
This is the **published version** of the bachelor thesis:

Alonso Pérez, Daniel; Parraga, Carlos Alejandro, dir. Balanç de blancs en fotografia quan hi ha més d'una il·luminació. 2022. (958 Enginyeria Informàtica)

This version is available at <https://ddd.uab.cat/record/264162>

under the terms of the  license

Balanç de blancs en fotografia quan hi ha més d'una il·luminació

D. Alonso

Resum– La constància de color és el fenomen que permet que puguis veure el color real dels objectes independentment de si estan siguent afectats per un il·luminant. En aquest article proposem un algorisme que funciona amb múltiples il·luminants. Primer de tot, l'algorisme separa la imatge en diversos segments utilitzant K-means++. El nombre de segments està determinat per un algorisme basat en l'histograma de la imatge. Un cop la imatge és segmentada, apliquem CCWF per escollir quins segments ens donen suficient informació de color. Aplicarem a cada segment escollit un algorisme d'un il·luminant per obtenir un factor de constància de color. Després, fusionarem aquests factors utilitzant la distància euclidiana de cada píxel al centre de gravetat de cada segment escollit. Els experiments mostren que aquest algorisme funciona aproximadament tan bé com els dels estat de l'art, fins i tot a vegades millor.

Paraules clau– Constància de color, múltiples il·luminants, kmeans, segmentació.

Abstract– Color constancy is the phenomenon that allows you to see the true color of the objects regardless of whether they are being affected by an illuminant. In this paper, we propose an algorithm that works with multiple illuminants. First of all, the algorithm splits the image into various segments using K-means++. The number of segments is determined by an algorithm based on the histogram of the image. Once the image is segmented, we apply the CCWF to choose which segments gives us enough colour information. Later on we are going to apply to each selected segment a single illuminant algorithm to obtain a color constancy factor. Then we are going to merge these factors using the Euclidian distance of each pixel to the center of gravity of each selected segment. The experiments shows that this algorithm works approximately as well as the state-of-the-art ones, sometimes even better.

Keywords– Color constancy, multiple illuminants, kmeans, segmentation.



1 INTRODUCCIÓ - CONTEXT DEL TREBALL

LA constància de color és una característica del nostre sistema visual que afecta a la percepció del color. Aquest fenomen ens permet percebre els objectes del mateix color encara que hi hagi un canvi d'il·luminació [1]. Per exemple, si veiem a una persona al carrer al capvespre, no la veurem de color vermell tot i que la il·luminació principal és vermellosa.

Al món de la fotografia també s'ha tractat de traslladar aquest fenomen degut a que, quan fem una instantània, ens agradaria poder capturar a la imatge l'escena tal com nosaltres l'estem veient. En aquest cas, si nosaltres féssim una

foto a la mateixa persona al capvespre sense cap tipus de processament, a la imatge aquesta persona sí que es veuria vermella. En aquest àmbit, la constància de color s'ha anomenat balanç de blancs.

Aquest fenomen és molt estudiat dintre de l'àmbit de visió per computadors degut a que ens serveix d'ajuda amb diverses tasques, especialment amb el reconeixement i seguiment d'objectes.

Aquest tema ha sigut ampliament estudiat i per aquest motiu ja existeixen diversos algorismes que intenten solucionar aquest problema. Entre d'ells ens trobem l'assumpció del món gris (Gray World), el del pedaç blanc (White Patch) o el de la vora gris (Gray Edge) que no requereixen d'aprenentatge previ, però també ens trobem d'algorismes que sí que necessiten que els entrenem, com els que es basen en el gamut o amb deep learning [2].

El concepte de gamut consisteix en assumir que els colors que poden tenir els objectes a l'escena són limitats i acotats. D'aquesta manera, podem estimar l'il·luminant, degut a que

- E-mail de contacte: daniel.alonso.dap@gmail.com
- Menció realitzada: Computació
- Treball tutoritzat per: Carlos Alejandro Parraga (Computer Science)
- Curs 2021/22

sabem que tots els píxels de l'escena han d'estar dintre d'aquest rang de valors. El deep learning, en canvi, consisteix en entrenar sistemàticament a un model d'aprenentatge computacional, el qual rep les fotografies inicials i les seves respectives imatges corregides i apren patrons a aplicar per aconseguir el mateix resultat.

La majoria d'aquests algorismes, però, fan diverses suposicions. Una d'elles és que a l'escena només hi ha una única il·luminació. Aquesta situació no es dona en molts casos fent que els algorismes fallin estrepitosament. Per exemple, si fem una foto dintre d'un establiment que està utilitzant llum artificial, com pot ser un fluorescent, i a la seva vegada entra llum solar per la finestra, ja hi haurien dos il·luminants afectant a la imatge.

Per aquest motiu, l'objectiu principal del treball és aconseguir fer un algorisme que sigui capaç d'aplicar balanç de blancs amb diversos il·luminants. Més concretament aquests són els objectius:

- Adquirir coneixement sobre color constancy per entendre bé la dificultat del problema i les possibles formes de tractar-lo.
- Cercar com han fet altres investigadors per tractar aquest problema, cercar l'estat de l'art i escollir la millor estratègia per abordar el problema.
- En el cas de que sigui un algorisme que requereixi aprenentatge, cercar un dataset adient per poder entrenar-lo.
- Cercar i implementar una forma efectiva d'avaluar l'algorisme, podent-lo comparar amb els diferents algorismes que componen l'estat de l'art.

2 ALGORISMES QUE FUNCIONEN AMB UN IL·LUMINANT

De cara a poder comparar la funcionalitat de l'algorisme que funciona amb múltiples il·luminants, primer hem implementat algorismes que estan pensats per a escenes que estan afectades només amb un il·luminant. Hem implementat els algorismes que millor funcionen i que, per tant, componen l'estat de l'art. [1].

2.1 White Patch

El primer algorisme implementat ha sigut el White Patch. Aquest algorisme es basa en la suposició de que el píxel més clar de l'escena és un punt blanc. Això és degut a que els reflexos dels objectes reflecten tota la llum incident. Si la llum de l'ambients fos blanca aquest reflexe també seria blanc, però a l'haver-hi un il·luminant afectant l'escena, l'objecte el reflexa. [1]

Per tal d'obtenir l'il·luminant pel qual multiplicarem la nostra escena, buscarem el píxel amb un valor més gran de cada canal i dividirem 255 entre aquest valor. Utilitzarem la següent fórmula.

$$K_c = \frac{255}{\max(I_c)} \quad (1)$$

K_c equival al valor de l'il·luminant en el canal C, podent C valer R, G o B. $\max(I_c)$ és el valor màxim del canal C.




Fig. 1: En ordre da dalt a sota i d'esquerra a dreta: La imatge d'entrada, la imatge corregida il·luminada amb il·luminació canònica i la imatge corregida amb l'algorisme de White Patch.

Si ens fixem en la imatge 5 podem veure les limitacions de l'algorisme White Patch. Tot i que modifica una mica la imatge està casi idèntica a la primera. Això pot ser degut a que hi ha algun píxel mort o que algun punt de l'escena és completament blanc.

2.2 Grey World

Aquest algorisme es basa en la suposició de que la reflectància mitjana de les superfícies a l'escena és acromàtica.

Per realitzar l'algorisme, primerament farem la mitjana dels valors de cada píxel per a cada canal de la imatge. Un cop tenim la mitjana de cada canal, hi han diverses maneres d'obtenir un valor de referència, nosaltres hem escollit fer la mitjana de les mitjanes de cadascun dels canals. Finalment, per obtenir el valor de l'il·luminant pel qual multiplicarem l'escena, dividim la mitja de cada canal entre el valor de referència. [1] [2] [13]

Amb la següent equació obtindrem el valor mitjà de cada canal.

$$C_{mean} = \frac{\sum \sum I_c}{N} \quad (2)$$

C_{mean} equival a la mitjana del canal C, podent C valer R, G o B. I_c és el canal C de l'imatge. Finalment, N és el número total de píxels de l'imatge. Un cop tenim aquest valor pels tres canals, obtindrem un valor de referència de la següent manera:

$$Avg = \frac{R_{mean} + G_{mean} + B_{mean}}{3} \quad (3)$$

Sent R_{mean} , G_{mean} i B_{mean} els valors calculats anteriorment.

Finalment aplicarem la següent fórmula.

$$K_c = \frac{Avg}{C_{mean}} \quad (4)$$

Sent K_c , l'il·luminant calculat del canal C. Avg el valor calculat prèviament i C_{mean} la mitja del canal C calculada.

Si ens fixem en la figura 2 podem veure que l'algorisme Grey-World funciona millor en aquest cas que White-Patch.




Fig. 2: En ordre da dalt a sota i d'esquerra a dreta: La imatge d'entrada, la imatge corregida il·luminada amb il·luminació canònica i la imatge corregida amb l'algorisme de Grey Edge.

2.3 Grey Edge

Finalment l'últim algorisme programat és el Grey Edge. Aquest algorisme es basa en la suposició de que la mitjana de les diferències de reflectància en una escena és acromàtica.

Primerament, el que farem serà obtenir el gradient de la imatge original. Per tal de fer-ho, farem dues derivades parcials en direccions oposades i farem una aproximació per cada píxel amb ajuda de les dues derivades. Elevarem al quadrat cada valor, el sumarem i farem l'arrel quadrada. Per realitzar aquestes derivades de moment només hi he implementat les màscares de Sobel i Prewitt. Un cop tenim el gradient, farem el mateix procediment que vam implementar al Grey World. Calcularem les mitjanes per canal, calcularem un valor de referència i calcularem l'il·luminació amb la que multiplicarem la imatge.[13]

Com existeix l'algorisme de Gray Edge de segon ordre, ens va semblar addient investigar i provar a executar l'algorisme aplicant derivades de més ordres.

El primer pas és aplicar les derivades parcials. Per tal de fer això utilitzarem les següents fórmules:

$$derParVC = Ic * FiltreV \quad (5)$$

Sent $derParVC$ la derivada parcial vertical del canal C, Ic el canal C de l'imatge original, $*$ simbolitza la operació de convolució i $FiltreV$ el filtre vertical. En el cas del filtre de Sobel seria:

$$\begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix}$$

També utilitzarem:

$$derParHC = Ic * FiltreH \quad (6)$$

Sent $derParHC$ la derivada parcial horitzontal del canal C, Ic el canal C de l'imatge original, $*$ simbolitza la operació de convolució i $FiltreH$ el filtre horitzontal. En el cas del filtre de Sobel seria:

$$\begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}$$

Tornarem a aplicar aquestes dues fórmules tants cops com sigui el grau de la derivada, però substituint Ic per $derParVC$ en el cas de la derivada vertical i $derParHC$ en el cas de la derivada horitzontal. Un cop tenim les nostres derivades parcials utilitzarem la següent fórmula i calcularem la distància euclidiana de cada píxel de les dues derivades parcials i posarem el valor resultant en una nova imatge:

$$ImDer = \sqrt{derParVC^2 * derParHC^2} \quad (7)$$

Un cop tenim la imatge derivada podem prendre-la com a variable d'entrada de l'algorisme Grey World i aplicar les mateixes equacions substituint Ic per $ImDer$:

$$Cmean = \frac{\sum \sum ImDerc}{N} \quad (8)$$

$$Avg = \frac{Rmean + Gmean + Bmean}{3} \quad (9)$$

$$Kc = \frac{Avg}{Cmean} \quad (10)$$

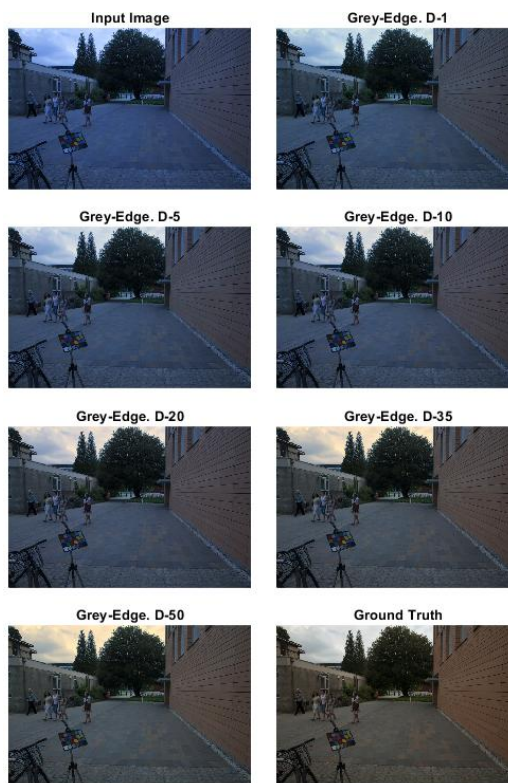


Fig. 3: En ordre da dalt a sota i d'esquerra a dreta: La imatge d'entrada, la imatge corregida amb l'algorisme de Grey Edge, aplicant la màscara de Prewitt i amb diferents ordres de derivades. En ordre, derivada d'ordre 1, 5, 10, 20, 35 i 50. Finalment la última imatge correspon amb la imatge corregida il·luminada amb il·luminació canònica.

Si ens fixem en la 3 podem veure com afecta l'algorisme amb els diferents ordres de derivades efectuades amb la màscara de Prewitt. Quan més gran sigui el grau, més es modifica la imatge.

3 ALGORISME MÚLTIPLES IL·LUMINANTS

Ara procedirem a explicar l'algorisme de múltiples il·luminants que hem implementat. Podem dividir l'algoris-

me en tres parts. La primera part de totes consisteix en segmentar l'imatge. Un cop la tenim segmentada, filtrarem els segments que realment ens aportin informació a l'escena. La segona part consisteix en, un cop tinguem els segments que considerem vàlids, calcularem l'il·luminant d'aquests segments suposant que tenen una il·luminació uniforme, per tant aplicarem un algorisme pensat per un únic il·luminant uniforme i obtindrem una estimació de l'il·luminant al segment. Un cop l'hem calculat, falta l'última part, que consisteix en juntar les diferents estimacions calculades.

3.1 Segmentació de la imatge.

Primerament, el que fem és segmentar l'imatge. Per tal de segmentar-la, utilitzarem l'algorisme K-means++. K-means és un algorisme de clusterització, és a dir, un algorisme de classificació no supervisada. Aquest algorisme rep com a paràmetre una estructura de dades i k, el número de clústers amb els que vols classificar les dades. L'algorisme funciona de la següent manera:

1. El primer pas consisteix en inicialitzar els k clústers dintre del espai de les dades a classificar. En el cas de K-means++ inicialitzarem aquests clústers de manera aleatòria.
2. Calcularem la distància euclidiana de cada mostra amb cada clúster, és a dir, per cada mostra tindrem k distàncies calculades.
3. Un cop calculades associarem cada mostra al clúster que es trobi més a prop d'ella, és a dir, que la distància sigui més petita.
4. Calcularem la nova posició dels clústers. Per fer-ho, operarem la mitjana de totes les mostres que pertanyin a cadascun dels clúster.
5. Repetirem 3 i 4 fins que cap mostra canviï de clúster associat.

En aquest cas, els paràmetres que rep és la imatge i k, el número de segments amb el que segmentarem la imatge. Hem d'estimar una manera d'escollir una k adequada per segmentar l'imatge de forma òptima.

El primer que farem serà transformar la imatge RGB a una imatge en escala de grisos. Un cop hem fet això, farem un histograma la fotografia, separant en 256 càpsules. Aplicarem una convolució a aquest histograma sis cops amb la següent màscara per suavitzar-ho.[17]

$$\begin{bmatrix} 0.25 & 0.5 & 0.25 \end{bmatrix}$$

El nombre de segments, k, l'obtindrem de calcular el número de màxims locals que trobem a l'histograma suavitzat. Per tal de fer-ho, tindrem en compte que la distància entre dos màxims ha de ser com a mínim de 30 i l'altura del màxim local ha de ser més gran que $\frac{N}{1000}$ [17], sent N el número de píxels de l'imatge.

Diversos papers [6] [17] recomanen segmentar l'imatge en l'espai de color $L^*a^*b^*$ degut a que obtenim uns segments més consistents. Nosaltres farem tres variants de l'algorisme. En la primera, segmentarem amb l'imatge en l'espai RGB. La segona, en l'espai $L^*a^*b^*$, i en la tercera ho farem en l'espai HSV.




Fig. 4: Imatge segmentada en 4 segments. Es poden veure els píxels que pertanyen a cada segment visualment i amb la mateixa disposició que es trobaven a l'imatge original.

Podem observar com queda una imatge segmentada.

Un cop tenim els segments, hem d'escollir quins d'aquests segments considerem que ens aporten la suficient informació de color com per tenir-los en compte i quins hem de descartar per no afectar al càlcul de l'il·luminant final. Utilitzarem la mètrica NAAD (Diferència absoluta mitjana normalitzada)[6]. La fórmula que utilitzarem serà la següent:

$$NAADc = \frac{1}{N \times \bar{S}_c} \sum \sum |P_c - \bar{S}_c| \quad (11)$$

Sent N el nombre de píxels que té el segment, S_c la mitja del valor del canal C dels píxels del segment i P_c el valor del canal C del píxel concret que s'està analitzant.

L'utilitzarem per cada segment i per cadascun dels tres canals (R, G i B) del segment. En cas de que algun dels canals sigui inferior al threshold seleccionat no comptarem el segment com vàlid. El valor que utilitzarem pel threshold serà 0.01 [6].

3.2 Càlcul d'il·luminant per cada segment vàlid

Un cop tenim els segments vàlids el que farem serà estimar un valor d'il·luminant per cadascun d'ells. Hem de saber a on ubicarem l'il·luminant calculat. És per aquest motiu que calcularem el centre de gravetat del segment. D'aquesta manera obtindrem les coordenades X i Y del segment a on correspon el centre de l'il·luminant.

Per estimar l'il·luminant de cada segment utilitzarem un algorisme d'un il·luminant. Nosaltres, en concret, utilitzarem els algorismes esmentats anteriorment. White Patch, Grey World i Grey Edge. També farem un quart algorisme que està basat en White Patch.

3.2.1 White Patch

Per realitzar el càlcul dels il·luminants de cada segment amb White Patch, hem buscat el valor més gran del segment i hem suposat que era blanc. D'una manera molt similar a com seria l'algorisme normal.

$$K_{ic} = \frac{255}{\max(S_{ic})} \quad (12)$$

K_{ic} és el valor de l'iluminant pel canal C i pel segment I. $\max(S_{ic})$ equival al valor màxim del canal C del segment I.

3.2.2 Grey World

En aquest cas, hem agafat els valors de tots els píxels del segment i , utilitzant el número de píxels que té el segment, hem fet que el color d'aquests píxels tendeixi a gris, és a dir, a uns colors acromàtics. L'algorisme aplicat és molt similar.

$$iC_{mean} = \frac{\sum \sum Sic}{Npixseg} \quad (13)$$

C_{mean} és la mitjana del canal C del segment i . Sic és el canal C del segment i . I $npxseg$ és el número de píxels del segment.

$$iAvg = \frac{iR_{mean} + iG_{mean} + iB_{mean}}{3} \quad (14)$$

$iAvg$ és el valor mitjà del segment i IC_{mean} la mitjana del canal C del segment i . Finalment apliquem:

$$Kic = \frac{iAvg}{iC_{mean}} \quad (15)$$

I obtenim Kic , que és el valor estimat de l'il·luminant pel canal C al segment i .

3.2.3 Grey Edge

Hem decidit mantenir els píxels que pertanyen al segment en la mateixa posició que estaven a la fotografia original, i els píxels que no pertanyen al segment deixar-los negres (amb valor 0). D'aquesta manera, apliquem la convolució a aquesta imatge i , un cop aplicada, busquem que la mitjana dels valors de només els píxels que pertanyien al segment sigui acromàtica (grisa).

3.3 Mean White Patch

Aquest algorisme consisteix en calcular el valor màxim de cada columna del segment i fer la mitjana. També farem la mitjana del màxim valor de cada columna de cada canal i farem la divisió[6].

$$Kic = \frac{iMaxColumnAvg}{iCMaxColumnAvg} \quad (16)$$

A on Kic és el valor estimat de l'il·luminant pel canal C (R , G o B) i el segment i , $iMaxColumnAvg$ és la mitjana del màxim valor de cada columna del segment i $iCMaxColumnAvg$ és la mitjana del màxim valor de cada columna del canal C del segment i .

3.4 Càlcul del factor de correcció de constància de color per píxel

Finalment ens queda anar píxel per píxel i calcular el seu pes del factor de correcció de constància de color. Utilitzarem la distància euclidiana que tenen els píxel en l'espai X, Y de l'imatge als diferents centroides calculats anteriorment. Un cop calculem des del píxel les distàncies a tots els clústers fusionarem els il·luminants estimats anteriorment amb la següent fórmula[14].

$$Kc = \frac{d1}{d1 + \dots + dn} (Kc1) + \dots + \frac{dn}{d1 + \dots + dn} (Kcn) \quad (17)$$

Sent les diferents d les distàncies euclidiànes del píxel actual als diferents centroides dels segments vàlids. Els diferents Kc són els valors dels il·luminants calculats per cada segment.

El resultat final és una matriu amb els diferents pesos de constància de color que té cada píxel com a estimació. Per tal de corregir l'imatge utilitzarem el model de diagonalització de Von-Kries[18].

$$\begin{bmatrix} p_corrR \\ p_corrG \\ p_corrB \end{bmatrix} = \begin{bmatrix} kR & 0 & 0 \\ 0 & kG & 0 \\ 0 & 0 & kB \end{bmatrix} \times \begin{bmatrix} p_R \\ p_G \\ p_B \end{bmatrix}$$

A on p_C equival als diferents canals del píxel original de l'imatge; C equivalent als diferents canals R , G o B . kC equival a l'estimació de regulació de la constància de color calculat per cada canal del píxel. I finalment p_corrC equival a cada canal del píxel corregit.




Fig. 5: En ordre da dalt a sota i d'esquerra a dreta: La imatge d'entrada, la correcció de l'il·luminació píxel a píxel estimada pel nostre algorisme, la correcció de l'il·luminació píxel a píxel oferida com a Ground Truth, la imatge corregida estimada pel nostre algorisme i finalment la imatge corregida amb el Ground Truth.

4 VALIDACIÓ DELS ALGORISMES

4.1 Datasets

És important validar els algorismes en més d'un algorisme per assegurar-nos del seu correcte funcionament. També és important que, com hem fet un algorisme que funciona amb múltiples il·luminants, utilitzem datasets que continguin fotografies que es vegin afectades amb més d'un il·luminant. És per aquest motiu que hem utilitzat els següents datasets.

4.1.1 MIMO dataset

El primer dataset que hem utilitzat ha sigut el Multi-Illuminant Multi-Object, a partir d'ara referenciat com a MIMO [15].

Aquest dataset està dividit en dos subdatasets. Un conté imatges preses a un laboratori i l'altre imatges preses a situacions reals. El dataset del laboratori està constituït per 58 imatges i el de la vida real per 20. Les imatges venen amb el seu pertenyent *groundtruth*, que consisteix en una matriu igual de gran que la imatge original, la qual conté el valor del factor de correcció de constànci de color per cada píxel.

4.1.2 MLS dataset

El segon dataset utilitzat és el Multiple Light Sources (MLS) dataset. [16]

Aquest dataset també està dividit en dos subdatasets. El primer recull 9 imatges preses a l'exterior. El següent, en canvi, conté 7 escenes preses al laboratori amb diferents tipus d'il·luminacions el que acaba suposant 59 imatges diferents en aquest entorn. També se'ns proporciona el seu pertenyent *groundtruth*.

4.2 Mètrica d'avaluació

La mètrica que utilitzarem per identificar què tan bé funcionen els algorismes serà l'error angular. Utilitzarem la següent equació:

$$Error_{angular} = \cos^{-1}(I_{GT} \cdot I_{Pred}) \quad (18)$$

A on I_{GT} equival a l'il·luminant que ens ofereix el *Ground-Truth* i I_{Pred} l'il·luminant predit per l'algorisme.

Calcularem tant la mitjana com la mediana de l'error angular. Un valor més petit indica que el grau que es crea entre els dos vectors tridimensionals dels il·luminants és més semblant, per tant millor funciona l'algorisme.

4.3 Resultats obtinguts

En aquest apartat analitzarem els resultats que hem obtingut per més endavant comparar-los. Mostrarem taules que contenen els diferents algorismes i com aquests es comporten en el MIMO i MLS dataset. Hem separat cada dataset en els seus respectius subdatasets i hem calculat, com hem explicat anteriorment, la mitjana i mediana de l'error angular

4.3.1 Algorismes d'un il·luminant

Començarem amb els algorismes pensats per un sol il·luminant.

En la taula 1, podem observar que en tots els casos l'algorisme Gray Edge és el que es millor es comporta en el MIMO dataset, tot i que variant el grau de la derivada que s'utilitza. Un detall a destacar és que en la mitjana del subdataset del laboratori l'algorisme que es comporta millor és el Gray Edge d'ordre 3. Tot i això podem observar que quan augmentem molt l'ordre de la derivada de Gray Edge els valors comencen a ser molt pitjors.

En la taula 2 podem veure com es comporten aquests algorismes en el MLS dataset. També podem veure que l'algorisme que millor es comporta és el Gray Edge. En aquest cas obtenim que l'algorisme que millors resultats ens dona quan parlem de la mitjana de l'error del dataset del laboratori és el Gray Edge d'ordre 5. D'igual manera quan augmentem l'ordre de manera significativa podem veure que empitjora significativament.

TAULA 1: MITJA I MITJANA EN GRAUS DELS ALGORISMES PENSATS PER IMATGES AFECTADES AMB UN SOL IL·LUMINANT UNIFORME EN MIMO DATASET.

Method	MIMO dataset (real)		MIMO dataset (lab)	
	Mean error (°)	Median error (°)	Mean error (°)	Median error (°)
White Patch	6.76	5.60	7.83	7.59
Grey World	5.18	4.23	3.21	2.86
Grey Edge-1	5.76	4.51	3.07	2.85
Grey Edge-2	5.06	3.64	3.09	2.93
Grey Edge-3	5.54	4.37	3.05	2.90
Grey Edge-4	6.00	4.75	3.09	2.93
Grey Edge-5	6.13	4.65	3.09	2.90
Grey Edge-10	6.27	4.77	3.34	3.13
Grey Edge-20	6.22	4.89	3.85	3.87
Grey Edge-35	6.16	5.35	4.33	4.22
Grey Edge-50	6.39	5.33	5.01	4.75

TAULA 2: MITJA I MITJANA DE L'ERROR EN GRAUS DELS ALGORISMES PENSATS PER IMATGES AFECTADES AMB UN SOL IL·LUMINANT UNIFORME EN MLS DATASET.

Method	MLS dataset (real)		MLS dataset (lab)	
	Mean error	Median error	Mean error	Median error
White Patch	6.66	7.83	15.04	14.47
Grey World	8.31	8.94	14.51	14.58
Grey Edge-1	6.39	6.68	14.27	13.90
Grey Edge-2	6.13	6.95	14.64	14.13
Grey Edge-3	6.35	7.60	14.23	13.68
Grey Edge-4	5.92	7.21	15.27	14.50
Grey Edge-5	6.88	7.51	14.35	13.64
Grey Edge-10	8.19	8.25	14.45	14.23
Grey Edge-20	9.41	9.50	14.80	14.36
Grey Edge-35	11.28	11.60	14.94	13.95
Grey Edge-50	11.81	12.28	17.00	15.42

4.3.2 Algorismes multi-il·luminants

Passarem a analitzar els resultats de les diferents variants de l'algorisme pensat per més d'un il·luminant.

Passarem a avaluar l'algorisme quan realitza la segmentació en l'espai HSV en els dos datasets.

A la taula 3 podem observar com en el cas del dataset real, Gray Edge d'ordre 2 és el que es comporta millor amb diferència. No obstant això, en el cas del dataset de lab, es comporta molt millor tant el Gray Edge d'ordre 35 com el Mean White Patch. En el següent apartat compararem més detingudament, però ja podem veure que en el dataset del lab aquesta segmentació no funciona massa bé.

A la taula 4 podem observar com gairebé en tots els datasets funcionen millor amb el Mean White Patch. Podem observar que, en aquest dataset, sí que obtenim uns molt millors resultats.

TAULA 3: MITJA I MITJANA DE L'ERROR EN GRAUS DE L'ALGORISME PENSAT PER IMATGES AFECTADES AMB MÉS D'UN IL·LUMINANT A MIMO DATASET REALITZANT LA SEGMENTACIÓ EN L'ESPAI HSV.

HSV segmentation	MIMO dataset (real)		MIMO dataset (lab)	
	Mean error	Median error	Mean error	Median error
Method to calculate illuminant of segments				
White Patch	7.65	6.52	15.19	16.28
Grey World	8.88	10.19	17.14	17.47
Grey Edge-1	7.61	6.98	13.93	14.16
Grey Edge-2	6.74	5.58	13.10	13.90
Grey Edge-3	8.19	7.75	12.48	13.97
Grey Edge-4	8.23	8.17	12.46	13.42
Grey Edge-5	7.58	7.29	12.27	14.03
Grey Edge-10	7.73	8.32	12.16	11.93
Grey Edge-20	8.12	7.94	12.27	11.78
Grey Edge-35	8.28	8.20	11.81	10.63
Grey Edge-50	7.74	8.10	12.73	10.65
Mean White Patch	7.14	7.75	10.70	11.83

TAULA 5: MITJA I MITJANA DE L'ERROR EN GRAUS DE L'ALGORISME PENSAT PER IMATGES AFECTADES AMB MÉS D'UN IL·LUMINANT A MIMO DATASET REALITZANT LA SEGMENTACIÓ EN L'ESPAI LAB.

Lab segmentation	MIMO dataset (real)		MIMO dataset (lab)	
	Mean error	Median error	Mean error	Median error
Method to calculate illuminant of segments				
White Patch	7.53	6.18	6.43	6.22
Grey World	9.67	7.98	3.74	3.57
Grey Edge-1	8.03	6.79	3.58	3.14
Grey Edge-2	7.51	7.10	3.53	3.13
Grey Edge-3	8.27	7.44	3.43	3.00
Grey Edge-4	8.17	8.24	3.55	3.18
Grey Edge-5	8.52	7.43	3.50	3.07
Grey Edge-10	8.00	6.35	3.60	3.02
Grey Edge-20	9.08	6.99	3.87	3.55
Grey Edge-35	9.06	9.16	3.96	3.47
Grey Edge-50	9.42	9.65	4.26	3.63
Mean White Patch	6.81	5.09	3.53	3.17

Ara analitzarem l'algorisme quan fa les segmentacions en l'espai Lab.

Si ens fixem en la taula 5 veurem que, en el dataset real l'algorisme per estimar els il·luminants dels segments que millor funciona és el Mean White Patch, no obstant això, en el dataset lab és el Gray Edge d'ordre 3. En aquest cas, funciona aproximadament bé en els dos datasets.

En la taula 6 podem observar com, en el dataset real funciona millor amb Grey Edge mentres que al dataset del laboratori torna a ser millor el Mean White Patch.

TAULA 4: MITJA I MITJANA DE L'ERROR EN GRAUS DE L'ALGORISME PENSAT PER IMATGES AFECTADES AMB MÉS D'UN IL·LUMINANT A MLS DATASET REALITZANT LA SEGMENTACIÓ EN L'ESPAI HSV.

HSV segmentation	MLS dataset (real)		MLS dataset (lab)	
	Mean error	Median error	Mean error	Median error
Method to calculate illuminant of segments				
White Patch	8.31	9.27	15.15	15.48
Grey World	8.40	7.49	16.21	15.38
Grey Edge-1	6.55	6.63	15.24	14.74
Grey Edge-2	7.69	6.55	15.68	16.36
Grey Edge-3	7.65	6.80	15.31	15.09
Grey Edge-4	7.80	6.46	16.55	16.27
Grey Edge-5	8.39	6.85	16.25	15.97
Grey Edge-10	8.83	7.83	15.90	15.78
Grey Edge-20	9.24	7.96	16.49	15.95
Grey Edge-35	10.23	9.49	16.58	16.57
Grey Edge-50	10.10	9.08	18.10	16.56
Mean White Patch	7.33	5.98	13.97	13.65

TAULA 6: MITJA I MITJANA DE L'ERROR EN GRAUS DE L'ALGORISME PENSAT PER IMATGES AFECTADES AMB MÉS D'UN IL·LUMINANT A MLS DATASET REALITZANT LA SEGMENTACIÓ EN L'ESPAI LAB.

Lab segmentation	MLS dataset (real)		MLS dataset (lab)	
	Mean error	Median error	Mean error	Median error
Method to calculate illuminant of segments				
White Patch	7.17	8.12	14.86	15.25
Grey World	9.57	8.55	16.52	15.92
Grey Edge-1	7.09	7.53	14.95	14.74
Grey Edge-2	7.44	7.06	15.17	15.06
Grey Edge-3	8.20	7.85	15.30	15.35
Grey Edge-4	8.47	8.39	15.95	15.58
Grey Edge-5	9.31	8.07	15.17	15.25
Grey Edge-10	10.17	8.55	15.22	15.24
Grey Edge-20	10.25	8.69	15.40	15.11
Grey Edge-35	10.91	10.93	16.17	15.76
Grey Edge-50	10.36	9.77	18.38	16.92
Mean White Patch	7.69	8.32	13.53	13.02

Finalment analitzarem l'algorisme quan realitza la segmentació en l'espai RGB.

Si ens fixem en la taula 7 podem veure com també funciona millor el Gray Edge. Curiosament, al dataset del laboratori funciona millor quan utilitzem l'algorisme Grey Edge d'ordre 5 i 10.

En la taula 8 veiem com, en el cas del dataset real, el que millor es comporta es Grey Edge de primer ordre i en el laboratori el Mean White Patch.

TAULA 7: MITJA I MITJANA DE L'ERROR EN GRAUS DE L'ALGORISME PENSAT PER IMATGES AFECTADES AMB MÉS D'UN IL-LUMINANT A MIMO DATASET REALITZANT LA SEGMENTACIÓ EN L'ESPAI RGB.

RGB segmentation	MIMO dataset (real)		MIMO dataset (lab)	
	Mean error	Median error	Mean error	Median error
Method to calculate illuminant of segments				
White Patch	10.46	9.26	5.12	4.97
Grey World	6.51	4.89	3.60	3.17
Grey Edge-1	5.96	4.16	3.41	3.00
Grey Edge-2	5.42	4.13	3.39	3.02
Grey Edge-3	5.37	4.25	3.36	2.96
Grey Edge-4	5.84	4.60	3.30	3.04
Grey Edge-5	5.78	4.61	3.29	2.99
Grey Edge-10	5.67	5.23	3.29	2.97
Grey Edge-20	5.37	4.88	3.42	3.05
Grey Edge-35	6.30	5.93	3.92	3.48
Grey Edge-50	7.19	5.59	3.68	3.06
Mean White Patch	5.53	4.53	3.32	2.96

TAULA 8: MITJA I MITJANA DE L'ERROR EN GRAUS DE L'ALGORISME PENSAT PER IMATGES AFECTADES AMB MÉS D'UN IL-LUMINANT A MLS DATASET REALITZANT LA SEGMENTACIÓ EN L'ESPAI RGB.

RGB segmentation	MLS dataset (real)		MLS dataset (lab)	
	Mean error	Median error	Mean error	Median error
Method to calculate illuminant of segments				
White Patch	8.91	9.84	14.40	14.66
Grey World	8.42	8.54	15.42	15.42
Grey Edge-1	7.04	7.38	14.52	14.06
Grey Edge-2	7.41	7.49	14.90	14.21
Grey Edge-3	8.09	7.85	14.66	14.18
Grey Edge-4	8.21	7.85	15.44	14.85
Grey Edge-5	8.69	8.15	14.52	13.64
Grey Edge-10	9.14	8.57	14.06	13.71
Grey Edge-20	9.04	8.91	14.48	14.18
Grey Edge-35	9.51	8.67	15.03	13.80
Grey Edge-50	9.35	7.47	16.83	16.09
Mean White Patch	8.44	9.43	12.79	12.44

TAULA 9: COMPARACIÓ DE MITJA I MITJANA DE L'ERROR EN GRAUS DELS ALGORISMES ESMENTATS ANTERIORMENT EN EL MIMO DATASET.

Method	MIMO dataset (real)		MIMO dataset (lab)	
	Mean error	Median error	Mean error	Median error
Single Il-luminant				
Grey Edge-1	5.76	4.51	3.07	2.85
Grey Edge-2	5.06	3.64	3.09	2.93
Grey Edge-3	5.54	4.37	3.05	2.90
Multiple Il-luminant HSV space segmentation				
Grey Edge-2	6.74	5.58	13.10	13.90
Grey Edge-35	8.28	8.20	11.81	10.63
Mean White Patch	7.14	7.75	10.70	11.83
Multiple Il-luminant Lab space segmentation				
Grey Edge-3	8.27	7.44	3.43	3.00
Mean White Patch	6.81	5.09	3.53	3.17
Multiple Il-luminant RGB space segmentation				
Grey Edge-2	5.42	4.13	3.39	3.02
Grey Edge-3	5.37	4.88	3.42	2.96
Grey Edge-10	5.67	5.23	3.29	2.97

4.4 Comparació dels resultats

En aquest apartat farem una comparació entre els millors resultats que hem obtingut de cada apartat i algorismes que componen l'estat de l'art per veure què tal funcionen.

A la taula 9 podem veure com cap versió de l'algorisme multi-il-luminant ha millorat els resultats dels algorismes amb només un il-luminant. Cal destacar com, el Grey-Edge d'ordre 3 ha donat els millors resultats en la mitjana de l'error al dataset del laboratori.

De la resta d'algorismes, podem veure com els que millors funcionen són els que la segmentació es realitza en l'espai RGB. HSV funciona molt malament en aquest dataset, especialment en el dataset del laboratori, donant uns resultats pèssims.

Els algorismes que hem agafat a la taula 10 són del paper del MIMO dataset [15]. Com podem veure, el nostre algoritme funciona una mica pitjor que MIRF als dos datasets però, en canvi, al dataset del laboratori el nostre algoritme és substancialment millor que el proposat per Gijsenij et al [16].

Podem observar diverses apreciacions a la Taula 11. Entre d'elles que quan l'algorisme segmenta en l'espai HSV, funciona molt bé amb el dataset real. També és important recalcar que, l'algorisme que millor ha funcionat en el dataset real quan parlem de la mitja de l'error ha sigut el Grey Edge d'ordre 3.

Tot i que es recomana passar l'imatge a l'espai Lab per obtenir millors resultats en segmentar l'imatge, podem veure com en aquest cas no ha donat gaire bons resultats i, fer-ho en RGB ha sigut el que millor resultat ha donat el dataset del laboratori.

Els valors dels algorismes a l'estat de l'art de la taula 12 els hem obtingut al paper de l'algorisme MLS [16], en el qual analitzen algorismes ja implementats i un que im-

TAULA 10: COMPARACIÓ DEL RENDIMENT DEL NOSTRE ALGORITME AMB L'ESTAT DE L'ART EN EL MIMO DATASET.

Method	MIMO dataset (real)		MIMO dataset (lab)	
	Mean error	Median error	Mean error	Median error
Our Method				
Multiple Il·luminant RGB space segmentation				
Grey Edge-2	5.42	4.13	3.39	3.02
Grey Edge-3	5.37	4.88	3.42	2.96
Grey Edge-10	5.67	5.23	3.29	2.97
State of the art				
Gijsenij et al GW [16]	4.4	4.3	6.4	5.9
Gijsenij et al WP [16]	4.2	3.8	5.1	4.2
MIRF GW [15]	3.7	3.4	3.1	2.8
MIRF WP [15]	4.1	3.3	3.0	2.8

TAULA 11: COMPARACIÓ DE MITJA I MITJANA DE L'ERRORE EN GRAUS DELS ALGORISMES ESMENTATS ANTERIORMENT EN EL MLS DATASET.

Method	MLS dataset (real)		MLS dataset (lab)	
	Mean error	Median error	Mean error	Median error
Single Il·luminant				
Grey Edge-1	6.39	6.68	14.27	13.90
Grey Edge-3	6.35	7.60	14.23	13.68
Grey Edge-4	5.92	7.21	15.27	14.50
Grey Edge-5	6.88	7.51	14.35	13.64
Multiple Il·luminant HSV space segmentation				
Grey Edge-1	6.55	6.63	15.24	14.74
Mean White Patch	7.33	5.98	13.97	13.65
Multiple Il·luminant Lab space segmentation				
Grey Edge-1	7.09	7.53	14.95	14.74
Grey Edge-2	7.44	7.06	15.17	15.06
Mean White Patch	7.69	8.32	13.53	13.02
Multiple Il·luminant RGB space segmentation				
Grey Edge-1	7.04	7.38	14.52	14.06
Mean White Patch	8.44	9.43	12.79	12.44

TAULA 12: COMPARACIÓ DEL RENDIMENT DEL NOSTRE ALGORITME AMB L'ESTAT DE L'ART EN EL MLS DATASET.

Method	MLS dataset (real)	MLS dataset (real)
	Median error	Median error
Our Method		
Multiple Il·luminant HSV space segmentation		
Mean White Patch	5.98	13.65
Our Method		
Multiple Il·luminant RGB space segmentation		
Mean White Patch	9.43	12.44
State of the art		
LSAC Exp. filter [19]	7.4	13.2
LSAC Gauss filter [19]	7.4	12.9
Retinex [20] Implement.	7.7	13.0
Retinex [21] Implement.	7.6	14.1
Gisenij et al WP [16]	6.7	13.2
Gisenij et al GGW [16]	7.0	13.1

plementen ells, basat en agafar una imatge i realitzar una graella, i a cada quadrat aplicar-hi un algorisme d'un sol il·luminant. En aquest paper únicament utilitzen la mediana degut a que consideren que és un valor més acurat de cara a calcular el rendiment de l'algorisme.

Podem veure com el nostre algorisme es comporta millor que els algorismes esmentats que componen part de l'estat de l'art.

5 CONCLUSIONS

La primera conclusió que podem obtenir són que l'algorisme Grey Edge, encara que freqüentment s'utilitza en la seva versió d'ordre 1 i 2, també funciona amb ordres més grans. De fet, el dataset MIMO, en el seu subdataset laboratori, la millor mitjana de l'error l'obtenim del Grey Edge d'ordre 3.

També hem explorat com aplicar un algorisme d'un il·luminant a múltiples il·luminants. Concretament segmentant l'imatge en un número de segments determinat per un algorisme que es basa en l'histograma de l'imatge i després utilitza K-means++ per acabar aplicant l'algorisme d'un il·luminant a cadascun dels segments. D'aquesta manera estimem un valor d'il·luminant per cada segment i després, píxel per píxel, obtenim un factor de correcció de la constància de color.

L'algorisme que hem obtingut, dona bons resultats i és competent. Si el comparem amb alguns dels algorismes que componen l'estat de l'art, podem veure que els valors que obtenim en els datasets són semblants, fins i tot millors en algunes situacions.

Per aquest motiu podem concloure que hem complert els objectius proposats.

6 AGRAÏMENTS

En el desenvolupament d'aquest projecte, el meu tutor Carlos Alejandro Parraga m'ha anat guiant quan m'encallava i ensenyant el coneixement necessari per fer-ho possible a través de diverses tutories. És per aquest motiu que em sento molt agraït, ja que sense la seva ajuda no hauria pogut acabar aquest projecte.

REFERÈNCIES

- [1] M. Ebner. (2007). Color Constancy. Universitat Würzburg, Germany. John Wiley & Sons.
- [2] A. Gijsenij, T. Gevers, and J. van de Weijer. (2011). Computational color constancy: Survey and experiments. (pp. 2475-2489). IEEE Transactions on Image Processing.
- [3] D. Cheng and others. (2016). Two Illuminant Estimation and User Correction Preference. (pp. 469-477). IEEE Conference on Computer Vision and Pattern Recognition
- [4] O. Sidorov. (2018). Conditional GANs for Multi-Illuminant Color Constancy: Revolution or Yet Another Approach? (pp. 1748-1758). The IEEE Conference on Computer Vision and Pattern Recognition (CVPR).
- [5] I. Domislovic. (2021). Outdoor daytime multi-illuminant color constancy. (pp. 270-275). 12th International Symposium on Image and Signal Processing and Analysis (ISPA).
- [6] A. Hussain and A. Sheikh. (2018) Color Constancy Algorithm for Mixed-Illuminant Scene Images. (pp. 8964-8976). IEEE Access.
- [7] J. Barron and Y. Tsai. (2016) Fast Fourier Color Constancy. Cornell University.
- [8] Research Website on Illuminant Estimation. P. Das, A.Gijsenij and T. Gevers <http://www.colorconstancy.com> Last checked: 05/03/2022.
- [9] Cube++ dataset. (2021) E. Ershov and A. Savchik. <https://zenodo.org/record/4153431#.YjNgjEDMKUI> Last checked: 05/03/2022.
- [10] A. Akbarinia and C. A. Parraga. (2016). Colour Constancy Beyond the Classical Receptive Field". Journal of Latex class files. Vol(14), No(8).
- [11] M. Solà. (2018). "Balance de blancos con más de una iluminación". UNIVERSITAT AUTÒNOMA DE BARCELONA (UAB).
- [12] Mahmoud Afifi, Brian Price, Scott Cohen, and Michael S. Brown, "When Color Constancy Goes Wrong: Correcting Improperly White-Balanced Images", CVPR, 2019.
- [13] Juan (2013). Color Constancy Algorithms (Gray World, White Patch, Modified White Patch, ETC) <https://es.mathworks.com/matlabcentral/fileexchange/41341-color-constancy-algorithms-gray-world-white-patch-modified-white-patch-etc> Last checked: 02/04/2022.
- [14] J. van de Weijer, T. Gevers and A. Gijsenij, "Edge-Based Color Constancy", in IEEE Transactions on Image Processing, vol. 16, no. 9, pp. 2207-2214, Sept. 2007, doi: 10.1109/TIP.2007.901808.
- [15] S. Beigpour, C. Riess, J. van de Weijer, E. Angel, "Multi-Illuminant Estimation With Conditional Random Fields", in IEEE Transactions on Image Processing, vol. 23, no. 1, pp. 83-96, Oct. 2013, doi: 10.1109/TIP.2013.2286327
- [16] A. Gijsenij, R. Lu and T. Gevers, Color Constancy for Multiple Light Sources, in IEEE Transactions on Image Processing, vol. 21, no. 2, pp. 697-707, Feb. 2012, doi: 10.1109/TIP.2011.2165219.
- [17] M. A. Hussain, A. Sheikh-Akbari and E. Abbott Halpin, Color Constancy for Uniform and Non-Uniform Illuminant Using Image Texture, in IEEE Access, vol. 7, pp. 72964-72978, 2019, doi: 10.1109/ACCESS.2019.2919997.
- [18] J. von Kries, Influence of adaptation on the effects produced by luminous stimuli, in Sources of Color Science, D. L. MacAdam, Ed. Cambridge, MA, USA: MIT Press, 1970, pp. 109-119.
- [19] M. Ebner, "Color constancy based on local space average color," Mach. Vis. Appl., vol. 20, no. 5, pp. 283-301, Jun. 2009.
- [20] B. Funt, F. Ciurea, and J. McCann, "Retinex in MATLAB," J. Electron. Imag., vol. 13, no. 1, pp. 48-57, Jan. 2004.
- [21] V. Struc and N. Pavešić, "Photometric normalization techniques for illumination invariance," in Advances in Face Image Analysis: Techniques and Technologies, Y. Zhang, Ed. Hershey, PA: IGI Global, 2010, ch. 15.