



# UNIVERSIDAD DE GRANADA

---

Facultad de Ciencias

GRADO EN FÍSICA

TRABAJO FIN DE GRADO

**Selección de bandas óptimas en el visible  
y en el infrarrojo para la recuperación de  
imágenes hiperespectrales deterioradas por  
niebla o neblina simulada**

Presentado por:  
**D. Eloy Prieto Panadero**

Curso Académico 2021/2022

## Resumen

En este trabajo se utilizan imágenes hiperespectrales, con rango dentro de visible e infrarrojo cercano, para encontrar los tripletes de bandas que son mejores para realizar el eliminado de niebla en una imagen dada. Se busca si existe una tendencia para todas las imágenes estudiando así el promedio de los valores obtenidos a partir de la evaluación de una métrica combinada que es sensible a diferentes aspectos de la calidad de imagen. Para llevar a cabo esta búsqueda, se utilizan algoritmos pertenecientes a la herramienta de optimización de MATLAB. En este caso se usan los algoritmos Surrogated, Genético y posteriormente evaluando Patternsearch partiendo los resultados obtenidos con los dos anteriores. Se obtienen que las mejores longitudes de onda, en nm y ordenadas de mejor a peor, son el triplete [1003.60, 1003.60, 1003.60], [997.40, 997.40, 994.31], [850.29, 850.29, 850.29], [551.49, 551.49, 551.49] y el [545.62, 545.62, 545.62]; siendo la mayoría de ellos tripletes monocromáticos.

## Abstract

In this paper, I work with hyperspectral images in the visible and near infrared range. These images are used to find the best triplets for dehazing. I look for a trend for all images by studying the average values obtained within the visible and near infrared ranges. To perform this search, I use MATLAB's optimization tool algorithms. In this case, the Surrogated and Genetic algorithms are used and later on, based on the results obtained with the two previous ones, I evaluated Patternsearch. Which these proposed methods, I obtained that the best wavelengths, in nm and ordered from best to worst, are the triplets [1003.60, 1003.60, 1003.60], [997.40, 997.40, 994.31], [850.29, 850.29], [551.49, 551.49, 551.49] and [545.62, 545.62, 545.62]; most of them being monochromatic triplets.

# Índice

<b>1</b>	<b>Introducción</b>	<b>4</b>
<b>2</b>	<b>Objetivos</b>	<b>5</b>
<b>3</b>	<b>Contribuciones</b>	<b>5</b>
<b>4</b>	<b>Métodos</b>	<b>6</b>
4.1	Algoritmos de eliminación de niebla . . . . .	6
4.2	Métricas . . . . .	7
4.2.1	Métrica Multi-Scale Structural Similarity (MS-SSIM) . . . . .	7
4.2.2	Métrica Multi-Scale Improved Color Image Difference (MS-iCID) . . . . .	7
4.2.3	Métrica Visual Information Fidelity (VIF) . . . . .	8
4.2.4	Métrica combinada CMDIE . . . . .	8
4.3	Algoritmos de optimización . . . . .	9
4.3.1	Surrogated . . . . .	10
4.3.1.1	Construcción de la función o modelo sustituto . . . . .	11
4.3.1.2	Definición de la función mérito . . . . .	11
4.3.2	Algoritmo Genético . . . . .	12
4.4	Imágenes usadas . . . . .	15
<b>5</b>	<b>Resultados y discusión</b>	<b>17</b>
5.1	Análisis de la calidad de imágenes monocromo construidas a partir de la información espectral . . . . .	17
5.2	Resultados de la optimización. . . . .	18
5.2.1	Convergencia de Surrogated . . . . .	19
5.2.2	Convergencia del algoritmo genético . . . . .	19
5.3	Optimización imagen por imagen . . . . .	22
5.4	Cambio en el coeficiente de extinción . . . . .	23
<b>6</b>	<b>Conclusiones</b>	<b>25</b>
<b>7</b>	<b>Agradecimientos</b>	<b>25</b>
	<b>Referencias</b>	<b>25</b>

## 1 Introducción

La niebla o neblina es un aerosol visible que consiste en pequeñas gotas de agua o cristales de hielo suspendidos en el aire o cerca de la superficie de la Tierra. La diferencia entre estas dos, radica en el grosor de las gotas de agua en suspensión y su concentración. En el caso de la neblina, estas gotas suelen ser del orden entre los 0.01 y los 1  $\mu\text{m}$ , con una concentración entre 100 y 1000  $\text{cm}^{-3}$ ; mientras que en el caso de la niebla, suelen ser del orden entre los 1 y los 10  $\mu\text{m}$  con una concentración de entre 10 y 100  $\text{cm}^{-3}$ . En general para el caso de la niebla, tenemos gotas de mayor tamaño con una menor concentración, mientras que en la neblina es justo al contrario. En adelante se utilizará el término niebla, como término que engloba tanto a la niebla y neblina. Las partículas que forman la niebla, producen una atenuación y dispersión de la luz que puede degradar significativamente la visibilidad. Esta degradación de la visibilidad afecta a cualquier imagen obtenida con una cámara, particularmente en aquellas en las que el rango de distancias a las que están situados los objetos es grande. Como muestra de la pérdida de visibilidad producida por la niebla se presenta la imagen 1



Figura 1: Ejemplo de imágenes con niebla.

A pesar de los avances en la industria, la mala visibilidad sigue siendo un problema importante, encontrar la mejor forma de atenuar el efecto producido por la niebla es útil en multitud de campos. Las técnicas para eliminar esta degradación son cruciales en sistemas de mejora de la visión en vuelo, u en otras aplicaciones como el transporte marítimo, la teledetección, la vigilancia, y espacialmente también los sistemas que más de moda están ahora como son los sistemas de asistencia al conductor y de visión artificial.

La atenuación y dispersión de la luz depende de la distancia a la que está el objeto, de la longitud de onda, y del tipo de niebla. Este esparcimiento de la luz hace que la atmósfera se comporte como una fuente de luz, produciendo el fenómeno que se conoce como "airlight". La intensidad total con la que la luz llega a la cámara viene descrita por la siguiente ecuación [1]:

$$I(x, \lambda) = J(x, \lambda) \cdot t(x, \lambda) + A(x, \lambda) \cdot (1 - t(x, \lambda)) \quad (1.1)$$

donde  $J(x, \lambda)$  es la intensidad de la luz reflejada en la escena (antes de sufrir la atenuación atmosférica),  $A(x, \lambda)$  es la intensidad del airlight en el infinito,  $x$  es el vector  $(x, y)$  de coordenadas de cada píxel y  $t(x, \lambda)$  es el término de transmisión. En atmósfera homogénea, el término de transmisión se modela como:

$$t(x, \lambda) = e^{-\beta(\lambda)d(x)} \quad (1.2)$$

siendo  $d(x)$  la distancia desde la escena hasta la cámara y  $\beta(\lambda)$  el coeficiente de extinción de la atmósfera. El coeficiente de extinción tiene una dependencia de la forma que éste se vuelve más pequeño conforme aumenta la longitud de onda.

En este trabajo se utilizarán imágenes hiperespectrales, a diferencia de la imágenes RGB, las cuales están compuestas por tres canales; las imágenes hiperespectrales están compuestas por multitud de canales (o bandas), cada una de ellos correspondiente a una longitud de onda (o banda o canales) diferente.

## 2 Objetivos

El principal objetivo de este trabajo ha sido encontrar un intervalo de bandas para obtener las mejores imágenes sin niebla

Probar los algoritmos de eliminación de niebla así como las métricas, desarrollados originalmente para trabajar en imágenes RGB, se pueden utilizar con imágenes espectrales y conocer si funcionarían mejor para longitudes de onda particulares.

Para abordar este objetivo, en primer lugar es necesario la modificación de los métodos de eliminación de niebla debido a que la mayoría de los métodos existentes funcionan con imágenes en color de tres canales como entrada; en este trabajo, se ha dado un paso adelante buscando el triplete óptimo de bandas espectrales para usar como entrada para un algoritmo dado. Esto también puede estar relacionado con la simplificación del dispositivo de captura utilizado para una aplicación particular.

Esta búsqueda del triplete óptimo ya se intentó hacer en [3] mediante la fuerza bruta utilizando un método combinatorio, a diferencia en este trabajo se realiza la búsqueda utilizando algoritmos de optimización.

## 3 Contribuciones

Las principales contribuciones de este trabajo son:

- 1) La evaluación de tres algoritmos de eliminación de niebla de imagen única de última generación, así como la evaluación de cuatro métricas (ver sección 4.2) que tienen en cuenta diferentes aspectos como la mejora del contraste y la presencia de artefactos en la imagen.
- 2) La optimización del código, para realizar eliminado de niebla banda a banda, para poder ser ejecutado de forma paralelizada y así disminuir el tiempo de ejecución.
- 3) La selección de tres bandas óptimas en el rango de 400 a 1000 nm, llevada a cabo mediante una estrategia de búsqueda utilizando métodos de optimización. Partiendo de las imágenes hiperespectrales, que contenían 204 bandas, se ha llegado a encontrar los mejores tripletes para realizar el eliminado de niebla.

- 4) Comparación entre distintos métodos de optimización y análisis de la mejor opción para las restricciones iniciales del proceso de optimización.

En este trabajo, se presenta los resultados obtenidos a modo de comparación entre distintos métodos de optimización, así como la comparación entre la imposición de diferentes restricciones iniciales.

## 4 Métodos

### 4.1 Algoritmos de eliminación de niebla

En los últimos veinte años se han propuesto diferentes métodos para la eliminación de la niebla en imágenes. (Al no existir una palabra corta en español que signifique mejora de imagen afectada por deterioro atmosférico, de ahora en adelante se usará la palabra dehazing).

Existen multitud de algoritmos de dehazing, la primera diferencia entre unos algoritmos suele ser la cantidad de imágenes usadas para el dehazing. En este trabajo se han usado exclusivamente algoritmos que usan una sola imagen (single-image dehazing), entre los cuales destacan:

- Artificial Multiple Exposure image Fusion (AMEF) [4]
- Berman [5]
- Contrast Limited Adaptive Histogram Equalization (CLAHE) [6]
- Dark Channel Prior (DCP) [7]
- DehazeNet [8]
- Image Dehazing and Exposure Using an Enhanced Atmospheric Scattering Model (IDE) [9]
- RGB response ratio constancy [10].
- Meng [11]
- Multi-scale Convolutional Neural Networks (MSCNN) [12]

Algunos de ellos están basados en la estrategia de procesado de imagen independiente de los modelos físicos como por ejemplo los modelos AMEF y CLAHE, BERMAN. Otros usan "Deep Learning" como por ejemplo el IDE y el MSCNN. los cuales se basan en el uso de imágenes con niebla y sin niebla para entrenar al algoritmo a eliminarlas. Otros algoritmos como el DCP, MENG y LUZON, usan modelos físicos.

Los algoritmos mencionados anteriormente constituyen un conjunto bastante completo y representativo de las diferentes estrategias de eliminado de niebla existentes.

En este trabajo se usará exclusivamente los algoritmos AMEF, Berman e IDE debido a que AMEF había dado muy buenos resultados en estudios previos, IDE es algoritmo que mejores resultados ofrece de los basados en Convolutional Neural (CNN). Y Berman se ha elegido por producir un incremento de contraste notorio en las imágenes recuperadas.

## 4.2 Métricas

Los algoritmos de dehazing se suelen evaluar analizando la calidad de las imágenes recuperadas que producen y dicha evaluación se realiza mediante distintas métricas que pueden ser clasificadas en cuatro categorías:

- 1) Métricas de referencia completa: requieren la imagen de referencia (la degradada por la atmósfera) y la imagen recuperada. Es el caso de las métricas MS-iCID [13] y MS-SSIM [14].
- 2) Métricas de referencia reducida: requieren la imagen de referencia o la imagen original. Es el caso de la métrica VIF [15].
- 3) Métricas sin referencia: como su nombre indica, no requieren de imagen de referencia. Es el caso de las métricas Brisque [16], Nique [17], Pique [18].
- 4) Métricas combinadas: las cuales combinan los otros tipos de métricas. Es el caso de la métrica CMDIE [3], detallada en la sección 4.2.4

Hay que tener en cuenta que cada métrica evalúa diferentes características de la imagen. Por lo tanto, es necesario establecer un terreno común para elegir un conjunto adecuado de métricas para el análisis de resultados.

En este trabajo se han tenido muy en cuenta las métricas de referencia completa. El uso de métricas de referencia completas requiere bases de datos que incluyan imágenes con y sin niebla de una misma escena y en condiciones controladas. En general, existe una gran escasez de bases de datos de imágenes hiperespectrales en las anteriores condiciones. Por lo que se trabajará con bases de datos de imágenes con niebla simulada obtenidas utilizando imágenes capturadas por el Color Imaging Lab del Departamento de Óptica de la Universidad de Granada.

### 4.2.1 Métrica Multi-Scale Structural Similarity (MS-SSIM)

Esta métrica se basa en la métrica SSIM [19] la cual utiliza el hecho de que las imágenes tienen señales estructuradas que dependen de los píxeles vecinos [20], al igual que el sistema visual humano usa la información estructural de una escena dada. SSIM es sensible a las distorsiones que son críticas para la percepción de la escena por parte del observador humano. En esta métrica se consideran tres componentes: luminancia, contraste y estructura.

Por otro lado, la métrica MS-SSIM [14] se introdujo como una mejora de SSIM que considera la mejor escala espacial según las condiciones de visualización de la escena teniendo así en cuenta la distancia y la resolución de visualización. Estas condiciones de visualización se encuentran integradas para tener en cuenta estos factores. Los valores de esta métrica están comprendidos entre 0 y 1. Cuanto más se acerque el valor de la métrica a la unidad, más similares serán las dos imágenes que se comparan.

### 4.2.2 Métrica Multi-Scale Improved Color Image Difference (MS-iCID)

Esta métrica se propuso [13] como una mejora de la métrica de diferencia de imagen de color (CID) [21], que es la versión de SSIM adaptada a la evaluación de la diferencia

de color. Además de los anteriores factores utilizados originalmente en SSIM, se tienen en cuenta las diferencias de tono y croma, al igual que CID, pero también se aplican múltiples escalas a la imagen para obtener el valor final. Esta métrica se puede utilizar para la evaluación de la distorsión en aplicaciones de mapeo de gama [22]. Los valores de esta métrica están comprendidos entre 1 y 0. Cuanto más se acerque el valor del resultado a cero, más similares serán las dos imágenes que se comparan.

#### 4.2.3 Métrica Visual Information Fidelity (VIF)

VIF [15] evalúa la calidad de la imagen recuperada basándose en una estimación de la cantidad de información compartida entre la imagen de referencia y la imagen recuperada. La pérdida de información debido a las distorsiones se cuantifica utilizando estadísticas de la escena natural (NSS), un modelo de sistema visual humano simplificado (HVS) y un modelo de distorsión de imagen. La imagen de referencia se modela como la salida de una fuente "natural" estocástica que pasa a través del canal HVS y luego es procesada por el cerebro. Por otro lado, el contenido de información de la imagen de referencia se cuantifica como la información mutua entre la entrada y la salida del canal HVS. Esta es la información que el cerebro idealmente podría extraer de la salida del HVS. Finalmente, se cuantifica la cantidad de información de una imagen distorsionada, estimando así la información que el cerebro idealmente podría extraer de la imagen de prueba. A continuación, se calcula el VIF como la relación entre las dos estimaciones de información correspondientes a las imágenes de prueba y de referencia. Cuanto más cerca de la unidad esté el valor, mejor será el resultado, aunque el valor métrico también puede estar por encima de la unidad si se compara una versión mejorada de la imagen con la versión original.

#### 4.2.4 Métrica combinada CMDIE

Esta métrica fue propuesta en [3] como una combinación de las métricas MS-SSIM, VIF y MS-iCID. CMDIE produce un valor único para la evaluación de la calidad de la imagen, que permite llevar a cabo el método de optimización para seleccionar las mejores bandas para cada algoritmo de dehazing ya que los resultados dependen de la métrica utilizada teniendo en cuenta que se evalúan diferentes características. La métrica queda definida de la siguiente forma:

$$CMDIE = w_1 \cdot (MSiCID) + w_2 \cdot (1 - MSSIM) + w_3 \cdot |(1 - VIF)| \quad (4.1)$$

donde,  $w_1$ ,  $w_2$  y  $w_3$  son pesos relativos normalizados a la unidad. VIF representa el valor de VIF, MSiCID el valor de MS-iCID, MSSIM el valor de MS-SSIM para el par de imágenes (imagen de referencia e imagen recuperada). El propósito de los pesos se realiza para conseguir que la contribución de las tres métricas sea la misma en CMDIE, ya que las distintas métricas utilizadas tienen algunas diferencias en la forma en la que evalúan la calidad de las imágenes, realizando la media y haciendo este ajuste de pesos nos aseguramos de tener en cuenta las diferencias que las métricas presentan y su contribución sea la misma.

Teniendo en cuenta cómo se define CMDIE, cuanto más se acerca al valor nulo, mejor es la imagen obtenida del dehazing, y la métrica tendría un valor comprendido entre 1 y 0.

En adelante vamos a usar la métrica CMDIE para el proceso de selección de bandas en este trabajo.

En resumen, los valores que pueden tener las distintas métricas son:

	CMDIE	MSiCID	1-MSSIM	1-VIF
Mejor valor	0	0	0	0
Peor valor	1	1	1	1

Tabla 1: Mejores Bandas obtenidas y valor de las métricas.

### 4.3 Algoritmos de optimización

Como hemos comentado anteriormente, el principal objetivo es la obtención de las bandas óptimas para la realización del dehazing. Se ha considerado bandas óptimas como aquellas que minimizan el valor de la métrica CMDIE. Existen multitud de algoritmos de optimización, creados para encontrar mínimos de una determinada función que es comúnmente denominada función objetivo. Entre entre los distintos algoritmos de optimización [23, 24] se han estudiado los siguientes:

- fminunc
- fmincon
- global search
- fminsearch
- simulated annealing
- particleswarm
- patternsearch
- surrogated
- Algoritmos genéticos (ga)

Se ha realizado un estudio comparativo entre los todos los algoritmos anteriormente mencionados. Para ello, por un lado se han hecho pruebas usando un número de imágenes inferior al total disponible, y por otro lado se han usado funciones de prueba con mínimos conocidos como las funciones de Hartmann, Levy N13, Michalewicz o Rastrigin entre otras [26]. Se han escogido éstas debido a su similitud en comportamiento respecto a CMDIE.

Tras este estudio comparativo resulta que los algoritmos fminunc, fmincon y global search no funcionan adecuadamente para obtener el mínimo de nuestra función. CMDIE es por lo general una función no suave, además de que está definida de forma discreta, ya que está limitada por la cantidad de bandas diferentes que tenemos en las imágenes hiperespectrales. Por otro lado fminsearch y simulated annealing convergen muy rápidamente y encuentran exclusivamente un mínimo local. El algoritmo patternsearch, está mejor diseñado para poder encontrar mínimos globales, ofreciendo así mejores resultados que los anteriores algoritmos. Esta función comienza a buscar entorno a un punto, si

se comienza utilizando distintos puntos uniformemente distribuidos, se pueden obtener buenos resultados. Los algoritmos con los que se han obtenido mejores resultados han sido *ga*, y *surrogated*, cuyo funcionamiento veremos en detalle más adelante.

Por último, se han descartado el estudio de algoritmos como la optimización bayesiana y similares, debido a la gran complejidad que presenta su implementación para este caso.

### 4.3.1 Surrogated

*Surrogateopt* es un algoritmo de optimización diseñado para intentar encontrar un mínimo global de una función. Este algoritmo está diseñado para tratar sobre todo con funciones objetivo que consumen mucho tiempo de cálculo [27] (como es en este caso la obtención del valor de *CMDIE*). Como veremos más adelante, este algoritmo funciona bien para funciones objetivo con gran consumo de tiempo de cálculo ya que crea una función sustituta (o "surrogate", en inglés) a partir de la evaluación de puntos aleatorios. A su vez, este algoritmo puede tratar también con diversas condiciones sobre la variable o variables a optimizar, como puede ser por ejemplo, establecer límites superiores o inferiores, así como, establecer condiciones de distancia entre los valores de una variable y los de otra. Este algoritmo realiza repetidamente estos pasos:

- 1) Crea un conjunto de puntos de prueba aleatorios dentro de los límites establecidos y evalúa la función objetivo en los puntos de prueba. La cantidad de puntos aleatorios que crea se encuentra definida por la opción *MinSurrogatePoints*. Cuantos más valores aleatorios sean creados, más precisos serán los resultados que nos proporcionará, pero se tardará más tiempo para finalizar. *Surrogateopt* crea este número de puntos aleatorios después de cada cambio a la fase de generación aleatoria.
- 2) Crea un modelo sustituto de la función objetivo (*surrogated*, en adelante) interpolando una función de base radial a través de todos los puntos de ensayo aleatorios.
- 3) Crea una función de mérito que le asigna un peso al modelo sustitutivo y un peso a la distancia entre los puntos de prueba. Localiza el valor más pequeño de la función de mérito muestreando al azar dicha función en una región alrededor del punto "incumbent" (el mejor punto encontrado desde el último reset del sustituto). Si al muestrear encuentra un punto mejor en la función sustituta, usa este punto, llamado el punto adaptativo o "adaptive", como un nuevo punto de prueba.
- 4) Evalúa la función objetivo en el punto adaptativo, y actualiza el modelo sustituto basándose en este punto y su valor. Cuenta un "éxito" si el valor de la función objetivo es suficientemente inferior (más bajo) al mejor valor anterior observado, y cuenta un "fracaso" de lo contrario.
- 5) Actualiza la dispersión de la distribución de la muestra dándole un valor más alto si se producen tres éxitos antes que se produzcan  $\max(\text{nvar}, 5)$  fallos, de donde *nvar* es el número de variables a optimizar. En caso contrario, actualiza la dispersión dándole un valor más bajo si se producen  $\max(\text{nvar}, 5)$  fallos antes de tres éxitos.
- 6) Continúa desde el paso 3 hasta que todos los puntos de prueba estén dentro de *MinSampleDistance* de los puntos evaluados. En ese momento, restablece el susti-

tuto (surrogate reset) descartando todos los puntos adaptativos del sustituto, restablece la escala y vuelve al paso 1 para crear nuevos puntos de prueba aleatorios `MinSurrogatePoints` para la evaluación.

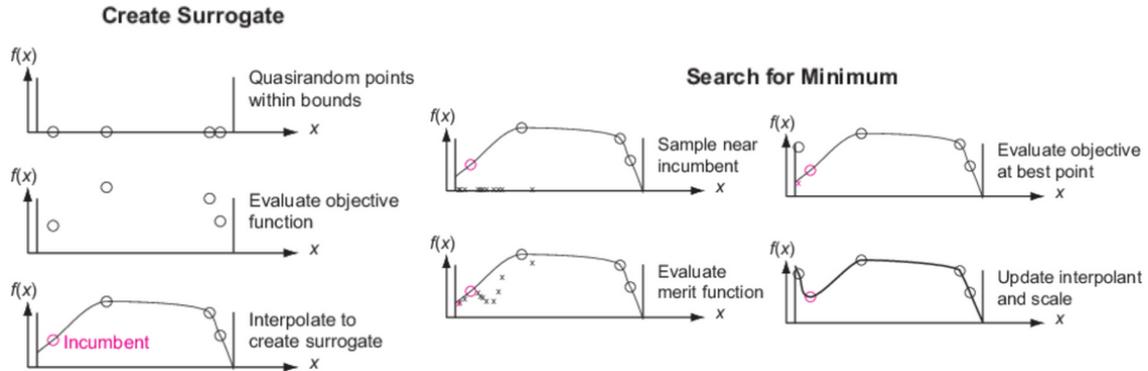


Figura 2: Esquema gráfico del funcionamiento de surrogated [28].

El proceso de convergencia puede encontrarse descrito con más detalle en la sección 4.2.1.

#### 4.3.1.1 Construcción de la función o modelo sustituto

El algoritmo, usando los puntos aleatorios generados, construye un sustituto realizando una interpolación de la función objetivo utilizando un interpolador de función de base radial (RBF). La interpolación RBF tiene varias propiedades convenientes que la hacen adecuada para construir un sustituto:

- 1) Se define utilizando la misma fórmula en cualquier número de dimensiones y con cualquier número de puntos.
- 2) Toma los valores prescritos en los puntos evaluados.
- 3) La evaluación de la RBF es muy rápida.
- 4) Se puede agregar un punto a una interpolación existente y es relativamente rápida.
- 5) La construcción de la RBF implica resolver un sistema de ecuaciones lineales  $N$ -por- $N$ , donde  $N$  es el número de puntos sustitutos. Como mostró Powell [29], este sistema tiene una solución única para muchos RBF. `Surrogateopt` utiliza un RBF cúbico con una cola lineal. Esta RBF minimiza la fluctuaciones de la función entre los valores de los puntos aleatorios. Véase Gutmann [30].

#### 4.3.1.2 Definición de la función mérito

La función mérito  $f_{merit}(x)$  está definida por una combinación ponderada de dos términos:

- 1) Sustituto escalado. Definiendo  $s_{min}$  como el valor sustituto mínimo entre los puntos de muestra,  $s_{max}$  como el máximo y  $s(x)$  como el valor sustituto en el punto  $x$ . Siendo

el valor sustituto, el valor de un punto evaluado en el modelo sustituto anteriormente creado. Entonces el sustituto escalado  $S_{esc}(x)$  es:

$$S_{esc}(x) = \frac{s(x) - s_{min}}{s_{max} - s_{min}} \quad (4.2)$$

Nótese que  $S_{esc}(x)$  es siempre positivo y que resulta ser nulo en los puntos  $x$  que tienen un valor sustituto mínimo entre los puntos de muestra.

2) Distancia escalada. Definiendo  $x_j, j = 1, \dots, k$  como los  $k$  puntos evaluados. Sea  $d_{ij}$  como la distancia desde el punto de muestra  $i$  hasta el punto evaluado  $k$ . Establezca  $d_{min} = \min(d_{ij})$  y  $d_{max} = \max(d_{ij})$ , donde el mínimo y el máximo se toman sobre todos los  $i$  y  $j$ . La distancia escalada  $D_{esc}(x)$  es:

$$D_{esc}(x) = \frac{d_{max} - d(x)}{d_{max} - d_{min}} \quad (4.3)$$

donde  $d(x)$  es la distancia mínima del punto  $x$  a un punto evaluado. Nótese que  $D_{esc}(x)$  es siempre positivo y que es cero en los puntos  $x$  que están lo más lejos posible de los puntos evaluados. Entonces, minimizar  $D_{esc}(x)$  lleva al algoritmo a puntos que están lejos de los puntos evaluados.

Teniendo esto en cuenta, la función de mérito es una combinación del sustituto escalado y la distancia escalada. Para un peso  $w$  con  $0 < w < 1$ , la función de mérito es:

$$F_{merit}(x) = w \cdot S_{esc}(x) + (1 - w)D_{esc}(x) \quad (4.4)$$

Notar que un valor grande de  $w$  da importancia a los valores suplentes, lo que hace que la búsqueda minimice el suplente. Un valor pequeño de  $w$  da importancia a los puntos que están lejos de los puntos evaluados, lo que lleva a la búsqueda a nuevas regiones. Durante la fase de búsqueda del mínimo, el peso  $w$  pasa por estos cuatro valores, como sugieren Regis y Shoemaker [31]: 0.3, 0.5, 0.8 y 0.95.

### 4.3.2 Algoritmo Genético

Los algoritmos genéticos (GA) son técnicas de búsqueda estocástica de propósito general basados en poblaciones que imitan los principios de la selección natural y la genética establecidos por Charles Darwin. El concepto de GA fue introducido por Holland [33]. Este enfoque fue utilizado por primera vez para resolver problemas de optimización por De-Jong [34]. Una implementación detallada de GA se puede encontrar en [35]. Este algoritmo está basado en los procesos naturales de evolución y selección natural, y ha sido utilizado en multitud de campos diferentes. Este algoritmo realiza repetidamente estos pasos:

- 1) Comienza creando una población inicial aleatoria, denominada generación 1.
- 2) Crea una secuencia de nuevas poblaciones. En cada paso, el algoritmo utiliza los individuos de la generación actual para crear la siguiente población. Para crear la nueva población, el algoritmo realiza los siguientes pasos:
  - a) Califica a cada miembro de la población actual calculando su valor de aptitud (valor de CMDIE). Estos valores se denominan puntajes brutos de condición

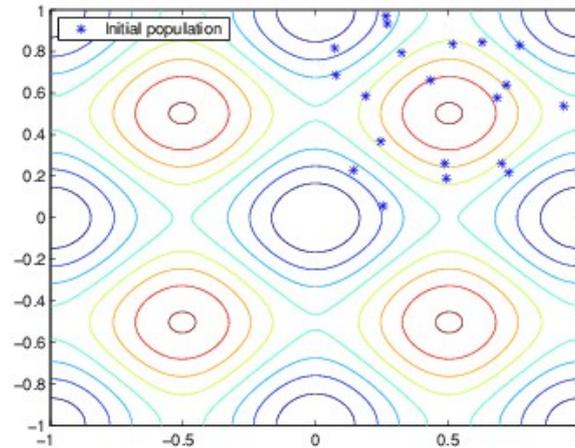


Figura 3: Paso 1: población inicial [36]

física.

- b) Reescala los puntajes anteriores para convertirlos en un rango de valores más utilizable. Estos valores escalados se denominan valores esperados.
  - c) Selecciona a los miembros, llamados padres, según sus valores esperados.
  - d) Algunos de los individuos de la población actual que tienen una aptitud más baja se eligen como élite. Estos individuos de élite se pasan a la siguiente población.
  - e) Produce hijos de los padres. Los hijos se producen haciendo cambios aleatorios en un solo padre (mutación) o combinando las entradas de vectores de un par de padres (cruce).
  - f) Reemplaza la población actual con los hijos para formar la próxima generación.
- 3) El algoritmo se detiene cuando se cumple uno de los criterios de detención. En nuestro caso cuando durante 5 generaciones no se encuentra un hijo con un mejor valor de CMDIE.
  - 4) En nuestro caso los valores  $x$  para evaluar CMDIE son números enteros porque corresponden a un orden de bandas, estas bandas están numeradas de 1 al 204 cada una de las cuales correspondiente a una longitud de onda diferente. El algoritmo tiene que elegir una banda concreta entre la 204 bandas lo que supone varias modificaciones en el algoritmo genético.

De forma predeterminada, las funciones creación, cruce y mutación exigen que las variables sean números enteros. Para más detalles, véase Deep et al. [37]. El algoritmo genético intenta minimizar una función de penalización, no la función de aptitud. La

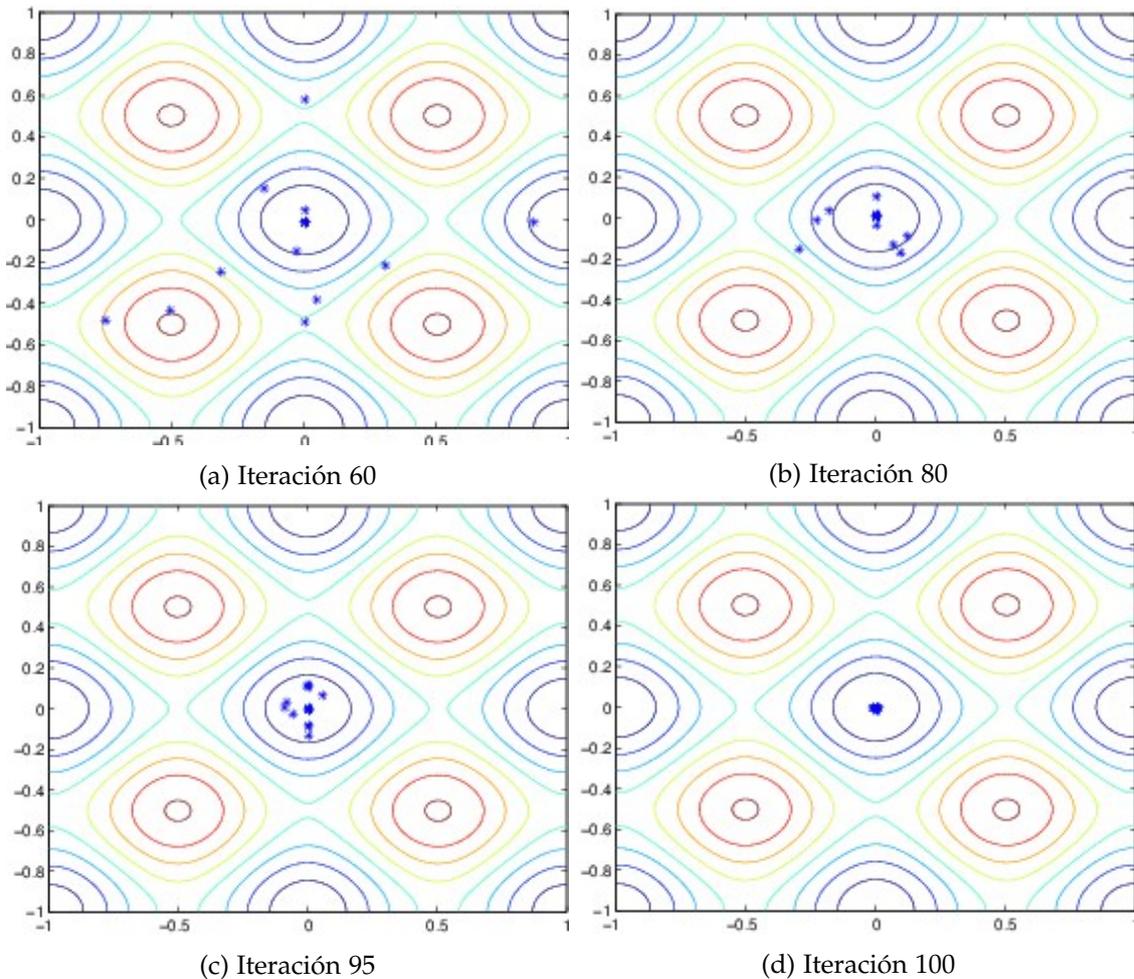


Figura 4: Paso 2: evolución.

función de penalización incluye un término para la inviabilidad. Esta función de penalización se combina con la selección binaria de forma predeterminada para seleccionar individuos para las generaciones posteriores. El valor de la función de penalización de un miembro de una población es:

a) Si el miembro es factible, la función de penalización es la función de aptitud.

b) Si el miembro no es factible, la función de penalización es la función de aptitud máxima entre los miembros factibles de la población, más la suma de las violaciones de las restricciones del punto (no factible). Para obtener detalles sobre la función de penalización, consulte Deb [38].

Los algoritmos internos para trabajar con enteros son similares a los de surrogateopt. Cuando un problema tiene restricciones enteras, el algoritmo primero crea puntos linealmente factibles. Luego, el algoritmo intenta satisfacer las restricciones de enteros redondeando puntos linealmente factibles a números enteros utilizando una heurística que intenta mantener los puntos linealmente factibles. Cuando este proceso no logra obtener suficientes puntos factibles para construir una población, el algoritmo trata de encontrar más puntos que sean factibles con respecto a los límites, las restricciones lineales y las restricciones de enteros.

Más tarde, cuando la mutación o el cruce crean nuevos miembros de la población, los

algoritmos aseguran que los nuevos miembros sean enteros y lineales factibles tomando pasos similares. Cada miembro nuevo se modifica, si es necesario, para estar lo más cerca posible de su valor original, al mismo tiempo que satisface las restricciones y los límites de enteros y lineales.

#### 4.4 Imágenes usadas

En la figura 5 se muestran las imágenes en RGB que han sido usadas en este trabajo. Estas imágenes fueron capturadas usando la las cámaras hiperespectrales Pika L y Pika NIR de Resonon. Se capturaron en la ciudad de Granada y en pueblos cercanos.



(a) Imagen 1



(b) Imagen 2



(c) Imagen 3



(d) Imagen 4



(e) Imagen 5



(f) Imagen 6



(g) Imagen 7



(h) Imagen 8



(i) Imagen 9



(j) Imagen 10

Figura 5: Imágenes de referencia usadas en RGB.

Partiendo de dichas imágenes capturadas de forma hiperespectral, se realiza una simulación de niebla debido a la imposibilidad de capturar bajo las mismas condiciones parejas de imágenes con y sin niebla en la zona geográfica de Granada. Para realizar esta simulación se usa el modelo dicromáticos de espaciamiento atmosférico [39], el cual es usado en muchos otros trabajos.

## 5 Resultados y discusión

### 5.1 Análisis de la calidad de imágenes monocromo construidas a partir de la información espectral

En primer lugar, se realiza una adaptación de varios métodos de eliminación de niebla de una sola imagen. Esta adaptación, se realizó mediante la construcción de imágenes monocromáticas de tres canales (con la misma información en cada canal, correspondiente a una longitud de onda). Construidos estos tripletes monocromáticos, se lleva a cabo un dehazing utilizando los algoritmos AMEF, Berman e IDE, obteniendo así la imagen recuperada para cada una de las bandas. Para evaluar la eficacia de estos algoritmos se procede a realizar un análisis de tres métricas de referencia completa, cuya labor es comparar la imagen de referencia (imagen sin niebla) con la imagen recuperada (imagen obtenida tras utilizar el algoritmo de dehazing sobre la imagen con niebla simulada). Usando estas dos imágenes, se aplican las métricas MS-iCID, 1-MS-SSIM y 1-VIF. Este procedimiento se realiza para un total de 10 imágenes hiperespectrales y a partir de los valores de cada una, se realiza la media entre todas las imágenes banda por banda, obteniendo así tres valores de métrica promedio para cada una de las bandas, tras los cuales se realiza un ajuste de los pesos para conseguir que la contribución de las tres métricas sea la misma en CMDIE. Obteniendo los pesos que aparecen en la tabla 2.

Metrica	Peso
MSiCID	0.372056
1-MSSSIM	0.487416
1-VIF	0.140528

Tabla 2: Pesos para el cálculo de CMDIE relacionados con las distintas métricas que lo componen.

Calculados los pesos, se procede a evaluar la métrica de CMDIE para cada una de las imágenes y se realiza también el promedio. Los valores promedio de las diferentes métricas usadas se representan en la figura 6.

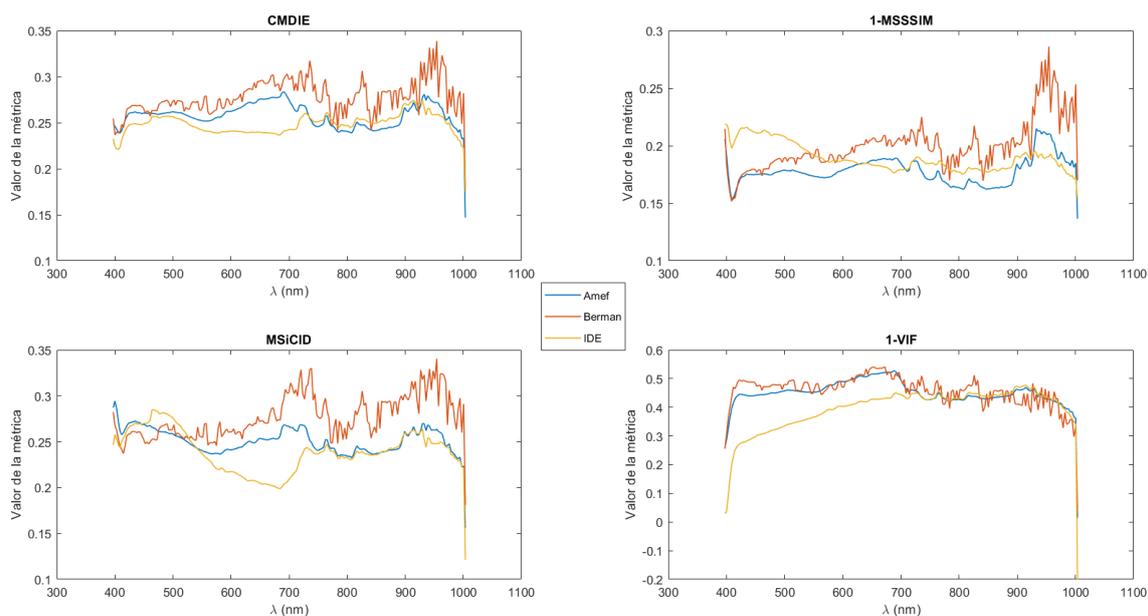


Figura 6: Métricas medias de las imágenes

Se puede observar que las mejores longitudes de onda para el eliminado de niebla, se encuentran por encima de 800 nm, sobre todo usando AMEF e IDE. Por otro lado, Berman parece ser mejor si se usa para longitudes por debajo de 700 nm.

## 5.2 Resultados de la optimización.

La optimización se ha llevado a cabo de forma separada para los algoritmos de ga y surrogated, y usando AMEF e IDE como métodos de dehazing. Para llevar a cabo la optimización se dejó que los índices de bandas en las combinaciones variaran libremente. Se tomó como hipótesis de partida que una combinación de tres bandas diferentes podría producir mejores resultados que las imágenes monocromo, pero de la tabla se deduce que no es así. Sin embargo, esto no era posible saberlo a priori sin realizar el proceso de optimización, y el número de combinaciones posibles de tres bandas diferentes era del orden de  $10^7$ , con lo cual era imposible probarlas todas mediante fuerza bruta.

Obteniendo así los siguientes resultados:

AMEF						
optimización	BANDAS	$\lambda$ (nm)	CMDIE	MSiCID	1-MSSIM	1-VIF
ga	52 52 52	545.62	0.219470	0.219259	0.160080	0.426019
surrogated	54 54 54	551.49	0.218423	0.217326	0.159263	0.426524

IDE								
optimización	BANDAS	$\lambda$ (nm)			CMDIE	MS-iCID	1-MSSIM	1-VIF
ga	202 202 201	997.40	997.40	994.31	0.208180	0.211608	0.158104	0.372789
surrogated	154 154 154	850.29			0.214587	0.209075	0.161800	0.412270

Tabla 3: Mejores bandas obtenidas, longitudes de onda y valor de las métricas.

Como curiosidad, comentar que la banda 202 202 201, tiene un mejor valor que cual-

quier otra combinación en otro orden diferente. Durante la ejecución de la optimización el algoritmo llega a probar las 3 combinaciones posibles, teniendo esa combinación como la mejor. Esto es debido a que MSiCID otorga un mejor puntaje si las bandas están ordenadas de mayor a menor, al igual que lo están en una imagen RGB. En las siguientes secciones se muestra el progreso estos dos algoritmos durante la ejecución.

### 5.2.1 Convergencia de Surrogated

La información más relevante de surrogated para entender el proceso de convergencia de este algoritmo se puede compactar en una gráfica para cada uno de los métodos de dehazing, como puede verse en la figura 7.

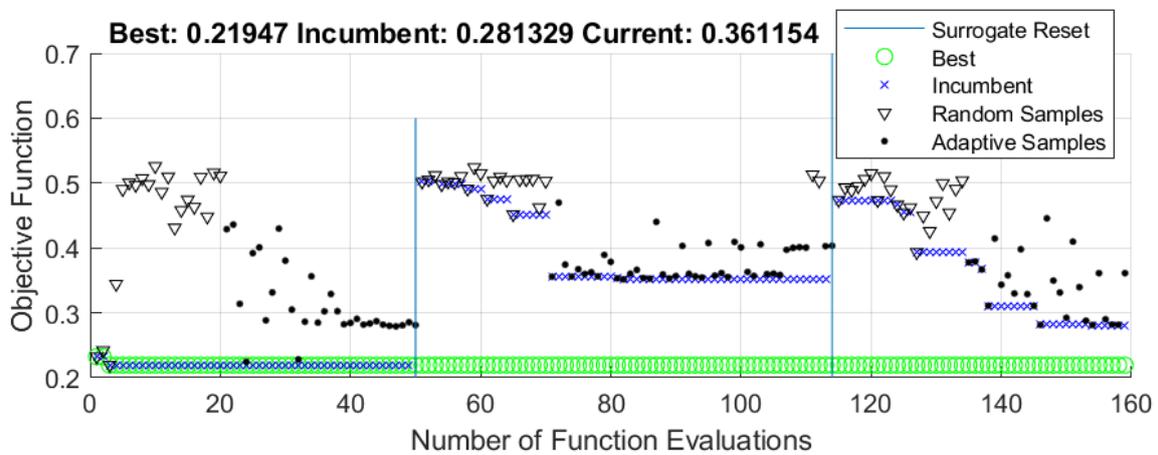


Figura 7: Figura tomada durante la ejecución de surrogated con AMEF

Donde de izquierda a derecha de la gráfica se puede observar: Los primeros puntos son triángulos negros (Random Samples), que indican las muestras pseudoaleatorias. Estos puntos provienen de la fase de construcción sustituta. A continuación, hay puntos negros que indican los puntos adaptativos (Adaptative Samples), los puntos creados en la fase de búsqueda de mínimos. Los círculos verdes (Best) representan el mejor (más bajo) valor de la función objetivo encontrado. La línea vertical indica el "Surrogate reset"; en este punto, el algoritmo vuelve a la fase construir sustituto. Además, esto ayuda al algoritmo a explorar nuevas zonas no exploradas. Por último, "Incumbent" indica el mejor punto encontrado desde el último reset del sustituto como se comentó en la sección: 4.3.1.

El proceso de búsqueda duró en torno a las 3 horas y finalizó tras realizar 300 evaluaciones de la función objetivo.

### 5.2.2 Convergencia del algoritmo genético

La evolución de algoritmo ga se muestra en la figura 8.

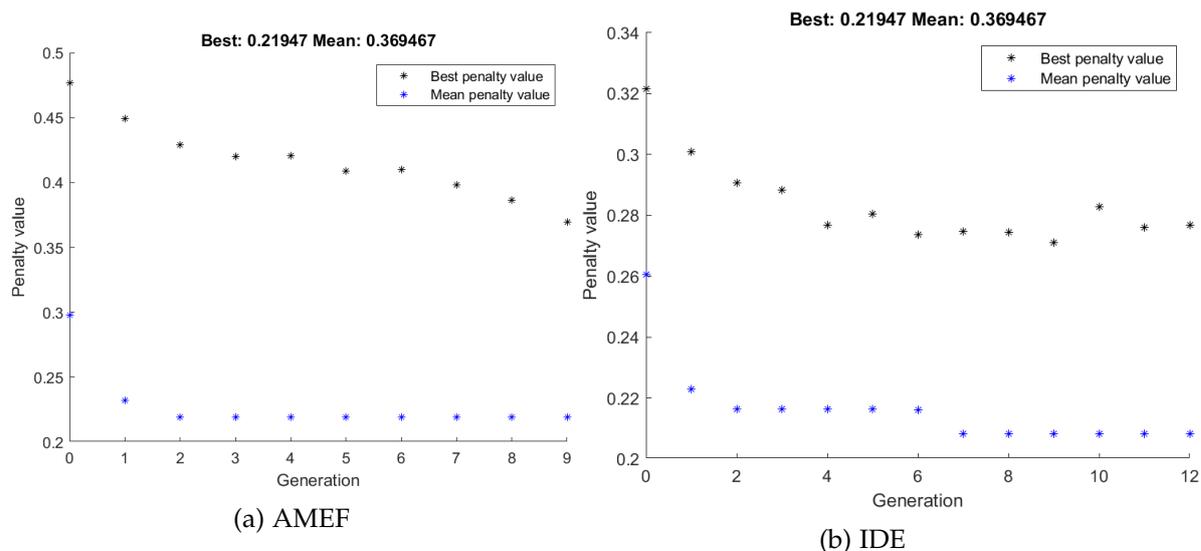


Figura 8: Figura de evolución de ga.

El proceso de búsqueda duró en torno a las 5 horas.

En general, tanto con surrogated como ga, se obtienen diferentes mínimos, pero no podemos asegurar que sean mínimos globales. La única forma posible de asegurar que se han obtenido mínimos globales sería haciendo un muestreo de todas las combinaciones, pero eso sería un reto computacional. Otra posible estrategia, sería pasar a surrogated los 15 mejores mínimos que han sido encontrados con la evaluación monocromática de CMDIE que se ha obtenido durante el ajuste de los pesos comentado en la sección 5.1. Otra posible estrategia [32] puede ser la realización de una búsqueda secuencial de mínimos. Partiendo de los distintos de los distintos puntos anteriormente encontrados como puntos iniciales, se prueba ejecutar patternsearch. Tras realizar varias pruebas cambiando el escalado de la función, se obtienen los siguientes mínimos:

patternsearch						
dehazing	BANDAS	$\lambda$ (nm)	CMDIE	MSiCID	1-MSSIM	1-VIF
AMEF	204 204 204	1003.60	0.156187	0.151069	0.148679	-0.059901
IDE	204 204 204	1003.60	0.174538	0.125276	0.165171	-0.247722

Tabla 4: Mejores bandas obtenidas, longitudes de onda y valor de las métricas.

Estos mínimos obtenidos se consideran los mínimos globales debido a la incapacidad de encontrar algún otro mejor. En la figura 9 se representa la mejor banda encontrada. Tanto usando AMEF como IDE, podemos observar en ambos casos la imagen recuperada es incluso mejor que la imagen de referencia.

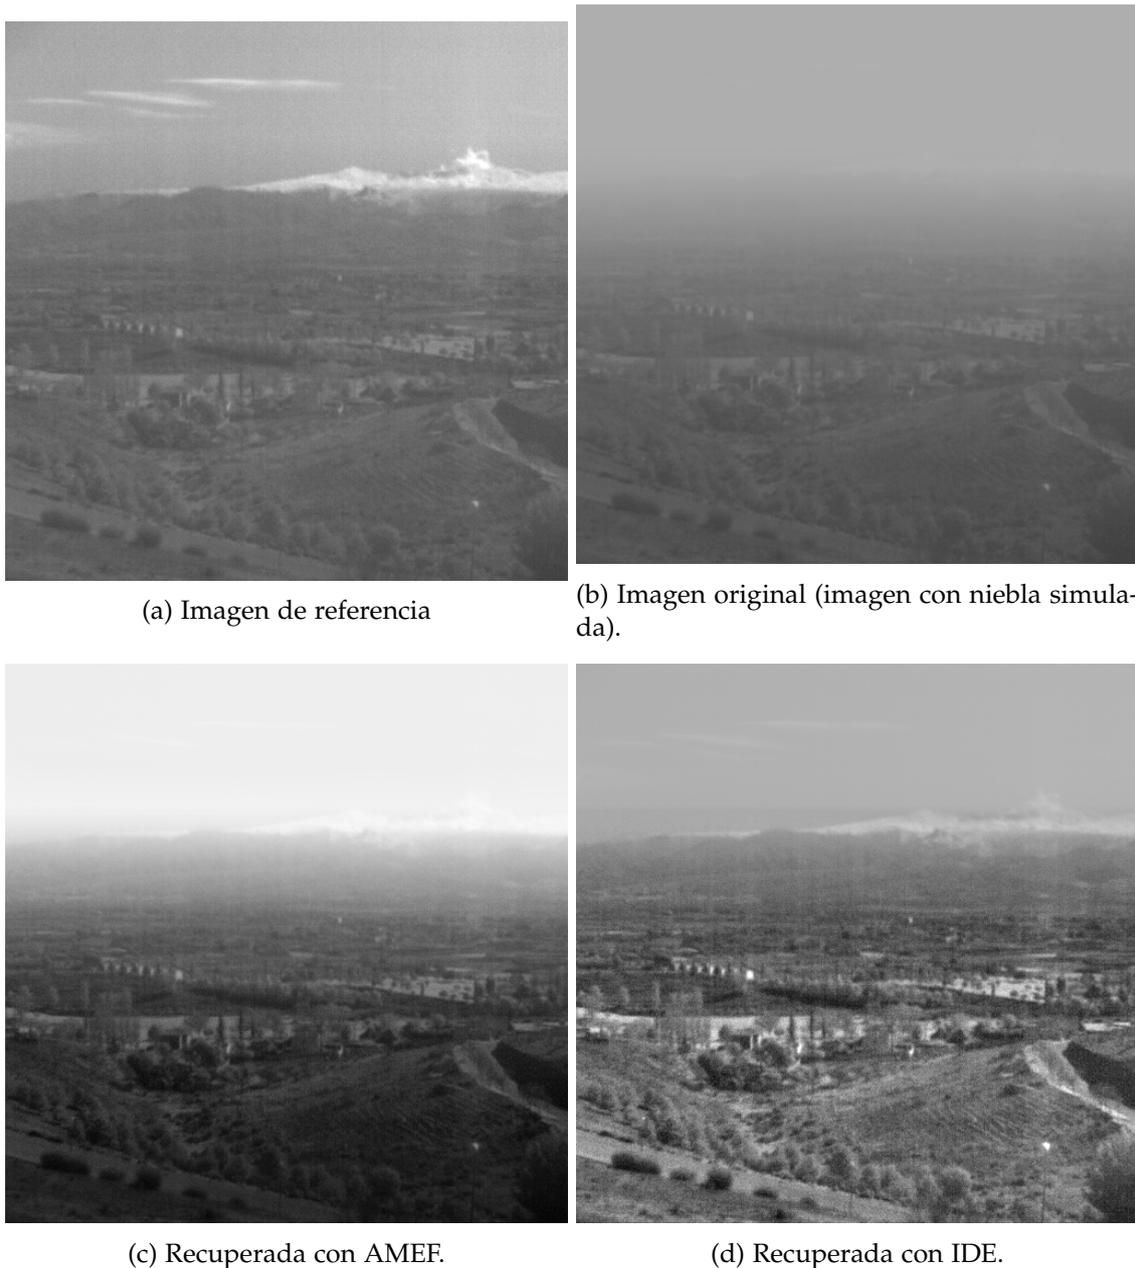


Figura 9: Imagen de referencia, original y recuperada con los diferentes algoritmos de la mejor banda encontrada.

Por lo general, *surrogated* me parece el mejor algoritmo de optimización ya que ha encontrado bandas prácticamente igual de buenas que las encontradas por *ga*, pero en la mitad de tiempo de ejecución. Además *surrogated* tiene una ventaja y es que combina un proceso estocástico y no estocástico de búsqueda, ya que tras tener la función interpolada puede conocer la pendiente de la misma, y el algoritmo va evaluando con los mejores puntos que encuentra siguiendo las pendientes. Otra ventaja es que este algoritmo puede generar los puntos aleatorios de la misma forma que el genético siendo así un algoritmo de búsqueda híbrida.

Las mejores bandas encontradas corresponden a imágenes monocromáticas. Esto puede ser debido a algunas de las métricas usadas como en el caso de VIF se calcula para

cada una de las bandas y luego se hace el promedio, si una de las bandas tiene un mejor valor, al final la optimización acaba colapsando a esa banda con mejor valor. Además VIF trabaja en el espacio hsv (hue-saturation-value), que al ser mono cromática, hace que factores como la saturación no sean algo a tener en cuenta. La métrica MSSIM también trabaja con cada una de las bandas por separado, y hace la media. Por último, MSiCID, resulta ser la única que valora la comparación del contraste y la estructura cromática de la imagen. También puede ser debido a una cuestión de calidad de imagen de referencia (la cual en los extremos del espectro es peor) y también puede ser debido a valores de  $\beta$  menores.

### 5.3 Optimización imagen por imagen

Hasta el momento la optimización realizada ha sido para el promedio del valor de CMDIE promedio de todas las imágenes anteriormente mostradas. En la tabla 5 se presentan los resultados obtenidos de esta minimización de cada imagen por separado. En la tabla se puede observar que hay bastantes imágenes en las que los mínimos encontrados coinciden entre sí.

Mínimos Imagen por Imagen							
Imagen	BANDAS	$\lambda$ (nm)	CMDIE	MSiCID	1-MSSIM	1-VIF	
Surrogated y AMEF							
1	204 204 204	1003.58 1003.58 1003.58	0.161031	0.222510	0.132541	0.097082	
2	152 156 157	844.22 856.37 859.42	0.286338	0.262744	0.225881	0.558501	
3	152 152 152	844.22 844.22 844.22	0.126668	0.105484	0.093665	0.297221	
4	1 1 1	397.32 397.32 397.32	0.161077	0.209708	0.135116	0.122367	
5	5 5 5	408.85 408.85 408.85	0.287599	0.252571	0.202112	0.676846	
6	153 153 153	847.25 847.25 847.25	0.155843	0.135144	0.133806	0.287074	
7	204 204 204	1003.58 1003.58 1003.58	0.135699	0.151380	0.161789	0.003692	
8	52 52 52	545.62 545.62 545.62	0.158939	0.151165	0.123878	0.301129	
9	45 45 45	525.10 525.10 525.10	0.232096	0.243112	0.173921	0.404705	
10	52 52 52	545.62 545.62 545.62	0.089191	0.071840	0.056939	0.246995	
Surrogated e IDE							
1	28 28 28	475.50 475.50 475.50	0.173160	0.215548	0.169774	0.072682	
2	80 81 80	628.18 631.15 628.18	0.254634	0.247914	0.237343	0.332397	
3	95 95 95	672.75 672.75 672.75	0.128669	0.091560	0.102762	0.316776	
4	160 160 160	868.55 868.55 868.55	0.140034	0.104358	0.124327	0.288970	
5	3 1 1	403.09 397.32 397.32	0.260340	0.239201	0.173839	0.616331	
6	204 204 2	1003.58 1003.58 400.20	0.152272	0.244880	0.092207	0.115420	
7	2 2 2	400.20 400.20 400.20	0.117579	0.139905	0.110673	0.082423	
8	81 81 81	631.15 631.15 631.15	0.130711	0.114958	0.100814	0.276116	
9	2 1 1	400.20 397.32 397.32	0.226233	0.264699	0.183983	0.270934	
10	47 47 47	530.96 530.96 530.96	0.095349	0.093892	0.064797	0.205178	

Mínimos Imagen por Imagen						
Imagen	BANDAS	$\lambda$ (nm)	CMDIE	MSiCID	1-MSSIM	1-VIF
Ga y AMEF						
1	153 153 153	847.25 847.25 847.25	0.234852	0.270970	0.165335	0.380346
2	203 202 202	1000.49 997.40 997.40	0.286045	0.242048	0.242262	0.554388
3	153 153 153	847.25 847.25 847.25	0.126997	0.105265	0.093723	0.299940
4	1 1 1	397.32 397.32 397.32	0.161077	0.209708	0.135116	0.122367
5	1 1 1	397.32 397.32 397.32	0.292725	0.248712	0.208531	0.701276
6	204 204 204	1003.58 1003.58 1003.58	0.136966	0.173016	0.148649	0.000996
7	204 204 204	1003.58 1003.58 1003.58	0.135699	0.151380	0.161789	0.003692
8	52 52 52	545.62 545.62 545.62	0.158939	0.151165	0.123878	0.301129
9	52 52 52	545.62 545.62 545.62	0.232113	0.243587	0.170754	0.414556
10	52 52 52	545.62 545.62 545.62	0.089191	0.071840	0.056939	0.246995
Ga e IDE						
1	21 21 21	455.16 455.16 455.16	0.174776	0.226319	0.176129	0.033623
2	102 102 103	693.62 693.62 696.61	0.256086	0.251273	0.229340	0.361598
3	203 203 203	1000.49 1000.49 1000.49	0.112188	0.114686	0.100767	0.145189
4	153 153 153	847.25 847.25 847.25	0.143782	0.105641	0.128157	0.298952
5	1 3 1	397.32 403.09 397.32	0.278344	0.287593	0.173839	0.616331
6	204 204 204	1003.58 1003.58 1003.58	0.096225	0.142303	0.075108	-0.047473
7	1 1 1	397.32 397.32 397.32	0.132089	0.160992	0.145478	-0.009129
8	103 103 103	696.61 696.61 696.61	0.145515	0.114827	0.100388	0.383285
9	5 204 5	408.85 1003.58 408.85	0.196665	0.301282	0.157687	0.054883
10	52 52 52	545.62 545.62 545.62	0.098226	0.097019	0.066318	0.212094

Tabla 5: Mínimos imagen por imagen

#### 5.4 Cambio en el coeficiente de extinción

Tras haber encontrado un mínimo, se sospecha que los resultados que se obtienen, aparte de la longitud de onda, dependen también de las condiciones de niebla; para comprobar esto, se ha simulado niebla en la última banda, pero esta vez se ha usado el coeficiente de extinción de la banda de 550 nm, obteniendo los resultados que aparecen en la tabla 6.

IDE				
Coefficiente	CMDIE	MSiCID	1-MSSIM	1-VIF
550 nm	0.170128	0.163105	0.165132	-0.032805
1003 nm	0.174538	0.125276	0.165171	-0.247722

Tabla 6: Cambio del coeficiente de extinción.

La imagen capturada a 550 nm, está tomada con mejor calidad que la tomada a 1003 nm debido a las especificaciones técnicas de la cámara. Pese a que la imagen de entrada a 550 nm tiene mejor calidad, se obtiene un valor de CMDIE que podríamos decir que es idéntico para ambas imágenes recuperadas. Por lo que pasamos a compararlas visualmente en la figura 10.

(a) Recuperada con AMEF para  $\beta(550)$ (b) Recuperada con IDE para  $\beta(550)$ (c) Recuperada con AMEF para  $\beta(1003)$ (d) Recuperada con IDE para  $\beta(1003)$ Figura 10: Comparación visual de las imágenes variando el coeficiente de extinción  $\beta$ .

Si se observa minuciosamente, se puede ver que la imagen recuperada para 1003 nm es ligeramente mejor, debido a que tenemos un mejor contraste; la recuperación permite ver Sierra Nevada al fondo de la imagen, cosa que no sucede para 550 nm. El valor de 1-VIF, es la principal diferencia entre la calidad obtenida, seguida de MSiCID. Este valor, al ser negativo, nos indica que se ha producido una mejora de la imagen; esta mejora normalmente se produce en el contraste. Comparando tanto visualmente como con los valores de 1-VIF, se puede decir que la imagen de 1003 nm sigue siendo la mejor.

## 6 Conclusiones

Encontrar un mínimo global no es tarea fácil, sin embargo los métodos de optimización son capaces de obtener buenos resultados. En los casos en los que no se han encontrado el mínimo global, el punto encontrado suele ser el siguiente mínimo por arriba del global, por lo que resulta un resultado aceptable teniendo en cuenta el tiempo de ejecución empleado.

La primera y la última bandas capturadas por el sensor pueden ser problemáticas, para verificar que el mínimo global está en esa banda habría que disponer de otra cámara que tuviera una mejor sensibilidad en esa banda.

Es cierto que la mejor banda que ha sido encontrada es la 204, pero es que para esa banda resulta que la imagen de referencia es bastante mala, comparando así una imagen de baja calidad con otra que también lo es obteniendo una similitud bastante buena. Por ello resulta mejor descartar esa banda como la mejor, haciendo así que los mínimos encontrados por surrogate y sea los mejores mínimos teniendo en cuenta este factor.

Para futuros estudios se propone trabajar más a fondo con optimización multiobjetivo de minimización simultánea de las tres métricas que componen CMDIE. Estos algoritmos multiobjetivo bajo libertad de condiciones iniciales, son capaces de ofrecer más de un solo resultado de posibles tripletes, entre los cuales se puede conseguir tanto tripletes no monocromáticos como monocromáticos.

También se propone avanzar más en el infrarrojo con otra cámara que capture imágenes más allá de 1000 nm.

## 7 Agradecimientos

Agradecimientos a Sol, por su ayuda con la familiarización de los distintos algoritmos de dehazing y las métricas. Agradecimientos a Miguel A Muñoz, del Instituto Carlos I de Física Teórica y Computacional por brindarme el acceso al servidor de Joel. Agradecimientos a Javi por su apoyo. Agradecimientos mi tutora Eva Valero, por su inestimable ayuda en la organización de este trabajo.

## Referencias

- [1] Min, X., Zhai, G., Gu, K., Zhu, Y., Zhou, J., Guo, G. et al.  
*Quality Evaluation of Image Dehazing Methods Using Synthetic Hazy Images.*  
IEEE Transactions On Multimedia, vol. 21, no. 9, pp. 2319-2333, Sept. 2019, <https://doi.org/10.1109/TMM.2019.2902097>
- [2] Martínez-Domingo, M.Á.; Valero, E.M.; Nieves, J.L.; Molina-Fuentes, P.J.; Romero, J.; Hernández-Andrés, J.  
*Single Image Dehazing Algorithm Analysis with Hyperspectral Images in the Visible Range.*  
Sensors 2020, 20, 6690.  
<https://doi.org/10.3390/s20226690>

- [3] Fernández-Carvelo S, Martínez-Domingo MÁ, Valero EM, Romero J, Nieves JL, Hernández-Andrés J.  
*Band Selection for Dehazing Algorithms Applied to Hyperspectral Images in the Visible Range.*  
Sensors (Basel). 2021 Sep 3;21(17):5935.  
<https://doi.org/10.3390/s21175935>
- [4] Galdran, A.  
*Image dehazing by artificial multiple-exposure image fusion.*  
Signal Process. 2018, 149, 135–147.  
<https://doi.org/10.1016/j.sigpro.2018.03.008>
- [5] Berman, D.; Avidan, S.  
*Non-local image dehazing.*  
In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV, USA, 27–30 June 2016; pp. 1674–1682.  
<https://doi.org/10.1109/CVPR.2016.185>
- [6] Xu, Z.; Liu, X.; Ji, N.  
*Fog Removal from Color Images using Contrast Limited Adaptive Histogram Equalization.*  
In Proceedings of the 2nd International Congress on Image and Signal Processing, Tianjin, China, 17–19 October 2009; pp. 1–5.
- [7] He, K.; Sun, J.; Tang, X.  
*Single image haze removal using dark channel prior.*  
IEEE Trans. Pattern Anal. Mach. Intell. 2010, 33,2341–2353.
- [8] Cai, B., Xu, X., Jia, K., Qing, C., y Tao, D.  
*DehazeNet: An End-to-End System for Single Image Haze Removal.*  
IEEE Transactions On Image Processing, 2016, 25(11), 5187-5198.  
<https://doi.org/10.1109/tip.2016.2598681>
- [9] Ju, M.; Ding, C.; Ren, W.; Yang, Y.; Zhang, D.; Guo, Y.J.  
*IDE: Image Dehazing and Exposure Using an Enhanced Atmospheric Scattering Model.*  
IEEE Trans. Image Process. 2021, 30, 2180–2192.  
<https://doi.org/10.1109/TIP.2021.3050643>
- [10] Luzon Gonzalez, R., Nieves, J., y Romero, J.  
*Recovering of weather degraded images based on RGB response ratio constancy.*  
Applied Optics, 2015, 54(4), B222.  
<https://doi.org/10.1364/ao.54.00b222>
- [11] Meng, G., Wang, Y., Duan, J., Xiang, S. y Pan, C.  
*Efficient Image Dehazing with Boundary Constraint and Contextual Regularization.*  
IEEE International Conference On Computer Vision, 2013.  
<https://doi.org/10.1109/iccv.2013.82>
- [12] Ren, Wenqi, Siboluo, Hua Zhang, Jinshan Pan, Xiaochun Cao and Ming-Hsuan Yang. Single Image Dehazing via Multi-scale Convolutional Neural Networks. ECCV (2016).

- [13] Preiss, J.; Fernandes, F.; Urban, P.  
*Color-Image Quality Assessment: From Prediction to Optimization*.  
IEEE Trans. Image Process. 2014, 23, 1366–1378.  
<https://doi.org/10.1109/TIP.2014.2302684>
- [14] Khoury, J.  
*Model and Quality Assessment of Single Image Dehazing*.  
Ph.D. Thesis, Université de Bourgogne, Franche-Comté, France, 2016.  
<https://hal.archives-ouvertes.fr/tel-01731624>
- [15] Sheikh, H.R.; Bovik, A.C.  
*Image information and visual quality*.  
IEEE Trans. Image Process. 2006, 15, 430–444.  
<https://doi.org/10.1109/TIP.2005.859378>
- [16] Mittal, A., A. K. Moorthy, and A. C. Bovik.  
*No-Reference Image Quality Assessment in the Spatial Domain*. IEEE Transactions On Image Processing, vol. 21, no. 12, december 2012.  
<https://doi.org/10.1109/TIP.2012.2214050>
- [17] Mittal, A., R. Soundararajan, and A. C. Bovik.  
*Making a Completely Blind Image Quality Analyzer*.  
IEEE Signal Processing Letters. Vol. 22, Number 3, March 2013, pp. 209–212.
- [18] N. Venkatanath, D. Praneeth, Bh. M. Chandrasekhar, S. S. Channappayya, and S. S. Medasani.  
*Blind Image Quality Evaluation Using Perception Based Features*.  
In Proceedings of the 21st National Conference on Communications (NCC). Piscataway, NJ: IEEE, 2015.
- [19] Wang, Z.; Bovik, A.C.; Sheikh, H.R.; Simoncelli, E.P.  
Image quality assessment: From error visibility to structural similarity.  
IEEE Trans. Image Process. 2004, 13, 600–612.  
<https://doi.org/10.1109/TIP.2003.819861>
- [20] Wang, Z.; Bovik, A.C.; Lu, L.  
*Why is image quality assessment so difficult?*  
In Proceedings of the 2002 IEEE International Conference on Acoustics, Speech, and Signal Processing, Orlando, FL, USA, 13–17 May 2002; Volume 4, pp. 3313–3316.  
<https://doi.org/10.1109/ICASSP.2002.5745362>
- [21] Lissner, I.; Preiss, J.; Urban, P.; Lichtenauer, M.S.; Zolliker, P.  
*Image-difference prediction: From grayscale to color*.  
IEEE Trans. Image Process. 2012, 22, 435–446.  
<https://doi.org/10.1109/TIP.2012.2216279>
- [22] el Khoury, J.; le Moan, S.; Thomas, J.-B.; Mansouri, A.  
*Color and sharpness assessment of single image dehazing*.

- Multimed. Tools Appl. 2018, 77, 15409–15430.  
<https://doi.org/10.1007/s11042-017-5122-y>
- [23] *Solver based optimization in matlab cheat sheet.*  
<https://gmoein.github.io/files/solver-based-optimization-in-matlab-cheat-sheet.pdf>
- [24] Agnarsson, J.; Sunde, M; Ermilova I.  
Parallel Optimization in Matlab.  
Project in Computational Science: Report, January 2013  
[https://www.it.uu.se/edu/course/homepage/projektTDB/ht12/project09/Report\\_09.pdf](https://www.it.uu.se/edu/course/homepage/projektTDB/ht12/project09/Report_09.pdf)
- [25] MATLAB (2022).  
*Comparison of Six Solvers,*  
<https://mathworks.com/help/gads/example-comparing-several-solvers.html>. Accedido el 1 julio de 2022.
- [26] Surjanovic, S.; Bingham, D.  
*Virtual Library of Simulation Experiments: Test Functions and Datasets.*  
<https://www.sfu.ca/~ssurjano/calibrat.html>
- [27] Wang, Y., and C. A. Shoemaker. *A General Stochastic Algorithm Framework for Minimizing Expensive Black Box Objective Functions Based on Surrogate Models and Sensitivity Analysis.*  
arXiv:1410.6271v1 (2014).  
<https://arxiv.org/pdf/1410.6271>
- [28] MATLAB (2022).  
<https://mathworks.com/help/gads/surrogate-optimization-algorithm.html>  
Accedido el 1 julio de 2022.
- [29] Powell, M. J. D.  
*The Theory of Radial Basis Function Approximation in 1990.*  
In Light, W. A. (editor), *Advances in Numerical Analysis, Volume 2: Wavelets, Subdivision Algorithms, and Radial Basis Functions.* Clarendon Press, 1992, pp. 105–210.
- [30] Gutmann, H.-M.  
*A radial basis function method for global optimization.*  
*Journal of Global Optimization* 19, Issue 3, 2001, pp. 201–227.  
<https://doi.org/10.1023/A:1011255519438>
- [31] Regis, R. G., and C. A. Shoemaker.  
*A Stochastic Radial Basis Function Method for the Global Optimization of Expensive Functions.*  
*INFORMS J. Computing* 19, 2007, pp. 497–509.
- [32] MATLAB (2022) *Can You Certify That a Solution Is Global?* <https://mathworks.com/help/gads/can-you-certify-a-solution-is-global.html>. Accedido el 1 julio de 2022.

- [33] J.H. Holland.  
*Adaptation in Natural and Artificial systems*. University of Michigan Press, Ann Arbor, 1975.
- [34] K.A. De-Jong,  
*An Analysis of the Behavior of a Class of Genetic Adaptive Systems*.  
Ph.D. Thesis, University of Michigan, 1975.
- [35] D.E. Goldberg.  
*Genetic Algorithms in Search, Optimization and Machine Learning*.  
Addison-Wesley, New York, USA, 1989.
- [36] MATLAB (2022).  
*How the Genetic Algorithm Works*.  
<https://www.mathworks.com/help/gads/how-the-genetic-algorithm-works.html>.  
Accedido el 1 julio de 2022.
- [37] Deep, Kusum, Krishna Pratap Singh, M.L. Kansal, and C. Mohan.  
*A real coded genetic algorithm for solving integer and mixed integer optimization problems*.  
*Applied Mathematics and Computation*, 212(2), pp. 505–518, 2009.  
<https://doi.org/10.1016/j.amc.2009.02.044>
- [38] Deb, Kalyanmoy.  
*An efficient constraint handling method for genetic algorithms*.  
*Computer Methods in Applied Mechanics and Engineering*, 186(2–4), pp. 311–338,  
2000.  
[https://doi.org/10.1016/S0045-7825\(99\)00389-8](https://doi.org/10.1016/S0045-7825(99)00389-8)
- [39] Helmuth Horvath.  
*On the applicability of the koschmieder visibility formula*.  
*Atmospheric Environment* (1967), Volume 5, Issue 3, 1971, Pages 177-184.  
[https://doi.org/10.1016/0004-6981\(71\)90081-3](https://doi.org/10.1016/0004-6981(71)90081-3).



UNIVERSIDAD  
DE GRANADA



Facultad de Ciencias  
Sección de Físicas

## Propuesta de Trabajo Fin de Grado en Física

**Tutor/a:** Javier Hernández Andrés

**Departamento y Área de** Óptica

**Conocimiento:**

**Correo electrónico:** javierha@ugr.es

**Cotutor/a:** Eva M. Valero Benito

**Departamento y Área de** Óptica

**Conocimiento:**

**Correo electrónico:** valerob@ugr.es

**Título del Trabajo:** Selección de bandas óptimas en visible e infrarrojo para la recuperación de imágenes hiperespectrales deterioradas por niebla o neblina simulada.

**Tipología del Trabajo:**

(Segun punto 3 de las Directrices del TFG aprobadas por Comisión Docente el 10/12/14)

(Marcar con X)

1. Revisión bibliográfica		4. Elaboración de nuevas prácticas de laboratorio	
2. Estudio de casos teórico-prácticos		5. Elaboración de un proyecto	
3. Trabajos experimentales	x	6. Trabajo relacionado con prácticas externas	

**Breve descripción del trabajo:**

A pesar de los avances en la industria de la aviación, la mala visibilidad sigue siendo un problema importante para los pilotos, especialmente durante el acercamiento y aterrizaje. Recientemente se han publicado nuevas normas para el aterrizaje con sistema de mejora de la visión en vuelo (EFVS). Las técnicas para eliminar esta degradación, llamadas dehazing (o defogging), son cruciales en EFVS y otras aplicaciones como el transporte marítimo, la vigilancia, los sistemas de asistencia al conductor, la teledetección. En estudios recientes elaborados por nuestro laboratorio, hemos comparado diferentes algoritmos de dehazing para imágenes hiperespectrales en dos rangos espectrales diferentes: visible e infrarrojo. Hemos realizado un estudio sobre selección de bandas óptimas para los algoritmos de dehazing dentro del visible, utilizando una base de datos disponible con fuertes limitaciones en cuanto a la calidad de imagen y proponiendo una métrica combinada para la evaluación de la calidad de las imágenes recuperadas. También hemos capturado una serie de escenas panorámicas con sistemas de captura hiperespectrales en el rango visible e infrarrojo.

El trabajo se plantea como una extensión lógica de los estudios realizados, utilizando las escenas capturadas para simular diferentes niveles de niebla, y varios algoritmos de dehazing y métricas específicas de evaluación para realizar una selección de bandas óptimas a la vez en los rangos visible e infrarrojo. Se evaluarán los resultados utilizando una métrica combinada, y se comparará la calidad de la imagen recuperada con la obtenida para la imagen con neblina simulada dentro del rango infrarrojo, sin aplicar ningún algoritmo de mejora.

**Objetivos planteados:**

1. Selección de escenas en ambos rangos (visible e infrarrojo). Si se estima necesario, captura de nuevas escenas
2. Simulación de niebla (ya implementada) de diferentes niveles y de tipo no homogéneo

Campus Fuentenueva  
Avda. Fuentenueva s/n  
18071 Granada  
Tfno. +34-958242902  
fisicas@ugr.es

**Comisión Docente de Físicas**  
Facultad de Ciencias



3. Utilización de diferentes algoritmos de dehazing sobre las imágenes con niebla simulada, seleccionando conjuntos de cuatro bandas en diferentes rangos, imponiendo restricciones razonables para evitar obtener un número excesivamente elevado de posibles combinaciones de bandas.
4. Uso de un algoritmo de optimización con la métrica de calidad combinada, para obtener la mejor combinación de bandas para cada algoritmo.
5. Evaluación y discusión de los resultados obtenidos.

#### **Metodología:**

Como se ha indicado, ya se dispone de los datos de imágenes hiperespectrales en diferentes rangos. Si se considera necesario, se podría realizar una captura de la misma escena o conjunto reducido de escenas en ambos rangos, con las cámaras hiperespectrales Pika L y Pika NIR de Resonon, disponibles en el laboratorio del Color Imaging Lab. Una vez seleccionados los datos de imagen, se procederá a la simulación de niebla con dos niveles (leve y fuerte). Los algoritmos de simulación dependen del rango de distancias estimado en las escenas, y ya están implementados. Se seleccionan dos algoritmos representativos de la estrategia de diseño basada en modelos físicos (Berman y DCP). Se seleccionan también dos algoritmos basados en la estrategia de procesamiento de imagen independiente de los modelos físicos (CLAHE y AMEF). Se estudiará también la posibilidad de combinar algoritmos para obtener un mejor resultado final. Se procederá a restringir el conjunto de bandas espectrales de los cuatro canales de la imagen reducida, imponiendo restricciones basadas en la diferencia en la información presente en las diferentes bandas y también en la separación espectral y posición de las mismas en los dos rangos. Se generarán las imágenes de cuatro canales y se aplicarán versiones adaptadas de los algoritmos para generar la imagen recuperada, dentro de una optimización basada en métodos que no sean brute-force, para encontrar el conjunto de bandas óptimo para cada algoritmo y nivel de niebla. Para esta optimización, se utilizará la métrica combinada ya desarrollada en estudios previos. Finalmente, se discutirán los resultados obtenidos, y en especial se analizará la hipótesis de si utilizar una banda simple o una combinación de bandas en el rango infrarrojo sin aplicar algoritmos de dehazing puede alcanzar resultados de calidad comparables a aplicar algoritmos de dehazing a las bandas seleccionadas.

#### **Bibliografía:**

E. J. McCartney, "Optics of the atmosphere: Scattering by molecules and particles," New York (1976).

Sensors | Free Full-Text | Single Image Dehazing Algorithm Analysis with Hyperspectral Images in the Visible Range," <https://www.mdpi.com/1424-8220/20/22/6690>

W. Wang and X. Yuan, "Recent Advances in Image Dehazing," <http://html.rhhz.net/iee-jas/html/2017-3-410.htm>

J. A. Stark, "Adaptive image contrast enhancement using generalizations of histogram equalization," IEEE Transactions on Image Processing 9(5), 889–896 (2000).

D. Berman, T. Treibitz, and S. Avidan, "Non-Local Image Dehazing," in (2016), pp. 1674–1682.

G. Meng, Y. Wang, J. Duan, S. Xiang, and C. Pan, "Efficient Image Dehazing with Boundary Constraint and Contextual Regularization," in (2013), pp. 617–624.

A. Galdran, "Image dehazing by artificial multiple-exposure image fusion," Signal Processing 149, 135–147 (2018)



UNIVERSIDAD  
DE GRANADA



Facultad de Ciencias  
Sección de Físicas

***A rellenar sólo en el caso que el alumno sea quien realice la propuesta de TFG***

Alumno/a                      Eloy Prieto Panadero  
propuesto/a:

Granada, 21 de Mayo de 2021

Sello del Departamento

*Campus Fuentenueva  
Ava. Fuentenueva s/n  
18071 Granada  
Tfno. +34-958242902  
fisicas@ngr.es*

**Comisión Docente de Físicas**  
Facultad de Ciencias