

Universidad Autónoma de Querétaro
Facultad de Informática
Doctorado en Ciencias de la Computación.

UN ALGORITMO PARA CORREGIR EL PROBLEMA DEL HAZING EN
PROCESAMIENTO DE IMÁGENES.

Tesis

Que como parte de los requisitos para obtener el Grado de
Doctor en Ciencias de la Computación

Presenta

M. I. E. Sebastián Salazar Colores

Dirigido por

Dr. Juan Manuel Ramos Arreguín

Dr. Eduardo Cabal Yépez

Dr. Juan Manuel Ramos Arreguín
Presidente

Dr. Eduardo Cabal Yépez
Secretario

Dr. Manuel Toledano Ayala
Vocal

Dr. Marco Antonio Aceves Fernández
Suplente

Dr. Jesús Carlos Pedraza Ortega
Suplente

Centro Universitario, Querétaro, Qro.
Agosto, 2019
México

La presente obra está bajo la licencia:
<https://creativecommons.org/licenses/by-nc-nd/4.0/deed.es>



CC BY-NC-ND 4.0 DEED

Atribución-NoComercial-SinDerivadas 4.0 Internacional

Usted es libre de:

Compartir — copiar y redistribuir el material en cualquier medio o formato

La licenciante no puede revocar estas libertades en tanto usted siga los términos de la licencia

Bajo los siguientes términos:



Atribución — Usted debe dar [crédito de manera adecuada](#), brindar un enlace a la licencia, e [indicar si se han realizado cambios](#). Puede hacerlo en cualquier forma razonable, pero no de forma tal que sugiera que usted o su uso tienen el apoyo de la licenciante.



NoComercial — Usted no puede hacer uso del material con [propósitos comerciales](#).



SinDerivadas — Si [remezcla, transforma o crea a partir](#) del material, no podrá distribuir el material modificado.

No hay restricciones adicionales — No puede aplicar términos legales ni [medidas tecnológicas](#) que restrinjan legalmente a otras a hacer cualquier uso permitido por la licencia.

Avisos:

No tiene que cumplir con la licencia para elementos del material en el dominio público o cuando su uso esté permitido por una [excepción o limitación](#) aplicable.

No se dan garantías. La licencia podría no darle todos los permisos que necesita para el uso que tenga previsto. Por ejemplo, otros derechos como [publicidad, privacidad, o derechos morales](#) pueden limitar la forma en que utilice el material.

Agradecimientos

Esta tesis no hubiera sido posible sin la colaboración de muchas personas que me han brindado su ayuda, conocimientos y atención. Quiero agradecerles a todos ellos todo lo que hicieron por mí, para que este trabajo saliera de la mejor manera posible.

Todo mi agradecimiento:


A mis Asesor de Tesis el Doctor Juan Manuel Ramos Arreguin por sus consejos, tiempo y paciencia invertidos en esta tesis.

A mi Coasesor de Tesis el Doctor Eduardo Cabal Yopez por su apoyo al realizar esta tesis.

A todos los profesores que ahora hacen de mí una mejor persona, a mis compañeros y amigos que dieron un toque muy especial a esta travesía... no los voy a olvidar.

Agradecimientos Institucionales

- A la Facultad de Informática de la Universidad Autónoma de Querétaro.




- Al Consejo Nacional de Ciencia y Tecnología (CONACYT), por su apoyo económico mediante la beca 477758/285651, otorgada en el posgrado, durante el periodo de 2015-2019 y por la asignación de la beca Mixta para Estancia Académica en el Extranjero periodo Marzo-Octubre 2018.



- Esta Tesis fue parcialmente financiada a través del proyecto 292399 “Generación de estrategias científico-tecnológicas con un enfoque multidisciplinario e interinstitucional para afrontar la amenaza que representan los complejos ambrosiales en

los sectores agrícola y forestal de México” del Fondo Institucional de Fomento Regional para el Desarrollo Científico, Tecnológico y de Innovación (FORDECyT) del Consejo Nacional de Ciencia y Tecnología (CONACyT).



INTELIGENCIA ARTIFICIAL

Consortio de Centros Públicos Conacyt

- Agradezco el apoyo otorgado mediante el proyecto FORDECYT 296737 "CONSORCIO EN INTELIGENCIA ARTIFICIAL" para el desarrollo de la presente tesis.

Dedicatoria

Esta tesis está dedicada en primer lugar con todo mi cariño y mi amor para las personas que hicieron todo en la vida para que yo pudiera lograr mis sueños, mis padres Juan y Yolanda, por motivarme y estar siempre cuidando de mí, a ustedes por siempre mi corazón y mi agradecimiento.

A mi hermana Raquel y mi cuñado Rafael por el apoyo que me brindan, sé que cuento con ellos siempre.

También a mi sobrino y ahijado Diego Benjamín y a Angelito.

A mis abuelos Ángela, Tereso, Silviano y Onésima, que aunque los últimos tres ya no están presentes, siempre me motivaron para realizarla.

Prólogo

*Al final, no os preguntarán qué habéis sabido,
sino qué habéis hecho. - Jean de Gerson*

*Pedid, y se os dará; buscad, y hallaréis; llamad, y se os abrirá.
Porque todo el que pide, recibe; y el que busca, halla; y al que llama, se le abrirá. - Mateo*

*No puedes conectar los puntos viendo hacia adelante, únicamente puedes conectarlos viendo
hacia atrás. Así que tienes que confiar que de alguna manera se conectarán en un futuro.
Debes confiar en algo, tu instinto, destino, vida, karma, lo que sea. - Steve Jobs*

El mejoramiento de imágenes es un área de investigación muy activa, ya que la calidad de la imagen tiene una influencia directa en los sistemas de visión por computadora. En general, las imágenes exteriores son susceptibles a diferentes condiciones atmosféricas, especialmente la neblina, la niebla y el smog (conocidos genéricamente en la literatura como *hazing*). Los principales efectos causados por estas condiciones atmosféricas son imágenes de bajo contraste, colores distorsionados y visibilidad reducida.

Los sistemas de visión artificial utilizan imágenes como entradas, lo que tiene como consecuencia que sus resultados son influidos de manera directa por la calidad de las mismas. Por tanto la restauración de este tipo de imágenes, de manera precisa y eficiente tiene una amplia posibilidad de aplicación en sistemas de visión artificial, tales como: monitoreo de tráfico, sistemas de vigilancia, navegación autónoma, etc.

Teniendo como motivación lo anteriormente expuesto, en este trabajo se plantean dos métodos basados en dos enfoques para restaurar imágenes con *haze*. El primero de ellos se basa en inteligencia artificial (Perceptrón multicapa), y el segundo está basado en un enfoque estadístico multidireccional donde es propuesta una modificación del canal oscuro, el cual es ampliamente utilizado en la literatura para abordar el problema del *haze* [1]. Los métodos fueron evaluados cuantitativamente mediante las métricas PSNR y el índice SSIM sobre una muestra de imágenes distintas, las cuales son representativas de distintos escenarios. Estas imágenes fueron tomadas de los repositorios descritos en [2], [3] y [4], además se realizan comparaciones cuantitativas con métodos

recientes de *dehazing* y finalmente se muestra un análisis de los resultados.

Los métodos propuestos consiguen obtener buenos resultados en el cálculo del mapa de profundidad (transmisión); realizando el proceso más eficientemente que las alternativas existentes, haciendo viable la utilización de los métodos en sistemas de tiempo real.

La organización del documento, se encuentra dividida en cinco capítulos:

- En el capítulo titulado Introducción, se da una descripción del problema, los objetivos específicos los cuales ayudarán a alcanzar el objetivo general, también se muestra un panorama histórico y actual de las investigaciones orientadas al *dehazing*, así como los objetivos y alcances de la investigación.
- En el capítulo nombrado Fundamento teórico se presentan brevemente los términos y conceptos utilizados en la investigación, la visión artificial, las imágenes, el procesamiento de las imágenes, operaciones morfológicas, el modelo de dispersión atmosférica, el concepto del principio del canal oscuro y la métrica PSNR y el índice SSIM.
- En el tercer capítulo titulado Metodología se expone una descripción del proceso llevado a cabo en la investigación. La cual a grandes rasgos, se divide en dos partes, una donde se propone y desarrolla un método basado en estadística, morfología matemática y filtros de procesamiento de imágenes, y otra donde se utiliza una red neuronal para resolver el problema de hazing.
- En el capítulo cuatro, se muestran los resultados de la evaluación y la comparación de los métodos propuestos con métodos del estado del arte.
- En el capítulo cinco se dan a conocer las conclusiones obtenidas después de haber conseguido tanto los objetivos específicos como el general de la tesis.
- En el capítulo seis, basado en los resultados obtenidos se describen posibles líneas de investigación y trabajo futuro a realizar.

Índice general

Agradecimientos	1
Agradecimientos Institucionales	3
Dedicatoria	5
Prólogo	7
Índice de figuras	13
Índice de tablas	17
Resumen	19
Abstract	21
1. Introducción	1
1.1. Objetivos	2
1.1.1. Objetivo general	2
1.1.2. Objetivos específicos	2
1.2. Antecedentes	3
1.2.1. Análisis de distintos enfoques de algoritmos de dehazing que utilizan una sola imagen como entrada	6
1.2.2. El principio del canal oscuro (dark channel prior)	7
1.2.3. Medición del desempeño de algoritmos de dehazing	11
1.2.4. Análisis del costo computacional de los métodos más relevantes	13
1.2.5. Implementaciones de métodos de dehazing en la literatura	17
1.2.6. Aplicaciones de los métodos de dehazing en la literatura	19
2. Fundamento teórico	23
2.1. La visión artificial	23
2.2. Las imágenes	24
2.3. Procesamiento de imágenes	27
2.4. La atmósfera	28
2.4.1. Dispersión atmosférica	29

2.4.2. Teoría del alcance de la visión de campo horizontal (Theorie der horizontalen Sichtweite)	30
2.5. Modelo de dispersión atmosférica	31
2.6. El principio del canal oscuro	32
2.7. Operaciones morfológicas	36
2.7.1. Erosión en escalas de grises	36
2.7.2. Dilatación en escalas de grises	37
2.8. El perceptrón multicapa	37
2.9. Evaluación del dehazing	38
2.10. MSE y PSNR	38
2.11. Índice SSIM	39
3. Metodología	41
3.1. Método basado en el DCP e Inteligencia Artificial (Perceptrón multicapa)	42
3.1.1. Planteamiento general del algoritmo propuesto	42
3.1.2. Imágenes utilizadas	43
3.1.3. Desarrollo del algoritmo propuesto	43
3.1.4. Generación de datos <i>ground-truth</i> (datos referencia)	45
3.1.5. El proceso de entrenamiento	45
3.1.6. Aplicación del MLP	47
3.1.7. Ajuste de parámetros	49
3.1.8. Algoritmos utilizados durante experimentación	51
3.2. Método basado en el DCP, Morfología matemática y estadística	51
3.2.1. Planteamiento general del algoritmo propuesto	51
3.2.2. Imágenes utilizadas	52
3.2.3. Desarrollo del algoritmo propuesto	54
3.2.4. Algoritmos utilizados durante experimentación	61
4. Prueba y resultados	63
4.1. Análisis del método basado en el DCP e Inteligencia Artificial (Perceptrón multicapa)	63
4.1.1. Análisis del rendimiento	63
4.2. Análisis del método basado en el DCP Multidireccional Estadístico	68
4.2.1. Análisis del rendimiento	68
4.2.2. Evaluación del tiempo de procesamiento	70
Conclusiones	73
Trabajos futuros	75
Productos académicos obtenidos	77
.1. Artículos en revistas indizadas en el Journal Citation Report (JCR) de Thompson	77
.2. Artículos publicados en revistas arbitradas del CONACYT	82

.3.	Capítulos de libro publicados	84
.4.	Actas de conferencias	87
	Referencias bibliográficas	89

Índice de figuras

1.1. Diagrama con los distintos enfoques de algoritmos utilizados para el <i>dehazing</i> [Creación Propia].	3
2.1. Sistema de visión artificial.	24
2.2. Imagen digital	25
2.3. El modelo <i>RGB</i> [Modificado de [5]].	26
2.4. Tipos de operaciones en el procesamiento de imágenes [Modificado de [5]].	27
2.5. El modelo de dispersión atmosférica [Creación propia].	32
2.6. Resultado del cálculo del canal oscuro en una imagen sin <i>hazing</i>	33
2.7. Imágenes resultado de la aplicación del <i>dark channel prior</i> [Imagen propia].	35
3.1. Diagrama donde se observa la función que el método debe aprender [Creación propia].	42
3.2. Diagrama de flujo del método propuesto [Creación propia].	44
3.3. Proceso de entrenamiento para el MLP basado en mapas de transmisión [Creación propia].	46
3.4. Proceso para estimar el mapa de transmisión utilizando el MLP [Creación propia].	47
3.5. Ejemplos del procesamiento realizado por el método propuesto: (a) imágenes de entrada $I(x, y)$, (b) transmisión inicial $t_{min}(x, y)$, (c) transmisión final $t'(x, y)$, (d) imágenes recuperadas $J(x, y)$ [Creación propia].	48
3.6. Relación entre la arquitectura MLP y el rendimiento utilizando el conjunto de imágenes de formación [Creación propia].	49
3.7. Relación entre las ventanas δ utilizadas en la aplicación de la MLP en la imagen, (a) índice SSIM, (b) procesamiento de tiempo [Creación propia].	50
3.8. Transmisiones y resultados generados usando diferentes ventanas deslizantes de δ : (a) $\delta = 1$, (b) $\delta = 2$, (c) $\delta = 4$, (d) $\delta = 8$, (e) $\delta = 12$, (f) $\delta = 16$ [Creación propia].	50
3.9. Ejemplo de una imagen con neblina, el DCP original y artefactos generados en $J(x, y)$. (a) Imagen de entrada $I(x, y)$, (b) canal oscuro usando $\Omega = (15, 15)$, (c) estimación de $J(x, y)$ desde el canal oscuro (b), (d) mapa del canal oscuro usando $\Omega = (35, 35)$, (e) estimación de $J(x, y)$ desde el canal oscuro (d) [Creación propia].	52
3.10. Imágenes del mundo real utilizadas [Creación propia].	53

3.11. Imágenes sintéticas utilizadas. (a) Imágenes <i>ground-truth</i> (de referencia), (b) Imágenes con neblina [Creación propia].	53
3.12. Diagrama de las formas de las ventanas (líneas), donde n es el número de líneas orientadas, k es la longitud de la línea y α es el ángulo entre líneas, que comienza en el eje horizontal de la ubicación del píxel central (x, y) [Creación propia].	54
3.13. Ejemplo de mapas multidireccionales de canal oscuro de la imagen mos- trada en la Figura 4.2 con cuatro orientaciones. (a) $I_{(35,0^\circ)}^{dark}(x, y)$, (b) $I_{(35,45^\circ)}^{dark}(x, y)$, (c) $I_{(35,90^\circ)}^{dark}(x, y)$, (d) $I_{(35,135^\circ)}^{dark}(x, y)$ [Creación propia]. . . .	55
3.14. Ejemplo de los mapas multidireccionales de canal gris con 4 orientaciones: tenga en cuenta que los contornos son más nítidos que en la figura ante- rior. (a) $I_{(35,0^\circ)}^{grey}(x, y)$, (b) $I_{(35,45^\circ)}^{grey}(x, y)$, (c) $I_{(35,90^\circ)}^{grey}(x, y)$, (d) $I_{(35,135^\circ)}^{grey}(x, y)$ [Creación propia].	56
3.15. Ejemplo de concatenación de canales grises $M(x, y)_n$ (izquierda), y ejem- plo de cálculo del mapa de desviación estándar $M_\sigma(x, y)$ (derecha) usando la imagen mostrada en la Figura 4.2 (a) [Creación propia].	57
3.16. Mapa de desviación estándar $M_\sigma(x, y)$ calculado a partir de la Figura 4.2 (a), (b) Mapa de desviación estándar $M_\sigma(x, y)$ mezclado con la imagen original [Creación propia].	57
3.17. Mapas de canal oscuro <i>ground-truth</i> y tres mapas de canal oscuro cal- culados a partir de la Figura 4.2, cada uno con zoom en dos regiones: no homogénea (abajo a la izquierda) y homogénea (abajo a la derecha), (a) Mapa de canal oscuro <i>ground-truth</i> , (b) $M_{\max}(x, y)$ tienen un mejor rendimiento en las regiones no homogéneas, (c) $\bar{M}(x, y)$ logra un mejor rendimiento en áreas homogéneas, (d) M_{dc} , combinación de ambos mé- todos utilizando la Ecuación (3.11), la cual reduce los artefactos en las regiones homogéneas, y el contorno está bien definido [Creación propia].	58
3.18. Ejemplo del mejoramiento de M_{dc} . (a) Imagen de entrada donde $\max(M_{dc}) >$ $0,7$, (b) M_{dc} original, (c) Imagen restaurada usando (b), (d) M_{dc} mejo- rado, (e) Imagen restaurada usando (d), (f) Imagen de entrada donde $\max(M_{dc}) < 0,7$, (g) M_{dc} original, (h) Imagen restaurada usando (b), (i) M_{dc} mejorado, (j) Imagen restaurada usando (i) [Creación propia]. . . .	59
3.19. Diagrama de flujo del método propuesto SMLDC [Creación propia]. . .	60
4.1. Comparación de los resultados obtenidos en imágenes naturales de exte- riores utilizando los diez métodos comparados: (a) imágenes de entrada, (b) Tarel et al. [6], (c) He et al. [7], (d) Pang et al. [8], (e) Gibson et al. [9], (f) Zhu et al. [10], (g) Berman et al. [11], (h) Ren et al. [12], (i) Cai et al. [13], (j) Li et al. [14], (k) Método propuesto [Creación propia].	65

4.2.	Comparación de los resultados obtenidos de las imágenes sintéticas por los diez métodos: (a) imágenes originales, (b) imágenes con neblina simulada, (c) Tarel et al. [6], (d) He et al. [7], (e) Pang et al. [8], (f) Gibson et al. [9], (g) Zhu et al. [10], (h) Berman et al. [11], (i) Ren et al. [12], (j) Cai et al. [13], (k) Li et al. [14], (l) Método propuesto [Creación propia].	66
4.3.	Análisis del rendimiento en términos de procesamiento de tiempo computacional [Creación propia].	67
4.4.	Cálculo de los parámetros óptimos ($k = 8$, $n = 37$) para una longitud de línea diferente k y número de líneas n .(a) Índice SSIM para diferentes k y n . (b)Tiempo de procesamiento para diferentes configuraciones de k y n . (c) Elección de los mejores valores del índice SSIM y tiempo de procesamiento [Creación propia].	68
4.5.	Conjunto de diez imágenes del mundo real restauradas con diferentes métodos de dehazing. (a) Conjunto de imágenes exteriores con neblina, (b) restauración usando He et al. [15], (c) restauración usando Berman et al. [11], (d) restauración usando Ren et al. [12], (e) restauración usando Galdran et al. [16], (f) restauración usando el método propuesto [Creación propia].	71
4.6.	Conjunto de imágenes de neblina sintética con diferentes métodos de dehazing. (a) Conjunto de imágenes exteriores con neblina, (b) restauración usando He et al. [15], (c) restauración usando Berman et al. [11], (d) restauración usando Ren et al. [12], (e) restauración usando Galdran et al. [16], (f) restauración usando el método propuesto [Creación propia].	72

Índice de tablas

1.1.	Análisis de diferentes tipos de algoritmos de dehazing.	5
1.2.	Algunos algoritmos basados en el principio del canal oscuro presentes en la literatura.	8
1.2.	(Continuación) Algunos algoritmos basados en el principio del canal oscuro presentes en la literatura.	9
1.2.	(Continuación) Algunos algoritmos basados en el principio del canal oscuro presentes en la literatura.	10
1.2.	(Continuación) Algunos algoritmos basados en el principio del canal oscuro presentes en la literatura.	11
1.3.	Análisis de diferentes métricas utilizadas para medir el desempeño de métodos dehazing.	12
1.3.	Análisis de diferentes métricas utilizadas para medir el desempeño de métodos dehazing (Continuación).	13
1.4.	Comparativa del desempeño de métodos en la literatura.	14
1.4.	(Continuación) Algunos algoritmos basados en el principio del canal oscuro presentes en la literatura.	15
1.4.	(Continuación) Algunos algoritmos basados en el principio del canal oscuro presentes en la literatura.	16
2.1.	Clasificación de las condiciones climáticas en el código de visibilidad internacional [Modificada de [17]].	29
4.1.	Análisis comparativo utilizando la proporción máxima de señal a ruido (PSNR).	64
4.2.	Análisis comparativo utilizando el índice de similitud estructural (SSIM).	64
4.3.	Comparación del índice SSIM con diferentes métodos.	69
4.4.	Comparación de PSNR con diferentes métodos	70
4.5.	Comparación del tiempo medio (en segundos) de diferentes métodos.	70

Resumen

Cuando las imágenes son adquiridas en exteriores están sujetas a malas condiciones clim'lo cual causa una serie de afectaciones tales como disminución de contraste y alteración de colores lo cual reduce la visibilidad, este problema es conocido como hazing. El problema del hazing es un desafío importante para muchas aplicaciones de visión por computadora, por ejemplo en sistemas de vigilancia, vehículos inteligentes, reconocimiento de objetos en exteriores, sistemas de detección remota etc., ya que la degradación consecuencia del hazing influye en la precisión y capacidad del sistema de visión. Es por ello en esta tesis es presentada una investigación orientada a resolver este problema. Se plantean dos estrategias: Una basada en filtros morfológicos y Gaussianos además de un Perceptrón Multicapa. Resultados experimentales muestran la validez de los enfoques propuestos.

Abstract

When images acquired outdoors are subject to bad weather conditions which causes a series of effects such as decreased contrast and altered colors which reduces visibility, this problem is known as hazing. The hazing problem is a major challenge for many computer vision applications, e.g. in surveillance systems, intelligent vehicles, outdoor object recognition, remote sensing systems etc., as the degradation resulting from hazing influences the accuracy and capability of the vision system. That is why in this thesis is presented a research aimed at solving this problem. Two strategies are proposed: One based on morphological filters and Gaussians as well as a Multilayer Perception. Experimental results show the validity of the proposed approaches.

Capítulo 1

Introducción

La visión artificial tiene como meta la construcción de descripciones explícitas y útiles sobre objetos y escenas físicas reales, con el fin de tomar decisiones basándose en las imágenes detectadas [18]; sin embargo, la mayoría de sistemas de visión artificial asumen que el observador está inmerso en un medio totalmente transparente, lo cuál en exteriores generalmente no ocurre ya que los sensores que capturan las imágenes tienen que lidiar con un amplia gama de condiciones atmosféricas como la neblina, la niebla, el smog, la lluvia, la brisa y la nieve (estas condiciones generan el fenómeno físico conocido como hazing).

Los sistemas de visión artificial utilizan imágenes como entradas, lo que tiene como consecuencia que sus resultados son influidos de manera directa por la calidad de las mismas. La mayoría de aplicaciones de visión artificial como vigilancia y navegación autónoma requieren de una detección robusta de las características de una imagen, pero las malas condiciones atmosféricas oscurecen las escenas, reducen la visibilidad, y alteran o degradan el contraste y colores, es entonces cuando surge la necesidad de incluir en el sistema de visión mecanismos que contrarresten estos efectos. Por tanto la restauración de este tipo de imágenes, de manera precisa y eficiente tiene una amplia posibilidad de aplicación en sistemas de visión artificial. En los algoritmos actuales se ha detectado la necesidad de mejorar su tiempo de cómputo, calidad de restauración y robustez ante distintos tipos de imágenes.

El problema del hazing es un desafío importante para muchas aplicaciones de visión por computadora, por ejemplo en sistemas de vigilancia, vehículos inteligentes, reconocimiento de objetos en exteriores, sistemas de detección remota etc., ya que la degradación consecuencia del hazing influye en la precisión y capacidad del sistema de visión. La motivaciones de este trabajo surgen entonces dada la importancia abordar el problema antes expuesto y el hecho de que no existe a la fecha un método capaz de resolver este problema en todos los entornos eficientemente [3, 19, 20]. Más precisamente, Salazar-Colores [21] muestra algunas áreas de oportunidad en los algoritmos de dehazing que pueden ser mejoradas, las cuales son:

1. Mejorar su velocidad de ejecución para tener la capacidad de procesar video en tiempo real.
2. Mejorar el mapa de transmisión generado por el algoritmo, es decir conseguir una mejor estimación de información de profundidad de cada pixel.
3. Aumentar la robustez del algoritmo, es decir que su desempeño (exactitud) se más estable con diferentes entradas.
4. Mejorar el cálculo de la luz atmosférica.
5. Utilización de métricas tanto referenciadas como no referenciadas que den una idea más certera del desempeño de los algoritmos en distintas situaciones.
6. Se requiere realizar un comparación más formal con el estado del arte, esto es con un mayor número de imágenes. La utilización del principio del canal oscuro como base del algoritmo es debido a los buenos resultados que ha mostrado este principio en investigaciones recientes [15, 21–24].

La decisión de experimentar con herramientas de morfología matemática, segmentación de imágenes, y técnicas de inteligencia artificial está basada en las observaciones mostradas en [21].

1.1. Objetivos

1.1.1. Objetivo general

Desarrollar e implementar un algoritmo de procesamiento de imágenes para resolver el problema de hazing en imágenes de exteriores, utilizando una combinación de técnicas de procesamiento que dé como resultado un nuevo algoritmo para resolver el problema, requiriendo de un menor tiempo de procesamiento en comparación de métodos actuales, comparando el algoritmo mediante métricas referenciadas y no referenciadas, contra algoritmos del estado del arte.

1.1.2. Objetivos específicos

- Obtener un algoritmo de dehazing que requiera un menor tiempo de cómputo, para su implementación en tiempo real.
- Experimentar con morfología matemática, segmentación de imágenes e inteligencia artificial para el dehazing.
- Evaluar el algoritmo mediante métricas referenciadas y no referenciadas en un número de imágenes que den una idea más certera de su desempeño en distintas situaciones.

- Comparar el desempeño de la técnica propuesta en relación con métodos recientes en la literatura para solucionar el problema del hazing paralelizar el algoritmo con la finalidad de aplicar el algoritmo a video en tiempo real.
- Aplicar el algoritmo propuesto como parte de un sistema de vigilancia.

1.2. Antecedentes

Dada la complejidad de restaurar el hazing, en la literatura han sido propuestas distintos tipos de estrategias para tratar el problema del *hazing* (Ver Figura 1.1).

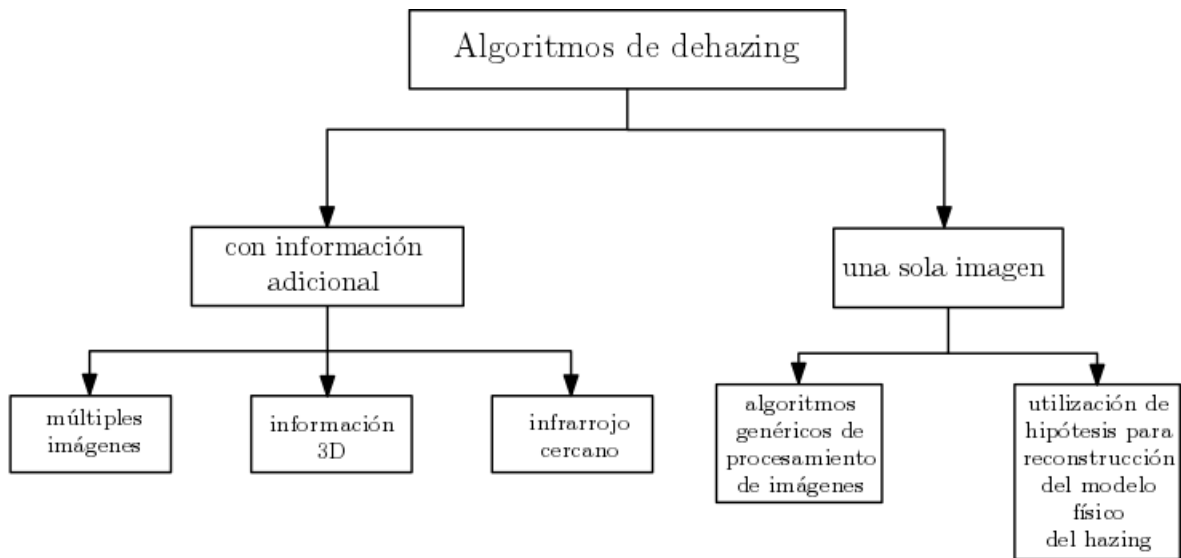


Figura 1.1: Diagrama con los distintos enfoques de algoritmos utilizados para el *dehazing* [Creación Propia].

Los algoritmos de dehazing pueden ser divididos en dos grupos: los que requieren información adicional de la imagen de la escena y los que solo trabajan con una, en seguida se muestra un breve panorama general de investigaciones realizadas en estos dos grupos:

- Utilizando información adicional de la escena en malas condiciones climatológicas:
 - Trabajos como el presentado en [25] donde se utiliza mediante la modificación de cámaras digitales comunes información del infrarrojo cercano para eliminar el *hazing*.
 - Utilizando información de profundidad de los elementos de la escena mediante modelos estructurales 3D de la escena proporcionada por algunas bases

de datos, tales como *Bing Maps* y *Google Earth* [26] propone un sistema para la navegación, mejoramiento, y manipulación de fotografías en exteriores combinando con información terrestre georreferenciada digital y modelos urbanos existentes. Una vez que la fotografía y el modelo han sido registradas; múltiples fuentes de información, tales como profundidad, textura, datos sistema de información geográfica (GIS, por sus siglas en inglés), están disponibles inmediatamente para el sistema.

- Métodos basados en la polarización de la luz, que remueven el *hazing* utilizando dos o más imágenes tomadas con diferentes grados de polarización [27,28], los que calculan la profundidad de la escena utilizando múltiples imágenes de la misma escena que son capturadas en distintas condiciones climatológicas [29, 30].

Aunque estos métodos producen excelentes resultados, son imprácticos, porque sus requerimientos no pueden ser satisfechos siempre por ejemplo en las propuestas de infrarrojo cercano requieren la modificación de dispositivos para poder obtener información del espectro infrarrojo o los algoritmos de polarización se presentan problemas en ambientes con viento, vibración o movimiento que hacen que los filtros de polarización sean muy sensibles a la traslación y lo de múltiples imágenes hacen imposible su implementación en aplicaciones en tiempo real [30].

- Empleando una sola imagen y calculando una aproximación de profundidad de la escena adquirida. Este tipo de condición es la que ha sido más estudiada recientemente, dado que es la situación más recurrente cuando se trata el problema del *hazing* [20, 22, 31–33].

En la Tabla 1.1 se muestra un análisis detallado de los enfoques antes mencionados.

Tabla 1.1: Análisis de diferentes tipos de algoritmos de dehazing.

	Enfoques	Ventajas	Inconvenientes
Información adicional	Múltiples imágenes	Rápido	La limitación común de estos métodos es que las imágenes adicionales no son de fácil acceso. Todos requieren ajustes especiales con una calibración cuidadosa. Esto no es práctico en la mayoría de los casos, como en el caso de las cámaras portátiles y las cámaras de exterior y sistemas de vigilancia. Las limitaciones de estos métodos motivan a los desarrollo de métodos de eliminación de la neblina de una sola imagen.
.....	Información en 3D	Resultados precisos	No es trivial obtener la información de profundidad. El modelo de estructura 3D no está disponible en la mayoría de los casos.
.....	Infrarrojo cercano	Presentar un resultado robusto y rápido.	Necesita un sensor infrarrojo alineado con el sensor de luz visible.
.....	Métodos basados en la polarización	Tiempo de procesamiento instantáneo.	Capturar dos imágenes polarizadas estrictamente alineadas es problemático en la práctica. Otro problema es que la transmisión directa no siempre es completamente impolarizada.
Una sola imagen	Algoritmos generales	Fácil de encontrar implementaciones.	Su rendimiento es inestable.
.....	Utiliza los antecedentes de la recuperación el modelo de dispersión	No se requiere información adicional.	El tiempo que consume es alto. La mayoría de los modelos sólo funcionan con luz diurna y una sola fuente de luz, y son homogéneos.

1.2.1. Análisis de distintos enfoques de algoritmos de dehazing que utilizan una sola imagen como entrada

Investigaciones pioneras:

A finales de la primera década de este siglo, el aumento de la capacidad de procesamiento computacional hizo viable el estudio y desarrollo de métodos para procesar y mejorar imágenes. Es en esta época cuando surgen los primeros métodos para abordar el problema de hazing digitalmente, estas son alguna de las primeras investigaciones realizadas en ese rubro:

- *Tan* en [19] observa que una imagen libre de *hazing* debe tener un contraste más alto comparado con una imagen con *hazing* y remueve el *haze* maximizando el contraste local de la imagen de la imagen restaurada. Los resultados son visualmente agradables pero pueden no ser válidos físicamente y generalmente produce imágenes sobresaturadas y que no parecen naturales.
- *Fattal* [32] utiliza el Análisis de Componentes Independientes (*ICA*, por sus siglas en inglés). *ICA* es un método estadístico que separa dos componentes aditivos de una señal, *Fattal* adapta el *ICA* al problema del *Hazing* estimando el *albedo* de la escena y el medio de transmisión mediante el supuesto que la transmisión y el sombreado de la superficie están correlacionados localmente. Este enfoque está basado en el modelo físico y puede producir buenos resultados, sin embargo en imágenes con una gran cantidad de *hazing* suele fallar pues su hipótesis deja de tener validez.
- *Tarel et al.* [6] se agrega un filtro de mediana para eliminar los halos de la imagen, lo cuál logra parcialmente. *Xie et al.* en [34] propone un algoritmo, que emplea un filtro bilateral rápido para suavizar la estimación del *hazing* en la atmósfera. *Gao* en [35] introduce el concepto de la corrección negativa de revelado fotográfico en el algoritmo de *dehazing*, con el fin de suprimir los halos.
- *K. He* [36] propone el principio del canal oscuro *dark channel prior* para estimar la transmisión y obtiene resultados satisfactorios en el *dehazing*. Pero sus resultados sufren de halos alrededor de bordes. El mismo autor mejoró el algoritmo usando un *soft matting*, sin embargo el proceso es lento y no puede ser usado en sistemas de tiempo real.
- Usando otros enfoques:
 - Existen también enfoques distintos como en [37] donde se introduce una nueva estrategia para restaurar una imagen degradada por el *hazing*. El algoritmo presentado permite la rápida identificación de regiones afectadas por el *hazing*, sin hacer uso de una optimización costosa mediante

procedimientos de refinación. Aplicando una operación a nivel pixel sobre la imagen original, se produce una “semi-inversa” de la imagen. Basado en la diferencia de tono entre la imagen original y la “semi-inversa”, se logra identificar las regiones con Haze sobre una base de pixeles. Esto permite realizar una estimación simple de la constante de la luz atmosférica y el mapa de transmisión. Su enfoque está basado en un estudio extenso sobre un conjunto de imágenes, y basa su validez sobre una métrica que mide el contraste pero también los cambios estructurales.

- En [29] se utiliza el hecho de que las imágenes que contienen neblina son capturadas de cámaras de exteriores. Como el resultado, la geometría de la escena está usualmente dominada por un plano de tierra. Mas importantes aún, los objetos que aparecen hacia la parte posterior de la escena están usualmente más lejos. Se muestra como esta preferencia (implementada como una constante suave) es compatible con la técnica de optimización expansión-alfa e ilustra como puede ser usada para mejorar la robustez de cualquier técnica de *dehazing* utilizando una sola imagen.

1.2.2. El principio del canal oscuro (dark channel prior)

El método propuesto por *K. He* [36] “Single Image Haze Removal using Dark Channel Prior” base del presente trabajo tuvo un gran impacto en la comunidad científica, dada la sencillez del principio del canal oscuro, y prometedora calidad de restauración ¹.

Las investigaciones basadas en el principio del canal oscuro tienen como meta el solventar alguna de las dos principales limitaciones del canal oscuro:

- tiempo de procesamiento,
- calidad de restauración.

En la Tabla 1.2 se muestran algunas de las investigaciones del estado del arte basadas en el principio del canal oscuro.

¹En noviembre de 2018 el número de trabajos que han citado el trabajo de *K. He*: “Single Image Haze Removal using Dark Channel Prior” de acuerdo a la plataforma Google Scholar es de 3028.

Tabla 1.2: Algunos algoritmos basados en el principio del canal oscuro presentes en la literatura.

Año	Nombre publicaciones	Puntos destacados	Tiempo (segundos)
2010	Improved single image dehazing using segmentation [38]	Se basa en una segmentación de la imagen que puede eliminar en gran medida los efectos de halo. Su complejidad es sólo $O(n)$	No reportado
2011	Improved Single Image Dehazing Using Guided Filter [8]	Utiliza el principio del canal oscuro y el filtrado de imágenes guiado.	4 segundos, 1 megapixel
2012	Removal of Haze and Noise from a Single Image [39]	Proponen dos métodos para eliminar tanto la neblina como el ruido de una sola imagen	No reportado
2012	Single Image De-haze Based On a New Dark Channel Estimation Method [31]	Usa el canal oscuro en un área local. Su complejidad es una función lineal del tamaño de la imagen.	No reportado
2013	Single Image Dehazing Combining Physics Model based and Non-physics Model based Methods [20]	Utiliza el algoritmo de retinex basado en dos filtros bilaterales, y un filtro de mediana adaptable.	No reportado
2013	Optimized contrast enhancement for real-time image and video dehazing [40]	Formula una función de coste que se basa en el término de contraste y de pérdida de información. Al minimizar la función de coste, mejora el contraste y conserva la información de forma óptima reduciendo el parpadeo de los artefactos en una secuencia de vídeo desajustada haciendo que la transmisión tenga valores temporalmente coherentes	02.0 segundos, 640 x 356 pixeles
2013	Multiple Scattering Model based Single Image Dehazing [41]	Propone un modelo de degradación de la imagen basado en la dispersión múltiple para la eliminación de la neblina de imagen y mejora el modelo dicromático ampliamente utilizado con la función de dispersión por puntos atmosféricos.	2.56 segundos, 283 mb
2013	Haze effect removal from image via haze density estimation in optical model [42]	Proponen dos nuevas observaciones de la imagen, llamados el principio del canal oscuro basado en píxeles y el principio del canal brillante basado en píxeles.	3.41 segundos, 576 x 768 pixeles

Continua en la siguiente página...

Tabla 1.2: (Continuación) Algunos algoritmos basados en el principio del canal oscuro presentes en la literatura.

Año	Nombre publicaciones	Puntos destacados	Tiempo (segundos)
2014	Single image dehazing based on multiple scattering model [43]	Propone un modelo de degradación de imágenes basado en la dispersión múltiple. Utiliza el concepto de semi-inversa para determinar el área de niebla, y luego estima la luz atmosférica A del área más concentrada.	No reportado
2014	Improved Single image dehazing by fusion [44]	Está basado en una estrategia de fusión que combina dos imágenes derivadas de la imagen original. Estas imágenes derivadas son ponderadas por un mapa de peso específico seguido de representaciones de pirámides laplacianas y gaussianas.	30-32 segundos, 600 x 800 pixels
2014	Single image dehazing in inhomogeneous atmosphere [45]	Considerando la variación de la concentración de aerosoles en la atmósfera no homogénea y la relación entre el coeficiente de atenuación y los aerosoles, se propone un modelo más válido para el coeficiente de atenuación que el existente.	0.4 segundos, 600 x 800 pixeles
2014	Underwater image dehazing using joint trilateral filter	Compensa la discrepancia de atenuación a lo largo del trayecto de propagación y toma el filtro trilateral conjunto para filtrar el mapa de profundidad de transmisión.	5.46 segundos 640 x 480 pixeles
2015	Fast Single Image Dehazing Through Edge-Guided Interpolated Filter [46]	Propone el filtro interpolado guiado (GIF), el filtro interpolado guiado por bordes (EGIF), basados en un submuestreo de la imagen.	0.031 segundos, 600 x 400 pixeles
2015	Single image dehazing with a physical model and dark channel prior [47]	Propone un método para la estimación de las emisiones atmosféricas. Mejora el valor lumínico mediante el concepto de variograma.	No reportado
2015	An improved image dehazing and enhancing method using dark channel prior [48]	El método toma un pequeño parche para resolver el canal oscuro (DC) junto con un filtro guiado (GF)	No reportado

Continúa en la siguiente página...

Tabla 1.2: (Continuación) Algunos algoritmos basados en el principio del canal oscuro presentes en la literatura.

Año	Nombre publicaciones	Puntos destacados	Tiempo (segundos)
2015	An efficient dehazing method for edge enhancement by using entropy-map [49]	Se genera un mapa de entropía a partir del espacio de color YCbCr La imagen de entrada se divide en regiones de textura complejas y otras.	No reportado
2015	Single-Image Dehazing via Optimal Transmission Map Under Scene Priors [50]	Formula el problema como una minimización restringida y lo resuelve mediante programación cuadrática con el sistema global óptimo.	300 segundos, 600 x 400
2015	Adaptive transmission compensation via human visual system for efficient single image dehazing [51]	Propone un único algoritmo de dehazing mediante compensación adaptativa de la transmisión basado en el sistema visual humano (HVS)	No reportado
2015	Single image haze removal via a simplified dark channel [52]	El mapa se refina a través de un filtro de imágenes guiado adaptable al contenido.	0.40 segundos, 600 x 400 pixeles
2015	Single image dehazing using the change of detail prior [53]	Propone un cambio de detalle previo llamado (CoD) previo	No reportado
2015	Multiscale Single Image Dehazing Based on Adaptive Wavelet Fusion [54]	Utiliza un método de fusión de wavelets basado en la similitud local adaptativa	0.63, 600 x 400 pixeles
2015	Improved Single Image and Video Dehazing Using Morphological Operation [55]	Obtiene una luz de dispersión atmosférica inicial utilizando escala de grises y una operación morfológica y refinarla utilizando un filtro guiado.	24.75 segundos, 600 x 400
2015	Image Dehazing with Dark Channel Prior and Novel Estimation Model [56]	Se presenta una formulación novedosa para la estimación de la variable transmisión con la combinación de un albedo constante y un principio del canal oscuro, introduce la metodología de segmentación de watershed en el algoritmo.	10-20 segundos, 600 x 400 pixeles
2015	Fast single-image dehazing using linear transformation [57]	Estima la luz atmosférica usando la relación entre una región de cielo y la región blanca cercana calcula el mapa de transmisión usando una transformación lineal.	0.75, 1 megapixeles

Continúa en la siguiente página...

Tabla 1.2: (Continuación) Algunos algoritmos basados en el principio del canal oscuro presentes en la literatura.

Año	Nombre publicaciones	Puntos destacados	Tiempo (segundos)
2015	Mean Shift-Based Single Image Dehazing with Re-refined Transmission Map [58]	Propone un algoritmo de dehazing de imágenes basado en el desplazamiento medio con mapa de transmisión re-refinada	No reportado
2016	An improved dehazing algorithm of aerial high-definition image [59]	Basado en el modelo de canal oscuro anterior, el nuevo algoritmo extrae en primer lugar los bordes del mapa de transmisión estimado del crudo y expande los bordes extraídos.	1.25 segundos, 425 750 píxeles
2016	Single image dehazing via multi-scale convolutional neural networks [12]	El algoritmo propuesto consiste en una red de escala gruesa que predice un mapa de transmisión holístico basado en la imagen completa, y una red de escala fina que refina los resultados localmente. Para entrenar el sistema multiescala en una red profunda, sintetizamos un conjunto de datos compuesto de imágenes dañadas y mapas de transmisión correspondientes basados en el conjunto de datos de profundidad de la Universidad de Nueva York (NYU).	0.61 segundos, 640 x 480
2017	Single image dehazing using kernel regression model and dark channel prior [60]	Se propone un nuevo método mejorado usando el Modelo de Regresión del Kernel (KRM) sobre datos de vecinos locales.	No reportado
2017	Dehazing via graph cut [61]	Se propone un método que considera simultáneamente el canal oscuro anterior y el supuesto de suavidad por partes. Se logra minimizando una función de energía basada en todas las suposiciones empleadas.	No reportado

1.2.3. Medición del desempeño de algoritmos de dehazing

Como se ha mostrado previamente el mejoramiento de imágenes adquiridas en malas condiciones climáticas (*dehazing*) es investigado intensivamente en el mundo, además de tener muchas aplicaciones potenciales en la actualidad. Como consecuencia de lo antes mencionado, la evaluación de distintas estrategias orientadas a resolver este problema permite tener un marco de comparación, sin embargo, medir el desempeño de un algoritmo de dehazing es difícil, dado el gran número de distintos escenarios donde

se presenta el fenómeno de hazing y la gran diferencia de características que estas presentan. En la Tabla 1.3 se presentan distintas métricas y el número de artículos donde fueron utilizadas.

Tabla 1.3: Análisis de diferentes métricas utilizadas para medir el desempeño de métodos dehazing.

Métricas	Referencias
Evaluación de la calidad de imagen (IQA)	[46] [37] [62]
Error cuadrático medio (MSE)	[46] [63] [64] [65] [65]
Relación señal/ruido pico (PSNR)	[46] [63] [66] [67] [14] [65] [12] [60] [68] [69] [70]
Relación contraste/ruido (CNR)	[14]
Índice de Similitud Estructural (SSIM)	[71] [65] [12] [68] [69] [70]
Medida de mejora (ME)	[72]
Entropía y gradiente promedio de las imágenes restauradas	[48]
Relación de bordes visibles (e), el porcentaje del número de píxeles saturados (σ) (Hautiere)	[51] [55] [71] [33] [73]
Similitud de estructura (Ss) y la similitud de luminancia (Ls). (Wang)	[51]
Raíz de Error Cuadrático Medio (RMSE) y coeficiente de correlación cuadrática (CCC)	[49] [50]
Subjetivo	[56] [58] [43] [74] [49] [40] [39] [31] [52] [75] [28] [33] [8] [22] [36] [76] [25] [77] [19] [78] [57] [79] [80] [36] [51]
Índice CNC	[71]
Evaluador de calidad de imagen natural sin referencia (NIQE)	[63]
e, r (Tarel)	[43] [41] [6] [81] [82]
Q-Mos	[66]
Entropía y gradiente promedio de las imágenes restauradas	[35] [20] [83] [62] [79] [82]
Error de transmisión	[3]
Desviación Estándar	[20] [62]

Continúa en la siguiente página...

Tabla 1.3: Análisis de diferentes métricas utilizadas para medir el desempeño de métodos dehazing (Continuación).

Métricas	Referencias
Gradiente Promedio	[20] [62] [82]
Error de transmisión	[3]
Evaluación de la calidad de imagen independiente del rango dinámico	[62]
Error de estimación de A	[3]

Se observa que se utiliza una gran número de métricas tanto referenciadas, no referenciadas, aunque las evaluaciones subjetivas han sido más utilizadas en la literatura. Es importante mencionar que en la literatura existen métricas diseñadas expresamente para medir el desempeño de métodos de dehazing como los descritos a continuación:

En [84] se calcula la relación entre el gradiente de los bordes visibles antes y después de la restauración, también se propone un indicador basado en el concepto de nivel de visibilidad. En [85] son propuestas tres métodos para evaluar la calidad del dehazing, el primero un método referenciado usando haze sintético, las otras son calculando la densidad de haze de imágenes en grises y la creación de un sistema de imagen de color basado en la percepción visual humana. En esta investigación no son utilizadas estas métricas debido a su bajo nivel de adopción en la comunidad científica.

Las métricas utilizadas para medir el rendimiento de los métodos propuestos son las dos métricas más usadas: el índice de similitud estructural (por sus siglas en inglés SSIM) y la proporción máxima de señal a ruido (por sus siglas en inglés PSNR).

1.2.4. Análisis del costo computacional de los métodos más relevantes

Dada la imposibilidad de poder realizar un análisis temporal de todos los algoritmos representativos de *dehazing* en un mismo *hardware*, y la dificultad de acceder al código de cada uno de los algoritmos, además de que la mayoría no ofrecen un reporte de su complejidad computacional, se muestra a continuación una comparación basada en los resultados temporales expuestos, y aunque los resultados son obtenidos bajo distintos tipos de *hardware*, la información ofrece un marco de comparación de los órdenes de magnitud asociados a cada algoritmo.

En la Tabla 1.4 son mostrados los tiempos de ejecución aproximados de algoritmos representativos, y las especificaciones de *hardware* sobre los que se ejecutaron.

Tabla 1.4: Comparativa del desempeño de métodos en la literatura.

Año	Referencia	Tiempos de procesamiento (s)	Resolución (píxeles)	Hardware	Lenguaje
2008	[19]	300-420	600×400	Intel Pentium dual core a 2 ghz	No reportado
	[32]	35	512×512	Intel Pentium dual core a 1.6 ghz	No reportado
2009	[6]	0.17	759×574	No reportado	No reportado
2010	[62]	0.002-0.03	600×400	No reportado	No reportado
	[86]	0.08-0.1	600X400	Intel Pentium Dual CPU T3200(2.00 GHz) y NVIDIA GeForce 9300M GS	C++, CUDA y OpenCV
	[86]	0.5	600×400	Intel Pentium Dual CPU T3200(2.00 GHz)	C++ y OpenCV
2010	[36]	10-20	600×400	Intel Pentium 4 a 3.0 ghz	No reportado
	[8]	4	1 megapixel	Intel Core 2 Duo a 2.2 ghz	No reportado
	[8]	4	1 megapixel	2.2 GHz Intel Core 2 Duo	C++
	[37]	0.013	600X800	CPU (Intel 2 Duo 2.00 GHz)	No reportado
	[87]	0.54	720×480	Intel Core 2 Quad Processor a 2.5 GHz	Matlab
	[22]	20-30	600×400	2.5GHz Core Quad processor	MATLAB
2012	[39]	0.031	600×400	3.2GHz Intel Core i5 Processor	C++
	[88]	0.023	640×480	Intel 3.3GHz quad core processor	openMP y SIMD
	[88]	0.050	640×480	Intel 3.3GHz quad core processor	No reportado
2013	[20]	9.53	260×147	2.8GHz Pentium Dual and 2.0GB of RAM	MATLAB
	[89]	5.909	600×450	Cortex A8	C
	[83]	97.193	800×600	AMD quad core 3.0GHz y 4GB de memoria RAM	Matlab 2012a
	[40]	0.02	640×356	Intel Core i5-2500K processor y 4 GB de memoria RAM	SIMD y OpenMP
	[74]	0.1	600×400	64-bit 2.70GHZ processor	C
	[40]	0.12	640×356	Intel Core i5-2500K processor y 4 GB de memoria RAM	MATLAB
	[89]	0.172	600×400	Pentium Dual Core	C
	[89]	0.172	600×400	Core 2 Quad	C
[89]	0.641	600×400	Pentium 4	C	

Continúa en la siguiente página...

Tabla 1.4: (Continuación) Algunos algoritmos basados en el principio del canal oscuro presentes en la literatura.

Año ²	Referencia	Tiempos de procesamiento (s)	Resolución (píxeles)	Hardware	Lenguaje
	[75]	0.256	2.83 mb	Intel Xeon E5520 2.27 GHz CPU y 4 GB de memoria RAM	C++
	[89]	0.033	2560×2048	TSMC 0.13-?m	Verilog HDL
	[?]	3.41	576×768	Intel® Core i7-2600 processor y 4 GB de memoria RAM	MATLAB
2014	[71]	120	600×400	3.00 GHz Intel Pentium Dual-Core Processor.	MATLAB
	[90]	4	720×576	3.2 GHZ CORE i5	MATLAB
	[80]	13	640×480	3.2 GHz Intel Core i5 Processor	MATLAB
	[91]	2.278	600×400	Intel Xeon @2.50GHz	Matlab 7.0.4
	[90]	.013	720X576	FPGA	VHDL
	[78]	0.038	720×576	Core i3, Cpu 2.39 GHZ, 1.92 GHz Memory	Visual Studio 2010
	[92]	0.2	600×400	Pentium 4	C
	[?]	0.4	600×800	3.2 GHz Intel Core i5 Processor)	Not reported
	[3]	0.55	1 megapixel	CPU (2.6 GHz Computer)	C
	[35]	3.56 s	600×400	Intel Core (TM) i5-3230M CPU@2.60GHz y 8 GB de memoria RAM	MATLAB
	[44]	30-32	600×800	2.20 GHz Intel core2duo	MATLAB 12
	[66]	5.46	640×480	Intel Core 2 duo (2.0 GHz) y 1 GB de memoria RAM	MATLAB7.1
[66]	0.030	640×480	Intel Core 2 duo (2.0 GHz) y 1 GB de memoria RAM	OpenCV2.4 e Intel TBB	
2015	[46]	0.031	651×509	2.93GHz Intel Core2 Duo CPU y 6 GB de memoria RAM	No reportado
	[50]	300	600×400	No reportado	No reportado
	[55]	2.475	600×400	Intel Core(TM) i5-3337U CPU @ 1.80GHz y 4 GB de memoria RAM	MATLAB R2012b
	[52]	0.040	600×400	No reportado	No reportado
	[57]	0.075	1 megapixel	2.7 GHz Intel Pentium dual-core CPU y 2 GB de memoria RAM	c++

Continúa en la siguiente página...

Tabla 1.4: (Continuación) Algunos algoritmos basados en el principio del canal oscuro presentes en la literatura.

Año ²	Referencia	Tiempos de procesamiento (s)	Resolución (píxeles)	Hardware	Lenguaje
2015	[86]	0.08-0.1	600×400	No reportado	No reportado
	[93]	0.13	600×400	3.4 GHz Intel i7 Processor	MATLAB
	[94]	0.463 (CPU and GPU)	600×480	Windows Phone device, Snapdragon MSM8260A y 1 gb de RAM	No reportado
	[54]	0.63	600×400	Intel core i7 CPU, 16 GB RAM	Matlab 7.0.4
	[56]	10-20	600×400	P4-4GHz PC y 2 GB de RAM	No reportado
	[94]	11.122 (CPU)	600×480	Windows Phone device y Snapdragon MSM8260A and 1 GB de RAM	No reportado
	[95]	1933.73	800×600	No reportado	No reportado
	[96]	0.020-0.060	768×576	a 64-bit 2.70GHZ processor	No reportado
[96]	0.6	768×576	a 64-bit 2.70GHZ processor	No reportado	

²Otros trabajos como los presentados por *Kratz* [77] y *Nishino* [51] no reportan resultados, mientras *Gibson* [74] no reporta resultados claros.

1.2.5. Implementaciones de métodos de dehazing en la literatura

Hay varias investigaciones orientadas a implementar los métodos de dehazing sobre distintos dispositivos y tecnologías para aumentar su rendimiento y hacerlos aptos para posibles aplicaciones, algunas de ellas son:

En la Tesis Doctoral presentada en [95] se realiza una implementación del dark channel prior donde se elimina el proceso de matting, dado su costo y para minimizar los artefactos producidos por los parches de 15×15 , se usan de 4×4 , para posteriormente realizar una ecualización, para una imagen de 1376×856 se consigue velocidad de 1 Hz utilizado en un sistema de vigilancia. La implementación fue realizada sobre el siguiente hardware:

- Procesador Intel Core i5 750 (QuadCore) @2,67Ghz.
- Nvidia GeForce GTS 250, PCIe, 1GB GDDR3.
- 8GB DDR3 (1333Mhz) RAM.

En [40] se propone un algoritmo para el dehazing y utilizando técnicas de paralelización como SIMD y OpenMP consiguen llevar su algoritmo a 7.5, 7.6, y 8.1 cuadros por segundo (por sus siglas en inglés fps) para imágenes de 640×356 píxeles, en las imágenes Riverside, Intersection, y Road View, a 31.8, 36.8, y 46.1 fps respectivamente.

El SIMD es usada en el refinamiento de la transmisión, procesando 4 píxeles en paralelo, y aplicando OpenMP para restaurar los valores de los píxeles usando 4 procesadores en paralelo.

Las características del sistema donde es implementada son:

- Procesador Intel Core i5-2500K.
- 4GB RAM.

En [86] se implementó un algoritmo basado en el dark prior channel y un filtro bilateral cruzado en dos versiones, una versión basada en una GPU usando OpenCV para la entrada y salida de imágenes y videos y NVIDIA CUDA(Compute Unified Device Architecture) y una versión con sólo el CPU usando C++.

Las características del sistema donde es implementada son:

- Procesador Intel Pentium Dual CPU T3200 (2.00 GHz).
- NVIDIA GeForce 9300M GS.

Para una imagen de tamaño de 600×400 , puede procesar cerca de 10-12 cuadros por segundo, y el tiempo de procesamiento de la versión del CPU es cerca 0.5 segundos.

En [88] es propuesto un algoritmo de dehazing para video, se introduce la noción de coherencia temporal dentro del algoritmo para eliminar el parpadeo entre los fotogramas. Se utiliza SIMD y OpenMP.

Las características del sistema donde es implementada son:

- Procesador Intel 3.3GHz quad core.
- NVIDIA GeForce 9300M GS.

Se alcanzan 50 fps sobre secuencias de video de 640×480 píxeles.

En [81] se propone un método eficiente para remover el haze de una sola imagen basado en el dark prior channel y la transformada rápida de Fourier. Bajo métricas cualitativas como cuantitativas se muestra que el método alcanza el rendimiento del filtrado bilateral siendo un 88 % de rendimiento. Una imagen de 600×400 se procesa en 0.561 segundos. Este método es adecuado para sistemas de vigilancia y teledetección.

Las características del sistema donde es implementada son:

- Core (TM) i5-3337U CPU @1.80 GHz.
- 4GB RAM.
- MATLAB R2012b.

En [93] se propone un nuevo método de dehazing que utiliza una sola imagen. También está basado en el Dark Prior Channel y hace un interpolación de bloque a pixel. Con una interpolación una imagen de 320×240 píxeles se procesa en 0.05 segundos.

- 3.4 GHz Intel i7 Processor.
- MATLAB.

En [89] es presentado un algoritmo de dehazing rápido y eficiente, se emplea un método aproximado de extremos para extraer la luz atmosférica y propone una estimación de contornos para obtener la transmisión usando un algoritmo de conservación de bordes y filtros de media alternativamente, el algoritmo puede eliminar los artefactos (halos) generados por el Dark Prior Channel.

Para conseguir los requerimientos del tiempo real, se utiliza una arquitectura de Hardware pipeline de 11 niveles, esta arquitectura alcanza una velocidad de 200 MHz

con 12.8k compuertas utilizadas usando la tecnología TSMC 0.13.

La arquitectura de hardware es implementada usando Verilog HDL, se uso SYNOPSYS Design Vision para sintetizar el diseño con la librería de TSMC 0.13. Trabaja con un periodo de reloj de 5 ns y alcanza una velocidad de 200 Mpíxeles/s, lo cual permite por ejemplo, procesar un video con resolución QSXGA (2560 x2048) a 30 cuadros/segundo, el consumo de energía es de 11.9 mW con un voltaje de 1.8 V.

Para verificar la complejidad computacional del método se probó en un procesador Cortex A8 (procesador de sistema embebido) y un procesador Core 2 Quad, respectivamente. Para una imagen de 600×400 el Cortex A8 toma 5.909 segundos, el cual es cerca de 50 veces más lento que lo obtenido por un procesador Core 2 Quad (0.172 segundos).

En [90] se presenta una aceleración alcanzando tiempo real sobre Hardware del dark channel prior y el filtro guiado sobre un chip FPGA con las siguientes características:

- El cálculo del canal oscuro y la luz atmosférica son modificadas para reducir los cálculos.
- Dos pipelines son aplicados en el filtrado guiado para acelerar el procesamiento.
- Se usa un filtro rápido de media para acelerar el filtrado por media, el cual es el cálculo principal del filtro guiado, para eliminar los cálculos redundantes.

El diseño puede alcanzar 13.74 ms en 100 MHz cuando se procesa una imagen de 720×576 , dando casi los mismos resultados que el algoritmo original.

1.2.6. Aplicaciones de los métodos de dehazing en la literatura

Existe una gran cantidad de sistemas visión artificial que son susceptibles a malas condiciones climáticas (hazing). el mejoramiento de la eficiencia de los algoritmos de dehazing y el aumento de capacidad de procesamiento ha permitido que cada vez haya más aplicaciones, en el dehazing, estos son algunos ejemplos:

En [72] se presenta un algoritmo adaptativo espacialmente que mezcla los histogramas de color considerando la longitud de onda dependiente de la turbidez atmosférica. Este algoritmo es dividido en tres partes: la segmentación de imágenes basada en las clases geométricas, la generación del mapa de transmisión adaptado al contexto y la transformación de intensidad para mejorar las imágenes obtenidas de un vehículo aéreo no tripulado (UAV, por sus siglas en inglés), generando un modelo de degradación en imágenes obtenidas de UAV's considerando la longitud de onda de las fuentes de iluminación.

En [66] se describe un nuevo método para mejorar imágenes submarinas afectadas por haze, la dispersión y el cambio de color son los principales problemas de la distorsión en imágenes submarinas, la principal contribución es la propuesta de un nuevo modelo submarino para compensar la discrepancia en la atenuación a través de la trayectoria de propagación, usando un algoritmo de dehazing el cuál es un filtrado trigonométrico mixto rápido.

Para validar su algoritmo simulan reconocimiento de objetos submarinos en un tanque en un cuarto oscuro. El sistema donde implementan su algoritmo tiene las siguientes características:

- OLYMPUS STYLUS TG 2.
- Intel Core 2 duo (2.0 GHz).
- 1 GB RAM.
- MATLAB 7.1.
- OpenCV 2.4 a Intel TBB parallel algorithms.

El algoritmo procesa imágenes de 640×480 píxeles en 30 ms aproximadamente. Su desempeño ha sido medido mediante PSNR, SSIM y QMOS.

En [9] se propone un algoritmo basado en el principio del canal oscuro que mediante el filtro de la mediana elimina los halos creados por el principio del canal oscuro original. Además se estudia su desempeño en sistemas de vigilancia. En esta investigación se concluye que se presentan mejores resultados cuando se realiza el dehazing antes de comprimir y transmitir las imágenes.

En [62] se presenta un método nuevo de dehazing basado en BSHTI (Background Suppressed Haze Thickness Index) orientado a eliminar la afectación ocasionado por el hazing en teledetección, además se presenta una implementación paralela del algoritmo.

Para una imagen de 1523×1276 píxeles, el tiempo de procesamiento es de 80 segundos para la versión normal, y 20 segundos para la versión paralelizada.

En [76] se propone un algoritmo del dehazing en imágenes submarinas y analiza su desempeño, comparando su desempeño con el presentado en [32] y ecualización de histogramas.

En [97] es descrito un módulo para remover el haze en Lenguaje IDL (usado con el software ENVI) orientado a imágenes obtenidas de satélites, este algoritmo requiere mucha intervención humana.

En [98] se presenta un algoritmo de detección de horizontes basado en el principio del canal oscuro para imágenes tomadas por UAV's en malas condiciones climáticas, el cual es capaz de detectar los horizontes y es robusto aun para algunas escenas complejas.

En [99] se propone un algoritmo para mejorar una imagen degradada por haze, reduciendo los efectos de la haze en sistemas de monitoreo (video) para el tráfico en exterior mediante las siguientes etapas:

- Se usa el principio del canal oscuro para remover el hazing.
- Se realiza una ecualización de histograma para mejorar el contraste y brillo de las imágenes.

Es implementado en hardware, en un FPGA Cyclone3 de Altera, consiguiendose ejecutar el algoritmo propuesto en tiempo real.

En [78] es propuesto un método para el dehazing usado para el monitoreo de tráfico, realizando en primer lugar un dark prior channel mejorado, para después mejorar su velocidad utilizando la correlación entre los fotogramas adyacentes de videos. Los objetos móviles son detectados usando un método de diferencias en fotogramas adyacentes. Los contenidos de los fotogramas son divididos en fondo y frente, entonces el frente y el fondo son procesados de distintas formas para reducir la complejidad computacional del dehazing.

Las características del sistema donde se implementó el algoritmo son las siguientes:

- CPU Core i3 a 2.39 GHz.
- 1.92 Gb de memoria Ram.
- Visual Studio 2010 Platform.

El algoritmo puede procesar fotogramas de 720×576 a 26 fotogramas por segundo en promedio y de 1280×720 a 13 ó 14 fotogramas por segundo.

En [100] se analizan técnicas del estado del arte orientadas a mejorar imágenes submarinas con dehazing, la investigación propone un método llamado Mix CLAHE (Mixture contrast limited adaptive histogram equalization) y el Dark prior channel para mejorar las imágenes, lo cuál permite reducir el nivel de ruido, mejorar la exposición de las regiones oscuras, mejorar el contraste global mientras los detalles más finos y los bordes son mejorados significativamente.

En [101] se estudian los principios de degradación y la ley del canal oscuro de imágenes con haze en reconocimiento de imágenes en UAV.

En [102] es implementado un algoritmo de dehazing para remover el haze de radiografías donde se observan objetos soldados, dado que los objetos soldados tienen grietas y las imágenes a menudo son muy ruidosas y de baja calidad, se muestra que los métodos de dehazing pueden mejorar el contraste de la radiografía.

En [96] se presenta una arquitectura para un sistema de monitoreo de tráfico en tiempo real para videos con haze. Un sistema así debe cumplir con dos características:

1. La calidad de una imagen después de remover el haze debe ser suficiente para un análisis posterior como la detección de objetos y seguimiento de objetos.
2. Debe ser barato computacionalmente para procesarlo en tiempo real.

En este trabajo se propone una arquitectura paralela.

La resolución de las imágenes es de 768×576 y el número de cuadros por segundo alcanzado por el sistema es de 30.

El sistema donde implementan su algoritmo tiene un procesador de 64-bit a 2.70 GHz, el tiempo de procesado para cada imagen es de 0.6 segundos en su implementación sin aceleración, mientras que para la versión paralela se alcanza a reducir de 0,020 a 0,060 segundos. Basado en el análisis mostrado en esta sección la investigación está orientada en mejorar la exactitud de la restauración de las imágenes tomadas bajo malas condiciones climáticas, sin dejar de lado la importancia del tiempo computacional.

Capítulo 2

Fundamento teórico

En el fundamento teórico se explican conceptos utilizados en el desarrollo de esta investigación, abarcando los siguientes temas: La visión, las partes de un sistema de visión artificial, las imágenes, el procesamiento de Imágenes, operaciones morfológicas, el modelo de dispersión atmosférica, el algoritmo basado en el *dark channel prior* y las métricas de evaluación de los algoritmos de *dehazing*.

2.1. La visión artificial

La visión artificial expone grandes retos y dificultades, en parte ello se debe a que la visión es un problema inverso, debido a que vivimos en un mundo tridimensional(3D), y cuando las computadoras intentan analizar objetos en el espacio 3D, los sensores disponibles (por ejemplo cámaras de TV) usualmente dan imágenes de dos dimensiones(2D), y esta proyección a un número más bajo de dimensiones incurre en enormes pérdidas de información, por lo tanto tratamos de recuperar algunas incógnitas proporcionando información insuficiente para especificar la solución completa, lo que conlleva a no tener una solución única. Existen varias alternativas para eliminar la ambigüedad entre las posibles soluciones [103]:

- Tomar más imágenes,
- hacer más hipótesis sobre el mundo.

Generalmente tomar una mayor cantidad de imágenes es imposible de llevar a cabo por lo que muchas veces, la única opción posible es hacer más hipótesis del mundo recurriendo a modelos basados en la física y la Teoría de la probabilidad [104].

La estructura general de un sistema de Visión Artificial es dividida en dos partes bien diferenciadas, el procesamiento de imágenes y la comprensión de imágenes un diagrama de la estructura y la interrelación de sus etapas es mostrada a continuación (Figura 2.1):

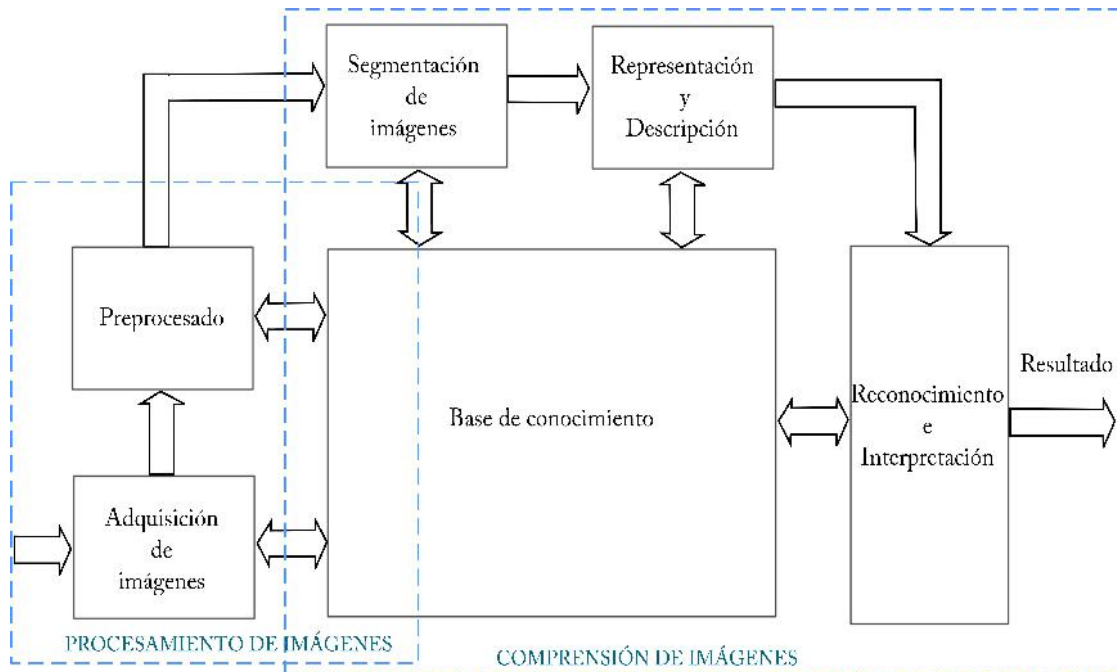


Figura 2.1: Estructura general de un sistema de visión artificial [Modificado de [5]].

Debido a que este trabajo está centrado en la etapa de preprocesado, se describirá este tema, siendo necesario también explicar la etapa anterior: la Adquisición de Imágenes y el concepto de imágenes.

2.2. Las imágenes

La forma en que los humanos y los sistemas de Visión Artificial tienen contacto con el mundo es a través de las imágenes. La Real Academia Española (RAE) define a una imagen como: “Figura, representación, semejanza y apariencia de algo” y en el contexto de óptica “Reproducción de la figura de un objeto por la combinación de los rayos de luz que proceden de él” [105].

Existen 2 tipos de imágenes: analógicas y digitales.

Imagen analógica

Una imagen es analógica cuando los matices captados son infinitos y susceptibles de ser interpretados una y otra vez, especialmente el color de los objetos y la definición de sus perímetros, así es como las imágenes reales son captadas por nuestro cerebro [106].

Imagen digital

Una imagen digital puede ser definida como una función bidimensional $f(x, y)$, donde x e y son coordenadas espaciales, y la amplitud f de cualquier par de coordenadas (x, y) es llamado la intensidad de la imagen en ese punto. Cuando la intensidad de los valores de f son finitos en cantidades discretas, se dice que son imágenes digitales, una imagen digital esta compuesta de un número finito de elementos, cada uno de ellos con una localización y valor, cada uno de estos elementos es llamado pixel (*Picture Element*) [5].

Generalmente, una imagen digital es un arreglo bidimensional, consistiendo de n renglones y m columnas. La resolución de una imagen dada es escrita como $m \times n$. Por convención $f(0, 0)$ es asignado a la esquina superior izquierda y $f(m - 1, n - 1)$ la esquina inferior derecha (Figura 2.2).




Figura 2.2: Imagen digital [Modificado de [5]].

La información que pueden guardar los píxeles depende del tipo de dato usado para representarlo. Los píxeles son generalmente siempre palabras binarias de longitud k tal que un píxel puede representar 2^k valores distintos. El valor k es llamado profundidad del bit o del píxel de la imagen. La elección del nivel exacto de bits de un píxel individual depende del propósito de la imagen. Algunos ejemplos de imágenes de acuerdo a la profundidad del bit son imágenes en escala de grises y color *RGB* [106].

Imagen en escala de grises (Imagen de intensidad)

Los datos de una imagen en escala de grises consisten de un solo canal que representa la intensidad, brillo o densidad de la imagen. En la mayoría de los casos, solo pueden ser detectados valores positivos, como los números representan la intensidad de la energía

de la luz o la densidad de la película esta no puede ser negativa, generalmente se usan enteros en el rango de $[0 \dots 2^k - 1]$. Por ejemplo cuando $k = 1$, es decir la información de un pixel ocupa solo un bit, las imágenes son llamadas binarias. El tipo de imagen en escala de grises mas utilizado usa $k = 8 \text{ bits}$ (1 *byte*) por pixel y los valores de intensidad están en el rango de $[0 \dots 255]$, donde el valor 0 representa el menor brillo (negro) y 255 el máximo brillo (blanco) [5].

Imagen de color

Una imagen de color es similar a una de escalas de grises solo que en esta existen por lo menos 3 bandas, o canales. Existen distintas formas de representar los colores en una imagen llamadas modelos del color, por ejemplo *CMYK*, *HSL*, *HSV*, *YUV*, *YIQ* y *RGB* (Ian T. Young, 1998), en este trabajo utilizaremos el modelo *RGB* debido a que es el modelo más ampliamente utilizado [5]. A continuación es explicado brevemente:




Figura 2.3: El modelo *RGB* [Modificado de [5]].

En el modelo *RGB* (*Red*, *Green*, *Blue*) (Figura 2.2) existen 3 canales (rojo, verde, azul), cada uno de ellos con 8 bits por lo que pueden existir $2^{24} = 256^3 = 16,777,216$ colores distintos por pixeles (Figura 2.3), es el modelo más ampliamente utilizado debido a la sencillez para su implementación en el hardware [5].

Para almacenar las imágenes digitales existen muchos formatos, entre los más utilizados están *BMP*, *PNG*, *GIF*, *TIFF* y *JPEG*, sin embargo en este trabajo fue utilizado el *PNG* y *JPEG* (debido a que las imágenes que fueron obtenidas del repositorio de imágenes tenían esos formatos y no hubo necesidad de modificarlos).

2.3. Procesamiento de imágenes

Debido a la imperfección del dispositivo de captura de la imagen o la incapacidad de controlar el medio ambiente la imagen digital obtenida generalmente es sometida al procesamiento de imágenes. Aunque algunos consideran el procesamiento de imágenes fuera del ámbito de la visión artificial, pues la comprensión de imágenes es muy distinta al procesamiento de imágenes (el cual estudia las transformaciones imagen a imagen, no la obtención de algún significado de un conjunto de objetos reconocidos extraídos de atributos de imágenes [106]), la mayoría de las aplicaciones de visión artificial, tal como el reconocimiento de patrones, requieren ser cuidadosos en el diseño de los pasos a seguir del procesamiento de imágenes para lograr resultados aceptables [104].

De una forma general en el procesamiento de imágenes los tipos de operaciones que pueden ser aplicadas a imágenes digitales que transforman una imagen de entrada $a[m, n]$ en una de salida $b[m, n]$ (u otra representación) pueden ser clasificadas dentro de tres categorías [107].

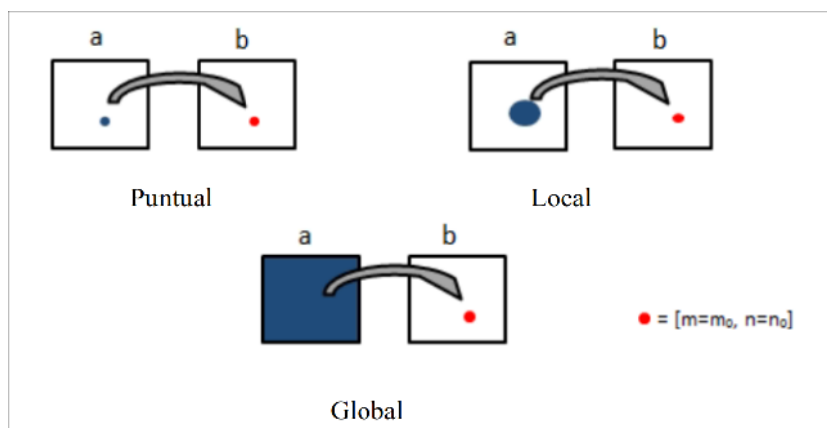


Figura 2.4: Tipos de operaciones en el procesamiento de imágenes [Modificado de [5]].

A continuación se describen las tres categorías mostradas en la Figura 2.4:

- **Puntual:** el valor de la salida en una coordenada específica depende solo del valor de la entrada en alguna posición que puede ser la misma coordenada.
- **Local:** el valor de la salida en una coordenada específica depende de los valores de entrada en los vecinos y la misma.
- **Global:** el valor de la salida en una coordenada específica depende de todos los valores de la imagen de entrada.

Operaciones realizadas en el procesamiento de una imagen

El procesamiento de imágenes puede dividirse en distintas operaciones de acuerdo a su finalidad, estas son algunas de las operaciones más importantes [107]:

- **Corrección de exposición de colores y balance de colores:** el objetivo es corregir ciertos defectos de iluminación en la obtención de la imagen.
- **Reducción de ruido de la imagen:** tienen por objeto reducir el ruido y/o efectos falsos que pueden presentarse en una imagen a consecuencia del proceso de captura, digitalización y transmisión.
- **Escalado de la imagen:** transformación geométrica utilizada para comprimir o agrandar el tamaño de una imagen (o parte de una imagen).
- **Incremento de nitidez:** operaciones en las que se intenta aumentar la claridad con la que los detalles son percibidos en la imagen.
- **Rotación de imágenes:** transformación geométrica utilizada para cambiar la orientación de una imagen.
- **Cambio de espacio o dominio:** operaciones que tienen como finalidad cambiar la forma de representar una imagen.

La herramienta utilizada de procesamiento de imágenes para tratar el problema del hazing fue la morfología de imágenes, por lo que a continuación son explicados algunos conceptos de este tema.

2.4. La atmósfera

Constitución

La atmósfera nunca está libre de partículas. Aún el aire puro, está formada por Nitrógeno, Oxígeno, Argón, Dioxido de Carbono y otros compuestos. Estudios realizados con aire puro, han determinado que el rango visual está entre las de 277km a 348km, sin considerar la curvatura de la tierra [108].

Se ha creado un código de visibilidad internacional que define y limita los distintos rangos meteorológicos con sus nombres abarcando desde menos de 50 metros hasta 50 kilómetros (Tabla 2.1).

Código	Condición climática	Rango Meteoreológico, R_m	Coefficiente de dispersión, $B_{sc}(km^{-1})$
0	Niebla densa	50 m	78.2
1	Niebla espesa	50 m-200 m	78.2-19.6
2	Niebla moderada	200 m-500 m	19.6-7.82
3	Niebla ligera	500 m-1000 m	7.82-3.91
4	Niebla clara	1 km-2 km	3.91-1.96
5	Neblina	2 km-4 km	1.96-0.954
6	Neblina ligera	4 km-10 km	0.954-0.391
7	Claridad	10 km-20 km	0.391-0.196
8	Mucha Claridad	20 km-50 km	0.196-0.078
9	Excepcionalmente claro	50 km	0.078
-	Aire puro	277 km	0.0141

Tabla 2.1: Clasificación de las condiciones climáticas en el código de visibilidad internacional [Modificada de [17]].

El hecho que siempre existan partículas en la atmósfera origina que el fenómeno de dispersión atmosférica suceda en menor o mayor medida, por eso la necesidad de describirlo.

2.4.1. Dispersión atmosférica

La dispersión es el fenómeno de separación de las ondas de distinta frecuencia al atravesar un material. Todos los medios materiales son más o menos dispersivos, y la dispersión afecta a todas las ondas.

El coeficiente de dispersión $B(\gamma)$ está determinado por el material de la partícula, tamaño, forma, y concentración. Este fenómeno tiene como consecuencia dos fenómenos en la formación de una imagen los cuáles son la luz atmosférica y la atenuación directa [108].

2.4.1.1. Atenuación directa

El primer efecto de la dispersión es atenuar la luz incidente y este fenómeno está en función directa con la distancia a mayor distancia o índice de dispersión β la atenuación es más grande.

2.4.1.2. Luz atmosférica

Este fenómeno es visible a grandes distancias, influyendo en la iluminación donde el tono que está más cerca del horizonte parece mas luminoso. La fuente para este incremento de luminancia con la distancia es la luz del sol la cual es dispersada hasta los ojos del observador por el aire, que está en la línea de visión del humano y el objeto

observado.

Con la finalidad de realizar un modelo de la dispersión atmosférica se han realizado varios estudios acerca de la atmósfera. En el libro “*Theorie der horizontalen Sichtweite*” [109], se exponen los resultados de algunos estudios, a continuación se presenta los puntos más importantes de este trabajo, así como algunas otras conclusiones añadidas posteriormente.

2.4.2. Teoría del alcance de la visión de campo horizontal (Theorie der horizontalen Sichtweite)

El modelo de dispersión atmosférica está basados en generalizaciones y supuestos los cuáles fueron recopilados en [109], ahora se presentan los más importantes:

- La atmósfera es considerada como un medio turbio, conteniendo un gran número de pequeñas partículas.
- Cada elemento de volumen contiene un número muy grande de partículas.
- La acción de dispersión de cada partícula es independiente de la presencia de los demás.
- La luz dispersada desde un elemento de volumen se considera como proveniente de un punto en donde la intensidad es proporcional al número de partículas.
- Los rayos de luz se consideran rectilínea, es decir, la refracción atmosférica es ignorada.
- Todas las partes del cielo están igualmente iluminadas.

Más tarde, los supuestos realizados por el físico *Gruner* (1919) se encontraron convenientes para esta teoría y por lo tanto se han añadido:

- El coeficiente de atenuación por dispersión, es constante en un plano horizontal
- La curvatura de la tierra se descuida, y su superficie se considera como plana, horizontal, y de reflexión difusa.
- Las dimensiones lineales de todo el objeto observado son pequeñas en comparación con su distancia del observador.

Después describir la teoría y supuestos sobre la que descansa el modelo de dispersión atmosférica ya nos es posible describirlo.

2.5. Modelo de dispersión atmosférica

El modelo utilizado para describir la formación de una imagen con *haze* es el siguiente [20] (ver Figura 2.5):

$$I(x, y) = J(x, y)t(x, y) + A(1 - t(x, y)) \quad (2.1)$$

donde

- $I(x, y)$ es la intensidad observada en cada uno de los tres canales R , G o B en el pixel (x, y)
- $J(\chi)$ es el vector de la intensidad (RGB) de la superficie original de la escena en el mundo real que corresponde al pixel (x, y)
- A es el vector de color de la luz atmosférica global
- $t(x, y)$ es el medio de transmisión describiendo la porción de luz que no es dispersada o absorbida y alcanza la cámara
- Cuando la atmósfera es homogénea, la transmisión $t(x, y)$ puede ser expresada como:

$$t(x, y) = e^{-\beta d(x, y)} \quad (2.2)$$

donde

- β es el coeficiente de dispersión de la atmósfera
- $d(x, y)$ es la profundidad del elemento

β es una variable que ha sido caracterizada en el Sistema de Visión Internacional para los cuáles dependiendo del valor de afectación toma distintos nombres (ver Tabla 2.1), en seguida se describe este sistema.

Por tanto, la imagen sin afectaciones $J(x, y)$ se puede obtener como

$$J(x, y) = \frac{I(x, y) - A}{t(x, y)} + A \quad (2.3)$$

Es importante mencionar que la dificultad de obtener $J(\chi)$ radica en que en las imágenes se desconocen las variables A (luz atmosférica) y $t(x)$ (transmisión) lo que requiere el uso de conjeturas y suposiciones para encontrar una aproximación a estos valores, uno de los algoritmos más importantes que genera de manera muy certera estos valores es el, principio del canal oscuro el cuál es la base del algoritmo planteado y es descrito enseguida.

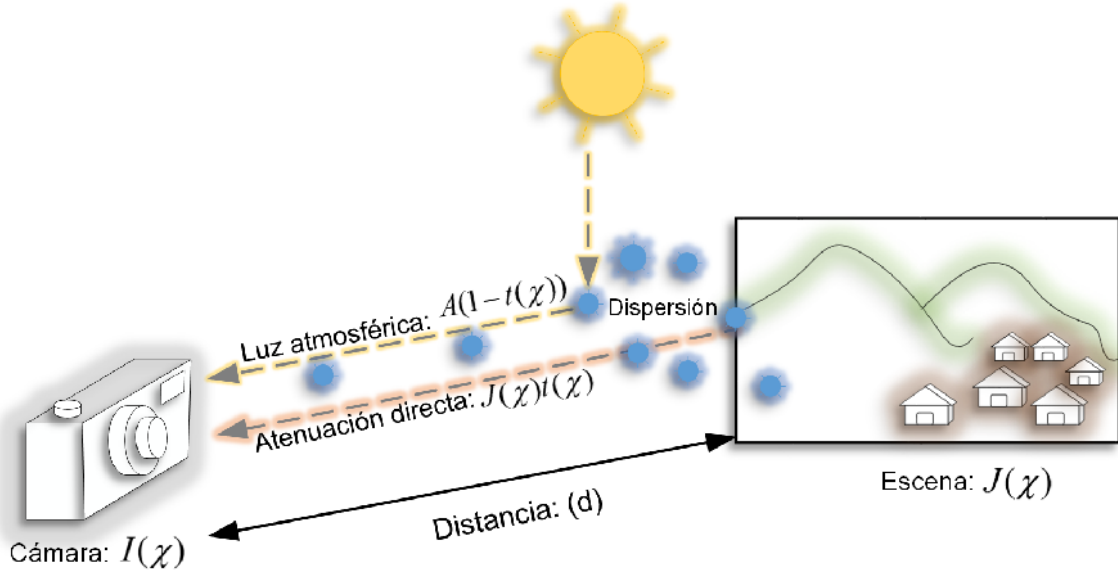


Figura 2.5: El modelo de dispersión atmosférica [Creación propia].

2.6. El principio del canal oscuro

El principio del canal oscuro o por su nombre en inglés *dark channel prior* propuesto en el 2011 en [15] es una observación de lo que ocurre en imágenes que no presentan el problema del *hazing* y son adquiridas de ambientes exteriores: en la mayoría de las regiones locales de una imagen (que no representen el cielo), al menos un canal del color (R , G o B) (llamado canal oscuro), tiene una muy baja intensidad en algunos píxeles. En otras palabras, la mínima intensidad en tales regiones locales de píxeles tiene un valor muy bajo (cercano a 0) (Véase Figura 2.6).

Formalmente, para una imagen $I(x, y)$, el canal oscuro $I^{dark}(x, y)$ se define como [15]:

$$I^{dark}(x, y) = \min_{C \in R, G, B} \left(\min_{z \in \Omega(x, y)} (I^c(z)) \right) \quad (2.4)$$

donde $\Omega(x, y)$ es la región local centrada en (x, y) , I^c es el canal de color de I (R , G o B) e z denota el índice para un píxel en $\Omega(x, y)$, por lo tanto el *dark channel prior* está definido como:

$$I^{dark}(x, y) \rightarrow 0. \quad (2.5)$$

Existen diversos factores responsables de la validez del Principio del canal oscuro:

- La existencia de sombras en las imágenes.



Figura 2.6: Ejemplo de los valores del canal oscuro de una imagen sin *hazing* (Sus valores tienden a 0) [Modificado de [15]].

- Objetos muy coloridos: Si un objeto es muy colorido, tendrá valores en cada componente de color con una gran varianza, esto es habrá elementos con valores muy altos y otros bajos.
- Objetos oscuros.

La observación del canal oscuro se cumple en la mayoría de los parches utilizados, sin embargo no en todos. Al decir la “mayoría” se debe entender que hay una alta probabilidad de que la observación sea cierta. Así que esta observación es verdadera sólo en términos estadísticos.

Sustituyendo en el modelo de dispersión atmosférica el principio del canal oscuro, suponiendo que transmisión en una ventana local es constante y tomando el operador mínimo para los tres canales de color se tiene que:

$$\min_c \left(\min_{z \in \Omega(x, y)} \left(\frac{I_h^c(z)}{A^c} \right) \right) = \tilde{t}(x, y) \min_c \left(\min_{z \in \Omega(x, y)} \left(\frac{I_h^c(z)}{A^c} \right) \right) + (1 - \tilde{t}(x)) \quad (2.6)$$

donde, $\tilde{t}(x, y)$ es la transmisión en la ventana $\Omega(x, y)$, como A es siempre positiva y el canal oscuro de una imagen libre de *hazing* de la imagen J tiende a cero (de acuerdo al *dark prior channel*), se tiene

$$\min_c \left(\min_{z \in \Omega(x, y)} \left(\frac{I_h^c(z)}{A^c} \right) \right) = 0. \quad (2.7)$$

Entonces la transmisión puede ser expresada como:

$$\tilde{t}(x, y) = 1 - \min_c \left(\min_{z \in \Omega(x, y)} \left(\frac{I_h^c(z)}{A^c} \right) \right). \quad (2.8)$$

Aunque la hipótesis del canal oscuro no fue propuesta teniendo en cuenta a los píxeles que forman el cielo, la ecuación anterior continúa funcionando debido a que el cielo está a una distancia infinita, lo que hace que el valor de la transmisión sea cercano a 0. Teniendo en cuenta que la ausencia total de *hazing* hace parecer la imagen poco natural, el autor en [15] propone utilizar un valor arbitrario $w = 0,95$ para dar naturalidad a las imágenes, ya que sugiere que las imágenes con $w = 1$ no lucen naturales:

$$\tilde{t}(x, y) = 1 - \omega \min_c \left(\min_{z \in \Omega(x, y)} \left(\frac{I_h^c(z)}{A^c} \right) \right). \quad (2.9)$$

El proceso anterior da una buena aproximación sin embargo como se puede apreciar en la Figuras 2.7 (a), 2.7 (b), 2.7 (c) y 2.7 (d) al usarse ventana en el cálculo de la transmisión se produce halos y artefactos falsos.

Este problema fue solucionado por el autor [33] mediante un proceso de *matting*, el cual es un proceso utilizado para separar el frente del fondo en las imágenes, mediante la utilización de un trimapa, esto es una imagen, separada en tres tipos de elementos: frente, fondo y una región no definida [75].

Matemáticamente el *matting* consiste en resolver un sistema Laplaciano de ecuaciones [15].

$$(L + \lambda I)t = \lambda \cup t \quad (2.10)$$

Donde L es una matriz Laplaciana y λ es un parámetro de regularización e I es una matriz de identidad con el mismo tamaño de L .

El método propuesto después de la refinación produce excelentes resultados (Ver Figuras 2.7 (e) y 2.7 (f)) sin embargo el costo temporal del algoritmo es muy alto y consume aproximadamente un 97% del tiempo de ejecución total del algoritmo (valores obtenidos por experimentación).

Finalmente el valor de cada píxel $I_o(x)$ está dado por:

$$I_o(x) = \frac{I_h(x) - A}{\max(t(x), t_0)} + A, \quad (2.11)$$

donde t_0 es una variable introducida para evitar tener 0 en el cociente, en [15] se propone el valor de 0,1.

2.6.0.1. Cálculo de la luz atmosférica

La luz atmosférica A es definida como el píxel con la intensidad más alta en la imagen original I_h del 0,01 % de los píxeles con mayor intensidad en el canal oscuro.

A continuación, se muestra un ejemplo del proceso del algoritmo:

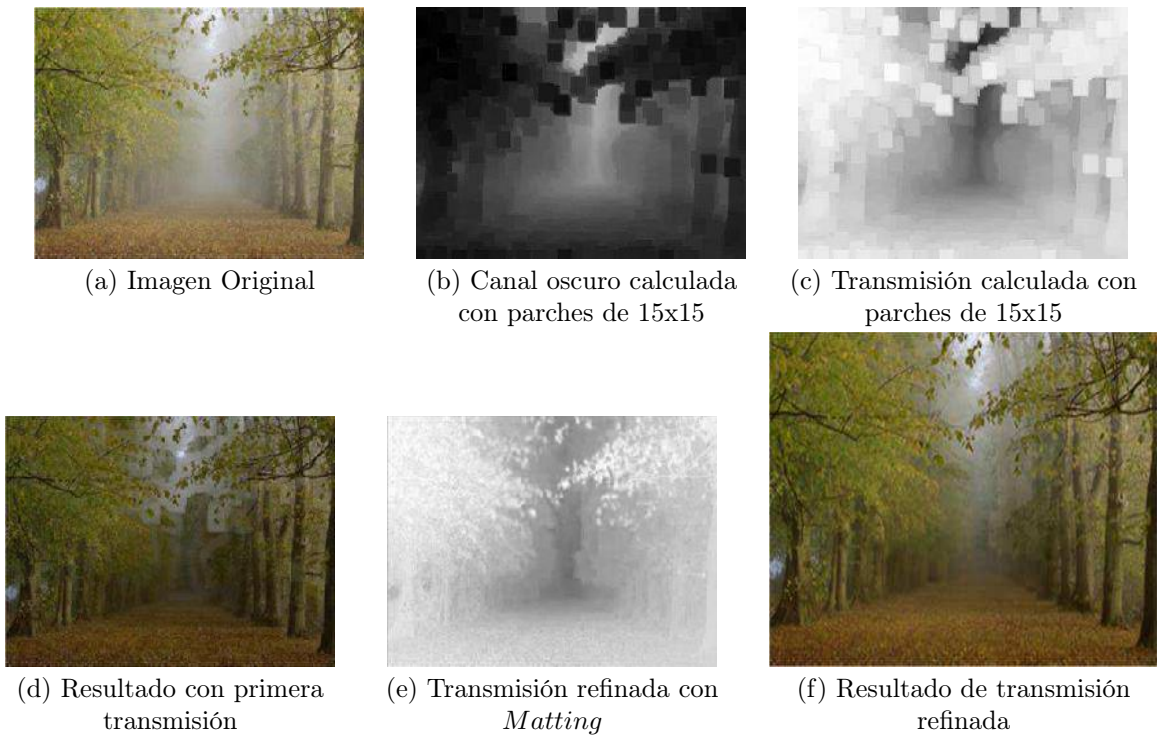


Figura 2.7: Imágenes resultado de la aplicación del *dark channel prior* [Imagen propia].

El problema del algoritmo clásico basado en el *dark channel prior* es el tiempo (ver Tabla 1.4), el refinamiento es extremadamente lento (97 por ciento del tiempo total aproximadamente para una imagen de 600×400 píxeles); este hecho es gran parte de la motivación al realizar esta investigación.

En la primera parte de esta investigación se propone una modificación a la definición del canal oscuro en la cual se sustituye el uso de las regiones locales cuadradas Ω por la mezcla estadística de múltiples ventanas que tienen distintas direcciones. Para entender mejor lo antes expresado es conveniente introducir términos de morfología matemática. Por tanto, a continuación se expresan conceptos básicos de esta disciplina.

2.7. Operaciones morfológicas

La morfología matemática se basa en geometría y forma [110]. Las operaciones morfológicas simplifican imágenes y conservan las principales características de forma de los objetos.

Un sistema de operadores como los de la morfología matemática es útil porque pueden formarse composiciones con sus operadores, que cuando actúan sobre formas complejas, son capaces de descomponerlas en sus partes conocidas y separarlas de las partes que le son extrañas [110].

Una imagen puede considerarse formada por conjuntos (regiones) de píxeles y, por tanto, pueden aplicarse herramientas de la Teoría de conjuntos. Un sistema de operadores de este tipo y su composición, permite que las formas subyacentes sean identificadas y reconstruidas de forma óptima a partir de sus formas distorsionadas y ruidosas.

La morfología matemática se puede usar, entre otros, con los siguientes objetivos [111]:

- Pre-procesamiento de imágenes (supresión de ruidos, simplificación de formas).
- Destacar la estructura de los objetos (extraer el esqueleto, detección de objetos, envolvente convexa, ampliación, reducción, . . .)
- Descripción de objetos (Área, perímetro, . . .)

Enseguida, se definirán conceptos utilizados en la investigación como erosión, dilatación y apertura en escala de grises.

2.7.1. Erosión en escalas de grises

La erosión de A por un elemento estructurante plano B en cualquier posición (x, y) está definido como el valor mínimo de la imagen en la región coincidente B cuando el origen de B está en (x, y) [112]. Por tanto, la erosión en (x, y) de una imagen A por un elemento estructurante B , está dado por:

$$[A \ominus B](x, y) = \min_{(s,t) \in B} A(x + s, y + t) \quad (2.12)$$

para un Elemento estructurante no plano, se define como:

$$[A \ominus B_N](x, y) = \min_{(s,t) \in B_N} A(x + s, y + t) - B_N(s, t). \quad (2.13)$$

2.7.2. Dilatación en escalas de grises

La Dilatación de A por un elemento estructurante plano B en la posición (x, y) está definido como el valor máximo de la imagen en la ventana definida por \hat{B} cuando el origen de \hat{B} está en (x, y) [113]. Entonces, la dilatación en (x, y) de una imagen A por un elemento estructurante B , está dado por:

$$[A \oplus B](x, y) = \max_{(s,t) \in B} A(x - s, y - t) \quad (2.14)$$

para un Elemento Estructurante no plano, se define como:

$$[A \oplus B_N](x, y) = \max_{(s,t) \in B_N} A(x - s, y - t) + B_N(s, t) \quad (2.15)$$

tanto para la erosión como dilatación en escala de grises generalmente solo se utilizan Elementos Estructurantes planos, debido a la dificultad del entendimiento de los resultados y a que se manejan resultados fuera del dominio de A . Finalmente la apertura es definida como una erosión seguida de una dilatación morfológica.

2.8. El perceptron multicapa

Las redes neuronales artificiales (RNA) son máquinas de aprendizaje inspiradas en un modelo matemático muy simplificado de sistemas neuronales biológicos [114]. En estos modelos, cada Elemento de Procesamiento (PE) se denomina neurona, y la conexión entre los PE forma una red. Uno de los primeros PE desarrollados fue el Perceptron, que consiste en múltiples entradas X_i multiplicadas por un valor escalar conocido como peso W_{ij} , y se añade un sesgo b_j . El resultado obtenido se procesa mediante una función de activación predefinida f , que puede describirse de la siguiente manera:

$$Y_j = f \left(\sum_i (W_{ij} * X_i + b_j) \right) \quad (2.16)$$

La función de activación más común f utilizada en Perceptron es la función tangente hiperbólica \tanh , que se expresa mediante

$$\tanh(x) = 2 \cdot \sigma(2x) - 1, \quad (2.17)$$

where $\sigma(x)$ is,

$$\sigma(x) = \frac{e^x}{1 + e^x} \quad (2.18)$$

El entrenamiento de la RNA ajusta los valores de peso y sesgo, con el fin de obtener la salida deseada en función de las combinaciones de entradas. Para resolver problemas de separación no lineal se conectan muchos Perceptrones en una o más topologías de

capas ocultas, esta red se llama Perceptrón Multicapa (MLP). La retropropagación es un algoritmo de entrenamiento eficiente para MLP, y es el más utilizado desde mediados de los años ochenta hasta el presente. La retropropagación es una generalización del método de mínimos cuadrados en el que las ponderaciones se actualizan según el error del cuadrado medio, que se determina mediante una comparación entre la salida deseada y la calculada [114]. La idea es encontrar la función de error mínimo en relación con los pesos de conexión. La función de error se calcula como

$$E = \frac{1}{2} \sum_{j \in M} (\hat{y}_m - y_m)^2, \quad (2.19)$$

siendo \hat{y}_m la salida deseada de m neuron y_m .

En el presente trabajo, se utiliza un MLP para lograr mapas de transmisión precisos con el fin de obtener imágenes de alta calidad en formato libre. Este método se describe en la siguiente sección.

2.9. Evaluación del dehazing

La evaluación de algoritmos de *dehazing* históricamente ha sido en su mayoría subjetiva, es decir, las personas usualmente juzgan la eficacia de los algoritmos basados en la intuición [75]. Sin embargo cada vez se hace más necesario utilizar herramientas que permitan comparaciones basadas en métricas cuantitativas, sin embargo las medidas cuantitativas presentan limitaciones propias de su diseño [115] [51], por tanto para tener una visión del desempeño más completa en este trabajo se evalúan los resultados mediante el uso de métricas ampliamente utilizadas en la literatura [116] las cuáles son el Error cuadrático medio *MSE*, la Proporción máxima de señal a ruido *PSNR* y el índice de similitud estructural *SSIM*, enseguida se explicarán brevemente estos conceptos:

2.10. MSE y PSNR

La Relación Señal a Ruido de Pico o *PSNR* (del inglés *Peak Signal-to-Noise Ratio*) es una medida cuantitativa de la calidad de una reconstrucción [117]. Es utilizada ampliamente en imágenes.

Para definir la métrica *PSNR* es necesario definir el error cuadrático medio (del inglés *MSE*), el cuál para dos imágenes monocromas I y J de tamaño $m \times n$ se define como:

$$MSE = \frac{1}{mn} \sum_{i=0}^{m-1} \sum_{j=0}^{n-1} \|I(i, j) - J(i, j)\|^2 \quad (2.20)$$

y el *PSNR* está dado por:

$$PSNR = 10 \log_{10} \left(\frac{\text{máx}_I^2}{MSE} \right) = 20 \log_{10} \left(\frac{\text{máx}_I}{\sqrt{MSE}} \right) \quad (2.21)$$

donde $\text{máx} = 2^B - 1$ y B es el número de Bits utilizados en la imagen.

En imágenes *RGB* se sigue la misma lógica con salvedad que se calcula el error cuadrático medio para los tres colores *R*, *G* y *B*.

Entre más grande sea el valor del *PSNR* es mejor la codificación.

2.11. Índice SSIM

El índice de Similitud Estructural o por su nombre en inglés *The Structural Similarity Index* (índice *SSIM*) está basado en el hecho de que las estructuras de los objetos de las escenas son independientes de la iluminación, entonces la influencia de esta debe ser aislada en el cálculo de la calidad de la imagen.

Sean f y g la imagen base y la restaurada respectivamente se obtienen sus medias (μ_f y μ_g), sus desviaciones estándar (σ_f y σ_g), y la covarianza (σ_{fg}), con la finalidad de definir tres componentes independientes, la iluminación ($l(f, g)$), el contraste ($c(f, g)$) y la estructura ($s(f, g)$) [115]:

$$l(f, g) = \frac{2\mu_f\mu_g + C_1}{\mu_f^2 + \mu_g^2 + C_1} \quad (2.22)$$

$$c(f, g) = \frac{2\sigma_f\sigma_g + C_2}{\sigma_f^2 + \sigma_g^2 + C_2} \quad (2.23)$$

$$s(f, g) = \frac{2\sigma_{fg} + C_3}{\sigma_f\sigma_g + C_3} \quad (2.24)$$

donde:

C_1 , C_2 y C_3 son constantes introducidas para evitar la inestabilidad de la métrica cuando los denominadores son muy bajos.

Finalmente el índice *SSIM* se define como:

$$SSIM(f, g) = l(f, g)^\alpha c(f, g)^\beta s(f, g)^\gamma \quad (2.25)$$

$\alpha > 0$, $\beta > 0$ y $\gamma > 0$ son parámetros usados para ajustar la importancia relativa de los tres componentes.

Generalmente el índice se aplica por ventanas y no a la imagen completa, lo que genera mejores resultados [118].

Como fue mostrado el problema del algoritmo *dark prior channel* es el tiempo de ejecución el cuál en su gran mayoría está dado por el proceso de refinamiento de la transmisión, es entonces cuando se propone la utilización inteligencia artificial y de operaciones de morfología matemática que tiene ventajas como el conservar la estructuras principales de la transmisión, eliminando aquellas discontinuidades que no ofrecen información útil para recuperar la imagen sin *hazing*.

Capítulo 3

Metodología

En este capítulo se describe el proceso que fue seguido en esta investigación.

Como se ha mencionado en la Introducción, las dos áreas de oportunidad en los métodos de dehazing es el ámbito de la eficiencia y calidad de restauración, por tanto sigue existiendo la necesidad de seguir investigando en esta área. Este trabajo tiene como objetivo principal la propuesta, el desarrollo y la evaluación de dos métodos de dehazing basados en el principio del canal oscuro utilizando dos enfoques distintos:

- Filtros de procesamiento de imágenes: al igual que la gran mayoría de los métodos del estado del arte de dehazing, buscando conseguir mayor exactitud y un mejor rendimiento de tiempo computacional,
- Inteligencia artificial, dado su potencial y gran desempeño que tiene en muchas áreas del procesamiento de señales.

Se describirá la metodología en las siguientes etapas:

- Primera etapa: Desarrollo del método basado en el DCP e inteligencia artificial (Perceptrón multicapa)
 - Planteamiento general del algoritmo propuesto
 - Imágenes utilizadas
 - Desarrollo del algoritmo propuesto
 - Algoritmos comparados durante experimentación
- Segunda etapa: Desarrollo del método basado en el DCP y en filtros (Morfología matemática y estadística)
 - Planteamiento general del algoritmo propuesto
 - Imágenes utilizadas
 - Desarrollo del algoritmo propuesto
 - Algoritmos comparados durante experimentación

3.1. Método basado en el DCP e Inteligencia Artificial (Perceptrón multicapa)

3.1.1. Planteamiento general del algoritmo propuesto

Los algoritmos de dehazing basados en el principio del canal oscuro utilizan dos etapas diferentes para calcular el mapa de transmisión [64]. En la primera etapa, una transmisión aproximada se estima utilizando parches cuadrados de un tamaño predeterminado. En la segunda etapa, el mapa de transmisión basta se mejora utilizando diferentes estrategias, como el soft-matting [7], el filtro bilateral [31], el filtro de la mediana [9], la media [58], filtro guiado [119], filtro Wiener [74], y graph cuts [61]. La principal desventaja de estas estrategias es la solución de compromiso entre la restauración precisa y el tiempo computacional.

Como se muestra en la Figura 3.1, el método propuesto tiene como motivación el aprender la función que le permite obtener directamente de la transmisión basada en el canal mínimo, la transmisión refinada.

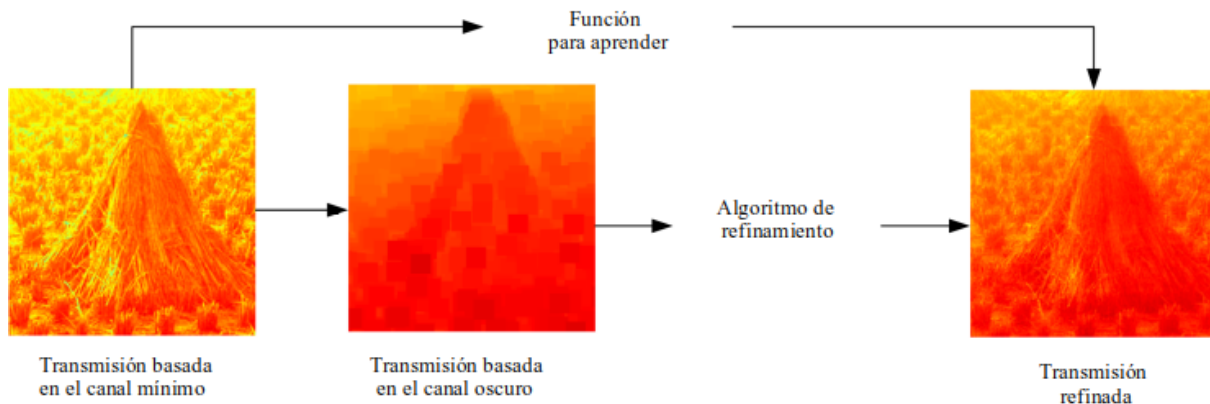


Figura 3.1: Diagrama donde se observa la función que el método debe aprender [Creación propia].

3.1.1.1. Tipo de red neuronal utilizada

Inspirados en el trabajo presentado en 2012: “Image denoising: Can plain neural networks compete with BM3D?” [120], donde se aborda el problema del ruido Gaussiano utilizando un Perceptrón Multicapa el cual es un tipo de red “plano” que compete con los métodos del estado del arte basados en otras técnicas, se diseñó una metodología y abordó el problema de dehazing. En el artículo antes mencionado, se encontraron los siguientes puntos importantes:

- Es posible aprender características locales de una imagen utilizando un perceptrón.

- El número de muestras adecuados para entrenar es del orden de 10^6 a 10^9 muestras (En el artículo para 10^9 muestras tardaron 1 mes usando una gpu Nvidia Tesla C2050).
- Los siguientes hiperparámetros de la red neuronal son un buena comienzo:
 - 1 o 2 capas ocultas
 - tamaño de ventanas alrededor de 17×17 pixeles
 - razón de aprendizaje (learning rate)=0.0001
 - método de minimización de error Gradiente Descendente Estocástico

3.1.2. Imágenes utilizadas

En el desarrollo de este método fue utilizada una base de datos de 126 imágenes RGB. La base de datos se dividió en dos subconjuntos: un juego de entrenamiento de 80 imágenes y un juego de prueba de 46 imágenes. El conjunto de imágenes de prueba consta de 30 imágenes del mundo real y 16 imágenes sintéticas adquiridas de Fattal et al. [3] y el Middlebury Stereo Dataset [121]. Los efectos de neblina sobre las imágenes sintéticas fueron simulados usando el modelo de dispersión presentado en la Ecuación (2.1). El valor de cada canal de A fue asignado aleatoriamente entre valores de 0,7 y 1, y β tiene valores aleatorios entre 0,5 y 1,5 como fue propuesto por Ren et al. [12].

3.1.3. Desarrollo del algoritmo propuesto

El método propuesto se basa en el mapa de transmisión t_{min} definido como

$$t_{min}(x, y) = 1 - \omega I^{min}(x, y), \quad (3.1)$$

donde el canal mínimo $I^{min}(x, y)$ se define como sigue [122]

$$I^{min}(x, y) = \min_{c \in (R, G, B)} \frac{I^c(x, y)}{A^c} \quad (3.2)$$

El canal mínimo t_{min} es equivalente al canal oscuro cuando el tamaño la ventana es $\Omega = 1$.

El canal mínimo $t_{min}(x, y)$ tiene una excelente resolución espacial, sin embargo, su resolución de profundidad calculada es baja porque omite la información sobre píxeles adyacentes. Desde el mapa de transmisión calculado $t_{min}(x, y)$, la aplicación de una red neuronal artificial MLP para estimar un mapa de transmisión $t'(x, y)$ se realiza de la siguiente manera:

$$t'(x, y) = MLP(t_{min}(x, y)) \quad (3.3)$$

La idea principal detrás del método propuesto es la estrategia para estimar el mapa de transmisión y la introducción de un paso adicional para mejorar la imagen de contraste. Para mejorar el contraste de la imagen recuperada, se modificó la luminancia al introducir el espacio de color L^*a^*b y una estrategia de estiramiento de contraste (CS) [123]. En la Fig. 3.2 se introduce el procedimiento realizado por el método propuesto.

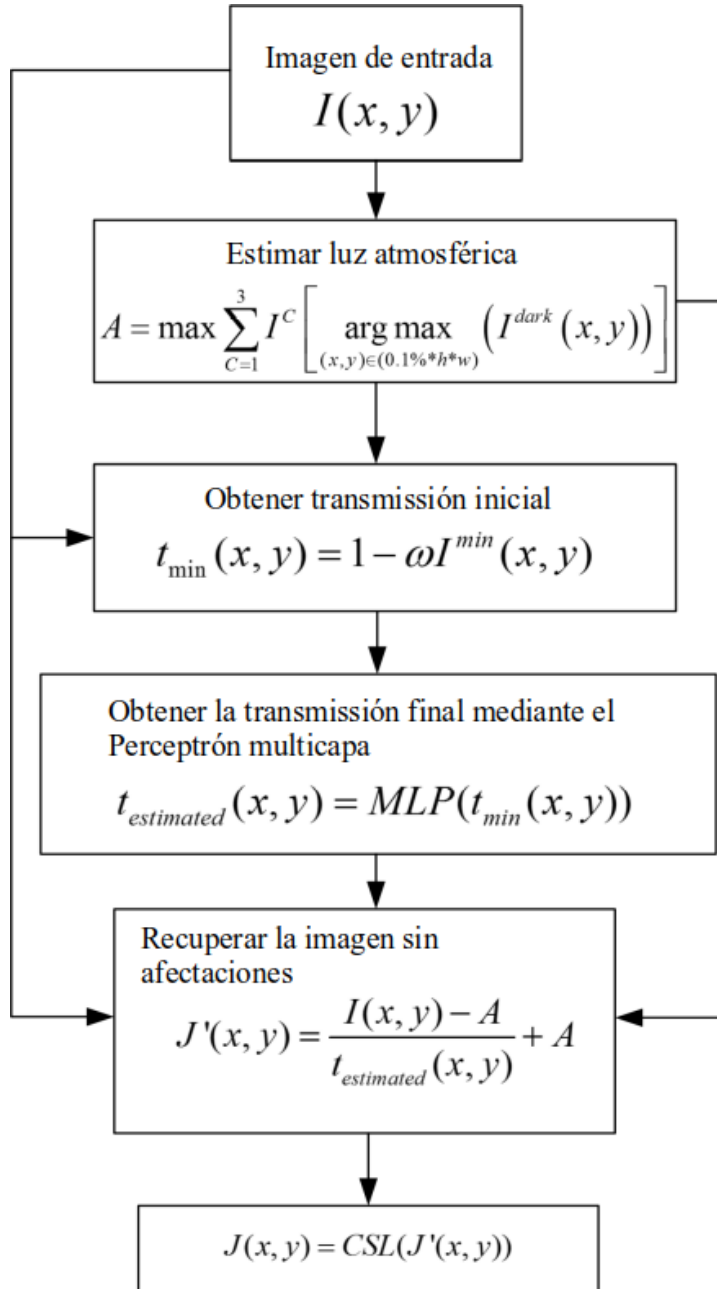


Figura 3.2: Diagrama de flujo del método propuesto [Creación propia].

3.1.4. Generación de datos *ground-truth* (datos referencia)

Dado que el MLP es una técnica supervisada, se requiere datos *ground-truth* para realizar el paso de entrenamiento. En el presente trabajo, los datos del *ground-truth* se calculan utilizando el algoritmo de *soft-matting* propuesto por Levin et al. [124], que ha demostrado ser adecuado para el problema de dehazing [7], sin embargo, su procesamiento computacional: tiempo y memoria son altos.

El procedimiento de *soft-matting* de la imagen se puede expresar de la siguiente manera

$$I = F\alpha + B(1 - \alpha), \quad (3.4)$$

donde B y F son la información de color de fondo y de primer plano, respectivamente, y α es la opacidad de un primer plano. En el trabajo de He et al. [7] se demostró la equivalencia entre el mapa α y el mapa de transmisión $\bar{t}(x, y)$. Luego, el $\bar{t}(x, y)$ óptimo se puede calcular resolviendo el sistema lineal disperso expresado en la siguiente ecuación

$$(L + \lambda U)\bar{t} = \lambda \hat{t}, \quad (3.5)$$

donde los parámetros utilizados fueron $\lambda = 10^{-4}$, \bar{t} es la transmisión óptima, \hat{t} es la transmisión calculada desde el canal oscuro, L es la matriz laplaciana y U es una matriz de identidad del mismo tamaño que L .

3.1.5. El proceso de entrenamiento

Para entrenar el Perceptrón de capas múltiples, se usó un conjunto de datos de 80 imágenes del mundo real de diferentes tamaños y características. De cada imagen, se generaron dos imágenes del mismo tamaño. El primero contiene el mapa de transmisión estimado $t_{min}(x, y)$ usando la Ecuación 3.1, y el segundo es el resultado de transmisión $\bar{t}(x, y)$, que es obtenido aplicando el método de matting suave a $t_{min}(x, y)$.

El paso de entrenamiento de un MLP requiere dos vectores de muestras: los datos de entrada y los vectores objetivo. A partir de la imágenes utilizadas se generaron 2,880,955 muestras. En este trabajo, cada muestra se adquirió desde una ventana cuadrada de tamaño l centrada en las posiciones (x, y) donde la longitud de cada muestra es $l \times l$. El vector de entrada se obtuvo de $t_{min}(x, y)$ y el vector objetivo de $\bar{t}(x, y)$. La configuración para realizar la etapa de entrenamiento se ilustra en la Fig. 3.3.

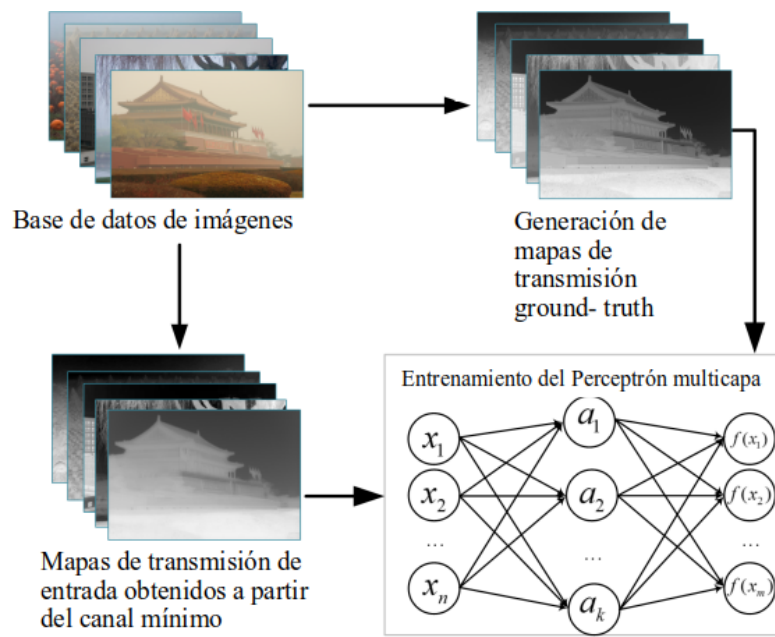


Figura 3.3: Proceso de entrenamiento para el MLP basado en mapas de transmisión [Creación propia].

3.1.6. Aplicación del MLP

Como se muestra en la Fig. 3.16, para calcular el mapa de transmisión $t'(x, y)$ usando el MLP entrenado, se genera un vector de entrada a partir de ventanas cuadradas de $t_{min}(x, y)$. Cada ventana cuadrada bidimensional de tamaño s se convierte en una señal unidimensional de tamaño $s \times s$. El intervalo de cada muestreo en la imagen se expresa mediante la variable δ . Si $\delta = s$ el muestreo no tiene intersección en las posiciones de píxeles, y si $\delta = 1$ el muestreo se realiza en cada píxel. El valor de cada píxel en el mapa de transmisión $t'(x, y)$ es el valor mínimo de la superposición de ventanas.

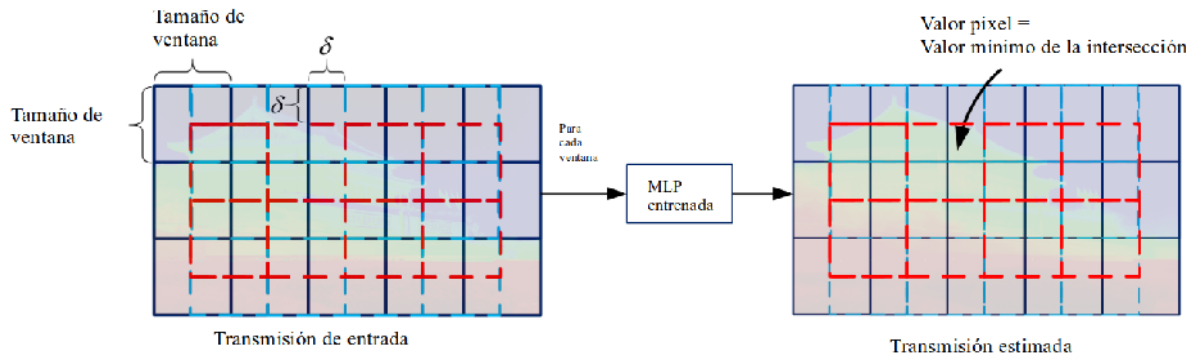


Figura 3.4: Proceso para estimar el mapa de transmisión utilizando el MLP [Creación propia].

En la Fig. 3.5 se presenta un ejemplo del algoritmo propuesto en cuatro imágenes del mundo real y los resultados de la aplicación del método propuesto, junto con la entrada $t_{min}(x, y)$ y la salida $t'(x, y)$ se muestran los mapas de transmisión de la MLP. Los valores de los parámetros son $\delta = 16$ y $s = 8$.




Figura 3.5: Ejemplos del procesamiento realizado por el método propuesto: (a) imágenes de entrada $I(x, y)$, (b) transmisión inicial $t_{min}(x, y)$, (c) transmisión final $t'(x, y)$, (d) imágenes recuperadas $J(x, y)$ [Creación propia].

3.1.7. Ajuste de parámetros

Para obtener el mejor rendimiento posible del método propuesto, se realizaron varias pruebas con diferentes configuraciones de MLP utilizando el conjunto de entrenamiento de 80 imágenes lo cual generó 2,880,955 muestras. En Fig 3.6 se muestran los resultados de las configuraciones más significativas en términos de la métrica MSE. El mejor rendimiento de MLP de una sola capa es presentado por la configuración 256 – 1024, que corresponde al tamaño de una ventana $s = 16$. La arquitectura 256 – 1024 indica que tenemos una capa de entrada de 256 neuronas, 1024 en una capa oculta y 256 de salida. Cada una de las pruebas se realizaron utilizando una tarjeta nvidia Tesla C2075 de 6 GB de RAM con 448 núcleos.

Los mejores hiperparámetros encontrados fueron:

- 1 capa oculta
- tamaño de ventanas de 16×16 pixeles
- razón de aprendizaje (learning rate)=0.0001
- método de minimización de error: Gradiente Descendente Estocástico

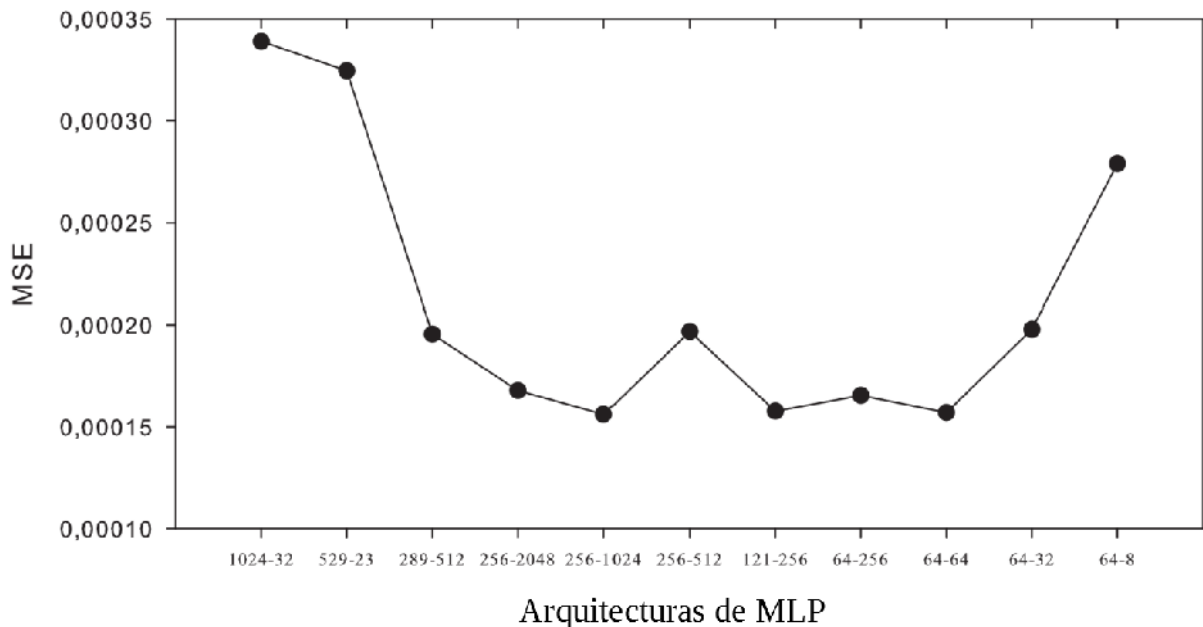


Figura 3.6: Relación entre la arquitectura MLP y el rendimiento utilizando el conjunto de imágenes de formación [Creación propia].

Una vez determinado el valor s , para obtener el valor óptimo de δ (valor de deslizamiento de la ventana), se probó el método sobre un conjunto de entrenamiento

variando el valor δ en el rango $[1, \dots, 16]$. Se consideraron tres aspectos para elegir el valor δ : un análisis cuantitativo utilizando el índice SSIM (Fig. 3.7) (a), un análisis de procesamiento de tiempo (Fig. 3.7) (b)), y un análisis cualitativo (Fig. 3.8). Basado en los resultados obtenidos, el mejor valor fue $\delta = 8$, representando el SSIM más alto y el tiempo de procesamiento más bajo.

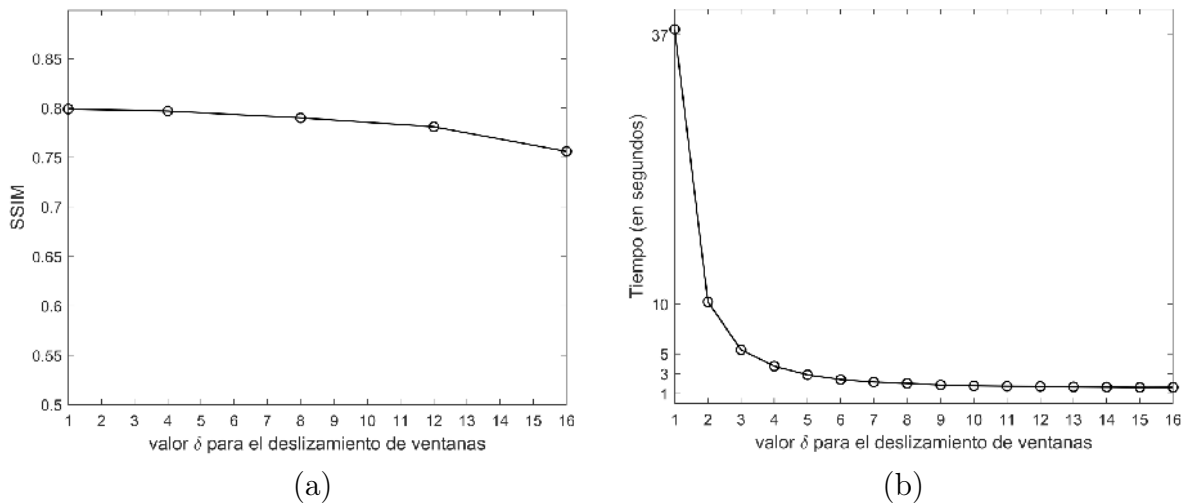


Figura 3.7: Relación entre las ventanas δ utilizadas en la aplicación de la MLP en la imagen, (a) índice SSIM, (b) procesamiento de tiempo [Creación propia].




Figura 3.8: Transmisiones y resultados generados usando diferentes ventanas deslizantes de δ : (a) $\delta = 1$, (b) $\delta = 2$, (c) $\delta = 4$, (d) $\delta = 8$, (e) $\delta = 12$, (f) $\delta = 16$ [Creación propia].

3.1.8. Algoritmos utilizados durante experimentación

El método propuesto se comparó con nueve métodos de dehazing de última generación:

- Tarel et al. [6]: utiliza un filtro de mediana y un filtro para preservar los bordes y las esquinas
- He et al. method [7]: emplea el DCP y un proceso de soft-matting
- Pang et al. method [8]: usa el DCP y el filtro guiado
- Gibson et al. [9]: propone una variante de DCP que sustituye al operador mínimo por el operador de la mediana
- Zhu et al. [10]: utiliza un principio de atenuación lineal del color basada en la diferencia entre la saturación y el brillo de los píxeles.
- Berman et al. [11]: usa un algoritmo orientado a píxeles, donde los píxeles se agrupan en el espacio RGB para estimar una línea de *haze* utilizada para recuperar la imagen libre de *haze*.
- Ren et al. [12]: usa redes neuronales convolucionales para estimar la profundidad
- Cai et al. [13]: usa aprendizaje profundo
- Li et al. [54]: usa redes neuronales convolucionales usando los tres canales de la imagen (RGB).

Para el método propuesto, los parámetros son: $\delta = 8$, tamaño de la ventana $s = 16$ y $w = 0,7$.

3.2. Método basado en el DCP, Morfología matemática y estadística

3.2.1. Planteamiento general del algoritmo propuesto

El método propuesto, nombrado como: Canal Oscuro Estadístico Multidireccional (SMLDC, por sus siglas en inglés), se basa en dos conceptos principales: el cálculo de n mapas lineales multidireccionales del canal oscuro y operaciones estadísticas. Cada dirección del SMLDC genera un mapa de canal oscuro orientado, procesando la escena de la imagen con múltiples líneas, donde cada una de ellas tiene distintas orientaciones de forma análoga a la transformada de Radón [125]. Sin embargo, en lugar de calcular la proyección de la línea, se utilizan operaciones estadísticas con cada mapa. Este método elimina la necesidad del proceso de refinamiento comúnmente utilizado en la literatura cuando se utiliza el principio del canal oscuro para eliminar los artefactos generados (ver Figura 4.2), lo que permite aumentar la precisión de la restauración y utilizar menos tiempo de procesamiento.

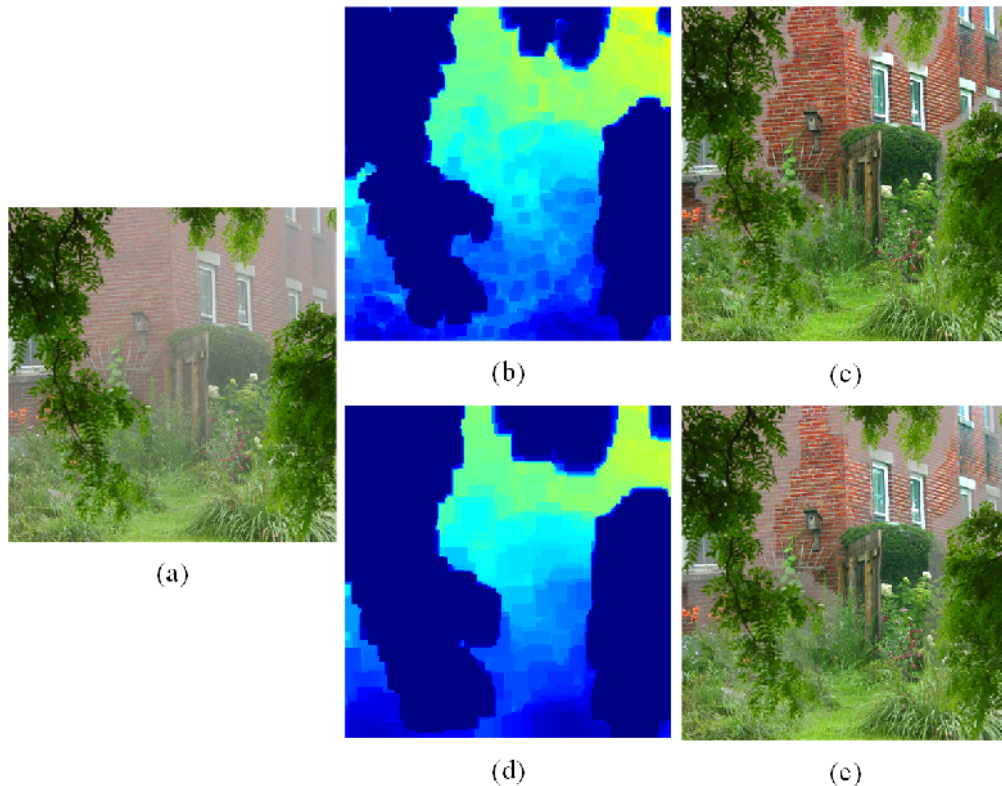


Figura 3.9: Ejemplo de una imagen con neblina, el DCP original y artefactos generados en $J(x, y)$. (a) Imagen de entrada $I(x, y)$, (b) canal oscuro usando $\Omega = (15, 15)$, (c) estimación de $J(x, y)$ desde el canal oscuro (b), (d) mapa del canal oscuro usando $\Omega = (35, 35)$, (e) estimación de $J(x, y)$ desde el canal oscuro (d) [Creación propia].

3.2.2. Imágenes utilizadas

Se utilizaron dos conjuntos de datos comúnmente utilizados en la literatura para obtener una comparación de rendimiento precisa y fiable:

- Diez imágenes reales obtenidas de [3]. Este conjunto de datos, comúnmente empleado en la literatura, se utilizó para realizar un análisis cualitativo, Figura 3.10.
- El conjunto de datos utilizado para aplicar la evaluación cuantitativa fue el RESIDE-HSTS [65], que contiene 10 imágenes sintéticas creadas con valores aleatorios y sus correspondientes imágenes ground-truth (de referencia), Figura 3.11.



Figura 3.10: Imágenes del mundo real utilizadas [Creación propia].



Figura 3.11: Imágenes sintéticas utilizadas. (a) Imágenes *ground-truth* (de referencia),
 (b) Imágenes con neblina [Creación propia].

3.2.3. Desarrollo del algoritmo propuesto

A continuación se explica con más detalle el proceso del algoritmo propuesto.

En la etapa inicial del método propuesto, la ventana cuadrada Ω utilizada para calcular el canal oscuro (presentado en la Ecuación (2.4)) es reemplazado por n líneas de tamaño $(1 \times k)$. Las líneas se distribuyen uniformemente entre 0° y 180° , donde el ángulo de las n líneas está dado por $i\alpha$, $0 \leq i \leq n-1$ y $\alpha = 180^\circ/n$, como se ilustra en la Figura 4.1.

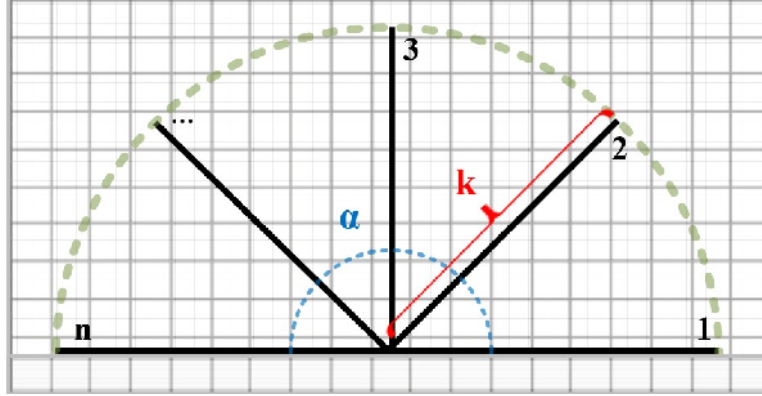


Figura 3.12: Diagrama de las formas de las ventanas (líneas), donde n es el número de líneas orientadas, k es la longitud de la línea y α es el ángulo entre líneas, que comienza en el eje horizontal de la ubicación del píxel central (x, y) [Creación propia].

En consecuencia, se propone una adaptación a la Ecuación (2.4) para calcular los mapas del canal oscuro orientado $I_{(k,i\alpha)}^{dark}$, con ángulo $i\alpha$ para un valor fijo de tamaño k :

$$I_{(k,i\alpha)}^{dark}(x, y) = \min_{c \in \{R, G, B\}} \left(\min_{z \in \Omega_{(k,i\alpha)}(x, y)} \frac{I^c(z)}{A^c} \right). \quad (3.6)$$

De hecho, cada uno de los mapas de canal oscuro generado tiene información diferente y complementaria para cada dirección, lo cual es especialmente útil para recuperar la forma del borde (equivalente a un proceso de erosión morfológica con un elemento estructurante lineal). Por ejemplo, la Figura 3.13 presenta el cálculo multidireccional del canal oscuro de la imagen presentada en la Figura 4.2 (a), con $k = 35$ y $n = 4$ líneas con ángulos de 0° , 45° , 90° y 135° , resultando en cuatro imágenes de canal oscuro con diferentes orientaciones. En la Figura 3.13, los detalles del contorno entre las áreas más oscuras (más cerca de la cámara) y las áreas más brillantes (más lejos de la cámara) pueden preservarse mejor que usando sólo cuadrados.




Figura 3.13: Ejemplo de mapas multidireccionales de canal oscuro de la imagen mostrada en la Figura 4.2 con cuatro orientaciones. (a) $I_{(35,0^\circ)}^{dark}(x, y)$, (b) $I_{(35,45^\circ)}^{dark}(x, y)$, (c) $I_{(35,90^\circ)}^{dark}(x, y)$, (d) $I_{(35,135^\circ)}^{dark}(x, y)$ [Creación propia].

En la segunda etapa, se calcula sobre los mapas de canal oscuro previamente estimados, el valor máximo de cada canal oscuro orientado (lo cual es equivalente a la apertura morfológica); y es designado aquí como el canal gris $I_{(k,i\alpha)}^{grey}(x, y)$, como sigue:

$$I_{(k,i\alpha)}^{grey}(x, y) = \max_{z \in \Omega_{(k,i\alpha)}(x, y)} I^{dark}(z)_{(k,i\alpha)}. \quad (3.7)$$

El canal gris es útil para abrir un espacio entre las regiones más cercanas a la cámara, generando una mejor aproximación de las zonas de contorno. La Figura 3.14 presenta el canal gris calculado a partir de los mapas mostrados en la Figura 3.13 con los mismos ángulos que en la figura anterior: 0° , 45° , 90° , 135° . La Figura 3.14 (c) presenta dos zonas máximas aisladas (una línea vertical roja en el centro superior y otra en la esquina superior izquierda) correspondientes al contorno de la ventana blanca que se muestra en la Figura 4.2 (a).

Cada $I_{(k,i\alpha)}^{grey}(x, y)$ tiene información sobre la profundidad correspondiente a $I(x, y)$. Sin embargo, dependiendo de su dirección $i\alpha$, podría tener valores diferentes. Para analizar la conexión entre los mapas grises, se implementa una tercera etapa basada en un enfoque estadístico pixel a pixel. Cada resultado del canal gris $I_{(k,i\alpha)}^{grey}(x, y)$ se concatena en n mapas: $M_{1,\dots,n}(x, y)$, donde n son las diferentes líneas con orientación $i\alpha$, esto puede verse en la Figura 3.15.




Figura 3.14: Ejemplo de los mapas multidireccionales de canal gris con 4 orientaciones: tenga en cuenta que los contornos son más nítidos que en la figura anterior. (a) $I_{(35,0^\circ)}^{grey}(x, y)$, (b) $I_{(35,45^\circ)}^{grey}(x, y)$, (c) $I_{(35,90^\circ)}^{grey}(x, y)$, (d) $I_{(35,135^\circ)}^{grey}(x, y)$ [Creación propia].

Utilizando $M_{1,\dots,n}(x, y)$, es posible calcular la desviación estándar en píxeles para obtener información sobre el comportamiento de los valores a lo largo de los bordes y las fronteras. El mapa de desviación estándar $M_\sigma(x, y)$ es definido como

$$M_\sigma(x, y) = \sqrt{\frac{1}{n} \sum_{i=1}^n (M(x, y)_i - \bar{M}(x, y))^2}, \quad (3.8)$$

donde $M(x, y)_i$ es el i -ésimo mapa de canal gris en (x, y) y $\bar{M}(x, y)$ es el promedio de los valores pixel a pixel del canal gris de n en (x, y) .

$$\bar{M}(x, y) = \frac{1}{n} \sum_{i=1}^n M(x, y)_i. \quad (3.9)$$

La Figura 3.15 muestra n mapas concatenados en la izquierda y el mapa de desviación estándar a la derecha. Nótese que los valores de desviación estándar son más altos a lo largo de las fronteras de regiones adyacente que tienen diferentes profundidades.

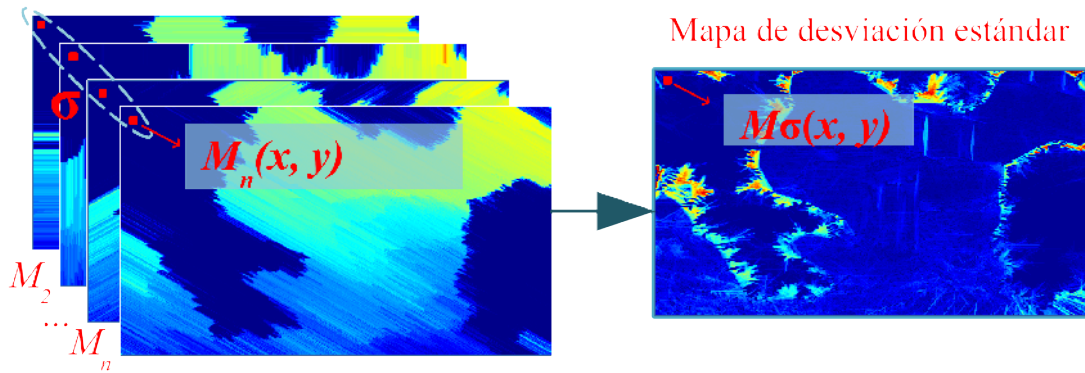


Figura 3.15: Ejemplo de concatenación de canales grises $M(x, y)_n$ (izquierda), y ejemplo de cálculo del mapa de desviación estándar $M_\sigma(x, y)$ (derecha) usando la imagen mostrada en la Figura 4.2 (a) [Creación propia].

A modo de ilustración, la Figura 3.16 presenta el mapa de desviación estándar fusionado con la imagen original. En la Figura 3.16 (b) puede observarse que los valores máximos de desviación estándar están presentes en las regiones frontera. Por lo tanto, $M_\sigma(x, y)$ proporciona un criterio para segmentar las regiones en regiones frontera y homogéneas.




Figura 3.16: Mapa de desviación estándar $M_\sigma(x, y)$ calculado a partir de la Figura 4.2 (a), (b) Mapa de desviación estándar $M_\sigma(x, y)$ mezclado con la imagen original [Creación propia].

Se observó que se podía lograr un mejor rendimiento utilizando $\bar{M}(x, y)$ en las regiones homogéneas (véase la Figura 3.17 (c)). En contraste, el valor máximo de $M(x, y)_n$: $M_{\text{máx}}(x, y)$ tuvo un mejor desempeño en las regiones frontera (ver Figura 3.17 (b)), porque los halos en las fronteras (Figura 4.2) son el resultado de una subestimación de los valores de las fronteras cuando se utiliza el DCP original [15]. La operación $M_{\text{máx}}(x, y)$, definida a continuación, reduce estos artefactos:

$$M_{\text{m}\acute{\text{a}}\text{x}}(x, y) = \text{m}\acute{\text{a}}\text{x}(M_i(x, y)), 0 \leq i \leq n. \quad (3.10)$$

La siguiente etapa de este m\acute{e}todo consiste en una combinaci3n lineal de $\bar{M}(x, y)$ y $M_{\text{m}\acute{\text{a}}\text{x}}(x, y)$ utilizando $M_{\sigma}(x, y)$ como criterio (ver Figura 3.17 (d)) para lograr un mejor desempe\~{n}o en cada regi3n mediante la ponderaci3n de cada contribuci3n; esta combinaci3n lineal se conoce como M_{dc} , y se define de la siguiente manera:

$$M_{dc}(x, y) = \bar{M}(x, y) \left(1 - \frac{M_{\sigma}(x, y)}{\text{m}\acute{\text{a}}\text{x}(M_{\sigma})} \right) + M_{\text{m}\acute{\text{a}}\text{x}}(x, y) \left(\frac{M_{\sigma}(x, y)}{\text{m}\acute{\text{a}}\text{x}(M_{\sigma})} \right) \quad (3.11)$$




Figura 3.17: Mapas de canal oscuro *ground-truth* y tres mapas de canal oscuro calculados a partir de la Figura 4.2, cada uno con zoom en dos regiones: no homog\~{e}nea (abajo a la izquierda) y homog\~{e}nea (abajo a la derecha), (a) Mapa de canal oscuro *ground-truth*, (b) $M_{\text{m}\acute{\text{a}}\text{x}}(x, y)$ tienen un mejor rendimiento en las regiones no homog\~{e}neas, (c) $\bar{M}(x, y)$ logra un mejor rendimiento en \c{a}reas homog\~{e}neas, (d) M_{dc} , combinaci3n de ambos m\acute{e}todos utilizando la Ecuaci3n (3.11), la cual reduce los artefactos en las regiones homog\~{e}neas, y el contorno est\c{a} bien definido [Creaci3n propia].

Adicionalmente, se observó un fenómeno estadístico: en la mayoría de las imágenes I donde $\max(M_{dc}) > 0,7$ (generalmente imágenes con regiones del cielo), los resultados aparecen saturados. Por lo tanto, se propone un proceso adicional en el que si $\max(M_{dc}) > 0,7$, entonces los valores de los píxeles donde $M_{dc}(x, y) > 0,5$ son sustituidos por su inverso, es decir, $M_{dc}(x, y) = 1 - M_{dc}(x, y)$. Esta corrección se muestra en la Figura 3.18. El valor de transmisión $t_{dc}(x, y)$ se calcula utilizando $M_{dc}(x, y)$, como sigue:

$$t_{dc}(x, y) = 1 - \omega M_{dc}(x, y), \quad (3.12)$$




Figura 3.18: Ejemplo del mejoramiento de M_{dc} . (a) Imagen de entrada donde $\max(M_{dc}) > 0,7$, (b) M_{dc} original, (c) Imagen restaurada usando (b), (d) M_{dc} mejorado, (e) Imagen restaurada usando (d), (f) Imagen de entrada donde $\max(M_{dc}) < 0,7$, (g) M_{dc} original, (h) Imagen restaurada usando (b), (i) M_{dc} mejorado, (j) Imagen restaurada usando (i) [Creación propia].

Luego, A se calcula usando la definición mostrada en la Subsección 2.6.0.1 y finalmente se obtiene la imagen restaurada $J'(x, y)$ usando la Ecuación (2.3). A continuación se muestra el pseudocódigo y la Figura 3.19 los cuales resumen e ilustran el método propuesto.

Algoritmo 1 Método propuesto

```

1: procedure SMLDC( $I, n, k, \omega$ )
2:    $A = \text{estimateAirLight}(I)$  ▷ usando método mostrado en subsección 2.6.0.1
3:   for  $i = 0 : n - 1$  do
4:      $\alpha = \lfloor 180/n \rfloor$ 
5:      $M_{i+1} = I_{(k, i \times \alpha)}^{grey}$  ▷ usando ecuación 3.7
6:   end for
7:    $M_\sigma = \text{Compute\_}M_\sigma(M)$  ▷ usando ecuación 3.8
8:    $\bar{M} = \text{Compute\_}\bar{M}(M)$  ▷ usando ecuación 3.9
9:    $M_{max} = \text{Compute\_}M_{max}(M)$  ▷ usando ecuación 3.10
10:   $M_{dc} = \text{Compute\_}M_{dc}(M, M_{max}, M_\sigma)$  ▷ usando ecuación 3.11
11:  if  $\max(M_{dc}) > 0,7$  then ▷ mejorando  $M_{dc}$ 
12:    for  $x, y \in M_{dc}$  do
13:      if  $M_{dc}(x, y) > 0,5$  then
14:         $M_{dc}(x, y) = 1 - M_{dc}(x, y)$ 
15:      end if
16:    end for
17:  end if
18:   $t = \text{Compute\_transmission\_}(M_{dc});$  ▷ usando ecuación 3.12
19:   $J' = \text{Recover\_Image}(I, t, A);$  ▷ usando ecuación 2.3
20:  return  $J'$ ; ▷ The recovered image
21: end procedure

```

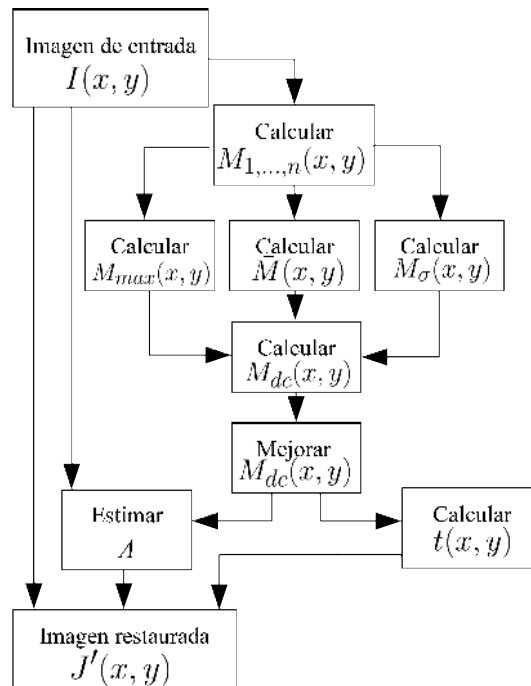


Figura 3.19: Diagrama de flujo del método propuesto SMLDC [Creación propia].

3.2.4. Algoritmos utilizados durante experimentación

Para comparar el rendimiento del algoritmo propuesto, se realizó una comparación con cuatro algoritmos del estado del arte:

- He et al. method [7]: emplea el DCP y un proceso de soft-matting
- Berman et al. [11]: usa un algoritmo orientado a píxeles, donde los píxeles se agrupan en el espacio RGB para estimar una línea de *haze* utilizada para recuperar la imagen libre de *haze*.
- Galdran et al. [16]: la imagen nebulosa original es primero subexpuesta artificialmente por medio de una secuencia de operaciones de corrección gamma. El conjunto resultante de imágenes expuestas múltiples se fusiona en un resultado libre de neblina a través de un esquema de mezcla Laplaciana multi-escala.

Capítulo 4

Prueba y resultados

4.1. Análisis del método basado en el DCP e Inteligencia Artificial (Perceptrón multicapa)

La evaluación del rendimiento del método propuesto se evaluó utilizando una base de datos de 126 imágenes RGB. La base de datos se dividió en dos subconjuntos: un conjunto de capacitación de 80 imágenes y un conjunto de prueba de 46 imágenes. El conjunto de prueba de imágenes consta de 30 imágenes del mundo real y 16 imágenes sintéticas adquiridas de Fattal et al. [3] y el conjunto de datos estéreo de Middlebury [121]. Los efectos de haze en las imágenes sintéticas se simularon utilizando el modelo de dispersión presentado en la Ecuación (2.1). El valor de cada canal de A se asignó al azar entre los valores de 0,7 y 1, y β tiene valores aleatorios entre 0,5 y 1,5, tal como lo propusieron Ren et al. [12]. Además, los experimentos computacionales se realizaron utilizando el software *Matlab*, versión *R2016a* en una computadora con Intel Core i5-2400 a 3.10 GHz y 12 GB de memoria RAM.

4.1.1. Análisis del rendimiento

El método propuesto se comparó con nueve métodos de dehazing de última generación: Tarel et al. [6], He et al. method [7], Pang et al. method [8], Gibson et al. [9], Zhu et al. [10], Berman et al., Ren et al. [12], Cai et al. [13], y Li et al. [14]. Los parámetros utilizados en cada método son los propuestos por cada autor. Para el método propuesto, los parámetros son: $\delta = 8$, tamaño de la ventana $s = 16$ y $w = 0,7$.

Para realizar un análisis visual, en la Fig. 4.1 se presentan los resultados de dehazing de los métodos propuestos y comparativos sobre un subconjunto de imágenes del mundo real. En este subconjunto, se obtiene un mayor contraste junto con intensidades más naturales mediante el método propuesto. Además, la Fig. 4.2 muestra los resultados utilizando imágenes sintéticas.

Para evaluar el nivel de restauración, la Tabla 4.1 y la Tabla 4.2 presentan los valores del índice PSNR y SSIM, respectivamente. El método propuesto logra el valor medio más alto de PSNR, y el promedio más alto en términos del índice SSIM. Finalmente,

la Fig. 4.3 presenta la comparación del tiempo de procesamiento, donde el método propuesto obtiene el mejor rendimiento.

Tabla 4.1: Análisis comparativo utilizando la proporción máxima de señal a ruido (PSNR).

Imagen	Tarel et al [6]	He et al [7]	Pang et al [8]	Gibson et al [9]	Zhu et al [10]	Berman et al [11]	Ren et al [12]	Cai et al [13]	Li et al [14]	Proposed
Aloe	17,91	14,20	14,22	15,46	18,42	16,05	17,99	18,14	16,60	16,08
Baby1	19,96	13,98	14,23	22,81	23,09	17,64	23,09	22,01	25,98	17,69
Books	16,03	12,71	13,37	15,43	22,36	13,31	20,07	21,03	19,07	23,03
Bowling1	19,34	11,60	11,71	12,88	23,29	14,06	20,62	27,20	25,69	13,00
Dolls1	13,24	14,93	14,98	15,22	15,94	15,70	17,06	14,37	15,20	15,23
Moebius1	18,97	15,04	15,28	19,86	24,44	19,18	20,64	24,28	21,22	23,49
Monopoly	17,41	10,48	10,76	13,39	21,52	16,43	18,93	19,99	19,30	19,26
Reindeer	14,77	18,32	18,21	19,39	16,20	18,60	16,82	14,11	18,11	16,82
Bikes1	8,29	18,49	18,31	15,47	12,59	26,08	14,36	14,38	14,22	21,77
Church	11,76	12,51	12,69	14,00	13,77	15,96	15,01	15,24	11,03	17,04
Cones	19,38	20,16	19,45	19,03	19,98	19,77	17,60	19,46	21,43	17,50
Couch	16,12	18,44	18,60	17,41	18,89	18,47	19,24	17,89	17,02	19,00
Flower2	16,88	17,59	17,99	18,62	21,01	11,92	13,27	20,15	14,55	22,24
Mansion	16,45	19,80	19,75	16,98	18,09	17,42	17,86	17,93	15,44	22,35
Roofs2	11,58	22,86	22,73	17,51	15,42	21,00	13,95	13,70	15,98	20,77
Trees2	10,69	17,84	17,70	16,60	13,38	20,79	14,29	12,24	15,15	15,12
Promedio	15,55	16,19	16,25	16,88	18,65	17,65	17,55	18,26	17,87	18,77

Tabla 4.2: Análisis comparativo utilizando el índice de similitud estructural (SSIM).

Imagen	Tarel et al [6]	He et al [7]	Pang et al [8]	Gibson et al [9]	Zhu et al [10]	Berman et al [11]	Ren et al [12]	Cai et al [13]	Li et al [14]	Proposed
Aloe	0,9028	0,7855	0,7976	0,8381	0,9549	0,8250	0,9473	0,9458	0,9220	0,8180
Baby1	0,9032	0,7763	0,7961	0,9403	0,9706	0,8563	0,9596	0,9655	0,9729	0,8317
Books	0,8403	0,7378	0,7715	0,8237	0,9561	0,7705	0,9254	0,9439	0,9357	0,9219
Bowling1	0,9255	0,6760	0,6902	0,7305	0,9764	0,7786	0,9496	0,9844	0,9814	0,7698
Dolls1	0,7354	0,7912	0,7737	0,8317	0,8119	0,8343	0,8413	0,7958	0,8136	0,8268
Moebius1	0,8665	0,7933	0,7940	0,9080	0,9593	0,8731	0,9322	0,9629	0,9259	0,9159
Monopoly	0,8929	0,7197	0,7308	0,8486	0,9763	0,9137	0,9562	0,9647	0,9605	0,9407
Reindeer	0,6842	0,7966	0,7805	0,8033	0,7409	0,7779	0,7632	0,7102	0,7814	0,7753
Bikes1	0,4939	0,7785	0,7560	0,6436	0,5143	0,8479	0,5963	0,5469	0,5009	0,7953
Church	0,7627	0,7692	0,7682	0,8532	0,8218	0,8832	0,8544	0,8198	0,6108	0,8889
Cones	0,8530	0,9090	0,8904	0,9186	0,9274	0,9162	0,8186	0,9247	0,8995	0,8776
Couch	0,7950	0,8450	0,8356	0,8183	0,8293	0,8620	0,8658	0,8217	0,8169	0,8245
Flower2	0,8023	0,8431	0,8591	0,8640	0,9630	0,6652	0,5919	0,9105	0,7814	0,9086
Mansion	0,8434	0,8958	0,8917	0,8424	0,8769	0,8697	0,8730	0,8362	0,6907	0,9140
Roofs2	0,6552	0,8445	0,8424	0,7806	0,6619	0,8602	0,6296	0,6156	0,6601	0,8335
Trees2	0,5462	0,6833	0,6710	0,6758	0,5800	0,7387	0,6122	0,5492	0,5877	0,6833
Average	0,7814	0,7903	0,7906	0,8201	0,8451	0,8295	0,8198	0,8311	0,8026	0,8454



Figura 4.1: Comparación de los resultados obtenidos en imágenes naturales de exteriores utilizando los diez métodos comparados: (a) imágenes de entrada, (b) Tarel et al. [6], (c) He et al. [7], (d) Pang et al. [8], (e) Gibson et al. [9], (f) Zhu et al. [10], (g) Berman et al. [11], (h) Ren et al. [12], (i) Cai et al. [13], (j) Li et al. [14], (k) Método propuesto [Creación propia].



Figura 4.2: Comparación de los resultados obtenidos de las imágenes sintéticas por los diez métodos: (a) imágenes originales, (b) imágenes con neblina simulada, (c) Tarel et al. [6], (d) He et al. [7], (e) Pang et al. [8], (f) Gibson et al. [9], (g) Zhu et al. [10], (h) Berman et al. [11], (i) Ren et al. [12], (j) Cai et al. [13], (k) Li et al. [14], (l) Método propuesto [Creación propia].

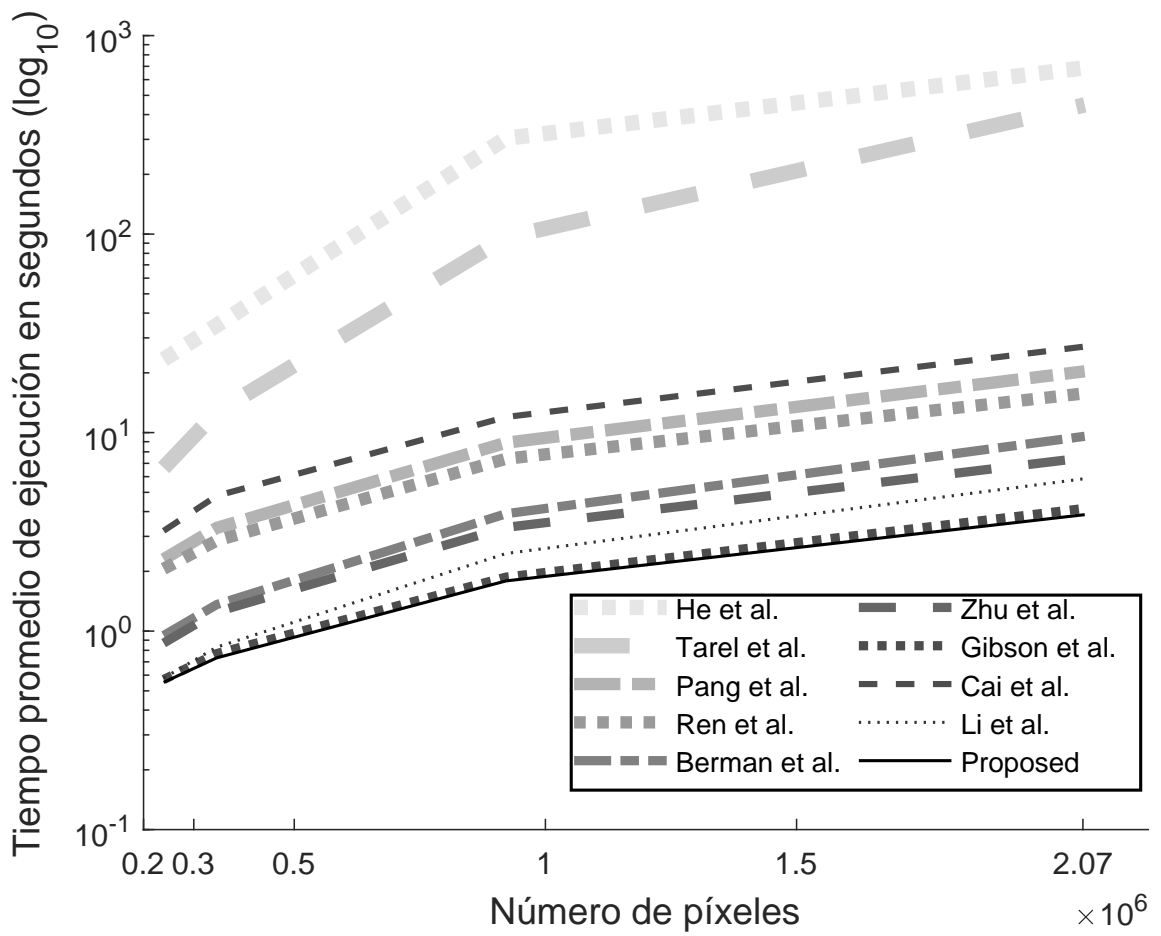


Figura 4.3: Análisis del rendimiento en términos de procesamiento de tiempo computacional [Creación propia].

4.2. Análisis del método basado en el DCP Multidireccional Estadístico

Para definir los parámetros óptimos para el método propuesto, k (longitud de la línea) y n (número de líneas), se crearon 23 imágenes con neblina sintéticas aplicando el modelo de dispersión (Ecuación 2.1) con valores aleatorios de t y A , a las imágenes adquiridas a partir del conjunto de datos Middlebury [126]. Fig. 4.4 (a) presenta el índice SSIM con valores diferentes de k ; el valor máximo (el área más blanca) indica un mejor rendimiento. El tiempo de procesamiento se muestra en la Figura 4.4. (b), donde puede observarse que si aumentan k o n , entonces también aumenta el tiempo de procesamiento. Los parámetros óptimos (mejor SSIM con el menor tiempo de procesamiento) son $k = 8$ y $n = 37$. La Figura 4.4 (c) muestra la fusión de la mejor región SSIM y los valores más bajos de k y n para encontrar el tiempo de procesamiento más rápido.




Figura 4.4: Cálculo de los parámetros óptimos ($k = 8$, $n = 37$) para una longitud de línea diferente k y número de líneas n . (a) Índice SSIM para diferentes k y n . (b) Tiempo de procesamiento para diferentes configuraciones de k y n . (c) Elección de los mejores valores del índice SSIM y tiempo de procesamiento [Creación propia].

4.2.1. Análisis del rendimiento

El análisis cualitativo se muestra en la Figura 4.5. El primer conjunto presenta diez imágenes con neblina del mundo real. La columna (a), presenta las imágenes con neblina, mientras que las columnas restantes proporcionan los resultados de diferentes métodos de deshaz: (b) He et al, (c) Berman et al, (d) Ren et al, (e) Galdran et al y (f) el método propuesto. Obsérvese que el método propuesto arroja un resultado similar al de los otros métodos; sin embargo, (b) He et al. (c) Berman et al. y (d) Ren et al. muestran colores no realistas, mientras que (e) Galdran et al. muestran una mejor respuesta en regiones más cercanas (más cercanas a la cámara) que (f) el método

propuesto. Sin embargo, en la segunda imagen, donde se puede ver una gran neblina, el método propuesto exhibe una calidad de restauración no afectada.

La figura 4.6 muestra una matriz de 10 imágenes sintéticas (en el mismo orden que en la Tabla 4.3). La columna (a) muestra la imagen original sin neblina. Las columnas siguientes muestran los resultados de: (b) He et al., (c) Berman et al., (d) Ren et al., (e) Galdran et al. y (f) el método propuesto.

Los colores en las imágenes originales y en las obtenidas por el método propuesto son muy similares; sin embargo, el método propuesto reconstruye el cielo y las nubes con colores reales, ya que presenta menos artefactos en el cálculo del mapa de canal oscuro. Estos resultados cualitativos se han correlacionado con los resultados cuantitativos, que se presentan a continuación.

La tabla 4.3 compara el rendimiento de los diferentes métodos de deshazing utilizando el índice SSIM. Tenga en cuenta que el método propuesto tiene un índice SSIM más alto (mejor) en 6 de cada 10 imágenes, mientras que el método propuesto no presenta un bajo rendimiento en ninguna imagen. El índice SSIM promedio para el método propuesto es de 0.84, que es aproximadamente un 5% más alto que el valor del índice SSIM obtenido de cualquier otro método en la literatura revisada.

Tabla 4.3: Comparación del índice SSIM con diferentes métodos.

Imagen ID	He et al.	Berman et al.	Ren et al.	Galdran et al.	Propuesto
0586	0.82	0.88	0.88	0.85	0.89
1352	0.8	0.77	0.91	0.88	0.89
1381	0.83	0.86	0.7	0.68	0.81
3146	0.76	0.65	0.73	0.73	0.77
4184	0.79	0.7	0.74	0.77	0.78
4561	0.81	0.81	0.8	0.8	0.82
5576	0.75	0.65	0.68	0.7	0.78
5920	0.84	0.88	0.87	0.83	0.89
7471	0.85	0.87	0.85	0.88	0.91
8180	0.83	0.92	0.91	0.91	0.9
Promedio	0.808	0.799	0.807	0.803	0.844

La tabla 4.4 presenta el cálculo del PSNR sobre las mismas 10 imágenes utilizando los mismos métodos mencionados anteriormente. Como en la tabla anterior, el método propuesto produce valores más altos que los otros métodos para 7 de cada 10 imágenes. El promedio del método propuesto es de 20.41 (aproximadamente 16% más alto que el PSNR obtenido de cualquier otro método en la literatura revisada). Considerando que el PSNR tiene una respuesta logarítmica, la diferencia es notable.

Tabla 4.4: Comparación de PSNR con diferentes métodos

Imagen ID	He et al.	Berman et al.	Ren et al.	Galdran et al.	Propuesto
586	13.57	18.58	19.37	17	23.02
1352	13.06	11.46	20.04	19.14	23.73
1381	14.93	16.86	14.28	13.05	19.21
3146	18.91	15.13	17.28	16.59	18.48
4184	20.99	15.14	16.25	16.63	16.27
4561	20.1	19.18	20.82	20.73	18.64
5576	19.35	14.56	16.26	15.92	19.67
5920	18.85	20.8	20.52	16.48	22.82
7471	18.23	19.7	18.22	16.38	21.25
8180	16.48	24.72	24.08	19.86	20.98
Promedio	17.45	17.61	18.71	17.18	20.41

4.2.2. Evaluación del tiempo de procesamiento

Table 4.5 presenta el tiempo promedio de procesamiento (en segundos) usando diferentes métodos sobre las 10 imágenes sintéticas obtenidas del conjunto de datos RESIDE-HSTS [65]. Utilizando los parámetros optimizados calculados en la sección anterior ($k = 8, n = 37$), el método propuesto alcanza un rendimiento de tiempo medio sobresaliente de 0,29 s. Este resultado refuerza la confianza de los autores en el método propuesto. El tiempo de procesamiento más cercano es 5,37 más lento que el método propuesto, que es capaz de procesar imágenes de 3,44 por segundo.

Tabla 4.5: Comparación del tiempo medio (en segundos) de diferentes métodos.

	He et al.	Berman et al.	Ren et al.	Galdran et al.	Propuesto
Tiempo	29.3	1.56	1.97	2.34	0.29



Figura 4.5: Conjunto de diez imágenes del mundo real restauradas con diferentes métodos de dehazing. (a) Conjunto de imágenes exteriores con neblina, (b) restauración usando He et al. [15], (c) restauración usando Berman et al. [11], (d) restauración usando Ren et al. [12], (e) restauración usando Galdran et al. [16], (f) restauración usando el método propuesto [Creación propia].




Figura 4.6: Conjunto de imágenes de neblina sintética con diferentes métodos de dehazing. (a) Conjunto de imágenes exteriores con neblina, (b) restauración usando He et al. [15], (c) restauración usando Berman et al. [11], (d) restauración usando Ren et al. [12], (e) restauración usando Galdran et al. [16], (f) restauración usando el método propuesto [Creación propia].

Conclusiones

En este trabajo de tesis se presentan dos métodos de eliminación de hazing basados en el principio del canal oscuro. Los métodos planteados no hacen uso de información adicional como pueden ser datos de profundidad u otras imágenes de la escena capturada.

Respecto al primer método propuesto basado en una red neuronal artificial Perceptron multicapa (MLP) se ha demostrado que el método propuesto logra un rendimiento superior a nueve métodos del estado del arte en términos de calidad de restauración sobre un conjunto de pruebas de imágenes sintéticas. Además, un análisis comparativo utilizando el conjunto de pruebas de 40 imágenes entre los métodos propuestos y los comparativos, revela que el tiempo computacional más bajo se obtuvo por el método propuesto. Dados los resultados adecuados en términos de calidad de restauración y tiempo de ejecución del método propuesto con respecto a los nueve métodos de dehazing de última generación, puede ser muy apropiado utilizarlo en sistemas en tiempo real y bajo condiciones muy diversas dada su robustez respecto al primer método.

Analizando los resultados del segundo método basado en una combinación de un filtro multidireccional, desviación estándar y cálculos del canal oscuro, se mostró mediante un análisis cualitativo de las imágenes naturales y cuantitativo que el algoritmo propuesto permite obtener más detalles en comparación con dos métodos del estado del arte. Sin embargo, la principal contribución de este método está relacionada con el bajo tiempo de procesamiento y facilidad de implementación. Esta ventaja puede ser aprovechada para realizar dehazing de vídeo, abriendo algunas posibilidades de visión artificial como la navegación automática, los sistemas de vigilancia, la inspección óptica de un proceso industrial en entornos contaminados, entre otros.

Al finalizar el desarrollo y pruebas de los métodos desarrollados se puede confirmar el éxito de los enfoques propuestos, pues superan a métodos del estado del arte en varios aspectos. Lo anterior abre la posibilidad real de generar una línea de investigación que tenga como propósito utilizar los métodos en aplicaciones tecnológicas.

Trabajos futuros

Dados los resultados obtenidos en este trabajo de investigación desarrollado existen varias líneas de investigación que pueden ser desarrolladas, aquí se nombran algunas:

- Conseguir una implementación eficaz y eficiente sobre dispositivos de hardware reconfigurables.
- Paralelizar los algoritmos con la finalidad de aplicar el algoritmo a video en tiempo real.
- Aplicar métodos de inteligencia artificial novedosos del estado del arte para conseguir un mejor rendimiento.
- Generar tecnología basado en los métodos desarrollados y aplicarla en problemas específicos como robótica móvil, vigilancia, reconocimiento de patrones, conducción autónoma, etc.


Productos académicos obtenidos

1. Artículos en revistas indizadas en el Journal Citation Report (JCR) de Thompson

1. Salazar-Colores Sebastian, Moya-Sánchez E. Ulises, Ramos-Arreguin Juan-Manuel and Cabal-Yépez Eduardo, “Statistical Multidirectional Line Dark Channel for Single Image Dehazing”. Journal of Engineering IET Image Processing, ACEPTADO, April/2019. (Factor de impacto = 1,401)

IET Research Journals

Statistical Multidirectional Line Dark Channel for Single-Image Dehazing



The Institution of
Engineering and Technology

ISSN 1751-8644
doi:10.1093/iet/itj
www.iet.org

Statistical Multidirectional Line Dark Channel for Single-Image Dehazing

Sebastián Salazar Colores¹, E. Ulises Moya-Sánchez^{2*}, Juan-Manuel Ramos-Arreguín³, Eduardo Cabal-Yépez⁴

¹ Facultad de informática, Universidad Autónoma de Querétaro, Av. de las Ciencias S/N, Juárez de Querétaro, México
² High-Performance Artificial Intelligence Group, Barcelona Supercomputing Center, Spain and Postgrado en Ciencias Computacionales Universidad Autónoma de Guadalajara
³ Facultad de Ingeniería, Universidad Autónoma de Querétaro, Cerro de las Campanas s/n, Querétaro, México
⁴ División de Ingenierías del Campus Irapuato-Salamanca, Universidad de Guanajuato, Guanajuato, México
* E-mail: eduardo.moyasanchez@bc.cs

Abstract: Outdoor scenes often contain atmospheric degradation such as fog or haze which deteriorate the performance of tracking, autonomous driving and surveillance systems, among others, making dehazing methods an area of considerable interest. However, some dehazing techniques are computationally demanding, generating a trade-off between time-consumption and restoration quality. In this paper, a new method is proposed for improving outdoor images taken with haze effects while making them less time-consuming. The proposed method, was inspired by the Radon transform and tailored for dehazing images by computing the dark channel, in addition to statistical computations and a heuristic approach to avoid saturated areas. The results obtained were subjected to a reduced-reference image quality dehazing assessment and full-reference metrics Structural Similarity (SSIM) index and the Peak Signal to Noise Ratio (PSNR) over real-world and synthetic outdoor images. The results demonstrate that the proposed method presents an adequate balance between new visible edges, increased gradient and saturated pixels besides to at least 5% higher SSIM index, 16% higher PSNR and is 5.37 times faster than four dehazing methods recently introduced in the literature.

1 Introduction

Outdoor scenes frequently produce images stained by haze, resulting in colour fading, blurring and contrast reduction [1]. These image degradations associated with haze are caused by the absorption and scattering effects of light particles (see Section 3) as they travel from the source to the observer [2, 3]. As a consequence, the performance of computer vision algorithms can be deteriorated during different tasks, such as tracking [4], autonomous driving [5], image recognition [6, 7] and surveillance systems, among many others [8–10].

Dehazing is a restoration process (when scattering model is used), or enhancement task (when are not used a physic model) to reduce the haze effects presented in images, when they are acquired in haze conditions [1, 11]. The dehazing methods are divided according to the input information into single-image (usually for RGB images) or multiple image (using for instance RGBD images) processing [9, 12]. In recent years, the methods that process a single-image for dehazing have attracted the attention of the research community in this field [13].

One of the most important studies into single-image dehazing algorithms is the dark channel prior (DCP), a method proposed by He et al. [14], which consists of computing the transmission map of an image by estimating the depth of each of its elements; nevertheless, processing time and artifacts do not allow using this algorithm to be used in real-time applications [4]. For that reason, many studies are focused on reducing DCP processing time without losing restoration quality and attempting to avoid image artifacts [9].

This work presents a new single-image dehazing method capable of better reducing visible artifacts, preserving the edges with less time consumption. The proposed method is inspired by the Radon transform [15] and is based on three main concepts:

- Local statistical computations (mean value and standard deviation) to obtain a robust processing.
- Contrast enhancement, in order to present more realistic colours.

The obtained results were assessed and compared against those from four dehazing methods, which are in one hand representative/valuable in the dehazing literature and on the other, the implementation and computational resources are available. The four dehazing methods are listed as follows: He et al. [14], Berman et al. [16], Ren et al. (deep learning method) [17] and Galdrin et al. [18].

To compare the method performance we have used a reduced-reference image quality assessment (RR-IQA) and full-reference image quality assessment (FR-IQA). The used RR-IQA measures how the visibility of objects in the scene is enhanced. This metric uses three descriptors: ratio of new visible edges (ϵ), degree of increased gradient ρ , and percentage of saturated pixels θ_s [19]. Higher values in the two first descriptors (ϵ, ρ) simultaneously with a lower value of θ_s suggest good restoration. The two FR-IQA metrics used in this work are, the Structural Similarity (SSIM) index and the Peak Signal to Noise Ratio (PSNR). For these metrics, higher values are better. The tests and evaluation were realized over synthetic and real-world images acquired from the RESIDE-ISTIS dataset [20] and [21], respectively.

The rest of this manuscript is organized as follows: Section 2 presents a literature review, Section 3 introduces the theory of the atmospheric degradation model and dark channel prior, Section 4 describes the proposed methodology, Section 5 presents the datasets and metrics used in this paper, as well as the fine-tuning parameters, Section 6 shows the results and presents a discussion of same. Finally, Section 7 presents conclusions and future work.

- Multidirectional line operations to improve the computing process of the DCP.

IET Research Journals, pp. 1–10
© The Institution of Engineering and Technology 2019

2. Salazar-Colores, S., Ramos-Arreguín, J.-M., Pedraza-Ortega, J.-C., and Rodríguez-Resendiz, “**Efficient single image dehazing by modifying the dark channel prior**”. *EURASIP Journal on Image and Video Processing JIVP*, **ACEPTADO**, Mar/2019. (Factor de impacto = 1,737)

[Click here to view linked References](#)

1
2
3
4
5
6
7
8
9
10
11
12
13
14
15
16
17
18
19
20
21
22
23
24
25
26
27
28
29
30
31
32
33
34
35
36
37
38
39
40
41
42
43
44
45
46
47
48
49
50
51
52
53
54
55
56
57
58
59
60
61
62
63

Salazar-Colores et al.

RESEARCH

Efficient single image dehazing by modifying the dark channel prior

Sebastián Salazar-Colores¹, Juan-Manuel Ramos-Arreguín^{2*}, Juan-Carlos Pedraza-Ortega² and Juvenal Rodríguez-Reséndiz²

Abstract

Outdoor images due to the particles in the air that absorb and scatter light are degraded. The produced degradation generates contrast attenuation, blurring, and distortion of the values of the pixels, resulting in low visibility. These limits the efficiency of computer vision systems such as target tracking, surveillance, and recognition of patterns. In this paper, we propose a simple, fast and effective method that through modification in the computation of the dark channel significantly reduces the artifacts generated in the restored images presented when using the ordinary dark channel. According to experimental data, our method produces better results than some state-of-art methods in both efficiency and restoration quality. The processing time in realized tests show that the algorithm is adequate for images with high resolution and real-time video processing.

Keywords: Dark channel prior; Defogging; Dehazing; Image enhancement; Single image dehazing

1 Introduction

The presence of environmental disturbances such as haze and smog give to outdoor images and videos undesirable characteristics that affect the ability of computer vision systems to detect patterns and perform an efficient features classification. These characteristics are caused by the decrease in contrast and color modification caused by the presence of suspended particles in the air.

Hence the task of removing the haze, fog, and smog (dehazing), without compromising the image information, takes on special relevance. Therefore, to improve the performance of systems just as, security problems [1], traffic [2], self-driving vehicles [3] is essential to develop new and better dehazing methods. This problem has been studied extensively in the literature with two main approaches: methods that use multiple images [4], and, methods that use just a single image [1].

In the single image approach can be mentioned relevant results, such as the obtained by Tan et al. in [5], Fattal in [6], and Tarel et al. [7] where the main problem of these proposed methods is the time processing required and that the proposed methods are not based on solid physics concepts. The most studied method in

the literature is the presented by He et al. [8] where it is introduced the dark channel prior (DCP). The DCP is a simple but effective approach in most cases, although it produces artifacts around regions where the intensity changes abruptly. Usually, in the literature to eliminate the artifacts, a refinement stage is necessary, which has an impact on time processing [1, 9]. To get around this problem, Gibson et al. [10] proposed a DCP method based on the median operator. Zhu et al. [11] introduced a linear color attenuation prior. Ren et al. [12] used a deep multiscale neural network.

This paper presents a simple and fast novel method in which a modified dark channel is introduced, improving the quality of the depth estimations of the image elements, and reducing significantly the artifacts generated when the traditional dark channel is used. The modification of the proposed dark channel unlike most state-of-the-art methods makes unnecessary a refinement stage which has a positive impact on the simplicity and speed of the dehazing process. Experimental results demonstrate the effectiveness of the proposed method, and when was compared quantitatively with three state-of-the-art methods, where it was observed that the proposed method has a best restoration quality and requires significantly less time.

The paper is organized as follows. In section 2, the image degradation model and the dark channel prior used is discussed. The proposed method is presented in

*Correspondence: jstidig@yahoo.com.mx

²Facultad de Ingeniería, Universidad Autónoma de Querétaro, Cerro de las Campanas s/n, 76010 Querétaro, México

Full list of author information is available at the end of the article

3. S. Salazar-Colores, E. Cabal-Yepez, J. M. Ramos-Arreguin, G. Botella, L. M. Ledesma-Carrillo and S. Ledesma (2018). “A Fast Image Dehazing Algorithm Using Morphological Reconstruction”. IEEE Transactions on Image Processing. doi: 10.1109/TIP.2018.2885490. (Factor de impacto = 5,071)

A Fast Image Dehazing Algorithm Using Morphological Reconstruction

Sebastian Salazar-Colores, Eduardo Cabal-Yepez, Juan M. Ramos-Arreguin, *Senior member, IEEE*,
Guillermo Botella, Luis M. Ledesma-Carrillo, Sergio Ledesma *Member, IEEE*.

Abstract— Outdoor images are used in a vast number of applications, such as surveillance, remote sensing, and autonomous navigation. The greatest issue with these types of images is the effect of environmental pollution: haze, smog, and fog originating from suspended particles in the air, such as dust, carbon and water drops, which cause degradation to the image. The elimination of this type of degradation is essential for the input of computer vision systems. Most of the state-of-the-art research in dehazing algorithms is focused on improving the estimation of transmission maps, which are also known as depth maps. The transmission maps are relevant because they have a direct relation to the quality of the image restoration. In this paper, a novel restoration algorithm is proposed using a single image to reduce the environmental pollution effects, and it is based on the dark channel prior and the use of morphological reconstruction for the fast computing of transmission maps. The obtained experimental results are evaluated and compared qualitatively and quantitatively with other dehazing algorithms using the metrics of the Peak Signal-to-Noise Ratio (PSNR) and Structural Similarity (SSIM) index; based on these metrics, it is found that the proposed algorithm has improved performance compared to recently introduced approaches.

Index Terms—Single-image dehazing, Image enhancement, Morphological operations, Dark channel prior

I. INTRODUCTION

OUTDOOR images are exposed to adverse weather conditions such as haze, fog or smog, which cause effects such as scene darkening, contrast degradation, and color change, among others. Haze is among the most common atmospheric conditions and is caused by floating particles such as water drops or any other aerosol that reflects the light, diffusing it in the air and reducing the visibility of details. Vision systems applied to remote sensing, surveillance, and

autonomous navigation generally use input images under adverse weather conditions; therefore, the results produced depend on the quality of the image received as input. Atmospheric scattering adds nonlinear and data-dependent noise to the captured outdoor image, which makes image restoration a very difficult process; consequently, several research works have focused on diminishing the haze effects in images captured using vision systems by designing and applying dehazing algorithms [1], which can be divided into those requiring additional information from the scene (for instance, in [2], a method for haze removal that utilizes the correlations between hazy images and haze-free images as external information is presented) and those using one single image (in [3], a study and evaluation of existing single-image dehazing algorithms, using a large-scale benchmark of synthetic and real-world hazy images, is presented). The algorithms that use a single image to diminish the effects of adverse atmospheric conditions are the most studied these days because they are useful for practical applications, such as autonomous vehicle navigation, surveillance and remote sensing [4], [5]. In this regard, dark channel prior (DCP), which consists of estimating the transmission map of an image by estimating the depth of each element in it, has been used in combination with other algorithms for fast computation of accurate transmission maps [6], at the cost of long computation times compromising its utilization on online vision systems. Therefore, recent research has focused on the computation speed of transmission maps, aiming to preserve the image quality.

In this work, a novel fast algorithm is proposed for lessening haze effects using morphological reconstruction to preserve important structures in all its stages and refine the transmission-map computation of single images captured by vision systems, making it feasible for use in online applications.

The remainder of the manuscript is organized as follows. Section II provides a brief literature review of related work. Section III introduces an overview of the theoretical background utilized in this work. Section IV describes the proposed technique and its implementation in depth. Obtained results are presented in Section V and compared against those obtained from six different dehazing algorithms. Finally, conclusions are given in Section VI.

Manuscript received February 12, 2018. This work was supported in part by the National Council on Science and Technology (CONACYT), Mexico, under Scholarship 285651, and by DAIP - U. de Gto. under Research Project 209, Convocatoria Institucional de Investigación Científica 2018

Sebastian Salazar-Colores and Juan-Manuel Ramos-Arreguin are with the Faculty of Informatics, Universidad Autónoma de Querétaro (UAQ), Querétaro, Querétaro, Mexico, (e-mail: s.salazarcolores@gmail.com, jramos@mecamex.net).

Eduardo Cabal-Yepez, Luis M. Ledesma-Carrillo, and Sergio Ledesma are with the Division de Ingenierías del Campus Irapuato-Salamanca, Universidad de Guanajuato, Yuriria/Salamanca, Guanajuato, Mexico, (e-mail: e.cabalYepez@gmail.com, Lm.ledesmacarrillo@gmail.com, selo@ugto.mx).

Guillermo Botella is with the Departamento de Arquitectura de Computadores y Automática, Universidad Complutense de Madrid, Av. Complutense S/N, 28040 Madrid, Spain (e-mail: gbotella@fdi.ucm.es)

Color versions of one or more of the figures in this paper are available online at <http://dx.doi.org/10.1109/TIP.2018.2885490>

4. Salazar-Colores, S., Cruz-Aceves, I., and Ramos-Arreguin, J.-M. (2018). “Single image dehazing using a multilayer perceptron”. *Journal of Electronic Imaging*, 27, 43011–43022. Retrieved from <https://doi.org/10.1117/1.JEI.27.4.043022>. (Factor de impacto = 0,780)

Single image dehazing using a multilayer perceptron

Sebastián Salazar-Colores,^a Ivan Cruz-Aceves,^b and Juan-Manuel Ramos-Arreguin^c

^aUniversidad Autónoma de Querétaro, Facultad de Informática, Santiago de Querétaro, Querétaro, México

^bConsejo Nacional de Ciencia y Tecnología, Centro de Investigación en Matemáticas, Guanajuato, Guanajuato, México

^cUniversidad Autónoma de Querétaro, Facultad de Ingeniería, Santiago de Querétaro, Querétaro, México

Abstract. This paper presents an algorithm to improve images with hazing effects. Usually, the dehazing methods based on the dark channel prior make use of two different stages to compute the transmission map of the input image. The stages are the transmission map estimation and a transmission map refinement. However, the main disadvantage of these strategies is the trade-off between accurate restoration and computational time. The proposed method uses a multilayer perceptron to compute the transmission map directly from the minimum channel and a contrast stretching technique to improve the dynamic range of the restored image. The multilayer perceptron is trained in terms of mean squared error using a training set of 80 images. To evaluate the restoration quality, the metrics of peak signal-to-noise ratio (PSNR) and the structural similarity (SSIM) index are used. The experimental results have proven that the proposed method achieves superior performance in terms of restoration quality (PSNR = 18.77, SSIM index = 0.8454) compared with nine state-of-the-art dehazing methods. In addition, based on the average computational time achieved by the proposed method (0.52 s using a test set of 46 images), it can be highly suitable for real-time applications. © 2018 SPIE and IS&T [DOI: [10.1117/1.JEI.27.4.043022](https://doi.org/10.1117/1.JEI.27.4.043022)]

Keywords: artificial neural network; dark channel prior; defogging; image enhancement; multilayer perceptron; single image dehazing. Paper 180180 received Mar. 5, 2018; accepted for publication Jul. 3, 2018; published online Jul. 25, 2018.

1 Introduction

Image enhancement is a very active research area since the image quality has a direct influence on computer vision systems. In general, outdoor images are susceptible to different atmospheric conditions, especially haze, fog, and smog. The main effects caused by these atmospheric conditions are images with low contrast, distorted colors, and reduced visibility. Consequently, the performance of systems, such as surveillance,¹ target tracking,² remote sensing,³ traffic control,⁴ and autonomous driving,⁵ could be highly affected.

In the literature, the problem of eliminating or reducing the effects of atmospheric scattering has been widely studied. The most representative strategies can be classified according to the input information such as multiple images,^{6,7} infrared radiation,⁸ three-dimensional data,⁹ and the use of a single image.¹⁰ However, the most studied approach is based on a single image, because additional data are not commonly available.¹¹

In the single image dehazing problem, several representative works have been proposed. Tarel and Hautiere¹² proposed a method based on two different filters: a median filter and a filter for preserving edges and corners. The method estimates the scattered airlight for recovering a haze-free image. Fattal¹³ assumed that there is a nonlocal relation between the shading and the signal. Since the method tries to solve a nonlinear inverse problem by computing a transmission map, this approach generates suitable results in regions where the shading and transmission are different. However, it does not perform well in regions where they are similar. He et al.¹⁴ introduced the dark channel prior (DCP)

based on a statistic analysis of haze-free images. They use the DCP to compute the transmission and restore the image using an atmospheric scattering model. The DCP algorithm obtains accurate results in most of the cases. The main drawback of DCP method is that it requires an intensive computational processing to refine a generated coarse transmission, making it inadequate for many applications where a short response time is required. In order to improve the computational time of the DCP along with the qualitative results of the DCP, different works have been introduced. Pang et al.¹⁵ proposed to refine the transmission by applying an edge-preserving smoothing operator named guided filter using a patch radius of 30 pixels. Nishino et al.¹⁶ used a probabilistic Bayesian method that combines the estimation of the albedo and depth of a scene. Gibson et al.¹⁷ proposed a variant of DCP replacing the minimum operator with the median operator. Zhu et al.¹⁸ proposed a linear color attenuation based on the difference of the saturation and the brightness of the pixels. Berman et al.¹⁹ used a pixel-oriented algorithm, where pixels are clustering in the RGB space to estimate a haze-line used to recover the haze-free image.

In particular, artificial neural networks (ANN) have begun to attract more attention in computer vision systems. ANN are computing systems inspired by biological neural networks trying to emulate the microstructure of the brain. One of the most popular ANN classes is the multilayer perceptron (MLP) because of its robustness and ease of implementation.²⁰ It is an ANN with at least three layers of neurons and it commonly uses a supervised learning strategy called backpropagation.²¹ Recently, it has been used to

*Address all correspondence to: Ivan Cruz-Aceves, E-mail: ivan_cruz@oma

5. Salazar-Colores, S., Ramos-Arreguín, J.-M., Ortiz Echeverri, C. J., Cabal-Yepez, E., Pedraza-Ortega, J.-C., and Rodríguez-Resendiz, J. (2018). “Image dehazing using morphological opening, dilation and Gaussian filtering”. *Signal, Image and Video Processing*. <https://doi.org/10.1007/s11760-018-1286-9>. (Factor de impacto = 1,643)



Image dehazing using morphological opening, dilation and Gaussian filtering

Sebastián Salazar-Colores¹ · Juan-Manuel Ramos-Arreguín¹ · César Javier Ortiz Echeverri¹ · Eduardo Cabal-Yepez² · Jesus-Carlos Pedraza-Ortega¹ · Juvenal Rodríguez-Resendiz¹

Received: 16 August 2017 / Revised: 30 January 2018 / Accepted: 11 April 2018
© Springer-Verlag London Ltd., part of Springer Nature 2018

Abstract

Image pre-processing is a critical stage in computer vision systems, with greater relevance when the input images are captured in outdoor environments because the pictures could contain low contrast and modified colors. A common condition present in outdoor images is haze. In this work, a new dehazing algorithm based on dark channel prior mathematical morphology operations (opening and dilation), and a Gaussian filter, is proposed. Moreover, the proposed algorithm performance is compared qualitatively and quantitatively against previously reported algorithms. Obtained results show that the proposed algorithm requires less processing time providing higher quality dehazing results than other state-of-the-art approaches.

Keywords Atmospheric scattering · Contrast enhancement · Dehaze · Dark channel prior · Image enhancement · Image restoration

1 Introduction

Computer vision systems use images as inputs; for this reason, the quality of the images has a direct impact on its performance. An outdoor computer vision system, such as surveillance, autonomous navigation, and remote sensing, assumes that images are acquired in a transparent atmosphere; but in real conditions, the acquired image could be affected by conditions such as inclement weather, haze, fog

or smog. These conditions mainly affect the contrast, color, and visibility of the images. Therefore, many image processing algorithms have been created to alleviate such effects. The reduction in these effects is significant for many applications.

In previous works, different approaches have been proposed for dehazing, such as: application of depth information obtained from 3D models of the acquired scene [1], near-infrared information [2], light polarization [3,4], multiple images [5,6], and just a single image. The first four approaches produce excellent results, but their requirements cannot be easily met as is shown in [1,6].

In recent years, the single-image approach has been widely studied, due that most images are captured using common cameras. For instance, Tan maximizes local contrast in the image [7]. Fattal [8] uses the independent component analysis (ICA) to restore the image. He et al. [9] had proposed to use the dark channel prior (DCP) to recover the images with excellent results; however, the main drawback is that the algorithm is expensive in terms of time processing, mainly because of the matting operation used to refine the transmission map (estimation of depth). Since then, many alternatives based on DCP have been proposed to achieve shorter processing times and at the same time good quality; for instance, using image segmentation [10], a guided filter [11], and an edge-guided filter [12], a linear model [13], a median fil-

✉ Juan-Manuel Ramos-Arreguín
jramos@mecamex.net

Sebastián Salazar-Colores
s.salazarcolores@gmail.com

César Javier Ortiz Echeverri
cesarortiz1983@gmail.com

Eduardo Cabal-Yepez
e.cabalYepez@gmail.com

Jesus-Carlos Pedraza-Ortega
caryoko@yahoo.com.mx

Juvenal Rodríguez-Resendiz
juvenal@uaq.edu.mx

¹ Facultad de Informática - Facultad de Ingeniería, Universidad Autónoma de Querétaro, Santiago de Querétaro, Querétaro, Mexico

² División de Ingenierías, Campus Irapuato-Salamanca, Universidad de Guanajuato, Salamanca, Guanajuato, Mexico

.2. Artículos publicados en revistas arbitradas del CONACYT

1. Sebastián Salazar-Colores, Mariano Garduño-Aparicio, E. Ulises Moya-Sánchez, Claudia-Victoria Lopez-Torres, and Juan-Manuel Ramos-Arreguín. “The Dark Channel Applied To Reduce The Effects Of Non-uniform Illumination In Image Binarization”. Computación y Sistemas, Oct/2018. ACEPTADO.

The Dark Channel Applied To Reduce The Effects Of Non-uniform Illumination In Image Binarization

Sebastián Salazar-Colores^{1,2}, Mariano Garduño-Aparicio³, E. Ulises Moya-Sánchez², Claudia-Victoria Lopez-Torres², Juan-Manuel Ramos-Arreguín³

¹ Facultad de Informática, Universidad Autónoma de Querétaro
México

² High-Performance Computing Artificial Intelligence, Barcelona Supercomputing Center,
España

³ Facultad de Ingeniería, Universidad Autónoma de Querétaro
México

s.salazarcolores@gmail.com

Abstract. Non-uniform illumination is a common issue in images acquired in uncontrolled environments. Elimination or reduction of the non-uniform illumination problem is required in order to get an accurate image binarization. This paper introduces the combination of the dark channel and the atmospheric scattering model along with the k-means segmentation to reduce the effects of non-uniform illumination conditions in image binarization. The results show the effectiveness and robustness of this approach.

Keywords. Non-uniform illumination, Uneven illumination, Dark channel, Binarization

Resumen. La iluminación no uniforme es un problema común en las imágenes adquiridas en entornos no controlados. La eliminación o reducción del problema de iluminación no uniforme es necesaria para obtener una binarización precisa de la imagen. Este artículo presenta la combinación del canal oscuro y el modelo de dispersión atmosférica junto con la segmentación k-means para reducir los efectos de las condiciones de iluminación no uniforme en la binarización de imágenes. Los resultados muestran la eficacia y la solidez de este enfoque.

Keywords. Iluminación no uniforme, Iluminación irregular, Canal oscuro, Binarización

1 Introduction

Uneven illumination is a common problem in uncontrolled environments, which affects the performance of computer vision systems that use the acquired images. Non-uniform illumination affects operations in digital image processing like classification [13], segmentation [19], pattern recognition [9]. In order to observe the effects of the proposed approach, in this paper the proposed method is applied to binarization. Binarization is the process for converting from pixel image to a binary image [3] and it is the simplest image segmentation case [17]. The binary image is a kind of image that just has two values; one of them are the pixels of foreground image forming the objects of interest and the rest as background pixels [20].

Building robust algorithms, which can realize effective binarization of an image, regardless the lighting conditions, it is not a trivial task, but final results are quite important, because there are a lot of applications that need to do image processing through binary images, like recognition of writing in documents [16], fingerprints recognition [2], analysis of brain MR images [11], recognition of license plate [11], defect detection in production lines [15], etc.

2. Enrique Javier Arriaga-Varela, E. Ulises Moya-Sánchez, A. Aguilar-Meléndez, Octavio Castillo-Reyes, Eduardo Vazquez-Santacruz, Sebastian Salazar Colores and Ulises Cortés, “**Detection, Count, and Classification of Visual Ganglia Columns of Drosophila Pupae**”. *Computación y Sistemas*, Mar/2019. ACEP-TADO.

Detection, Count, and Classification of Visual Ganglia Columns of Drosophila Pupae

Enrique Javier Arriaga-Varela², E. Ulises Moya-Sánchez², Armando Aguilar-Meléndez^{2,3}, Octavio Castillo-Reyes²
Eduardo Vazquez-Santacruz, Sebastian Salazar Colores⁴, Ulises Cortés¹,

¹Universitat Politècnica de Catalunya - BarcelonaTECH, Barcelona, Spain

²Barcelona Supercomputing Center (BSC), Barcelona, Spain

³Universidad Veracruzana, Poza Rica, Mexico

⁴Queretaro, Queretaro, Mexico

enrique@.edu, eduardo.moyasanchez@bsc.es, ia@cs.upc.edu

Abstract. Many neurobiologists use the fruit fly (*Drosophila*) brain as a model for the study of neuron development and interaction mechanisms to extrapolate this knowledge to the human brain, and to shed light on the nature of human neurological disorders. Recent study shows that neurons that are grouped in columns are the main functional unit of the brain in many different organisms, including fruit fly and mammals. However, in many laboratories, the detection, counting, and analysis of these columnar union is still a manual task. An automated detection, counting, and morphologic analysis of these images can provide faster data processing and new information. The main object of this work is to present a semi-automatic detection-counting system and give the main characteristics of the visual ganglia columns in *Drosophila*. We concluded that in an image with a Signal to Noise Ratio greater than 4.7, we can obtain an accuracy of 75% (with a Kappa statistic of 0.50) in the shape classification using our algorithm. One of the main contributions of these algorithms is that we combine automatic operations, with image analysis results, machine learning techniques, and user parameters in real-time to obtain a more reliable results. Additionally, we develop and share, a multi-platform software which can be used by neurobiology laboratories whose research interests are focused on this topic.

Keywords. Wind Power Forecast, Wind Speed Forecast, Short-term Prediction, Machine Learning, Deep Learning, Neural Networks

Detección, recuento y clasificación de las columnas de ganglios visuales de Drosophila Pupae

Resumen. Muchos neurobiólogos usan el cerebro de la mosca de la fruta como un modelo para el estudio del desarrollo neuronal y mecanismos de interacción para extrapolar este conocimiento al cerebro humano y generar conocimiento sobre la naturaleza de desórdenes neurológicos humanos.

Palabras clave. Pronóstico de la producción de energía eólica, Pronóstico de la velocidad del viento, Aprendizaje Automático, Deep Learning, Redes Neuronales.

1 Introduction

Many neurobiologists use the fruit fly (*Drosophila*) to study their brain, optical lobe neurons, cortical columns among others [2, 5, 3], and then extrapolate this knowledge to human behavior and diseases [4] [2] [7]. *Drosophila* studies have a significant value for the scientific community (5 Nobel Prizes related) because fruit fly it is an easily reproducible technique and a big amount of genetic tools are available, including different tools for control and manipulation of neuron growth and functions. Additionally, fruit flies, shows a relatively complex behavioral repertoire in a relatively simply organized brain, with only 100,000 neurons. Within the fly, the optic lobe is especially appealing because flies are highly visual animals, with the two optic lobes encompassing approximately 50% of the total brain volume.

The fluorescence microscopy images of columns commonly have high contrast. However, the detection is compromised by background signals, generating fuzzy boundaries of columns.

.3. Capítulos de libro publicados

1. Salazar-Colores, S., Cruz-Aceves, I., Ortiz Echeverri, C. J., Ramos-Arreguín, J.-M., Memorias de la Escuela de Cómputo Evolutivo, “Una aproximación al mejoramiento de imágenes en exteriores mediante redes neuronales”, ISBN: 978-84-947311-9-8. Oct/2017, ACEPTADO.

Una aproximación al mejoramiento de imágenes en exteriores mediante redes neuronales

SEBASTIÁN SALAZAR-COLORES, Universidad Autónoma de Querétaro, México
IVÁN CRUZ-ACEVES, CONACYT- Centro de Investigación en Matemáticas (CIMAT), A. C., México
CÉSAR ORTÍZ-ECHEVERRI, Universidad Autónoma de Querétaro, México
JUAN-MANUEL RAMOS-ARREGUIN, Universidad Autónoma de Querétaro, México

Resumen En este artículo es propuesto un nuevo método para eliminar de imágenes tomadas en exteriores defectos presentes como el bajo contraste y distorsión de colores. Estos defectos son causados por malas condiciones climáticas como neblina, niebla o smog. El método propuesto está basado en el principio del canal oscuro junto con una red neuronal entrenada para eliminar ruido. Los resultados experimentales demuestran que el enfoque propuesto obtiene mejores resultados que algunos métodos del estado del arte.

1 INTRODUCCIÓN

Eliminar los efectos adversos presentes en imágenes tomadas de exteriores tiene como consecuencia el incremento en la visibilidad de las escenas, lo cual puede beneficiar a aplicaciones tales como conducción autónoma, teledetección o vigilancia [15]. Por ello es un tópico importante en visión por computadora.

Sin embargo, eliminar o al menos atenuar esos efectos adversos es un problema desafiante ya que físicamente el modelo de dispersión atmosférica requiere de tres parámetros para restaurar la imagen: la imagen de entrada, el color de la luz atmosférica y la transmisión, y generalmente se desconocen los dos últimos [3].

Recientemente, se han presentado avances significativos utilizando principios o suposiciones obtenidas empíricamente. Fattal [4] asume que el sombreado de las superficies y el medio transmisión no están correlacionados con lo cual estima el albedo de la escena y el medio de transmisión. El método no funciona adecuadamente en regiones donde la afectación es muy grande. Tan [14] basa su método en el hecho que imágenes sin afectaciones tienen contrastes mayores a imágenes que están más afectadas, funcionando adecuadamente en muchos casos, sin embargo dado que su método carece de validez física suele fallar en otros casos [10]. He et al. [7] propone un método que utiliza un hecho estadístico -el principio del canal oscuro- el cual parte del hecho que la mayoría de las ventanas locales en imágenes sin afectaciones contienen píxeles con baja intensidad. Combinando el principio del canal oscuro con el modelo físico y una etapa de refinamiento de transmisión mediante “soft matting” se recupera con gran calidad imágenes sin afectaciones. La limitación del método es el alto tiempo de procesamiento que requiere, lo que ha motivado investigaciones recientes orientadas a mejorar ese aspecto, entre otros la utilización del filtro bilateral [8], el filtro guiado [11], la mediana [6], el filtro interpolado guiado [17], la creación de un modelo lineal [16], y la utilización de una red neuronal profunda multiescala [12].

En este artículo, se propone un método en el que el canal mínimo de la imagen es considerada como una imagen con ruido y a partir de ella es generada la transmisión final aplicando una red neuronal artificial entrenada para eliminar ruido de una imagen. Para probar la validez del método

Autores: Sebastián Salazar-Colores, Universidad Autónoma de Querétaro, Av. de las Ciencias s/n, Querétaro, Querétaro, 76230, México, s.salazarclores@gmail.com; Iván Cruz-Aceves, CONACYT- Centro de Investigación en Matemáticas (CIMAT), A. C., Guanajuato, México, ivan.cruz@cimat.mx; César Ortiz-Echeverri, Universidad Autónoma de Querétaro, Av. de las Ciencias s/n, Querétaro, Querétaro, 76230, México, cesarortiz1983@gmail.com; Juan-Mamuel Ramos-Arreguín, Universidad Autónoma de Querétaro, Cerro de Las Campanas, s/n, Querétaro, Querétaro, México, jramos@mecamex.net.

2. Sebastian Salazar-Colores, Fernando Cervantes-Sanchez, Arturo Hernandez-Aguirre, and Ivan Cruz-Aceves. De Gruyter. Intelligent Multimedia Data Analysis. “An Unsupervised Graph-Based Approach for the Representation of Coronary Arteries in X-ray Angiograms”. Dec/2017.

Sebastian Salazar-Colores, Fernando Cervantes-Sanchez,
Arturo Hernandez-Aguirre, and Ivan Cruz-Aceves*

3 An unsupervised graph-based approach for the representation of coronary arteries in X-ray angiograms

Abstract: This paper presents a novel unsupervised framework for the graph-based representation of coronary arteries in X-ray angiograms. The framework consists of the steps of vessel detection, segmentation, and skeleton simplification. Vessel detection is performed by Gaussian matched filters (GMF) trained by the univariate marginal distribution algorithm for a continuous domain. The detection results are evaluated in terms of the area (A_z) under the receiver operating characteristic curve. The second step is focused on the binary classification of the response obtained from the GMF method. In the final step, the vessel skeleton simplification is carried out by using the Ramer–Douglas–Peucker algorithm. During the computational experiments, the proposed framework obtained a detection performance of $A_z = 0.926$. The inter-class variance method was selected from five state-of-the-art thresholding methods according to its classification accuracy on the segmentation of the detection response (0.923). In the final step, a graph-based structure of the coronary arteries with a data compression ratio of 0.954 is obtained. Based on the experimental results, the proposed method has demonstrated that it is suitable for a variety of applications in computer-aided diagnosis.

Keywords: Automatic segmentation, coronary arteries, curve simplification, estimation of distribution algorithms, Gaussian filters, graph-based representation

3.1 Introduction

In clinical practice, the coronary angiography represents the current gold standard for detecting and monitoring blood vessel abnormalities. The two main disadvantages for working with gray-scale X-ray coronary angiograms are the nonuniform illumination, and the low contrast between coronary arteries and image background. In general, to address this problem, two different steps have to be performed; vessel enhance-

Sebastian Salazar-Colores, Facultad de Informática, Universidad Autónoma de Querétaro, Av. de las Ciencias, s/n, Juriquilla, Santiago de Querétaro, Querétaro, México

Fernando Cervantes-Sanchez, Arturo Hernandez-Aguirre, Centro de Investigación en Matemáticas (CIMAT), A. C., Jalisco S/N, Col. Valenciana, C. P. 36000, Guanajuato, Gto, México.

*Corresponding author: Ivan Cruz-Aceves, CONACYT – Centro de Investigación en Matemáticas (CIMAT), A. C., Jalisco S/N, Col. Valenciana, C. P. 36000, Guanajuato, Gto, México.

<https://doi.org/10.1515/9783110552072-003>

3. Salazar-Colores Sebastián, Ramos Arreguin Juan Manuel, Garduño-Aparicio Mariano, Torres-Hernández Carlos-Miguel, “Implementación de un sistema de dehazing basado en el canal oscuro en Raspberry pi 3”, Innovaciones en Mecatrónica, ISBN 978-607-9394-11-0.

Innovaciones en Mecatrónica
ISBN: 978-607-9394-11-0, Asociación Mexicana de Mecatrónica A.C., 2017



Implementación de un sistema de dehazing basado en el canal oscuro en Raspberry pi 3

Salazar-Colores Sebastián¹, Ramos Arreguin Juan Manuel², Garduño-Aparicio Mariano², Torres-Hernández Carlos-Miguel²

¹Facultad de Informática, Universidad Autónoma de Querétaro

²Facultad de Ingeniería, Universidad Autónoma de Querétaro
jramos@mecamex.net

Resumen

En este artículo se muestran los resultados obtenidos al desarrollar un sistema para eliminar los efectos adversos como alteración de color y bajo contraste generados al adquirir imágenes de color en exteriores bajo malas condiciones climáticas, por ejemplo: neblina, niebla y smog, mediante la utilización de sistemas embebidos de bajo costo y bajo consumo energético. Un sistema como el desarrollado tiene potenciales aplicaciones integrándose como parte de otros sistemas que utilicen imágenes en exteriores como conducción autónoma, vigilancia, teledetección. El sistema está montado sobre un sistema embebido, el cual es en este caso es una Raspberry Pi 3 junto con una cámara de 8 Mega-píxeles, el sistema operativo utilizado es Raspbian, y está programado en C++ junto con librerías OpenCV. La imagen procesada es guardada con lo cual se hace posible la utilización del sistema como parte de un sistema más grande. Los resultados obtenidos demuestran la viabilidad del enfoque propuesto.

Palabras clave: Sistemas embebidos, Raspberry pi 3, dehazing, canal oscuro, openCV.

1. Introducción

La Visión Artificial es una rama de la Computación, que tiene como meta la construcción de descripciones explícitas y útiles sobre objetos y escenas físicas reales, con el fin de tomar decisiones basándose en las imágenes detectadas [1]; sin embargo, la mayoría de sistemas de Visión Artificial asumen que el observador está inmerso en un medio totalmente transparente, lo cual en exteriores, generalmente no ocurre, ya que los sensores que capturan las imágenes tienen que lidiar con una amplia gama de condiciones atmosféricas como la neblina, la niebla, el smog, la lluvia, la brisa y la nieve. Estas condiciones generan el fenómeno físico conocido como *hazing*.

La mayoría de aplicaciones de Visión artificial como vigilancia y navegación autónoma requieren de una detección robusta de las características de una imagen, pero las malas condiciones atmosféricas oscurecen las escenas, reducen la visibilidad, y alteran o degradan el contraste y colores, es entonces cuando surge la necesidad de incluir en el sistema de visión mecanismos que contrarresten estos efectos. Desafortunadamente, esto no puede ser realizado satisfactoriamente con técnicas simples de procesamiento de imágenes. Por lo tanto, es necesario entender el fenómeno físico que causa esos resultados y utilizarlo para anular en la medida de lo posible los efectos producidos en las imágenes. El rendimiento de muchos sistemas mecatrónicos dependen de imágenes en exteriores, tales como vigilancia [2], seguimiento de objetivos [3], teledetección [4], control de navegación [5], conducción autónoma [6] y otros. Lo anteriormente mencionado ha impulsado una gran cantidad de investigaciones tratando este problema.

En la literatura, han sido propuestos distintos tipos de estrategias para tratar el problema del *hazing*. Por ejemplo, la utilización de técnicas genéricas de procesamiento de imágenes para el mejoramiento del contraste, como la corrección *Gamma*, ecualización de histogramas, *Unsharp Masking* que si bien logran resultados aceptables en algunos casos, generalmente tienen un pobre

.4. Actas de conferencias

1. E. Ulises Moya- Sanchez, Sebastian Salazar Colores, Abraham Sanchez and Ulises Cortes, **Quaternion Phase CNN**, 21st International Conference of the Catalan Association for Artificial Intelligence.
2. E. Ulises Moya- Sanchez, Sebastian Salazar Colores, Abraham Sanchez and Ulises Cortes. **Deep Learning Monogenic Convolutional Neural Network**, The 7th Conference on Applied Geometric Algebras in Computer Science and Engineering 2018, Accepted.

Referencias bibliográficas

- [1] S. Lee, S. Yun, J.-H. Nam, *et al.*, “A review on dark channel prior based image dehazing algorithms,” *EURASIP Journal on Image and Video Processing* **2016**(1), 4 (2016).
- [2] C. Kim, H. Zimmer, Y. Pritch, *et al.*, “Scene reconstruction from high spatio-angular resolution light fields,” *ACM Transactions on Graphics (TOG)* **32**(4), 73:1—73:12 (2013).
- [3] R. Fattal, “Dehazing using color-lines,” *ACM Transactions on Graphics (TOG)* **34**(1), 13:1—13:14 (2014).
- [4] B. Li, W. Ren, D. Fu, *et al.*, “Benchmarking Single-Image Dehazing and beyond,” *IEEE Transactions on Image Processing* (2019).
- [5] R. C. Gonzalez and R. E. Woods, *Digital Image Processing (3rd Edition)*, Prentice-Hall, Inc., Upper Saddle River, NJ, USA (2006).
- [6] J.-P. J.-P. Tarel and N. Hautiere, “Fast visibility restoration from a single color or gray level image,” in *IEEE International Conference on Computer Vision (ICCV)*, **1**, 2201–2208, IEEE, (Kyoto, Japan) (2009).
- [7] K. He, J. Sun, and X. Tang, “Single image haze removal using dark channel prior,” *IEEE Transactions on Pattern Analysis and Machine Intelligence* **33**(12), 2341–2353 (2010).
- [8] J. Pang, A. Oscar, and G. Zheng, “Improved single image dehazing using guided filter,” in *Proceedings of the APSIPA Annual Summit and Conference (APSIPA ASC)*, **1**, 1–4, (Xián, China) (2011).
- [9] K. B. Gibson, D. T. Vĩ, and T. Q. Nguyen, “An investigation of dehazing effects on image and video coding,” *IEEE transactions on image processing : a publication of the IEEE Signal Processing Society* **21**(2), 662–73 (2012).
- [10] Q. Zhu, J. Mai, and L. Shao, “A fast single image haze removal algorithm using color attenuation prior,” *IEEE Transactions on Image Processing* **24**, 3522–3533 (2015).

- [11] D. Berman, T. Treibitz, and S. Avidan, “Non-local image dehazing,” in *The IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, (2016).
- [12] W. Ren, S. Liu, H. Zhang, *et al.*, “Single image dehazing via multi-scale convolutional neural networks,” in *Computer Vision – ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11-14, 2016, Proceedings, Part II*, B. Leibe, J. Matas, N. Sebe, *et al.*, Eds., 154–169, Springer International Publishing, Cham (2016).
- [13] B. Cai, X. Xu, K. Jia, *et al.*, “DehazeNet: An end-to-end system for single image haze removal,” *IEEE Transactions on Image Processing* **25**(11), 5187–5198 (2016).
- [14] B. Li, X. Peng, Z. Wang, *et al.*, “AOD-Net: All-in-One Dehazing Network,” in *Proceedings of the IEEE International Conference on Computer Vision*, **2017-Octob**, 4780–4788 (2017).
- [15] K. He, J. Sun, and X. Tang, “Single image haze removal using dark channel prior,” *IEEE transactions on pattern analysis and machine intelligence* **33**(12), 2341–2353 (2011).
- [16] A. Galdran, “Image dehazing by artificial multiple-exposure image fusion,” *Signal Processing* **149**, 135–147 (2018).
- [17] L. J. Cox, “Optics of the atmosphere-scattering by molecules and particles,” *Optica Acta: International Journal of Optics* **24**(7), 779 (1977).
- [18] L. G. Shapiro and G. C. Stockman, *Computer Vision*, Prentice Hall (2005).
- [19] R. T. Tan, “Visibility in bad weather from a single image,” in *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, **1**, 1–8, (Anchorage, USA) (2008).
- [20] H. Zhang, Q. Liu, F. YANG, *et al.*, “Single image dehazing combining physics model based and non-physics model based methods,” *Journal of Computational Information Systems (IJCA)* **9**(4), 1623–1631 (2013).
- [21] S. Salazar-Colores, *Procesamiento de imágenes orientado al Dehazing*. PhD thesis, Universidad de Guanajuato (2015).
- [22] J.-H. Kim, J.-Y. Sim, and C.-S. Kim, “Single image dehazing based on contrast enhancement,” in *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, **1**, 1273–1276, (Prague, Czech) (2011).
- [23] C.-Y. Lien, F.-J. Yang, and C.-C. Huang, “An efficient image dehazing method,” in *International Conference on Genetic and Evolutionary Computing (ICGEC)*, **6**, 348–351, (Kitakushu, Japan) (2012).

- [24] G. Wang, G. Ren, L. Jiang, *et al.*, “Single image dehazing algorithm based on sky region segmentation,” *Information Technology Journal* **12**(6), 1168–1175 (2013).
- [25] L. Schaul, C. Fredembach, and S. Susstrunk, “Color image dehazing using the near-infrared,” in *IEEE International Conference on Image Processing (ICIP)*, **1**, 1629–1632, (Cairo, Egypt) (2009).
- [26] J. Kopf, B. Neubert, B. Chen, *et al.*, “Deep photo: Model-based photograph enhancement and viewing,” *ACM Transactions on Graphics (TOG)* **27**(5), 116:1–116:10 (2008).
- [27] Q. Liu, H. Zhang, M. Lin, *et al.*, “Research on image dehazing algorithms based on physical model,” in *International Conference on Multimedia Technology (ICMT)*, **2**, 467–470, (Hangzhou, China) (2011).
- [28] X. Wang, X. Jin, G. Xu, *et al.*, “A multi-scale decomposition based haze removal algorithm,” in *International Conference on Remote Sensing, Environment and Transportation Engineering (RSETE)*, **2**, 1–4, (Nanjing, China) (2012).
- [29] P. Carr and R. Hartley, “Improved single image dehazing using geometry,” in *Digital Image Computing: Techniques and Applications (DICTA)*, **1**, 103–110, (Melbourne, Canada) (2009).
- [30] Y. Y. Schechner, S. G. Narasimhan, and S. K. Nayar, “Instant dehazing of images using polarization,” in *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR)*, **16**, I——325, (Kauai, USA) (2001).
- [31] W. Jin, Z. Mi, X. Wu, *et al.*, “Single image de-haze based on a new dark channel estimation method,” in *IEEE International Conference on Computer Science and Automation Engineering (CSAE)*, **2**, 791–795, (Zhangjiajie, China) (2012).
- [32] R. Fattal, “Single image dehazing,” in *ACM Transactions on Graphics (TOG)*, **27**, 72:1–72:9, (New York, USA) (2008).
- [33] R. He, Z. Wang, H. Xiong, *et al.*, “Single image dehazing with white balance correction and image decomposition,” in *International Conference on Digital Image Computing Techniques and Applications (DICTA)*, **1**, 1–7, (Fremantle, Australia) (2012).
- [34] X. H. Xie, C. Ma, X. F. Yu, *et al.*, “Liver image segmentation using Improved Watershed Method,” *Applied Mechanics and Materials* **58**, 1311–1316 (2011).
- [35] Y. Gao, H.-M. Hu, S. Wang, *et al.*, “A fast image dehazing algorithm based on negative correction,” *Signal Processing* **103**(1), 380–398 (2014).
- [36] H. K., S. J., and T. X., *Single image haze removal using dark channel prior. Single image haze removal using dark channel prior.* PhD thesis (2010).

- [37] C. Ancuti, C. Ancuti, C. Hermans, *et al.*, “A fast semi-inverse approach to detect and remove the haze from a single image,” in *Computer Vision (ACCV), Lecture Notes in Computer Science* **6493**, 501–514, Springer Berlin Heidelberg (2011).
- [38] S. Fang, J. Zhan, Y. Cao, *et al.*, “Improved single image dehazing using segmentation,” in *IEEE International Conference on Image Processing (ICIP)*, **1**, 3589–3592, (Hong Kong, China) (2010).
- [39] E. Matlin and P. Milanfar, “Removal of haze and noise from a single image,” in *Proc. SPIE*, **8296**, 82960T–82960T–12, (Burlingame, USA) (2012).
- [40] J.-H. H. Kim, W.-D. D. Jang, J.-Y. Y. Sim, *et al.*, “Optimized contrast enhancement for real-time image and video dehazing,” *J. Vis. Comun. Image Represent.* **24**(3), 410–425 (2013).
- [41] R. He, Z. Wang, Y. Fan, *et al.*, “Multiple scattering model based single image dehazing,” in *IEEE Conference on Industrial Electronics and Applications (ICIEA)*, **1**, 733–737, (Melbourne, Australia) (2013).
- [42] C.-H. Yeh, L.-W. Kang, M.-S. Lee, *et al.*, “Haze effect removal from image via haze density estimation in optical model,” *Opt. Express* **21**, 27127–27141 (2013).
- [43] X. Lu, G. Lv, and T. Lei, “Single image dehazing based on multiple scattering model,” in *IEEE International Conference on Signal Processing, Communications and Computing (ICSPCC)*, **1**, 239–244, (Guilin, China) (2014).
- [44] N. Gundawar and V. B. Baru, “Improved Single image dehazing by fusion,” *International Journal of Research in Engineering and Technology (IJRET)* **3**(5), 432–437 (2014).
- [45] Z. Shi, J. Long, W. Tang, *et al.*, “Single image dehazing in inhomogeneous atmosphere,” *Optik - International Journal for Light and Electron Optics* **125**(15), 3868–3875 (2014).
- [46] X. Zhu, Y. Li, and Y. Qiao, “Fast single image dehazing through Edge-Guided interpolated filter,” in *International Conference on Machine Vision Applications (MVA)*, **1**, 443–446, (Tokyo, Japan) (2015).
- [47] J.-B. Wang, N. He, L.-L. Zhang, *et al.*, “Single image dehazing with a physical model and dark channel prior,” *Neurocomputing* **149**, Part, 718–728 (2015).
- [48] Y. Song, H. Luo, B. Hui, *et al.*, “An improved image dehazing and enhancing method using dark channel prior,” in *Control and Decision Conference (CCDC)*, **1**, 5840–5845, (Qingdao, China) (2015).
- [49] K. T. Park, Y. M. Kim, and Y. S. Moon, “An efficient dehazing method for edge enhancement by using entropy-map,” in *IEEE International Conference on Consumer Electronics (ICCE)*, **1**, 362–363, (Las Vegas, USA) (2015).

- [50] Y.-H. Lai, Y.-L. Chen, C.-J. Chiou, *et al.*, “Single-image dehazing via optimal transmission map under scene priors,” *IEEE Transactions on Circuits and Systems for Video Technology (CSVT)* **25**, 1–14 (2015).
- [51] Z. Ling, S. Li, Y. Wang, *et al.*, “Adaptive transmission compensation via human visual system for efficient single image dehazing,” *The Visual Computer* , 1–10 (2015).
- [52] Z. Li, J. Zheng, W. Yao, *et al.*, “Single image haze removal via a simplified dark channel,” in *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, **1**, 1608–1612, (South Brisbane, Australia) (2015).
- [53] J. Li, H. Zhang, D. Yuan, *et al.*, “Single image dehazing using the change of detail prior,” *Neurocomputing* **156**, 1–11 (2015).
- [54] W. Wang, W. Li, Q. G. W. Wang, *et al.*, “Multiscale single image dehazing based on adaptive Wavelet fusion,” *Mathematical Problems in Engineering* **1**(14), 14 (2015).
- [55] A. Kumari, S. Sahdev, and S. K. Sahoo, “Improved single image and video dehazing using morphological operation,” in *International Conference on VLSI Systems, Architecture, Technology and Applications (VLSI-SATA)*, **1**, 1–5, (Bangalore, India) (2015).
- [56] B. Huo, F. Yin, and B. Polytechnic, “Image dehazing with Dark Channel Prior and novel estimation model,” *International Journal of Multimedia and Ubiquitous Engineering* **10**(3), 13–22 (2015).
- [57] G. Ge, Z. Wei, and J. Zhao, “Fast single-image dehazing using linear transformation,” *Optik - International Journal for Light and Electron Optics* **126**(21), 3245–3252 (2015).
- [58] Q. Zhu, J. Mai, Z. Song, *et al.*, “Mean shift-based single image dehazing with re-refined transmission map,” in *IEEE International Conference on Systems, Man and Cybernetics (SMC)*, **1**, 4058–4064, (San Diego, USA) (2014).
- [59] W. Jiang, M. Ji, X. Huang, *et al.*, “An improved dehazing algorithm of aerial high-definition image,” **9796**, 97962T–9796–9 (2016).
- [60] C.-H. Xie, W.-W. Qiao, Z. Liu, *et al.*, “Single image dehazing using kernel regression model and dark channel prior,” *Signal, Image and Video Processing* **11**, 705–712 (2017).
- [61] M. Zhu and B. He, “Dehazing via graph cut,” *Optical Engineering* **56**, 113105–113111 (2017).

- [62] C. O. C. O. Ancuti, C. O. C. O. Ancuti, and P. Bekaert, “Effective single image dehazing by fusion,” in *IEEE International Conference on Image Processing (ICIP)*, **1**, 3541–3544, (Hong Kong, China) (2010).
- [63] S. Fang, X. Xia, X. Huo, *et al.*, “Image dehazing using polarization effects of objects and airlight,” *Optics Express* **22**(16), 19523 (2014).
- [64] K. Tang, J. Yang, and J. Wang, “Investigating haze-relevant features in a learning framework for image dehazing,” in *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, **1**, 2995–3002, (Columbus, USA) (2014).
- [65] B. Li, W. Ren, D. Fu, *et al.*, “RESIDE: A Benchmark for Single Image Dehazing,” *CoRR* **abs/1712.0** (2017).
- [66] S. Serikawa and H. Lu, “Underwater image dehazing using joint trilateral filter,” *Computers & Electrical Engineering* **40**(1), 41–50 (2014).
- [67] J. Zhang, Y. Cao, and Z. Wang, “Nighttime haze removal based on a new imaging model,” in *IEEE International Conference on Image Processing (ICIP)*, **1**, 4557–4561, (Paris, France) (2014).
- [68] D. Yang and J. Sun, “Proximal Dehaze-Net: A Prior Learning-Based Deep Network for Single Image Dehazing,” tech. rep.
- [69] H. Zhang and V. M. Patel, “Densely Connected Pyramid Dehazing Network,” tech. rep. (2018).
- [70] Z. Liu, B. Xiao, M. Alrabeiah, *et al.*, “Generic Model-Agnostic Convolutional Neural Network for Single Image Dehazing,” tech. rep.
- [71] F. Guo, J. Tang, and H. Peng, “A Markov random field model for the restoration of foggy images,” *International Journal of Advanced Robotic Systems* **11**(1), 92 (2014).
- [72] I. Yoon, S. Jeong, J. Jeong, *et al.*, “Wavelength-adaptive dehazing using histogram merging-based classification for UAV Images,” *Sensors* **15**(3), 6633 (2015).
- [73] D. Li, W. Jia, W. Sun, *et al.*, “Image enhancement focusing on hazy and non-uniform illumination images,” in *International Conference on Electronic Science and Automation Control (ESAC)*, **1**, 200–203, (Zhengzhou, China) (2015).
- [74] K. B. Gibson and T. Q. Nguyen, “Fast single image fog removal using the adaptive Wiener filter,” in *2013 IEEE International Conference on Image Processing*, **1**, 714–718, IEEE, (Melbourne, Canada) (2013).
- [75] M. Ding and R. Tong, “Efficient dark channel based image dehazing using quad-trees,” *Science China Information Sciences* **56**(9), 1–9 (2013).

- [76] N. Carlevaris-Bianco, A. Mohan, and R. M. Eustice, "Initial results in underwater single image dehazing," in *OCEANS 2010*, **1**, 1–8, (Seattle, USA) (2010).
- [77] L. Kratz and K. Nishino, "Factorizing Scene Albedo and Depth from a Single Foggy Image," in *IEEE International Conference on Computer Vision (ICCV)*, **1**, 1701–1708, (Kyoto, Japan) (2009).
- [78] X. Hu, L. Zhuo, and X. Li, "A moving objects based real-time defogging method for traffic monitoring videos," in *Digital Signal Processing (DSP), 2014 19th International Conference on*, **1**, 1–6, (Hong Kong, China) (2014).
- [79] L. Bai, Y. Wu, J. Xie, *et al.*, "Real time image haze removal on multi-core {DSP}," *Procedia Engineering* **99**(1), 244–252 (2015).
- [80] M. Sulami, I. Glatzer, R. Fattal, *et al.*, "Automatic recovery of the atmospheric light in hazy images," in *IEEE International Conference on Computational Photography (ICCP)*, **1**, 1–11, (Santa Clara, USA) (2014).
- [81] A. Kumari and S. K. Sahoo, "Real time visibility enhancement for single image haze removal," *Procedia Computer Science* **54**, 501–507 (2015).
- [82] M. Qi, Q. Hao, Q. Guan, *et al.*, "Image dehazing based on structure preserving," *Optik - International Journal for Light and Electron Optics* **126**(22), 3400–3406 (2015).
- [83] C. Zhen, S. Jihong, P. Roth, *et al.*, "Single image defogging algorithm based on dark channel priority," *Journal of Multimedia* **8**(4), 432–438 (2013).
- [84] N. Hautière, J. P. Tarel, D. Aubert, *et al.*, "Blind contrast enhancement assessment by gradient ratioing at visible edges," *Image Analysis and Stereology* **27**(2), 87–95 (2008).
- [85] F. Guo, J. Tang, and Z.-x. Cai, "Objective measurement for image defogging algorithms," *Journal of Central South University* **21**(1), 272–286 (2014).
- [86] X. Lv, W. Chen, and I.-F. Shen, "Real-Time dehazing for image and video," in *Computer Graphics and Applications (PG), 2010 18th Pacific Conference on*, **1**, 62–69, (Hangzhou, China) (2010).
- [87] C.-C. Lin, Y.-C. Lin, L.-T. Chen, *et al.*, "A novel fast dehazing algorithm in driver assistance system," in *IEEE Conference on Industrial Electronics and Applications (ICIEA)*, **1**, 1560–1563, (Beijing, China) (2011).
- [88] J.-H. Kim, W.-D. Jang, Y. Park, *et al.*, "Temporally x real-time video dehazing," in *IEEE International Conference on Image Processing (ICIP)*, **1**, 969–972, (Orlando, USA) (2012).

- [89] Y.-H. Shiau, H.-Y. Yang, P.-Y. Chen, *et al.*, “Hardware implementation of a fast and efficient haze removal method,” *IEEE Transactions on Circuits and Systems for Video Technology (CSVT)* **23**(8), 1369–1374 (2013).
- [90] Z. Liang, H. Liu, B. Zhang, *et al.*, “Real-time hardware accelerator for single image haze removal using dark channel prior and Guided filter,” *IEICE Electronics Express* **1**(1), 1–11 (2014).
- [91] X. Qian and L. Han, “Fast image dehazing algorithm based on multiple filters,” in *Natural Computation (ICNC), 2014 10th International Conference on*, **1**, 937–941, (Xiamen, China) (2014).
- [92] Y.-H. Shiau, P.-Y. Chen, H.-Y. Yang, *et al.*, “Weighted haze removal method with halo prevention,” *Journal of Visual Communication and Image Representation* **25**(2), 445–453 (2014).
- [93] T. Yu, I. Riaz, J. Piao, *et al.*, “Real-time single image dehazing using block-to-pixel interpolation and adaptive dark channel prior,” *Image Processing, IET* **9**(9), 725–734 (2015).
- [94] Y. Shang and Y. Meng, “Single image dehazing on mobile device based on GPU rendering technology,” in *International Conference on Artificial Life and Robotics (ICAROB 2015)*, **1**, 10–12, (Oita, Japan) (2015).
- [95] J. Mao, *Study on image dehazing with the self-adjustment of the haze degree*. PhD thesis, Muroran Institute of Technology (2015).
- [96] S. Kim, S. Park, and K. Choi, “A system architecture for real time traffic monitoring in foggy video,” in *Korea-Japan Joint Workshop on Frontiers of Computer Vision (FCV)*, **1**, 1–4, IEEE, (Mokpo, South Korea) (2015).
- [97] J. Hu, W. Chen, X. Li, *et al.*, “A haze removal module for multispectral satellite imagery,” in *Urban Remote Sensing Event, 2009 Joint*, **1**, 1–4, (Shanghai, China) (2009).
- [98] B. B. Xu, J. Li, Z. Y. Guan, *et al.*, “Research on Horizon Detection Algorithm Based on Dark Channel Prior for Images Captured by UAV,” *Applied Mechanics and Materials* **496-500**(1), 1853–1856 (2014).
- [99] X. Ji, J. Cheng, J. Bai, *et al.*, “Real-time enhancement of the image clarity for traffic video monitoring systems in haze,” in *International Congress on Image and Signal Processing (CISP)*, **1**, 11–15, (Dalian, China) (2014).
- [100] M. K. Saggi and S. Singh, “Different techniques to dehaze an underwater image,” *International Journal For Technological Research In Engineering* **2**(6), 566–568 (2015).

- [101] Q. Yue, H. Zheng, and C. Jiang, “Dark Pixels law-based image dehazing in UAV reconnaissance,” in *Proceedings of the 15th International Conference on Man-Machine-Environment System Engineering*, S. Long and B. S. Dhillon, Eds., *Lecture Notes in Electrical Engineering* **356**, 199–206, Springer Berlin Heidelberg, Xián, China (2015).
- [102] A. Movafeghi, E. Yahaghi, N. Mohammadzadeh, *et al.*, “Improvement of radiography images contrast and detection of the cracks in welds by dehazing algorithm,” in *Digital Industrial Radiology and Computed Tomography (DIR 2015)*, **1**, 1–5, (Ghent, Belgium) (2015).
- [103] M. Sonka, V. Hlavac, and R. Boyle, *Image processing, analysis, and machine vision second edition*, International Thomson (1999).
- [104] R. Szeliski, *Computer Vision: Algorithms and applications*, Springer (2011).
- [105] R. A. Española and RAE, *Real Academia Española*, Real Academia Española (2011).
- [106] D. H. Ballard and C. M. Brown, *Computer vision*, Prentice-Hall (1982).
- [107] I. T. Young, J. J. Gerbrands, and L. J. Van Vliet, *Fundamentals of image processing*, Delft University of Technology Delft, The Netherlands (1998).
- [108] A. Cantor, “Optics of the atmosphere—scattering by molecules and particles,” *IEEE Journal of Quantum Electronics (JQE)* **14**(9), 698–699 (1978).
- [109] H. Koschmieder, *Theorie der horizontalen Sichtweite: kontrast und Sichtweite*, Beitr{ä}ge zur Physik der freien Atmosph{ä}re, Keim & Nemnich (1925).
- [110] R. M. Haralick, S. R. Sternberg, and X. Zhuang, “Image analysis using mathematical morphology,” *IEEE Transactions on Image Processing (TIP)* **9**(4), 532–550 (1987).
- [111] F. Meyer and S. Beucher, “Morphological segmentation,” *Journal of visual communication and image representation (JVCIR)* **1**(1), 21–46 (1990).
- [112] H. J. A. M. Heimans and C. Ronse, “The algebraic basis of mathematical morphology. I. dilations and erosions,” *Computer Vision, Graphics, and Image Processing* **50**(3), 245–295 (1990).
- [113] P.-G. Ho and C. H. Chen, “2-D Time Series Model Based Support Vector Machine for Remote Sensing Image Segmentation,” in *International Joint Conference on Neural Networks (IJCNN)*, **1**, 316–320, (Orlando, USA) (2007).
- [114] L. Fausett, “Fundamentals of neural networks,” *Igarss 2014* **1**(1), 1–5 (2014).

- [115] Z. Wang, A. C. Bovik, H. R. Sheikh, *et al.*, “Image quality assessment: from error visibility to structural similarity,” *IEEE Transactions on Image Processing (TIP)* **13**(4), 600–612 (2004).
- [116] K. K. Singh and A. Singh, “A study of image segmentation algorithms for different types of images,” *International Journal of Computer Science Issues* **7**, 414–417 (2010).
- [117] Q. Huynh-Thu and M. Ghanbari, “Scope of validity of PSNR in image/video quality assessment,” *Electronics Letters* **44**(13), 800–801 (2008).
- [118] R. Dosselmann and X. Yang, “A comprehensive assessment of the structural similarity index,” *Signal, Image and Video Processing* **5**(1), 81–91 (2011).
- [119] K. He, J. Sun, and X. Tang, “Guided image filtering,” *IEEE Transactions on Pattern Analysis and Machine Intelligence* **35**(6), 1397–1409 (2013).
- [120] H. C. Burger, C. J. Schuler, and S. Harmeling, “Image denoising: Can plain neural networks compete with BM3D?,” in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2392–2399 (2012).
- [121] H. Hirschmuller and D. Scharstein, “Evaluation of Cost Functions for Stereo Matching,” in *Conference on Computer Vision and Pattern Recognition*, 1–8 (2007).
- [122] S. Jeong and S. Lee, “The single image dehazing based on efficient transmission estimation,” in *2013 IEEE International Conference on Consumer Electronics (ICCE)*, 376–377 (2013).
- [123] C. C. Yang, “Image enhancement by modified contrast-stretching manipulation,” *Optics and Laser Technology* **38**(3), 196–201 (2006).
- [124] A. Levin, D. Lischinski, and Y. Weiss, “A closed-form solution to natural image matting,” *IEEE Transactions on Pattern Analysis and Machine Intelligence* **30**(2), 228–242 (2008).
- [125] S. R. Deans, *The Radon transform and some of its applications*, Courier Corporation (2007).
- [126] D. Scharstein and R. Szeliski, “High-accuracy stereo depth maps using structured light,” *Computer Vision and Pattern Recognition, 2003. Proceedings. 2003 IEEE Computer Society Conference on* (2003).