RGB para mayor comprensión de los lectores.

Para evaluar el desempeño de reconstrucción espectral se escogieron 2 píxeles espectrales al azar y sus firmas espectrales fueron graficadas en la figura 20, los puntos son indicados como **P1** y **P2**. El punto P1 y P2 representa todos los píxeles contenidos en las bandas espectrales $L = 1, \dots, 24$, con una misma coordenada espacial. En el cual se puede observar como las firmas espectrales obtenidas por el método propuesto se aproximan más a las firmas espectrales originales.


Figura 20: Representación gráfica de las firmas espectrales en los punto **P1** y **P2**.



4.2.1. Resultados cualitativos: En esta sección se muestran las imágenes reconstruidas por la interpolación Lanczos, los métodos de superresolución NLM, SKR y el algoritmo propuesto. En estas reconstrucciones se implementaron diferentes tamaños y enfoques de las imágenes de baja resolución obtenidas por la implementación de la ecuación 21.

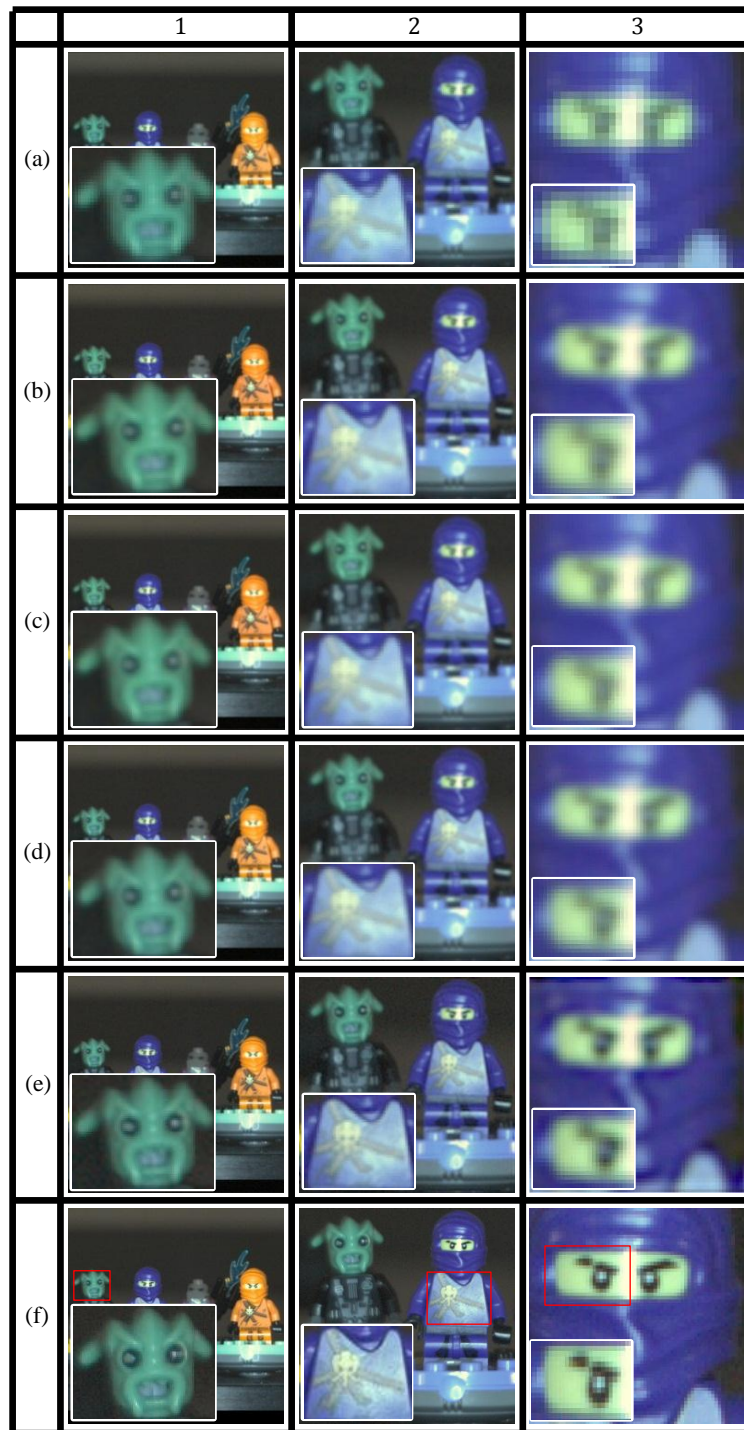
La figura 21 muestra los resultados obtenidos en dos bandas espectrales de la HSI de Legos. La columna (1) representa la banda espectral $L = 1$, y la columna (2) representa la banda espectral $L = 11$. La fila (a) representa las bandas espectrales de baja resolución con tamaño $(256 \times 256 \times 12)$, la columna (b) representa las bandas espectrales de alta resolución restauradas por el método NLM con tamaño $(512 \times 512 \times 24)$, la columna (c) representa las bandas espectrales de alta resolución restauradas por el método de SKR con tamaño $512 \times 512 \times 24$, la columna (d) representa las bandas espectrales de altas resolución reconstruidas por el método propuesto con un tamaño de $512 \times 512 \times 24$ y por último la columna (e) representa las bandas espectrales originales con un tamaño de $512 \times 512 \times 24$.

Figura 21: Reconstrucción de dos bandas espectrales de baja resolución ($L = 1,11$) con tamaño $256 \times 256 \times 12$.



En la Figura.21, la primera fila representa las bandas de baja resolución, la segunda fila muestra las bandas espectrales reconstruidas por el método NLM, la tercera fila muestra las bandas espectrales reconstruidas por el método de SKR, la cuarta fila muestra las bandas espectrales reconstruidas por el método propuesto y la última fila representa las bandas de alta resolución originales. (a) Bandas LR. (b) NLM. (c) SKR. (d) Método propuesto. (e) Bandas originales.

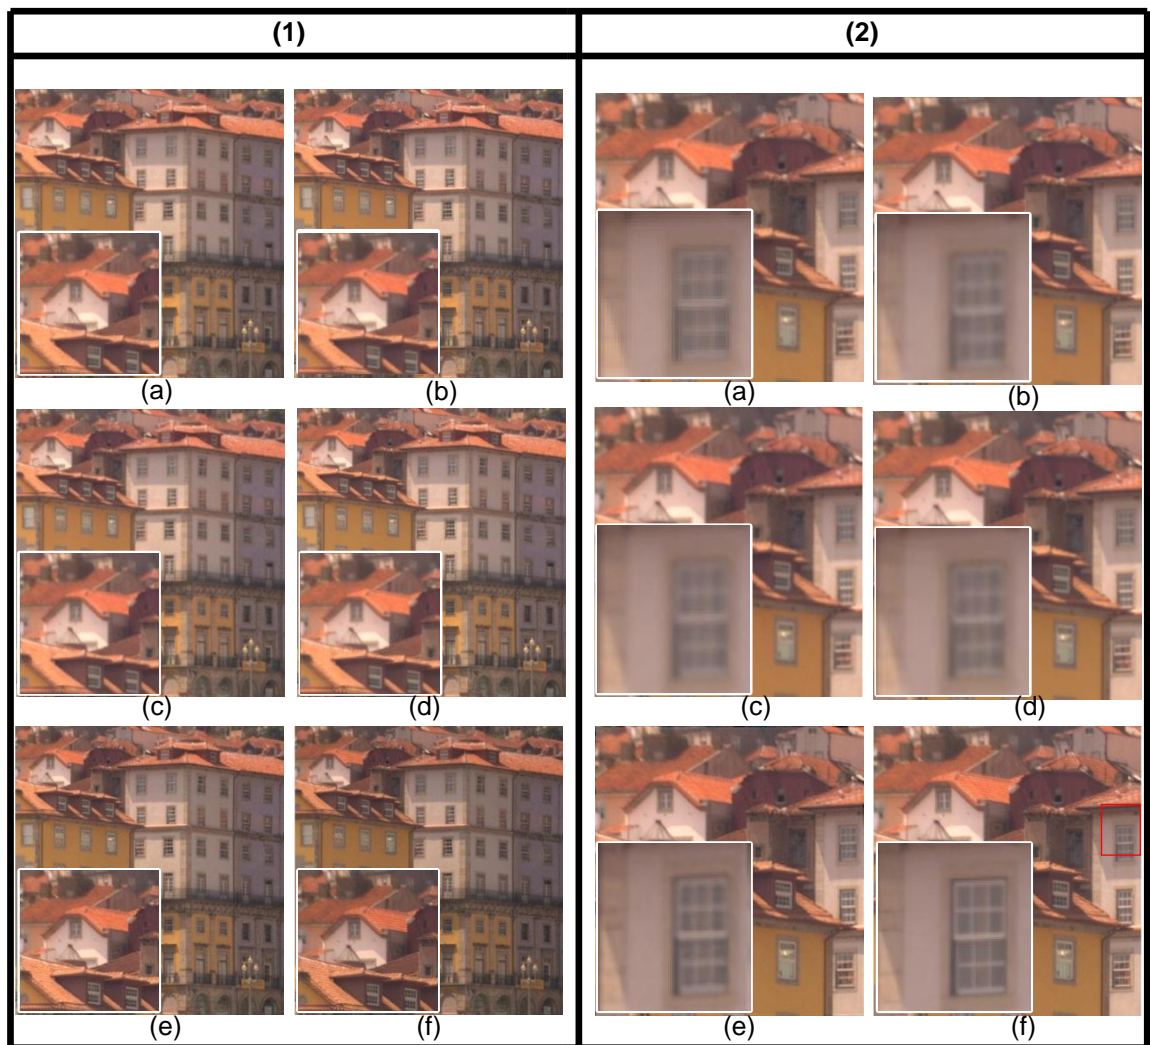
Figura 22: Resultado de tres fragmentos de la imagen hiperespectral Legos.



En la Figura.21, la primera fila (a) representa las imágenes de baja resolución con tamaños $256 \times 256 \times 12$ (columna 1), $128 \times 128 \times 12$ (columna 2) y $32 \times 32 \times 12$ (columna 3); estas imágenes son reconstruidas por un factor de superresolución de $s_1 = s_2 = s_3 = 2$. Las siguiente 4 filas representan las HSI's

reconstruidas por los métodos de SR y la última fila representa la HSI de HR original; estas imágenes tienen un tamaño de $512 \times 512 \times 24$ (columna 1), $256 \times 256 \times 12$ (columna 2) y $64 \times 64 \times 12$ (columna 3). La segunda fila representa las HSI reconstruidas por la interpolación Lanczos, la tercera fila representa las HSI reconstruidas por el método de NLM, la cuarta fila representa las HSI's reconstruidas por el método de KSR, la quinta fila representa las HSI reconstruidas por el método propuesto y la última fila representa las HSI's originales.

Figura 23: Resultados para dos fragmentos de la HSI de la ciudad de Ribeira.



En la Figura.22, (a) representa los fragmentos de LR, (b) representa la reconstrucción por interpolación Lanczos, (c) representa la reconstrucción por

NLM, (d) representa la reconstrucción por SKR, (e) representa la reconstrucción por el método propuesto y (f) representa los fragmentos de HR originales.

La figura 22 muestra los resultados obtenidos en tres fragmentos de la HSI de Legos. La fila (a) representa las imágenes de baja resolución con tamaños de $256 \times 256 \times 12$ (columna 1), $128 \times 128 \times 12$ (columna 2) y $32 \times 32 \times 12$ (columna 3). Las imágenes reconstruidas por los métodos de superresolución se les aplica un factor de superresolución de $s_1 = s_2 = s_3 = 2$, estos métodos son: interpolación Lanczos (fila b), NLM (fila c), SKR (fila d) y el método propuesto (fila e). La fila f representa las HSI de HR originales con tamaños de $512 \times 512 \times 24$ (columna 1), $256 \times 256 \times 24$ (columna 2) y $64 \times 64 \times 24$ (columna 3).

La figura 23 muestra las reconstrucciones obtenidas para dos fragmentos de la HSI de la ciudad de Ribeira. Donde (a) representa las imágenes de baja resolución $500 \times 500 \times 16$ (columna 1) y $250 \times 250 \times 16$ (columna 2). Las siguientes cuatro imágenes (b)-(e) muestran los resultados obtenidos por la reconstrucción de las imágenes en (a), por un factor de superresolución $s_1 = s_2 = s_3 = 2$; interpolación Lanczos (b), método NLM (c), método SKR (d) y el método propuesto (e). La HSI de HR es representada en (f). La HSI de HR (f) y las reconstrucciones por los métodos (b)-(c) tienen un tamaño de $1000 \times 1000 \times 32$ (columna 1) y $500 \times 500 \times 32$ (columna 3).

4.2.2. Resultados cuantitativos: En esta sección se muestran los resultados obtenidos en PSNR por los métodos de superresolución NLM, SKR y el algoritmo propuesto. En estas reconstrucciones se implementaron diferentes tamaños de las imágenes de baja resolución obtenidas por la implementación de la ecuación 21.

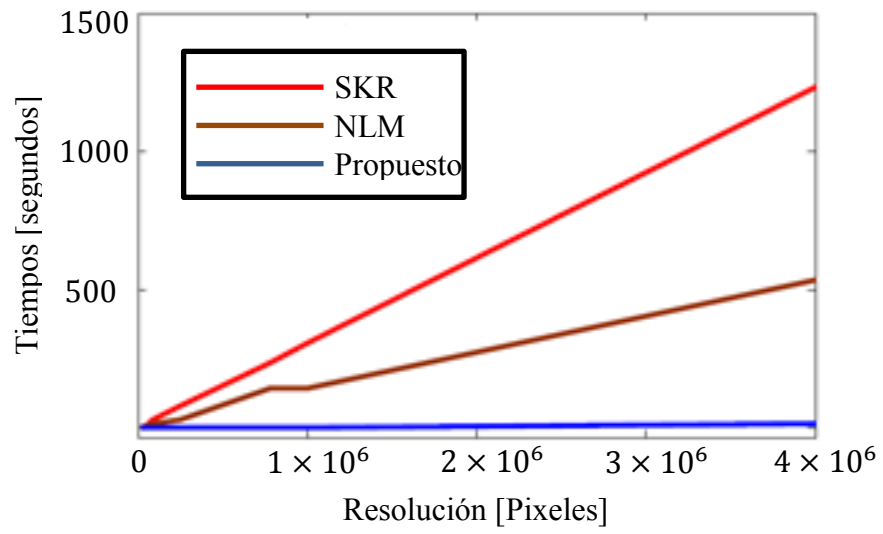
La tabla IV resume los resultados obtenidos en las reconstrucciones ilustradas en las figuras 21-23. Los resultados obtenidos por el método propuesto indican mejoras de hasta 4 dB en las imágenes hiperespectrales en comparación con la interpolación Lanczos. Los métodos NLM y SKR logran mejores resultados que la interpolación Lanczos pero inferiores al método propuesto, además estos métodos tienen un rendimiento inferior al propuesto. Por lo tanto, en términos de los valores de PSNR, el método propuesto alcanza un rendimiento mayor a los tradicionales.

IMAGEN	RESOLUCIÓN	LANCZOS	NLM	SKR	Método propuesto
Legos	256x256x12	28.993	29.479	30.188	32.316
	64x64x12	25.738	26.002	26.726	27.341
	32x32x12	22.336	22.492	23.380	24.473
Ciudad de Ribeira	500x500x16	35.612	35.685	37.075	38.868
	250x250x16	32.584	32.667	34.161	35.000
	125x125x16	30.616	30.888	32.520	33.504
	75x75x16	32.583	33.557	34.743	34.821

Realizamos una comparación en términos de tiempos de CPU y su tasa de convergencia para medir la complejidad computacional del método propuesto.

La figura 24 muestra los tiempos de CPU empleado en todas las imágenes de prueba en un CPU Intel Core I7 con 3.4 GHz y 32 GB de memoria RAM, en la plataforma Windows. En la cual se puede observar que el método propuesto requiere menos tiempo de procesamiento para obtener una reconstrucción de la imagen de HR.

Figura 24: Comparación de los tiempos de CPU entre los métodos NLM, SKR y el método propuesto.



5. CONCLUSIONES

- Las reconstrucción de imágenes hiperespectrales por los métodos SKR y NLM obtienen hasta 2.5 dB más de mejora que la interpolación Lanczos.
- Las estructuras locales con características radiales implementadas en el método SKR obtienen hasta 1.5 dB más de mejora que las estructuras locales tradicionales implementadas en el método NLM.
- El método SKR a pesar de obtener un mayor índice de reconstrucción sobre Lanczos y NLM, su tiempo de computo es el doble.
- El método de superresolución desarrollado en esta tesis es superior a los métodos Lanczos, NLM y SKR. Obteniendo índices de reconstrucción de hasta 2.5 dB sobre los métodos tradicionales planteados.
- El tiempo de cómputo del método propuesto es 50 veces menor que el tiempo gastado por el método NLM y hasta 125 veces menor que el método SKR.

6. RECOMENDACIONES

- Basándose en el modelo expuesto en el presente trabajo, investigar métodos alternativos de superresolución para imágenes hiperespectrales.
- Adaptar e implementar los métodos NLM y SKR para reconstruir imágenes hiperespectrales, mediante el uso de filtros tridimensionales.
- Basándose en el modelo propuesto integrar los métodos NLM y SKR como funciones de restricción.

CITAS BIBLIOGRAFICAS

- [1] G.A. Shaw y H.K. Burke, "Spectral Imaging for Remote Sensing," *Lincoln Laboratory Journal*, vol. 14, no. 1, pp. 3-27, 2003.
- [2] Ayan Chakrabarti and Todd Zickler. "Statistics of Real-World Hyperspectral Images," Proc. of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR), 2011.
- [3] E. Belluco, M. Camuffo, S. Ferrari, L. Modenese, S. Silvestri, A. Marani, and M. Marani, "Mapping salt-marsh vegetation by multispectral and hyperspectral remote sensing," *Remote sensing of environment*, 105(1):54–67, 2006.
- [4] M. Borengasser, W. Hungate, and R. Watkins. "Hyperspectral remote sensing: principles and applications". CRC, 2008.
- [5] A. Castrodad, Z. Xing, J. Greer, E. Bosch, L. Carin, and G. Sapiro, "Discriminative Sparse Representations in Hyperspectral Imagery," In Proc. ICIP, 2010.
- [6] F. Melgani and L. Bruzzone, "Classification of hyperspectral remote sensing images with support vector machines," *IEEE Trans. Geoscience and Remote Sensing*, 42(8):1778–1790, 2004.
- [7] E. Underwood, S. Ustin, and D. DiPietro, "Mapping nonnative plants using hyperspectral imagery," *Remote Sensing of Environment*, 86(2):150–161, 2003.
- [8] D. Dicker, J. Lerner, P. Van Belle, S. Barth, D. Guerry, et al, "Differentiation of normal skin and melanoma using high resolution hyperspectral imaging," *Cancer biology & therapy*, 5(8):1033, 2006.
- [9] G. Stamatias, C. Balas, and N. Kollias. "Hyperspectral image acquisition and analysis of skin". In Proc. SPIE, 2003.
- [10] Dietmar Knipp, Helmut Stiebig, Sameer R. Bhalotra, Eerke Bunte, Helen L. Kung, and David A. B. Miller, "Silicon-Based Micro-Fourier Spectrometer", *IEEE Transactions on electron devices*, Vol. 52, No. 3, March 2005.
- [11] R. Rowe, K. Nixon, and S. Corcoran. Multispectral fingerprint biometrics. In Proc. Info. Assurance Workshop, 2005.
- [12] Reinoud F. Wolffenbuttel, "State-of-the-Art in Integrated Optical Microspectrometers", *IEEE Transactions on instrumentation and measurement*, Vol. 53, No. 1, February 2004.
- [13] Kaibing Zhang, Xinbo Gao, Dacheng Tao, and Xuelong Li, "Single Image Super-Resolution With Non-Local Means and Steering Kernel Regression", *IEEE Transactions on image processing*, Vol. 21, o 11, November 2012.
- [14] Hiroyuki Takeda, Sina Farsiu, and Peyman Milanfar, "Kernel Regression for Image Processing and Reconstruction", *IEEE Transactions on image processing*, Vol. 16, No. 2, February 2007.

- [15] X. Li and M. T. Orchard, "New edge-directed interpolation," *IEEE Trans. Image Process.*, vol. 10, no. 10, pp. 1521–1527, Oct. 2001.
- [16] L. Zhang and X. Wu, "An edge-guided image interpolation algorithm via directional filtering and data fusion," *IEEE Trans. Image Process.*, vol. 15, no. 8, pp. 2226–2238, Aug. 2006.
- [17] M. Li and T. Nguyen, "Markov random field model-based edge-directed image interpolation," *IEEE Trans. Image Process.*, vol. 17, no. 7, pp. 1121–1128, Jul. 2008.
- [18] Protter M, Elad M, Takeda H, and Milanfar P, "Generalizing the Nonlocal-Means to Super-Resolution Reconstruction", *IEEE Transactions on Image Processing*, Vol. 18, Issue.1, December 2008.
- [19] T. Akgun, Y. Altunbasak, and R. M. Mersereau, "Super-resolution reconstruction of hyperspectral images," *IEEE Trans Image Process.*, vol. 14, no. 11, pp.1860-1875, Nov. 2005.
- [20] F. A. Mianji, Y. Zhang and H. K. Sulehria "Super-resolution challenges in hyperspectral imagery", *Inf. Technol. J.*, vol. 7, no. 7, pp.1030 -1036 2008.
- [21] H. Arguello, H. Rueda, and G. R. Arce, "Spatial super-resolution in code apertura spectral imaging," in *SPIE Conference on Defense, Security and Sensing*, Baltimore, AMD, April 2012.
- [22] H. Arguello, H. Rueda, and G. R. Arce, "On super-resolved coded apertura spectral imaging," in *Submitted to IEEE Workshop on Signal Processing Systems*, Quebec, Canada, April 2012.
- [23] H. Arguello and G. R. Arce, "Restricted isometry property in coded aperture compressive spectral imaging," in *IEEE Statistical Signal Processing Workshop*, Ann Arbor, MI, USA, 2012.
- [24] H. Rueda, C. Vargas and H. Arguello, "Single-pixel optical sensing architecture for compressive hyperspectral imaging," in *Journal of the Engineering Department*, Universidad de Antioquia, Colombia, 2014.
- [25] W. T. Freeman, T. R. Jones, and E. C. Pasztor, "Example based super-resolution," *IEE Comput. Graphics Appl*, vol 22, No. 2, pp. 56-65, Mar. 2002.
- [26] RESONON Inc., "What is Spectral Imaging and When Should I Use it?," [en linea]. Disponible en: <http://www.resonon.com/whitepapers/Resonon-Hyperspectral-Tutorial.pdf>
- [27] A. Wagadarikar, R. John, R. Willett, and D. Brady, "Single disperser design for coded aperture snapshot spectral imaging," *Applied optics*, vol. 47, No. 10, pp. B44-B51, April 2008.
- [28] M. Elad, "On the bilateral filter and ways to improve it", *IEEE Trans. Image Process.*, Vol. 11, pp. 1141–1151, October 2002.

- [29] G. Gilboa and S. Osher, "Nonlocal linear image regularization and supervised segmentation", *SIAM Multiscale Modeling and Simulation (MMS)*, Vol. 6, No. 2, pp. 595-630, 2007.
- [30] G. Wolberg, *Digital Image Warping*, IEEE Computer Society Press, Washington, USA, 1990.
- [31] K. Turkowski, "Filters for common resampling tasks", *Graphics Gems*, Academic Press, 1990.
- [32] L. Rudin, S. Osher, and E. Fatemi, "Nonlinear total variation based noise removal algorithms", *Physica D*, Vol. 60, pp. 259–268, 1992.
- [33] M. P. Wand and M. C. Jones, *Kernel Smoothing*, ser. Monographs on Statistics and Applied Probability. New York: Chapman & Hall, 1995.
- [34] Yee and S. Haykin, "Pattern classification as an ill-posed, inverse problem: a regularization approach," in *Proc. IEEE Int. Conf. Acoustics, Speech, Signal Processing*, Apr. 1993, vol. 1, pp. 597–600.
- [35] X. Feng and P. Milanfar, "Multiscale principal components analysis for image local orientation estimation," presented at the 36th Asilomar Conf. Signals, Systems and Computers, Pacific Grove, CA, Nov. 2002.
- [36] D. F. Galvis, Y. Hercilia, "Efficient reconstruction of Raman spectroscopy imaging based on compressive sensing," in *Journal of the Engineering Department*, Universidad de Antioquia, Colombia, 2014.
- [37] D. H. Foster, M. C. Nascimento, and K. Amano, "Information limits on neural identification of colored surfaces in natural scenes," *Visual Neuroscience*, Cambridge University, USA, 2014.

BIBLIOGRAFIA

BELLUCO E, et al. Mapping salt-marsh vegetation by multispectral and hyperspectral remote sensing. En: Remote sensing of environment. Vol; 105, No 1 (2006); p. 54–67.

BORENGASSER M, HUNGATE W., and WATKINS R. "Hyperspectral remote sensing: principles and applications". CRC, 2008.

DICKER D, LERNER J, et al. Differentiation of normal skin and melanoma using high resolution hyperspectral imaging. En: Cancer biology & therapy. Vol; 5, No 8 (2006); p.1033.

DIETMAR K, HELMUT S, SAMEER R. et al. Silicon-Based Micro-Fourier Spectrometer. En: IEEE Transactions on electron devices. Vol. 52, No. 3 (March 2005).

LI M. and NGUYEN T. Markov random field model-based edge-directed image interpolation. En: IEEE Trans. Image Process. Vol. 17, No. 7 (Jul. 2008); p. 1121–1128.

MELGANI F. and BRUZZONE L.. En: Classification of hyperspectral remote sensing images with support vector machines. En: IEEE Trans. Geoscience and Remote Sensing. Vol; 42, No 8 (2004); p, 1778–1790.

PROTTER M, et al. Generalizing the Nonlocal-Means to Super-Resolution Reconstruction. En: IEEE Transactions on Image Processing. Vol. 18, No.1 (December 2008).

ROWE R, NIXON K, and CORCORAN S. Multispectral fingerprint biometrics. En: In Proc. Info. Assurance Workshop. 2005.

SHAW G.A, and BURKE H.K., Spectral Imaging for Remote Sensing. En: Lincoln Laboratory Journal. Vol; 14, No. 1 (2003). pp. 3-27.

UNDERWOOD E, USTIN S., and DIPIETRO D. Mapping nonnative plants using hyperspectral imagery. En: Remote Sensing of Environment. Vol; 86, No 2 (2003); p. 150–161.

ZHANG L. and WU X. An edge-guided image interpolation algorithm via directional filtering and data fusion. En: IEEE Trans. Image Process. Vol; 15, No. 8 (Aug. 2006); p. 2226–2238.