

UNIVERZA V LJUBLJANI
FAKULTETA ZA RAČUNALNIŠTVO IN INFORMATIKO

Rok Kreslin

**Barvna konstantnost z uporabo
barvnih podprostorov**

DIPLOMSKO DELO
NA UNIVERZITETNEM ŠTUDIJSKEM PROGRAMU
RAČUNALNIŠTVA IN INFORMATIKE

MENTOR: doc. dr. Peter Peer

Ljubljana, 2012

Rezultati diplomskega dela so intelektualna lastnina avtorja in Fakultete za računalništvo in informatiko Univerze v Ljubljani. Za objavlanje ali izkoriščanje rezultatov diplomskega dela je potrebno pisno soglasje avtorja, Fakultete za računalništvo in informatiko ter mentorja.

Besedilo je oblikovano z urejevalnikom besedil $\text{\LaTeX}$.



Št. naloge: 01830/2012

Datum: 03.04.2012

Univerza v Ljubljani, Fakulteta za računalništvo in informatiko izdaja naslednjo nalogo:

Kandidat: **ROK KRESLIN**

Naslov: **BARVNA KONSTANTNOST Z UPORABO BARVNIH PODPROSTOROV**
COLOR CONSTANCY USING COLOR SUBSPACES

Vrsta naloge: Diplomsko delo univerzitetnega študija

Tematika naloge:

Preučite postopke za modeliranje barve, tako z vidika človeka kot naprav. Osredotočite se na zagotavljanje barvne konstantnosti. Naredite pregled postopkov za detekcijo osvetlitve na sliki ter postopkov za transformacijo osvetlitve na sliki. Nato opišite in implementirajte nov postopek za transformacijo osvetlitve z uporabo barvnih podprostorov. Vse postopke med seboj primerjajte ter poročajte o njihovi učinkovitosti.

Mentor:


doc. dr. Peter Peer



Dekan:


prof. dr. Nikolaj Zimic

IZJAVA O AVTORSTVU DIPLOMSKEGA DELA

Spodaj podpisani Rok Kreslin, z vpisno številko **63070111**, sem avtor diplomskega dela z naslovom:

Barvna konstantnost z uporabo barvnih podprostorov

S svojim podpisom zagotavljam, da:

- sem diplomsko delo izdelal samostojno pod mentorstvom doc. dr. Petra Peera,
- so elektronska oblika diplomskega dela, naslov (slov., angl.), povzetek (slov., angl.) in ključne besede (slov., angl.) identični s tiskano obliko diplomskega dela,
- soglašam z javno objavo elektronske oblike diplomskega dela v zbirki "Dela FRI".

V Ljubljani, dne 15. septembra 2012

Podpis avtorja:

Hvala mentorju doc. dr. Petru Peeru za pomoč in vodenje pri izdelavi diplomske naloge. Hvala dr. Luis Galu Corzu in dr. Pilar Marii Calvo-Salomon za idejo o metodi transformacije slik z barvnimi podprostori. Hvala staršem, sestri in bratu, ki so mi stali ob strani tekom celotnega študija. Hvala Melani za vzpodbudo pri izdelavi diplomske naloge.

Kazalo

Seznam uporabljenih kratic in simbolov

Povzetek

Abstract

1	Uvod	1
2	Modeliranje barve	3
2.1	Barva in človeško oko	3
2.2	Osvetlitev in odbojne lastnosti predmetov	5
2.3	Barvni prostori in modeli	6
2.3.1	XYZ barvni prostor	8
2.3.2	xyY barvni prostor	8
2.3.3	RGB barvni model	8
2.3.4	rg barvni model	9
2.3.5	HSV, HSI, HSL barvni modeli	9
2.4	Nastanek digitalne fotografije in model sveta	9
3	Barvna konstantnost	13
3.1	Barvna konstantnost in človeški vizualni sistem	13
3.2	Barvna konstantnost v digitalnem svetu	14
3.3	Detektiranje osvetlitve na sliki	16
3.3.1	Siv svet	18
3.3.2	Bela lisa	19

3.3.3	Siv rob	19
3.3.4	Preslikava barvnega obsega	20
3.3.5	Bayesova barvna konstantnost	22
3.3.6	Barvna konstantnost z uporabo naravnih statistik slike	24
3.3.7	Semantična barvna konstantnost	27
3.4	Transformacija slike	30
3.4.1	Transformacija slike v barvnem prostoru, ki temelji na RGB barvnem modelu	32
3.4.2	Transformacija slike v barvnih prostorih, dobljenih z linearno transformacijo XYZ barvnega prostora	33
3.5	Transformacija slik z uporabo barvnih podprostorov	35
3.5.1	Transformacija slik, ki vsebujejo Macbethovo barvno razporednico	41
3.5.2	Transformacija slik, ki ne vsebujejo Macbethove barvne razporednice	42
4	Primerjava metod	45
4.1	Primerjava metod za detekcijo osvetlitve	46
4.2	Primerjava metod za transformacijo slik z znano osvetlitvijo .	51
4.2.1	Vizualna primerjava slik z znano osvetlitvijo, transfor- miranih z metodo barvnih podprostorov	57
4.3	Primerjava metod za transformacijo slik z neznano osvetlitvijo	60
4.3.1	Vizualna primerjava slik z neznano osvetlitvijo, trans- formiranih z metodo barvnih podprostorov	66
5	Zaključek	69
	Seznam slik	70
	Seznam tabel	72
	Literatura	79

Seznam uporabljenih kratic in simbolov

CIE – *Commission internationale de l'éclairage* – mednarodna komisija s področja osvetlitve.

RGB – *Red, Green, Blue* – aditivni barvni model.

rg – kromatični barvni model, ki temelji na RGB barvnem modelu.

sRGB – barvni prostor, ki temelji na RGB barvnem modelu.

AdobeRGB – barvni prostor, ki temelji na RGB barvnem modelu.

XYZ – referenčni barvni prostor.

xyY – kromatični barvni prostor, ki temelji na XYZ barvnem prostoru.

HSV, HSL, HSI – *Hue, Saturation, Value, Lightness, Intensity* – barvni prostori, ki barvo opišejo s tonom, nasičenostjo in količino svetlosti.

CMOS – *Complementary Metal Oxide Semiconductor* – tehnologija za izdelavo slikovnih senzorjev.

CCD – *Charge Coupled Device* – tehnologija za izdelavo slikovnih senzorjev.

D65 – standardna vrednost osvetlitve.

SIFT – *Scale Invariant Feature Transform* – algoritem za iskanje in opis lokalnih lastnosti slike.

CMCCAT2000 – algoritem za barvno transformacijo slike.

Povzetek

Zahteva po barvno konstantnih slikah se pojavi vsaj na področju fotografije, tiska in računalniškega vida. Človek se je skozi evolucijo naučil izločiti vpliv osvetlitve na barvni izgled predmetov, kar je cilj algoritmov področja digitalne barvne konstantnosti. V diplomskem delu opišemo sodobne algoritme dvostopenjskega procesa digitalne barvne konstantnosti, ki sestoji iz detekcije osvetlitve in transformacije slike. Predlagamo novo metodo za transformacijo slike, ki temelji na uporabi barvnih podprostorov. Objektivna primerjava algoritmov za detekcijo osvetlitve pokaže, da se najbolje obnese algoritem Bayesove barvne konstantnosti. V primeru transformacije slike, katere osvetlitev poznamo, se najbolje obnese predlagani algoritem za transformacijo slike z uporabo barvnih podprostorov. Vizualni pregled slik, transformiranih z metodo uporabe barvnih podprostorov, razkrije dve pomanjkljivosti metode: občutljivost na šum in problem ostrih barvnih prelomov. V primeru transformacije slike, katere osvetlitev detektiramo z algoritmom, se vse metode obnesejo podobno. Pravilno detektirana osvetlitev ima na končni rezultat večji vpliv kot uporabljena metoda transformacije. Vizualni izgled slik, transformiranih z metodo barvnih podprostorov, je v primeru napačno detektirane osvetlitve bolj naraven.

Ključne besede:

barvni prostor, barvni podprostor, barvna konstantnost, osvetlitev slike, barvna transformacija

Abstract

Photography, printing and computer vision are the areas where color constancy of images is essential. The human beings have learned to eliminate the effect that illumination has on the color appearance of objects, which is also the goal of color constancy algorithms. In this diploma thesis, we describe modern algorithms of the two-level process of color constancy, which consists of illumination detection and image transformation. We propose a new method for image transformation based on the use of color subspaces.

The objective comparison of the illumination detection algorithms shows that the Bayesian color constancy algorithm proves to be the most effective. In the case of image with known illumination, the suggested algorithm for image transformation with the use of color subspaces proves to be the most effective. Visual analysis of images transformed with the method of using color subspaces, reveals two deficiencies of the method – noise sensitivity and sharp color refractions. In the case of image with unknown illumination, all the methods for image transformation prove to be equally effective. The correct illumination detection has a larger effect on the transformed image as the used method of transformation. In the case of incorrect illumination detection, the visual appearance of images transformed with the color subspace method proves to look more natural.

Keywords:

color space, color subspace, color constancy, image illumination, chromatic adaptation transform

Poglavje 1

Uvod

Vid je sposobnost zaznavanja in interpretacije okolja na podlagi informacije, vsebovane v vidnem delu elektromagnetnega valovanja. Človek fizično zaznava svetlobo z očesom, interpretacija zaznane svetlobe pa se dogaja v možganih. Oko in del možganov, odgovoren za interpretacijo svetlobe, imenujemo človeški vizualni sistem. Ta, poleg drugih čutil, človeku omogoča, da se znajde v dinamičnem, stalno spreminjajočem se okolju.

Ena izmed pomembnih lastnosti človeškega vizualnega sistema je barvna konstantnost. Človeku omogoča, da barve enakih predmetov zazna vedno enako – ne glede na osvetlitev, s katero so predmeti osvetljeni. Banana bo rumene barve ne glede na to, ali jo bomo opazovali zunaj pod soncem ali v notranjosti hiše pod umetno lučjo. Človek bi težje prepoznaval objekte in subjekte, če bi bili ti vedno drugačne barve – odvisno od tega, pod kakšno svetlobo bi jih opazoval.

Senzorji znotraj fotografskih aparatov posnemajo delovanje človeškega očesa. Njihova naloga je, da fizično izmerijo količino svetlobe, ki pade skozi objektiv. Končni produkt teh meritev je digitalna fotografija, katere barve pa se velikokrat razlikujejo od barv, ki jih je opazoval avtor fotografije ob zajemu slike. V opisanem procesu izdelave digitalne slike manjka del človeškega vizualnega sistema, ki poskrbi za barvno konstantnost. Poleg tega, da so barvno konstantne slike videti bolj naravne (fotografski zorni kot), so nujno potrebne

za pravilno delovanje nekaterih algoritmov s področja računalniškega vida, ki se zanašajo na barvno informacijo.

Najpogosteje se za pridobivanje digitalnih barvno konstantnih slik uporablja dvostopenjski proces, ki pa najbrž nima neposredne povezave z barvno konstantnostjo človeškega vizualnega sistema. Beseda *najbrž* v prejšnjem stavku je uporabljena zato, ker delovanja človeškega vizualnega sistema v veliki meri še vedno ne poznamo. Najprej detektiramo osvetlitev slike (korak 1), zatem sliko na podlagi informacije o osvetlitvi ustrezno transformiramo (korak 2).

Obstoječe metode za transformacijo slike vse barve na sliki preslikajo z enako transformacijo. Metoda, ki jo predlagamo v diplomskem delu, barve na vhodni sliki razdeli v več skupin in vsako skupino barv preslika s svojo transformacijo. Gre za nov, neraziskan pristop, s katerim želimo zagotoviti, da transformirana slika nima barvnega pridiha, ki se velikokrat pojavi pri obstoječih metodah za transformacijo slik.

Struktura diplomskega dela je sledeča. V drugem poglavju opišemo pojem barve. Kaj barva sploh je, kako deluje človeški vizualni sistem, kako barvo predstavimo v digitalnem svetu in kaj določa barvni izgled predmetov. V tretjem poglavju podrobneje predstavimo pojem barvne konstantnosti. Najprej opišemo, kako človeški vizualni sistem pridobi barvno konstantno sliko, zatem opišemo, kako pridobimo digitalno barvno konstantno sliko. Predstavljeni so nekateri osnovni in kompleksni algoritmi za detekcijo osvetlitve ter obstoječe metode za transformacijo slike. Podrobno opišemo predlagano metodo transformacije slike z uporabo barvnih podprostorov. V četrtem poglavju podamo rezultate objektivne primerjave metod, opisanih v tretjem poglavju. Vizualni pregled transformiranih slik, ki izpostavi prednosti in slabosti predlagane metode ter poda nekaj smernic za nadaljnji razvoj, je prav tako podan v četrtem poglavju. Zaključimo s petim poglavjem, ki povzame rezultate diplomskega dela.


Poglavje 2

Modeliranje barve

2.1 Barva in človeško oko

Barva je odziv možganov na stimulacijo očesa z vidnim delom elektromagnetnega valovanja [1]. Vidni del elektromagnetnega valovanja predstavljajo valovne dolžine med 390 nm in 750 nm, kot prikazuje slika 2.1.

Ker občutek barve nastane v možganih, je subjektiven. Vsak posameznik bo predmet enake barve doživel rahlo drugače. Objektivno lahko barvo opišemo tako, da opišemo porazdelitev elektromagnetnega spektra barve – intenziteto elektromagnetnega valovanja pri različnih valovnih dolžinah. Tak opis barve je redundanten. Razlog je v načinu delovanja človeškega očesa. Oko ob zadostni intenziteti svetlobe zaznava barvo s čepnicami (angl. *cones*), v slabši svetlobi s paličnicami (angl. *rods*). Paličnice so bolj občutljive na svetlobo, vendar niso zmožne natančnega zaznavanja barv. Zato v temi barv skorajda ne zaznavamo.




Slika 2.1: Umestitev vidne svetlobe v spekter elektromagnetnega valovanja.

Obstajajo tri vrste čepnic, ki vzorčijo svetlobo v treh pasovnih širinah:

- L – svetloba dolge valovne dolžine, ki ustreza rdeči barvi,
- M – svetloba srednje valovne dolžine, ki ustreza zeleni barvi,
- S – svetloba kratke valovne dolžine, ki ustreza modri barvi.


Pojav opisuje trikromatična teorija [2], ki pravi, da lahko s pomočjo treh svetlob (rdeče, zelene, modre) opišemo vsako barvo vidnega spektra. Slika 2.2 prikazuje občutljivost različnih vrst čepnic na svetlobo različne valovne dolžine. Čepnice za zaznavanje modre svetlobe imajo maksimalno občutljivost pri 420 nm, čepnice za zaznavanje zelene svetlobe pri 534 nm, čepnice za zaznavanje rdeče svetlobe pa pri 564 nm. Barvo tako objektivno opišemo z jakostjo odziva treh različnih vrst čepnic.



Slika 2.2: Občutljivost različnih vrst čepnic v odvisnosti od valovne dolžine svetlobe.

2.2 Osvetlitev in odbojne lastnosti predmetov

Da bi dobili barvno informacijo, rabimo izvor svetlobe. Ta je lahko naraven (sonce) ali umeten (luči v stanovanju). Zaznano barvo predmetov poleg osvetlitve (angl. *illumination*) določajo odbojne lastnosti (angl. *reflection*) [1]. Te določajo, koliko vidne svetlobe pri določeni valovni dolžini se bo od objekta odbilo in koliko absorbiralo. Slika 2.3 prikazuje, kako različne osvetlitve in odbojne lastnosti predmetov vplivajo na barvni signal. V prvi vrsti imamo osvetlitev, kjer je energija enakomerno razporejena po celotnem vidnem spektru elektromagnetnega valovanja. Predmet svetlobo kratke in dolge valovne dolžine odbija, medtem ko svetlobo srednje valovne dolžine



Slika 2.3: Vpliv osvetlitve in odbojnih lastnosti predmetov na barvni signal. V prvem stolpcu so opisi osvetlitve, v drugem odbojne lastnosti predmetov, v tretjem pa dobljeni barvni signali kot kombinacija osvetlitve in odbojnih lastnosti.

absorbira. Rezultat osvetljevanja predmeta je barvni signal, ki ima identično porazdelitev energije kot opazovani predmet. Ker predmet odbija svetlobo kratke (modri odtenki) in dolge (rdeči odtenki) valovne dolžine, bo človek barvni signal doživel kot roza barvo.

V drugi vrsti imamo opravka z neenakomerno razporeditvijo energije osvetlitve. Ta narašča z valovno dolžino. Takšna osvetlitev bo predmetom dala bolj rdečkast videz. Odbojne lastnosti predmeta so enake kot v prvi vrsti slike 2.3. Rezultat je barvni signal z magnificirano energijo pri višjih valovnih dolžinah. Barva istega predmeta bo pod to osvetlivijo bolj rdečkasta.


Osvetlitev v zadnji vrsti slike 2.3 je podobna kot osvetlitev v drugi vrsti. Odbojne lastnosti predmeta pa so drugačne. Predmet absorbira celotno svetlobo, s katero ga osvetljujemo. Tak predmet imenujemo črno telo (angl. *black body*) [1]. Predmet bo – ne glede na to, s kakšno svetlobo ga osvetljujemo – črne barve. Nasprotno črnemu telesu poznamo tudi belo telo (angl. *white body*), ki popolnoma odbije vso energijo osvetlitve, ki pade nanj.

2.3 Barvni prostori in modeli

Barvni prostor je metoda, s katero določimo, ustvarimo in vizualiziramo barvo [3]. Medtem ko ljudje barvo definiramo z odtenkom, barvitostjo in svetlostjo, lahko računalnik namesto tega uporablja količino rdeče, modre in zelene fosforjeve emisije, potrebne za prikaz neke barve. Večina barvnih prostorov uporablja za opis barve tri ali štiri parametre in izhaja iz trikromatične teorije. Nesmiselno bi namreč bilo, če bi morali pri delu z digitalnimi slikami vsako točko na sliki opisati s porazdelitvijo elektromagnetnega spektra.

Pomembno je, da ločimo med pojmom barvni prostor in barvni model, čeprav se v literaturi velikokrat uporabljata izmenično. Barvni model je abstraktni matematični model za opis barve z n -torkami parametrov. Sam po sebi nima nobene povezave z realnim opisom barv. Povezavo ustvarimo tako, da barvnemu modelu dodamo preslikovalno funkcijo, ki vrednosti v barvnem modelu preslika v referenčni barvni prostor (na primer XYZ, ki je opisan v

nadaljevanju). Tako lahko isti barvni model uporablja več barvnih prostorov. Ločijo se samo v preslikovalni funkciji. Področje znotraj referenčnega barvnega prostora, v katerega se preslika določen barvni prostor, imenujemo barvni obseg (angl. *gamut*) barvnega prostora [1]. Slika 2.4 prikazuje obseg dveh barvnih prostorov, ki temeljita na RGB barvnem modelu. Vidimo, da barvni obseg AdobeRGB barvnega prostora pokriva večje področje, zato lahko v tem prostoru predstavimo večje število barv, kot v sRGB barvnem prostoru.



Slika 2.4: Barvna obsega AdobeRGB in sRGB prostorov v referenčnem xy prostoru. Zaradi lažje ponazoritve sta barvna obsega predstavljena v kromatičnem prostoru (normalizirana svetlost). Področje, omejeno s krivuljo v obliki konjskega kopita, predstavlja vse barve, ki jih človeško oko lahko zazna. Obe področji, omejeni s trikotniki, predstavljata barve, ki jih lahko predstavimo v omenjenih barvnih prostorih. Točka D65 označuje xy vrednost standardne osvetlitve.

2.3.1 XYZ barvni prostor

CIE (fra. *Commission internationale de l'éclairage*) je leta 1931 definiral barvni prostor, ki klasificira barvo glede na sistem človeškega vida. X, Y in Z vrednosti so pridobljene iz odzivov človeškega očesa na svetlobo kratke, srednje in dolge valovne dolžine [1]. Prostor je zgrajen tako, da Y predstavlja svetlost barve. Velikokrat je uporabljen kot referenčni barvni prostor, iz katerega so izpeljani drugi barvni prostori.

2.3.2 xyY barvni prostor

Iz XYZ lahko izpeljemo xyY barvni prostor [1], v katerem x in y komponenta predstavljata kromatičnost barve, Y pa svetlost kot v originalnem barvnem prostoru. Preslikava med obema prostoroma je podana v enačbi (2.1).

$$\begin{aligned}x &= \frac{X}{X + \frac{Y}{Y} + Z} \\y &= \frac{\frac{Y}{Y}}{X + Y + Z}\end{aligned}\tag{2.1}$$

2.3.3 RGB barvni model

Najbolj pogosto uporabljeni barvni model, ki temelji na principu dodajanja barv (angl. *additive color mixing*), je RGB [1]:

- R (angl. *red*) – količina rdeče barve,
- G (angl. *green*) – količina zelene barve,
- B (angl. *blue*) – količina modre barve.

Enostaven je za realizacijo in uporabo v sistemih, vendar neintuitiven za človeka, saj si je težko predstavljati, kakšno barvo dobimo z mešanjem treh primarnih barv. Dva izmed mnogih barvnih prostorov, ki temeljijo na RGB barvnem modelu, sta že prej omenjena sRGB in AdobeRGB.

2.3.4 rg barvni model

rg [1] je 2-dimenzionalen kromatični model (angl. *chromaticity model*), ki vsebuje samo informacijo o kromatičnosti barve; ne vsebuje informacije o intenziteti barve. Pretvorbo med RGB in rg modelom podaja enačba (2.2). Kot bomo videli v nadaljevanju, se rg model uporablja na različnih področjih barvne konstantnosti. rg koordinati sta sorodni xy koordinatam xyZ barvnega prostora.

$$\begin{aligned} r &= \frac{R}{R + G + B} \\ g &= \frac{G}{R + G + B} \end{aligned} \quad (2.2)$$


2.3.5 HSV, HSI, HSL barvni modeli

To je družina barvnih modelov, za katere je značilno, da barvo ločijo na barvni ton (angl. *hue*), nasičenost (angl. *saturation*) in količino svetlosti (angl. *value, intensity, lightness*) [1]. Gre za linearne transformacije RGB barvnega modela. Omenjeni barvni modeli so intuitivni, saj barvo opišejo podobno kot človek.

2.4 Nastanek digitalne fotografije in model sveta

Večina fotografij v današnjem času nastane s pomočjo digitalnega fotoaparata. Slika 2.5 prikazuje poenostavljeno shemo delovanja CMOS (angl. *Complementary metal-oxide-semiconductor*) senzorja v digitalnem fotoaparatu [4]¹. Svetloba vstopi skozi objektiv fotoaparata in se s pomočjo zrcal fokusira na slikovni senzor. Na prvem nivoju potuje skozi IR filter, ki odstrani infrardeči del spektra. Na drugem nivoju imamo različne filtre, ki prepuščajo rdečo, modro oziroma zeleno svetlobo. Na tretjem nivoju imamo svetlobne


¹Poleg CMOS senzorjev se v digitalnih fotoaparatih uporabljajo še CCD (angl. *Charge-coupled device*) senzorji.



Slika 2.5: Poenostavljena shema delovanja CMOS senzorja.

senzorje, ki filtrirano svetlobo pretvorijo v električno napetost. Podatki o napetosti na svetlobnem senzorju se uporabijo za izračun vrednosti slikovnih točk na sliki. Število slikovnih točk je odvisno od ločljivosti senzorja.

Svetloba, ki pade skozi objektiv fotoaparata, je odvisna od osvetlitve scene in odbojnih lastnosti fotografiranih predmetov. Model sveta nam opisuje, kako se svetloba iz vira osvetlitve odbija od predmetov [1]. Slika 2.6 prikazuje dve vrsti odbojev. Del svetlobe, ki pade na predmet, se odbije od površine pod kotom, ki je glede na normalo površine enak vpadnemu kotu. Pojav imenujemo zrcalni odboj (angl. *specular reflection*). Polirane metalne površine svetlobo skoraj v celoti odbijejo zrcalno. Del svetlobe, ki pade na predmet, pa se razprši v vse smeri. V tem primeru gre za difuzni odboj (angl. *diffuse reflection*). Papir je primer materiala, ki svetlobo skoraj v celoti odbije difuzno.



Slika 2.6: Zrcalni in difuzni odboj svetlobe.

Enačba (2.3) formalno povezuje vrednost slikovnega elementa s svetlobo, ki pade na svetlobni senzor [5].

$$f_c(x) = m_b(x) \int_{\omega} I(\lambda) \rho_c(\lambda) S(x, \lambda) d\lambda + m_s(x) \int_{\omega} I(\lambda) \rho_c(\lambda) d\lambda \quad (2.3)$$

$f_c(x)$ je vrednost slikovnega elementa na prostorski koordinati x , pri čemer c predstavlja enega izmed treh barvnih kanalov $\{R, G, B\}$. Koeфициenti $m_b(x)$ in $m_s(x)$ določata količino difuznega in zrcalnega odboja. ω predstavlja valovne dolžine vidnega spektra elektromagnetnega valovanja, $I(\lambda)$ intenziteto osvetlitve pri valovni dolžini λ , $\rho_c(\lambda)$ občutljivost svetlobnega senzorja za barvni kanal c pri valovni dolžini λ in $S(x, \lambda)$ odbojnost opazovanega predmeta na koordinati x pri valovni dolžini λ . Da bi problem poenostavili, velikokrat privzamemo, da imamo opravka s površinami, ki ne vsebujejo zrcalnih odbojev. Enačba (2.3) se poenostavi v enačbo (2.4).

$$f_c(x) = \int_{\omega} I(\lambda) \rho_c(\lambda) S(x, \lambda) d\lambda \quad (2.4)$$


Vrednost slikovnega elementa se spreminja s spremembo osvetlitve ali s spremembo odbojnih lastnosti predmeta. Pri digitalni obdelavi slike poznamo samo končno vrednost slikovnega elementa. Podatka o osvetlitvi ali odbojnih lastnostih predmeta navadno ne poznamo. Kot bomo videli v nadaljevanju, je ravno podatek o osvetlitvi ključen za doseganje barvne konstantnosti.

Poglavje 3

Barvna konstantnost

3.1 Barvna konstantnost in človeški vizualni sistem

Barvna konstantnost (angl. *color constancy*) je sposobnost vizualnega sistema, da kompenzira vpliv osvetlitve na izgled predmetov [6]. Primer: banana bo vedno videti rumeno, ne glede na to, pod kakšno osvetlitvijo jo bomo opazovali. Zato barvna konstantnost predstavlja eno ključnih vlog pri razpoznavanju predmetov. Velik del delovanja človeškega vizualnega sistema, vključno z barvno konstantnostjo, ne znamo v celoti pojasniti. Največkrat privzeti model v literaturi je Retinex model [7]. Ime je sestavljeno iz angleških besed za oko (angl. *retina*) in možgane (angl. *cortex*). Avtor modela je s preprostim eksperimentom dokazal, da zaznana barva v točki ni odvisna samo od spektra svetlobe v dani točki, ampak tudi od spektra svetlobe v okolici te točke. Podobno lahko opazimo tudi na sliki 3.1 (ni del eksperimenta avtorja Retinex modela). Človeški vizualni sistem posebej primerja intenziteto svetlobe, zaznano s čepnicami za svetlobo kratke, srednje in dolge valovne dolžine. S primerjavo pridobljenih intenzitet v dani točki in njeni okolici dobimo količino, imenovano svetlost (angl. *lightness*) (pojem se uporablja v domeni teorije in ni povezan s splošno priznanim pojmom svetlosti), ki se direktno odraža v občuteni barvi predmetov [7].



Slika 3.1: Optična iluzija, ki prikazuje, da je barva v točki odvisna od njene okolice. Barvni vrednosti kvadratov pod črkama A in B sta enaki. Kljub temu človek zazna kvadrat B v svetlejši barvi kot kvadrat A.

3.2 Barvna konstantnost v digitalnem svetu

Če se je človek skozi evolucijo priučil barvne konstantnosti, to ne velja za digitalno kamero. Ta v osnovi ne vsebuje mehanizmov, ki bi podpirali proces barvne konstantnosti, opisan v prejšnjem poglavju. Vrednosti slikovnih točk na sliki so direkten odraz svetlobe, ki pade na svetlobni senzor. Čeprav sliko opazujemo skozi barvno konstantni človeški vizualni sistem, ta ni sposoben realne rekonstrukcije zajete scene. Odbojne lastnosti scene na zajeti sliki namreč niso enake odbojnim lastnostim realne scene. Tudi če sliko opazujemo pod svetlobo, ki ima enako porazdelitev moči spektra kot svetloba ob zajemu slike, doživete barve ne bodo enake.

Digitalna fotografija je eno izmed področij, kjer se pojavi zahteva po barvni konstantnosti. Fotografi si želijo, da bi bile barve na njihovih fotografijah karseda podobne barvam, ki jih je opazoval avtor fotografije ob zajemu slike. Praktično vse digitalne kamere in programi za urejanje fotografij vsebujejo algoritme za nastavitev beline (angl. *white balance*) [8], ki poskrbijo, da barve na zajeti sliki čim bolj odražajo realnost. V prvi vrsti poskrbijo za

pravilen prikaz bele barve, a se transformacija propagira čez celoten razpon barv. Slika 3.2 prikazuje fotografije enake scene, zajete z različnimi nastavitvami beline. Ker je bila slika zajeta pod dnevno svetlobo, nastavitev beline na drugi fotografiji z leve poskrbi za najbolj realen prikaz barv.

Naslednje področje, kjer se pojavi potreba po digitalni barvni konstantnosti, je področje računalniškega vida. V nadaljevanju so opisane tri kategorije algoritmov s področja računalniškega vida, ki za pravilno delovanje potrebujejo barvno konstantno sliko [9]:

Prepoznavanje objektov: Veliko algoritmov za prepoznavanje objektov na sliki uporablja barvno informacijo. Primer: algoritem za iskanje obraza si lahko pri iskanju pomaga z razponom barv značilnih za človeško kožo. Če digitalna kamera osvetlitve scene ne kompenzira, se lahko zgodi, da bo imela koža človeka pod neko osvetlitvijo povsem drugačen razpon barv. Posledično algoritem ne bo znal pravilno poiskati obraza na sliki.


Segmentacija: Recimo, da moramo na spomladanskih slikah pokrajin poiskati gozd. Kot gozd klasificiramo vse, kar je zelene barve. Če bomo ob zajemu slike uporabili nepravilno nastavitev beline, se lahko zgodi, da gozd na sliki ne bo zelene, ampak rumene barve. Rezultat bo nepravilna segmentacija slike.



Slika 3.2: Fotografije enake scene z različnimi nastavitvami beline. Nastavitve beline od leve proti desni: svetloba iz žarnice, dnevna svetloba, svetloba ob oblačnem vremenu, svetloba v senci.

Preiskovanje slikovnih podatkovnih baz: Nekatere aplikacije uporabniku omogočajo iskanje slik na podlagi barvne informacije. Uporabnik izbere barve, ki naj prevladujejo na slikah, ki jih iskalnik vrne. Če so bile slike ob zajemu osvetljene pod nestandardno osvetlitvijo, tak sistem ne bo deloval optimalno.

Omenjena področja so samo nekatera, ki zahtevajo barvno konstantne slike. Da bi algoritmi z omenjenih področij delovali pravilno, jim moramo kot vhod podati barvno konstantno sliko pridobljeno iz originalne slike. Postopek za pridobitev barvno konstantne slike opisuje slika 3.3. Najprej detektiramo



Slika 3.3: Postopek pridobivanja barvno konstantne slike.

osvetlitev vhodne slike. Naloga algoritmov je, da s pomočjo značilnih lastnosti vhodne slike in predznanja ugotovijo, pod kakšno osvetlitvijo je bila zajeta vhodna slika. Informacije o osvetlitvi v drugem koraku uporabimo za transformacijo vhodne slike. Kot rezultat transformacije dobimo barvno konstantno sliko. Opisan dvostopenjski postopek sicer nima neposredne povezave z delovanjem človeškega vizualnega sistema [10], vendar se na področju algoritmične barvne konstantnosti (angl. *computational color constancy*) uporablja najbolj pogosto.

3.3 Detektiranje osvetlitve na sliki

Detekcija osvetlitve je prvi korak v procesu pridobivanja barvno konstantne digitalne slike. Detektiramo samo barvo (kromatičnost) osvetlitve. Barvna konstantnost se ne ukvarja z absolutnimi intenzitetami slikovnih elementov,

ki so odvisne še od ekspozicije (angl. *exposure*), temveč samo z relativnimi razmerji med barvnimi kanali. Pred transformacijo vhodne slike je tako potrebno detektirano osvetlitev normalizirati, na primer pretvoriti v rg kromatični prostor.

Algoritmi, ki jih bomo opisali v diplomskem delu, predvidevajo, da je bila scena s slike osvetljena samo z enim virom svetlobe. Delimo jih v tri večje skupine [5]:

Statični algoritmi (angl. *static methods*): Ti algoritmi za detekcijo osvetlitve uporabljajo samo informacijo s trenutne slike, brez dodatnega predznanja. V nadaljevanju diplome so opisani trije algoritmi s tega področja: siv svet (angl. *Grey-world*), bela lisa (angl. *maxRGB*), siv rob (angl. *Grey-edge*) [11, 12]. Njihova prednost je v preprosti implementaciji in nizki časovni zahtevnosti.

Algoritmi, ki izhajajo iz informacije o barvnem obsegu (angl. *gamut-based methods*): Metode iz te družine se opirajo na dejstvo, da pod določeno osvetlitvijo lahko opazimo samo omejeno število barv. Zato je vsaka barva, ki jo opazimo na sliki in je ne najdemo znotraj barvnega obsega standardne osvetlitve (angl. *canonical gamut*), posledica ne-standardne osvetlitve. Cilj algoritmov je najti preslikavo, ki vse barve, ki jih najdemo na sliki, preslika v notranjost barvnega obsega standardne osvetlitve. V delu podrobneje opišemo osnovno idejo [13] in omenimo nekatere razširitve osnovne ideje [14]. Algoritmi te skupine spadajo med bolj uspešne algoritme za detekcijo osvetlitve, a so računsko zahtevni in posledično časovno potratni.

Algoritmi, ki uporabljajo metode strojnega učenja (angl. *learning-based methods*): Za razliko od statičnih algoritmov se algoritmi te skupine pri določanju osvetlitve opirajo tako na deskriptorje vhodne slike kot na predznanje. V diplomskem delu so opisani trije algoritmi s tega področja: Bayesova barvna konstantnost (angl. *Bayesian color constancy*) [15] določi maksimalno posteriorno verjetnost različnih osvetli-

tev v odvisnosti od trenutne slike, barvna konstantnost z uporabo naravnih statistik slike (angl. *Color constancy using natural image statistics*)[16] izbere najbolj primerno kombinacijo statičnih algoritmov za iskanje osvetlitve, semantična barvna konstantnost (angl. *Using high-level visual information for color constancy*) [17] pa si pri iskanju osvetlitve pomaga s semantičnimi kategorijami na sliki. Uspešnost algoritmov iz te skupine je močno odvisna od učne množice slik, ki jih uporabimo v fazi pridobivanja predznaka. V splošnem moramo uporabiti veliko množico slik, zajetih pod različnimi osvetlitvami.

Vsi algoritmi, ki so opisani v nadaljevanju, zahtevajo na vhodu linearno sliko (brez gama korekcije), opisano z RGB barvnim modelom.

3.3.1 Siv svet

Siv svet [11] je ena izmed prvih metod za detekcijo osvetlitve na sliki. Temelji na predpostavki, da je povprečna barva na sliki akromatična, brezbarvna. Zatorej je vsako odstopanje povprečne barve na sliki od akromatične barve posledica nestandardne osvetlitve. Trojček $e = (e_R, e_G, e_B)$, ki predstavlja detektirano barvo osvetlitve, izračunamo s pomočjo enačbe:

$$e_C = \frac{1}{N} \sum_{i=1}^N p_{(i,C)}, \quad (3.1)$$

pri čemer N predstavlja število slikovnih točk na sliki, $p_{(i,C)}$ vrednost barvnega kanala C slikovnega elementa i . Prednost metode je v enostavni implementaciji in nizki časovni zahtevnosti. Pri šibkih odstopanjih osvetlitve se metoda obnese, medtem ko pri bolj ekstremnih odstopanjih osvetlitve ni uspešna. Osnovna predpostavka metode je za realne slike naivna. Kljub temu se metoda velikokrat uporablja kot referenca za primerjavo z drugimi metodami.

3.3.2 Bela lisa

Metoda temelji na White-patch predpostavki [1], ki trdi, da je maksimalen odziv barvnega kanala posledica površine na sceni, ki popolnoma odbija svetlobo. Takšna površina bo odbila celoten spekter svetlobe, ki pade nanjo iz vira osvetlitve. Posledično bo barva odboja enaka barvi osvetlitve. V praksi predpostavko omilimo in privzamemo, da na sceni obstajajo tri površine, od katerih vsaka odbije maksimalno količino svetlobe iz posameznega barvnega kanala. Dobimo algoritem bele lise [11]. Barvo osvetlitve izračunamo s pomočjo enačbe:

$$e_C = \max(p_{(i,C)}). \quad (3.2)$$

Uspešnost in časovna kompleksnost metode je podobna kot pri metodi sivega sveta. Predpostavka, da imamo na realnih slikah vedno površino, ki popolnoma odbija svetlobo, je naivna. Prav tako je bilo dokazano, da je uspešnost metode močno odvisna od ekspozicije slike [18]. Če je slika preveč osvetljena, pride do odrezovanja barvnih vrednosti (angl. *clipping*): eden ali več kanalov ima maksimalen odziv, ki ga omogoča RGB barvni model pri barvni globini slike. Zato je metoda v splošnem bolj primerna za temnejše slike.

3.3.3 Siv rob

Metoda sivega robu [12] je izpeljanka iz metode sivega sveta. Predvideva, da je povprečna barva na odvodih slike akromatična. Povod za razvoj metode so dala opažanja, da distribucija barve pri odvodih slike najbolj variira v smeri osvetlitve. Za izračun odvoda slike barvnega kanala dp_C uporabimo konvolucijo z odvodom Gaussovega jedra:

$$dp_C = p_C * \frac{\delta^2 G_\sigma}{\delta x \delta y}, \quad (3.3)$$

kjer so p_C vrednosti barvnega kanala C , $*$ operator konvolucije in G_σ gaussovo jedro z standardno deviacijo σ .

Barvo osvetlitve izračunamo s pomočjo enačbe:

$$e_C = \frac{1}{N} \sum_{i=1}^N dp_{(i,C)}, \quad (3.4)$$


kjer je $dp_{i,C}$ vrednost odvoda barvnega kanala C v i -tem slikovnem elementu. Metoda na slikah, kjer je veliko robov, deluje bolje kot metoda sivega sveta. A na račun nekoliko višje časovne zahtevnosti, saj je potrebno izračunati odvod vhodne slike.

3.3.4 Preslikava barvnega obsega

Osnovna ideja metode izhaja iz dejstva, da lahko pod določeno osvetlitvijo opazimo samo omejeno število različnih barv [13]. Pred opazovanjem definiramo tako imenovani standardni barvni obseg, ki predstavlja vse barve vidne pod standardno osvetlitvijo. Če na vhodni sliki opazimo barvo, ki ni znotraj standardnega barvnega obsega, je ta posledica nestandardne osvetlitve. Metoda deluje v dveh korakih. Najprej izračunamo množico vseh možnih preslikav, ki ustrezajo barvnemu obsegu vhodne slike, zatem pa s pomočjo heuristike izberemo optimalno preslikavo. Slika 3.4 predstavlja osnovni princip izračuna množice vseh možnih preslikav. Najprej definiramo barvni obseg vhodne slike (leva slika). Zatam za vsa oglišča na konveksni ovojnici barvnega obsega vhodne slike izračunamo parametrizacije preslikav (desna slika), ki oglišča preslikajo v standardni barvni obseg. Preslikave modeliramo kot diagonalno von Kries skaliranje [19]. Če $[r, g, b]$ predstavlja opis barve pri neki osvetlitvi, potem lahko to isto barvo pod drugo osvetlitvijo opišemo z:

$$\begin{bmatrix} r' \\ g' \\ b' \end{bmatrix} = \begin{bmatrix} k_r & 0 & 0 \\ 0 & k_g & 0 \\ 0 & 0 & k_b \end{bmatrix} \begin{bmatrix} r \\ g \\ b \end{bmatrix}, \quad (3.5)$$

pri čemer k_r , k_g in k_b predstavljajo parametre preslikave. Preslikovanje prelomnih točk na konveksni ovojnici in von Kries skaliranje nam zagotavljata, da bodo v standardni barvni obseg preslikane tudi vse druge barvne točke iz



Slika 3.4: Osnovni princip izračuna množice vseh možnih preslikav. Barvni obseg in preslikave so zaradi lažje vizualizacije podani v 2-dimenzionalnem kromatičnem prostoru. Levo: barvni obseg vhodne slike. Desno: presek množice preslikav, ki ustrezajo točkam na konveksni ovojnici barvnega obsega vhodne slike.

barvnega obsega vhodne slike. Rezultat iskanja predstavlja presek parametrizacij preslikav (desna slika). Odločiti se moramo med večimi preslikavami, ki predstavljajo detektirane osvetlitve. Največkrat se uporabi (uteženo) povprečje vseh preslikav [5].

Iskanje preslikav lahko poteka v 3-dimenzionalnem ali 2-dimenzionalnem barvnem prostoru. Izkaže se, da je iskanje v 3-dimenzionalnem barvnem prostoru bolj učinkovito in manj zahtevno [20]. Največkrat je iskanje množice preslikav implementirano z metodo konveksnega programiranja (angl. *displined convex programming*) [21].

Razširitev osnovne metode preslikave barvnega obsega predstavlja metoda [14], ki za izračun barvnih obsegov uporablja množicov odvodov (angl. *n-jet*) slik. Uspešnost metode v primerjavi z osnovno metodo je (podobno kot pri metodi sivega robu) odvisna od števila robov na sliki.

Uporaba te metode doprinese dve novi hevristici za izbiro optimalne preslikave:

- Izračunamo množico preslikav z osnovno metodo in metodo, ki uporablja množico odvodov slike. Pri izbiri optimalne preslikave upoštevamo presek dveh izračunanih množic, kar nam zoža izbor možnih preslikav in poveča zaupanje, da bomo izbrali optimalno preslikavo.
- Izračunamo množico preslikav z osnovno metodo in metodo, ki uporablja množico odvodov slike. Na vsaki množici izberemo optimalno preslikavo, končen rezultat pa predstavlja (uteženo) povprečje obeh preslikav.

Metode preslikave barvnega obsega dosegajo pri detekciji osvetlitve dobre rezultate, a so računsko in implementacijsko zelo zahtevne in kot take niso primerne za uporabo v realnem času.

3.3.5 Bayesova barvna konstantnost

Metode iz te družine uporabljajo bajesovski pristop pri izračunu osvetlitve slike. V nadaljevanju opisana metoda je podana v [15]. Osvetlitev posameznega barvnega kanala $l = (l_r, l_g, l_b)$ in odbojne lastnosti predmetov $x = (x_r, x_g, x_b)$ modeliramo kot naključni, neodvisni spremenljivki:

$$p(x, l) = p(x)p(l). \quad (3.6)$$

Predhodne verjetnosti osvetlitev $p(l)$ lahko definiramo na dva načina:

- privzamemo, da so vse osvetlitve enako verjetne,
- izračunamo relativne frekvence pojavitev osvetlitev v podatkovni bazi slik, katerih osvetlitve poznamo.

Težje je določiti model verjetnosti za modeliranje odbojnih lastnosti. Definirati moramo porazdelitev $p(\mathbf{X})$, pri čemer:

$$\mathbf{X} = (x(1), \dots, x(n)) \quad (3.7)$$

predstavlja n različnih odbojnih površin, ki so prisotne na sliki. Odbojne površine kvantiziramo s pomočjo histograma (angl. *reflectance histogram*) s k stolpci. Pri tem privzamemo, da so odbojne površine med sabo izmenljive (angl. *exchangable*). Izmenljivost je šibkejša omejitev kot neodvisnost in pravi, da so odbojne površine lahko odvisne samo od odbojnih površin znotraj istega stolpca histograma. Če histogram opišemo s k -terko $(n_1, \dots, n_k)$, pri čemer n_i predstavlja število površin na vhodni sliki, ki padejo v i -ti stolpec histograma, potem velja $p(x(1), \dots, x(n)) \propto f(n_1, \dots, n_k)$. Funkcijo f definiramo takole:

$$\begin{aligned} f(n_1, \dots, n_k) &= \prod_k m_k^{v_k} \\ v_k &= n \frac{\text{clip}(n_k)}{\sum_k \text{clip}(n_k)} \\ \text{clip}(n_k) &= \begin{cases} 0, & n_k = 0 \\ 1, & n_k > 0 \end{cases} \end{aligned} \quad (3.8)$$

Faktor v_k in funkcija $\text{clip}(n_k)$ sta uporabljena za normalizacijo pri slikah, kjer imamo manjše število odbojnih površin. Členi m_k predstavljajo verjetnost, da odbojna površina leži v histogramu znotraj stolpca k . Določimo jih s pomočjo baze slik z znano osvetlitvijo v dveh korakih:

1. Slike transformiramo z metodami za transformacijo slike (poglavje 3.4) tako, da je njihova osvetlitev standardna.
2. Izračunamo relativne frekvence pojavitev barvnih točk na sliki in jih kvantiziramo v histogram.

Definirajmo barvne vrednosti na vhodni sliki z množico $\mathbf{Y}$, v kateri so vse točke na sliki opisane z $y = (y_r, y_g, y_b)$. Množica $\mathbf{X}$, s točkami $x = (x_r, x_g, x_b)$, predstavlja barvne vrednosti slikovnih elementov pod standardno osvetlitvijo. Možne osvetlitve ustrezno diskretiziramo. Verjetnost slike, opisane z množico $\mathbf{Y}$, pod diskretizirano osvetlitvijo l opisuje enačba:

$$\begin{aligned} p(\mathbf{Y}|l) &= \int_{\mathbf{X}} \left(\prod_i p(y(i)|l, x(i)) \right) p(\mathbf{X}) d\mathbf{x} \\ &= |\mathbf{L}^{-1}|^n p(\mathbf{X} = \mathbf{L}^{-1}\mathbf{Y}), \end{aligned} \quad (3.9)$$

pri čemer i teče preko vseh slikovnih točk, $\mathbf{L}$ predstavlja diagonalno matriko osvetlitve l , količino $\mathbf{L}^{-1}Y$ pa si predstavljamo kot barvno popravljeno sliko. $|\mathbf{L}^{-1}|^n$ je normalizacijski člen. Za izračun posteriorne verjetnosti osvetlitve l pri dani sliki uporabimo Bayesov teorem in jo ocenimo s:

$$p(l|\mathbf{Y}) \propto p(\mathbf{Y}|l)p(l). \quad (3.10)$$

Rezultat metode je ocena osvetlitve e , ki jo določimo kot povprečno posteriorno vrednost vseh obravnavanih osvetlitev:

$$e = \sum_l l \cdot p(l|\mathbf{Y}). \quad (3.11)$$

Uspešnost bayesovskih metod za detekcijo osvetlitve je močno odvisna od naučenih apriornih verjetnosti [22]. Boljše kot bodo naučene ocene verjetnosti osvetlitev in odbojnih površin, boljši bodo rezultati detekcije. Performančno gledano so bayesovske metode zahtevnejše od statičnih metod, a manj zahtevne od metod preslikave barvnega obsega.

3.3.6 Barvna konstantnost z uporabo naravnih statičnih slik

Avtorji algoritma so uspeli pokazati, da je uspeh statičnih algoritmov za iskanje osvetlitve odvisen od lastnosti slike [16]. Primer: algoritem bele lise se bo na slikah z veliko različnimi teksturami in močnim kontrastom obnesel bolje kot algoritem sivega sveta. Algoritem barvne konstantnosti z uporabo naravnih statistik slik vhodno sliko klasificira v razred in določi optimalno kombinacijo statičnih algoritmov za iskanje osvetlitve. Za opis statičnih algoritmov so uporabili ogrodje, ki temelji na normi Minkowskega [12]:

$$\left(\int \left| \frac{\delta^n f_{c,\sigma}(x)}{\delta x^n} \right|^p dx \right)^{\frac{1}{p}} = k e_c^{n,p,\sigma}. \quad (3.12)$$

$F_{c,\sigma}(x)$ predstavlja odvod barvnega kanala c slikovnega elementa na koordinati x , ki ga dobimo kot konvolucijo slike z odvodom Gaussovega jedra s

Algoritem	Opis algoritma s parametri enačbe (3.12)
Siv svet	$e^{0,1,0}$
Bela lisa	$e^{0,\infty,0}$
Siv rob (1. odvod)	$e^{1,1,\sigma}$
Siv rob (2. odvod)	$e^{2,1,\sigma}$


Tabela 3.1: Opis statičnih algoritmov s parametri enačbe, ki temelji na normi Minkowskega.

standardnim odklonom σ . P je norma Minkowskega, n stopnja odvoda, k konstanta, ki poskrbi, da ima ocena osvetlitve $e_c^{n,p,\sigma}$ enotno dolžino. Tabela 3.1 prikazuje opis statičnih metod z ogrođjem predstavljenim z enačbo (3.12).

Lastnosti slike, ki določajo uspeh statičnih algoritmov za detekcijo osvetlitve, so odvisne od razporeditve robov na sliki [23]. Distribucijo robov lahko aproksimiramo z Weibull parametrizacijo [24]:

$$f(x) = \frac{\gamma}{\beta} \left(\frac{x}{\beta}\right)^{\gamma-1} e^{-\left(\frac{x}{\beta}\right)^\gamma}, \quad (3.13)$$

kjer x predstavlja vrednosti odvoda slike, parameter β določa širino distribucije, parameter γ pa obliko distribucije. Večji β pomeni večji kontrast slike, večji γ manjšo zrnatost (bolj fine teksture). Če primerjamo uspešnost statičnih algoritmih na slikah, katerih osvetlitve poznamo, z Weibull parametrizacijo slik, ugotovimo veliko stopnjo korelacije. Slika 3.5 prikazuje omejeno primerjavo. Liki na grafu prikazujejo parametrizacije slik v podatkovni bazi. Barva lika določa algoritem, ki se je na sliki najbolj obnesel. Opazimo, da se metode ničnega reda (siv svet, bela lisa) najbolj obnesejo na slikah s finimi teksturami in srednjo oziroma visoko stopnjo kontrasta. Metode prvega reda so najbolj uspešne na slikah z malo kontrasta in grobimi teksturami. Metode drugega reda so najbolj obnesejo na slikah, ki imajo ali visok kontrast ali veliko tekstur.



Slika 3.5: Weibull parametrizacija podatkovne baze slik in (njihova) korelacija s statičnimi metodami. Zaradi preglednosti je prikazana samo parametrizacija odvoda barvnega kanala v smeri x .

Predznanje metode pripravimo v treh korakih:

1. Izračunamo Weibull parametrizacijo vseh slik. Za vsako sliko dobimo 6 parametrizacij, saj je potrebno izračunati parametrizacijo posebej za vsak barvni kanal in za odvoda slik v dveh smereh. Pomembno je, da uporabljamo slike, katerih osvetlitev poznamo.
2. Z metodo razvrščanja z voditelji (angl. *k-means*) razdelimo parametrizacije slik v k različnih grozdov.
3. Za vsak grozd izračunamo, katera statična metoda se najbolj obnese na slikah znotraj grozda.

Ko imamo pripravljeno predznanje, osvetlitev nove vhodne slike prav tako izračunamo v treh korakih:


1. Izračunamo Weibull parametrizacijo vhodne slike.
2. Izračunamo razdalje parametrizacije vhodne slike od k grozdov. Na podlagi razdalj ocenimo verjetnosti, da vhodna slika pripada določenemu grozdu.
3. S statičnimi metodami izračunamo ocene osvetlitve. Končno oceno osvetlitve predstavlja uteženo povprečje osvetlitev. Uteži predstavljajo verjetnosti, izračunane v drugem koraku.

Algoritem dosega dobre rezultate, saj s pomočjo lastnosti slike določi optimalno kombinacijo preprostih algoritmov za izračun osvetlitve. Zahteva določitev predznanja, kar je lahko dolgotrajen proces – odvisno od velikosti učne množice. Izračun osvetlitve vhodne slike pa je manj zahteven kot pri metodah preslikave barvnega obsega.

3.3.7 Semantična barvna konstantnost

Za razliko od prej opisanih algoritmov, ki uporabljajo preproste statistike vhodnih slik, ta algoritem pri izračunu osvetlitve poleg preprostih statistik uporablja semantične kategorije na sliki [17]. Osnovna ideja temelji na rezultatih raziskave [25], ki je pokazala, da si človeški vizualni sistem pri zaznavanju barv pomaga s semantično informacijo o predmetih. Cilj algoritma je poiskati osvetlitev, ki bo po transformaciji vhodne slike prikazala čim bolj naravno sliko. Sliko, na kateri je gozd zelen ter nebo modro in ne obratno.

Shema na sliki 3.6 prikazuje proces izvedbe algoritma. Z vhodne slike zgeneriramo dve vrsti hipotez o osvetlitvi: hipoteze od spodaj navzgor (angl. *bottom-up*) in hipoteze od zgoraj navzdol (angl. *top-down*). Prve generiramo s pomočjo preprostih statistik vhodne slike in uporabo ogrodja, opisanega z enačbo (3.13). Za generiranje hipotez od zgoraj navzdol in izračun



Slika 3.6: Shema delovanja algoritma semantične barvne konstantnosti.

semantičnih verjetnosti hipotez, moramo najprej ustvariti model za opis semantičnih kategorij na sliki. Uporabimo verjetnostno sledljivo semantično analizo (angl. *Probabilistic latent semantic analysis*). Model je v osnovi namenjen analizi dokumentov, a se je izkazal kot učinkovit tudi pri klasifikaciji slikovnih točk v semantične kategorije [26]. Semantične kategorije na sliki opišemo z distribucijo vizualnih besed. Vhodno sliko razdelimo na področja velikosti 20×20 slikovnih točk, ki predstavljajo posamezne vizualne besede.

Te opišemo s tremi parametri:

- Teksturo: Za opis teksture uporabimo SIFT deskriptorje [27]. Ker je vseh možnih dekskriptorjev preveč, jih diskretiziramo z metodo razvrščanja z voditelji.
- Barvo: Opišemo s srednjo vrednostjo slikovnih točk znotraj področja.
- Lokacijo: Sliko enakomerno razdelimo na 64 področij. Lokacija predstavlja področje, na katerem se nahaja vizualna beseda.

Z opisanim modelom izračunamo verjetnosti, da je bila vhodna slika zajeta pod osvetlitvijo, ki jo predlaga hipoteza. Končno osvetlitev predstavlja hipoteza z maksimalno semantično verjetnostjo.

V razširitvi algoritma sivega sveta je bilo pokazano, da rezultate detekcije osvetlitve izboljšamo, če privzamemo, da povprečna barva na sliki ni akromatična, ampak je enaka povprečni barvi slik v bazi slik [28]. Avtorji algoritma semantične barvne konstantnosti postavijo podobno hipotezo: povprečna barva semantične kategorije na sliki je enaka povprečni barvi semantične kategorije v bazi slik [17]. Pristop od zgoraj navzdol poteka v treh korakih:

1. S pomočjo teksture in lokacije vizualnih besed algoritem določi semantične kategorije na sliki.
2. Za vsako semantično kategorijo na sliki izračunamo povprečno barvo.
3. Za vsako semantično kategorijo predlagamo hipotezo osvetlitve tako, da bo po transformaciji povprečna barva semantične kategorije na vhodni sliki enaka povprečni barvi semantične kategorije v bazi slik.

Končno število hipotez je enako številu semantičnih kategorij na sliki.

Uporaba semantične informacije bistveno izboljša uspeh statičnih metod za detekcijo osvetlitve. Vendar je tako kot pri drugih algoritmih, ki temeljijo na metodah strojnega učenja, pomembno, da imamo reprezentativno učno

množico. S pomočjo te izračunamo apriorne verjetnosti semantičnih kategorij. Algoritem je časovno zahteven in ni primeren za uporabo v realnem času.

3.4 Transformacija slike

Drugi korak v procesu pridobivanja barvno konstantne slike predstavlja transformacija slike. Zatim, ko smo v prvem koraku izračunali osvetlitev slike, sliko transformiramo tako, da izgleda, kot da bi bila zajeta pod drugo, ciljno osvetlitvijo. V diplomskem delu smo za ciljno osvetlitev uporabili osvetlitev D65 [29], ki predstavlja standardno dnevno osvetlitev. Največkrat uporabljen model za transformacijo slike je Von Kriesov model [19], ki smo ga že omenili v poglavju 3.3.4. Da bi spremenili osvetlitev slike, slikovne elemente pomnožimo s skalirnimi faktorji barvnih kanalov, ki jih izračunamo s pomočjo detektirane in ciljne osvetlitve. S stališča barvnega prostora je transformacija globalna, saj vse barve znotraj barvnega obsega transformira z enako transformacijsko matriko. V primeru napačno detektirane osvetlitve se zaradi enotne transformacijske matrike velikokrat zgodi, da ima transformirana slika barvni pridih – vse barve na sliki se nagibajo k istemu odtenku barve. Slika 3.7 prikazuje razliko med barvno pravilno sliko in sliko z barvnim pridihom. S predlagano metodo, opisano v poglavju 3.5, ki uporablja več transformacijskih matrik, želimo ta problem omejiti.




Slika 3.7: Barvno pravilna slika (levo) in slika z barvnim pridihom (desno).

Pri izbiri barvnega prostora, v katerem izvedemo množenje s skalirnimi faktorji barvnih kanalov, imamo več možnosti. Logična izbira je barvni prostor, v katerem je opisana vhodna slika. Največkrat je to eden izmed barvnih prostorov, ki temeljijo na RGB barvnem modelu. Izkaže se, da ti barvni prostori niso optimalni. Boljša izbira so barvni prostori dobljeni z linearno transformacijo XYZ prostora [30]. Postopek za iskanje linearnih transformacij je sledeč [31]:

1. Uporabimo pare XYZ barvnih vrednosti (C_1, C_2) ; prva vrednost predstavlja barvo pod začetno osvetlitvijo, druga barvo pod ciljno osvetlitvijo. Tako začetna kot ciljna osvetlitev morata biti znani.
2. Pare barvnih vrednosti (C_1, C_2) z linearno transformacijo M preslikamo v nov barvni prostor.
3. Vrednosti C_1 pomnožimo s skalirnimi faktorji in jih primerjamo z vrednostmi C_2 . Dobljene napake označimo z e .
4. Izračunamo skupno napako transformacij $E = \sum e$. Izberemo novo transformacijo M in ponovimo korak 2. Postopek nadaljujemo, dokler skupna napaka E ni dovolj majhna.

Dobljen barvni prostor je optimalen za izbrano množico barvnih vrednosti in izbrano mero napake. Postopek se v literaturi največkrat pojavlja pod imenom izostritev senzorjev (angl. *Sensor sharpening*)[31]. Bazne funkcije barvnih prostorov (angl. *color matching functions*), s pomočjo katerih iz spektra svetlobe izračunamo barvne vrednosti, imajo po opisanem postopku bolj ostre vrhove. Slika 3.8 prikazuje bazne funkcije XYZ barvnega prostora pred in po opisanem postopku. Izostritev je najbolj izrazita pri bazni funkciji zelene barve.

V naslednjih dveh podpoglavjih bomo opisali transformacijo v barvnem prostoru, ki temelji na RGB barvnem modelu in transformacije v barvnih prostorih, ki temeljijo na linearni transformaciji XYZ barvnega prostora.



Slika 3.8: Bazne funkcije prvotnega in transformiranega XYZ barvnega prostora. S črtkanimi črtami so označene bazne funkcije XYZ barvnega prostora, s polnimi črtami pa bazne funkcije linearne transformacije XYZ barvnega prostora, pridobljenega s postopkom ostrenja.

3.4.1 Transformacija slike v barvnem prostoru, ki temelji na RGB barvnem modelu

Transformacijo izvedemo tako, da vrednosti slikovnih elementov (R, G, B) pomnožimo s skalirnimi faktorji [30]:

$$\begin{bmatrix} R' \\ G' \\ B' \end{bmatrix} = \begin{bmatrix} R_{D65}/R_e & 0 & 0 \\ 0 & G_{D65}/G_e & 0 \\ 0 & 0 & B_{D65}/B_e \end{bmatrix} \cdot \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (3.14)$$

Trojček (R', G', B') predstavlja transformirane vrednosti slikovnih elementov. Vrednosti $(R_{D65}, G_{D65}, B_{D65})$ predstavljajo standardno D65 osvetlitev, vrednosti (R_e, G_e, B_e) pa detektirano osvetlitev vhodne slike.

Transformacija je preprosta in učinkovita, saj ne zahteva vmesne pretvorbe barvnega prostora.

3.4.2 Transformacija slike v barvnih prostorih, dobljenih z linearno transformacijo XYZ barvnega prostora

Prvi korak predstavlja pretvorba RGB vrednosti v XYZ vrednosti. Transformacijska matrika je odvisna od uporabljenega barvnega prostora, ki temelji na RGB barvnem modelu. V primeru sRGB barvnega prostora je transformacijska matrika sledeča [32]:

$$\begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = \begin{bmatrix} 0.4124 & 0.3576 & 0.1805 \\ 0.2126 & 0.7152 & 0.0722 \\ 0.0193 & 0.1192 & 0.9505 \end{bmatrix} \cdot \begin{bmatrix} R \\ G \\ B \end{bmatrix}. \quad (3.15)$$

Tukaj predpostavimo, da so (R, G, B) vrednosti pridobljene z linearne slike, brez gama korekcije. Splošno ogrodje za nadaljnjo transformacijo XYZ vrednosti podaja enačba (3.16) [30].

$$\begin{bmatrix} X' \\ Y' \\ Z' \end{bmatrix} = [\mathbf{M}]^{-1} \cdot \begin{bmatrix} R_{D65}'/R_e' & 0 & 0 \\ 0 & G_{D65}'/G_e' & 0 \\ 0 & 0 & B_{D65}'/B_e' \end{bmatrix} \cdot [\mathbf{M}] \cdot \begin{bmatrix} X \\ Y \\ Z \end{bmatrix}. \quad (3.16)$$

Matrika $\mathbf{M}$ predstavlja linearno transformacijo XYZ barvnega prostora, $\mathbf{M}^{-1}$ pa njen inverz. Vrednosti $(R_{D65}', G_{D65}', B_{D65}')$ in (R_e', G_e', B_e') dobimo tako, da izračunane (R_e, G_e, B_e) in referenčne $(R_{D65}, G_{D65}, B_{D65})$ vrednosti osvetlitev najprej pretvorimo z enačbo (3.15), nato pa pomnožimo z matriko $\mathbf{M}$. Dobljene (X', Y', Z') vrednosti pretvorimo v sRGB barvni prostor z inverzom

matrike uporabljene v enačbi (3.15). V nadaljevanju so opisane štiri linearne transformacije XYZ barvnega prostora $\mathbf{M}$.

XYZ: Matrika $\mathbf{M}_{\text{XYZ}}$ je identiteta (enačba (3.17)). Po transformaciji skaliramo vrednosti v prvotnem XYZ barvnem prostoru [33]. Metoda daje podobne rezultate kot skaliranje RGB vrednosti.

$$\mathbf{M}_{\text{XYZ}} = \begin{bmatrix} 1 & 0 & 1 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (3.17)$$

Bradford: Je pogosto uporabljena transformacija, ki je bila izpeljana s primerjanjem 58-tih vzorcev barvne volne pod osvetlitvama D65 in A [34]. Prvotna transformacija je bila nelinearna na področju modre barve, kasneje so nelinearnost odpravili.

$$\mathbf{M}_{\text{Bradford}} = \begin{bmatrix} 0.8951 & 0.2664 & -0.1614 \\ -0.7502 & 1.7135 & 0.0367 \\ 0.0389 & -0.0685 & 1.0296 \end{bmatrix} \quad (3.18)$$

Sharp: Je novejša transformacija, ki izhaja iz Bradford transformacije [35]. Vrhovi baznih funkcij barvnega prostora so po tej transformaciji bolj ostri kot po Bradford transformaciji. Posledično von Kriesov model pravilneje modelira spremembo osvetlitve.

$$\mathbf{M}_{\text{Sharp}} = \begin{bmatrix} 1.2694 & -0.0988 & -0.1706 \\ -0.8364 & 1.8006 & 0.0357 \\ 0.0297 & -0.0315 & 1.0018 \end{bmatrix} \quad (3.19)$$

CMCCAT2000: Je naslednica CMCCAT97 transformacije, ki prav tako izhaja iz Bradford transformacije [36]. CMCCAT2000 transformacija vpelje parameter D , ki omogoča modeliranje delne prilagoditve (angl. *partial adaptation*):

- $D = 1$: popolna prilagoditev – transformirana slika izgleda kot da bi bila zajeta pod ciljno osvetlitvijo.

- $D = 0$: brez prilagoditve – transformirana slika je enaka vhodni sliki.
- $0 < D < 1$: delna prilagoditev – transformirana slika izgleda kot da bi bila zajeta pod kombinacijo vhodne in ciljne osvetlitve.

Delne prilagoditve zaradi primerjave z drugimi metodami v diplomskem delu ne bomo obravnavali. Enačba (3.20) predpostavlja popolno prilagoditev.

$$\mathbf{M}_{\text{CMCCAT2000}} = \begin{bmatrix} 0.7982 & 0.3389 & -0.1371 \\ -0.5918 & 1.5512 & 0.0406 \\ 0.0008 & 0.239 & 0.9753 \end{bmatrix} \quad (3.20)$$

3.5 Transformacija slik z uporabo barvnih podprostorov

Metoda, ki jo predlagamo v diplomskem delu, razdeli barvni prostor na več podprostorov in za vsak podprostor izračuna transformacijsko matriko, s katero preslikamo barve znotraj posameznega podprostora. Za razliko od globalnih von Kriesovih transformacij, opisanih v poglavju 3.4, so te transformacije lokalne, saj delujejo le znotraj podprostorov. Metoda predstavlja nov pristop k transformaciji slik za doseganje barvne konstantnosti, ki ga v literaturi ni mogoče zaslediti. Pristop nima podlage v raziskavah delovanja človeškega vizualnega sistema, ampak zgolj razširi uveljavljeno teorijo o skaliranju barvnih kanalov na barvne podprostore.

Pri izbiri barvnega prostora, ki ga razdelimo na podprostore, imamo več možnosti. Prva izbira je sRGB barvni prostor, v katerem so opisane vhodne slike, saj ne zahteva dodatne transformacije. Izkaže se, da je bolj primeren rg kromatičen prostor. Razloga sta dva:


- Algoritmčno je postopek za razdeljevanje 3-dimenzionalnega sRGB prostora bolj zahteven kot postopek za razdeljevanje 2-dimenzionalnega rg prostora.

- rg prostor je kromatičen, kar pomeni, da ignorira informacijo o svetlosti barve. Razdalja med vizualno podobnima barvama (ne glede na svetlost) je v rg prostoru manjša kot v sRGB prostoru. Posledično se bosta vizualno podobni barvi preslikali z enako transformacijo, kar je cilj naše metode.

Barvni prostor razdelimo na podprostore z Delaunayjevo triangulacijo (angl. *Delaunay triangulation*) [37]. Triangulacija poveže točke v prostoru v neprekrivajoče se simplekse. Simpleks predstavlja generalizacijo pojma trikotnika v večdimenzionalne prostore. V 2-dimenzionalnem prostoru gre za povezovanje točk v trikotnike. Delaunayjeva triangulacija ima dve dodatni lastnosti:

- nobena izmed točk, ki jih trianguliramo, ni znotraj omejujočega kroga (angl. *circumcircle*) drugega trikotnika,
- maksimizira minimalne kote v trikotnikih.

Obe lastnosti pripomoreta k temu, da rezultirajoči trikotniki niso preozki. Slika 3.9 prikazuje Delaunayjevo triangulacijo točk v 2-dimenzionalnem prostoru.



Slika 3.9: Delaunayjeva triangulacija točk v 2-dimenzionalnem prostoru s pripadajočimi omejujočimi krogi.

Delaunayeva triangulacija ni unikatna – obstaja več različnih triangulacij nad isto množico točk. Prav tako je število trikotnikov, ki jih dobimo kot rezultat triangulacije, odvisno od razporeditve točk na ravnini. Časovna zahtevnost algoritma za triangulacijo n -tih 2-dimenzionalnih točk je $O(n \log n)$.


Barvni prostor s pomočjo Delaunayjeve triangulacije razdelimo na več barvnih podprostorov. Za triangulacijo potrebujemo referenčne točke znotraj barvnega prostora. Uporabimo sredinske barvne vrednosti kvadratov Macbethove barvne razpredelnice (angl. *Macbeth color checker*) [38], ki je postavljen na sceno vhodne slike. Slika 3.10 prikazuje Macbethovo barvno razpredelnico, ki se v osnovi uporablja za kalibracijo fotoaparata in kamer. Spektralne lastnosti 24-tih kvadratov so izbrane tako, da predstavljajo naravne objekte, največkrat prisotne na fotografijah: človeško kožo, rože, nebo in tako dalje. Naša metoda tako delno upošteva semantični vidik, saj objekte podobnih barv, ki predstavljajo enako semantično kategorijo, preslika z enako transformacijo. Da bi izračunali RGB in kasneje rg vrednosti kvadratov Macbethove barvne razpredelnice, potrebujemo področje A vsakega kvadrata na vhodni sliki. (R, G, B) vrednosti kvadrata izračunamo kot

$$\begin{aligned} R &= \text{median}(p_{(i,R)}), \\ G &= \text{median}(p_{(i,G)}), \\ B &= \text{median}(p_{(i,B)}), \end{aligned} \tag{3.21}$$



Slika 3.10: Macbethova barvna razpredelnica.

pri čemer $p(i, C)$ predstavlja vrednost slikovnih elementov barvnega kanala C znotraj področja A . Namesto srednje vrednosti bi lahko izbrali tudi povprečno vrednost, vendar je srednja vrednost manj občutljiva na nenatančno določene površine kvadratov, ki lahko vključujejo tudi temna področja okrog kvadratov. (R, G, B) vrednosti kvadratov z enačbo (2.2) pretvorimo v (r, g) vrednosti in jih uporabimo kot referenčne točke za triangulacijo. Slika 3.11 prikazuje rezultat triangulacije rg prostora pri dveh različnih osvetlitvah. Barvne vrednosti kvadratov leve Macbethove barvne razpredelnice so bile izračunane s slike, zajete pod neznano osvetlitvijo, medtem ko so na desni sliki predstavljene barvne vrednosti kvadratov Macbethove barvne razpredel-



Slika 3.11: Izračunane barve kvadratov dveh Macbethovih barvnih razpredelnic, zajetih pod neznano in standardno D65 osvetlitvijo, s pripadajočima razdelitvama barvnega prostora. Triangulaciji sta prikazani v kromatičnem rg prostoru. Barve točk na grafih so enake kot barve kvadratov pod grafom.

nice pri standardni D65 osvetlitvi [39]. Opazimo, da barve na levi Macbethovi barvni razpredelnici odstopajo od tistih na desni, kar se odrazi v drugačni razdelitvi barvnega prostora.

Potrebno je definirati še transformacijske matrike barvnih podprostorov. Vsak podprostor ima svojo transformacijsko matriko, ki služi za preslikavo vrednosti slikovnih elementov, katerih rg koordinate se nahajajo znotraj dotičnega podprostora. Povezavo med rg vrednostmi pod različnimi osvetlitvami lahko opišemo z različnimi modeli. Izbrali smo linearni model, ki izvirno rg vrednost $\mathbf{X}(x, y)$ transformira v ciljno rg vrednost $\mathbf{U}(u, v)$ z enačbo (3.22).

$$\begin{aligned} u &= a_0 + a_1 \cdot x + a_2 \cdot y \\ v &= b_0 + b_1 \cdot x + b_2 \cdot y \end{aligned} \quad (3.22)$$

V matrični obliki lahko to isto enačbo zapišemo kot:

$$\mathbf{U} = \mathbf{A} \cdot \mathbf{Y}, \quad (3.23)$$

kjer velja:

$$\begin{aligned} \mathbf{U} &= \begin{bmatrix} u \\ v \end{bmatrix}, \\ \mathbf{A} &= \begin{bmatrix} a_0 & a_1 & a_2 \\ b_0 & b_1 & b_2 \end{bmatrix}, \\ \mathbf{Y} &= \begin{bmatrix} 1 \\ x \\ y \end{bmatrix}. \end{aligned} \quad (3.24)$$

Za izračun neznanih faktorjev v transformacijski matriki $\mathbf{A}$ potrebujemo tri pare korenspondenčnih točk pod izvirno in ciljno osvetlitvijo. Pod izvirno osvetlitvijo izberemo oglišča trikotnika, ki omejuje podprostor, za katerega računamo transformacijsko matriko. Ta oglišča predstavljajo izračunane barvne vrednosti treh kvadratov znotraj Macbethove barvne razpredelnice.

Njihove korespondenčne točke poiščemo kot barvne vrednosti teh istih kvadratov zajetih pod D65 osvetlivijo. Barvne vrednosti kvadratov Macbethove barvne razpredelnice pod D65 osvetlitvijo najdemo v [39]. Točke pod izvorno osvetlitvijo opišemo z matriko $\mathbf{S}$:

$$\mathbf{S} = \begin{bmatrix} 1 & 1 & 1 \\ x_1 & x_2 & x_3 \\ y_1 & y_2 & y_3 \end{bmatrix}, \quad (3.25)$$

korespondenčne točke pod D65 osvetlitvijo pa z matriko $\mathbf{T}$:

$$\mathbf{T} = \begin{bmatrix} u_1 & u_2 & u_3 \\ v_1 & v_2 & v_3 \end{bmatrix}. \quad (3.26)$$

Povezavo med matrikama $\mathbf{T}$ in $\mathbf{S}$ podaja enačba (3.27).

$$\mathbf{T} = \mathbf{A} \cdot \mathbf{S} \quad (3.27)$$

Transformacijsko matriko $\mathbf{A}$ izračunamo kot

$$\mathbf{A} = \mathbf{T} \cdot \mathbf{S}^{-1}. \quad (3.28)$$

Za vsak slikovni element na sliki pogledamo, v kateri barvni podprostor spada in ga transformiramo z ustrezno matriko. Kot vidimo na sliki 3.10, barvni podprostori ne pokrivajo celotnega barvnega prostora. Lahko se zgodi, da slikovni element na vhodni sliki ne pripada nobenemu barvnemu podprostoru. Težavo rešimo tako, da pri triangulaciji 24-im barvnim vrednostim kvadratov Macbethove barvne razpredelnice dodamo mejne točke rg kromatičnega prostora. Koordinate teh točk so $(0, 0)$, $(0, 1)$ in $(1, 0)$ – točka $(1, 1)$ ni mejna točka rg kromatičnega prostora, saj vsota obeh koordinat prostora ne sme biti večja od ena.

3.5.1 Transformacija slik, ki vsebujejo Macbethovo barvno razpredelnico

Celoten postopek za transformacijo vhodne slike, ki vsebuje Macbethovo barvno razpredelnico, je naslednji:

1. Z enačbo (3.21) izračunamo RGB vrednosti kvadratov Macbethove barvne razpredelnice na vhodni sliki.
2. RGB točke, izračunane v prvem koraku, z enačbo (2.2) pretvorimo v rg točke.
3. V množico točk dodamo mejne točke rg kromatičnega prostora.
4. Nad množico točk izvedemo Delauneyjevo triangulacijo.
5. Za vsak dobljen podprostor s pomočjo enačbe (3.28) izračunamo transformacijsko matriko $\mathbf{A}$.
6. Iteriramo čez slikovne elemente vhodne slike:
 - (a) Izračunamo rg vrednost slikovnega elementa.
 - (b) Preverimo, v kateri podprostor spada izračunana rg vrednost.
 - (c) Z uporabo pripadajoče matrike A in enačbe (3.23) transformiramo rg vrednost slikovnega elementa. Novo vrednost označimo z (r', g') .
 - (d) Ker slikovnim elementom ne želimo spreminjati svetlosti, se mora vsota vrednosti barvnih kanalov ohraniti. Novo RGB vrednost slikovnega elementa (R', G', B') izračunamo z enačbo:


$$\begin{aligned} R' &= r' \cdot (R + G + B) \\ G' &= g' \cdot (R + G + B) \\ B' &= (1 - r' - g') \cdot (R + G + B), \end{aligned} \tag{3.29}$$

kjer so (R, G, B) stare vrednosti slikovnega elementa.

3.5.2 Transformacija slik, ki ne vsebujejo Macbethove barvne razporednice

Ker želimo, da je naša metoda uporabna v praksi, na realnih slikah, je nerealno pričakovati, da vse vhodne slike vsebujejo Macbethovo barvno razporednico. Problema se lotimo na sledeč način. Najprej zgradimo podatkovno bazo vrednosti kvadratov Macbethove barvne razporednice pod različnimi osvetlitvami. Množica Color-checker (množica barvnih razporednic) vsebuje 568 slik, zajetih pod različnimi osvetlitvami [22]. Slika 3.12 prikazuje distribucijo osvetlitve slik iz podatkovne baze Color-checker.

Vse slike vsebujejo Macbethovo barvno razporednico, s pomočjo katere lahko izračunamo osvetlitve slik (glej poglavje 4). Koordinate kvadratov Macbethove barvne razporednice na slikah so ročno določene. Za vsako sliko iz množice v podatkovno bazo shranimo izračunano osvetlitev in vrednosti kvadratov Macbethove barvne razporednice. Podatkovna baza predstavlja predznanje opisane metode.



Slika 3.12: Distribucija osvetlitve slik iz podatkovne baze Color-checker.

Za transformacijo vhodne slike, s pomočjo algoritmov, predstavljenih v poglavju 3.3, izračunamo osvetlitev vhodne slike $\mathbf{e}(e_R, e_G, e_B)$. V podatkovni bazi poiščemo osvetlitev $\mathbf{i}(i_R, i_G, i_B)$, ki je v množici osvetlitev $\mathbf{I}$ najbolj podobna izračunani osvetlitvi $\mathbf{e}$. Za mero podobnosti izberemo kotno napako (angl. *angular error*), ki je najbolj pogosto uporabljena metrika v domeni barvne konstantnosti [5]. Najbolj podobno osvetlitev poiščemo z enačbo:

$$\arg \min_{\mathbf{i} \in \mathbf{I}} \left(\cos^{-1} \left(\frac{\mathbf{e} \cdot \mathbf{i}}{\|\mathbf{e}\| \cdot \|\mathbf{i}\|} \right) \right), \quad (3.30)$$

kjer $\mathbf{e} \cdot \mathbf{i}$ predstavlja skalarni produkt dveh vektorjev in $\|\cdot\|$ evklidsko normo vektorja. Barvne vrednosti kvadratov Macbethove barvne razpredelnice, ki pripadajo izračunani osvetlitvi, uporabimo v nadaljnjem procesu transformiranja vhodne slike.

Celoten postopek za transformacijo vhodne slike, ki ne vsebuje Macbethove barvne razpredelnice, je naslednji:

1. S pomočjo algoritmov, predstavljenih v poglavju 3.3, izračunamo osvetlitev vhodne slike.
2. Z enačbo (3.30) v podatkovni bazi vrednosti kvadratov Macbethove barvne razpredelnice poiščemo osvetlitev, ki je najbolj podobna izračunani osvetlitvi. Pripadajoče RGB vrednosti kvadratov uporabimo v nadaljnjih korakih algoritma.
3. Nadaljujemo z drugim korakom algoritma, opisanega v poglavju 3.5.1.

Poglavje 4

Primerjava metod

V naslednjih podpoglavjih so podane primerjave metod za doseganje barvne konstantnosti:

- Poglavje 4.1 primerja metode za detekcijo osvetlitve.
- Poglavje 4.2 primerja metode za transformacijo slik, katerih osvetlitev je znana.
- Poglavje 4.3 primerja metode za transformacijo slik, katerih osvetlitev določimo z metodo za detekcijo osvetlitve.

Primerjave so bile izvedene na podatkovni bazi slik Color-checker [22]. Ta vsebuje 568 slik, zajetih pod različnimi svetlobnimi pogoji v notranjem in zunanjem okolju. Vse slike vsebujejo Macbethovo barvno razpredelnico, kar je pogoj za korektno testiranje metode transformacije slik z uporabo barvnih podprostorov. Koordinate kvadratov Macbethove barvne razpredelnice smo prenesli s spletne strani podatkovne baze slik [40]. Zaradi hitrosti testiranja smo uporabili pomanjšane različice slik (dostopne na spletni strani podatkovne baze slik). Slike so podane v sRGB barvnem prostoru, ki ni linearen. Metode za detekcijo osvetlitve in transformacijo slik zahtevajo linearne slike.

Zato smo pred testiranjem na vseh slikah izvedli inverzno gama transformacijo [32]:

$$C_{lin} = \begin{cases} \frac{C_{sRGB}}{12,92}, & C_{sRGB} \leq 0,04045 \\ \left(\frac{C_{sRGB} + 0,055}{1,055} \right)^{2,4}, & C_{sRGB} > 0,04045 \end{cases}. \quad (4.1)$$

C_{lin} je linearizirana sRGB vrednost barvnega kanala $C = \{R, G, B\}$.

Referenčne osvetlitve slik (angl. *ground-truth*) izračunamo s pomočjo kvadratov v zadnji vrsti Macbethove barvne razporednice. Ti kvadrati so akromatični – enakomerno odbijajo svetlobo vseh valovnih dolžin. Vsakršno odstopanje je posledica nestandardne osvetlitve slike. Osvetlitev $\mathbf{e}(e_R, e_G, e_B)$ določimo kot povprečno vrednost normiranih srednjih vrednosti kvadratov Macbethove barvne razporednice z indeksi $i = (19, 20, 21, 22, 23, 24)$

$$e_C = \frac{1}{6} \sum_i \frac{P_{(i,C)}}{\|\mathbf{P}_i\|}, \quad (4.2)$$

pri čemer je $P_{(i,C)}$ vrednost barvnega kanala C srednje vrednosti $\mathbf{P}_i$, ki jo izračunamo z enačbo (3.30), $\|\mathbf{P}_i\|$ pa je evklidska norma vektorja $\mathbf{P}_i$.

Časovne zahtevnosti in izvajalnih časov metod (vključno s predlagano metodo transformacije slik) v diplomskem delu nismo primerjali, saj optimizacija metode ni korak v procesu začetnega raziskovanja metode.

4.1 Primerjava metod za detekcijo osvetlitve

Metode za detekcijo osvetlitve primerjamo tako, da detektirano osvetlitev z mero napake primerjamo z referenčno osvetlitvijo. Primerjali smo učinkovitost metod, opisanih v poglavju 3.3:

- **siv svet** (osnovni algoritem),
- **bela lisa** (osnovni algoritem),
- **siv rob** (kot vhod v algoritem smo uporabili prvi odvod slike pri $\sigma = 1$, za izračun osvetlitve smo uporabili 4. normo Minkowskega),

- **preslikava barvnih obsegov** (osnovni algoritem),
- **Bayesova barvna konstantnost** (osnovni algoritem),
- **uporaba naravnih statistik slike** (za osnovne algoritme smo uporabili naslednje metode: siv svet, belo liso in siv rob),
- **semantična barvna konstantnost** (za osnovne algoritme smo uporabili naslednje metode: siv svet, belo liso in siv rob).

Vse metode, ki zahtevajo določitev in uporabo predznanja (zadnje štiri metode), smo testirali z metodo 3-kratnega prečnega preverjanja, kot je predlagano v [5]. Množico slik smo razdelili na tretjine in posamezno tretjino testirali tako, da smo uporabili predznanje iz preostalih dveh tretjin. Pred testiranjem smo zaradi zagotavljanja nepristranskosti maskirali dele slik z Macbethovo barvno razpredelnico.

Za osnovno metriko smo uporabili povprečno kotno napako pri detekciji osvetlitve, ki je najbolj pogosto uporabljena metrika pri testiranju algoritmov za detekcijo osvetlitve [5]. Tabela 4.1 prikazuje rezultate testiranja. Najboljše rezultate da metoda Bayesove barvne konstantnosti, sledita semantična barvna konstantnost in preslikava barvnih obsegov, zatem metoda sivega robu in bele lise ter na koncu siv svet in metoda uporabe naravnih

Algoritem	Kotna napaka	Doseženo mesto
Siv svet	7,3°	6.
Bela lisa	5,7°	5.
Siv rob	5,4°	4.
Gammut mapping	4,8°	2.
Bayesova barvna konstantnost	4,7°	1.
Uporaba naravnih statistik slike	7,6°	7.
Semantična barvna konstantnost	4,8°	2.

Tabela 4.1: Povprečne kotne napake algoritmov za detekcijo osvetlitve.


statistik slike. Presenetljivo se metoda Uporabe naravnih statistik slike obnese najslabše, slabše od vseh osnovnih algoritmov, ki jih metoda uporablja. Tudi avtorji algoritma Bayesova barvna konstantnost so pri testiranju ugotovili, da metoda Uporabe naravnih statistik slik ne daje dobrih rezultatov [22]. Očitno je, da Weibull parametrizacija ni primerna za učinkovito izbiro najprimernejše metode na uporabljeni množici slik Color-checker.

Metoda bele lise se obnese bolje od metode sivega sveta. Iz tega sklepamo, da slike v podatkovni bazi v povprečju niso akromatične in da so v povprečju temnejše – na svetlih slikah metoda bele lise ne dosega dobrih rezultatov.

Slika 4.1 prikazuje škatlaste grafe (angl. *box plot*) kotnih napak pri detekciji osvetlitve, ki bolj natančno opišejo distribucijo kotnih napak posamezne metode za detekcijo osvetlitve [5]. Iz njih razberemo podatke o:

- najmanjši vrednosti napake MIN ,
- spodnjem kvartilu Q_1 – 25% vseh napak je manjših od vrednosti Q_1 ,
- mediani Q_2 – 50% vseh napak je manjših od vrednosti Q_2 ,
- zgornjem kvartilu Q_3 – 75% vseh napak je manjših od vrednosti Q_3 ,
- omejeni maksimalni vrednosti napake $LMAX$ – ta ni večja od $Q_3 + 1.5(Q_3 - Q_1)$.

Napake, višje od omejene maksimalne vrednosti, so prikazane kot mimoležeče točke. Opazimo, da je minimalna napaka pri vseh metodah enaka 0, maksimalno napako pa najdemo pri metodi sivega sveta. Če primerjamo metodo sivega sveta z metodo uporabe naravnih statistik slike, opazimo, da imajo vse statistike na škatlastem grafikonu pri slednji kljub večji povprečni napaki boljše vrednosti. Napake metode Uporabe naravnih statistik slike so bolj stabilne in ne dosegajo velikih maksimalnih vrednosti. Primerjava preostalih metod pokaže, da imajo napake metode Bayesove barvne konstantnosti najmanjšo srednjo vrednost in najnižji spodnji kvartil (večina napak metode je majhnih), kar poleg najmanjše povprečne napake le še potrdi izbiro metode.



Slika 4.1: Škatlasti grafi kotnih napak pri detekciji osvetlitve. Škatlasti graf metode sivega sveta ima označene pomembne lastnosti škatlastih grafov.

Metoda semantične barvne konstantnosti ima najmanjši zgornji kvartil in normirano maksimalno vrednost – metoda je stabilna in napaka metode je redko velika. Kljub enaki povprečni napaki metod preslikave barvnih obsegov in semantične barvne konstantnosti je zaradi opisanega bolje izbrati slednjo.

Statistično razliko med metodami smo preverili še z Mann-Whitney U testom [41]. Neparametrični test, ki ne predvideva normalne ali druge porazdelitve vrednosti, ugotavlja, ali se srednji vrednosti dveh vzorcev statistično pomembno razlikujeta. Dve vrednosti se statistično pomembno razlikujeta, če lahko z dano stopnjo zaupanja trdimo, da rezultat ni posledica naključnega procesa. Za vsak par metod za detekcijo osvetlitve smo preverili, ali se srednji vrednosti napak obeh metod pomembno razlikujeta. Rezultati so predstavljeni v tabeli 4.2. Srednji napaki metod sivega sveta in uporabe naravnih

	Siv svet	Bela lisa	Siv rob	Preslikava barvnih obsegov	Bayesova barvna konstantnost	Uporaba naravnih statistik slike	Semantična barvna konstantnost
Siv svet	X	-1	-1	-1	-1	0	-1
Bela lisa	1	X	0	-1	-1	1	-1
Siv rob	1	0	X	0	0	1	0
Preslikava barvnih obsegov	1	1	0	X	0	1	0
Bayesova barvna konstantnost	1	1	0	0	X	1	0
Uporaba naravnih statistik slike	0	-1	-1	-1	-1	X	-1
Semantična barvna konstantnost	1	1	0	0	0	1	X

Tabela 4.2: Rezultati Mann-Whitney U testa pri primerjavi metod za detekcijo osvetlitve. Pozitivna vrednost (1) na lokaciji (i, j) pomeni, da je srednja vrednost kotne napake metode i pomembno nižja od srednje vrednosti napake metode j pri 95 % stopnji zaupanja. Negativna vrednost (-1) označuje nasprotno; ničla (0) pomeni, da med obema metodama ni pomembne razlike.

statistik slike sta statistično pomembno večji od srednjih napak preostalih metod, zato izbira teh dveh metod za detekcijo osvetlitve ni priporočljiva. Srednje napake preslikave barvnih obsegov, Bayesove barvne konstantnosti in semantične barvne konstantnosti se statično pomembno ne razlikujejo. Zaključimo, da so tri omenjene metode, najbolj primerne za detektiranje osvetlitve na sliki.

4.2 Primerjava metod za transformacijo slik z znano osvetlitvijo

Primerjava metod za transformacijo slik je na realnih slikah zahtevna. Težko je pridobiti dovolj veliko množico raznolikih slik, ki bi bile zajete pod točno določenimi osvetlitvami. Množica bi morala vsebovati pare slik identične scene, pri čemer bi bili slike zajeti pod različnima znanima osvetlitvama. Scena bi morala biti statična, pogoji osvetlitve pa se ne bi smeli spreminjati. Obe predpostavki je v naravi (izven fotografskih studiev) velikokrat težko zagotoviti. Zato se primerjava metod za transformacijo slik največkrat izvaja na sintetičnih slikah oziroma umetno pridobljenih barvnih vrednostih.

Metoda transformacije z uporabo barvnih podprostorov, opisana v poglavju 3.5.1, predvideva, da je na vhodni sliki prisotna Macbethova barvna razpredelnica. Zato na sintetičnih slikah njene učinkovitosti ni mogoče preveriti. Odločili smo se, da učinkovitost metod preverimo s primerjanjem transformiranih vrednosti kvadratov Macbethove barvne razpredelnice na vhodni sliki z referenčnimi vrednostmi kvadratov Macbethove barvne razpredelnice pod standardno D65 osvetlitvijo. Da bi zagotovili nepristranskost, smo upoštevali:

- Barvna vrednost obravnavanega kvadrata ne sme biti vključena med točke, s katerimi porazdeljujemo barvni prostor. Sicer se barvna vrednost preslika brez napake, saj je del transformacijske matrike.

- Kromatične vrednosti kvadratov v zadnji vrsti Macbethove barvne razpredelnice so si zelo podobne. Zato vsa preverjanja in transformacije potekajo na prirejeni Macbethovi barvni razpredelnici, ki v zadnji vrsti vsebuje samo tretji kvadrat z leve. Namesto tretjega kvadrata iz leve bi lahko izbrali katerikoli kvadrat v zadnji vrsti.

Postopek testiranja metode transformacije z uporabo barvnih podprostorov na vhodni sliki je naslednji:

1. Izračunamo barvne vrednosti kvadratov Macbethove barvne razpredelnice na vhodni sliki.
2. Iz množice barvnih vrednosti odstranimo vrednosti vseh kvadratov iz zadnje vrste, razen vrednosti tretjega kvadrata z leve.
3. Za vsakega izmed preostalih 19 kvadratov ponovimo:
 - (a) Iz množice barvnih vrednosti začasno odstranimo vrednost obravnavanega kvadrata – kvadrata, ki ga preslikujemo v trenutnem koraku iteracije.
 - (b) Razdelimo barvni prostor.
 - (c) Preverimo, v kateri podprostor pade vrednost trenutno obravnavanega kvadrata.
 - (d) S transformacijsko matriko preslikamo vrednost trenutno obravnavanega kvadrata.
 - (e) Izračunamo kotno napako med preslikano in referenčno vrednostjo kvadrata pod standardno osvetlitvijo
4. Skupna kotna napaka pri preslikavi slike je enaka povprečju napak pri 19-ih obravnavanih kvadratih.

Postopek testiranja drugih metod za transformacijo slik na vhodni sliki je podoben:

1. Izračunamo barvne vrednosti kvadratov Macbethove barvne razpredelnice na vhodni sliki.
2. Iz množice barvnih vrednosti odstranimo vrednosti vseh kvadratov iz zadnje vrste, razen vrednost tretjega kvadrata z leve.
3. Vrednosti vsakega izmed preostalih 19-ih kvadratov preslikamo z metodo transformacije (uporabimo referenčne vrednosti osvetlitev slik) ter izračunamo kotno napako med preslikano in referenčno vrednostjo kvadrata pod standardno osvetlitvijo.
4. Skupna kotna napaka pri preslikavi slike je enaka povprečju napak pri 19-ih obravnavanih kvadratih.


Za osnovno metriko smo uporabili povprečno kotno napako pri preslikavi slike. Tabela 4.3 prikazuje vrednosti napak. Rezultati posameznih metod so si podobni. Izstopata transformaciji v XYZ barvnem prostoru in transformacija z uporabo barvnih podprostorov. XYZ barvni prostor ni primeren za transformacijo slik in se uporablja zgolj kot osnova za linearno izpeljavo

Uporabljen barvni prostor	Kotna napaka	Doseženo mesto
sRGB	6,0°	2.
XYZ	6,3°	6.
Bradford	6,1°	4.
Sharp	6,0°	2.
CMCCAT2000	6,1°	4.
Barvni podprostor	5,1°	1.

Tabela 4.3: Povprečne kotne napake pri transformaciji kvadratov Macbethove barvne razpredelnice ob znanih osvetlitvah slik.

drugih, bolj primernih, barvnih prostorov. Povprečna napaka transformacije z uporabo barvnih podprostorov je manjša od povprečnih napak drugih metod, kar je vzpodbuden rezultat za uporabo in nadaljnji razvoj metode. Presenetljiv je rezultat transformacije v sRGB barvnem prostoru, saj nekateri avtorji navajajo [30, 31], da transformacije v prostorih, ki temeljijo na RGB barvnem modelu, dosegajo slabše rezultate kot transformacije v linearnih izpeljankah prostora XYZ.


Škatlasti grafi na sliki 4.2 podrobneje prikazujejo rezultate primerjave metod za transformacijo slik. Primerjane vrednosti niso enake kot pri osnovni metriki primerjave v tabeli 4.3. Tam smo primerjali kotne napake pri preslikavi slike, tukaj primerjamo napake pri preslikavi posameznih kvadratov.



Slika 4.2: Škatlasti grafi kotnih napak algoritmov za transformacijo slik na posameznih kvadratih Macbethove barvne razpredelnice ob znanih osvetlitvah slik.

Grafi vseh metod so si podobni. Opazno nižji spodnji kvartil, mediano, zgornji kvartil in omejeno maksimalno vrednost ima graf barvnih podprostorov. Zanimivi sta dve največji napaki (okoli 72° in 73°), ki se pojavita pri vseh metodah. Vzrok je v zelo šibki osvetljenosti slike iz podatkovne baze. Slika, kjer se napaki pojavita, je močno podosvetljena, zato je večina kvadratov Macbethove barvne razpredelnice na sliki črne barve. Posledica je velika napaka pri primerjavi vrednosti kvadratov z referenčnimi vrednostmi.

Primerjava povprečnih kotnih napak na posameznih kvadratih pri preslikavi z uporabo barvnih podprostorov na sliki 4.3 pokaže, da se povprečne napake po kvadratih razlikujejo.



Slika 4.3: Povprečje kotnih napak na posameznih kvadratih Macbethove barvne razpredelnice pri transformaciji z uporabo barvnih podprostorov ob znanih osvetlitvah slik. Kvadrati v zadnji vrsti (razen tretjega z leve) niso bili vključeni v testiranje.

V grobem lahko kvadrate razdelimo v dve skupini: kvadrati z večjo povprečno napako (rjav, temno zelen, vijoličen, turkizno moder) in kvadrati z manjšo povprečno napako (preostali kvadrati). Večja napaka v prvi skupini kvadratov je lahko posledica napačnih referenčnih barvnih vrednosti kvadratov. Referenčne vrednosti kvadratov Macbethove barvne razpredelnice pod standardno D65 osvetlivijo, specificirane v [39], so lahko drugačne od referenčnih vrednosti kvadratov Macbethove barvne razpredelnice, uporabljene pri zajemu slik. Drug razlog je lahko v manjši količini svetlobe, ki jo ti kvadrati odbijajo. Na podosvetljenih slikah so skorajda črne barve.

Rezultati Mann-Whitney U testa, podani v tabeli 4.4, pokažejo, da se srednje vrednosti napak transformacij v prostorih sRGB, Bradford, Sharp in CMCCAT2000 statistično pomembno ne razlikujejo. Transformacija v prostoru XYZ ima pomembno večjo srednjo vrednost napake od večine drugih metod. Nasprotno ima transformacija z uporabo barvnih podprostorov nižjo srednjo vrednost napake od vseh drugih metod. Zato pod pogoji eksperimenta predstavlja optimalno metodo za transformacijo slik.

	sRGB	XYZ	Bradford	Sharp	CMCCAT2000	Barvni podprostori
sRGB	X	1	0	0	0	-1
XYZ	-1	X	-1	-1	0	-1
Bradford	0	1	X	0	0	-1
Sharp	0	1	0	X	0	-1
CMCCAT2000	0	0	0	0	X	-1
Barvni podprostori	1	1	1	1	1	X


Tabela 4.4: Rezultati Mann-Whitney U testa pri primerjavi metod za transformacijo slik ob znanih osvetlitvah slik.

4.2.1 Vizualna primerjava slik z znano osvetlitvijo, transformiranih z metodo barvnih podprostorov

S pomočjo izbranih slik iz podatkovne baze smo vizualno primerjali rezultate transformacije z dvema različnima metodama: z metodo Sharp in metodo uporabe barvnih podprostorov. Metodo Sharp smo izbrali, ker je pri testiranju dosegla drug najboljši rezultat. Gre za subjektivno primerjavo s katero pa opozorimo na dve težavi, ki se pojavita pri preslikavah z metodo uporabe barvnih podprostorov. Slika 4.4 prikazuje tri izbrane fotografije pred in po transformaciji. Fotografija v prvi vrsti je bila zajeta pri osvetlitvi, ki se pomembno ne razlikuje od standardne D65 osvetlitve. Končni rezultat obeh transformacij je podoben. Večjih razlik med transformirano in vhodno sliko ni opaziti. Fotografija v drugem stolpcu prve vrste daje nekoliko bolj zelenkast vtis kot preostali fotografiji v prvi vrsti.

Vhodna fotografija v drugi vrsti je bila zajeta pod umetnim virom svetlobe, zato ima rumenkast pridih (angl. *color cast*). Obe metodi rumenkast pridih uspešno odstranita; barve na transformiranih slikah so bolj naravne. Povečan detajl prikazuje kvadrat Macbethove barvne razpredelnice, na katerem je na vhodni sliki moč opaziti nekaj šuma. Transformacija z uporabo barvnih podprostorov šum opazno poveča. Razlog je v različnih transformacijskih matrikah, ki se uporabljajo za preslikovanje barvnih podprostorov. Zgodi se da slikovni elementi, ki predstavljajo šum, pripadajo drugemu barvnemu podprostoru kot sosednji slikovni elementi brez šuma. V odvisnosti od podobnosti transformacijskih matrik obeh podprostorov se ta šum poveča oziroma zmanjša. Delno rešitev problema predstavlja predprocesiranje slike s filtrom za odstranjevanje šuma. Druge možnosti rešitve oziroma omejitve problema so podane v nadaljevanju.

Fotografija v tretji vrsti slike 4.4 je bila prav tako zajeta pod umetnim virom svetlobe. Obe transformaciji odstranita rumenkast pridih na sliki. Fotografija, transformirana z metodo uporabe barvnih podprostorov, ima nekoliko bolj naraven videz, saj je na fotografiji, transformirani z metodo Sharp, mogoče opaziti rahel rdečkast pridih (glej levo stran fotografije).



Slika 4.4: Transformacije izbranih fotografij iz podatkovne baze Color-checker. V prvem stolpcu vidimo slike pred transformacijo, v drugem vidimo slike, transformirane z metodo Sharp, in v tretjem stolpcu slike, transformirane z metodo barvnih podprostorov. Fotografije v drugi in tretji vrsti imajo povečane zanimive detajle. Po transformacijah smo na vseh slikah izvedli gama korekcijo, da smo slikale prilagodili za prikaz na zaslonih.

Povečan detajl prikazuje drugi problem, ki se pojavi pri transformaciji slik z uporabo barvnih podprostorov. Na povečanem detajlu fotografije v tretjem stolpcu opazimo, da se barve mize ne prelivajo gladko (oster prelom). Tega na preostalih fotografijah ni moč opaziti. Izvor problema je enak kot pri problemu s šumom – različne transformacijske matrike barvnih podprostorov. Slikovni element na področju preloma pripadajo drugemu barvnemu podprostoru, katerega transformacijska matrika se razlikuje od transformacijske matrike podprostora sosednjih slikovnih elementov.

Rezultat je močan in nenaden prelom, ki daje fotografiji nenaraven videz. Za rešitev oziroma omejitev omenjenih problemov predlagamo naslednje možnosti, katerih učinkovitost bomo raziskali v prihodnje:

- **Uporaba alternativnega barvnega prostora:** Algoritem pri preslikovanju in izračunu transformacijskih matrik uporablja barvne vrednosti rg kromatičnega modela. Potrebno bi bilo raziskati, ali obstaja drug barvni prostor, ki bi omejil omenjena problema.
- **Uporaba drugačnih transformacijskih matrik:** Algoritem predvideva linearno odvisnost med vsemi komponentami barvnih vrednosti. Lahko bi uporabili von Kriesov model, ki ga uporabljajo druge metode transformacije slik. Von Kriesov model ni tako omejujoč in bi posledično zmanjšal razlike med transformacijskimi matrikami različnih podprostorov.
- **Uporaba večih transformacijskih matrik:** Algoritem barvno točko preslika s transformacijsko matriko podprostora, v katerega spada obravnavana točka. Pri preslikavi bi lahko uporabili uteženo povprečje večih transformacijskih matrik, pri čemer bi uteži predstavljale razdalje med središči barvni podprostorov in obravnavano barvno točko. Rezultat bi bile bolj gladke transformacije.
- **Drugačno razdeljevanje barvnega prostora:** Algoritem razdeli barvni prostor z Delauneyjevo triangulacijo. Kromatični barvni prostor bi lahko razdelili na prekrivajoče se kroge. Barvne točke bi preslikali s transformacijsko matriko kroga, katerega središče je najbližje obravnavani točki, oziroma bi uporabili utežene transformacijske matrike k najbližjih krogov, pri čemer bi uteži predstavljale razdaljo točke do središč krogov.

4.3 Primerjava metod za transformacijo slik z neznano osvetlitvijo

Ker želimo, da je metoda transformacije slike z uporabo barvnih podprostorov uporabna v praksi, je nerealno pričakovati, da bi bile osvetlitve vhodnih slik vnaprej znane in da bi vse vhodne slike vsebovale Macbethovo barvno razporednico. Zato smo preverili, kako se transformacijska metoda obnese v primeru, ko osvetlitev vhodne slike ni znana in jo je potrebno izračunati z eno izmed metod za detekcijo osvetlitve. Za detekcijo osvetlitve smo uporabili algoritem Bayesove barvne konstantnosti, ki se je v primerjavi algoritmov za detekcijo osvetlitve najbolj izkazal (glej poglavje 4.1). Primerjavo smo izvedli na podatkovni bazi slik Color-checker [22], katerega slike vsebujejo Macbethovo barvno razporednico, vendar za razdeljevanje barvnega prostora nismo uporabili vrednosti kvadratov Macbethove barvne razporednice na sliki, temveč vrednosti kvadratov Macbethove barvne razporednice s slike, katere osvetlitev je najbolj podobna detektirani osvetlitvi vhodne slike (glej poglavje 3.5.2).

Postopek testiranja metode transformacije z uporabo barvnih podprostorov na vhodni sliki je sledeč:

1. Z algoritmom Bayesove barvne konstantnosti izračunamo osvetlitev vhodne slike.
2. V podatkovni bazi vrednosti kvadratov Macbethove barvne razporednice poiščemo osvetlitev, ki je najbolj podobna detektirani osvetlitvi. Pripadajoče vrednosti kvadratov Macbethove barvne razporednice V predstavljajo osnovo za razdeljevanje barvnega prostora.
3. Izračunamo barvne vrednosti kvadratov Macbethove barvne razporednice na vhodni sliki V_{img} .
4. Iz množic V in V_{img} odstranimo vrednosti vseh kvadratov iz zadnje vrste, razen vrednosti tretjega kvadrata z leve.

5. Za vsakega izmed preostalih 19-ih kvadratov iz množice V_{img} ponovimo:
 - (a) Iz množice V začasno odstranimo vrednost obravnavanega kvadrata.
 - (b) S točkami iz množice V razdelimo barvni prostor.
 - (c) Preverimo, v kateri podprostor pade vrednost trenutno obravnavanega kvadrata iz množice V_{img} .
 - (d) S transformacijsko matriko preslikamo vrednost trenutno obravnavanega kvadrata.
 - (e) Izračunamo kotno napako med preslikano in referenčno vrednostjo kvadrata pod standardno osvetlitvijo.
6. Napaka pri preslikavi slike je enaka povprečju napak pri 19-ih obravnavanih kvadratih iz množice V_{img} .

Postopek testiranja drugih metod za transformacijo slik na vhodni sliki pa je sledeč:

1. Z algoritmom Bayesove barvne konstantnosti izračunamo osvetlitev vhodne slike.
2. Izračunamo barvne vrednosti kvadratov Macbethove barvne razpredelnice na vhodni sliki.
3. Iz množice barvnih vrednosti odstranimo vrednosti vseh kvadratov iz zadnje vrste, razen vrednost tretjega kvadrata z leve.
4. Vrednosti vsakega izmed preostalih 19-ih kvadratov preslikamo z metodo transformacije (uporabimo v prvem koraku izračunane vrednosti osvetlitve) ter izračunamo kotno napako med preslikano in referenčno vrednostjo kvadrata pod standardno osvetlitvijo.
5. Napaka pri preslikavi slike je enaka povprečju napak na pri 19-ih obravnavanih kvadratih.


Za osnovno metriko smo uporabili povprečno kotno napako pri preslikavi slike. Tabela 4.5 prikazuje vrednosti napak. Povprečne kotne napake pri preslikavi so pri vseh metodah podobne. Tudi iz škatlastih grafov na sliki 4.5 lahko razberemo, da so distribucije povprečnih kotnih napak posameznih metod podobne. Najbolj izstopata večji tretji kvartil ter omejena maksimalna vrednost pri metodi transformacije z uporabo barvnih podprostorov.

Primerjava tabele 4.5 s tabelo 4.3 pokaže, da se je najbolj povečala napaka pri transformaciji z uporabo barvnih podprostorov. Sklepamo, da je uspešnost metode močno odvisna od natančnosti detekcije osvetlitve na vhodni sliki.

Vzroka za povečano napako sta dva. Prvi izvira iz napake pri detekciji osvetlitve. V primeru, da je napaka pri detekciji osvetlitve velika, se bo tudi najbolj podobna osvetlitev v podatkovni bazi močno razlikovala od realne osvetlitve. Graf na sliki 4.6 prikazuje korelacijo med napako pri detekciji osvetlitve in napako pri transformaciji slike. Linearna interpolacija točk (rdeča premica) opiše trend gibanja obeh napak; če se poveča napaka pri detekciji osvetlitve, se poveča tudi napaka pri transformaciji slike. Napake pri detekciji osvetlitve ne moremo zmanjšati, saj smo uporabili algoritem, katerega napaka je v povprečju najmanjša.


Uporabljen barvni prostor	Kotna napaka	Doseženo mesto
sRGB	7,6°	1.
XYZ	7,8°	5.
Bradford	7,6°	1.
Sharp	7,6°	1.
CMCCAT2000	7,7°	4.
Barvni podprostori	7,8°	5.

Tabela 4.5: Povprečne kotne napake pri transformaciji kvadratov Macbethove barvne razpredelnice z uporabo algoritma Bayesove barvne konstantnosti za detekcijo osvetlitve na vhodni sliki.



Slika 4.5: Škatlasti grafi kotnih napak algoritmov pri transformaciji kvadratov Macbethove barvne razporednice z uporabo algoritma Bayesova barvna konstantnost za detekcijo osvetlitve na vhodni sliki.


Drug vzrok izvira iz razlike med detektirano osvetlitvijo in najbližjim uje-manjem v podatkovni bazi. Ta napaka se pojavi samo pri metodi transformacije slike z uporabo barvnih podprostorov. Če osvetlitev slike detektiramo pravilno, a vrednosti kvadratov Macbethove barvne razporednice pod detektirano osvetlitvijo nimamo v podatkovni bazi, moramo za razdeljevanje barvnega prostora uporabiti točke Macbethove barvne razporednice pod osvetlitvijo, ki je samo približek detektirane osvetlitve. Graf na sliki 4.7 prikazuje odvisnost napake pri transformaciji slike od razlike med detektirano osvetlitvijo in najbližjo osvetlitvijo, za katero poznamo barvne vrednosti kvadratov



Slika 4.6: Odvisnost napake pri detekciji osvetlitve z metodo Bayesove barvne konstantnosti od napake pri transformaciji slike z metodo barvnih podprostorov. Rdeča premica prikazuje linearno odvisnost obeh napak.

Macbethove barvne razpredelnice. Opazimo, da napaka pri transformaciji hitro narašča z razliko med detektirano in najbližjo ujemačo se osvetlitvijo. Pri nični razliki med detektirano in najbližjo ujemačo se osvetlitvijo, je napaka (aproksimirana s premico) pri transformaciji slike enaka $7,5^\circ$. Če bi imeli na voljo podatke o vrednostih kvadratov Macbethove barvne razpredelnice pod večimi različnimi osvetlivami, bi zmanjšali napako pri transformaciji. Kljub morebitni napačno detektirani osvetlitvi, bi kot osnovo za razdeljevanje barvnega prostora uporabili barvne točke katerih osvetlitev je bližje detektirani, saj bi bila razlika med detektirano osvetlitvijo in najbližjim ujemanjem v podatkovni bazi manjša. Primerjava napake pri nični razliki med detektirano in najbližjo ujemačo osvetlitvijo $(7,5^\circ)$ z vrednostmi v ta-

beli 4.5 pokaže, da bi metoda transformacije z uporabo barvnih podprostorov v primeru nične razlike med detektirano in najbližjo osvetlitvijo dosegla prvo mesto. Razlika povprečnih kotnih napak metode transformacije slike z uporabo barvnih podprostorov ter metode Sharp bi bila v tem primeru $0,1^\circ$, medtem ko je razlika povprečnih kotnih napak obeh metod v tabeli 4.3 enaka $0,9^\circ$. Vzrok je napaka pri detekciji osvetlitve, ki ima večji vpliv v procesu pridobivanja barvno konstantne slike.



Slika 4.7: Odvisnost napake pri transformaciji slike z metodo barvnih podprostorov od napake iskanja najbližje ujemajoče se osvetlitve. Rdeča premica prikazuje linearni trend gibanja obeh napak.


Rezultati Mann-Whitney U testa, podani v tabeli 4.6, pokažejo, da se srednje vrednosti napak transformacij statistično pomembno ne razlikujejo. Zaključimo, da je za proces pridobivanja barvno konstantne slike v primeru, ko je osvetlitev vhodne slike neznana, bolj pomemben prvi korak, to je detekcija osvetlitve.

	sRGB	XYZ	Bradford	Sharp	CMCCAT2000	Barvni podprostor
sRGB	X	0	0	0	0	0
XYZ	0	X	0	0	0	0
Bradford	0	0	X	0	0	0
Sharp	0	0	0	X	0	0
CMCCAT2000	0	0	0	0	X	0
Barvni podprostor	0	0	0	0	0	X

Tabela 4.6: Rezultati Mann-Whitney U testa pri primerjavi metod za transformacijo slik, katerih osvetlitev detektiramo z metodo Bayesove barvne konstantnosti.

4.3.1 Vizualna primerjava slik z neznano osvetlitvijo, transformiranih z metodo barvnih podprostorov

Napačna detekcija osvetlitve ima na vizualno podobo slike večji vpliv kot izbira transformacijske metode. Slika 4.8 prikazuje fotografijo, na kateri smo izvedli celoten proces pridobivanja barvno konstantne slike: najprej detekcijo osvetlitve, zatem transformacijo slike. Osvetlitev smo detektirali z algoritmom sivega sveta (fotografije v prvi vrsti) in z metodo Bayesove barvne konstantnosti (fotografije v drugi vrsti). Fotografija je bila načrtno izbrana



Slika 4.8: Transformacija fotografije, pri kateri pride do velikih razlik med metodami za detekcijo osvetlitve. V prvi vrsti je bila osvetlitev detektirana z metodo sivega sveta, v drugi z metodo Bayesove barvne konstantnosti. Sliki v prvem stolpcu sta vhodni sliki (ki sta v obeh vrstah enaki), sliki v drugem stolpcu sta transformirani s Sharp transformacijo, sliki v tretjem stolpcu pa z metodo barvnih podprostorov. Po transformacijah smo na vseh slikah izvedli gama korekcijo. Kotna napaka pri detekciji osvetlitve je pri metodi sivega sveta enaka 42° , pri metodi Bayesove barvne konstantnosti pa 8° .

tako, da je bila napaka pri detekciji osvetlitve z algoritmom sivega sveta velika (42°), z algoritmom Bayesove barvne konstantnosti pa majhna (8°). Fotografijo smo transformirali z metodo Sharp (fotografiji v drugem stolpcu) in z metodo uporabe barvnih podprostorov (fotografiji v tretjem stolpcu).

Fotografija, pri kateri je bila osvetlitev detektirana z algoritmom sivega sveta in je bila transformirana z metodo Sharp, je videti nenaravno – ima močan zelen barvni pridih. Razlog je v veliki napaki pri detekciji osvetlitve. Nasprotno je rezultat transformacije metode z uporabo barvnih podprostorov fotografija, ki je videti bolj naravno. Metoda transformacije z uporabo barvnih podprostorov vizualno bolje kompenzira napačno detektirano osvetlitev.

Medtem ko druge metode za transformacijo slik v primeru napačno detektirane osvetlitve na celotni sliki povzročijo enakomeren barvni pridihi, metoda transformacije z uporabo barvnih podprostorov različne barvne vrednosti preslika z različnimi transformacijskimi matrikami. Rezultat je slika, ki nima tako izrazitega barvnega pridiha.

Pri transformaciji fotografije, z majhno napako pri detekciji osvetlitve (druga vrsta), je končni rezultat transformacije pri obeh metodah za transformacijo slik vizualno podoben. Obe barvno konstantni fotografiji imata naraven videz, s pravilno izravnano rahlo modrikasto osvetlitvijo na vhodni fotografiji.

Poglavje 5

Zaključek

Problem digitalne barvne konstantnosti se pojavi vsaj na treh področjih: na področju digitalne fotografije, na področju tiska in na področju računalniškega vida. V vseh primerih si želimo, da imajo slikovni elementi barvne vrednosti, ki odražajo spektralne lastnosti predmetov na sliki. Izločiti želimo vpliv morebitne nestandardne osvetlitve slike. Človeški vizualni sistem naredi to samodejno, slikovni senzorji pa ne.

V diplomskem delu je opisan dvostopenjski proces pridobivanja barvno konstantne slike: najprej detektiramo osvetlitev, zatem na podlagi pridobljene informacije ustrezno transformiramo vhodno sliko. Evalvacija algoritmov za detekcijo osvetlitve je podana v poglavju 4.1. Najboljše rezultate dosega naslednji algoritmi: preslikava barvnih obsegov, Bayesova barvna konstantnost in semantična barvna konstantnost. Vsi omenjeni algoritmi v procesu odločanja uporabljajo predznanje in dosega dobre rezultate tudi v primerih močnega odstopanja osvetlitve. Seveda v primeru, da je množica slik, s katero smo zgradili predznanje, vsebovala slike s podobno osvetlitvijo.

V poglavju 4.2 primerjamo metode za transformacijo slik. Če je osvetlitev vhodnih slik znana, najboljše rezultate doseže nova metoda, predlagana v diplomskem delu – metoda transformacije z uporabo barvnih podprostorov. Vizualni pregled transformiranih slik izpostavi dva problema predlagane metode. Prvi problem predstavlja občutljivost metode na šum.

Drugi problem predstavljajo ostri barvni prelomi, ki se pojavijo na nekaterih transformiranih slikah in na vhodnih slikah niso prisotni. Prelomi so posledica različnih transformacijskih matrik barvnih podprostorov. Smernice za rešitev problemov so podane v poglavju 4.2.1.

Rezultati testiranja dvostopenjskega procesa pridobivanja barvno konstantne slike so predstavljeni v poglavju 4.3. Izkaže se, da ima detekcija osvetlitve večji vpliv na končni rezultat kot transformacija slike. Napake metod za transformacijo slike se glede na statistično pomembnost ne razlikujejo. Metoda transformacije slik z uporabo barvnih podprostorov je poleg napake pri detekciji osvetlitve občutljiva še na eno vrsto napake. Na napako pri iskanju najbližje ujemajoče se osvetlitve, za katero poznamo barvne vrednosti kvadratov Macbethove barvne razpredelnice. Kljub temu se izkaže, da metoda transformacije slik z uporabo barvnih podprostorov vizualno kompenzira napačno detektirano osvetlitev bolje od preostalih metod, saj transformirani sliki ne doda tako izrazitega barvnega pridiha.

Transformiranje slik z uporabo barvnih podprostorov predstavlja novo idejo na področju barvne konstantnosti, ki doslej še ni bila raziskana. Rezultati in ugotovitve diplomskega dela kažejo, da predstavljena metoda dosega boljše (v določenih scenarijih pa primerljive) rezultate kot druge, uveljavljene metode s tega področja, kar je dobra vzpodbuda za nadaljnje raziskovanje in odpravo pomanjkljivosti predlagane metode.

Slike

2.1	Umestitev vidne svetlobe v elektromagnetni spekter	3
2.2	Občutljivost različnih vrst čepnic	4
2.3	Vpliv osvetlitve in odbojnih lastnosti predmetov na barvni signal	5
2.4	Barvna obsega AdobeRGB in sRGB prostorov	7
2.5	Poenostavljena shema delovanja CMOS senzorja	10
2.6	Zrcalni in difuzni odboj svetlobe	11
3.1	Optična iluzija	14
3.2	Fotografije enake scene z različnimi nastavitvami beline	15
3.3	Postopek pridobivanja barvno konstantne slike	16
3.4	Osnovni princip izračuna množice vseh možnih preslikav	21
3.5	Weibull parametrizacija podatkovne baze slik	26
3.6	Shema delovanja algoritma semantične barvne konstantnosti .	28
3.7	Barvno pravilna slika in slika z barvnim pridihom	30
3.8	Bazne funkcije transformiranega XYZ barvnega prostora	32
3.9	Delaunayjeva triangulacija točk	36
3.10	Macbethova barvna razpredelnica	37
3.11	Razdelitev barvnega prostora na barvne podprostore	38
3.12	Distribucija osvetlitve slik iz podatkovne baze Color-checker .	42
4.1	Škatlasti grafi kotnih napak pri detekciji osvetlitve	49
4.2	Škatlasti grafi kotnih napak algoritmov za transformacijo slik ob znanih osvetlitvah slik	54
4.3	Kotne napake na kvadratih Macbethove barvne razpredelnice .	55

4.4	Transformacije fotografij iz podatkovne baze Color-checker . . .	58
4.5	Škatlasti grafi kotnih napak algoritmov za transformacijo slik ob neznanih osvetlitvah slik	63
4.6	Odvisnost napake pri detekciji osvetlitve od napake pri trans- formaciji slike z metodo barvnih podprostorov	64
4.7	Odvisnost napake pri transformaciji slike z metodo barvnih podprostorov od napake iskanja najbližje ujemajoče se osvetlitve	65
4.8	Transformacija fotografije, pri kateri pride do velikih razlik med metodami za detekcijo osvetlitve	67

Tabele

3.1	Opis statičnih algoritmov s parametri enačbe, ki temelji na normi Minkowskega	25
4.1	Povprečne kotne napake algoritmov za detekcijo osvetlitve . . .	47
4.2	Rezultati Mann-Whitney U testa pri primerjavi metod za detekcijo osvetlitve	50
4.3	Povprečne kotne napake pri transformaciji kvadratov Macbethove barvne razpredelnice ob znanih osvetlitvah slik	53
4.4	Rezultati Mann-Whitney U testa pri primerjavi metod za transformacijo slik ob znanih osvetlitvah slik	56
4.5	Povprečne kotne napake pri transformaciji kvadratov Macbethove barvne razpredelnice ob neznanih osvetlitvah slik	62
4.6	Rezultati Mann-Whitney U testa pri primerjavi metod za transformacijo slik ob neznanih osvetlitvah slik	66

Literatura

- [1] M. Ebner, *Color Constancy*. New York: John Wiley, 2007.
- [2] G. Svaetichin, “Spectral response curves from single cones,” *Acta Physiol Scand Suppl*, vol. 39, no. 134, pp. 17–46, 1956.
- [3] (2012) Color space conversions. Dostopno na: <http://www.poynton.com/PDFs/coloureq.pdf>.
- [4] A. Dickinson, B. Ackland, E. S. Eid, D. Inglis, and E. Fossum, “Standard cmos active pixel image sensors for multimedia applications,” in *Conference on Advanced Research in VLSI*, vol. 16, pp. 214–224, 1995.
- [5] A. Gijsenij, T. Gevers, and J. van de Weijer, “Computational color constancy: survey and experiments,” *IEEE Trans Image Process*, vol. 20, no. 9, pp. 2475–2489, 2011.
- [6] F. Ciurea, *Colour constancy theories in the real world*. Ottawa: Library and Archives Canada (Bibliothèque et Archives Canada), 2006.
- [7] E. H. Land, “The retinex theory of color vision,” *Sci. am.*, vol. 237, no. 6, pp. 108–128, 1977.
- [8] K. Hirakawa and T. W. Parks, “Chromatic adaptation and white-balance problem,” in *IEEE International Conference on Image Processing (ICIP)*, vol. 3, pp. III – 984–7, sept. 2005.

-
- [9] J. Kovač, Izločanje vpliva nestandardnih osvetlitev iz slik, diplomska naloga, Fakulteta za računalništvo in informatiko Univerze v Ljubljani, Slovenija, 2002.
 - [10] J. J. M. Granzier, E. Brenner, and J. B. J. Smeets, “Can illumination estimates provide the basis for color constancy?,” *Journal of Vision*, vol. 9, no. 3, pp. 1–11, 2009.
 - [11] B. V. Funt, K. Barnard, and L. Martin, “Is machine colour constancy good enough?,” in *European Conference on Computer Vision (ECCV)*, vol. 1, pp. 445–459, 1998.
 - [12] J. van de Weijer, T. Gevers, and A. Gijsenij, “Edge-based color constancy,” *IEEE Transactions on Image Processing*, vol. 16, no. 9, pp. 2207–2214, 2007.
 - [13] D. A. Forsyth, “A novel algorithm for color constancy,” *Int. J. Comput. Vision*, vol. 5, pp. 5–36, Sept. 1990.
 - [14] A. Gijsenij, *Edge-driven color constancy*. PhD thesis, Natuurwetenschappen, Wiskunde en Informatica.
 - [15] C. Rosenberg, T. Minka, and A. Ladsariya, “Bayesian color constancy with non-gaussian models,” in *Advances in Neural Information Processing Systems 16*, Cambridge, MA: MIT Press, 2004.
 - [16] A. Gijsenij and T. Gevers, “Color constancy using natural image statistics,” in *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 1–8, 2007.
 - [17] J. van de Weijer, C. Schmid, and J. Verbeek, “Using high-level visual information for color constancy,” in *IEEE International Conference on Computer Vision (ICCV)*, pp. 1–8, 2007.

-
- [18] B. V. Funt and L. Shi, “The effect of exposure on maxRGB color constancy,” in *Proc. SPIE*, vol. 7527 Human Vision and Electronic Imaging XV, 2010.
 - [19] J. von Kries, “Influence of adaptation on the effects produced by luminous stimuli,” in *Sources of Color Science* (D. L. MacAdam, ed.), pp. 109–119, Cambridge, MA: MIT Press, 1970.
 - [20] G. Finlayson and S. Hordley, “Improving gamut mapping color constancy,” *IEEE Transactions on Image Processing*, vol. 9, no. 10, pp. 1774–1783, 2000.
 - [21] M. Grant, S. Boyd, and Y. Ye, “Disciplined convex programming,” in *Global Optimization: From Theory to Implementation, Nonconvex Optimization and Its Application* (P. Pardalos, ed.), pp. 155–210, New York, NY: Springer, 2006.
 - [22] P. V. Gehler, C. Rother, A. Blake, T. Minka, and T. Sharp, “Bayesian color constancy revisited,” in *IEEE Computer Vision and Pattern Recognition (CVPR)*, pp. 1–8, 2008.
 - [23] A. Torralba and A. Oliva, “Statistics of natural image categories,” in *Network: Computation in Neural Systems*, pp. 391–412, 2003.
 - [24] J. M. Geusebroek and A. W. M. Smeulders, “A six-stimulus theory for stochastic texture,” *International Journal of Computer Vision*, vol. 62, no. 1–2, pp. 7–16, 2005.
 - [25] T. Hansen, M. Olkkonen, S. Walter, and K. R. Gegenfurtner, “Memory modulates color appearance,” *Nat. Neurosci.*, vol. 9, no. 11, pp. 1367–1368, 2006.
 - [26] J. Sivic, B. C. Russell, A. A. Efros, A. Zisserman, and W. T. Freeman, “Discovering objects and their location in images,” in *IEEE International Conference on Computer Vision (ICCV)*, vol. 1, pp. 370–377, 2005.

-
- [27] D. G. Lowe, “Distinctive image features from scale-invariant keypoints,” *Int. J. Comput. Vision*, vol. 60, no. 2, pp. 91–110, 2004.
- [28] R. Gershon, A. D. Jepson, and J. K. Tsotsos, “From [r,g,b] to surface reflectance: computing color constant descriptors in images,” in *International joint conference on Artificial intelligence (IJCAI)*, vol. 2, pp. 755–758, 1987.
- [29] N. Ohta, *Colorimetry : fundamentals and applications*. Chichester, West Sussex, NJ, USA: J. Wiley, 2005.
- [30] S. Süssstrunk, J. Holm, and G. D. Finlayson, “Chromatic Adaptation Performance of Different RGB Sensors,” *Color imaging: Device-independent color*, vol. 4300, pp. 172–183, 2001.
- [31] K. Barnard, F. Ciurea, and B. Funt, “Sensor sharpening for computational color constancy,” *J. Opt. Soc. Am. A*, vol. 18, no. 11, pp. 2728–2743, 2001.
- [32] “IEC multimedia systems and equipment – colour measurement and management – part 2-1: Colour management – default rgb colour space – srgb,” *Standard IEC 61966-2-1: 1999*, 1999.
- [33] J. A. S. Viggiano, “Comparison of the accuracy of different white-balancing options as quantified by their color constancy,” *Sensors and Camera Systems for Scientific, Industrial, and Digital Photography Applications*, vol. 5301, pp. 323–333, 2004.
- [34] R. W. G. Hunt and M. R. Pointer, *Metamerism and Colour Constancy*. John Wiley and Sons, Ltd, 2011.
- [35] G. D. Finlayson and S. Süssstrunk, “Performance of a Chromatic Adaptation Transform Based on Spectral Sharpening,” in *Color Imaging Conference (CIC)*, vol. 8, pp. 49–55, 2000.

-
- [36] C. Li, M. R. Luo, and B. Rigg, "Simplification of the CMCCAT97," in *Color Imaging Conference (CIC)*, vol. 8, pp. 56–60, 2000.
- [37] B. Delaunay, "Sur la sphère vide, izvestia akademii nauk sssr," *Otdelenie Matematicheskikh i Estestvennykh Nauk*, vol. 6, no. 7, pp. 793–800, 1934.
- [38] C. S. McCamy, H. Marcus, and J. G. Davidson, "Sensor sharpening for computational color constancy," *A Color-Rendition Chart*, vol. 2, no. 3, pp. 95–99, 1976.
- [39] (2012) RGB coordinates of the Macbeth ColorChecker. Dostopno na: [http://www.babelcolor.com/download/RGB Coordinate of the Macbeth ColorChecker.pdf](http://www.babelcolor.com/download/RGB%20Coordinate%20of%20the%20Macbeth%20ColorChecker.pdf).
- [40] (2012) Bayesian Color Constancy Revisited. Dostopno na: <http://people.kyb.tuebingen.mpg.de/pgehler/colour/index.html>.
- [41] H. B. Mann and D. R. Whitney, "On a test of whether one of two random variables is stochastically larger than the other," *Annals of Mathematical Statistics*, vol. 18, no. 1, pp. 50–60, 1947.