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

Peña de Pedro, Carlos; Parraga, Carlos Alejandro, dir. Aprenentatge computacional de nous colors amb molt pocs exemples. 2022. (958 Enginyeria Informàtica)

This version is available at <https://ddd.uab.cat/record/264157>

under the terms of the  license

Aprentatge computacional de nous colors amb molt pocs exemples

Carlos Peña de Pedro

Resum– El projecte consisteix en implementar la classificació de nous colors en un model existent de machine learning basat en la generació d'el·lipsoides per representar colors. La premissa és utilitzar pocs exemples de color, per tant, no es podran utilitzar una gran quantitat d'imatges per entrenar el model. Es designarà una metodologia per poder portar a terme la implementació justificant totes les decisions realitzades. Finalment es comprovaran i discutiran els resultats mitjançant diferents mètodes incloent múltiples imatges de testeig i una enquesta.

Paraules clau– Machine learning, espai de color, classificació de color, NICE, Model el·lipsoidal.

Abstract– The project consists of implementing the classification of new colours in an existing machine learning model based on the generation of ellipsoids to represent colours, the premise is to use few colour examples, therefore, it will not be possible to use a large amount of images to train the model. A methodology will be designed to carry out the implementation justifying all the decisions made. Finally, the results will be tested and discussed using different methods including multiple test images and a poll.

Keywords– Machine learning, colour classification, colour space, NICE, ellipsoidal model.

1 INTRODUCCIÓ - CONTEXT DEL TREBALL

LA segmentació d'imatges basada en colors es un tema àmpliament tractat perquè té molta importància en les àrees de l'anàlisi d'imatges, el reconeixement de patrons i altres aplicacions relacionades amb la visió per computador.

Molts models de machine learning poden ser utilitzats per segmentar una imatge en diversos colors, aquests es divideixen en dos grans grups supervisats o no supervisats.

- No Supervisats: Clustering, Adaptive k-mean clustering.

Els models d'aprenentatge no supervisat, permeten que el model aprengui del conjunt de dades d'entrenament sense etiquetar i a partir d'aquestes, busca relacions i forma patrons per donar diferents valors a les sortides.

- Supervisats de Classificació: Support Vector Machine, Naïve Bayes, Neural Networks.

Aquests models, permeten classificar en múltiples categories un conjunt de dades a partir d'un entrenament amb dades ja etiquetades. Utilitzant aquestes dades, aprenen les característiques corresponents a cada categoria amb la finalitat de poder classificar futures dades.

Dintre d'aquests dos tipus de models de *machine learning*, els supervisats són els més rellevants per al projecte, ja que permeten classificar els diferents píxels d'una imatge, posant-li una etiqueta corresponent al color predit. En el cas dels no supervisats, podrien dividir la imatge, però no etiquetar els píxels en diferents colors.

És important fer aquesta distinció, perquè classificar colors no es una tasca trivial. El concepte de color és abstracte. En realitat, es tracta només de diferents longituds d'ona de la llum que es capturada per l'ull, projectada en la retina i processada al còrtex visual per obtenir el resultat final.

1.1 Estat de l'art

En aquesta secció s'explicaran possibles models de classificació de colors.

• E-mail de contacte: 1532529@uab.cat
 • Menció realitzada: Computació
 • Treball tutoritzat per: Carlos Alejandro Parraga (Centre de Visió per Computador)
 • Curs 2021/2022

- Support Vector Machine Multiclass:

Aquest model consisteix en generar diferents hiperplans dins l'espai de les mostres, per dividir-lo en diferents subconjunts del mateix, corresponent cada subconjunt a una etiqueta. En el cas d'un classificador de color, es crearan hiperplans que dividiran l'espai de color en el qual estan codificades les mostres, per exemple, en cas de ser un espai 3D com RGB, es crearà un pla de dues dimensions, d'aquesta manera es creen diferents subseccions corresponents a cadascun dels colors etiquetats.

Els hiperplans son generats maximitzant una funció que calcula la distancia d'aquest, a les diferents classes formades per les mostres etiquetades.




Fig. 1: Model Support Vector Machine [1]

- Neural Network:

El model més popular i que ha sigut una completa revolució en les últimes dècades, són les *neural networks*. Són formades per múltiples nodes disposats en capes. Tots els nodes estan interconnectats entre si, simulant el cervell humà. Una *neural network* sempre disposa d'una capa d'entrada, una de sortida i múltiples capes ocultes entre mig. Cada node o neurona artificial, té un pes i un llindar associats. Si la sortida de qualsevol node individual està per sobre del valor llindar especificat, aquest node s'activa enviant dades a la següent capa de la xarxa. En cas contrari, no es transmeten dades a la següent capa de la xarxa.

Un exemple punter aplicat a la classificació de colors, és el model creat per Alban Flachot et al[2] En aquest estudi, es buscava crear un model que pogués classificar colors sense importar la il·luminació, això es conegut com constància de color. Aquesta *neural network* utilitza imatges 2D, simulades amb 2.115 formes 3D, 1.600 reflectàncies de chips Munsell i 278 il·luminacions distintes. El resultat són 446.400 imatges d'entrenament.

- NICE:

Un altre model molt important per la classificació de colors es va plantejar al 2016. Aquest tenia com objectiu relacionar els resultats de segmentació amb els




Fig. 2: Model Neural Network

mecanismes psicofísics produïts al còrtex visual, simulant la resposta isoïdal-el·lipsoidal de les neurones corticals visuals (NICE, de El·lipsoides de color neurals isoresponsius)[3].

El mètode utilitzat per realitzar-lo va ser un experiment psicofísic on es mesurava en diferents individus de cultura similar, els límits categòrics dels 11 colors bàsics proposats per Berlin i Kay [4].

Per representar aquests límits de forma similar al nostre cervell, es realitzen una sèrie de transformacions per arribar a l'espai LMS que representen els 3 tipus de cons fotoreceptors de la retina humana; a continuació es normalitzen aquests valors arribant a l'espai l_sy, corresponent a la representació del color prèviament al pas de les neurones corticals del cervell. Finalment, s'utilitza una fórmula que s'adapta als resultats obtinguts amb forma de el·lipsoides per entrenar el model.

Degut a que la premissa del treball és aconseguir implementar un model robust amb poques imatges d'entrenament, s'arriba a la conclusió de que la millor manera, és utilitzar un model més senzill que pugui donar un bon resultat sense la necessitat de milers d'imatges d'entrenament. Per això he decidit, utilitzant el mateix model el·lipsoidal, crear un programa que, mitjançant l'aprenentatge computacional supervisat, pugui generar l'el·lipsoides corresponent de forma general per a qualsevol color i posteriorment segmentar-lo.

2 OBJECTIUS

- Entendre el funcionament dels models estat de l'art de classificació de color, especialment el model NICE (Parraga & Akbarinia, 2016), en el qual es basa el projecte.
- Fer una exploració dels possibles colors a afegir i seguint una metodologia detallada, escollir entre 10-15 colors que tinguin una major aportació al model.
- Crear o buscar un *dataset* dels diferents colors escollits, per a poder utilitzar-les posteriorment per l'entrenament.
- Fer les diferents modificacions necessàries al model, per incorporar els colors escollits.

- Comprovar mitjançant diversos tests que, al afegir els nous colors, es classifiquin correctament i no es superposin completament amb els 11 colors originals.

3 METODOLOGIA I DESENVOLUPAMENT

3.1 Selecció de colors

Els colors seleccionats per afegir al algorisme han de seguir un mètode ben establert i un propòsit concret, no poden ser colors escollits al atzar.

El propòsit decidit, ha sigut seleccionar els colors en base a quins d'ells donaran un millor resultat alhora de segmentar objectes i classificar imatges. D'aquesta manera, es podrà utilitzar el classificador per tractar imatges de forma que sigui més fàcil la seva posterior classificació.

Per aconseguir aquesta finalitat es segueix el mètode utilitzat en [5]. D'un subconjunt de 28 colors addicionals, es calcula la correlació de cadascun d'ells amb els colors del subconjunt format en un primer moment pels 11 colors bàsics. El color amb una menor correlació i per tant, el que donarà una major discriminació al model alhora de classificar imatges, serà afegit al subconjunt de colors. Per al projecte es buscaven afegir entre 10-15 colors. El número escollit ha sigut de 14, perquè així es forma un total de 25, corresponent amb el major rendiment aconseguit pel model de classificació d'imatges [5]. Els colors afegits són: Turquesa, verd oliva, verd menta, borgonya, lavanda, magenta, salmó, cian, beix, rosa intens, verd fosc, oliva, lila i groc pàl·lid Fig 3.



Fig. 3: Colors seleccionats per afegir al model

3.2 Creació del dataset

Per a la creació del *dataset* dels diferents colors a afegir, es van pensar diferents mètodes. En un primer moment, la idea era utilitzar imatges sense tractar, esperant que el propi algorisme d'entrenaments que funciona amb probabilitats, filtrés el soroll dels colors no desitjats. Aquesta versió però, funciona malament en casos amb **datasets** poc balancejats, per això es va descartar.

Una altre idea, era escollir imatges sense soroll utilitzant *macbeth charts* [6]. Aquesta opció tenia dos desavantatges; el primer era, que l'espectre del color escollit no seria tan ampli perquè els píxels d'una mateixa imatge no variarien excessivament en il·luminació i to, perquè es tracta d'un color pla. L'altre és que, no tots els colors pensats per afegir, es troben dins de les *macbeth charts*.

El mètode escollit finalment, consisteix en utilitzar l'algorisme *K-means* sobre els píxels de la imatge i agafar el nucli que tingui més píxels classificats filtrant així el soroll. Fig 4.

El valor del paràmetre k , que es correspon amb el nombre de nuclis generats, ha sigut escollit mitjançant un

algorisme que avalua els resultats utilitzant el Calinski-Harabasz Criterion[7], mètode basat en la variància intra i intercluster, per generar una puntuació als resultats amb diferents valors de k . A més es limita el nombre de k , fent d'aquesta forma, que diferents tonalitats d'un mateix color o diferents il·luminacions no produeixin que el color es classifiqui en dos nuclis diferents.

Aquests mètode també té un inconvenient i es que, les imatges utilitzades per a classificar, han de ser escollides tenint en compte que el color predominant en la imatge, ha de ser el que s'ha de classificar. També, en cas de que la imatge tingui molts colors diferents, com que existeix un límit de k nuclis generats, altres colors a banda del predominant seran classificats en el mateix nucli, provocant que existeixi el soroll que es pretenia eliminar. Això implica certa rigurositat i temps extra invertit alhora de seleccionar imatges, i no dona tanta llibertat com sí ho feia el primer model amb soroll.



Fig. 4: Imatge entrenament pre i post Kmeans

3.3 Selecció d'espais de color

Per entrenar el model, s'utilitzen diverses imatges originalment codificades en l'espai rgb (normalment l'estàndard). Existeixen però espais més adients per tal de representar un major nombre de colors amb major precisió. Un dels exemples més clars es tracta de l'espai CIELAB [8], aquest té la qualitat de ser perceptiblement lineal, és a dir, que la magnitud de canvi de valor es correspon amb un canvi en la percepció del color amb la mateixa magnitud. Utilitza un eix l^* per determinar el nivell de lluminositat, corresponent el valor 100 amb blanc i el 0 amb negre. Els dos eixos restants a^* i b^* determinen el color, el a^* correspon als nivells de verd-vermell quan a^* és negatiu el color es verd i positiu vermell, el b^* correspon als nivells de blau = $-b^*$ groc = $+b^*$. Fig 5.

En el cas del projecte s'utilitza una versió normalitzada de l'espai, on cadascun dels eixos lab comprenen valors del 0 al 255.

També s'ha considerat l'espai l^*s_y , dissenyat per modelar el processament de color realitzat per les neurones de la regió *Lateral Geniculate Nucleous* (LGN)[9]. Aquests va ser utilitzat per modelar els el·lipsoides amb els resultats obtinguts de l'experiment psicofísic realitzat en [3]. Aquests




Fig. 5: Representació de l'espai CIELAB

experiment però, es va dur a terme, en un espai molt controlat per obtenir els millors resultats possibles. Per tant, es possible que els resultats no es traslladin d'una forma tan positiva al entrenar el model amb imatges D'Internet.

Finalment es va entrenar el model amb els dos espais esmentats i, es van fer diverses proves per comparar els dos resultats.

3.4 Funcionament del model

En primera instància, es carreguen les imatges dels diferents colors a afegir, es realitza el *K-means* i es guarden els píxels del centroid més gran, etiquetant-los amb el color corresponent.

Quan es tenen tots els píxels etiquetats amb els colors, es passen a l'espai desitjat L_{sy} o LAB, s'eliminen els duplicats 22 i es crea un *array* amb un valor per cada píxel únic i la seva probabilitat de pertànyer a cadascun dels 25 colors. La probabilitat es calcula mitjançant la fórmula 1, on " P_c " és la probabilitat de que el píxel pertanyi al color c ", " N_c " el nombre de vegades que el píxel és etiquetat amb el color c i " N " el nombre total de repeticions del píxel. Per exemple, si el píxel [93 193 185] és etiquetat 7 vegades com a color turquesa i 3 de color verd, fent un total de 10 aparicions, la probabilitat del píxel serà 0.7 turquesa i 0.3 verd. Imatges del procés es poden veure en els annexos.

$$P_c = \frac{N_c}{N} \quad (1)$$

Mitjançant un llindar que per defecte pren el valor de 0.5, el píxel s'utilitzarà per entrenar o no l'el·lipsoide del color si la probabilitat corresponent és superior al llindar.

En el cas per defecte de 0.5, només els píxels que són clarament d'una categoria, seran utilitzats per l'entrenament. En situacions amb menys número de mostres es pot reduir aquest llindar per fer la selecció menys estricte, de forma que amb un valor inferior a 0.5, un mateix píxel pot ser utilitzat per entrenar més d'una categoria. Amb el valor per defecte es possible que un píxel no s'utilitzi per l'entrenament i es podrien considerar mètodes alternatius per

evitar-ho, per exemple seleccionar el color amb major probabilitat del píxel.

El model consta de 9 paràmetres que formen l'el·lipsoide, els punts centrals de cada eix, l'escala de cada eix i la rotació a cada eix. Els punts centrals són inicialitzats amb la mitjana dels píxels, l'escala amb la desviació típica i la rotació amb 0. El nivell de pertinença d'un píxel a cadascun dels el·lipsoïdes es calcula mitjançant la fórmula 2.

$$B_t(x) = \frac{1}{1 + e^{g_t(|p - c_t| - h)}} \quad (2)$$

" B_t " és el grau de pertinença de 0 a 1 del píxel a l'el·lipsoide " t ", c_t correspon al centre del el·lipsoide sent " p "- c_t " la distància del píxel a classificar al centre i " h " és la distància des de el píxel fins a tocar l'el·lipsoide.

Per crear un el·lipsoide d'un nou color es passa tot el conjunt de píxels únics que pertanyen al color. Es realitza un entrenament que ajusta els diferents paràmetres de l'el·lipsoide inicial, fins que la diferència entre el píxels donats i les prediccions de pertinença del color són menors que el llindar. Es posa com a límit de rotació π i com a límit de escala que sigui major a 0.

3.5 Consideracions de rendiment

Segons el número d'iteracions del model, la creació d'un el·lipsoide varia entre els 2 i 10 minuts. Això fa que el temps d'entrenament total sigui al voltant de 1 hora a l'espai lab en canvi el temps en l'espai L_{sy} és notablement superior. Aquesta diferència de temps ve donada per la representació utilitzada en lab (255 255 255), per tant poden existir fins a 16.581.375 píxels únics (no repetits). En realitat en el *dataset* d'entrenament són només 618.080 píxels únics, i en canvi, en L_{sy} la representació utilitza valors decimals arribant a 998.000 píxels en el *dataset*. Aquesta diferència provoca que al entrenar els el·lipsoïdes amb tots els píxels únics la diferència sigui notòria.

Es un primer moment, es van intentar fer canvis en la resolució de les imatges per tal de millorar el rendiment. La realitat es que aquest canvi no tenia un gran efecte, per que com a tal, el tractament de les imatges no era el que ocupava el major temps del programa. Indirectament però, es reduïa el nombre de píxels únics al fer la reducció reduint el temps. Finalment es va descartar la tècnica perquè era contraproduent ja que reduïa la precisió dels resultats.

3.6 Ajustos posteriors

Durant les proves del model amb diferents color afegits, existia un error recurrent on els nous el·lipsoïdes ocupaven l'espai dels 11 colors originals, això provocava per exemple, que el color salmó sempre es classifiqués per sobre del vermell. El problema esdevenia de que en la base de dades de probabilitats, els colors inicials no eren presents en un primer moment, perquè es posseïen els valors dels el·lipsoïdes generats per l'experiment psicotròpic de NICE. Per solucionar això, es van agafar imatges dels colors bàsics i es van posar al conjunt d'entrenament de forma des-balancejada, sent els píxels de colors bàsics superiors en nombre a la resta i per tant, fent que l'algorisme formés el·lipsoïdes nous que no es superposin totalment amb els antics.

4 RESULTATS

Per mesurar la qualitat de l'algorisme evitant la parcialitat provocada pel cervell humà, que ens fa veure colors pròxims de forma similar, encara que existeixi una considerable diferència entre els seus to o il·luminació, hem fet servir imatges *ground truth* utilitzades per mesurar el color com *macbeth charts*, un *munshell chart* generat artificialment amb diferents valors rgb i imatges utilitzades freqüentment per la classificació de color com *peppers*, d'aquesta forma podem estar segurs de que els colors que es veuen en les imatges es corresponen o no amb els que volíem classificar.

En les imatges classificades es pot veure la original etiquetada com "orgi" una imatge on es substitueix el color de cada píxel per una mostra estàndard del color classificat, etiquetada amb "max". En els annexos es pot veure amb major claredat la pertinença de cada píxel a les diferents classes de colors.

4.1 El·lipsoides generats

Es pot observar que els el·lipsoides en l'espai lab, es troben intuïtivament bé situats dins dels eixos; els el·lipsoides de color verdós es troben a la part esquerra del gràfic "a-b", on recordem que un menor valor de "a" corresponia amb color verd i a major valor "a" es corresponia a un valor vermell. El mateix passa amb l'eix vertical on el blau es troba situat a la part inferior i el groc a la superior. També es pot observar que els el·lipsoides es surten dels valors de l'espai, això es possible perquè en l'entrenament no vam limitar els valors màxims que podrien tenir els el·lipsoides, provocant que es pugui jugar més amb la mida i posició del centre d'aquests per representar de millor manera els colors.

En el cas de lsy es pot observar com els resultats no són tan bons (alguns el·lipsoides nous no s'han generat correctament), comprenent un espai tant petit que són imperceptibles. Els colors afectats són el verd oliva i el borgonya.




Fig. 6: El·lipsoides generats dels 25 colors en l'espai lab




Fig. 7: El·lipsoides generats dels 25 colors en l'espai lsy 1-a

4.2 Macbeth Chart

Per aquesta comprovació s'ha generat una taula *Macbeth* artificialment, seguint els valors de color rgb estàndard usats per calibrar colors.

En la primera comparació amb la *Macbeth chart 8* es pot observar la classificació realitzada amb l'entrenament en espai lab. La majoria de colors són classificats adequadament, existeixen però casos no tant clars, el primer d'ells es tracta del tercer color de la primera fila corresponent amb *blue sky*, aquest color probablement es correspon més amb els colors blau o cian que amb el lavanda que es el seleccionat per el model. Un altre cas no tant segur, es troba al tercer color de la segona fila *Moderate red*, que té una mica més similitud amb el color salmó que amb el *rose*, que és el decidit per l'algorisme. Finalment el to poc saturat del *cyan* corresponent amb l'últim color de la tercera fila es detectat com a blau en comptes de *cyan*.

En la segona imatge 9 es troba la mateixa classificació realitzada ara amb l'espai lsy, a diferència de lab, classifica de forma més precisa els diferents blaus, però té altres problemes, en el cas de *foliage green* quart color de la primera fila el detecta com a verd, el color més similar a aquest hauria de ser el verd menta o verd oliva. Altres colors com el *purple* i el *moderate red* de la segona fila quart i tercer colors respectivament, són classificats com a lavanda i vermell, tenint altres colors al model amb saturacions més similars a aquests el púrpura i el salmó respectivament.

4.3 Munsell Chart

El *Munsell chart* també ha sigut generat artificialment utilitzant 10 il·luminacions diferents i 41 tons formant els 410 chips presents a l'imatge.

En la primera imatge corresponent amb la classificació lab 10, es poden observar zones de color no del tot correctament definides, especialment es pot veure en la zona dels verds, existeixen espais entre el color oliva i el groc que




Fig. 8: Macbeth chart classificada per l'algorisme entrenat en espai lab




Fig. 9: Macbeth chart classificada per l'algorisme entrenat en espai lsy

están definits com a verd i haurien d'entrar més en el color oliva, també hi ha poca definició entre el rose i els tons vermell, borgonya i salmó.




Fig. 10: Munsell chart classificada per l'algorisme entrenat en espai lab

La segona imatge corresponent amb la classificació lsy 11, es pot observar la inexistència de colors classificats com

a borgonya, verd oliva, i verd menta. Les causes poden ser degudes a que els colors esmentats són molt similars en aquest espai als colors bàsics i per tant, els el·lipsoides generats no han pogut convergir correctament. Altres canvis a destacar són el cian que ocupa un espectre molt més gran del color blau, el marró que també es classificat en molts més chips *munsell*.




Fig. 11: Munsell chart classificada per l'algorisme entrenat en espai lsy

4.4 Peppers

En aquesta imatge podem observar colors naturals exposats a diferents il·luminacions. A simple vista els colors de les diferents hortalisses exposades les veiem com un mateix to de color, en canvi en l'algorisme, es pot veure que les distintes zones exposades a la llum, són considerades d'un altre color; per exemple, les parts brillants del pebrot vermell són classificades com a salmó.



Fig. 12: imatge peppers classificada per l'algorisme entrenat en espai lab

4.5 Mandrill

La imatge del mandril proporciona una gran varietat de pigmentació de colors en un espai petit, d'aquesta manera podem observar que l'algorisme representa correctament petites variacions de color del pelatge verd al groc i al negre. Al veure la imatge classificada s'entén correctament el que es mostra a la imatge.



Fig. 13: imatge peppers classificada per l'algorisme entrenat en espai lsy




Fig. 16: imatge Island classificada per l'algorisme entrenat en espai lab




Fig. 14: imatge Mandrill classificada per l'algorisme entrenat en espai lab




Fig. 17: imatge Island classificada per l'algorisme entrenat en espai lsy




Fig. 15: imatge Mandrill classificada per l'algorisme entrenat en espai lsy

4.6 Island

Aquesta imatge ha sigut seleccionada perquè el model no fa un bon treball al classificar els seus colors. El principal problema es que el color cian del cel no es diferencia del blau del mar provocant que al fer la segmentació no es pugui diferenciar clarament els elements. El mateix passa amb la vegetació del fons, les muntanyes y els núvols que son classificades amb colors blau fent que el paisatge general no es pugui entendre fàcilment.

4.7 Enquesta de classificació del color

L'enquesta ha sigut realitzada fent servint google forms [10].

Ha consistit en un primer apartat sobre qüestions de dades personals: nom, gènere, edat i si es presentava alguna condició que dificultava la percepció del color, com ara el daltonisme. Seguidament s'explicaven i es mostraven les diferents imatges utilitzades per valorar resultats i la seva classificació per colors. Finalment un últim apartat on es demanava una valoració general de la classificació, i una valoració de cadascun dels colors, segons si els percebien correcta o incorrectament classificats, utilitzant de base el resultat de les imatges mostrades. També es preguntava si consideraven necessari algun color no present en el classificador i quin.

Les imatges de classificació mostrades són les produïdes per l'entrenament realitzat en espai lab, això es degut a que són les que millors resultats generals produïen i una enquesta component els dos espais, resultaria en una tasca massa complexa amb moltes imatges que observar i comparar.

En un principi es volia fer una comparació de com afectava l'edat i el gènere en la percepció del color, però finalment les dades obtingudes no han sigut suficients per poder trobar una correlació significativa.

La mostra de persones enquestades ha consistint en un total de 22. La valoració mitjana del model es de 7,2 sobre 10 com es pot veure en la figura 18, això denota que la gent considera que aquest classifica correctament en general.

En la figura 19, podem veure que la gent considera especialment ben classificats els colors bàsics, superant el 50% en tots els casos excepte el púrpura, rosa, gris i marró.

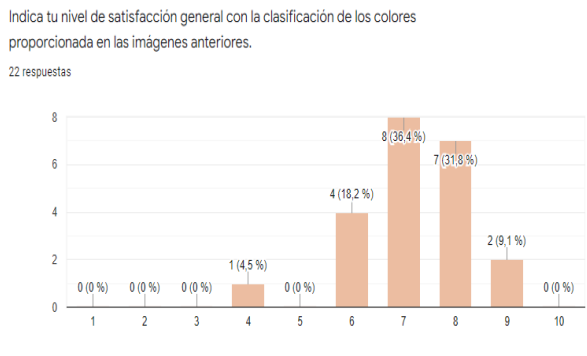


Fig. 18: Valoració general del model pels usuaris de l'enquesta

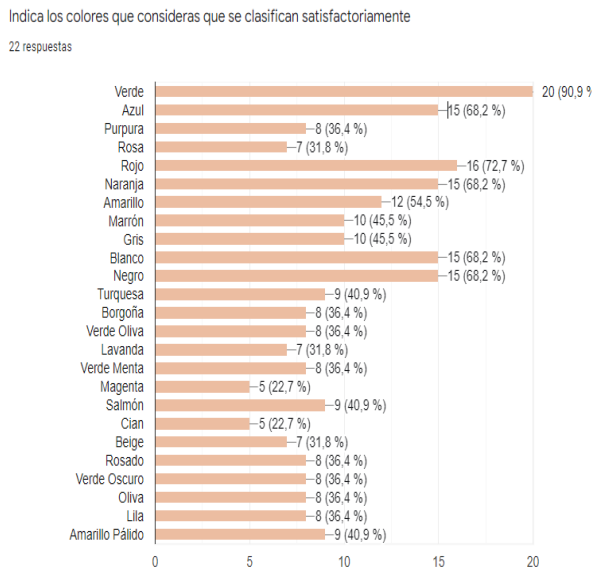


Fig. 19: Colors satisfactoriament classificats segons els usuaris de l'enquesta

El verd es el més destacat amb 20 dels 22 enquestats, destacant-lo com ben classificat. El fenomen de que els 11 colors bàsics tinguin millor valoració pot ser degut a que són colors més fàcilment identificables per les persones de forma innata al voltant del món, com senyalen diferents estudis [11]. També pot ser degut a que les imatges de mostra presenten en abundància els colors bàsics i no tant la resta, produint que sigui més difícil la valoració.

En la figura 20 podem veure els colors que la gent considera en general incorrectament classificats, el cian és considerat el pitjor amb un 36%. Això es degut principalment, a la imatge de l'illa on la classificació lab no aconsegueix diferenciar el color blau del mar amb el del cel. Molta gent ha comentat això en la part de comentaris extres. Altres colors destacats de negativament són el rosa, púrpura, blau i groc amb un 23% de vots.

Altres dades rellevants són que 19/22 persones creuen que el model no necessita afegir més colors, les restants han suggerit com a colors blau cel, blau klen i ocre.

Com ha suggeriments dues persones consideren que els colors bàsics predominen en excés sobre la resta.

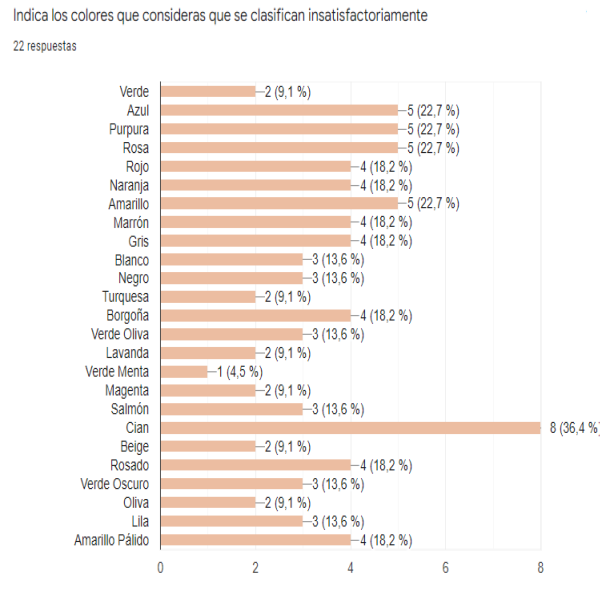


Fig. 20: Colors in-satisfactoriament classificats segons els usuaris de l'enquesta

5 CONCLUSIONES

Es pot afirmar que s'han assolit els objectius proposats per el treball, s'han testejat diferents metodologies per arribar finalment a poder incorporar nous colors al model d'el·lipsoïdes proposat sense la necessitat de requerir de una gran quantitat d'imatges, també s'ha aconseguit testejar la eficàcia del model utilitzant diversos mètodes.

5.1 Treball futur

Els següents passos per millorar el mètode seria millorar el *dataset* i el model de selecció de píxels per ser més senzill, això no comportaria necessàriament fer el *dataset* més extens, si no seleccionar millors imatges, amb més variació de píxels que puguin completar l'espectre sense dels colors classificats sense un excés en la repetició dels mateixos, com es dona en aquest cas.

El mètode de *k-means* per obtenir els píxels de les imatges, comporta una selecció a vegades massa concreta e ineficient de les imatges. La solució idònia doncs, seria permetre píxels classificats inadequadament, però gracies a la gran varietat i diferencia de proporció en el color al que realment pertocuen, l'error es corregeix al calcular la probabilitat de pertinença.

Un altre camí d'estudi seria provar altres espais del color per veure com es comporta el model amb ells i que beneficis comporten sobre els ja provats. També es podria escollir un altre set de colors seguint un altre criteri diferent al de segmentació d'objectes, seguit en aquest estudi, per obtenir un classificador encastat a una aplicació que requereixi la classificació de colors concrets.

AGRAÏMENTS

Primer m'agradaria agrair a la meua família per suportar-me en els constants moments de nervis que he passat durant

el meu pas per la universitat i la realització d'aquest treball.

També voldria agrair a tots els participants en l'enquesta de valoració de l'algoritme per ajudar a completar els resultats del treball a expenses del seu temps.

Finalment voldria agrair la paciència i implicació del meu tutor del TFG Carlos Alejandro Parraga que ha programat diferents sessions per poder portar un bon seguiment del treball i poder resoldre dubtes, a més de sempre aportar idees des de la seva experiència que m'han resultat molt beneficioses pel desenvolupament del treball.

REFERÈNCIES

- [1] "Support Vector Machine (SVM)", MathWorks, <https://es.mathworks.com/discovery/support-vector-machine.html>
- [2] Alban Flachot, Arash Akbarinia, Heiko H. Schütt, Roland W. Fleming, Felix A. Wichmann, Karl R. Gegenfurtner; Deep neural models for color classification and color constancy. *Journal of Vision* 2022;22(4):17. doi: <https://doi.org/10.1167/jov.22.4.17>.
- [3] Parraga CA, Akbarinia A (2016) NICE: A Computational Solution to Close the Gap from Colour Perception to Colour Categorization. *PLoS ONE* 11(3): e0149538. <https://doi.org/10.1371/journal.pone.0149538>
- [4] [3] Berlin B, Kay P. Basic color terms: their universality and evolution. Berkeley; Oxford. <https://files.eric.ed.gov/full-text/ED019655.pdf> (accessed February 20, 2022).
- [5] Yu, L., Zhang, L., van de Weijer, J., Khan, F. S., Cheng, Y., & Parraga, C. A. (2018). Beyond Eleven Color Names for Image Understanding. *Machine Vision and Applications*, 29(2), 361-373. doi: 10.1007/s00138-017-0902-y.
- [6] McCamy, Calvin S. and Marcus, H. and Davidson, J. G.,J. *Appl. Photogr. Eng., A color-rendition chart 1976*
- [7] Debomit Dey, Çalinski-Harabasz Index – Cluster Validity indices — Set 3", GeekforGeeks, <https://www.geeksforgeeks.org/calinski-harabasz-index-cluster-validity-indices-set-3/> 2022.
- [8] Jochum Beetsma; The CIELAB L*a*b* System – the Method to Quantify Colors of Coatings.
- [9] Horwitz GD, Hass CA. Nonlinear analysis of macaque V1 color tuning reveals cardinal directions for cortical color processing. *Nature Neuroscience*. 2012;15(6):913–U145. pmid:WOS:000304546700020.
- [10] Google Forms, <https://www.google.es/intl/es/forms/about/>
- [11] Baronchelli A, Gong T, Puglisi A, Loreto V. Modeling the emergence of universality in color naming patterns. *Proc Nat Ac Sci USA*. 2010;107(6):2403–7.

APÈNDIX

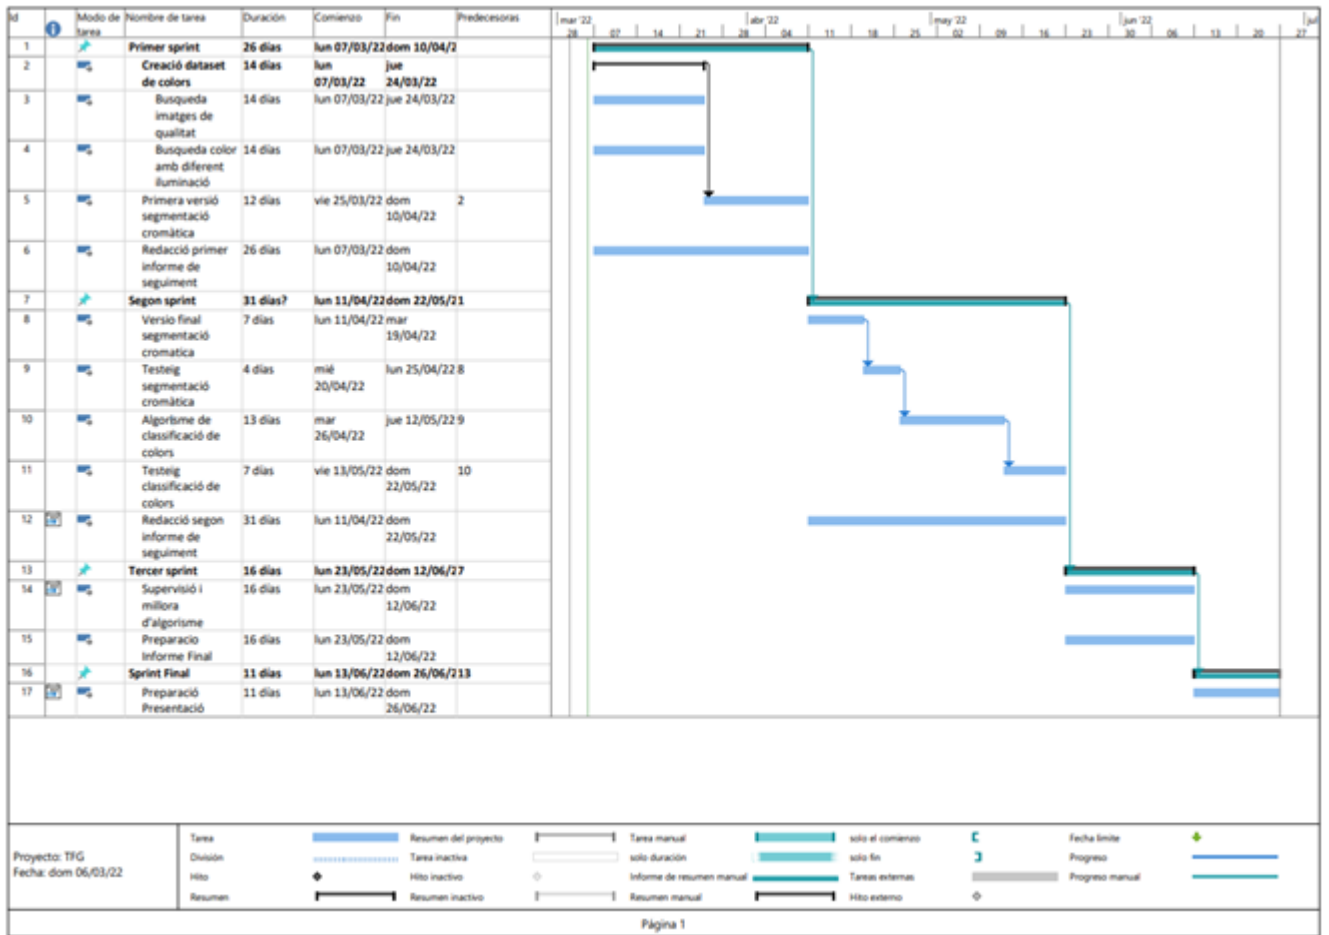


Fig. 21: Diagrama de gantt del projecte

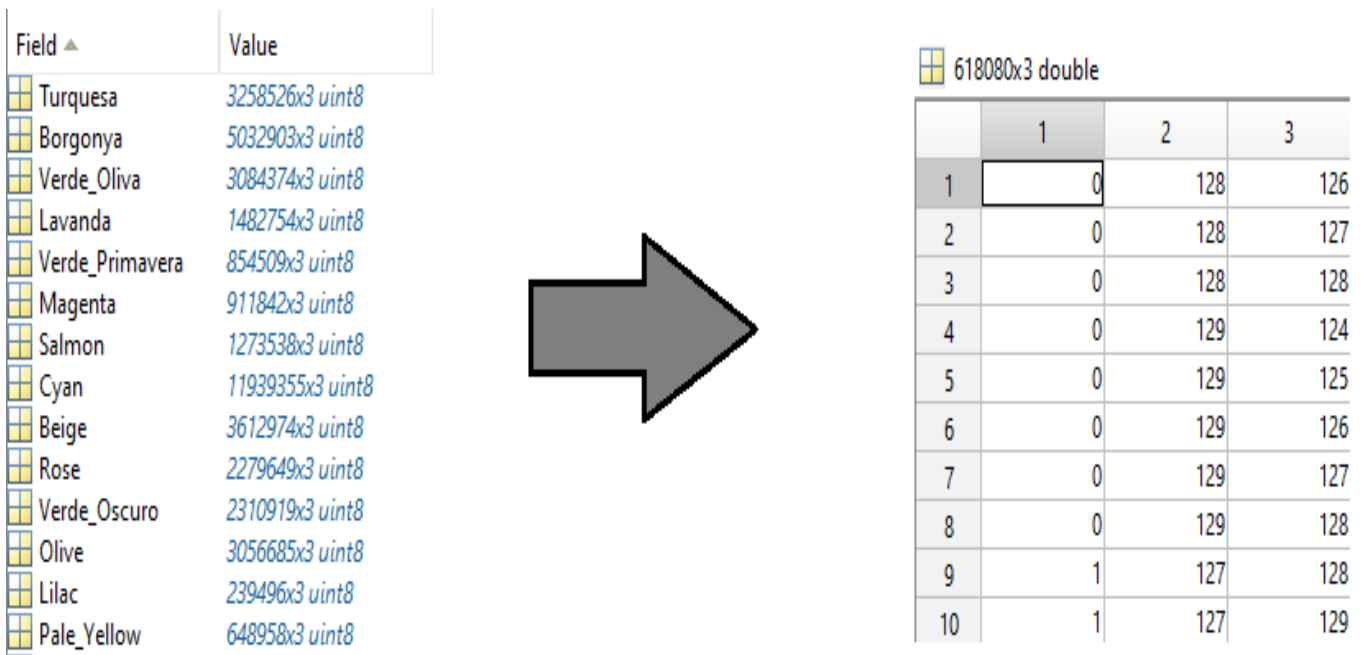


Fig. 22: Pas dels arrays de píxels de cada categoria de color a un array de píxels sense repetició

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25
1	0	0	0	0	0	0	0	0	0	0	0.0476	0	0.0238	0	0	0	0.0476	0	0	0.3095	0	0.5714	0	0	0
2	0	0	0	0	0	0	0	0	0	0	0.0602	0	0.1807	0	0	0	0.1325	0	0	0.5301	0	0.0361	0.0120	0	0
3	0	0	0	0	0	0	0	0	0	0	0.0126	0	0.4079	0	0.2898	0	0.0236	0	0	0.2441	0	0.0047	0	0	0
4	0	0	0	0	0	0	0	0	0	0	0.2857	0	0	0	0	0	0	0	0	0.0714	0	0.3571	0.2857	0	0
5	0	0	0	0	0	0	0	0	0	0	0.1143	0	0	0	0	0	0	0	0	0.0571	0	0.7571	0.0714	0	0
6	0	0	0	0	0	0	0	0	0	0	0.0435	0	0	0	0	0	0.0072	0	0	0.2029	0	0.6594	0.0072	0	0
7	0	0	0	0	0	0	0	0	0	0	0.0667	0	0.1733	0	0.1467	0	0.1067	0	0	0.1733	0	0.1333	0	0	0
8	0	0	0	0	0	0	0	0	0	0	0.0117	0	0.1897	0	0.3443	0	0.0281	0	0	0.4075	0	0.0023	0	0	0
9	0	0	0	0	0	0	0	0	0	0	0.0333	0	0.0167	0	0	0	0.2333	0	0	0.6500	0	0.0167	0	0	0
10	0	0	0	0	0	0	0	0	0	0	0.0506	0	0.2405	0	0	0	0.1646	0	0	0.3165	0	0.2278	0	0	0

Fig. 23: Probabilitats dels diferents píxels únics de pertinença a cada color



Fig. 24: Percentatge de pertinença de cada píxel de l'imatge del munsell chart als el·lipsoides entrenats en Lab, corresponent el color més blanc a major pertinença i negre cap pertinença.

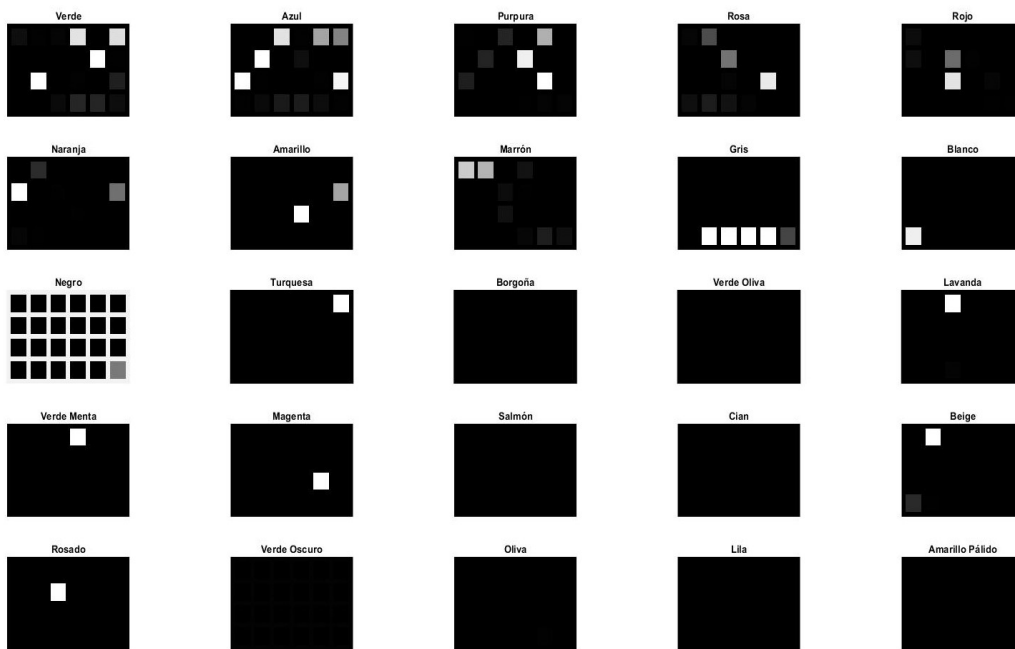


Fig. 25: Percentatge de pertinença de cada píxel de l'imatge del Macbeth chart als el·lipsoides entrenats en Lab, corresponent el color més blanc a major pertinença i negre cap pertinença.

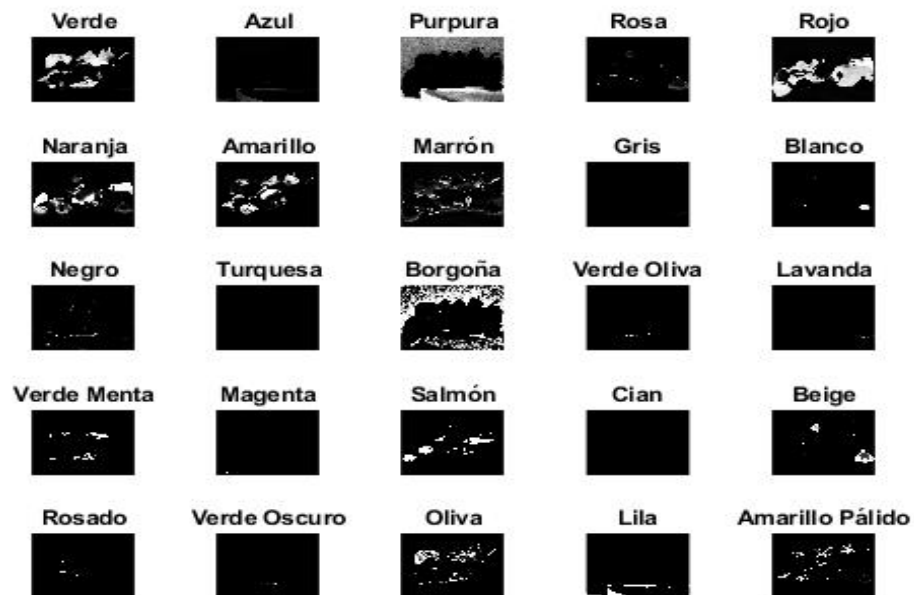


Fig. 26: Percentatge de pertinença de cada píxel de l'imatge Peppers als el·lipsoides entrenats en Lab, corresponent el color més blanc a major pertinença i negre cap pertinença.

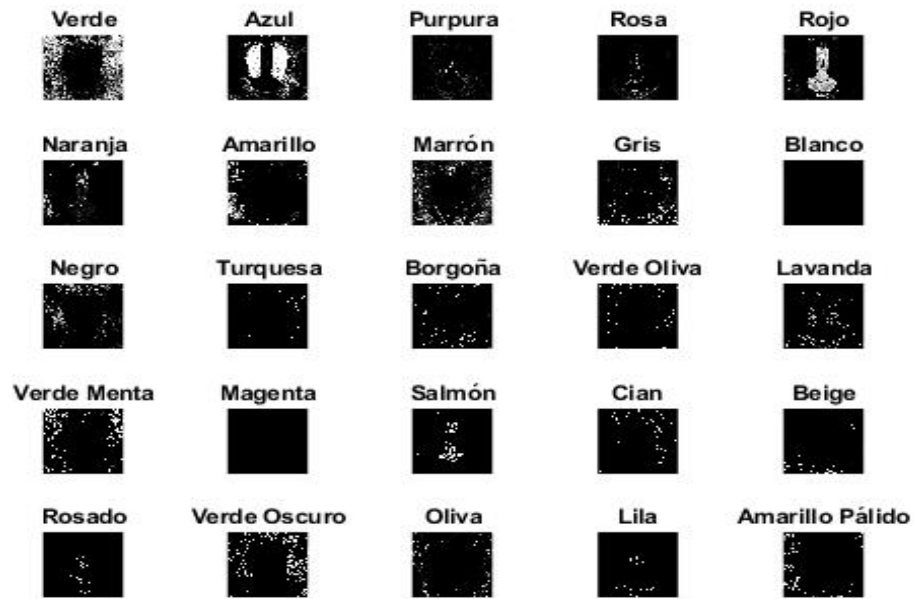


Fig. 27: Percentatge de pertinença de cada píxel de l'imatge Mandrill als el·lipsoides entrenats en Lab, corresponent el color més blanc a major pertinença i negre cap pertinença.



Fig. 28: Percentatge de pertinença de cada píxel de l'imatge Island als el·lipsoides entrenats en Lab, corresponent el color més blanc a major pertinença i negre cap pertinença.