

ALGORITMO ITERATIVO DE RECONSTRUCCIÓN DE IMÁGENES
ESPECTRALES CONSIDERANDO EL DESAJUSTE DEL SISTEMA ÓPTICO
MEDIANTE UN REGULARIZADOR DE REFUERZO

YESID ROMARIO GUALDRÓN HURTADO

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FISICOMECÁNICAS
ESCUELA DE INGENIERÍA DE SISTEMAS E INFORMÁTICA
BUCARAMANGA

2023

ALGORITMO ITERATIVO DE RECONSTRUCCIÓN DE IMÁGENES
ESPECTRALES CONSIDERANDO EL DESAJUSTE DEL SISTEMA ÓPTICO
MEDIANTE UN REGULARIZADOR DE REFUERZO

YESID ROMARIO GUALDRÓN HURTADO

Trabajo de Grado para optar al título de
Ingeniero de Sistemas

Director:

Jorge Luis Bacca Quintero
Ph.D. Computer Science

Codirector:

Henry Arguello Fuentes
Ph.D. Electrical and Computer Engineering

UNIVERSIDAD INDUSTRIAL DE SANTANDER
FACULTAD DE INGENIERÍAS FISICOMECAÑICAS
ESCUELA DE INGENIERÍA DE SISTEMAS E INFORMÁTICA
BUCARAMANGA

2023

DEDICATORIA

*A mi mami,
porque a pesar de todo
siempre me ha apoyado, amado y entendido,
y ha sido la mejor mamá posible en estos 20 años.*

*A mi Pau,
por su amor, apoyo, sacrificio,
comprensión, revisión, escritura, edición
y porque sé lo difícil que ha sido este proceso para los dos.*

Y a las dos, por nunca haberme dejado solo y ser lo mejor que tengo, las amo.

AGRADECIMIENTOS

Agradezco a mi director Jorge Bacca, en especial por su compromiso y paciencia.

Al grupo de investigación HDSP y al profesor Henry Arguello, por permitirme ser parte activa de su comunidad académica.

A mi madre, a Paula y a Doggy, por su apoyo, comprensión y cariño durante este proceso.

A todos quiénes de forma directa e indirecta me ayudaron durante estos 8 semestres en la consecución de este objetivo.

CONTENIDO

	pág.
INTRODUCCIÓN	12
1 OBJETIVOS	16
2 MARCO DE REFERENCIA	17
2.1 IMÁGENES ESPECTRALES	17
2.2 MÉTODOS DE ADQUISICIÓN POR BARRIDO	18
2.2.1 Barridos por punto espectral (<i>Whiskbroom</i>).	19
2.2.2 Barrido por fila espectral (<i>Pushbroom</i>).	19
2.2.3 Captura por banda espectral (<i>Filter wheel</i>).	19
2.3 MÉTODOS DE ADQUISICIÓN INSTANTÁNEOS	20
2.3.1 Sistema de adquisición de imágenes espectrales instantáneas de apertura codificada (CASSI).	22
2.4 PROBLEMAS INVERSOS	23
2.5 ALGORITMOS DE RECONSTRUCCIÓN	24
2.5.1 Método de los multiplicadores de dirección alterna (ADMM).	24
2.5.2 <i>Plug-and-Play</i> (PnP).	25
2.6 APRENDIZAJE PROFUNDO	26
2.6.1 Red neuronal convolucional (CNN).	27
2.6.2 Red neuronal residual (ResNet).	27
2.6.3 Arquitectura U-Net.	28
2.6.4 Métodos de reconstrucción que consideran el desajuste del modelamiento.	29

3 METODOLOGÍA	31
3.1 PROBLEMA DE CALIBRACIÓN	31
3.2 ALGORITMO ITERATIVO DE RECONSTRUCCIÓN DE IMÁGENES ESPECTRALES CONSIDERANDO EL DESAJUSTE DEL SISTEMA ÓPTICO MEDIANTE UN REGULARIZADOR DE REFUERZO	38
4 RESULTADOS	42
4.1 SIMULACIONES	44
4.1.1 Modelo de adquisición propuesto.	48
4.1.2 Reconstrucciones bajo diferentes niveles de degradación.	49
4.1.3 Reconstrucciones bajo diferentes niveles de ruido.	57
4.2 EXPERIMENTACIÓN	59
4.2.1 Modelo de adquisición propuesto.	65
4.2.2 Reconstrucciones bajo diferentes niveles de emulación.	66
5 CONCLUSIONES	71
6 TRABAJO FUTURO	72
BIBLIOGRAFÍA	73

LISTA DE FIGURAS

	pág.
Figura 1 Representación gráfica de una imagen espectral y la firma espectral de un píxel.	17
Figura 2 Métodos de adquisición de imágenes espectrales. (a) Escaneo de puntos. (b) Escaneo de líneas. (c) Escaneo de longitudes de onda.	20
Figura 3 Flujo de captura en CASSI.	23
Figura 4 Matriz de adquisición en CASSI con $N = M = 6, L = 5$.	23
Figura 5 Arquitectura de red neuronal residual ResNet.	28
Figura 6 Arquitectura de red neuronal convolucional U-Net.	29
Figura 7 Implementación del CASSI en el Laboratorio de óptica HDSP.	32
Figura 8 Comparación entre la apertura codificada simulada y fabricada.	32
Figura 9 Dispersión no precisa de los píxeles debido al prisma, resultando en la afectación de píxeles vecinos al integrar en el sensor.	33
Figura 10 Desplazamiento no lineal de la luz causado por el prisma.	34
Figura 11 Contraste entre la simulación y lo obtenido en laboratorio.	34
Figura 12 Montaje del sistema óptico CASSI con información adicional.	37
Figura 13 Imágenes presentes en el conjunto de datos ARAD 2022.	45
Figura 14 Gráficas de los valores de la frecuencia de paso por cada nivel de degradación en las simulaciones usado como parámetro para el filtro <i>lowpass</i> de Matlab.	46
Figura 15 Filtros por cada nivel de degradación en las simulaciones.	47
Figura 16 Filtro espectral convolucionado que simula la dispersión del prisma.	47

Figura 17	Ejemplo de la degradación efectuada por el filtro <i>lowpass</i> y el filtro de dispersión; y la resultante de añadirle el ruido gaussiano blanco de 25 SNR con la función <i>awgn</i> de Matlab.	47
Figura 18	Métricas evaluadas vs. Coeficiente del término propuesto.	49
Figura 19	PSNR vs. degradación de las medidas sintéticas.	52
Figura 20	SSIM vs. degradación de las medidas sintéticas.	52
Figura 21	SAM vs. degradación de las medidas sintéticas.	53
Figura 22	Métrica ponderada vs. degradación de las medidas sintéticas.	53
Figura 23	Comparación entre las reconstrucciones para distintos niveles de degradación.	55
Figura 24	Comparación entre las firmas espectrales para distintos niveles de degradación.	56
Figura 25	Medidas comprimidas con adición de diferentes valores de SNR.	57
Figura 26	Comparación de reconstrucciones a partir de medidas comprimidas con adición de diferentes valores de SNR.	58
Figura 27	Análisis de la robustez al ruido utilizando las 4 métricas evaluadas.	59
Figura 28	Aperturas codificadas binaria, con información adicional y con sensor CASSI.	61
Figura 29	Imágenes capturadas en el laboratorio de óptica HDSP.	62
Figura 30	Comparación entre las diferentes medidas comprimidas emuladas a partir de la información capturada en el laboratorio.	64
Figura 31	Comparación entre las reconstrucciones para distintos niveles de emulación.	67
Figura 32	Comparación entre las firmas espectrales para distintos niveles de emulación.	68
Figura 33	Influencia espectral del regularizador de refuerzo en las reconstrucciones espectrales.	70

LISTA DE CUADROS

	pág.
Cuadro 1 Métricas obtenidas con las redes de mapeo en las medidas comprimidas simuladas usando la arquitectura U-Net con profundidad de 5.	48
Cuadro 2 Media y desviación estándar de la Métrica ponderada en las medidas comprimidas simuladas.	50
Cuadro 3 Características de los niveles de emulación de la información capturada en el laboratorio.	64
Cuadro 4 Métricas obtenidas con las redes de mapeo en las medidas comprimidas capturadas en el laboratorio en la U-Net con profundidad de 5.	65
Cuadro 5 Métricas obtenidas con las redes de mapeo en las medidas comprimidas capturadas en el laboratorio en la U-Net con profundidad de 7.	65
Cuadro 6 Métricas obtenidas con las redes de mapeo en las medidas comprimidas capturadas en el laboratorio en la U-Net con profundidad de 9.	66
Cuadro 7 Media y desviación estándar de la métrica ponderada en las reconstrucciones experimentales.	69

RESUMEN

TÍTULO: ALGORITMO ITERATIVO DE RECONSTRUCCIÓN DE IMÁGENES ESPECTRALES CONSIDERANDO EL DESAJUSTE DEL SISTEMA ÓPTICO MEDIANTE UN REGULARIZADOR DE REFUERZO *

AUTOR: YESID ROMARIO GUALDRÓN HURTADO **

PALABRAS CLAVE: Imágenes espectrales, reconstrucción, calibración, aprendizaje profundo, regularizador de refuerzo.

DESCRIPCIÓN:

Las imágenes espectrales capturan información espacial a lo largo del espectro electromagnético con un alto costo en tiempos de adquisición. Dichas imágenes pueden ser obtenidas con un sistema óptico basado en capturas instantáneas lo cual reduce el tiempo de adquisición, en comparación con adquirir el cubo de datos espectral, sin embargo, para su reconstrucción se requiere de un proceso computacional. Además, existen diversos fenómenos que por una inadecuada calibración impiden el completo conocimiento del modelo de propagación, el cual es usado para obtener la imagen espectral resolviendo el problema inverso. El presente trabajo de grado muestra el desarrollo de un algoritmo iterativo para la reconstrucción de imágenes espectrales que considere el desajuste y las perturbaciones que se generan en el sistema óptico durante la implementación en el laboratorio mediante un regularizador de refuerzo aprendido. Para esto, se modela matemáticamente la adquisición de imágenes espectrales de un sistema óptico basado en apertura codificada de única captura (CASSI) considerando el problema de desajuste ocurrido en el proceso de calibración. Se realizaron simulaciones bajo distintos escenarios de desajuste junto con la influencia de emplear el regularizador de refuerzo propuesto, el rendimiento de las reconstrucciones fue evaluado bajo distintas métricas de calidad. Se realizó una implementación del sistema óptico para corroborar los resultados obtenidos. De allí se observa que el enfoque propuesto mejora sustancialmente los resultados en términos de las diversas métricas, en comparación con el caso en que se ignora el desajuste del sistema óptico.

* Trabajo de grado

** Facultad de Ingenierías Fisicomecánicas. Escuela de Ingeniería de Sistemas e Informática. Director: Jorge Luis Bacca Quintero. Codirector: Henry Arguello Fuentes.

ABSTRACT

TITLE: ITERATIVE ALGORITHM FOR SPECTRAL IMAGE RECONSTRUCTION CONSIDERING OPTICAL SYSTEM MISMATCH USING A REINFORCEMENT REGULARIZER *

AUTHOR: YESID ROMARIO GUALDRÓN HURTADO **

KEYWORDS: Spectral images, reconstruction, calibration, deep learning, reinforcement regularizer.

DESCRIPTION:

Spectral images capture spatial information along the electromagnetic spectrum with a high cost in acquisition time. These images can be obtained with an optical system based on instantaneous capture snapshots, which reduces the acquisition time compared to acquiring the spectral data cube. However, for their reconstruction, a computational process is required. In addition, several phenomena, due to an inadequate calibration, prevent the complete knowledge of the propagation model, which is used to obtain the spectral image by solving the inverse problem. The present work shows the development of an iterative algorithm for the reconstruction of spectral images that considers the mismatch and the disturbances generated in the optical system during the implementation in the laboratory using a learned reinforcement regularizer. For this purpose, acquiring spectral images from a Coded Aperture Snapshot Spectral Imaging system (CASSI) is mathematically modeled considering the mismatch problem in the calibration process. Simulations were performed under different mismatch scenarios along with the influence of employing the proposed enhancement regularizer, and the performance of the reconstructions was evaluated under different quality metrics. An implementation of the optical system was performed to corroborate the obtained results. It is observed that the proposed approach substantially improves the results regarding the various metrics, compared to the case where the mismatch of the optical system is ignored.

* Bachelor Thesis

** Facultad de Ingenierías Fisicomecánicas. Escuela de Ingeniería de Sistemas e Informática. Advisor: Jorge Luis Bacca Quintero. Co-advisor: Henry Arguello Fuentes

INTRODUCCIÓN

En el área de ciencia e ingeniería, diferentes aplicaciones, como agricultura de alta precisión¹, y en el ámbito militar², requieren el uso de imágenes espectrales por la cantidad de información que pueden aportar de una escena al proveer valores de intensidad en diferentes longitudes de onda. Dicha información resulta valiosa para tareas como clasificación de materiales³. Por ejemplo, en Santander, se han utilizado las imágenes espectrales para determinar el nivel de madurez del aguacate⁴ y clasificar la calidad del cacao⁵, entre otras tareas.

A pesar de la potencial utilidad de las imágenes espectrales, éstas no han sido ampliamente usadas en Colombia debido al costo temporal de la adquisición con métodos tradicionales de escaneo, por lo que se han desarrollado diferentes alternativas como los sistemas óptico-computacionales cuyo objetivo es reducir el tiempo y el almacenamiento requerido para obtener la información espectral de cada escena.

Un ejemplo de estos sistemas óptico-computacionales es el Sistema de Adquisición de Imágenes Espectrales Instantáneas de Apertura Codificada (CASSI, por sus si-

¹ Yannick Lanthier y col. «Hyperspectral data segmentation and classification in precision agriculture: A multi-scale analysis». En: *IGARSS 2008-2008 IEEE International Geoscience and Remote Sensing Symposium*. Vol. 2. IEEE. 2008, págs. II-585.

² X Briottet y col. «Military applications of hyperspectral imagery». En: *Targets and backgrounds XII: Characterization and representation*. Vol. 6239. SPIE. 2006, págs. 82-89.

³ Andrew Hennessy, Kenneth Clarke y Megan Lewis. «Hyperspectral classification of plants: A review of waveband selection generalisability». En: *Remote Sensing* 12.1 (2020), pág. 113.

⁴ Jhon Pinto, Hoover Rueda-Chacón y Henry Arguello. «Classification of Hass avocado (persea americana mill) in terms of its ripening via hyperspectral images». En: *TecnoLógicas* 22.45 (2019), págs. 111-130.

⁵ Karen Sánchez y col. «Classification of cocoa beans based on their level of fermentation using spectral information». En: *TecnoLógicas* 24.50 (2021), págs. 172-188.

glas en inglés). El sistema CASSI empleado en esta investigación se compone de lentes para focalizar la escena, un dispositivo digital de microespejos (DMD) que bloquea o deja pasar píxeles, un prisma que dispersa las diferentes longitudes de onda y el sensor monocromático que integra la luz incidente.

La razón principal de la reducción en el tiempo de adquisición es que dichos sistemas adquieren una proyección sin necesidad de escanear la escena, sin embargo, se necesita un paso posterior de procesamiento para obtener la imagen espectral. Para la reconstrucción se requiere del modelamiento matemático del sistema óptico como una matriz de adquisición, la cual se emplea en un algoritmo que recuperará la información espectral a partir de las medidas comprimidas.

El modelado del sistema de adquisición teórico y el sistema de adquisición real presentan discrepancias debido a asunciones sobre fenómenos físicos e imprecisiones en el montaje experimental del sistema, que pueden ser reducidas mediante un proceso conocido como calibración. Dicho desajuste dificulta el proceso de reconstrucción pues al ser un problema inverso, y un sistema mal condicionado⁶, existen infinitas imágenes espectrales posibles. Por lo tanto, para reconstruir la imagen espectral es necesario reducir el espacio de soluciones considerando el problema de calibración.

En este trabajo, se eligió el sistema CASSI con el fin de evaluar la capacidad del método propuesto para mejorar las reconstrucciones a partir de la consideración del desajuste en la calibración. Para el sistema CASSI, se han desarrollado diferentes trabajos con el fin de considerar las aberraciones ópticas. Algunos trabajos han modificado el sistema de propagación haciendo asunciones más realistas, como

⁶ Un sistema mal condicionado se refiere a que un ligero cambio en la matriz de adquisición genera un gran cambio en su solución.

considerar la dispersión no perfectamente horizontal del prisma⁷. En otro trabajo⁸, se hace una estimación de la función de dispersión de puntos (PSF, por sus siglas en inglés), la cuál permite estimar la respuesta del sistema.

Esta investigación propone aprender el modelo de calibración presente en el sistema óptico CASSI mediante el uso de aprendizaje profundo, para ser empleado en un algoritmo de reconstrucción, como un regularizador de refuerzo. Para esto, se simuló el proceso de captura con diferentes niveles de degradación con el fin de analizar el comportamiento. Se realizaron las simulaciones haciendo uso del conocimiento presente en el estado del arte del sistema óptico CASSI, como el comportamiento de sus diferentes componentes ópticos, el proceso de calibración del sistema óptico, las condiciones matemáticas de la matriz de adquisición y las diferentes aberraciones ópticas que se han estudiado. Posteriormente se contrastó con el fenómeno real al realizar el proceso de captura en el laboratorio con el sistema óptico implementado. Por lo anterior, en la investigación se desarrolla un algoritmo iterativo que permite la reconstrucción de imágenes espectrales, considerando el desajuste y las perturbaciones que se generan en el sistema óptico durante la implementación en el laboratorio haciendo uso de un regularizador de refuerzo, donde se puede ver una mejora considerable comparado con la función de costo tradicional.

Este trabajo tiene la siguiente organización de su contenido: Se presentan los objetivos en la sección 1. Luego, la sección 2 abarca el marco de referencia; en ella se describen las imágenes espectrales, sus aplicaciones y algunos métodos de adquisición con el fin de vislumbrar el funcionamiento de las tecnologías. Adicionalmente se presenta el sistema óptico seleccionado, su descripción y modelamiento. Poste-

⁷ Henry Arguello y col. «Higher-order computational model for coded aperture spectral imaging». En: *Applied optics* 52.10 (2013), págs. D12-D21.

⁸ Lingfei Song y col. «High-Accuracy Image Formation Model for Coded Aperture Snapshot Spectral Imaging». En: *IEEE Transactions on Computational Imaging* 8 (2022), págs. 188-200.

rior a esto, se muestran algunos enfoques y algoritmos utilizados en el estado del arte para resolver el problema inverso de reconstrucción de imágenes espectrales. Allí también se presenta algunas redes neuronales de aprendizaje profundo que han sido usadas para resolver este tipo de problemas. En la sección 3 se encuentra la metodología propuesta. La cual contiene la descripción del problema de calibración presente en el sistema óptico CASSI, posteriormente se presenta el problema de optimización, el algoritmo propuesto y sus componentes como la red de mapeo entre medidas comprimidas con diferente calibración, la red de reconstrucción, y el algoritmo de reducción del ruido. Los resultados obtenidos a partir de las simulaciones y las adquisiciones en el laboratorio de óptica, con su respectivo análisis, se observan a lo largo de la sección 4.

1. OBJETIVOS

Objetivo general

- Desarrollar un algoritmo iterativo para la reconstrucción de imágenes espectrales considerando el desajuste y las perturbaciones que se generan en el sistema óptico durante la implementación en el laboratorio mediante un regularizador de refuerzo.

Objetivos específicos

1. Modelar matemáticamente la adquisición de imágenes espectrales de un sistema óptico basado en apertura codificada de única captura (CASSI) considerando el problema de desajuste ocurrido en el proceso de calibración.
2. Simular el desajuste entre las medidas simuladas y las obtenidas del sistema óptico de adquisición espectral experimentable en el laboratorio.
3. Desarrollar e implementar un algoritmo iterativo que incluya aprendizaje profundo y un regularizador de refuerzo para la corrección del desajuste y perturbaciones del sistema óptico.
4. Evaluar el rendimiento del método propuesto al reconstruir imágenes espectrales con un sistema compresivo espectral simulado e implementado en el laboratorio HDSP.

2. MARCO DE REFERENCIA

2.1. IMÁGENES ESPECTRALES

Las imágenes espectrales son conjuntos de información de tres dimensiones, dos de ellas espaciales y una espectral, como se observa en la figura 1. Dichas imágenes son representables como un cubo de datos el cual contiene información de las longitudes de onda específicas del espectro electromagnético de una escena.

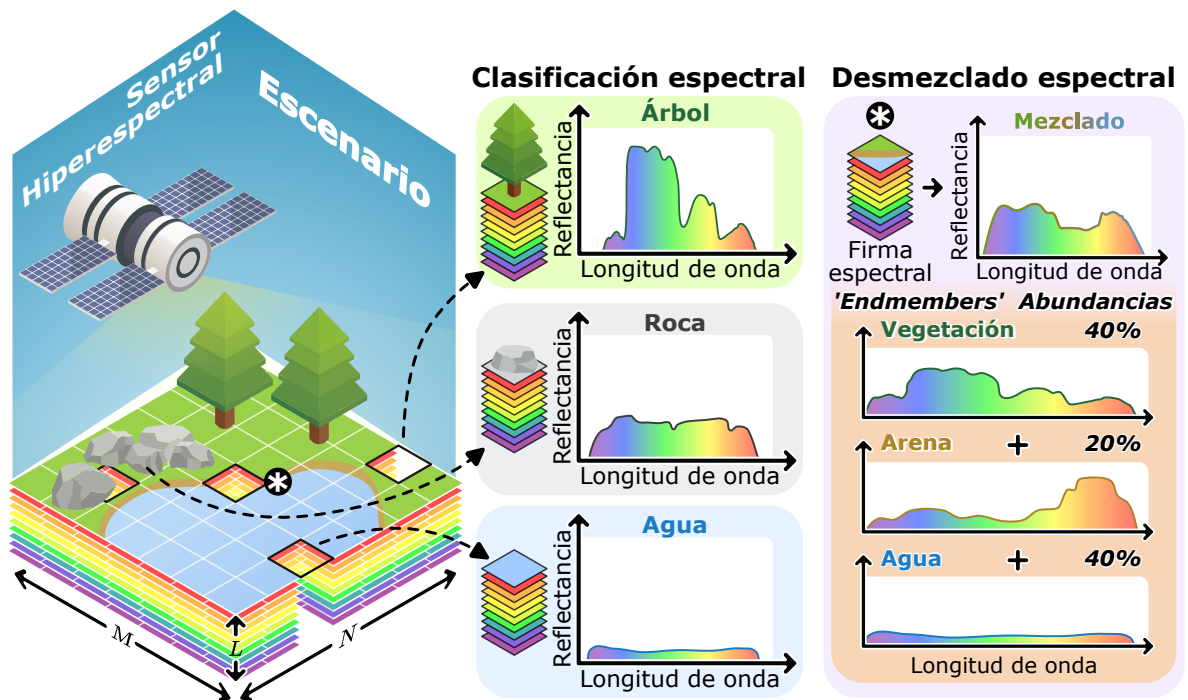


Figura 1. Representación gráfica de una imagen espectral y la firma espectral de un . Adaptada de ¹¹.

Las imágenes espectrales han sido utilizadas en diferentes áreas del conocimiento, ya que permiten analizar la composición química de los materiales presentes en la

escena⁹, condiciones atmosféricas¹⁰, entre otros¹¹.

La información aportada por las imágenes espectrales es adicional a la que puede percibir el ojo humano y a la capturada por los sensores RGB tradicionales, ya que estos solo abarcan 3 longitudes de onda de todo el espectro electromagnético¹².

Trabajos explorados en¹³, han demostrado que todos los materiales tienen una firma espectral única, que puede ser definida como la radiación reflejada por el material en función de la longitud de onda analizada, por lo que a medida que se aumenta la cantidad de longitudes de onda capturadas, se reduce la complejidad en tareas de clasificación o detección de materiales bajo condiciones ideales de adquisición¹⁴.

2.2. MÉTODOS DE ADQUISICIÓN POR BARRIDO

Distintos métodos que permiten capturar información de múltiples longitudes de onda han sido propuestos a través de los años, los cuales se diferencian en sus arquitecturas y tiempos de adquisición, siendo los siguientes los más característicos del

⁹ Paul Robert y col. «Identification of chemical constituents by multivariate near-infrared spectral imaging». En: *Analytical chemistry* 64.6 (1992), págs. 664-667.

¹⁰ Bernard Ogorzalek y col. «SSUSI-Lite: a far-ultraviolet hyper-spectral imager for space weather remote sensing». En: *Solar Physics and Space Weather Instrumentation VI*. Vol. 9604. SPIE. 2015, pág. 960402.

¹¹ Gary A Shaw y Hsiaohua K Burke. «Spectral imaging for remote sensing». En: *Lincoln laboratory journal* 14.1 (2003), págs. 3-28.

¹² Dragos Miha y Eugen Strajescu. «FROM WAVELENGTH TO RGB FILTER». En: *University "Politehnica" of Bucharest Scientific Bulletin, Series D: Mechanical Engineering* 69.2 (2007), págs. 77-84.

¹³ John C. Price. «How unique are spectral signatures?» En: *Remote Sensing of Environment* 49.3 (1994), págs. 181-186. DOI: [https://doi.org/10.1016/0034-4257\(94\)90013-2](https://doi.org/10.1016/0034-4257(94)90013-2).

¹⁴ Graham R Hunt. «Spectral signatures of particulate minerals in the visible and near infrared». En: *Geophysics* 42.3 (1977), págs. 501-513; Chuin-Mu Wang y col. «Detection of spectral signatures in multispectral MR images for classification». En: *IEEE Transactions on Medical Imaging* 22.1 (2003), págs. 50-61.

estado del arte¹⁵.

2.2.1. Barridos por punto espectral (*Whiskbroom*). Este sistema realiza la adquisición de la imagen espectral de forma secuencial, píxel a píxel, en donde haciendo uso de un espejo que refleja la luz en un único detector al momento de la captura, se recopila la información de cada píxel mediante un movimiento de ida y vuelta, como se muestra en la figura 2 (a). Se caracteriza por su simplicidad óptica y su complejidad mecánica, y requiere de un tiempo de captura considerable al hacer un escaneo para cada píxel¹⁶.

2.2.2. Barrido por fila espectral (*Pushbroom*). Esta arquitectura, representada en la figura 2 (b), consiste en capturar cada fila espectral por medio de un arreglo de lentes que pasa por un prisma que dispersa la luz donde posteriormente un sensor 2D integra la información espectral¹⁷.

2.2.3. Captura por banda espectral (*Filter wheel*). Mediante esta arquitectura, expuesta en la figura 2 (c), es posible capturar una banda espectral haciendo uso de diferentes filtros paso bandas, los cuales realizan un proceso de rotación reflejando longitudes de onda únicas que son capturadas con una cámara monocromática sincronizada¹⁸.

¹⁵ Yu Winston Wang y col. «Multiplexed optical imaging of tumor-directed nanoparticles: a review of imaging systems and approaches». En: *Nanotheranostics* 1.4 (2017), pág. 369.

¹⁶ Rajiv Gupta y Richard I Hartley. «Linear pushbroom cameras». En: *IEEE Transactions on pattern analysis and machine intelligence* 19.9 (1997), págs. 963-975.

¹⁷ C Martijn de Sterke. «Optical push broom». En: *Optics letters* 17.13 (1992), págs. 914 -916.

¹⁸ Nahum Gat. «Imaging spectroscopy using tunable filters: a review». En: *Wavelet Applications VII* 4056 (2000), págs. 50-64.

Cabe resaltar que las metodologías mencionadas son basadas en escaneo, lo que requiere altos tiempos de adquisición y limita el uso de las imágenes espectrales en escenas dinámicas.

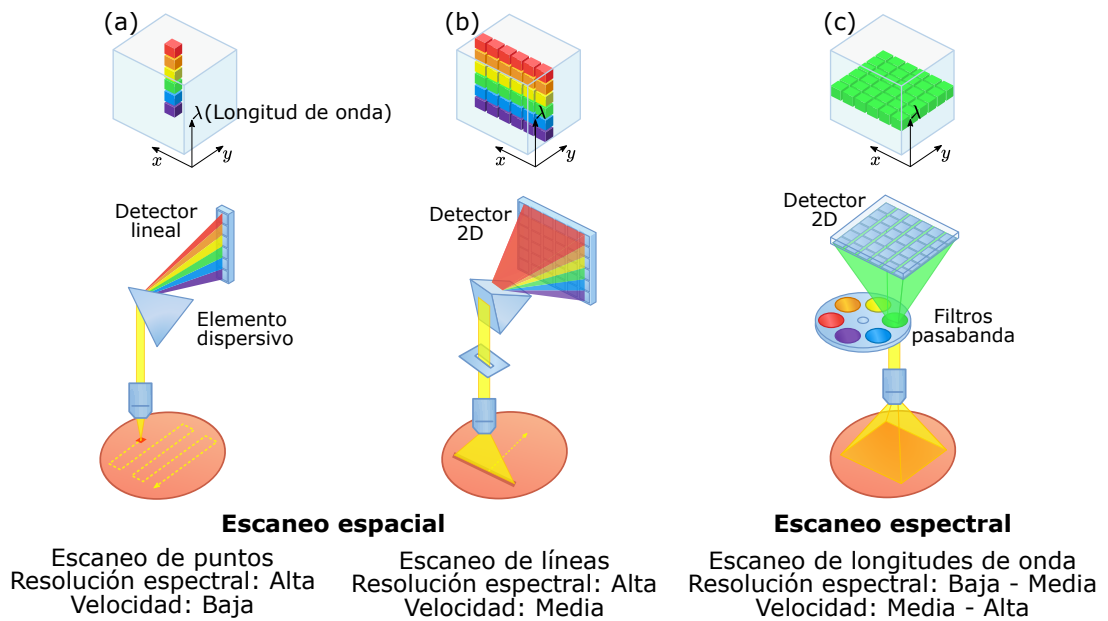


Figura 2. Métodos de adquisición de imágenes espectrales. (a) Escaneo de puntos. (b) Escaneo de líneas. (c) Escaneo de longitudes de onda. Adaptada de ¹⁴.

2.3. MÉTODOS DE ADQUISICIÓN INSTANTÁNEOS

Las limitaciones de las arquitecturas previamente mencionadas pueden ser contrarrestadas si se hace uso de la teoría de muestreo compresivo¹⁹. Dicha teoría consiste en la reconstrucción de la información espectral de la escena mediante una o varias medidas comprimidas en escala de grises y se sustenta en los principios de escasez e incoherencia.

El proceso de adquisición de la medida comprimida, puede ser representado de forma lineal, como se evidencia en la ecuación siguiente:

¹⁹ Emmanuel J Candès y Michael B Wakin. «An introduction to compressive sampling». En: *IEEE signal processing magazine* 25.2 (2008), págs. 21-30.

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

donde, en términos generales, $\mathbf{y} \in \mathbb{R}^M$ representa las medidas comprimidas capturadas vectorizadas, $\mathbf{H} \in \mathbb{R}^{M \times N}$ la matriz de adquisición donde $M < N$, $\mathbf{x} \in \mathbb{R}^N$ es la imagen de entrada al sistema óptico en forma vectorizada, además, ϵ representa el ruido presente en el sistema óptico al momento de la captura.

La escasez indica que es posible representar la señal de interés con pocos coeficientes, ya que, en la base de representación apropiada, gran parte de sus valores son despreciables. Matemáticamente, la señal \mathbf{x} puede ser representada en una base ortonormal $\Phi \in \mathbb{R}^{N \times N}$ con el fin de obtener una imagen con menor densidad de información haciendo uso de la propiedad de escasez, expresado así:

$$\mathbf{x} = \Phi\boldsymbol{\theta}, \quad (2)$$

donde $\boldsymbol{\theta} \in \mathbb{R}^N$, con $\|\boldsymbol{\theta}\|_0 = s$.

Lo mencionado anteriormente da la posibilidad de reducir la cantidad de información sin pérdida sustancial de calidad²⁰, ya que se cumple la siguiente igualdad

$$\|\mathbf{x} - \mathbf{x}_s\|_2 = \|\Phi\boldsymbol{\theta} - \Phi\boldsymbol{\theta}_s\|_2, \quad (3)$$

donde el subíndice s indica que se conservarán esa cantidad de valores y los demás se anularán.

El muestreo incoherente denota la baja correlación entre la base de adquisición y la base de representación, permitiendo así la reducción de las mediciones necesarias

²⁰ Emmanuel Candes y Justin Romberg. «Sparsity and incoherence in compressive sampling». En: *Inverse problems* 23.3 (2007), pág. 969.

para la captura de una señal²¹.

La coherencia mide la mayor correlación entre dos elementos de las matrices de adquisición y representación, su rango de valores es $[1, \sqrt{N}]$ y se define mediante la ecuación:

$$\mu(\mathbf{H}, \Phi) = \sqrt{N} \cdot \max_{1 \leq k, j \leq N} |\langle \mathbf{H}_k, \Phi_j \rangle|. \quad (4)$$

donde \mathbf{H}_k y Φ_j son las columnas de \mathbf{H} y las filas de Φ , respectivamente. El valor deseado de la coherencia es el mínimo, con el fin de que no exista correlación entre las matrices mencionadas.

2.3.1. Sistema de adquisición de imágenes espectrales instantáneas de apertura codificada (CASSI). Es una arquitectura que detecta de manera eficaz la información espectral de una escena, utilizando una medición instantánea de proyección aleatoria codificada en una matriz de plano focal codificado (FPA) o detector bidimensional, y un elemento dispersivo conocido como prisma. Normalmente, la salida discretizada en el detector CASSI se modela como la suma de los valores espectrales de píxeles vecinos modulados por una apertura codificada y dispersados espacialmente por un prisma. Para recuperar la información espectral a partir de la medida comprimida se busca la aproximación más escasa con distancia euclidiana mínima.

En la figura 3, se muestra el flujo que sigue la información durante el proceso de captura en CASSI, desde la escena hasta su integración en el detector²².

²¹ Candès y Wakin, ver n. 19.

²² Xun Cao y col. «Computational snapshot multispectral cameras: Toward dynamic capture of the spectral world». En: *IEEE Signal Processing Magazine* 33.5 (2016), págs. 95-108.




Figura 3. Flujo de captura en CASSI. Adaptada de ²².

El presente trabajo se enfocará en corregir los errores de calibración del CASSI. Específicamente, en este sistema óptico, la matriz de adquisición es $\mathbf{H} \in \mathbb{R}^{N(M+L-1) \times NML}$, donde N y M son las dimensiones espaciales, y L representa la cantidad de longitudes de onda capturadas. como se observa en la figura 4. Los elementos en la diagonal representan la apertura codificada para cada banda espectral.

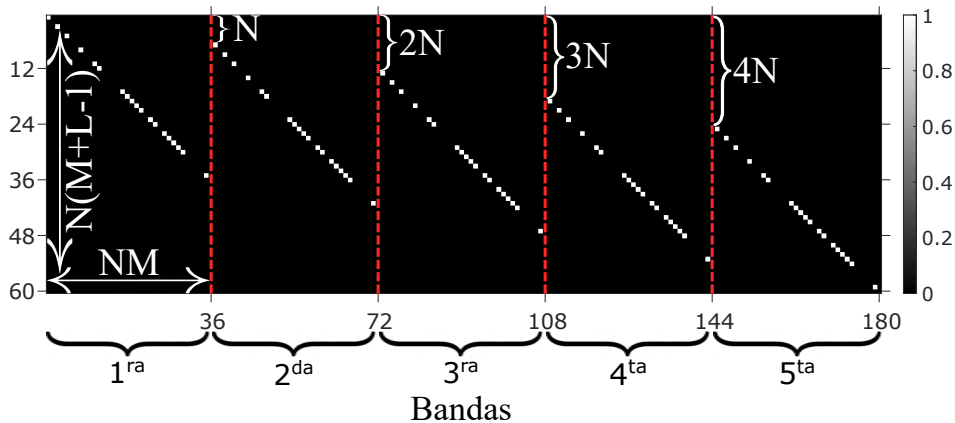


Figura 4. Matriz de adquisición en CASSI con $N = M = 6$, $L = 5$. Adaptada de ⁷.

2.4. PROBLEMAS INVERSOS

El problema de recuperar una señal desconocida $\mathbf{x} \in \mathbb{R}^{NML}$ a partir de sus medidas comprimidas $\mathbf{y} \in \mathbb{R}^{N(M+L-1)}$ es considerado un sistema mal condicionado²³, que se

²³ Shirin Shoushtari y col. «Deep Model-Based Architectures for Inverse Problems under Mismatched Priors». En: *arXiv preprint arXiv:2207.13200* (2022).

suele resolver utilizando un problema inverso con restricciones. La señal \mathbf{x} puede ser estimada si se resuelve un problema de optimización

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x} \in \mathbb{R}^N} \{g(\mathbf{x}) + h(\mathbf{x})\}. \quad (5)$$

con $g(\mathbf{x})$ como el término de fidelidad de los datos procurando la consistencia de la solución con las medidas comprimidas. Usualmente se utiliza la norma l_2 , $\|\mathbf{y} - \mathbf{H}\mathbf{x}\|_2$ y $h(\mathbf{x})$ es el regularizador que aprovecha la información previa y asunciones realizadas sobre la variable a estimar, \mathbf{x} , que puede usarse para garantizar escasez u otras propiedades basadas en la información a priori que se tenga de la señal a reconstruir.

2.5. ALGORITMOS DE RECONSTRUCCIÓN

2.5.1. Método de los multiplicadores de dirección alterna (ADMM). La metodología ADMM²⁴, se basa en separar un problema en múltiples subproblemas desde un enfoque de divide-y-vencerás²⁵. Dicha técnica puede ser usada para solucionar problemas inversos en muestreo compresivo²⁶ al introducir una variable de división del problema, \mathbf{z} , como

$$\min_{\mathbf{s}, \mathbf{z} \in \mathbb{R}^N} \left\{ \frac{1}{2} \|\mathbf{y} - \mathbf{H}\mathbf{x}\|_2^2 + \lambda f(\mathbf{z}) \right\} \text{ sujeto a } \mathbf{x} = \mathbf{z}. \quad (6)$$

²⁴ Stephen Boyd y col. «Distributed optimization and statistical learning via the alternating direction method of multipliers». En: *Foundations and Trends® in Machine learning* 3.1 (2011), págs. 1-122.

²⁵ Jon Louis Bentley. «Multidimensional divide-and-conquer». En: *Communications of the ACM* 23.4 (1980), págs. 214-229.

²⁶ Ryo Hayakawa. «Asymptotic analysis of ADMM for compressed sensing». En: *arXiv preprint arXiv:2009.08545* (2020).

Para resolver 6 se suele plantear el Lagrangiano aumentado e incorporar la variable dual \mathbf{w}

$$L_\rho(x, z, y) = \frac{1}{2} \|\mathbf{y} - \mathbf{H}\mathbf{x}\|_2^2 + \lambda f(\mathbf{z}) + \frac{\rho}{2} \|\mathbf{x} - \mathbf{z} + \mathbf{w}\|_2^2. \quad (7)$$

ADMM divide los problemas de optimización en pasos de actualización alternados con el fin de solucionarlos de la siguiente forma

$$\begin{aligned} \mathbf{x}^{(k+1)} &= \arg \min_{\mathbf{x} \in \mathbb{R}^N} \left\{ \frac{1}{2} \|\mathbf{y} - \mathbf{H}\mathbf{x}\|_2^2 + \frac{\rho}{2} \|\mathbf{x} - \mathbf{z}^{(k)} + \mathbf{w}^{(k)}\|_2^2 \right\} \\ &= (\mathbf{H}^\top \mathbf{H} + \rho \mathbf{I})^{-1} (\mathbf{H}^\top \mathbf{y} + \rho (\mathbf{z}^{(k)} - \mathbf{w}^{(k)})) \end{aligned} \quad (8)$$

$$\begin{aligned} \mathbf{z}^{(k+1)} &= \arg \min_{\mathbf{z} \in \mathbb{R}^N} \left\{ \lambda f(\mathbf{z}) + \frac{\rho}{2} \|\mathbf{x}^{(k+1)} - \mathbf{z} + \mathbf{w}^{(k)}\|_2^2 \right\} \\ &= \text{prox}_{\frac{\lambda}{\rho} f} (\mathbf{x}^{(k+1)} + \mathbf{w}^{(k)}) \end{aligned} \quad (9)$$

$$\mathbf{w}^{(k+1)} = \mathbf{w}^{(k)} + \mathbf{x}^{(k+1)} - \mathbf{z}^{(k+1)} \quad (10)$$

permitiendo dividir el problema de optimización original en varios subproblemas, los cuales se pueden resolver haciendo uso de soluciones ya conocidas y/o algoritmos empleados en la literatura para la solución de dicho subproblema, como es el caso del *proximal operator* en la ecuación 9.

2.5.2. Plug-and-Play (PnP). La arquitectura *Plug-and-Play*²⁷, permite la combinación de algoritmos de eliminación de ruido (*denoisers*) con métodos de inversión, lo que posibilita la simplificación de la integración algorítmica y permite que los *denoisers* puedan ser usados en la solución de un problema de optimización. Específicamente, la ecuación 9 se convierte en:

²⁷ Singanallur V Venkatakrishnan, Charles A Bouman y Brendt Wohlberg. «Plug-and-play priors for model based reconstruction». En: *2013 IEEE Global Conference on Signal and Information Processing*. IEEE. 2013, págs. 945-948.

$$\mathbf{z}^{(k+1)} = \text{Denoiser}(\mathbf{x}^{(k+1)} + \mathbf{w}^{(k)}). \quad (11)$$

Dicho *denoiser* puede ser variación total (TV)²⁸, medias no locales (NLM)²⁹, emparejamiento de bloques y filtrado 3D (BM3D)³⁰ y filtro recursivo (RF)³¹, entre otros.

2.6. APRENDIZAJE PROFUNDO

En los últimos años, el aprendizaje profundo ha tenido un gran impacto en la resolución de diversos problemas, incluyendo los problemas inversos. Un modelo de aprendizaje profundo consta de capas de procesamiento interconectadas formadas por unidades llamadas neuronas. Estas neuronas emplean módulos de aprendizaje lineales y no lineales de los datos de entrada, $\{(\mathbf{x}_i, c_i)\}_{i=1}^N$, donde c_i son las etiquetas en un aprendizaje supervisado, por medio de pesos y producen salidas que representan estimaciones de la tarea a aprender. El aprendizaje consiste en entrenar y actualizar iterativamente estos pesos para obtener el error mínimo entre las etique-

²⁸ Felix Kraher, Christian Kruschel y Michael Sandbichler. «Total variation minimization in compressed sensing». En: *Compressed sensing and its applications*. Springer, 2017, págs. 333-358; Clarice Poon. «On the role of total variation in compressed sensing». En: *SIAM Journal on Imaging Sciences* 8.1 (2015), págs. 682-720.

²⁹ Antoni Buades, Bartomeu Coll y J-M Morel. «A non-local algorithm for image denoising». En: *2005 IEEE computer society conference on computer vision and pattern recognition (CVPR'05)*. Vol. 2. Ieee. 2005, págs. 60-65.

³⁰ Kostadin Dabov y col. «Image denoising by sparse 3-D transform-domain collaborative filtering». En: *IEEE Transactions on image processing* 16.8 (2007), págs. 2080 -2095; Xiaojun Yuan y col. «The application of plug-and-play ADMM framework and BM3D denoiser for compressed sensing MR image reconstruction». En: *International Journal of Computer Applications in Technology* 65.4 (2021), págs. 304-315.

³¹ Eduardo SL Gastal y Manuel M Oliveira. «Domain transform for edge-aware image and video processing». En: *ACM SIGGRAPH 2011 papers*. 2011, págs. 1-12; Stanley H Chan, Xiran Wang y Omar A Elgendy. «Plug-and-play ADMM for image restoration: Fixed-point convergence and applications». En: *IEEE Transactions on Computational Imaging* 3.1 (2016), págs. 84-98.

tas de datos de entrada y la salida estimada³². Se puede describir como,

$$\{f_{\theta}(\mathbf{x}) = \sigma_L(\mathbf{W}_L \sigma_{L-1}(\mathbf{W}_{L-1}(\dots \sigma_2(\mathbf{W}_2 \sigma_1(\mathbf{W}_1 \mathbf{x})))) \mid \theta = \{\mathbf{W}_1 \dots \mathbf{W}_L\}\} \quad (12)$$

donde σ_{ℓ} , $1 \leq \ell \leq L$, representa una función no lineal en cada capa, y \mathbf{W}_{ℓ} la matriz de pesos.

El error se puede calcular usando una función de costo $\mathcal{L}(c_i, f_{\theta}(\mathbf{x}_i))$. La cual puede cambiar con respecto a la tarea que se está aprendiendo, produciendo un error de estimación que se propaga a través de las capas de procesamiento, mediante el algoritmo de *back-propagation*.

2.6.1. Red neuronal convolucional (CNN). Una CNN es un tipo de red neuronal que realiza un aprendizaje profundo, pero los datos a entrenar se procesan a partir de matrices y las capas se componen de filtros convolucionales con una o más dimensiones. Estas redes se utilizan comúnmente para tareas de clasificación. Su arquitectura lo hace muy útil para las tareas de procesamiento de señales, secuencias de imágenes o vídeos³³.

2.6.2. Red neuronal residual (ResNet). Las redes residuales, propuestas en³⁴, son un tipo de red neuronal que introduce conexiones de salto en su arquitectura. Esta se basa en la estructura de saltos entre dos o más capas con normalización y sin linealidad entre ellas, reduciendo así la retro-propagación (*back-propagation*)

³² Ian Goodfellow, Yoshua Bengio y Aaron Courville. *Deep learning*. MIT press, 2016.

³³ Laith Alzubaidi y col. «Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions». En: *Journal of big Data* 8 (2021), págs. 1 -74.

³⁴ Kaiming He y col. «Deep residual learning for image recognition». En: *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016, págs. 770-778.

del gradiente a la capa anterior y evitando su desvanecimiento. El comportamiento de esta arquitectura se basa en un bloque denominado bloque residual. Este bloque tiene rutas cuyas entradas se agregan directamente a sus salidas, llamadas conexiones de salto (*skip-connections*)³⁵. En la siguiente figura se muestra una red neuronal residual.




Figura 5. Arquitectura de red neuronal residual ResNet. Adaptada de ⁴³.

2.6.3. Arquitectura U-Net. Una red neuronal convolucional propuesta para resolver problemas de segmentación es la arquitectura U-Net³⁶. La arquitectura U-Net consta de dos etapas o subredes, una de contracción y otra de expansión. La primera subred, llamada *encoder*, actúa como extractor de características para aprender y obtener representaciones de las imágenes de entrada, cada bloque contiene tres capas convolucionales. Seguido a esto, por medio de un conexión de salto se realizan dos convoluciones para luego pasar a la subred de expansión, o *decoder*. En el *decoder* se realiza una secuencia doble de una convolución transpuesta y dos convoluciones adicionales. Por último hay una capa con una función sigmoide de activación que finalmente produce una máscara de segmentación. La arquitectura U-Net propuesta originalmente se muestra a continuación.

³⁵ Andreas Veit, Michael J Wilber y Serge Belongie. «Residual networks behave like ensembles of relatively shallow networks». En: *Advances in neural information processing systems* 29 (2016).

³⁶ Olaf Ronneberger, Philipp Fischer y Thomas Brox. «U-net: Convolutional networks for biomedical image segmentation». En: *International Conference on Medical image computing and computer-assisted intervention*. Springer. 2015, págs. 234 -241.

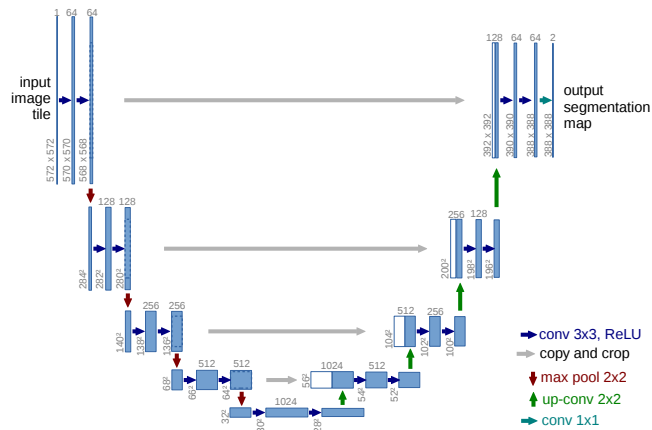


Figura 6. Arquitectura de red neuronal convolucional U-Net. Extraída de ³⁶.

2.6.4. Métodos de reconstrucción que consideran el desajuste del modelamiento.

Un enfoque computacional es propuesto para la auto-calibración de imágenes (deconvolución ciega), conocido como diseño difractivo codificado³⁷, que puede recuperar imágenes de alta calidad más rápido que las técnicas convencionales. Este codiseño de óptica y computación permite obtener imágenes de espectro completo ajustables utilizando ópticas difractivas delgadas. En 2017, fue presentada la arquitectura RED (Regularización por eliminación de ruido)³⁸ para la recuperación de imágenes que busca minimizar un regularizador explícito construido a partir de una función de eliminación de ruido complementaria. Adicionalmente, en otra investigación fue implementada la metodología *Deep Image Prior*³⁹ agregando un *prior* explícito para mejorar el efecto de regularización y conducir a imágenes me-

³⁷ Felix Heide y col. «Encoded diffractive optics for full-spectrum computational imaging». En: *Scientific reports* 6.1 (2016), págs. 1-10.

³⁸ Yaniv Romano, Michael Elad y Peyman Milanfar. «The little engine that could: Regularization by denoising (RED)». En: *SIAM Journal on Imaging Sciences* 10.4 (2017), págs. 1804-1844.

³⁹ Dmitry Ulyanov, Andrea Vedaldi y Victor Lempitsky. «Deep image prior». En: *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2018, págs. 9446-9454.

por recuperadas. Para esto se hace uso del concepto de RED, que aprovecha los eliminadores de ruido existentes para regularizar problemas inversos⁴⁰. Un enfoque más robusto que el lineal es planteado⁴¹, el cual modela la dispersión del prisma de forma no lineal para disminuir la dependencia de la calibración, esto considera la integración de un píxel y la afectación a sus vecinos, pero se hacen algunas asunciones de una dispersión fija que pueden no ser generalizables a implementaciones del mismo sistema óptico, como se muestra en⁴². Un trabajo reciente⁴³, se enfoca en la solución de este problema haciendo uso de la metodología *Deep Image Prior*, obteniendo reconstrucciones con alta resolución espectral, pero debido al enfoque con que fue realizado es dependiente de la escena que se desea reconstruir y no se aprende el modelo de adquisición. Una metodología para aprender el modelo de propagación no lineal es propuesta^{44,45}, pero en este caso, descartan la información que aporta la matriz de adquisición asumida, que debido a sus propiedades matemáticas, aporta información que puede mejorar la calidad de las reconstrucciones.

⁴⁰ Gary Mataev, Peyman Milanfar y Michael Elad. «Deepred: Deep image prior powered by red». En: *Proceedings of the IEEE/CVF International Conference on Computer Vision Workshops*. 2019, págs. 0-0.

⁴¹ Arguello y col., ver n. 7.

⁴² Song y col., ver n. 8.

⁴³ Romario Gualdrón-Hurtado, Jorge Bacca y Henry Arguello. «Compressive Spectral Image Reconstruction by using a Deep Image Prior with a Mismatch Regularizer». En: *Imaging and Applied Optics Congress 2022 (3D, AOA, COSI, ISA, pcAOP)*. Optica Publishing Group, 2022, CW4B.3. DOI: 10.1364/COSI.2022.CW4B.3.

⁴⁴ Jessica Escobar, Jorge Bacca y Henry Arguello. «Non-linear Propagation Model Learning for Coded Aperture Snapshot Spectral Imaging». En: *Computational Optical Sensing and Imaging*. Optica Publishing Group. 2022, CW4B-2.

⁴⁵ Jessica Paola Escobar Pérez. *Aprendizaje de un modelo de propagación no lineal para el sistema óptico de adquisición de imágenes espectrales basado en apertura codificada de única captura (CASSI) a través de redes neuronales profundas*. spa. 2022.

3. METODOLOGÍA

En el presente trabajo, el término desajuste hace referencia a la diferencia entre el modelamiento del sistema óptico mediante la matriz de adquisición asumida y el modelo de adquisición propio del sistema óptico. Adicionalmente, se usa el término de regularizador de refuerzo debido a que este regularizador que se incluye en la función de costo tradicional tiene como objetivo mejorar la calidad de las reconstrucciones en comparación con el estado del arte que no considera dicho desajuste.

3.1. PROBLEMA DE CALIBRACIÓN

Debido al problema de la imposibilidad de lograr una calibración precisa del sistema óptico CASSI, este trabajo parte de la hipótesis de que no es posible conocer el modelo de adquisición, por lo que la aproximación lineal no es lo suficientemente válida, es decir,

$$y \neq \mathbf{H}\mathbf{x} + \epsilon. \quad (13)$$

En la implementación del sistema de adquisición CASSI, que se muestra en la figura 7, existen variedad de alteraciones en los elementos ópticos que sustentan la hipótesis mencionada previamente, en cuanto al modelo de adquisición.

Por ejemplo, el DMD puede contener errores de fabricación o limitaciones tecnológicas, ya que se esperaría que la apertura codificada generada con ruido azul⁴⁶, mantuviera su estructura perfectamente cuadrada y binaria, pero analizando imagen tomada con un microscopio en la figura 8 se observa que esto no es lo que

⁴⁶ Claudia V Correa, Henry Arguello y Gonzalo R Arce. «Spatiotemporal blue noise coded aperture design for multi-shot compressive spectral imaging». En: *JOSA A* 33.12 (2016), págs. 2312-2322.

realmente sucede⁴⁷.




Figura 7. Implementación del CASSI en el Laboratorio de óptica HDSP. Adaptada de ⁴³.




Figura 8. Comparación entre la apertura codificada simulada y fabricada. Adaptada de ⁴⁷.

Adicionalmente, la dispersión de los píxeles puede no darse de forma precisa, porque lo que el valor de un píxel podría ser detectado por la cámara CCD en más

⁴⁷ Hoover Rueda, Henry Arguello y Gonzalo R Arce. «Compressive spectral testbed imaging system based on thin-film color-patterned filter arrays». En: *Applied Optics* 55.33 (2016), págs. 9584-9593.

de una localización, afectando los elementos vecinos⁴⁸, como en la figura 9, lo que generaría aberraciones en la medidas capturadas.




Figura 9. Dispersión no precisa de los píxeles debido al prisma, resultando en la afectación de píxeles vecinos al integrar en el sensor. Adaptada de ⁷.

También es posible, que las longitudes de onda capturadas al pasar por el prisma, no tengan una dispersión lineal⁴⁹. Por ejemplo, en la figura 10 se caracteriza porque inicia de forma lineal, con un valor constante de píxeles de diferencia entre bandas, y finaliza en valores menores de desplazamiento.

⁴⁸ Arguello y col., ver n. 7.

⁴⁹ Miguel Marquez y col. «Deep-Learning Supervised Snapshot Compressive Imaging Enabled by an End-to-End Adaptive Neural Network». En: *IEEE Journal of Selected Topics in Signal Processing* 16.4 (2022), págs. 688-699.




Figura 10. Desplazamiento no lineal de la luz causado por el prisma.

Esta conjunto de aberraciones generan problemas al intentar reconstruir la imagen espectral a partir de la medida comprimida capturada en el laboratorio, lo que deriva en que sea más sencillo reconstruir en el caso de las simulaciones sin degradación, como se observa en la figura 11.

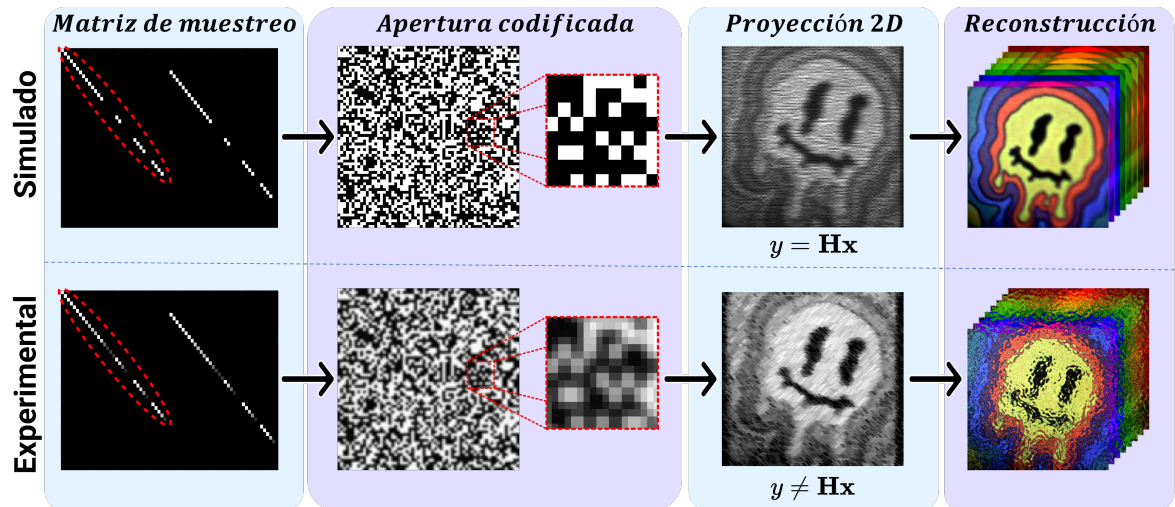


Figura 11. Contraste entre la simulación y lo obtenido en laboratorio.

Es necesario seguir una serie de pasos recomendados para la realización del proceso de calibración manual, sin embargo, no es suficiente para lograr ajustar a la perfección el sistema óptico CASSI.

1. **Control de la iluminación:** Es necesario iluminar la apertura codificada (AC) con la luz del monocromador lo más uniforme posible.
2. **Reducción del ruido de disparo:** En cada longitud de onda, se capturan fotogramas del detector monocromático de dispositivo de carga acoplada (CCD) y se promedian para reducir el impacto del ruido de disparo y de lectura.
3. **Sustracción del fondo:** En cada longitud de onda, se capturan fotogramas oscuros con el mismo tiempo de exposición que los fotogramas del espectralon, conocidos como blancos de referencia, y se promedian. El fotograma oscuro promediado en cada longitud de onda se resta de su correspondiente fotograma blanco de referencia para la calibración.
4. **Ajuste del tiempo de exposición:** Para mejorar la relación señal/ruido (SNR) de la imagen de la apertura codificada en cada longitud de onda, el tiempo de exposición en cada longitud de onda se escala para que los recuentos medios sobre la apertura codificada en las mediciones del CCD en todas las longitudes de onda sean similares.
5. **Distribución de la intensidad espectral de la fuente de luz:** La luz de la fuente en cada longitud de onda se mide con un foto-diodo con una curva de respuesta conocida para obtener una curva de calibración para la intensidad espectral no uniforme de la fuente de luz.

Considerando lo previamente mencionado, se hace necesario aprender el modelo de adquisición del sistema óptico, que es más general y preciso que la matriz de adquisición asumida, tal que se cumpla la siguiente igualdad

$$\mathbf{y} = \mathbf{S}(\mathbf{x}). \quad (14)$$

Es proceso de aprendizaje es posible realizarlo haciendo uso de redes neuronales, ya que estas contienen funciones de activación no lineales que pueden considerar fenómenos como la dispersión del prisma de forma más precisa. Es por esto que se propone una red de mapeo entre las medidas comprimidas obtenidas usando la matriz de adquisición asumida, $\mathbf{H}\mathbf{x}$, y las medidas comprimidas finalmente capturadas en el laboratorio \mathbf{y} .

$$\mathbf{y} \approx \mathcal{M}_{\theta}(\mathbf{x}), \quad (15)$$

donde \mathcal{M} es la red de mapeo, que podría ser cualquier arquitectura del estado del arte, y θ hace referencia a los pesos entrenados de la red.

Desde un enfoque de inteligencia artificial, la tarea consiste en el aprendizaje del modelo de calibración para mapear hacia las medidas comprimidas ideales, aprendiendo así la degradación de las medidas comprimidas. Lo que resulta en la corrección del desajuste presente en el sistema óptico, suprimiendo la necesidad desarrollar tecnologías más avanzadas o de una calibración manual de alta precisión.

Para lograr lo anteriormente mencionado se realizaron una serie de pasos, tanto en el laboratorio como en las simulaciones:

1. Obtener la medida comprimida y la imagen espectral, es decir, construir un conjunto de datos de la forma

$$\mathbf{D} = \{\mathbf{x}^i, \mathbf{y}^i\}_{i=1}^N. \quad (16)$$

Para los propósitos de este trabajo, fue necesario capturar las parejas de imágenes espectrales, \mathbf{x} , con su respectiva medida comprimida, \mathbf{y} . Esto se logró haciendo uso de una metodología de información adicional, que consiste en

ubicar un divisor de haz luego de la modulación con el DMD y antes de la dispersión por parte del prisma, con el fin de dividir el rayo de luz en dos teóricamente iguales y capturar cada longitud de onda con un sensor adicional. Dicha información adicional, solo difiere en la de dispersión de cada banda que posteriormente se integrará como medida comprimida, como se muestra en la figura 12. Adicional al divisor de haz, es imperativo usar un monocromador que ilumine la escena de acuerdo a la longitud de onda que se quiera capturar. Por el brazo del sensor CASSI se ilumina con luz blanca y se obtienen las medidas comprimidas, y el otro brazo se ilumina a diferentes longitudes de onda y se adquiere la imagen espectral.




Figura 12. Montaje del sistema óptico CASSI con información adicional.

2. Entrenar una red neuronal que considere el desajuste del sistema óptico en sus pesos, conocida en este trabajo como regularizador de refuerzo.

$$\hat{\theta} = \arg \min_{\theta} \sum_{i=1}^N \|\mathcal{M}_{\theta}(\mathbf{x}^i) - \mathbf{y}^i\|_2^2. \quad (17)$$

Se desean estimar el conjunto de pesos de la red que minimicen la diferencia

de la medida comprimida con desajuste que sale de la red y la medida comprimida ideal. Dicho regularizador de refuerzo será el encargado de hacer el mapeo de las medidas comprimidas ideales a las medidas comprimidas sin calibración.

3. Usar la red entrenada en el algoritmo de Plug-and-Play.

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} \frac{\lambda_1}{2} \|\mathcal{M}_{\hat{\theta}}(\mathbf{x}) - \mathbf{y}\|_2^2 + \frac{(1 - \lambda_1)}{2} \|\mathbf{H}\mathbf{x} - \mathbf{y}\|_2^2 + \lambda_2 R(\mathbf{x}), \quad (18)$$

El primer término contiene el regularizador de refuerzo, o red de mapeo, que cooperará con la red de reconstrucción, la cual solo contiene pesos de igual dimensión que la imagen espectral deseada, lo que les permite corregir el desajuste del sistema óptico. El segundo término hace uso de la matriz de adquisición asumida, pues esta contiene ciertas propiedades matemáticas y el comportamiento esperado. Al tener una combinación afín con el primer término es posible estudiar la influencia de cada término, como se mostrará más adelante. El tercer término es un regularizador de conocimiento previo para reducir el espacio de búsqueda de las soluciones.

3.2. ALGORITMO ITERATIVO DE RECONSTRUCCIÓN DE IMÁGENES ESPECTRALES CONSIDERANDO EL DESAJUSTE DEL SISTEMA ÓPTICO MEDIANTE UN REGULARIZADOR DE REFUERZO

Para obtener una estimación de la imagen espectral, se plantea el siguiente problema de optimización que considera la matriz de adquisición, \mathbf{H} , el modelo de adquisición aprendido mediante una red de mapeo, \mathcal{M}_{θ} y un regularizador de información *a priori*.

$$\hat{\mathbf{x}} = \arg \min_{\mathbf{x}} \frac{\lambda_1}{2} \|\mathcal{M}_{\theta}(\mathbf{x}) - \mathbf{y}\|_2^2 + \frac{(1 - \lambda_1)}{2} \|\mathbf{H}\mathbf{x} - \mathbf{y}\|_2^2 + \lambda_2 R(\mathbf{x}). \quad (19)$$

El problema mostrado es de difícil solución pues al realizar la derivada de la función de costo e igualarla a cero no será posible despejar \mathbf{x} del regularizador en el último término, es decir, no existe una solución cerrada. Por lo cual se usará la metodología de ADMM⁵⁰, para subdividir el problema mediante una sustitución que posteriormente permita resolverlo en diferentes pasos individuales entre sí:

$$(\hat{\mathbf{x}}, \hat{\mathbf{v}}) = \arg \min_{\mathbf{x}, \mathbf{v}} \left\{ \frac{\lambda_1}{2} \|\mathcal{M}_\theta(\mathbf{x}) - \mathbf{y}\|_2^2 + \frac{(1 - \lambda_1)}{2} \|\mathbf{H}\mathbf{x} - \mathbf{y}\|_2^2 + \lambda_2 R(\mathbf{v}) \right\} \text{ s.t. } \mathbf{x} = \mathbf{v}, \quad (20)$$

Usando el método del Lagrangiano aumentado y añadiendo la variable dual \mathbf{u} , se tiene que

$$\mathcal{L}(\mathbf{x}, \mathbf{v}, \mathbf{u}) = \frac{\lambda_1}{2} \|\mathcal{M}_\theta(\mathbf{x}) - \mathbf{y}\|_2^2 + \frac{(1 - \lambda_1)}{2} \|\mathbf{H}\mathbf{x} - \mathbf{y}\|_2^2 + \lambda_2 R(\mathbf{v}) + \frac{\rho}{2} \|\mathbf{x} - \mathbf{v} + \mathbf{u}\|_2^2, \quad (21)$$

donde ρ es un parámetro que pondera la restricción de la variable dual en la función de costo. La ecuación anterior puede ser resuelta alternadamente en una serie de problemas más simples, minimizando el Lagrangiano con cada variable:

$$\mathbf{x}^{(k+1)} = \arg \min_{\mathbf{x} \in \mathbb{R}^n} \frac{\lambda_1}{2} \|\mathcal{M}_\theta(\mathbf{x}) - \mathbf{y}\|_2^2 + \frac{(1 - \lambda_1)}{2} \|\mathbf{H}\mathbf{x} - \mathbf{y}\|_2^2 + \frac{\rho}{2} \|\mathbf{x} - \mathbf{v}^{(k)} + \mathbf{u}^{(k)}\|_2^2, \quad (22)$$

$$\mathbf{v}^{(k+1)} = \arg \min_{\mathbf{v} \in \mathbb{R}^n} \lambda_2 R(\mathbf{v}) + \frac{\rho}{2} \|\mathbf{x}^{(k+1)} - \mathbf{v} + \mathbf{u}^{(k)}\|_2^2, \quad (23)$$

$$\mathbf{u}^{(k+1)} = \arg \min_{\mathbf{u} \in \mathbb{R}^n} \frac{\rho}{2} \|\mathbf{x}^{(k+1)} - \mathbf{v}^{(k+1)} + \mathbf{u}\|_2^2. \quad (24)$$

⁵⁰ Boyd y col., ver n. 24.

Para adaptar el *Plug-and-Play* tradicional al método propuesto, la ecuación 22 es solucionada usando el gradiente descendiente (o sus variantes como Adam⁵¹ y SGD⁵²), realizando múltiples actualizaciones por cada iteración de k :

$$\begin{aligned} \mathbf{x}^{(t+1)} = \mathbf{x}^{(t)} - \alpha \left(\lambda_1 \nabla \mathcal{M}_\theta(\mathbf{x}^{(t)}) \cdot \left(\mathcal{M}_\theta(\mathbf{x}^{(t)}) - \mathbf{y} \right) + \right. \\ \left. (1 - \lambda_1) \mathbf{H}^T \left(\mathbf{H} \mathbf{x}^{(t)} - \mathbf{y} \right) + \rho \left(\mathbf{x}^{(t)} - \mathbf{v}^{(k)} + \mathbf{u}^{(k)} \right) \right). \end{aligned} \quad (25)$$

La variable \mathbf{v} se puede solucionar haciendo uso de un algoritmo eliminador de ruido, como el filtro recursivo (RF), o el algoritmo de coincidencia de bloques y filtrado 3D (BM3D):

$$\mathbf{v}^{(k+1)} = \mathcal{D}_\sigma \left(\mathbf{x}^{(k+1)} + \mathbf{u}^{(k)} \right). \quad (26)$$

La restricción de la variable dual se suele solucionar de la siguiente forma:

$$\mathbf{u}^{(k+1)} = \mathbf{u}^{(k)} + \left(\mathbf{x}^{(k+1)} - \mathbf{v}^{(k+1)} \right). \quad (27)$$

A continuación, se muestra el algoritmo diseñado a partir de las ecuaciones previamente mostradas.

⁵¹ Diederik P Kingma y Jimmy Ba. «Adam: A method for stochastic optimization». En: *arXiv preprint arXiv:1412.6980* (2014).

⁵² Léon Bottou. «Stochastic gradient descent tricks». En: *Neural networks: Tricks of the trade*. Springer, 2012, págs. 421-436.

Algoritmo 1 Algoritmo de reconstrucción usando la metodología PnP-ADMM.

- 1: **Entrada:** Medida comprimida \mathbf{y} , matriz de adquisición \mathbf{H} , coeficiente del regulador de refuerzo λ , coeficiente de la restricción de la variable dual ρ y modelo de adquisición aprendido \mathcal{M}_θ .
 - 2: $\mathbf{x} \leftarrow \mathbf{H}^T \mathbf{y}$ ▷ Inicialización de \mathbf{x}
 - 3: $\mathbf{v} \leftarrow \mathbf{0} \in \mathbb{R}^{NML}$ ▷ Inicialización de \mathbf{v}
 - 4: $\mathbf{u} \leftarrow \mathbf{0} \in \mathbb{R}^{NML}$ ▷ Inicialización de \mathbf{u}
 - 5: **para** iteración global = 1: k **hacer** ▷ k iteraciones globales
 - 6: **para** iteración interna = 1: t **hacer** ▷ t iteraciones internas
 - 7: $\mathbf{x}^{(t+1)} \leftarrow \mathbf{x}^{(t)} - \alpha \left(\lambda \nabla_{\mathbf{x}} \mathcal{M}_\theta(\mathbf{x}^{(t)}) \cdot \left(\mathcal{M}_\theta(\mathbf{x}^{(t)}) - \mathbf{y} \right) + (1 - \lambda) \mathbf{H}^T \left(\mathbf{H} \mathbf{x}^{(t)} - \mathbf{y} \right) + \rho \left(\mathbf{x}^{(t)} - \mathbf{v}^{(k)} + \mathbf{u}^{(k)} \right) \right)$ ▷ Optimización sobre \mathbf{x}
 - 8: **fin para**
 - 9: $\mathbf{x}^{(k+1)} \leftarrow \mathbf{x}^{(t+1)}$
 - 10: $\mathbf{v}^{(k+1)} \leftarrow \mathcal{D}_\sigma \left(\mathbf{x}^{(k+1)} + \mathbf{u}^{(k)} \right)$ ▷ Optimización sobre \mathbf{v}
 - 11: $\mathbf{u}^{(k+1)} \leftarrow \mathbf{u}^{(k)} + \left(\mathbf{x}^{(k+1)} - \mathbf{v}^{(k+1)} \right)$ ▷ Optimización sobre \mathbf{u}
 - 12: **fin para**
 - 13: **Salida:** Imagen espectral óptima, $\mathbf{x} \in \mathbb{R}^{NML}$.
-

4. RESULTADOS

En esta sección se presentan los resultados obtenidos a partir del método propuesto, tanto para las medidas comprimidas sintéticas como para las capturadas en el laboratorio. Se usaron diferentes métricas para evaluar la calidad de reconstrucción y se hizo un análisis del aporte del método propuesto.

Con el fin de tener métricas cuantitativas para evaluar el rendimiento del método propuesto y medir la calidad de las reconstrucciones se hizo uso de tres métricas; Proporción Máxima de Señal a Ruido (PSNR, por sus siglas en inglés ⁵³), Índice de Similitud Estructural (SSIM, por sus siglas en inglés ⁵⁴) y Mapeo del Ángulo Espectral (SAM, por sus siglas en inglés ⁵⁵), las cuales se enfocan respectivamente en la ausencia de ruido, la semejanza estructural y la similitud entre las firmas espectrales, dichas métricas son caracterizadas por las siguientes ecuaciones:

- **PSNR:** Para calcular el PSNR entre la imagen espectral reconstruida, \hat{x} , y la imagen espectral esperada o *ground truth*, x , es necesario hacer uso de la siguiente ecuación

$$\text{PSNR}(x, \hat{x}) = 10 \cdot \log_{10} \left(\frac{\text{MAX}_I^2}{\text{MSE}(x, \hat{x})} \right), \quad (28)$$

donde para las imágenes espectrales aquí usadas se tiene $\text{MAX}_I = 1$, y se

⁵³ Alain Hore y Djemel Ziou. «Image quality metrics: PSNR vs. SSIM». En: *2010 20th international conference on pattern recognition*. IEEE. 2010, págs. 2366-2369.

⁵⁴ Zhou Wang y col. «Image quality assessment: from error visibility to structural similarity». En: *IEEE transactions on image processing* 13.4 (2004), págs. 600-612.

⁵⁵ Fred A Kruse y col. «The spectral image processing system (SIPS)-interactive visualization and analysis of imaging spectrometer data». En: *Remote sensing of environment* 44.2-3 (1993), págs. 145-163.

calcula el error cuadrático medio (MSE) con la siguiente ecuación

$$\text{MSE}(\mathbf{x}, \hat{\mathbf{x}}) = \frac{1}{M \cdot N \cdot L} \|\mathbf{x} - \hat{\mathbf{x}}\|_2^2. \quad (29)$$

Su mayor valor, ∞ dB, indica imágenes idénticas, y a partir de 30 dB es difícilmente diferenciable por el ojo humano.

- **SSIM:** Para obtener el valor del SSIM de las reconstrucciones, \mathbf{x} , con respecto al *ground truth*, \mathbf{x} , se hace uso de la siguiente ecuación

$$\text{SSIM}(\mathbf{x}, \hat{\mathbf{x}}) = \frac{(2\mu_{\mathbf{x}}\mu_{\hat{\mathbf{x}}} + c_1)(2\sigma_{\mathbf{x}\hat{\mathbf{x}}} + c_2)}{(\mu_{\mathbf{x}}^2 + \mu_{\hat{\mathbf{x}}}^2 + c_1)(\sigma_{\mathbf{x}}^2 + \sigma_{\hat{\mathbf{x}}}^2 + c_2)}, \quad (30)$$

donde,

- $\mu_{\mathbf{x}}$ representa la media de \mathbf{x} .
- $\sigma_{\mathbf{x}}^2$ denota la varianza de \mathbf{x} .
- $\sigma_{\mathbf{x}\hat{\mathbf{x}}}$ simboliza la covarianza entre \mathbf{x} y $\hat{\mathbf{x}}$.
- $c_1 = (k_1L)^2$, $c_2 = (k_2L)^2$ son dos variables que estabilizan la división.
- $L = 1$ es el rango de valores de los píxeles.
- $k = 0,01$ y $k_2 = 0,03$ son dos parámetros preestablecidos.

Note que el valor 1, indica la máxima similitud entre las imágenes espectrales evaluadas.

- **SAM:** Para la obtención de la métrica SAM, la cual se enfoca en la calidad espectral de la escena reconstruida, se hace uso de la siguiente ecuación

$$\text{SAM}(\mathbf{x}, \hat{\mathbf{x}}) = \cos^{-1} \left(\frac{\sum_{i=1}^C \mathbf{x}_i \hat{\mathbf{x}}_i}{\sqrt{\sum_{i=1}^C \mathbf{x}_i^2} \sqrt{\sum_{i=1}^C \hat{\mathbf{x}}_i^2}} \right). \quad (31)$$

Cabe resaltar que este cálculo se hace tomando cada píxel espectral y comparando su firma con la original, el valor de 0 indica firmas idénticas.

- **MÉTRICA PONDERADA (MP):** Con el objetivo de reunir las tres métricas previamente mencionadas y comparar la calidad de las imágenes de forma general, se define una métrica ponderada con valores en $[0, 1]$. Inicialmente se normalizarán los valores de cada métrica (conocido como *Min-max normalization* en inglés) de modo que estén en la escala esperada de la métrica y basada exclusivamente en los valores obtenidos con el conjunto de datos específico

$$z' = \frac{z - \min(\mathbf{z})}{\max(\mathbf{z}) - \min(\mathbf{z})}, \quad (32)$$

donde z hace referencia al vector de valores obtenidos en una métrica arbitraria.

$$MP(\mathbf{x}, \hat{\mathbf{x}}) = \frac{1}{3} \left(PSNR'(\mathbf{x}, \hat{\mathbf{x}}) + SSIM'(\mathbf{x}, \hat{\mathbf{x}}) + \left(1 - SAM'(\mathbf{x}, \hat{\mathbf{x}}) \right) \right). \quad (33)$$

4.1. SIMULACIONES


Las simulaciones del sistema óptico, específicamente del proceso de captura, fueron realizadas usando el conjunto de datos ARAD 2022⁵⁶ y usando el conocimiento presente en el estado del arte correspondiente al funcionamiento del sistema CASI.

Se usaron las 950 imágenes espectrales de entrenamiento del conjunto de datos y con el fin de aumentar los datos de entrenamiento se subdividieron en 9 parches

⁵⁶ Boaz Arad y col. «NTIRE 2022 Spectral Recovery Challenge and Data Set». En: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) Workshops*. Jun. de 2022, págs. 863-881.

de 256×256 , ya que inicialmente son de $482 \times 512 \times 31$, obteniendo finalmente 8550 imágenes espectrales. Posteriormente al simular la captura de estas imágenes espectrales en varios de niveles de degradación de la medida comprimida (D_0 a D_5), de modo que se aumenta la dificultad de reconstrucción para intentar acercarse a lo que finalmente se capturaría con el sistema óptico implementado. En la figura 13 se muestra una representación RGB de las 900 imágenes espectrales usadas para entrenamiento y de las 50 de validación.

Figura 13. Imágenes presentes en el conjunto de datos ARAD 2022.



Se tuvo en cuenta el desenfoque que se presenta para cada longitud de onda capturada, y se caracterizó por medio de un filtro paso bajas. Adicionalmente, se consideró la dispersión del prisma por medio de filtros convolucionales de acuerdo a lo estudiado en⁵⁷.

En la figura 14, se puede observar la variación que sufrió el valor de la frecuencia

⁵⁷ Arguello y col., ver n. 7.

de paso dependiendo del nivel de degradación simulado, dicho valor se va disminuyendo ya que los lentes, debido a las aberraciones cromáticas, tienden a enfocar las bandas centrales con mayor precisión, por lo que complicaría el proceso de reconstrucción en las bandas de los extremos. Es posible relacionar este proceso de desenfoco con un filtro gaussiano que convolucionamos por cada banda de la imagen, a medida que aumenta el nivel de degradación también lo hace la desviación estándar de dicho filtro, como se ilustra a la derecha de la figura.




Figura 14. Gráficas de los valores de la frecuencia de paso por cada nivel de degradación en las simulaciones usado como parámetro para el filtro *lowpass* de Matlab.

Note como se aumenta el desenfoco de la imagen de ejemplo a medida que se disminuye el valor de la frecuencia de paso en el caso de que perteneciera a la primera banda.

Adicionalmente, se varió el filtro o kernel de dispersión, que es el encargado de considerar la vecindad que afecta al sensor al intentar capturar un píxel específico, por lo que hizo uso de una convolución 2D para generar las respectivas medidas.




Figura 15. Filtros por cada nivel de degradación en las simulaciones.

Cabe destacar que el filtro que simula la dispersión a diferencia del filtro anterior de desenfoque es convolucionado tanto espectral, como espacialmente. En la figura 16 se muestra el filtro espectral resultante de sumarlos todos con su desplazamiento en cada banda para los niveles de degradación nula D_0 y máxima degradación D_5 .




Figura 16. Filtro espectral convolucionado que simula la dispersión del prisma.

Finalmente se le agregó ruido gaussiano blanco a las medidas obtenidas con el fin de añadirle ruido que pudiera estar presente en el sistema óptico, el valor seleccionado de ruido fue moderado, de 25 SNR.




Figura 17. Ejemplo de la degradación efectuada por el filtro *lowpass* y el filtro de dispersión; y la resultante de añadirle el ruido gaussiano blanco de 25 SNR con la función *awgn* de Matlab.

4.1.1. Modelo de adquisición propuesto. Para las redes de mapeo, se consideraron diferentes arquitecturas, principalmente las convolucionales, ya que se ha mostrado su buen rendimiento en tareas de visión por computador donde los datos utilizados son imágenes⁵⁸. Se probó una arquitectura U-Net con 5 capas de profundidad, tamaño de los filtros de 3 y una cantidad de filtros equivalente a múltiplos de 16, se usaron funciones de activación *ReLU*⁵⁹ y un *padding* de ceros alrededor de la medida comprimida con el fin de mantener sus dimensiones.

En este problema de mapeo específico que consiste en ir de una medida comprimida simulada sin degradación, y_{D_0} , a cada uno de los diferentes niveles de degradación, ambas con dimensiones 256×262 , para aprender el modelo de adquisición, fue suficiente con esta red inicial para obtener resultados considerables, como se mostrará más adelante en el cuadro 1. Al momento de incorporar esta red entrenada en el algoritmo se observaba el correcto aprendizaje del modelo de propagación, pues no contiene las aberraciones ópticas que se pueden presentar en la implementación del sistema óptico en el laboratorio.

Cuadro 1. Métricas obtenidas con las redes de mapeo en las medidas comprimidas simuladas usando la arquitectura U-Net con profundidad de 5.


Degradación	PSNR (\uparrow)	SSIM (\uparrow)	SAM (\downarrow)
D_0	$60,73 \pm 3,1$	$0,999 \pm 3e^{-5}$	$0,004 \pm 0,002$
D_1	$38,60 \pm 3,7$	$0,963 \pm 0,03$	$0,057 \pm 0,001$
D_2	$38,44 \pm 3,6$	$0,963 \pm 0,03$	$0,058 \pm 0,002$
D_3	$38,06 \pm 3,6$	$0,959 \pm 0,03$	$0,058 \pm 0,001$
D_4	$37,47 \pm 3,6$	$0,952 \pm 0,04$	$0,059 \pm 0,002$
D_5	$37,39 \pm 3,6$	$0,947 \pm 0,04$	$0,058 \pm 0,001$

⁵⁸ Alzubaidi y col., ver n. 33.

⁵⁹ Abien Fred Agarap. «Deep learning using rectified linear units (relu)». En: *arXiv preprint arXiv:1803.08375* (2018).

4.1.2. Reconstrucciones bajo diferentes niveles de degradación. Usando el modelo de adquisición previamente entrenado con el conjunto de datos de entrenamiento dentro del algoritmo de reconstrucción propuesto, se reconstruirán las imágenes espectrales correspondientes al conjunto de validación. En el caso de las simulaciones el algoritmo eliminador de ruido utilizado fue RF, y se hizo un estudio de validación cruzada para ajustar sus parámetros. Se hicieron estudios de ablación para determinar el mejor valor para el coeficiente del término propuesto.

Figura 18. Métricas evaluadas vs. Coeficiente del término propuesto.



En la figura 18 se muestran las métricas evaluadas y sus valores promedio de acuerdo al valor del coeficiente del regularizador de refuerzo.

Se puede observar que en todas las métricas, a excepción del SAM, las mejores reconstrucciones, en términos de reducción de ruido y estructurales, se logran cuando se usa por completo el modelo de adquisición propuesto, $\lambda_1 = 1$, y se descarta la matriz de adquisición. En el caso del SAM, teniendo en cuenta que su mejor valor posible es 0, contrario a las demás, se observa que en promedio, los mejores resultados se obtienen si se considera en gran medida la red de mapeo, $\lambda_1 = 0,9$, pero sin llegar a descartar la matriz de adquisición, pues según indican los datos la información contenida allí es relevante espectralmente.

Note que $\lambda_1 = 0$ simboliza a los métodos tradicionales, y que en todos los casos, a excepción de uno donde no exista desajuste, se mejorará la calidad reconstrucción si se le aumenta la ponderación al regularizador de refuerzo en la función de costo. En el caso ideal, D_0 , se mantiene constante el rendimiento pues ya se conoce el modelo de adquisición porque coincide con la matriz de adquisición. Para niveles mayores de degradación se nota una brecha superior en la calidad de la reconstrucción al aumentar el coeficiente λ_1 .

Cuadro 2. Media y desviación estándar de la Métrica ponderada en las medidas comprimidas simuladas.

λ_1	D_0	D_1	D_2	D_3	D_4	D_5
0	$0,84 \pm 0,06$	$0,79 \pm 0,05$	$0,78 \pm 0,05$	$0,72 \pm 0,06$	$0,67 \pm 0,07$	$0,63 \pm 0,08$
0,1	$0,84 \pm 0,06$	$0,79 \pm 0,05$	$0,78 \pm 0,05$	$0,73 \pm 0,06$	$0,68 \pm 0,07$	$0,64 \pm 0,08$
0,2	$0,84 \pm 0,06$	$0,8 \pm 0,05$	$0,79 \pm 0,05$	$0,73 \pm 0,06$	$0,68 \pm 0,07$	$0,64 \pm 0,08$
0,3	$0,84 \pm 0,06$	$0,8 \pm 0,05$	$0,79 \pm 0,05$	$0,73 \pm 0,06$	$0,68 \pm 0,07$	$0,64 \pm 0,08$
0,4	$0,84 \pm 0,06$	$0,8 \pm 0,05$	$0,79 \pm 0,05$	$0,73 \pm 0,06$	$0,69 \pm 0,07$	$0,64 \pm 0,08$
0,5	$0,84 \pm 0,06$	$0,8 \pm 0,05$	$0,8 \pm 0,05$	$0,74 \pm 0,06$	$0,69 \pm 0,06$	$0,65 \pm 0,08$
0,6	$0,84 \pm 0,06$	$0,8 \pm 0,05$	$0,8 \pm 0,05$	$0,74 \pm 0,06$	$0,7 \pm 0,06$	$0,65 \pm 0,08$
0,7	$0,84 \pm 0,06$	$0,8 \pm 0,05$	$0,8 \pm 0,05$	$0,75 \pm 0,06$	$0,71 \pm 0,06$	$0,66 \pm 0,07$
0,8	$0,84 \pm 0,06$	$0,8 \pm 0,05$	$0,8 \pm 0,05$	$0,77 \pm 0,05$	$0,72 \pm 0,06$	$0,67 \pm 0,07$
0,9	$0,84 \pm 0,06$	$0,81 \pm 0,05$	$0,81 \pm 0,05$	$0,78 \pm 0,05$	$0,75 \pm 0,06$	$0,7 \pm 0,06$
1	$0,84 \pm 0,06$	$0,81 \pm 0,05$	$0,81 \pm 0,05$	$0,8 \pm 0,05$	$0,77 \pm 0,12$	$0,74 \pm 0,05$

En el cuadro 2 se muestran los resultados numéricos obtenidos para el conjunto de datos de validación del ARAD 2022. Nótese que algunos valores medios de la métrica ponderada en D_0 son muy similares entre sí, esto es debido a que tienen un comportamiento acorde a lo esperado, y la calidad de la reconstrucción decae a medida que aumenta la degradación, sin embargo, la red mantiene una brecha positiva.

Posteriormente, en las figuras de diagramas de caja, se hace una comparación entre tres posibles casos:

- AC binaria: Solo se dispone de la apertura codificada binaria, se ignoran los posibles problemas de calibración, y se intenta reconstruir haciendo uso de la matriz de adquisición asumida, como no se considera el desajuste se espera que aquí se obtengan los peores resultados.
- AC real: Se conoce de manera precisa la apertura codificada que moduló ópticamente la escena, lo cual en la implementación real sería imposible, pero al ser simulado se puede hacer uso de ella con el fin de analizar que pasaría en dado caso, se espera que este caso obtenga las mejores métricas.
- Propuesto: Usa la red de mapeo propuesta y la apertura codificada binaria, lo cual sí es posible realizar en la experimentación, ya que se usaría la matriz de adquisición asumida y la red previamente entrenada, se espera que este caso se encuentre entre los dos mencionados previamente.

En el eje de las abscisas, se varía la degradación de la medida, por lo que se espera que los valores medios decrezcan al aumentar la dificultad de la reconstrucción por la presencia de un mayor desajuste.

Figura 19. PSNR vs. degradación de las medidas sintéticas.




Figura 20. SSIM vs. degradación de las medidas sintéticas.

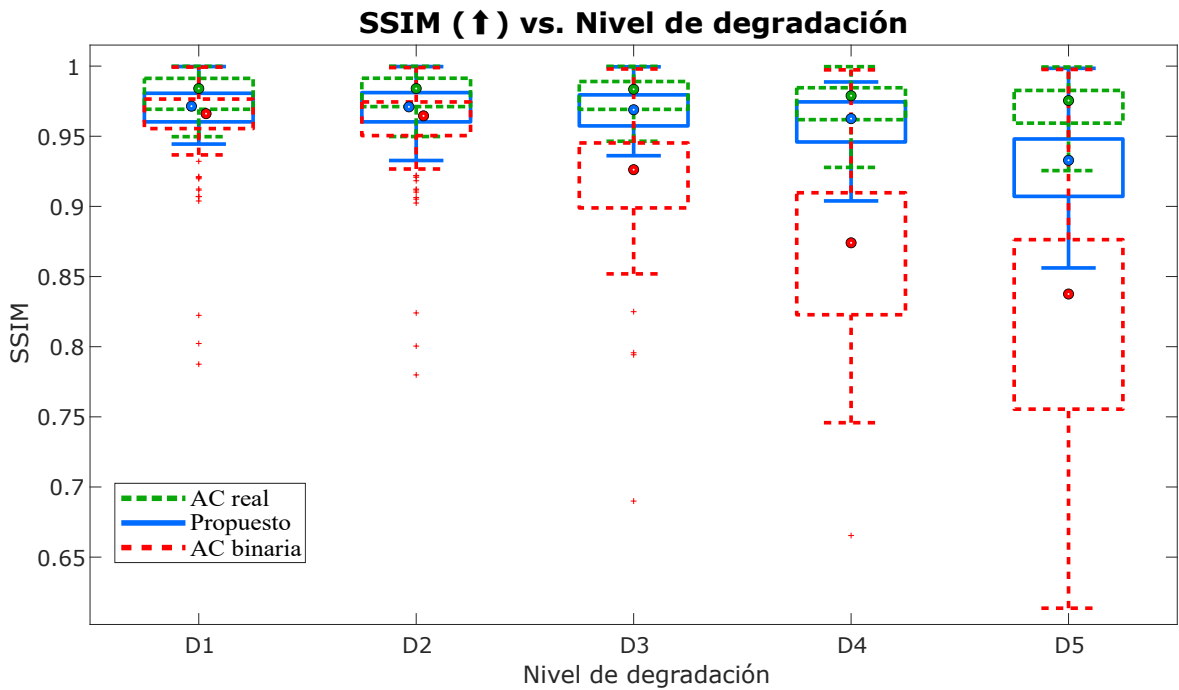


Figura 21. SAM vs. degradación de las medidas sintéticas.

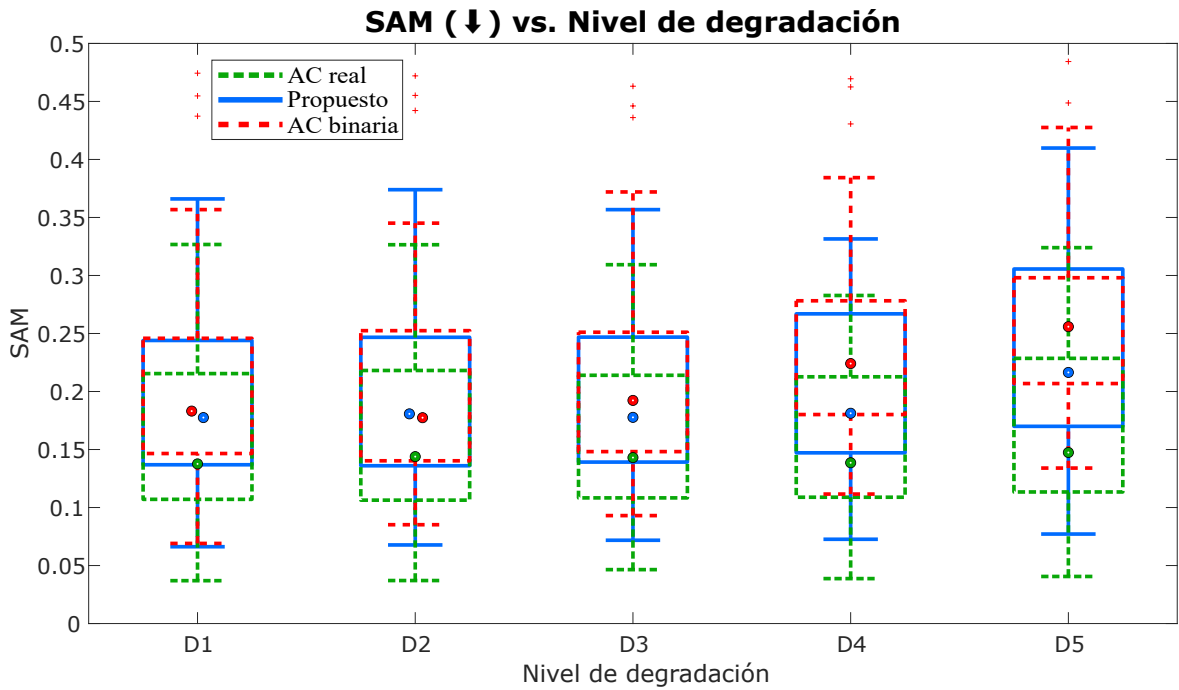
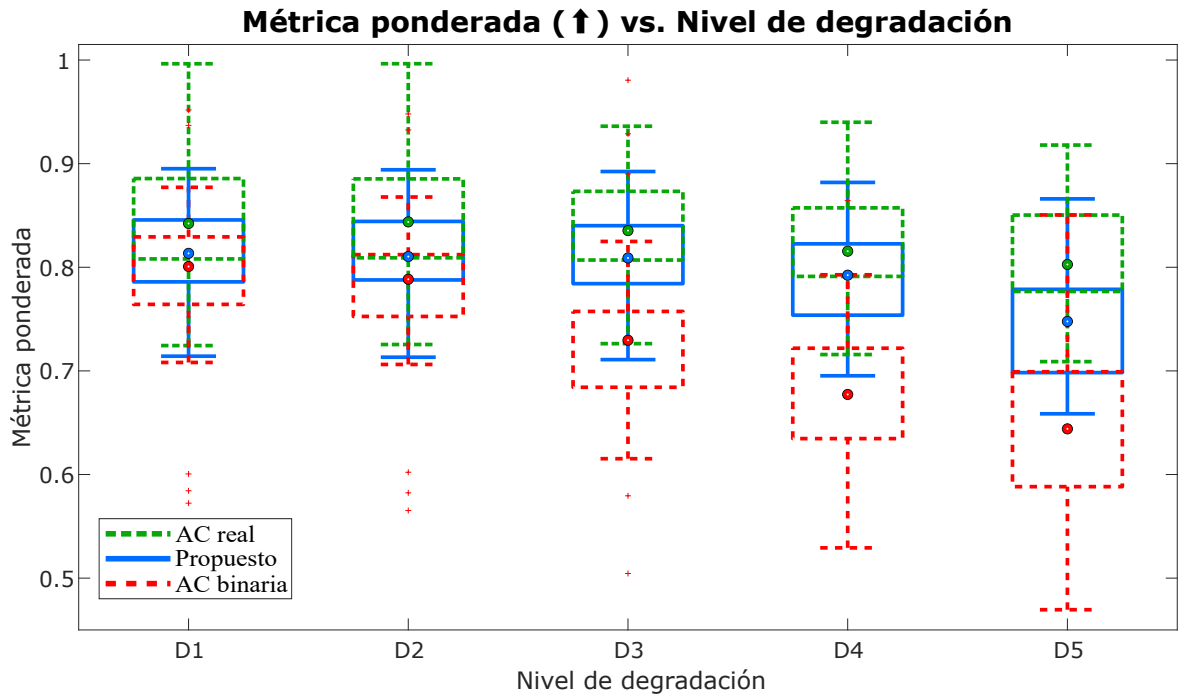


Figura 22. Métrica ponderada vs. degradación de las medidas sintéticas.



Se puede observar en cada una de las figuras la superioridad de las reconstrucciones realizadas con el conocimiento del modelo de adquisición, en este caso de la apertura codificada real, es decir, la apertura codificada con las degradaciones que fueron simuladas. Su obtención es posible en este caso porque se conocen todas las aberraciones simuladas, pero no es posible realizar esto en la implementación experimental por el desconocimiento de la totalidad de las aberraciones y sus implicaciones ópticas. Adicionalmente, se evidencia la cercanía del modelo de adquisición propuesto (azul) al caso de pleno conocimiento (verde) y como decaen los resultados cuando se intenta recuperar la imagen espectral desde un enfoque tradicional (rojo) que no considera el desajuste del sistema óptico.

En la figura 23 se comparan algunas de las reconstrucciones obtenidas como se haría en el estado del arte, es decir, sin considerar el problema de calibración, con $\lambda_1 = 0$, y haciendo uso en su totalidad del sistema de adquisición propuesto que corrige los errores de calibración, $\lambda_1 = 1$. En la figura 24 se muestra la comparación de las firmas de los 3 píxeles de cada imagen espectral señalados en la figura 23 y sus respectivos valores en la métrica SAM.

En la figura 23 es posible observar que si se aumenta el nivel de degradación, aumenta a su vez, la brecha entre las métricas entre los casos comparados. Inicialmente, si no existe desajuste en el sistema óptico, es decir, en D_0 , son comparables las dos reconstrucciones, pues sus métricas son muy similares y no se aprecian diferencias visualmente. Al momento de aumentar la degradación hasta al máximo nivel simulado, D_5 , se observa un aumento progresivo de la brecha debido a que se aprendió el modelo de adquisición, pues se obtienen métricas con valores muy diferentes y el ruido no permite apreciar correctamente la escena en la imagen espectral reconstruida mediante el enfoque tradicional, se observa el mismo comportamiento en las firmas de la figura 24.

Figura 23. Comparación entre las reconstrucciones para distintos niveles de degradación.


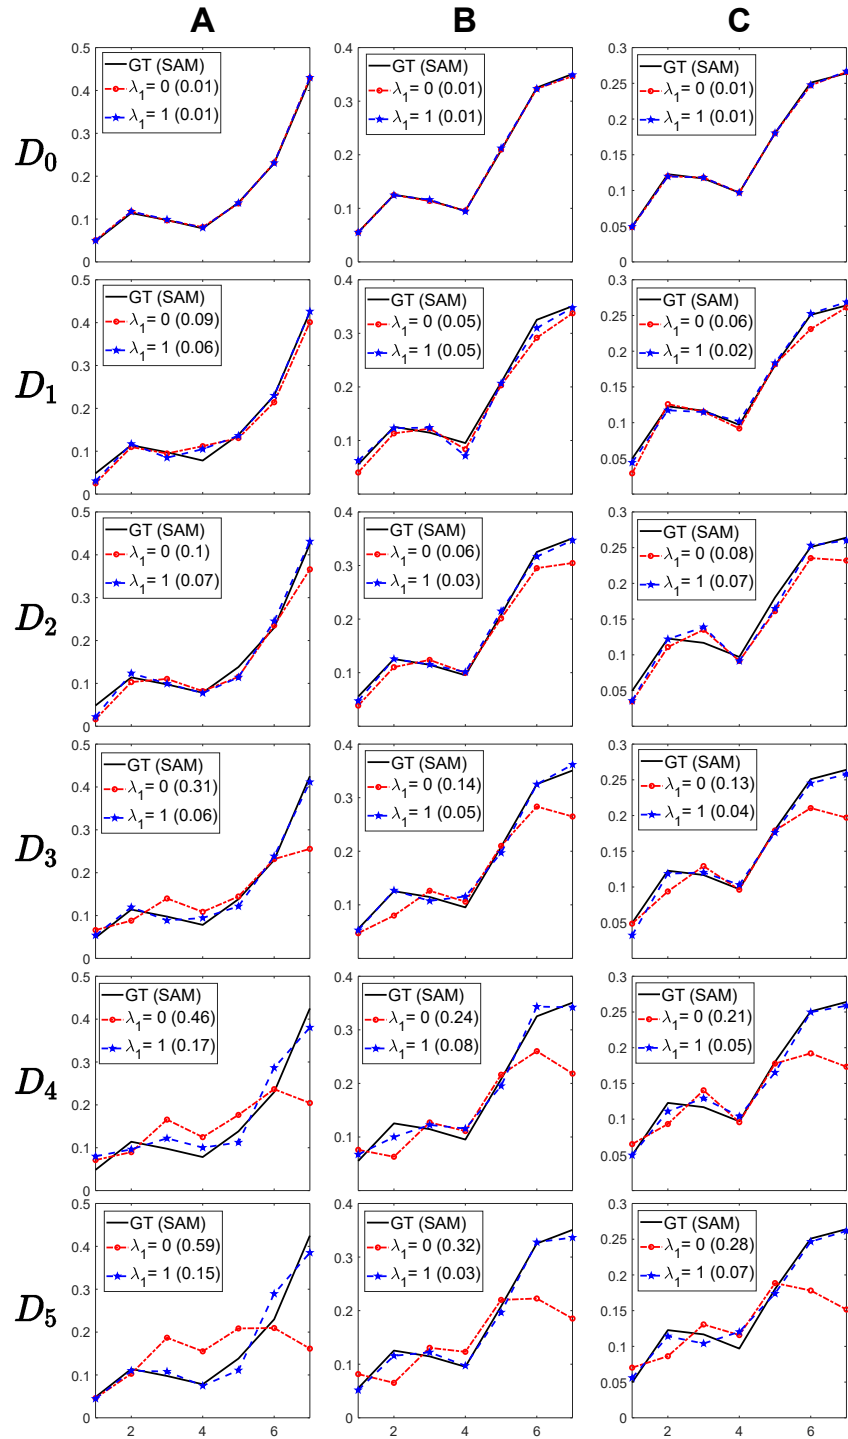



Figura 24. Comparación entre las firmas espectrales para distintos niveles de degradación.



4.1.3. Reconstrucciones bajo diferentes niveles de ruido. Posteriormente se realizaron pruebas añadiéndole un nivel de ruido variable a la medida comprimida con mayor nivel de degradación, D_5 , con el objetivo de analizar que tan robusto al ruido es el método propuesto. Cabe recalcar que la relación señal-ruido, (conocida como SNR, por sus siglas en inglés), es la relación de potencia entre la fuerza de señal y el nivel de ruido, es decir, que un menor valor indica mayor dificultad por la poca diferenciación entre el ruido y los valores de la medida comprimida original⁶⁰. A continuación se muestran las medidas comprimidas resultantes de añadirle diferentes valores de ruido, adicionalmente se grafica una fila, indicada con el rectángulo en color rojo, de la medida comprimida y su respectivo valor de SAM para comparar su diferencia con respecto a la imagen comprimida sin degradación.

Figura 25. Medidas comprimidas con adición de diferentes valores de SNR.




En la figura 26 se muestran los resultados de la reconstrucción en diferentes nive-

⁶⁰ Robert Kieser, Pall Reynisson y Timothy J Mulligan. «Definition of signal-to-noise ratio and its critical role in split-beam measurements». En: *ICES Journal of Marine Science* 62.1 (2005), págs. 123-130.

les de ruido. La dificultad de reconstrucción aumenta de izquierda a derecha pues se disminuye la diferencia entre la señal y el ruido, y se analizará la influencia del modelo de adquisición aprendido.


Figura 26. Comparación de reconstrucciones a partir de medidas comprimidas con adición de diferentes valores de SNR.



Se observa que el método propuesto mejora los resultados a pesar del ruido en todos los casos, ya que al disminuir el valor del SNR mantiene una diferencia positiva con respecto al método tradicional.

En la figura 27 se muestran las métricas evaluadas para valores del coeficiente del modelo de adquisición aprendido, λ_1 , de 0 y 1. Se observa que en el caso de las tres métricas cuyo mejor valor es el más alto, la calidad del método propuesto es siempre mayor que el caso en que no se usa la red de mapeo. En la métrica SAM, cuyo mejor valor es el menor, su comportamiento se invierte cuando se aumenta excesivamente el nivel de ruido, pues la diferencia espectral de la reconstrucción es mayor.

Figura 27. Análisis de la robustez al ruido utilizando las 4 métricas evaluadas.



4.2. EXPERIMENTACIÓN

Las imágenes reales, fueron capturadas con el sistema óptico CASSI, el cual presenta algunas distorsiones y problemas de calibración que son difíciles de identificar y corregir por parte del personal de laboratorio calificado para dicha tarea. En la etapa de calibración del modelo se hace uso de la información adicional, es decir, se captura el cubo de datos de la imagen espectral, esto con el fin de aprender una

red de degradación. Dicha red será posteriormente utilizada para nuevas capturas donde solo se requiera de la captura instantánea de la medida comprimida. La información que fue capturada es la siguiente

1. Apertura codificada con iluminación directa sobre el DMD con el fin de obtener la apertura codificada a partir del sensor de información adicional.
2. Apertura codificada con iluminación directa sobre el DMD y desplazamiento del prisma que conformará la apertura codificada capturada con el sensor CASSI.
3. Imagen espectral con la información adicional y sin apertura codificada, que posteriormente será conocida como *ground truth* y es el objetivo a reconstruir.
4. Imagen espectral con dispersión del prisma y apertura codificada, que será usada para emular diferentes niveles de complejidad, como se explicará más adelante.
5. Iluminación directa sin apertura codificada para obtener los valores de mayor intensidad, o blancos puros.


El procesamiento de la información capturada consiste de varios pasos, como lo son

1. Selección de la zona específica a procesar, ya que el sensor integró las escenas en zonas cuadradas de aproximadamente 675×675 píxeles, rodeada por píxeles con intensidad cercana a cero y generando un cubo de datos de $1038 \times 1388 \times 32$. También es necesario establecer a partir de que valor umbral se considera que empieza la escena.
2. Búsqueda y corrección de píxeles quemados o altamente ruidosos mediante la asignación de la media de sus ocho píxeles vecinos.

3. Posteriormente, en las capturas dispersadas se analiza, banda a banda, la magnitud del desplazamiento realizado por el prisma, con el fin de hacer un recorte específico que luego será útil cuando se emule dicho desplazamiento.
4. Hacer una reducción de la resolución, o *downsampling* en inglés, de la zona seleccionada a 128×128 , ya que esto reduciría el ruido.
5. Normalizar la imagen espectral tomada como *ground truth* y cada una de las aperturas codificadas, haciendo uso del valor máximo y mínimo general, de modo que su rango de valores sea $[0, 1]$.

Luego del procesamiento de los datos en las diferentes configuraciones se obtuvo lo que se mostrará a continuación. Específicamente, en la figura 28, se muestra una zona de 16×16 píxeles de las diferentes aperturas codificadas y su comparación con la binaria o ideal, también son mostradas las métricas de PSNR y SSIM.

Figura 28. Aperturas codificadas binaria, con información adicional y con sensor CASSI.




Note como las aperturas codificadas obtenidas luego de procesamiento, mantienen la estructura original, pero cambian sus intensidades a distintos valores de grises,

este es un ejemplo de los fenómenos físicos que dificultan el proceso de reconstrucción. También se evidencia la disminución en las métricas de calidad.

Adicionalmente, se capturaron las siguientes imágenes espectrales que son presentadas en un falso RGB para efectos de visualización en la figura 29.

Figura 29. Imágenes capturadas en el laboratorio de óptica HDSP.



La emulación para los diferentes niveles de complejidad se realizó de la siguiente forma

1. Multiplicando punto a punto por la apertura codificada ideal, o binaria, y un desplazamiento de un píxel entre cada longitud de onda capturada se obtiene la medida comprimida con la matriz de adquisición asumida, y_1 , que emula todo el proceso de captura de la información en el laboratorio.
2. Se multiplica por la apertura codificada capturada con información adicional, y se mantiene el desplazamiento entre bandas, generando así una medida comprimida, y_2 , que considera la codificación real y emula lo demás.
3. Se multiplica por la apertura codificada capturada con el sensor CASSI pero con desplazamiento final de un píxel, por lo que se obtiene una medida comprimida con mayor dificultad de reconstrucción, y_3 , pues considera en cierta medida la dispersión del prisma que es corregida mediante el procesamiento manual, y la codificación real.
4. Se toma la escena modulada ópticamente luego de pasar por el DMD y se hace una emulación de la integración del sensor, mediante una suma de las bandas específicas con las que se desea trabajar, consiguiendo así a y_4 .
5. Considerando que algunas bandas intermedias fueron descartadas por no tener el desplazamiento lineal esperado por el prisma, ahora se consideran y se suman, dejando de emular cualquier etapa del sistema óptico y obteniendo la medida comprimida real, y_5 .


En el cuadro 3 se resumen las características de cada nivel de emulación, sean, apertura codificada utilizada (AC), que puede ser binaria (B), capturada con el sensor de información adicional (A) o capturada con el sensor CASSI (C); la codificación óptica (CO) y la integración óptica (IO).

Cuadro 3. Características de los niveles de emulación de la información capturada en el laboratorio.

Nivel	Apertura codificada	Codificación óptica	Integración óptica
y_1	Binaria	×	×
y_2	Información adicional	×	×
y_3	Sensor CASSI	×	×
y_4	Sensor CASSI	✓	×
y_5	Sensor CASSI	✓	✓

A continuación, en la figura 30 se muestran las diferentes medidas comprimidas emuladas a partir de la información capturada en el laboratorio. Adicionalmente se muestra el valor de las intensidades de una fila, se usa la métrica SAM para analizar la diferencia entre cada conjunto de intensidades con la ideal, y_1 .

Figura 30. Comparación entre las diferentes medidas comprimidas emuladas a partir de la información capturada en el laboratorio.



Se puede observar visualmente como cambian las intensidades de las medidas comprimidas y el aumento de la métrica SAM usada para comparación. Cabe recalcar que aunque se vean similares, sus intensidades son cruciales en el proceso de reconstrucción, pues comprimen toda la información de imagen espectral.

4.2.1. Modelo de adquisición propuesto. Se realizó una validación del rendimiento de distintas arquitecturas para la reconstrucción de las medidas reales, debido a que se tiene un conjunto de datos de menor tamaño, y que se desconoce el nivel de degradación de las medidas comprimidas. Las arquitecturas probadas son: la U-Net inicial utilizada en las medidas comprimidas simuladas con 5 capas de profundidad, adicionalmente se aumentó la profundidad de la U-Net probando con 7 y 9 niveles de profundidad, ya que se observó que este hiperparámetro mejora la capacidad de la red en mayor medida, como se ve en los cuadros 4, 5 y 6. En dichas tablas se usa la caracterización de los niveles de emulación⁶¹ como fueron explicados en el cuadro 3.

Cuadro 4. Métricas obtenidas con las redes de mapeo en las medidas comprimidas capturadas en el laboratorio en la U-Net con profundidad de 5.

Nivel	AC	CO	IO	PSNR (↑)	SSIM (↑)	SAM (↓)
y ₁	B	×	×	97,58 ± 1,6	0,999 ± 5e ⁻⁸	4e ⁻⁵ ± 1e ⁻⁵
y ₂	A	×	×	50,10 ± 1,1	0,998 ± 4e ⁻⁴	0,008 ± 1e ⁻³
y ₃	C	×	×	50,99 ± 1,1	0,998 ± 4e ⁻⁴	0,008 ± 1e ⁻³
y ₄	C	✓	×	42,49 ± 1,4	0,988 ± 4e ⁻³	0,018 ± 3e ⁻³
y ₅	C	✓	✓	43,75 ± 1,2	0,991 ± 2e ⁻³	0,016 ± 4e ⁻³

Cuadro 5. Métricas obtenidas con las redes de mapeo en las medidas comprimidas capturadas en el laboratorio en la U-Net con profundidad de 7.

Nivel	AC	CO	IO	PSNR (↑)	SSIM (↑)	SAM (↓)
y ₁	B	×	×	100,9 ± 1,7	0,999 ± 7e ⁻⁸	3e ⁻⁵ ± 9e ⁻⁶
y ₂	A	×	×	55,41 ± 1,1	0,999 ± 2e ⁻⁸	0,004 ± 8e ⁻⁴
y ₃	C	×	×	56,08 ± 1,1	0,999 ± 1e ⁻⁴	0,004 ± 6e ⁻⁴
y ₄	C	✓	×	45,27 ± 1,1	0,994 ± 2e ⁻³	0,013 ± 2e ⁻³
y ₅	C	✓	✓	45,07 ± 1,5	0,994 ± 2e ⁻³	0,014 ± 1e ⁻³

⁶¹ Apertura codificada (AC): Binaria (B), información adicional (A), sensor CASSI (C); codificación óptica (CO), integración óptica (IO).

Cuadro 6. Métricas obtenidas con las redes de mapeo en las medidas comprimidas capturadas en el laboratorio en la U-Net con profundidad de 9.

Nivel	AC	CO	IO	PSNR (\uparrow)	SSIM (\uparrow)	SAM (\downarrow)
y_1	B	×	×	$95,58 \pm 2,1$	$0,999 \pm 3e^{-3}$	$0,016 \pm 4e^{-3}$
y_2	A	×	×	$57,40 \pm 1,1$	$0,999 \pm 1e^{-4}$	$0,004 \pm 6e^{-4}$
y_3	C	×	×	$47,96 \pm 1,2$	$0,997 \pm 6e^{-4}$	$0,010 \pm 1e^{-3}$
y_4	C	✓	×	$39,76 \pm 2,1$	$0,979 \pm 7e^{-3}$	$0,026 \pm 9e^{-3}$
y_5	C	✓	✓	$46,82 \pm 1,4$	$0,995 \pm 1e^{-3}$	$0,011 \pm 2e^{-3}$

De los cuadros 4, 5 y 6 se puede observar que existen niveles de emulación donde alguna de las redes tiene un mejor rendimiento. Para cada nivel de emulación, se hace uso de la red de mapeo con la que se obtuvo mejores métricas de calidad.

4.2.2. Reconstrucciones bajo diferentes niveles de emulación. Considerando el tamaño de este conjunto de datos, se optó por utilizar el eliminador de ruido BM3D. En la figura 31 se muestran los resultados obtenidos en los diferentes niveles de emulación de información capturada en el laboratorio.

Note que a medida que aumenta el desajuste, se obtienen reconstrucciones con menor calidad, según las métricas de evaluación. El método propuesto, que incluye un regularizador de refuerzo mantiene una diferencia positiva con respecto a las reconstrucciones realizadas mediante un enfoque tradicional que no considera el problema de calibración. Visualmente se observa que al aumentar el desajuste se dificulta la obtención de los colores apropiados, pero la estructura de la escena se conserva.

Posteriormente, se muestran en la figura 32 las firmas espectrales correspondientes a los píxeles indicados en la figura 31. Observe que en gran parte de las firmas espectrales, hay una disminución en la métrica SAM al usar el modelo de adquisición aprendido, lo que demuestra la capacidad espectral de recuperación del método propuesto con respecto al estado del arte.

Figura 31. Comparación entre las reconstrucciones para distintos niveles de emulación.


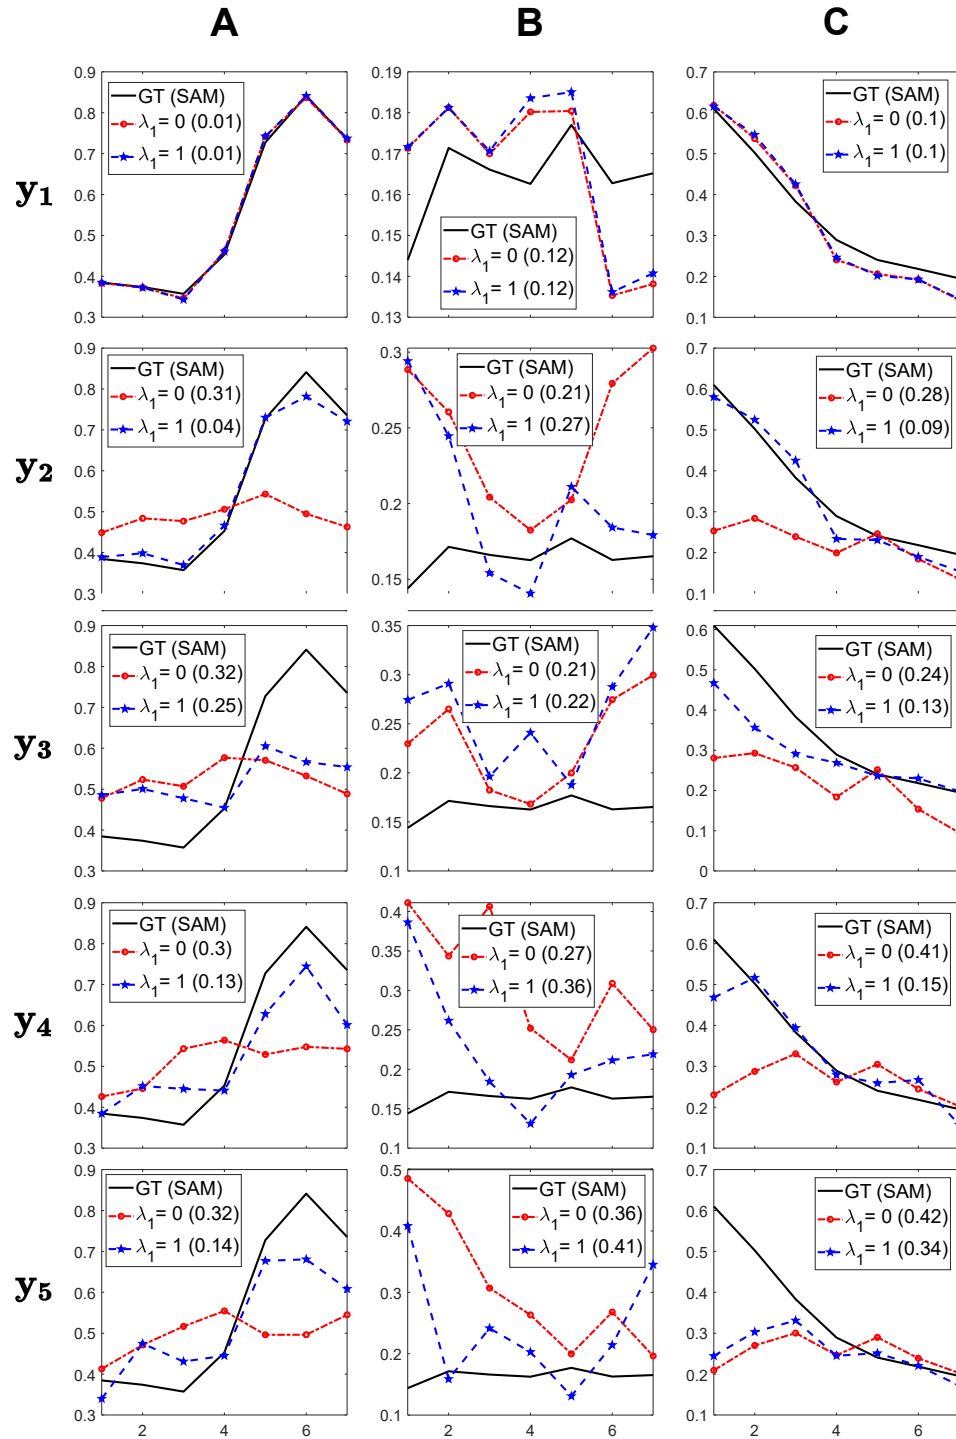


Figura 32. Comparación entre las firmas espectrales para distintos niveles de emulación.



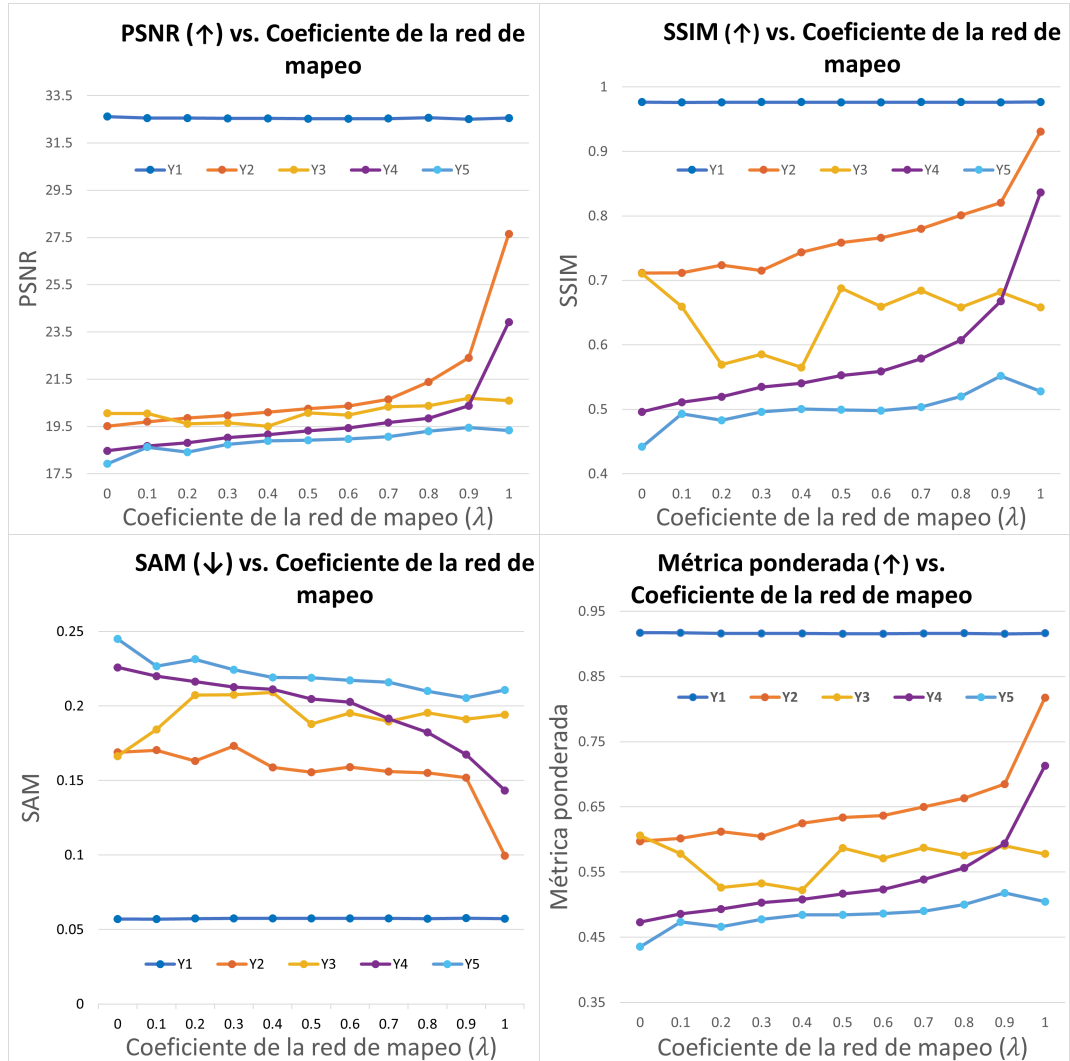
El cuadro 7 reúne en la métrica ponderada la información de la calidad de las reconstrucciones experimentales en las diferentes métricas evaluadas. Se observa un aumento de la métrica obtenida al momento de darle una ponderación superior al regularizador de refuerzo en la mayoría de las emulaciones.

Cuadro 7. Media y desviación estándar de la métrica ponderada en las reconstrucciones experimentales.

λ_1	y_1	y_2	y_3	y_4	y_5
0	$0,91 \pm 0,04$	$0,59 \pm 0,03$	$0,59 \pm 0,03$	$0,47 \pm 0,05$	$0,43 \pm 0,05$
0,1	$0,91 \pm 0,04$	$0,60 \pm 0,03$	$0,57 \pm 0,04$	$0,48 \pm 0,05$	$0,47 \pm 0,06$
0,2	$0,91 \pm 0,04$	$0,61 \pm 0,03$	$0,52 \pm 0,06$	$0,49 \pm 0,05$	$0,46 \pm 0,06$
0,3	$0,91 \pm 0,04$	$0,60 \pm 0,03$	$0,53 \pm 0,06$	$0,50 \pm 0,05$	$0,47 \pm 0,06$
0,4	$0,91 \pm 0,04$	$0,62 \pm 0,03$	$0,52 \pm 0,05$	$0,50 \pm 0,05$	$0,48 \pm 0,06$
0,5	$0,91 \pm 0,04$	$0,63 \pm 0,03$	$0,58 \pm 0,05$	$0,51 \pm 0,05$	$0,48 \pm 0,06$
0,6	$0,91 \pm 0,04$	$0,63 \pm 0,03$	$0,57 \pm 0,05$	$0,52 \pm 0,05$	$0,48 \pm 0,06$
0,7	$0,91 \pm 0,04$	$0,65 \pm 0,03$	$0,58 \pm 0,05$	$0,53 \pm 0,05$	$0,49 \pm 0,06$
0,8	$0,91 \pm 0,04$	$0,66 \pm 0,03$	$0,57 \pm 0,07$	$0,55 \pm 0,05$	$0,50 \pm 0,06$
0,9	$0,91 \pm 0,04$	$0,68 \pm 0,04$	$0,59 \pm 0,06$	$0,59 \pm 0,04$	$0,51 \pm 0,06$
1	$0,91 \pm 0,04$	$0,81 \pm 0,06$	$0,57 \pm 0,06$	$0,71 \pm 0,06$	$0,50 \pm 0,06$

En la figura 33 se muestran gráficamente las medias de las métricas evaluadas en las reconstrucciones obtenidas a partir de la medidas comprimidas emuladas con información capturada en el laboratorio. De las gráficas se observa un comportamiento constante para el caso con mayor cantidad de asunciones, y_1 . Las reconstrucciones obtenidas a partir de y_2 y y_4 muestran una mejora sustancial al momento de aumentar la ponderación del modelo de adquisición propuesto, por lo que su mejor reconstrucción se da en $\lambda_1 = 1$. En el caso de y_3 se observa que si $\lambda_1 = 0,5$ o $\lambda_1 = 0,9$ se tiende a aumentar la calidad y son comparables con $\lambda_1 = 0$. La recuperación a partir de la medida comprimida con integración óptica, y_5 , tiene una tendencia a la mejora cuando se utiliza $\lambda_1 = 0,9$.

Figura 33. Influencia espectral del regularizador de refuerzo en las reconstrucciones espectrales.



En la figura 33 se puede observar que para la información capturada en el laboratorio, la matriz de adquisición juega un rol importante, pues no en todos los casos $\lambda_1 = 1$ obtiene las mejores reconstrucciones en términos de las métricas de calidad.

5. CONCLUSIONES

En este trabajo se propuso aprender un modelo de adquisición del sistema óptico CASSI que considera el problema de la calibración que posteriormente es utilizado en un algoritmo de reconstrucción de imágenes espectrales. Para esto se realizó el modelamiento matemático del sistema óptico y se realizaron simulaciones de la degradación donde se evidenció la influencia positiva del regularizador de refuerzo comparado con utilizar la función de costo empleada en los esquemas tradicionales, Además, se validó el rendimiento del método propuesto de manera experimental, donde se evidenció la corrección del desajuste y las aberraciones presentes en el sistema óptico implementado.

6. TRABAJO FUTURO

El método propuesto puede ser validado en diferentes sistemas ópticos del estado del arte, debido a que ha demostrado mejorar las reconstrucciones de imágenes espectrales considerando el problema de la calibración mediante el aprendizaje del modelo de adquisición.

BIBLIOGRAFÍA

- Agarap, Abien Fred. «Deep learning using rectified linear units (relu)». En: *arXiv preprint arXiv:1803.08375* (2018) (vid. pág. 48).
- Alzubaidi, Laith y col. «Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions». En: *Journal of big Data* 8 (2021), págs. 1-74 (vid. págs. 27, 48).
- Arad, Boaz y col. «NTIRE 2022 Spectral Recovery Challenge and Data Set». En: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) Workshops*. Jun. de 2022, págs. 863-881 (vid. pág. 44).
- Arguello, Henry y col. «Higher-order computational model for coded aperture spectral imaging». En: *Applied optics* 52.10 (2013), págs. D12-D21 (vid. págs. 14, 30, 33, 45).
- Bentley, Jon Louis. «Multidimensional divide-and-conquer». En: *Communications of the ACM* 23.4 (1980), págs. 214-229 (vid. pág. 24).
- Bottou, Léon. «Stochastic gradient descent tricks». En: *Neural networks: Tricks of the trade*. Springer, 2012, págs. 421-436 (vid. pág. 40).
- Boyd, Stephen y col. «Distributed optimization and statistical learning via the alternating direction method of multipliers». En: *Foundations and Trends® in Machine learning* 3.1 (2011), págs. 1-122 (vid. págs. 24, 39).

- Briottet, X y col. «Military applications of hyperspectral imagery». En: *Targets and backgrounds XII: Characterization and representation*. Vol. 6239. SPIE. 2006, págs. 82-89 (vid. pág. 12).
- Buades, Antoni, Bartomeu Coll y J-M Morel. «A non-local algorithm for image denoising». En: *2005 IEEE computer society conference on computer vision and pattern recognition (CVPR'05)*. Vol. 2. IEEE. 2005, págs. 60-65 (vid. pág. 26).
- Candes, Emmanuel y Justin Romberg. «Sparsity and incoherence in compressive sampling». En: *Inverse problems* 23.3 (2007), pág. 969 (vid. pág. 21).
- Candès, Emmanuel J y Michael B Wakin. «An introduction to compressive sampling». En: *IEEE signal processing magazine* 25.2 (2008), págs. 21-30 (vid. págs. 20, 22).
- Cao, Xun y col. «Computational snapshot multispectral cameras: Toward dynamic capture of the spectral world». En: *IEEE Signal Processing Magazine* 33.5 (2016), págs. 95-108 (vid. pág. 22).
- Chan, Stanley H, Xiran Wang y Omar A Elgendy. «Plug-and-play ADMM for image restoration: Fixed-point convergence and applications». En: *IEEE Transactions on Computational Imaging* 3.1 (2016), págs. 84-98 (vid. pág. 26).
- Correa, Claudia V, Henry Arguello y Gonzalo R Arce. «Spatiotemporal blue noise coded aperture design for multi-shot compressive spectral imaging». En: *JOSA A* 33.12 (2016), págs. 2312-2322 (vid. pág. 31).
- Dabov, Kostadin y col. «Image denoising by sparse 3-D transform-domain collaborative filtering». En: *IEEE Transactions on image processing* 16.8 (2007), págs. 2080-2095 (vid. pág. 26).

- Escobar, Jessica, Jorge Bacca y Henry Arguello. «Non-linear Propagation Model Learning for Coded Aperture Snapshot Spectral Imaging». En: *Computational Optical Sensing and Imaging*. Optica Publishing Group. 2022, CW4B-2 (vid. pág. 30).
- Escobar Pérez, Jessica Paola. *Aprendizaje de un modelo de propagación no lineal para el sistema óptico de adquisición de imágenes espectrales basado en apertura codificada de única captura (CASSI) a través de redes neuronales profundas*. spa. 2022 (vid. pág. 30).
- Gastal, Eduardo SL y Manuel M Oliveira. «Domain transform for edge-aware image and video processing». En: *ACM SIGGRAPH 2011 papers*. 2011, págs. 1-12 (vid. pág. 26).
- Gat, Nahum. «Imaging spectroscopy using tunable filters: a review». En: *Wavelet Applications VII* 4056 (2000), págs. 50-64 (vid. pág. 19).
- Goodfellow, Ian, Yoshua Bengio y Aaron Courville. *Deep learning*. MIT press, 2016 (vid. pág. 27).
- Gualdrón-Hurtado, Romario, Jorge Bacca y Henry Arguello. «Compressive Spectral Image Reconstruction by using a Deep Image Prior with a Mismatch Regularizer». En: *Imaging and Applied Optics Congress 2022 (3D, AOA, COSI, ISA, pcAOP)*. Optica Publishing Group, 2022, CW4B.3. DOI: 10.1364/COSI.2022.CW4B.3 (vid. pág. 30).
- Gupta, Rajiv y Richard I Hartley. «Linear pushbroom cameras». En: *IEEE Transactions on pattern analysis and machine intelligence* 19.9 (1997), págs. 963-975 (vid. pág. 19).

- Hayakawa, Ryo. «Asymptotic analysis of ADMM for compressed sensing». En: *arXiv preprint arXiv:2009.08545* (2020) (vid. pág. 24).
- He, Kaiming y col. «Deep residual learning for image recognition». En: *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016, págs. 770-778 (vid. pág. 27).
- Heide, Felix y col. «Encoded diffractive optics for full-spectrum computational imaging». En: *Scientific reports* 6.1 (2016), págs. 1-10 (vid. pág. 29).
- Hennessy, Andrew, Kenneth Clarke y Megan Lewis. «Hyperspectral classification of plants: A review of waveband selection generalisability». En: *Remote Sensing* 12.1 (2020), pág. 113 (vid. pág. 12).
- Hore, Alain y Djemel Ziou. «Image quality metrics: PSNR vs. SSIM». En: *2010 20th international conference on pattern recognition*. IEEE. 2010, págs. 2366-2369 (vid. pág. 42).
- Hunt, Graham R. «Spectral signatures of particulate minerals in the visible and near infrared». En: *Geophysics* 42.3 (1977), págs. 501-513 (vid. pág. 18).
- Kieser, Robert, Pall Reynisson y Timothy J Mulligan. «Definition of signal-to-noise ratio and its critical role in split-beam measurements». En: *ICES Journal of Marine Science* 62.1 (2005), págs. 123-130 (vid. pág. 57).
- Kingma, Diederik P y Jimmy Ba. «Adam: A method for stochastic optimization». En: *arXiv preprint arXiv:1412.6980* (2014) (vid. pág. 40).

- Krahmer, Felix, Christian Kruschel y Michael Sandbichler. «Total variation minimization in compressed sensing». En: *Compressed sensing and its applications*. Springer, 2017, págs. 333-358 (vid. pág. 26).
- Kruse, Fred A y col. «The spectral image processing system (SIPS)-interactive visualization and analysis of imaging spectrometer data». En: *Remote sensing of environment* 44.2-3 (1993), págs. 145-163 (vid. pág. 42).
- Lanthier, Yannick y col. «Hyperspectral data segmentation and classification in precision agriculture: A multi-scale analysis». En: *IGARSS 2008-2008 IEEE International Geoscience and Remote Sensing Symposium*. Vol. 2. IEEE. 2008, págs. II-585 (vid. pág. 12).
- Marquez, Miguel y col. «Deep-Learning Supervised Snapshot Compressive Imaging Enabled by an End-to-End Adaptive Neural Network». En: *IEEE Journal of Selected Topics in Signal Processing* 16.4 (2022), págs. 688-699 (vid. pág. 33).
- Mataev, Gary, Peyman Milanfar y Michael Elad. «Deepred: Deep image prior powered by red». En: *Proceedings of the IEEE/CVF International Conference on Computer Vision Workshops*. 2019, págs. 0-0 (vid. pág. 30).
- Miha, Dragos y Eugen Strajescu. «FROM WAVELENGTH TO RGB FILTER». En: *University "Politehnica" of Bucharest Scientific Bulletin, Series D: Mechanical Engineering* 69.2 (2007), págs. 77-84 (vid. pág. 18).
- Ogorzalek, Bernard y col. «SSUSI-Lite: a far-ultraviolet hyper-spectral imager for space weather remote sensing». En: *Solar Physics and Space Weather Instrumentation VI*. Vol. 9604. SPIE. 2015, pág. 960402 (vid. pág. 18).

- Pinto, Jhon, Hoover Rueda-Chacón y Henry Arguello. «Classification of Hass avocado (persea americana mill) in terms of its ripening via hyperspectral images». En: *TecnoLógicas* 22.45 (2019), págs. 111-130 (vid. pág. 12).
- Poon, Clarice. «On the role of total variation in compressed sensing». En: *SIAM Journal on Imaging Sciences* 8.1 (2015), págs. 682-720 (vid. pág. 26).
- Price, John C. «How unique are spectral signatures?» En: *Remote Sensing of Environment* 49.3 (1994), págs. 181-186. DOI: [https://doi.org/10.1016/0034-4257\(94\)90013-2](https://doi.org/10.1016/0034-4257(94)90013-2) (vid. pág. 18).
- Robert, Paul y col. «Identification of chemical constituents by multivariate near-infrared spectral imaging». En: *Analytical chemistry* 64.6 (1992), págs. 664-667 (vid. pág. 18).
- Romano, Yaniv, Michael Elad y Peyman Milanfar. «The little engine that could: Regularization by denoising (RED)». En: *SIAM Journal on Imaging Sciences* 10.4 (2017), págs. 1804-1844 (vid. pág. 29).
- Ronneberger, Olaf, Philipp Fischer y Thomas Brox. «U-net: Convolutional networks for biomedical image segmentation». En: *International Conference on Medical image computing and computer-assisted intervention*. Springer. 2015, págs. 234-241 (vid. pág. 28).
- Rueda, Hoover, Henry Arguello y Gonzalo R Arce. «Compressive spectral testbed imaging system based on thin-film color-patterned filter arrays». En: *Applied Optics* 55.33 (2016), págs. 9584-9593 (vid. pág. 32).

- Sánchez, Karen y col. «Classification of cocoa beans based on their level of fermentation using spectral information». En: *TecnoLógicas* 24.50 (2021), págs. 172-188 (vid. pág. 12).
- Shaw, Gary A y Hsiaohua K Burke. «Spectral imaging for remote sensing». En: *Lincoln laboratory journal* 14.1 (2003), págs. 3-28 (vid. pág. 18).
- Shoushtari, Shirin y col. «Deep Model-Based Architectures for Inverse Problems under Mismatched Priors». En: *arXiv preprint arXiv:2207.13200* (2022) (vid. pág. 23).
- Song, Lingfei y col. «High-Accuracy Image Formation Model for Coded Aperture Snapshot Spectral Imaging». En: *IEEE Transactions on Computational Imaging* 8 (2022), págs. 188-200 (vid. págs. 14, 30).
- Sterke, C Martijn de. «Optical push broom». En: *Optics letters* 17.13 (1992), págs. 914-916 (vid. pág. 19).
- Ulyanov, Dmitry, Andrea Vedaldi y Victor Lempitsky. «Deep image prior». En: *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2018, págs. 9446-9454 (vid. pág. 29).
- Veit, Andreas, Michael J Wilber y Serge Belongie. «Residual networks behave like ensembles of relatively shallow networks». En: *Advances in neural information processing systems* 29 (2016) (vid. pág. 28).
- Venkatakrishnan, Singanallur V, Charles A Bouman y Brendt Wohlberg. «Plug-and-play priors for model based reconstruction». En: *2013 IEEE Global Conference on Signal and Information Processing*. IEEE. 2013, págs. 945-948 (vid. pág. 25).

- Wang, Chuin-Mu y col. «Detection of spectral signatures in multispectral MR images for classification». En: *IEEE Transactions on Medical Imaging* 22.1 (2003), págs. 50-61 (vid. pág. 18).
- Wang, Yu Winston y col. «Multiplexed optical imaging of tumor-directed nanoparticles: a review of imaging systems and approaches». En: *Nanotheranostics* 1.4 (2017), pág. 369 (vid. pág. 19).
- Wang, Zhou y col. «Image quality assessment: from error visibility to structural similarity». En: *IEEE transactions on image processing* 13.4 (2004), págs. 600-612 (vid. pág. 42).
- Yuan, Xiaojun y col. «The application of plug-and-play ADMM framework and BM3D denoiser for compressed sensing MR image reconstruction». En: *International Journal of Computer Applications in Technology* 65.4 (2021), págs. 304-315 (vid. pág. 26).