



Universidad Autónoma de Ciudad Juárez

Instituto de Ingeniería y Tecnología

Departamento de Ingeniería Eléctrica y Computación

Maestría en Cómputo Aplicado

***“Algoritmo de clasificación aplicado en la identificación
de píxeles en imágenes a repintar para su adaptación a
personas con protanopia”***

Trabajo recepcional para obtener el grado de

Maestro en Cómputo Aplicado

Ing. Juan Bruno Castro Carrillo

Bajo la dirección del

Dr. Rogelio Florencia Juárez

Codirector de tesis:

Dr. Gilberto Rivera Zárate

Ciudad Juárez, Chihuahua 8 de junio de 2021

Tabla de contenido

Índice de tablas	3
Índice de figuras	4
Resumen	5
1 Deficiencia de Visión al Color	6
1.1 Tipos de daltonismo	7
1.2 Identificación del tipo de daltonismo	7
1.3 Causas del daltonismo	8
2 Trabajos relacionados	9
2.1 Herramientas de hardware para personas con daltonismo.....	9
2.2 Algoritmos de simulación y corrección.....	11
2.2.1 Simulación	11
2.2.2 Corrección	12
3 Planteamiento del problema	18
4 Objetivos.....	21
5 Impacto del proyecto	22
6 Metodología de desarrollo	25
6.1 Entrenamiento de la Máquina de Soporte Vectorial.....	26
6.2 Clasificación de píxeles en la Máquina de Soporte Vectorial	29
7 Resultados y discusiones	31
7.1 Implementación de un algoritmo dependiente de contenido basado en agrupamiento ..	31
7.2 Métricas de desempeño de la Máquina de Soporte Vectorial	33
7.3 Desempeño en paletas del test Ishihara	35
7.4 Desempeño en pinturas de arte digitalizadas.....	37
7.5 Tiempos de cómputo y desempeño en corrección de la imagen	39
8 Conclusiones y recomendaciones.....	43
Referencias	45

Índice de tablas

Tabla 1. Tiempos para encontrar los clústeres en un universo de 307,200 píxeles.....	33
Tabla 2. Resultados de la identificación de píxeles de la MSV en paletas del test de Ishihara.	35
Tabla 3. Selección de píxeles de la MSV y K-Means (K=4) en el test de Ishihara.	37
Tabla 4 Desempeño de MSV y K-Means (K=50) en pinturas de arte digitalizadas	38
Tabla 5. Tiempos de cómputo en segundos de K-Means y MSV.	39
Tabla 6. Comparación de corrección con distintas técnicas de selección de píxeles en la paleta #2 del test Ishihara.	40
Tabla 7. Comparación de corrección con distintas técnicas de selección de píxeles.	41
Tabla 8. Selección de píxeles, corrección y tiempo de cómputo en pintura de arte digitalizada con K-Means K=50 y la MSV.	42

Índice de figuras

Figura 1. Arquitectura de la propuesta del algoritmo de corrección.	25
Figura 2. Paleta #2 del test Ishihara y su versión simulada para protanopia propuesta en [17].	27
Figura 3. a) Paleta #3 del test Ishihara. b) Agrupamiento con $K=3$. c) Agrupamiento con $K=256$	33
Figura 4. Resultado de la selección de píxeles de la MSV en paletas del test de Ishihara. ...	34

Resumen

El daltonismo, también conocido como *Deficiencia de Visión al Color* (DVC) o ceguera al color, es una deficiencia en el sistema visual humano que afecta al 8% de la población masculina y al 0.4% de la población femenina mundial. Una persona con daltonismo puede llegar a confundir los colores presentes en el medio ambiente. El no poder percibir correctamente los colores ocasiona dificultades en ámbitos personales, académicos o laborales debido al amplio uso del color e incluso puede tener implicaciones graves en áreas como en la señalización de tráfico y en la codificación de colores usados en áreas médicas o eléctricas.

Aunque no existe una cura o un tratamiento para tratar el daltonismo, sí existen herramientas diseñadas para minimizar el impacto negativo de esta condición. La herramienta más exitosa para ayudar a personas con daltonismo a identificar mejor los colores son los algoritmos de corrección de color. Estos algoritmos realizan una corrección de los colores presentes en dispositivos como computadoras o celulares inteligentes, pero pueden ser utilizados para corregir imágenes que serán posteriormente impresas, como los mapas en un subterráneo.

Los algoritmos de corrección de color dependientes de contenido permiten a las personas con daltonismo identificar mejor los colores en medios digitales manteniendo una mayor naturalidad de la imagen en comparación con otros algoritmos de corrección de color. Esto lo logran realizando una evaluación de los píxeles y clasificando los píxeles que se deben corregir y los píxeles que se deben dejar intactos. Algunas de las técnicas implementadas en la literatura para realizar esta clasificación se basan en algoritmos de agrupamiento. En este documento se propone el uso de una Máquina de Soporte Vectorial (MSV) para la clasificación de píxeles con el fin de implementar un algoritmo de corrección de color dependiente de contenido. Se comparó el desempeño de la MSV al identificar píxeles a corregir contra un enfoque basado en agrupamiento que utiliza el algoritmo K-Means. Para efectos de realizar la comparación, ambas técnicas utilizaron el mismo método de corrección. Los resultados obtenidos dan evidencia que la MSV identificó mejor los píxeles que se debían corregir y en un menor tiempo de cómputo en comparación que el tiempo que tomó el agrupamiento con K-Means.

1 Deficiencia de Visión al Color

El daltonismo, también conocido como *Deficiencia de Visión al Color* (DVC) o ceguera al color, es una deficiencia en el sistema visual humano que no tiene cura ni tratamiento y que afecta al 8% de la población masculina y al 0.4% de la población femenina mundial [1][2].

Las personas que padecen daltonismo presentan dificultades para percibir ciertos colores y en casos extremos no pueden percibir ningún color. Algunos conjuntos de tonalidades fáciles de confundir para personas con esta deficiencia son: el rojo con el negro, el rojo con el verde, café oscuro con verde oscuro, algunos azules con púrpuras, rosas y rojos, rosas con grises, verdes con amarillos y naranjas, entre otros [3][5][30].

El color es percibido e interpretado por el sistema visual humano. Esta percepción se lleva a cabo cuando los ojos detectan las ondas de luz visible a través de células llamadas “cono” las cuales se encuentran detrás del ojo humano y son sensibles a tres tipos de ondas de luz de diferente longitud: ondas largas (L), ondas medias (M), y ondas cortas (S) [8]. Estas ondas tienen longitudes que se encuentran en un rango entre 380 nm y 700 nm. Las ondas largas se encuentran en un pico de sensibilidad de 557 nm, las ondas medias en 530 nm y las ondas cortas en 426 nm. Las ondas largas son percibidas por estas células como el color rojo (R), las ondas medias como el color verde (G), y las ondas cortas como el color azul (B) [1][7][9].

Cada persona tiene entre 6 y 7 millones de estas células “cono” de las cuales más del 90% de ellas detectan las ondas largas y medianas [6]. Estos fotorreceptores permiten percibir al ser humano los colores presentes a su alrededor. Sin embargo, si alguna de estas células presenta alguna anomalía, no se pueden percibir correctamente los colores. A esta anomalía en el sistema visual se le conoce como daltonismo.

No poder identificar adecuadamente los colores pone en desventaja a las personas con daltonismo al llevar a cabo actividades visuales básicas como la interpretación de señales de tráfico, selección de pintura, interpretación de gráficos estadísticos y visualización de imágenes digitales [3][4]. En ocasiones no identificar correctamente los colores puede tener implicaciones graves, como en la señalización de tráfico o señalización de material peligroso.

1.1 Tipos de daltonismo

Existen tres tipos de daltonismo directamente asociados a la falta de cualquiera de los tres tipos de fotorreceptores de luz: los fotorreceptores que perciben las ondas largas, medianas y cortas. Cuando sólo falta uno de los tres fotorreceptores, el daltonismo se define como *dicromático*. Si faltan dos de los tres fotorreceptores, se define como daltonismo *monocromático*. Sin embargo, si los tres tipos de cono están presentes, pero con alguna anomalía, el daltonismo se denomina *tritanomalía* o *tricromía anómala* [6].

De este último tipo de daltonismo se desprenden tres condiciones dependiendo del tipo de onda de luz que no se puede percibir correctamente. Si el cono anómalo es el que percibe la onda de luz larga se define el daltonismo como *protanopia*. Esta condición confunde principalmente el color rojo. Si el cono anómalo no percibe correctamente la onda de luz media se define la condición que padece como *deuteranopia* en la cual se confunde principalmente el color verde. Sin embargo, cuando el cono anómalo es el que percibe la onda corta el daltonismo se define como *tritanomalia* en la cual el color principal que se confunde es el azul y amarillo [8][10].

1.2 Identificación del tipo de daltonismo

Existen personas que tienen DVC y no lo saben o no conocen qué tipo de daltonismo padecen. Esto se debe a que el daltonismo se puede presentar de forma leve o severa y en el caso de la tricromía anómala puede ser que no se detecte hasta que se realiza un test de daltonismo [2]. Saber que se padece esta condición y el tipo de daltonismo puede ayudar a la persona afectada a identificar sus limitantes visuales y persuadirlos a tomar mejores decisiones como al elegir una carrera profesional o al aceptar alguna actividad laboral [13].

Detectar el daltonismo es importante para un mejor manejo de la deficiencia. Es conveniente que la persona esté consciente de su padecimiento para realizar una mejor toma de decisiones al realizar actividades en las que el color juega un rol primordial. Detectar el daltonismo es relativamente fácil gracias a exámenes diseñados para lograr identificar si una persona percibe correcta o incorrectamente las tonalidades de colores.

El test Ishihara es la prueba más conocida para detectar el daltonismo. Esta prueba consiste en el conjunto de 38 hojas o paletas las cuales incluyen patrones formados por distintos colores conflictivos, distinta luminancia y diferentes tamaños [6][9]. Estos patrones están

acomodados de tal manera que permitan mostrar una figura o número a una persona con visión normal, pero una figura o número diferente a una persona con DVC.

1.3 Causas del daltonismo

Existen dos maneras en las que se presenta el daltonismo en una persona. A la primera y más común se le conoce como Daltonismo Congénito. En este tipo de daltonismo la condición es heredada en los genes por alguno de los padres del portador. Las probabilidades de que alguna persona padezca daltonismo si alguno de sus padres le heredó la condición es de 25% hasta un 100% [3]. Esta condición también se puede presentar debido a alguna lesión en el ojo o como consecuencia de alguna enfermedad [6][9]. A este tipo de daltonismo se le conoce como Daltonismo Adquirido.

Según la Asociación de Optometría Americana, el Daltonismo Adquirido puede presentarse en personas que padezcan diabetes, glaucoma, esclerosis múltiple, trastornos quiasmáticos, estrías angioides, degeneración corioidea, y otras condiciones [2][4]. El Daltonismo Adquirido también puede ser ocasionado por aspectos como medicación, lesiones, inflamación en el ojo, cataratas, e incluso simplemente por envejecimiento [5][9][13]. El Daltonismo Adquirido es poco estudiado, sin embargo, se considera que es común en personas mayores de 40 años. Aunque no existen muchos estudios sobre este tipo de daltonismo, se considera que su prevalencia puede ser común.

El Daltonismo Congénito se presenta desde el nacimiento, es estable durante el crecimiento, afecta a ambos ojos y a todo el rango de visión. En contraste, el Daltonismo Adquirido puede presentarse de manera progresiva o regresiva con la edad, puede afectar sólo a un ojo o ambos, y puede afectar incluso sólo una parte del rango de visión [9].

2 Trabajos relacionados

Aunque no existe una cura o un tratamiento para el daltonismo, sí existen herramientas diseñadas para minimizar el impacto negativo de esta condición. Estas herramientas pueden ser de hardware o software. Las herramientas de hardware consisten en filtros o lentes especializados y buscan ayudar a las personas con daltonismo a percibir los colores en el medio ambiente. Por otro lado, las herramientas de software ayudan a percibir mejor los colores específicamente en dispositivos como computadoras o celulares inteligentes. Ambas herramientas buscan mejorar la experiencia de visualizar colores para una persona con DVC. En las siguientes secciones se describen estas herramientas.

2.1 Herramientas de hardware para personas con daltonismo

Las herramientas de hardware orientadas a ayudar a las personas con daltonismo se componen principalmente de lentes o filtros especializados. El primer filtro propuesto para personas con esta deficiencia fue presentado en 1817 y desde entonces los filtros han sido investigados como una opción para mejorar la percepción de colores en personas con esta condición.

Los filtros para daltonismo están diseñados para resaltar los colores al incrementar la luminosidad, saturación e incluso algunos buscan modificar la amplitud de ondas de luz visibles específicas. Un ejemplo de estos filtros son los filtros del lente X-Chrom patentado en 1971 que oscurece los colores amarillo y verde y que hace los naranjas un poco más oscuros para permitir a tricromatas y dicromatas percibir mejor el rojo. En un estudio con 16 participantes se obtuvieron buenos resultados al probarlos con el test de daltonismo AO HRR (Hardy-Rand-Rittler) Pseudoisocromatico, pero no hubo mejora cuando los participantes realizaron el test de daltonismo 100-Hue [2][19].

En 1996 se desarrollaron los lentes de contacto ChromaGen que cuentan con filtros de diferentes colores que van desde el rojo hasta el violeta. Estos lentes fueron probados en 14 personas con DVC quienes realizaron tres pruebas de daltonismo: Ishihara, Farnsworth D-15 y Farnsworth Lantern. Al haberlos usado por dos semanas, las personas con DVC mejoraron sus resultados en el test Ishihara y Farnsworth D-15 en comparación con los resultados registrados antes de usar los lentes. Sin embargo, registraron poca visión en ambientes con poca luz debido a que los lentes eran oscuros. El autor concluyó que, aunque

los lentes ayudaban a discriminar mejor los colores, no realizaban una verdadera percepción de color y que tendrían serias implicaciones si se prescribían a personas que dependen de la visión de color en su profesión [24].

En 2019 se desarrollaron otros lentes para daltonismo llamados Eye-Eye Lens. Los filtros de estos lentes cuentan con nanopartículas que proveen un rango de luz visible específico para la corrección de daltonismo. Estos lentes fueron probados en 19 personas con DVC al realizarles la prueba del test Ishihara. El autor de estos lentes menciona que los resultados fueron similares o mejor a los de los lentes ChromaGen descritos en el párrafo anterior [29].

Otros lentes para personas con DVC son los lentes EnChroma. Estos lentes cuentan con filtros de distintas tonalidades como azul claro y gris oscuro. La compañía que los comercializa menciona que los filtros cuentan con una tecnología que selectivamente filtra partes del espectro visual dependiendo la onda de luz que se busque corregir. Los lentes EnChroma buscan separar las ondas de luz medianas de las ondas de luz largas para que no se puedan confundir y el observador pueda percibir una diferencia. Sin embargo, estas declaraciones no han sido respaldadas en pruebas clínicas [2].

Un estudio realizado en 2017 llevó a cabo dos pruebas a los lentes EnChroma para examinar la transmisión y filtrado de las ondas de luz y su efecto en personas con visión normal, así como determinar si los lentes permiten a las personas con DVC ver más colores en comparación con otros filtros para daltonismo. Los resultados obtenidos del estudio determinaron que los lentes EnChroma no mejoraban los resultados en la prueba digital del test Ishihara, ColorDx, y no había mejora en la discriminación de color en la prueba Farnsworth 100-Hue. Además, se registró que el filtro rojo de los lentes EnChroma empeoraba los resultados del test [2].

En el mismo estudio se describen los resultados de otras investigaciones sobre los lentes EnChroma. En 2016 se probaron los lentes EnChroma en dos personas con esta deficiencia y una persona con visión normal quienes registraron mejoría en el contraste de los colores. En 2015 otra investigación destacó que los lentes EnChroma no tuvieron efecto significativo en 27 personas con daltonismo y que los lentes causaban baja discriminación de colores azul y amarillo. Estos estudios concluyeron que, aunque los lentes EnChroma

pueden agudizar los colores como los otros filtros de daltonismo, no permiten discriminar los colores independientemente de su intensidad.

En 2018 se propuso resolver las deficiencias de los lentes para daltonismo al desarrollar unos lentes de realidad aumentada que permitiera mejorar la percepción de color. Los ChromaGlasses no hacen uso de filtros especializados como otros lentes descritos anteriormente, sino que se basan en computación para la detección de colores, el procesamiento de los mismos, y la posterior presentación de los colores modificados al portador de los lentes. Este proceso se realiza en tiempo real y fue probado en 19 personas con DVC quienes registraron una mejora en los resultados de pruebas de daltonismo. Sin embargo, el algoritmo de corrección usado en el prototipo realiza un cambio de colores que, según el autor, pudiera ser intrusivo o parecer innatural, además de que los colores resultantes pudieran ya estar presentes en el rango de visión. El autor menciona que otros algoritmos de corrección más naturales no pudieron ser implementados en este prototipo [28].

2.2 Algoritmos de simulación y corrección

Dentro de las herramientas de software para mejorar la percepción al color en personas con daltonismo se encuentran algoritmos de simulación y de corrección. La simulación de daltonismo es una herramienta útil dirigida a personas con visión normal que permite detectar colores que la audiencia pudiera confundir en caso de padecer DVC. Los algoritmos de corrección están dirigidos a personas con daltonismo y buscan adaptar los colores en medios digitales para que puedan ser mejor percibidos.

2.2.1 Simulación

Existen métodos computacionales que permiten simular el daltonismo para conocer cómo perciben los colores las personas con este padecimiento. Estos métodos son utilizados en el procesamiento de documentos, interfaces de software, presentaciones, entre otros. Para simular el color, los métodos establecidos en la literatura toman como base el valor RGB original de un píxel. Este método de simulación propuesto por Brettel se detalla en la página 26 de este documento.

La simulación del daltonismo permite a las personas con visión normal entender cómo se ven los colores para las personas que padecen DVC. Esta simulación es útil para verificar

que el contenido creado por algún diseñador o expositor será bien percibido tanto por lectores con visión normal como por lectores con daltonismo. Al detectar estos colores confusos, el diseñador puede modificar el contenido generado ya sean gráficos, imágenes, artículos, etc., para que sea amigable a lectores con esta deficiencia. Algunos de estos ejemplos de herramientas de simulación de DVC son COBLIS, Vischeck o perfiles en Photoshop [5][12]. Estas herramientas son útiles para creadores de contenido o diseñadores conscientes de que alrededor de 4% de sus lectores padecen esta deficiencia. Al realizar esta comprobación, el diseñador genera contenido incluyente para personas con esta discapacidad [6][14].

2.2.2 Corrección

Los algoritmos de corrección de colores son la herramienta más exitosa para ayudar a las personas con daltonismo a identificar colores [11]. Estas herramientas son empleadas en medios digitales y buscan adaptar los colores para que sean mejor percibidos por personas con DVC. Esta adaptación es resultado de una corrección de los píxeles que componen el material digital. Los colores resultantes deben ser más fáciles de identificar por una persona con esta deficiencia que los colores originales de la imagen [7][8].

Los algoritmos de corrección pueden adaptar a personas con DVC diversos tipos de material como gráficos estadísticos, videos, fotografías, páginas web, software, pinturas de arte digitalizadas, entre otros. Además, ciertos algoritmos de corrección pueden realizar el cambio de colores en dispositivos en tiempo real. Otros algoritmos de corrección incluso pueden reemplazar los algoritmos de simulación usados por diseñadores ya que pueden adaptar los colores tanto para personas con DVC como personas con visión normal. Una desventaja de los algoritmos de simulación es que conforman un ciclo que requiere de un esfuerzo por parte del diseñador el cual consiste en: generar el material, verificar si los colores son amigables para la audiencia con esta deficiencia, modificar el material en caso de que no, y repetir este proceso hasta que el diseñador este satisfecho con el resultado. En cambio, los algoritmos de corrección realizan esta modificación de una manera más automática.

Los algoritmos de corrección se dividen en dos tipos: los algoritmos dependientes de contenido y los independientes de contenido. La característica de los algoritmos

independientes de contenido es que corrigen todos los píxeles presentes en la imagen sin importar si el color original es confuso o no. En contraste, los algoritmos dependientes de contenido evalúan los colores de la imagen y sólo corrigen los colores confusos para adaptarlos a personas con DVC.

Los dos tipos de algoritmos de corrección presentan ventajas y desventajas. Por un lado, los independientes de contenido son tan rápidos que pueden realizar el procesamiento en tiempo real, pero su desventaja es que modifican colores que no necesitaban modificarse e incluso los colores resultantes pueden ser nuevos colores confusos incluso para personas con visión normal. Esto puede ser un problema cuando en el público objetivo pueden estar presentes tanto personas con DVC como personas con visión normal, como al procesar un mapa que será colocado en una estación de subterráneo o al procesar una presentación de diapositivas que será presentada a una clase.

Por otro lado, los algoritmos dependientes de contenido son más precisos modificando únicamente los colores confusos y dejando intactos los que son percibidos correctamente, procurando así mantener la naturalidad de la imagen original, sin embargo, estos algoritmos pueden consumir más tiempo de cómputo. Todavía hay una búsqueda abierta de un método de corrección para adaptar el contenido de la imagen de una manera óptima para todos los grupos de usuarios con DVC [10].

Los algoritmos dependientes de contenido evalúan los píxeles de la imagen. Esta evaluación se realiza previa al proceso de corrección y tiene como objetivo:

- 1) Identificar los píxeles confusos de la imagen para usuarios con daltonismo.
- 2) Identificar el tipo de corrección que se debe implementar al píxel.

Al aplicar esta evaluación, se busca dejar intactos los colores que no presentan confusión para las personas con daltonismo y así mantener una mayor naturalidad de la imagen original. La evaluación de píxeles es un proceso importante en los algoritmos dependientes de contenido. Esta evaluación se justifica debido a que existen colores que no presentan ninguna confusión para personas con daltonismo y por lo tanto no necesitan ser modificados. Los algoritmos de corrección pueden tomar en cuenta varios criterios para evaluar si un píxel contiene un color confuso [10]:

- 1) El color original del píxel, esta es la principal característica que se toma en cuenta para evaluar si es confuso o no.
- 2) Los colores presentes en el resto de la imagen para determinar la diversidad de tonalidades presentes en la imagen.
- 3) La posición del píxel en la imagen, para determinar los colores de los píxeles aledaños o si la posición es clave para mantener la naturalidad de la imagen.

Esta evaluación se puede realizar a todos los píxeles de la imagen uno por uno, lo cual pudiera consumir mayor tiempo y esfuerzo de cómputo, o implementar alguna técnica como agrupamiento [10][11]. A continuación, se detallan algunos algoritmos dependientes de contenido y posteriormente se presentan algoritmos que implementen la técnica de agrupamiento para realizar la evaluación de píxeles. Se encontró en la literatura que esta técnica es la más usada en los algoritmos dependientes de contenido.

Anagnostopoulos et. al. fueron de los primeros en proponer los algoritmos dependientes de contenido [17]. Su primera propuesta consiste en comparar los píxeles de la imagen original y los píxeles de la versión simulada de la misma imagen. Esta comparación tenía como objetivo detectar los píxeles que son diferentes los cuales se considerarían como píxeles confusos. A los píxeles confusos se les aplicaría una corrección mientras que los que no fueran confusos se dejarían intactos. En la última etapa del algoritmo se implementó un proceso iterativo para evitar que los colores resultantes obtenidos se encuentren presentes en la imagen original. De esta manera se busca que los nuevos colores no generen confusión en la imagen resultante. Esta propuesta fue evaluada en imágenes de arte digitalizadas y estaba dirigida a personas con protanomalía. El algoritmo fue desarrollado en Matlab donde cada iteración del algoritmo en una imagen de 300x300 píxeles duraba poco más de 2 segundos. El autor no especifica la cantidad de iteraciones que era necesario realizar.

Huang & Wang realizaron propuestas de algoritmos dependientes de contenido dirigidos a personas con deuteranomalía y protanomalía [20][22]. Al igual que otros algoritmos dependientes de contenido buscaban preservar los colores naturales lo más posible. La primera propuesta realizaba la corrección a todos los píxeles presentes en la imagen y estaba fuertemente inclinada en cálculos matemáticos para la obtención de los colores

resultantes. Aun así, registraron que la corrección mantenía mayor naturalidad que otros algoritmos propuestos en esa época. Una segunda propuesta de Wang implementa un Mapa Autoorganizado para construir un espacio de color. Los usuarios con daltonismo que evaluaron esta propuesta mencionaron que el algoritmo sí les permitía discriminar mejor los colores. Sin embargo, los autores registraron que los colores resultantes pueden parecer innaturales para personas con visión normal y que el Mapa Autoorganizado puede ocasionar discontinuidad de color en tonalidades con poco contraste.

Anagnostopoulos realizó una segunda propuesta de algoritmo dependiente de contenido. Esta segunda propuesta se basa en el agrupamiento de los colores presentes en la imagen. El agrupamiento propuesto tiene como objetivo dividir el conjunto de píxeles en clústeres y clasificar los clústeres en dos categorías: clústeres confusos y no confusos. Este algoritmo estaba dirigido para personas con protanomalía. Una vez que se clasificaron los clústeres se definieron los siguientes objetivos para el algoritmo:

1. Los colores en los clústeres no confusos deben dejarse intactos.
2. Los colores en clústeres confusos deben ser corregidos.
3. Ningún color resultante debe ser igual que uno de los clústeres no confusos para personas con protanopia.

Con este último término se propone un algoritmo que garantice que los nuevos colores no coincidan con los de la primera categoría. Este algoritmo también fue probado en pinturas de arte en su versión digital. Para finalizar, en este algoritmo se realiza una iteración de modo opcional para verificar que no se rompa alguno de los tres términos anteriores.

El algoritmo de agrupamiento utilizado en esta propuesta es Fuzzy C-means y fue implementado con el objetivo de evitar evaluar cada color presente. El autor menciona que eligieron de manera empírica el número de clústeres en $C=100$ [18] y no menciona los tiempos de cómputo al procesar una imagen en este algoritmo.

Huang & Wang realizaron otra propuesta de algoritmo dependiente de contenido. En esta propuesta se agrupan los colores de la imagen usando el Modelo de Mezcla Gaussiana. Los autores mencionan que definieron la cantidad de grupos usando el Principio de Longitud de Descripción Mínima. En los experimentos la cantidad de clústeres varía de 2 a 6 grupos.

Los autores mencionan que al algoritmo le toma menos de 5 segundos procesar una imagen de 300x300 píxeles [21].

Kuhn et. al. también propusieron un algoritmo dependiente de contenido que implementa agrupamiento. La propuesta está dirigida a personas con daltonismo dicromata y fue probado sobre imágenes de gráficos estadísticos [23][25]. El algoritmo busca elevar el contraste a través de tres pasos:

1. La cuantización de la imagen, es decir la obtención de los colores representativos de la imagen original.
2. La aplicación de un modelo mass-spring: esta técnica consiste en un conjunto de partículas (para esta implementación son los colores obtenidos de la cuantización) conectados a través de springs que se deforman al serles aplicadas una fuerza externa.
3. La obtención de los colores resultantes obtenidos a través de los colores optimizados con el modelo mass-spring.

Kuhn et. al. utilizaron el algoritmo de agrupamiento K-Means para la cuantización de la imagen con $K=64$, $K=128$ y $K=256$ clústeres [23]. El algoritmo fue probado en imágenes no naturales, es decir imágenes científicas y de información visual. Aunque sí se realizaron pruebas con imágenes naturales, sus usuarios prefirieron las imágenes sin corregir o las imágenes de otro algoritmo de corrección. El segundo algoritmo de corrección de Kuhn et. al. también implementa K-Means para una fase inicial de cuantización y su técnica buscaba elevar el contraste de imágenes científicas o de información visual. Sin embargo, los autores registraron escenarios en los que el algoritmo cambia colores que no era necesario corregir incluso en imágenes con pocas tonalidades [25].

Más recientemente, el agrupamiento con K-Means en algoritmos de corrección fue retomado por Milic et al [10]. En esta propuesta los autores mencionan que buscan mantener la naturalidad al restringir la intensidad de la corrección de los colores realizadas a cada clúster. Este algoritmo permite que los colores resultantes sean distinguibles de los no confusos, pero manteniendo la naturalidad de la imagen natural lo más posible. Otra característica definida por el autor es que el algoritmo puede llegar a ser modificado para permitir una corrección personalizada al grado de daltonismo de cada usuario. Los autores

mencionan que para imágenes del test Ishihara se utilizaron tres clústeres y para una imagen natural usaron cuatro clústeres.

El equipo de Anagnostopoulos realizó una tercera propuesta de corrección dependiente de contenido. El agrupamiento utilizado en esta propuesta es el de Fuzzy C-Means. El algoritmo consiste en dos fases: una cuantización de color basada en una modificación del algoritmo de Fuzzy Clustering, y una corrección iterativa a los colores obtenidos de la cuantización. La cantidad de grupos a encontrar lo definieron a través de prueba y error en $C=50$. Anagnostopoulos et. al. mencionan que su algoritmo puede ser mejorado al implementar otros enfoques de aprendizaje y corrección más efectivos para simulación de protanopia y adaptación de color. Los autores no mencionan los tiempos de cómputo al procesar alguna imagen.

Después de la revisión de los trabajos relacionados, se encontró que una de las desventajas de las técnicas de agrupamiento es que se debe definir previamente la cantidad de clústeres. Se considera una desventaja debido a que la cantidad óptima de clústeres es diferente para cada imagen [11]. Definir pocos clústeres puede que no sea lo suficientemente representativo de las tonalidades de la imagen. De igual manera, usar demasiados clústeres puede dar como resultado imágenes que no se vean naturales [21]. Definir la cantidad de clústeres ideal para cualquier imagen pudiera ser complicado de justificar y si se buscara encontrar esta cantidad por medio de otro cálculo pudiera incrementar aún más el tiempo de cómputo. En este proyecto se propone una técnica para la clasificación de píxeles que evita entrar en este dilema.

3 Planteamiento del problema

Identificar colores correctamente es una necesidad diaria para todas las personas. El color está presente en áreas personales, académicas y profesionales. Esto es debido a que psicológicamente el color genera una atracción y un estímulo en el cerebro que permite captar la atención de las personas y permite codificar información que asegura una mayor retención del mensaje. Sin embargo, las personas con DVC son más propensas a cometer errores o realizar actividades más lento cuando el color es un elemento principal en la tarea a realizar [5][6].

Esta dificultad tiene afectaciones negativas en la vida diaria de las personas que la padecen debido a que no pueden realizar actividades básicas correctamente si el color está involucrado. Algunos ejemplos cotidianos de este tipo de actividades son: combinar prendas de ropa, elegir fruta madura, interpretar gráficos estadísticos, decoración, deportes, etc. [4][11][30]. Sin embargo, la problemática se extiende más allá de lo cotidiano y puede presentarse al desempeñar competencias académicas y laborales.

Se ha registrado que las personas con DVC presentan dificultades al realizar actividades que pudieran tener implicaciones graves que pudieran poner en riesgo la seguridad de las personas como al interpretar señales de tráfico o al usar mapas de navegación [33][35]. Los profesionales del área médica que padecen DVC también han registrado dificultades en la codificación de colores utilizados en algunos instrumentos y dispositivos como en las agujas para inyectar, sistemas de administración de oxígeno, cinta de emergencia pediátrica, sistemas de vías respiratorias orofaríngeas e instrumentos dentales de endodoncia [34][36]. Considerando que el 4% de la población puede padecer esta deficiencia, es importante buscar alternativas para que las personas con DVC interpreten mejor los colores [10].

Un porcentaje considerable de la población mundial tiene algún tipo de daltonismo. Esta deficiencia se encuentra más presente en la población masculina que en la femenina. Al menos 8% de la población masculina mundial la padece. En contraste, solo el 0.4% de la población femenina tiene daltonismo. Esto significa que al menos 300 millones de personas a nivel global lo padecen [6][10].

Las personas con daltonismo encuentran el color mucho más hoy en día debido a que el color es usado para presentar información y generar comunicación en dispositivos como computadoras o celulares, e incluso hasta relojes inteligentes [8]. En la literatura mencionan que “el color genera una atracción psicológica y un estímulo cerebral abundante. En incontables casos captura la atención, asegura una retención de la información y, en conclusión, incrementa el alcance del mensaje.” [5].

Al menos 60% de usuarios con daltonismo reportan problemas al leer gráficos, diapositivas, reportes de clima, análisis financieros, mapas y documentos impresos a color. Sin embargo, a pesar de que un considerable porcentaje de la población mundial lo padece, de que no existe alguna cura ni tratamiento, y que las personas que lo padecen pueden cometer errores en ámbitos académicos y profesionales, el daltonismo no es considerado una discapacidad [8].

La habilidad para identificar colores se convierte en una necesidad cuando el color es usado como un atributo clave para transmitir un mensaje. A continuación, se detallan algunas actividades en las que el color juega un rol importante [5]:

1. Actividades comparativas: En este tipo de actividades se comparan o diferencian colores con un objetivo preciso. Un ejemplo de este tipo de actividad es al elegir las prendas de un atuendo.
2. Actividades connotativas: Este tipo de actividades sirven para decodificar información como en las señales de tráfico o en la codificación de códigos en el área médica.
3. Actividades denotativas: En estas actividades el color es usado para resaltar elementos u organizar información. Un ejemplo en donde esta actividad se lleva a cabo es al leer mapas de subterráneo.
4. Actividades con fines estéticos: este tipo de actividades buscan causar alguna emoción o un humor específico en el usuario.

La problemática que presenta el daltonismo se ha amplificado en las últimas décadas con el crecimiento de la tecnología multimedia. Este crecimiento de tecnología ha hecho más cotidiano el uso de dispositivos como computadoras o celulares inteligentes dentro del aula o en espacios laborales. Es en estos espacios en los que se aprovecha el color como un

vehículo de comunicación: para resaltar, comparar, o codificar algún mensaje. Sin embargo, para las personas que padecen DVC es complicado y en ocasiones imposible entender un mensaje en el que se depende de interpretar un color. Al incrementarse la problemática se incrementa la necesidad de percibir el color de manera correcta [5][11].

4 Objetivos

En esta sección se describe el objetivo general y los objetivos específicos de este proyecto. A continuación, se plantea el objetivo general:

“Desarrollar un algoritmo dependiente de contenido que sea capaz de identificar los píxeles a repintar en imágenes para su adaptación a personas con deficiencia de visión al color de tipo protanopia”.

Los objetivos específicos de este proyecto se listan a continuación:

1. Implementar la simulación de daltonismo de tipo protanopia en base a la literatura.
2. Crear un dataset de imágenes que contenga tanto la imagen original como la imagen simulada a protanopia.
3. Entrenar una Máquina de Soporte Vectorial para la identificación de píxeles que necesitan ser corregidos para adaptarse a una persona con protanopia.
4. Implementar una técnica de corrección de la literatura.
5. Evaluar el proceso de selección de píxeles propuesto en este trabajo contra algún algoritmo de agrupamiento.

5 Impacto del proyecto

A nivel global, cada vez es más común el uso de dispositivos tanto computadoras como celulares para uso cotidiano, académico y laboral. Tan solo en el caso de celulares inteligentes se estima que para el 2020 había más de 3.6 billones de dispositivos en el mundo y podrían superar los 4 billones para 2023 [31]. El incremento de uso y el avance de la tecnología ha ofrecido a la sociedad dispositivos con una mayor resolución lo que motiva el uso de color en estos medios.

En ámbitos académicos el daltonismo impacta negativamente a estudiantes con esta deficiencia. Sin embargo, programas de ingeniería y tecnología comúnmente no toman en cuenta esta discapacidad. Es común que los instructores y profesores no adapten sus materiales a estudiantes con esta deficiencia. Esto es incongruente debido a que, al impartir una clase, el objetivo principal es que el máximo número de estudiantes logren comprender el material. Sin embargo, si el profesor o instructor no sufre de DVC existe un potencial de desarrollar material para su clase que sea difícil de entender e interpretar para un estudiante con daltonismo [6][14]. Este problema puede ser aún mayor en clases de modalidad virtual, donde los medios digitales como diapositivas y documentos son ampliamente utilizados sin importar la materia. Aunque el uso de estos medios digitales no solo se limita a este tipo de modalidad, sino a cualquiera donde se usen medios digitales. Es por esto, que algoritmos de corrección de color pueden resultar particularmente útiles al procesar material de clase tanto para educadores como para estudiantes.

A continuación, se enlistan áreas de oportunidad específicas en las que los algoritmos de corrección de color pudieran ser implementados para ayudar a estudiantes con daltonismo quienes han experimentado estas limitantes en clases como Química o Biología.

- Diferenciar los colores de soluciones químicas y resolver exámenes prácticos.
- Identificar metales por el color de la flama producida cuando el metal se quema.
- Correcta lectura bajo microscopio.
- Llevar a cabo disecciones.
- Identificar especies de plantas o insectos correctamente.
- Entender diagramas a color de la literatura.

La literatura ha registrado que los estudiantes con daltonismo han sido incapaces de realizar estas actividades. Al menos 1 de cada 12 estudiantes masculinos padece DVC, lo que significa que probablemente haya personas con esta deficiencia en cualquier grupo de clase o en alguna conferencia. Si el orador de la clase o de la exposición hace uso del color para su presentación y no toma en cuenta esta condición, los asistentes que padezcan daltonismo potencialmente no entenderán algunos mensajes que se les desee transmitir [12]. Por lo que el uso de algoritmos de corrección pudiera evitar este escenario.

El uso de gráficos, imágenes y documentos no solo resulta útil para ayudar a captar la atención y codificar información, sino que, en algunos países como España, es obligatorio que programas de primaria, secundaria, y bachillerato los incluyan para asignaturas como matemáticas, física, química, biología y geología, historia, o en ciencias de la tierra y el medio ambiente [4].

En ámbitos universitarios, tanto estudiantes como investigadores se benefician si los gráficos son accesibles para las personas con DVC. Los investigadores lograrán que sea mayor el entendimiento de su trabajo si es inclusivo. De otra manera, se estaría excluyendo a algunos lectores, limitando también la visibilidad de esos trabajos entre la comunidad científica [12].

En ámbitos laborales, los algoritmos de corrección pueden resultar particularmente útiles en áreas donde se use el color para presentar información. Por ejemplo, en el área de manufactura se generan señalamientos, instrucciones de trabajo y animaciones de procesos que se basan en la codificación con color para facilitar la comprensión del mensaje que se desea transmitir. En Asegurancia de Calidad se usa software con colores para indicar procesos y sus estados. En Electrónica el color es clave en resistores para indicar valores mientras que los arneses tienen colores para asignarle algún uso distinto. En la mayoría de los dispositivos eléctricos, especialmente para solución de errores técnicos, se usan LEDs de colores para indicar estados en los dispositivos. Las herramientas de software hacen amplio uso del color para navegar dentro del software. Incluso en áreas de negocios o finanzas se utiliza el color en gráficos o análisis de datos [6]. Por lo que el uso de algoritmos de corrección resultaría ampliamente útil para las personas con esta deficiencia al realizar actividades profesionales.

La visualización de datos es una herramienta ampliamente utilizada en otros sectores y profesiones como ingenieros, analistas de datos, analistas financieros, periodistas, diseñadores, investigadores, entre otros. Identificar correctamente los colores permitiría aliviar el impacto negativo que profesionales con daltonismo pudieran experimentar.

Aunque los algoritmos de corrección de color han sido implementados principalmente para procesar imágenes digitales en computadoras, se espera que con el avance de la tecnología y la miniaturización puedan ser implementados en lentes de realidad aumentada. Aportar al desarrollo de los algoritmos de corrección permitirá que en un punto lleguen a ser implementados en realidad aumentada y puedan ser usados en actividades en el mundo real tanto por profesionales o estudiantes, e incluso en ámbitos cotidianos como al cocinar o elegir prendas de vestir.

En el ámbito de la salud, se ha registrado en la literatura que médicos y odontólogos pueden cometer errores si no perciben correctamente los colores. Los médicos prestan atención a colores en superficies o debajo de la superficie para determinar fenómenos que pudieran estar presentando y realizar un diagnóstico acertado. Tal es el caso de la cianosis, ictericia, hematuria o hematoquecia que requieren de una observación en los cambios de tonalidades para un diagnóstico y tratamiento acertado [13]. En un estudio realizado a 40 doctores con DVC, se registró que la mayoría presentó dificultad para interpretar gráficas, diapositivas, medios impresos y códigos, así como para interpretar tiras reactivas de orina y sangre y otras dificultades al practicar su labor médica [30]. Es en estos escenarios donde los algoritmos de corrección pudieran tener un impacto positivo.

En los profesionales de la salud bucal, los odontólogos monitorean el color como un parámetro al tratar lesiones o en procedimientos restauradores en la mucosa oral, lengua, encía o paladar. Según la literatura, los médicos bucales que padecen algún grado de daltonismo cometen una mayor cantidad de errores en comparación con los odontólogos con visión normal. Por lo que implementar algún algoritmo de corrección pudiera ayudarles a realizar su labor.

6 Metodología de desarrollo

La arquitectura de la propuesta se presenta en la Figura 1 y se compone de cinco módulos. Un módulo tiene como objetivo crear un dataset de imágenes simuladas al daltonismo de tipo protanopia. Este módulo se representa en la Figura 1 como el elemento “Dataset de imágenes de entrenamiento”. Un segundo módulo utiliza este dataset para clasificar los píxeles como confusos o no confusos y así entrenar la Máquina de Soporte Vectorial. Este módulo se representa en la Figura 1 como el elemento “Entrenamiento”. Una vez entrenada la MSV, un tercer módulo se encarga de clasificar los píxeles de nuevas imágenes. Este módulo está representado en la Figura 1 como el elemento “Clasificación de píxel con la MSV”. La finalidad de implementar la MSV en los módulos de “Entrenamiento” y “Clasificación de píxel con la MSV” es mejorar la selección de píxeles confusos en comparación con otros algoritmos de corrección. El último módulo tiene como objetivo corregir los píxeles que la MSV haya clasificado como confusos y está representado en la Figura 1 como el elemento “Post-Procesamiento”. El elemento de la Figura 1 llamado “Pre-procesamiento” se refiere a la extracción de los píxeles de cualquier imagen a procesar.




Figura 1. Arquitectura de la propuesta del algoritmo de corrección.

Para el desarrollo de esta propuesta, se partió de una revisión de la literatura para conocer las herramientas que han sido desarrolladas para personas con DVC. En la literatura se encontró una consistencia en las declaraciones de que los algoritmos de corrección son la

herramienta más exitosa al ayudar a las personas con esta deficiencia al identificar mejor los colores. Sin embargo, fueron pocas las propuestas que se encontraron. La mayoría de la literatura de daltonismo se enfoca en el estudio de la deficiencia, su fisiología y su impacto en personas que la padecen. Los pocos trabajos que hablan de algoritmos de corrección se dividen en algoritmos dependientes de contenido e independientes de contenido. De los dependientes de contenido la principal técnica utilizada para seleccionar píxeles confusos es la de agrupamiento. Sin embargo, para el desarrollo de esta propuesta se buscó implementar una técnica que permitiera realizar una selección de píxeles que evitará predefinir alguna cantidad de clústeres a encontrar. La técnica propuesta es una Máquina de Soporte Vectorial. Las MSV son algoritmos que son usados en la clasificación de datos basándose en aprendizaje con ejemplos. Al entrenar la MSV con un conjunto de píxeles previamente clasificados como confusos se logra predecir la clasificación de un píxel nuevo.

6.1 Entrenamiento de la Máquina de Soporte Vectorial

La MSV se basa en un aprendizaje con ejemplos. Estos ejemplos se obtuvieron de la clasificación de píxeles confusos y no confusos en imágenes del test Ishihara. Para obtener estas clasificaciones se realizó la simulación a daltonismo de tipo protanopia propuesta por Brettel. Del total de 38 paletas del test Ishihara, se tomaron 26 paletas al azar para el entrenamiento y las 12 paletas restantes se designaron para la etapa de pruebas.

La simulación de las imágenes originales se obtuvo con la multiplicación de matrices propuesta por [26]. Este método está basado en el espacio de color LMS. Este espacio de color representa los colores de acuerdo con las longitudes de las ondas largas (L), medianas (M) y cortas (S). Por lo que el primer paso es convertir el color del píxel en el espacio RGB al espacio LMS. Esto se logra multiplicando el valor RGB por la matriz definida en [17]:

$$LMS = RGB * \begin{bmatrix} 17.8824 & 43.5161 & 4.1193 \\ 4.1193 & 27.1554 & 3.8671 \\ 0.02996 & 0.18431 & 0.18431 \end{bmatrix}$$

Al realizar esta operación se obtiene la representación del RGB en el espacio de color LMS. Posteriormente se procede a realizar el cálculo para la simulación del tipo de daltonismo que se desea obtener. Este cálculo se realizó multiplicando el valor LMS por la matriz

definida por [26] e implementada en [17]. Para el daltonismo de tipo protanopia la operación que se debe realizar para obtener la simulación es:

$$LMSp = LMS * \begin{bmatrix} 0 & 2.02344 & -2.52581 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}$$

Al multiplicar el valor del RGB en espacio de color LMS por esta matriz, se obtiene el valor de LMS simulado para protanopia. Por último, para regresar al valor RGB es necesario realizar una última multiplicación para transformar del espacio de color LMS al RGB. Esta operación es:

$$RGB = LMSp * \begin{bmatrix} 0.0809 & -0.1305 & 0.1167 \\ -0.0102 & 0.0540 & -0.1136 \\ -0.0003 & -0.0041 & 0.6935 \end{bmatrix}$$

El valor resultante es el RGB simulado del píxel original en el espacio de color RGB para el tipo de daltonismo por el que se haya multiplicado, en esta propuesta es para la simulación de protanopia. Una vez obtenido el RGB simulado se guarda en la imagen.




Figura 2. Paleta #2 del test Ishihara y su versión simulada para protanopia propuesta en [17].

Estas operaciones se realizan para cada píxel en cada imagen del dataset. En la Figura 2 se observa el resultado de realizar estas operaciones a todos los píxeles de la paleta #2 del test Ishihara. Las imágenes de este dataset tienen una dimensión de 233x233 píxeles. Por lo que este procedimiento se lleva a cabo 54,289 veces para cada una de las imágenes.

Las imágenes originales y simuladas del dataset se utilizan para identificar los píxeles confusos y no confusos. Esto tiene como objetivo darle a la MSV los ejemplos con los que se va a entrenar. Para identificar estos píxeles confusos y no confusos se evaluó cada píxel individualmente con su simulación a protanopia para evaluar la diferencia como propuso

Tsekouras [18]. Tsekouras definió que si un píxel simulado es 1% diferente a su píxel original entonces sería clasificado como confuso. Esta diferencia es un umbral, que de acuerdo a Tsekouras puede ser modificado para obtener resultados distintos. Para este proyecto se realizaron pruebas con el umbral de Tsekouras pero los resultados no fueron satisfactorios ni en K-Means ni en SVM. Para este proyecto se definió el umbral en 3%. Indicando así que si un píxel simulado era diferente en un 3% del píxel original entonces será clasificado como confuso. Una vez obtenida la clasificación de todos los píxeles de todas las imágenes del entrenamiento, se cargan estos datos a la MSV para crear el hiperplano en el espacio tridimensional RGB. En el Algoritmo 1 se detalla la estructura del entrenamiento realizado a la Máquina de Soporte Vectorial. El hiperplano definido por la MSV resulta de maximizar las distancias con los datos más cercanos de clasificaciones opuestas. En esta propuesta se utilizan tres dimensiones en el hiperplano definidas por el espacio de color RGB.

1. *Para cada Imagen original Ior:*
 - a. *Para cada píxel P de Ior:*
 - i. *Se obtiene P_{sim} al simular P con la matriz propuesta en [17].*
 - ii. *Si la diferencia entre P y P_{sim} es mayor al umbral:*
 1. *Se registra el color del píxel P como confuso.*
 - iii. *Si la diferencia entre P y P_{sim} es menor al umbral:*
 1. *Se registra el color del píxel P como no confuso.*
 2. *Se cargan los datos a la MSV para la creación del hiperplano.*

Algoritmo 1. Entrenamiento de la MSV para la clasificación de píxeles confusos.

Al darle un conjunto de imágenes como entrenamiento a la MSV e indicando las categorías a la que pertenecen cada uno de los píxeles de las imágenes de entrenamiento (confusos y no confusos) el algoritmo construye un modelo que permita clasificar nuevos píxeles de nuevas imágenes. Otra ventaja de las MSV sobre los algoritmos de agrupamiento propuestos en la literatura es que la MSV se entrena solo una vez a pesar de que se procesen diferentes imágenes. En contraste, en los algoritmos de agrupamiento es necesario generar nuevos grupos o clústeres para cada imagen a procesar. La MSV evita este proceso y ahorra este recurso de tiempo y de cómputo. Aunque tenemos que respetar que el tipo de

imágenes que entrenemos sean similares en variedad de tonalidades con las imágenes a procesar. Es decir, los resultados pudieran no ser tan exactos al procesar fotografías reales si solo fuera entrenado con imágenes del test Ishihara.

6.2 Clasificación de píxeles en la Máquina de Soporte Vectorial

El modelo resultante de la MSV permite clasificar los nuevos colores que se procesen. Al procesar las 26 imágenes de prueba se obtuvieron 336,845 píxeles únicos de los cuales 134,820 fueron clasificados como no confusos y 202,025 como confusos. Con la clasificación de estos 336,844 píxeles en su categoría correspondiente, el modelo de la MSV permite clasificar nuevos píxeles en el espacio tridimensional en la categoría que le corresponda. En el Algoritmo 2 se describe el proceso que se lleva a cabo cuando se presenta una imagen nueva al algoritmo propuesto.

1. *Se cargan los resultados obtenidos del entrenamiento*
2. *Para cada píxel P de una imagen nueva:*
 - a. *El píxel P se ubica en el hiperplano de la MSV.*
 - b. *Se obtiene la clasificación de P por la MSV:*
 - i. *Si el color del píxel P pertenece a C_c se aplica la corrección.*
 - ii. *Si el color del píxel P pertenece a C_{nc} se deja intacto para garantizar la naturalidad.*

Algoritmo 2. Clasificación de píxeles confusos en una imagen nueva por la MSV.

Al procesar una imagen nueva se carga el modelo de la MSV y para cada imagen se extraen los píxeles para obtener su clasificación de acuerdo con su posición en el hiperplano construido. Si la MSV clasifica el nuevo píxel como confuso, se le aplica la corrección a ese píxel, de lo contrario se deja intacto. De esta manera se garantiza que los colores que no sean confusos no se modifiquen y se procese únicamente los colores confusos cumpliendo la característica principal de los algoritmos dependientes de contenido.

La corrección que se aplica a los píxeles confusos es similar al cálculo matricial que se fue propuesto en [17]. Para la corrección de color sólo es necesario calcular el error entre cada valor del RGB y su valor RGB simulado. El error en el valor R del RGB es la diferencia entre el R original y el R simulado a protanopia. Lo mismo es para el resto de los valores del píxel RGB. Al obtener estas diferencias, se realiza una multiplicación por la matriz definida en [17] para obtener los valores resultantes de RGB.

En el Algoritmo 3 se describe el pseudocódigo de la propuesta de algoritmo de corrección dependiente de contenido. Como otros métodos de corrección, la herramienta propuesta usa los procesos de simulación y corrección de multiplicación de matrices definidos en [13] y [17]. La aportación de la propuesta se centra en la selección de píxeles confusos en el universo de colores presentes en la imagen. Una vez clasificados todos los píxeles confusos se les realiza la misma corrección de multiplicación de matrices definida en el algoritmo de corrección original.

1. *Dada una imagen original **I_{or}**.*
2. *Se extraen los RGB presentes en cada píxel.*
3. *Se clasifican los RGB confusos **C_c** y los no confusos **C_{nc}** con la Máquina de Soporte Vectorial.*
4. *A los colores **C_c** se les procesa con el método de corrección matricial definido en [17] y se obtiene **C_r**.*
5. *Se reemplazan los **C_r** en los píxeles de **I_{or}** que les corresponda y se obtiene **I_{res}**.*

Algoritmo 3. Pseudocódigo de la propuesta del algoritmo de corrección dependiente de contenido.

El algoritmo fue implementado en el lenguaje de programación Python con el módulo *sklearn* en una computadora con AMD A9 Radeon de 3.10 GHz de 64 bits. En la página 30 de este documento se describe el desempeño de la MSV, así como la implementación de K-Means para realizar una comparación entre ambas técnicas.

7 Resultados y discusiones

En este capítulo se describe la evaluación realizada y los resultados obtenidos por la propuesta presentada en este trabajo, la cual consiste en un algoritmo dependiente de contenido basado en una MSV para la clasificación de píxeles confusos.

La evaluación consistió en determinar: *a)* el desempeño de la clasificación de píxeles en imágenes del Test Ishihara contra un enfoque uniforme y uno basado en K-Means, *b)* el desempeño de la clasificación de píxeles en imágenes de pinturas de arte contra un enfoque uniforme y uno basado en K-Means, y *c)* el tiempo de cómputo de la MSV al seleccionar píxeles y corregirlos en comparación con K-Means. Las métricas de precisión, recuperación y exactitud usadas en el punto *a)* y *b)* se describen a continuación:

$$\text{Precisión} = \frac{\text{Verdaderos Positivos}}{\text{Verdaderos Positivos} + \text{Falsos Positivos}}$$

$$\text{Recuperación} = \frac{\text{Verdaderos Positivos}}{\text{Verdaderos Positivos} + \text{Falsos Negativos}}$$

$$\text{Exactitud} = \frac{\text{Verdaderos Positivos} + \text{Verdaderos Negativos}}{\text{Verdaderos Positivos} + \text{Falsos Negativos} + \text{Verdaderos Negativos} + \text{Falsos Positivos}}$$

Los *verdaderos positivos* representan el número de píxeles etiquetados como confusos y que realmente son confusos.

Los *falsos positivos* son el número de píxeles etiquetados como confusos y que en realidad no son confusos.

Los *falsos negativos* representan el número de píxeles etiquetados como no confusos que en realidad son confusos.

Los *verdaderos negativos* son el número de píxeles etiquetados como no confusos que en realidad son no confusos.

7.1 Implementación de un algoritmo dependiente de contenido basado en agrupamiento

Una de las técnicas implementadas en otros algoritmos dependientes de contenido es la técnica de agrupamiento. El objetivo de implementar esta técnica es dividir los colores de la

imagen en clústeres o grupos y evaluar cuáles de estos son confusos o no confusos en vez de evaluar los píxeles de uno por uno. El agrupamiento en los algoritmos de corrección consiste en transformar los píxeles de la imagen en un espacio tridimensional y calcular las distancias entre los píxeles de tal manera que se consigan agrupar los píxeles según la distancia al grupo más cercano [8]. Al obtener los grupos de píxeles se procede a clasificar los grupos confusos y no confusos para procesar únicamente los que causen confusión [10]. Con este procedimiento se evita modificar los grupos que no contienen colores conflictivos.

Para continuar evaluando el desempeño de la MSV se desarrolló la implementación del algoritmo de agrupamiento con K-Means como propuso [10]. Esta implementación se llevó a cabo en Python a través del módulo *sklearn* y se realizó con el objetivo de evaluar la selección de píxeles que realiza cada método sobre las mismas imágenes, así como comparar tiempos de cómputo. Cabe mencionar que no se propone un nuevo método de corrección, sino que se propone un módulo basado en una MSV para la selección de píxeles. Este módulo propuesto se compara con un método de agrupamiento. El método de corrección implementado en esta propuesta es el mismo método usado por otros autores.

El agrupamiento con K-Means necesita de una variable K que determina la cantidad de grupos o clústeres que debe encontrarse en el universo de píxeles en la imagen. La cantidad de clústeres propuesta en la literatura se encuentra en un rango de 3 a 256 clústeres. En la Figura 3b y 3c se muestran el agrupamiento obtenido con $K=3$ y $K=256$, respectivamente en la paleta #3 del test Ishihara (Figura 3a) en una imagen de 80x80 píxeles y se pueden observar las desventajas descritas en [21]: definir pocos clústeres para una imagen puede que no sea muy representativo de la imagen original, mientras que definir demasiados clústeres puede resultar incluso en clústeres que sean muy similares en tonalidades.

Milic et. al. propusieron encontrar tres clústeres para imágenes del test Ishihara y cuatro para imágenes reales [10]. Anagnostopoulos propuso 50 clústeres para pinturas de arte digitalizadas [8]. Para la comparación de nuestro método con el método de agrupamiento se utilizaron estos clústeres. Sin embargo, encontrar esta cantidad de clústeres puede ser lento.




Figura 3. a) Paleta #3 del test Ishihara. b) Agrupamiento con $K=3$. c) Agrupamiento con $K=256$.

En la Tabla 1 se describe el tiempo de cómputo para encontrar la cantidad de clústeres definidos por otros autores en una imagen con 640x480 píxeles. El proceso de agrupamiento fue implementado en una PC de 3.10 GHZ y 12 GB de RAM.

Clústeres	Tiempo (segundos)
$K=3$	7.39
$K=4$	8.03
$K=50$	692.87

Tabla 1. Tiempos para encontrar los clústeres en un universo de 307,200 píxeles.

Encontrar tres clústeres toma más de siete segundos mientras que encontrar 50 clústeres toma más de diez minutos. Los tiempos de cómputo para un K mayor a 50, como propuso Kuhn, no fueron calculados debido a la duración.

7.2 Métricas de desempeño de la Máquina de Soporte Vectorial

La MSV fue evaluada inicialmente con paletas del test Ishihara. De las 38 paletas del test, 26 fueron utilizadas para el entrenamiento y las 12 restantes fueron utilizadas para las pruebas. La fase de entrenamiento de la MSV con las 26 paletas tomó un tiempo de 3.27 segundos.

La métrica de *recuperación* obtenida en el entrenamiento fue del 76%, esto indica que un 24% de los píxeles confusos no fueron clasificados como tal. La métrica de *precisión* obtenida fue del 99%, esto indica que casi todos los píxeles clasificados como confusos fueron acertados.

Para apreciar visualmente la clasificación de píxeles que realiza la MSV se repintaron las imágenes de prueba a blanco y negro. En color blanco se repintaron los píxeles clasificados como confusos y en color negro se repintaron los píxeles clasificados como no confusos. En la Figura 4 se pueden observar los resultados de aplicar la selección de píxeles con la MSV a las 12 imágenes de prueba.



Figura 4. Resultado de la selección de píxeles de la MSV en paletas del test de Ishihara.

Como se observa en cada imagen de la Figura 4, la MSV separa los píxeles de manera que se revela comprensiblemente el número o figura correspondiente a esa paleta. Los píxeles resaltados forman un patrón similar al que debe percibir una persona con visión normal. En la Tabla 2 se presenta en la columna 1 el número de paleta procesada. La columna 2 describe los números o figuras que debe percibir una persona con visión normal en las

paletas del test Ishihara [27]. La columna 3 muestra los números o figuras resaltadas por la MSV.

Paleta	Figura que debe ser percibida	Figura resaltada con la MSV
#2	8	8
#4	29	29
#5	57	57
#7	3	3
#11	6	6
#13	45	45
#23	42	42
#25	96	96
#27	2 líneas	2 líneas
#31	1 línea	1 línea
#33	1 línea	1 línea
#34	1 línea	1 línea







Tabla 2. Resultados de la identificación de píxeles de la MSV en paletas del test de Ishihara.

Como se puede ver en base a las columnas 2 y 3 de la Tabla 2, la MSV logró clasificar en confusos y no confusos los píxeles de manera que se resalta el resultado correcto de la paleta.

7.3 Desempeño en paletas del test Ishihara

Para comparar el desempeño de la propuesta contra el enfoque de K-Means se procesaron las imágenes del test Ishihara con un método uniforme. El método uniforme evalúa píxel por píxel y clasifica como confusos los que hayan superado el umbral. Para iniciar esta comparación y, posteriormente la evaluación, se procesaron todas las imágenes del test Ishihara en los tres métodos: uniforme, SVM, y K-Means. Para K-Means se utilizó $K=3$ (propuesto por Milic para las paletas de Ishihara) pero no dio buenos resultados, por tal motivo, se utilizó $K=4$ (propuesto por Milic para imágenes reales) buscando generar clústeres más precisos y, por consiguiente, mejorar el desempeño de K-Means. Las paletas del test Ishihara fueron procesadas en dimensiones de 233 x 233 píxeles, es decir un universo de 54,289 píxeles para cada imagen. Los píxeles detectados como confusos en los

tres métodos son repintados con el valor RGB [255,255,255], es decir el color blanco, y los píxeles que se dejarán intactos son repintados con RGB [0,0,0], es decir con el color negro. Esto permite visualizar la selección de píxeles de cada método en las imágenes a procesar. En la Tabla 3 se presentan las paletas utilizadas en la comparación de ambos algoritmos.

Paleta	Uniforme	MSV	K-Means ($K=4$)
#3		 Precisión: 100% Recuperación: 69% Exactitud: 95%	 Precisión: 33% Recuperación: 95% Exactitud: 74%
#5		 Precisión: 100% Recuperación: 81% Exactitud: 98%	 Precisión: 24% Recuperación: 93% Exactitud: 68%
#10		 Precisión: 100% Recuperación: 55% Exactitud: 93%	 Precisión: 25% Recuperación: 99% Exactitud: 55%


#22		 Precisión: 100% Recuperación: 74% Exactitud: 98%	 Precisión: 24% Recuperación: 93% Exactitud: 68%
-----	---	---	--

Tabla 3. Selección de píxeles de la MSV y K-Means ($K=4$) en el test de Ishihara.

Como se puede apreciar en la Tabla 3, la precisión de la MSV es del 100%. Esto significa que todos los píxeles clasificados como confusos por la MSV son acertados. En contraste, de todos los píxeles que selecciona K-Means solo menos de la mitad son acertados. También se puede concluir que la MSV acierta arriba de un 90% al clasificar tanto píxeles confusos como no confusos. El que K-Means tenga una mayor recuperación se debe a que clasifica más píxeles de los que debería y por consecuente acierta en muchos de ellos. En la paleta #10 K-Means selecciona casi todos los píxeles de la paleta como confusos y tiene una recuperación del 99% porque al seleccionar todos como confusos forzosamente tiene que acertar. Esto significa que K-Means agrupa todos los píxeles de la paleta como confusos como lo haría un algoritmo independiente de contenido lo cual no es deseable. Esto conlleva a que en el siguiente modulo se procesen mayor cantidad de píxeles.

7.4 Desempeño en pinturas de arte digitalizadas

Posteriormente, se realizó una comparación de la selección de píxeles en pinturas digitalizadas. Las obras procesadas son las mismas usadas por el equipo de Anagnostopoulos en [8]. Cada imagen digital tiene una dimensión de 500x300 píxeles, es decir un universo de 150,000 píxeles cada una. Debido a que no se tiene la implementación del algoritmo de Anagnostopoulos, quien utilizó agrupamiento con una versión modificada de Fuzzy C Means con $C=50$, se empleó nuevamente K-Means para la selección de píxeles con $K=50$. Para comparar el desempeño nuevamente se procesaron las imágenes con un método uniforme, es decir píxel por píxel se evaluaron los píxeles confusos. En la Tabla 4 se presenta la comparación del desempeño de los tres métodos: uniforme, MSV y K-Means ($K=50$).


Original	Clasificación Uniforme	Clasificación con MSV	Clasificación con K-Means (K=50)
		 Precisión: 69% Recuperación: 89% Exactitud: 82%	 Precisión: 66% Recuperación: 96% Exactitud: 81%
		 Precisión: 100% Recuperación: 63% Exactitud: 92%	 Precisión: 47% Recuperación: 93% Exactitud: 76%
		 Precisión: 99% Recuperación: 85% Exactitud: 94%	 Precisión: 80% Recuperación: 96% Exactitud: 90%
		 Precisión: 99% Recuperación: 61% Exactitud: 92%	 Precisión: 62% Recuperación: 98% Exactitud: 87%

Tabla 4 Desempeño de MSV y K-Means (K=50) en pinturas de arte digitalizadas

Como se puede apreciar en la Tabla 4, se repite el mismo fenómeno que se presentó con las paletas del test Ishihara: la MSV clasifica píxeles confusos más acertadamente que K-Means (precisión). La recuperación continúa siendo mayor en K-Means debido a que selecciona mayor cantidad de píxeles como confusos y forzosamente tiene que acertar en

ellos. La exactitud continúa siendo mayor en la MSV, esto indica que la MSV acierta más en la clasificación de píxeles confusos y no confusos.

7.5 Tiempos de cómputo y desempeño en corrección de la imagen

Por último, en la Tabla 6 se presenta el tiempo de cómputo de ambas técnicas al procesar la misma imagen. La imagen a procesar tiene dimensiones de 1366x768 píxeles, es decir un universo de 1,049,088 píxeles. Ambas implementaciones de K-Means y MSV fueron realizadas en Python en una PC de 3.1 GHz y 12GB de RAM. Se consideran exclusivamente los tiempos de cómputo de la selección de píxeles en la imagen. No se consideran tiempos de corrección de color.

Algoritmo	Tiempo (segundos)
K-Means ($K=50$)	3,019.75 s
K-Means ($K=3$)	20.20 s
MSV	7.47 s

Tabla 5. Tiempos de cómputo en segundos de K-Means y MSV.

Encontrar 50 clústeres en una imagen con dimensión de 1366x768 píxeles llevó más de 3,000 segundos, lo que equivale a más de 50 minutos. Entre mayor sea la cantidad de clústeres mayor será el tiempo de cómputo final. El tiempo mínimo de agrupamiento se obtiene de la propuesta con la mínima cantidad de clústeres en el estado del arte, la cual es de $K=3$. En la misma imagen, encontrar $K=3$ toma más de 20 segundos para cada imagen que se procese. La MSV obtiene la clasificación en menos de la mitad de tiempo.

Implementar una MSV para la selección de píxeles en un algoritmo de corrección toma menos tiempo que un algoritmo de agrupamiento como K-Means. En el caso de las paletas del test Ishihara, un algoritmo de agrupamiento como K-Means puede encontrar dificultades para separar adecuadamente los píxeles confusos de los no confusos. Sin embargo, la MSV tiene un mejor desempeño en este sentido.

La propuesta principal de este proyecto se centra en la selección de píxeles. En los algoritmos de corrección dependientes de contenido, la siguiente fase es la de corregir los píxeles clasificados como confusos. Estos píxeles confusos se obtienen de la selección de píxeles propuesta en este trabajo. Una vez definidos los píxeles confusos, se define el tipo de corrección que se les va a aplicar. Para este proyecto se utilizó la corrección propuesta por Anagnostopoulos descrita en la página 29 de este documento.

A continuación, se presentan las correcciones aplicadas a paletas del test Ishihara. Las correcciones fueron implementadas de tres maneras: de manera uniforme (es decir todos los píxeles de la imagen), con los píxeles seleccionados por K-Means y los seleccionados por la MSV. En la Tabla 7 se muestra el resultado de aplicar cada uno de estos tres métodos y los tiempos de cómputo al ser ejecutados una sola vez. Aunque las tres técnicas resaltan el número de la paleta, el algoritmo de K-Means con tres clústeres procesa mayor cantidad de píxeles (blanco) en comparación con la MSV. Este resultado es consistente con las pruebas mencionadas en los párrafos anteriores. De los tres métodos el que resultó con menor tiempo de cómputo fue la MSV.





Imagen Original	Uniforme	K-Means ($K=3$)	MSV
			
			
Porcentaje de píxeles corregidos	100%	30.99%	7.36%
Tiempo en corregir imagen	17.92 segundos	22.78 segundos	10.2024 segundos

Tabla 6. Comparación de corrección con distintas técnicas de selección de píxeles en la paleta #2 del test Ishihara.

En la paleta #2 del test Ishihara, K-Means selecciona una mayor cantidad de píxeles en comparación con la MSV. En contraste, la MSV selecciona menos píxeles, y en específico únicamente los píxeles de la figura que se debe resaltar en esta paleta. Además, la MSV toma menos tiempo de cómputo que la corrección de color uniforme de la imagen y que la corrección con K-Means.

En la paleta #30 del test Ishihara se obtiene la misma conclusión como se puede observar en la Tabla 8. En la imagen de K-Means en blanco y negro casi todos los píxeles de la paleta fueron seleccionados como confusos. Esto quiere decir que K-Means selecciona todos los píxeles de la paleta como confusos tal y como lo haría el método Uniforme. En esta paleta una persona con visión normal debe identificar una línea que atraviesa la paleta de lado a lado. K-Means selecciona los píxeles de esta línea, así como los píxeles fuera de esta línea. En contraste, la MSV únicamente selecciona los píxeles fuera de la línea permitiendo así que se resalte la figura. De los tres métodos, nuevamente el que procesa menos píxeles y tiene menor tiempo de cómputo es la MSV.







Original	Uniforme	K-Means ($K=3$)	MSV
N/A	Todos los píxeles		
			
N/A	18.91 segundos	24.94 segundos	15.1241 segundos

Tabla 7. Comparación de corrección con distintas técnicas de selección de píxeles.

En el caso de las pinturas de arte digitalizadas, el tiempo de cómputo se incrementa en K-Means debido a la cantidad de clústeres ($K=50$) propuestas por el Anagnostopoulos y por el incremento dimensiones que tienen las imágenes. Las imágenes de arte procesadas tienen dimensiones de 500x300 píxeles. En pinturas de arte digitalizadas, como la que se presenta en la Tabla 9, se obtienen resultados consistentes a las pruebas anteriores. Estos resultados son similares a los presentados previamente en este capítulo.




	
K-Means ($K=50$)	MSV
	
	
43.02% de píxeles	30.85% de píxeles
692.87 segundos	20.6642 segundos

Tabla 8. Selección de píxeles, corrección y tiempo de cómputo en pintura de arte digitalizada con K-Means $K=50$ y la MSV.

8 Conclusiones y recomendaciones

Los algoritmos de corrección al color permiten adaptar los colores en una imagen para que usuarios con Deficiencia de Visión al Color (DVC) puedan percibir mejor los colores. Algunos de estos algoritmos realizan una corrección uniforme, es decir corrigen todos los píxeles de la imagen. Otros algoritmos, conocidos como dependientes de contenido, buscan solo corregir los colores confusos para las personas con DVC. Para encontrar en una imagen los píxeles confusos se realiza una evaluación de los colores. Esta evaluación permite corregir solo los píxeles que causan confusión en las personas con DVC y dejar intactos los píxeles que sí pueden ver bien lo cual permite que se mantenga la naturalidad de la imagen tanto para personas con DVC como para personas con visión normal.

Para llevar a cabo la selección de píxeles se han propuesto técnicas de agrupamiento en la literatura. Estas técnicas de agrupamiento necesitan de un valor predefinido por el investigador que especifique la cantidad de grupos en los que se van a separar los colores de la imagen. En este proyecto se propuso una alternativa que logra la clasificación de píxeles confusos sin que se tenga que predefinir una cantidad de clústeres. Esta propuesta se basa en usar una Máquina de Soporte Vectorial (MSV) para la clasificación de píxeles confusos.

La MSV es una técnica de aprendizaje supervisado usado para clasificación. La implementación de la MSV en este proyecto permitió clasificar los píxeles como confusos y no confusos en imágenes sin realizar un agrupamiento de clústeres. Para evaluar el desempeño de la propuesta se compararon los resultados de la MSV con una implementación del agrupamiento de K-Means. Ambas técnicas se procesaron en las mismas condiciones dentro del mismo algoritmo de corrección y procesando las mismas imágenes de paletas del test Ishihara y pinturas de arte digitalizadas.

Los resultados presentados dan evidencia que la MSV acertó más en la clasificación de píxeles confusos en comparación con K-Means. K-Means clasificaba píxeles confusos de más. De igual manera al comparar los píxeles confusos y no confusos la MSV acertó más. En todas las pruebas la MSV seleccionó menos píxeles como confusos en comparación con K-means. Además, se concluyó que implementar la MSV en un algoritmo dependiente de contenido consumirá menor tiempo que el algoritmo de agrupamiento de k-means.

Debido a lo anterior, se puede concluir que la MSV es una buena alternativa que otros investigadores pudieran considerar para la selección de píxeles en algoritmos de corrección de color dependientes de contenido en la búsqueda de un algoritmo de corrección ideal.

Trabajos futuros de algoritmos de corrección dependientes de contenido que implementen la MSV pueden aplicar diversas modificaciones a esta propuesta. Por ejemplo, se puede proponer trabajar en otro espacio de color, utilizar otra simulación del tipo de daltonismo, corregir otro tipo de daltonismo, modificar el umbral para definir si un píxel es confuso o no, o aplicar otro algoritmo de corrección.

En este proyecto se trabajó en el espacio de color RGB, sin embargo, se puede considerar algún otro espacio de color como LMS, Luv, o CIELAB como lo han hecho otros autores. La simulación aplicada para el entrenamiento de la MSV se basa en la simulación de protanopia propuesta por Brettel, pero existen otros métodos de simulación que pudieran ser probados en esta propuesta o incluso corregir otro tipo de daltonismo. La propuesta de este proyecto utilizó un umbral similar al de Tsekouras para definir si un píxel es confuso o no. Sin embargo, trabajos futuros pueden extender estos criterios para definir otro método para clasificar un píxel confuso. Por último, este trabajo no se enfocó en un nuevo método de corrección de color, sino en proponer una estrategia para la selección de píxeles. Una vez detectados los píxeles confusos por la MSV se les aplicó la corrección propuesta por Anagnostopolous. Por lo que trabajos posteriores pudieran considerar aplicar una técnica de corrección distinta y evaluar los resultados con usuarios con daltonismo.

Referencias

- [1] Simunovic, M. P. (2010). Colour vision deficiency. *Eye*, 24(5), 747-755.
- [2] Almutairi, N., Kundart, J., Muthuramalingam, N., Hayes, J., Citek, K., & Aljohani, S. (2017). Assessment of Enchroma Filter for Correcting Color Vision Deficiency. Pacific University (Oregon).
- [3] Angchekar, S., Gurav, H., & Darvesh, M. (2017, September). An overview study of various re-coloring and wavelength adjustment algorithm for color vision deficient individuals. In 2017 IEEE International Conference on Power, Control, Signals and Instrumentation Engineering (ICPCSI) (pp. 1660-1668). IEEE.
- [4] Alcaraz Martínez, R., Ribera Turró, M., & Granollers i Saltiveri, T. (2020). La accesibilidad de los gráficos estadísticos para personas con baja visión y visión cromática deficiente: revisión del estado del arte y perspectivas. *Interacción, Revista digital de AIPO*, 2020, núm. 1, p. 59-75.
- [5] Kvitle, A. K. (2018). Accessible maps for the color vision deficient observers: past and present knowledge and future possibilities.
- [6] Berisso, K. (2018). Addressing color blind awareness in the classroom. *Journal of Business and Management Sciences*, 6(3), 93-99.
- [7] Hassan, M. F., & Paramesran, R. (2017). Naturalness preserving image recoloring method for people with red–green deficiency. *Signal Processing: Image Communication*, 57, 126-133.
- [8] Tsekouras, G. E., Chatzistamatis, S., Anagnostopoulos, C. N., & Makris, D. (2018, May). Color adaptation for protanopia using differential evolution-based fuzzy clustering: a case study in digitized paintings. In 2018 IEEE Conference on Evolving and Adaptive Intelligent Systems (EAIS) (pp. 1-8). IEEE.
- [9] Simunovic, M. P. (2016). Acquired color vision deficiency. *Survey of ophthalmology*, 61(2), 132-155.
- [10] Milić, N., Hoffmann, M., Tómacs, T., Novaković, D., & Milosavljević, B. (2015). A content-dependent naturalness-preserving daltonization method for dichromatic and

anomalous trichromatic color vision deficiencies. *Journal of Imaging Science and Technology*, 59(1), 10504-1.

[11] Li, H., Zhang, L., Zhang, X., Zhang, M., Zhu, G., Shen, P., ... & Shah, S. A. A. (2020). Color vision deficiency datasets & recoloring evaluation using GANs. *Multimedia Tools and Applications*, 79(37), 27583-27614.

[12] Patrignani, M. (2020). Why Should Anyone use Colours? or, Syntax Highlighting Beyond Code Snippets. *arXiv preprint arXiv:2001.11334*.

[13] Alqahtani, N. A., Togoo, R. A., Alqahtani, M. M., Suliman, N. S., Alasmari, F. A., Alqahtani, F. M., & Alshahrani, F. T. (2020). Frequency of Color Vision Deficiency among Saudi Dental Students: A Cross-Sectional Study. *European Journal of Dentistry*.

[14] De Paor, D., Karabinos, P., Dickens, G., & Atchison, C. (2017). Color vision deficiency and the geosciences. *GSA Today*, 27(6).

[15] Machado, G. M., Oliveira, M. M., & Fernandes, L. A. (2009). A physiologically-based model for simulation of color vision deficiency. *IEEE transactions on visualization and computer graphics*, 15(6), 1291-1298.

[16] Suthaharan, S. (2016). Support vector machine. In *Machine learning models and algorithms for big data classification* (pp. 207-235). Springer, Boston, MA.

[17] Anagnostopoulos, C. N., Tsekouras, G., Anagnostopoulos, I., & Kalloniatis, C. (2007, December). Intelligent modification for the daltonization process of digitized paintings. In *International Conference on Computer Vision Systems: Proceedings* (2007).

[18] Doliotis, P., Tsekouras, G., Anagnostopoulos, C. N., & Athitsos, V. (2009, April). Intelligent modification of colors in digitized paintings for enhancing the visual perception of color-blind viewers. In *IFIP International Conference on Artificial Intelligence Applications and Innovations* (pp. 293-301). Springer, Boston, MA.

[19] Zeltzer, H. I. (1991). U.S. Patent No. 4,998,817. Washington, DC: U.S. Patent and Trademark Office.

- [20] Huang, J. B., Tseng, Y. C., Wu, S. I., & Wang, S. J. (2007). Information preserving color transformation for protanopia and deuteranopia. *IEEE Signal Processing Letters*, 14(10), 711-714.
- [21] Huang, J. B., Chen, C. S., Jen, T. C., & Wang, S. J. (2009, April). Image recolorization for the colorblind. In 2009 IEEE International Conference on Acoustics, Speech and Signal Processing (pp. 1161-1164). IEEE.
- [22] Ma, Y., Gu, X., & Wang, Y. (2009). Color discrimination enhancement for dichromats using self-organizing color transformation. *Information Sciences*, 179(6), 830-843.
- [23] Kuhn, G. R., Oliveira, M. M., & Fernandes, L. A. (2008). An efficient naturalness-preserving image-recoloring method for dichromats. *IEEE transactions on visualization and computer graphics*, 14(6), 1747-1754.
- [24] Swarbrick, H. A., Nguyen, P., Nguyen, T., & Pham, P. (2001). The ChromaGen contact lens system: colour vision test results and subjective responses. *Ophthalmic and Physiological Optics*, 21(3), 182-196.
- [25] Machado, G. M., & Oliveira, M. M. (2010, June). Real-Time Temporal-Coherent Color Contrast Enhancement for Dichromats. In *Computer Graphics Forum* (Vol. 29, No. 3, pp. 933-942). Oxford, UK: Blackwell Publishing Ltd.
- [26] Brettel, H., Viénot, F., & Mollon, J. D. (1997). Computerized simulation of color appearance for dichromats. *JOSA A*, 14(10), 2647-2655.
- [27] Agrawal, A., Malik, M., & Singh, L. U. P. (2017, November). CBAT—Color blind assisting tool. In 2017 International Conference on Multimedia, Signal Processing and Communication Technologies (IMPACT) (pp. 46-50). IEEE.
- [28] Langlotz, T., Sutton, J., Zollmann, S., Itoh, Y., & Regenbrecht, H. (2018, April). Chromaglasses: Computational glasses for compensating colour blindness. In *Proceedings of the 2018 CHI Conference on Human Factors in Computing Systems* (pp. 1-12).
- [29] Ro, G., Choi, Y., Kang, M., Hong, S., & Kim, Y. (2019). Novel color filters for the correction of red–green color vision deficiency based on the localized surface plasmon resonance effect of Au nanoparticles. *Nanotechnology*, 30(40), 405706.

- [30] Spalding, J. A. (1999). Colour vision deficiency in the medical profession. *British journal of general practice*, 49(443), 469-475.
- [31] O’dea, S. (2020). Number of smartphone users worldwide from 2016 to 2021. Statista Research Department.
- [32] Atchison, D. A., Pedersen, C. A., Dain, S. J., & Wood, J. M. (2003). Traffic signal color recognition is a problem for both protan and deutan color-vision deficient. *Human factors*, 45(3), 495-503.
- [33] Sakuma, Y., Kishimoto, N., & Momota, Y. (2017). Appropriate color codes for medical materials and devices in terms of color vision deficiency management to ensure patient safety. *Journal of Osaka Dental University*, 51(1), 31-38.
- [34] Oliveira, R. F. D., Pugliesi, E. A., Ramos, A. P. M., & Decanini, M. M. S. (2018). Driver preference concerning in-car route guidance and navigation system maps for drivers with color vision deficiency. *Boletim de Ciências Geodésicas*, 24(2), 186-201.
- [35] Thomas, P. B., Nesaratnam, N., Chaudhuri-Vayalambone, P., & Mollon, J. D. (2019). Color Vision Deficiency Among Doctors: Can We Make Useful Adaptations to the Color Codes Used in the Clinical Environment?. *Journal of patient safety*.
- [36] Salih, A. E., Elsherif, M., Ali, M., Vahdati, N., Yetisen, A. K., & Butt, H. (2020). Ophthalmic Wearable Devices for Color Blindness Management. *Advanced Materials Technologies*, 5(8), 1901134.