

**SVEUČILIŠTE U ZAGREBU**  
**GRAFIČKI FAKULTET**

**KRISTINA MARIJANOVIĆ**

**PROCJENA KOLORIMETRIJSKIH VRIJEDNOSTI**  
**PIGMENATA SLIKE KORIŠTENJEM**  
**HIPERSPEKTRALNIH INFORMACIJA**

**DIPLOMSKI RAD**

**ZAGREB, 2013.**



Sveučilište u Zagrebu  
Grafički fakultet

MODUL: GRAFIČKA TEHNOLOGIJA

**PROCJENA KOLORIMETRIJSKIH VRIJEDNOSTI  
PIGMENATA SLIKE KORIŠTENJEM  
HIPERSPEKTRALNIH INFORMACIJA**

DIPLOMSKI RAD

Mentor

doc. dr.sc.Maja Strgar Kurečić

Student

Kristina Marijanović

## **ZAHVALA**

Zahvaljujem se članovima katedre za Reprodukcijsku fotografiju Grafičkog fakulteta doc. dr. sc. Lidiji Mandić i doc.dr.sc. Anti Poljičku na uvijek kvalitetnom druženju. Također, hvala profesoricu Dijani Milčić na višegodišnjem povjerenju i inspiraciji. Zahvaljujem se članovima Instituta za Fotoniku University of Eastern Finland koji su mi nesebično omogućili proširivanje ovog rada danim mjerenjima u svom laboratoriju. Jedno ogromno hvala mojoj mentorici doc.dr.sc. Maji Strgar Kurečić na velikoj podršci tijekom nastajanja ovog rada. Na kraju, neizmjereno hvala mojim roditeljima za nesebičnu ljubav kojom me uvijek prate. Konačno, hvala Svemiru na jedinstvenoj dozi optimizma i ludila koja me, nadam se, neće nikada napustiti.

Mojoj Susedi.

## SAŽETAK

Procjena kolorimetrijskih vrijednosti pigmenata umjetničke slike korištenjem spektralnih informacija proširena je na hiperspektralne informacije. Razlog tome je dostupnost specijalno napravljenih hiperspektralnih kamera. Hiperspektralnom informacijom dobivamo značajno više podataka o mjerenom objektu, u ovom slučaju je to određeni pigment i vezivo korišteno u stvaranju slike. Fizikalne metode korištene u klasičnoj restauraciji slika daju nam uvid u kemijski sastav pigmenata na temelju kojeg se dalje zaključuju i točno određuju pigmenti slike. Svaki pigment i vezivo u kombinaciji daju specifičnu informaciju. Tako definiran spektar na tek korištenom pigmentu te usporedba tog pigmenta nakon određenog vremenskog razdoblja daju nam osnovu za digitalno predviđanje i ponašanje u procesu starenja pigmenta i pripadajućeg veziva. U metodološkom dijelu rada slijedi obrada mjerenih podataka korištenjem Matlab-a pomoću kojeg je omogućeno predviđanje podataka. Rezultati modeliranja izraženi su kolorimetrijskim vrijednostima u cilju jednostavnije primjene u digitalnom okruženju i komunikacije prostora boja. Postojanje sličnih rješenja trebalo bi olakšati konzervacijski, kasnije i restauracijski, rad gdje je informacija o ponašanju određenih slikarskih boja u vremenskoj dimenziji vrlo značajna. U cilju uštede vremena i upotrebljenih materijala, poput pigmenata i veziva, korištenje metoda zapisa koje nemaju degradacijsko djelovanje na ispitivani objekt uzimamo kao pozitivan pristup. Predviđanje kolorimetrijskih vrijednosti namjenjenih korištenju u digitalnom okruženju pomoću spektralnih i hiperspektralnih informacija trebalo bi omogućiti preciznije modeliranje željenog produkta odnosno vrijednosti boje.

Ključne riječi: procjena boje, hiperspektralni zapisi, digitalizacija, umjetničke slike, resturacija, modeliranje

## **SUMMARY**

Initial topic of this research was focused on colorimetric estimation of pigments in fine art by means spectral information. Nevertheless, it was upgraded to hyperspectral information due to hyperspectral camera access. Hyperspectral information enable fairly significant amount of measured object than it is case with spectral information. Methods used in fine art restoration provide chemical information of the object that is afterwards used to determine origin, color and pigments of that object. Every pigment and binder in their specific combination will result with unique spectral response, spectral information. That unique spectrum, if compared from its beginning and in present time can give us direction of deterioration of that specific material used (color paint). This is to be done by digital methods in order to preserve measured fine art object (painting). In this work this was done by using Matlab. Modeling was conducted using initial information from 2006. and final information that was measured again in 2013. Combining these two resources for two different painting techniques together with classic spectral response and hyperspectral one resulted in one step closer to possibility of defining material used by non-destructive method.

Key words: paint estimation, hyperspectral information, digitalization, fine art, restoration, modeling

# SADRŽAJ

## 1. UVOD

## 2. TEORIJSKI DIO

2.1. Pigmenti.....	3
2.2. Analiza umjetičke slike.....	4
2.2.1. Raman spektroskopija.....	5
2.2.2. X - ray fluorescentna spektroskopija .....	5
2.2.3. X- ray difrakcijom .....	5
2.2.4. Optička mikroskopija .....	5
2.2.5. Skeniranje elektronskim mikroskopom .....	6
2.3. Korištenje blizu-infracrvene spektroskopije.....	6
2.3.1. Metode određivanja pigmenata.....	7
2.3.1.1. Metoda razlikovne slike .....	8
2.3.1.2. Simulacijska kompozitna slika u boji.....	8
2.3.1.3. Analiza glavnih komponenata.....	8
2.3.1.4. Faktorska analiza.....	9
2.4. Spektralna refleksija.....	9
2.5. Slikarske tehnike.....	10
2.5.1. Tempera.....	11
2.5.2. Gvaš.....	12
2.6. Hiperspektralni zapis slike.....	14
2.6.1. Korištenje hiperspektralne informacije.....	16

## 3. EKSPERIMENTALNI DIO

3.1. LCTF Nuance kamera.....	19
3.2. Spektrofotometar GretagMacbeth Eye-One XT.....	23
3.3. Materijali korišteni.....	23
3.4. Svojstveni vektori.....	29
3.5. Spektralna metrika.....	31
3.5.1. RMSE (Root mean square error).....	31
3.5.2. GFC (Goodness of Fit Coefficient).....	31

#### **4. REZULTATI I RASPRAVA**

4.1. Gvaš rezultati .....32

4.2. Tempera rezultati.....39

**5.ZAKLJUČAK..... 46**

**6. LITERATURA.....48**

**7. PRILOG.....54**



## UVOD

Tema ovog diplomskog rada inicijalno je bila usmjerena na procjenu kolorimetrijskih vrijednosti pigmenata umjetničke slike korištenjem spektralnih informacija. Tijekom rada susreli smo se s mogućnosti proširivanja teme na hiperspektralne informacije korištenjem za to specijalno napravljenih hiperspektralnih kamera. Kako je za cilj bila postavljena estimacija kolorimetrijske vrijednosti pigmenta odnosno boje umjetničke slike ova se prilika nije smjela odbiti s obzirom na količinu informacija koju nam hiperspektralni zapis pruža. Što su za monokromatski svijet boje to je hiperspektralna informacija za klasičan spektralni zapis. Hiperspektralnom informacijom dobivamo značajno više podataka o mjerenom objektu, u ovom slučaju je to određeni pigment i vezivo korišteno u stvaranju slike. Fizikalne metode korištene u klasičnoj restauraciji slika daju nam uvid u kemijski sastav pigmenata na temelju kojeg se dalje zaključuju i točno određuju pigmenti slike. Vrlo aktualnom digitalizacijom kulturne baštine neinvazivne metode prikupljanja informacije velika su prednost. Hiperspektralna informacija omogućena je korištenjem posebno izrađenih kamera koje, ovisno o osjetljivosti, definiraju krivulju spektra u digitalnom okruženju s puno više podataka u odnosu na dobivene trikromatske podatke. U ovome vidimo najvažniju prednost koju razradom ove teme želimo iskoristiti u svrhu procjene kolorimetrijskih vrijednosti smještanjem u digitalno okruženje.

Svaki pigment i vezivo u kombinaciji daju specifičnu informaciju. Tako definiran spektar na tek korištenom pigmentu te usporedba tog pigmenta nakon određenog vremenskog razdoblja daju nam osnovu za digitalno predviđanje i ponašanje u procesu starenja pigmenta i pripadajućeg veziva. U ovom radu vremenski period na raspolaganju je 7 godina budući su korišteni materijali naslikani 2006. i čija su mjerenja sačuvana do danas. U metodološkom dijelu rada slijedi obrada mjerenih podataka korištenjem Matlab-a pomoću kojeg je omogućeno predviđanje podataka. Rezultati modeliranja izraženi su kolorimetrijskim vrijednostima u cilju jednostavnije primjene u digitalnom okruženju i komunikacije prostora boja.

Cilj ovog istraživanja je usporediti komunikacijski kanal između umjetničkih slika dvaju različitih slikarskih tehnika odnosno njihove vremenske dimenzije. Na taj način se kreće prema procjeni boje kojom su umjetničke slike kreirane. Postojanje sličnih rješenja trebalo bi olakšati konzervacijski, kasnije i restauracijski, rad gdje je informacija o ponašanju određenih slikarskih boja u vremenskoj dimenziji vrlo značajna. U cilju uštede vremena i upotrebljenih materijala (pigmenata, veziva) korištenje metoda zapisa koje nemaju degradacijsko djelovanje na ispitivani objekt uzimamo kao pozitivan pristup. Predviđanje kolorimetrijskih vrijednosti namjenjenih korištenju u digitalnom okruženju pomoću spektralnih i hiperspektralnih informacija trebalo bi omogućiti preciznije modeliranje željenog produkta odnosno vrijednosti boje.

## **2. TEORIJSKI DIO**

### **2.1. Pigmenti**

Pri identifikaciji autora određene umjetničke slike upravo su materijali ono što daje konačan odgovor. Pri tome vrlo važnu ulogu imaju sami pigmenti koji su jedan od najčešće ispitivanih dijelova na umjetničkim djelima i slikama. Karakteristike pigmenata su temelj slikarstva te je znanje o njima vrlo bitno za povijesno smještanje umjetničkih djela te samim time i za restauraciju njihovih oštećenih područja. Moderne metode analize pružaju vrlo temeljite informacije o kemijskom sastavu pigmenata u slikama. No, velika većina tih metoda zahtijeva i male količine primjerka same slike što je vrlo nepoželjno. Također, neke metode ne mogu dobiti potpunu informacije te se zato koristi više metoda u kombinaciji zajedno za cijelovitu analizu. Ispitivanje materijala odnosno pigmenata korištenjem infracrvenog spektra primijenjuje se i na područje povijesti umjetnosti i restauracije. Ova se metoda izvorno koristi za identifikaciju materijala (pigmenti u slikama), ali se primjenjuje i za druge svrhe. Jedna od tih je i procjena nalazi li se možda druga slika ili crtež ispod same ispitivane slike, zatim razlikuje li se od original od nekog danog crteža ili procjena štete od nastalih oštećenja. Najpraktičniji i najčešće korišten pristup je identificirati pigmente na temelju vidljive refleksije postupkom spektroskopije. Pri restauraciji slike može se također pojaviti i fenomen metamerije ukoliko su oštećena područja obnavljana korištenjem samo vizualnog podudaranja boje. Međutim, metamerija se može izbjeći pažljivim odabirom originalnog ili modernog pigmenata koji ima slična svojstva odnosno spektralnu refleksiju kao i ciljani, tradicionalni pigment. Iako danas određeni pigmenti iz umjetničkih slika više nisu dostupni kao i kombinacije sa vezivima koje su tvorile određenu slikarsku boju, a poneki pigmenti su opisani i sa otrovnim svojstvima te se u tim slučajevima koriste prije navedeni moderni pigmenti.



Slika 1. Primjer različitih pigmenata u njihovm prirodnom stanju

[http://www.trovavetrine.it/imgs/all/studioprofessioni/prodotti/pr\\_studioprofessioni8817.jpg](http://www.trovavetrine.it/imgs/all/studioprofessioni/prodotti/pr_studioprofessioni8817.jpg)

## 2.2. Analiza umjetničke slike

Moderne metode analize pigmenata daju sveobuhvatne informacije o kemijskom sastavu pigmenata u slikama. Metode koje za davanje rezultata zahtijevaju manje količine izvađene iz same slike su invanzivne te su nazvane destruktivnim metodama. Muzeji koriste više analitičkih metoda određivanja svojstava pigmenata. Neke od njih su: x-ray spektroskopija, x-ray fluorescentna spektroskopija, x-ray difrakcijska metoda, neutronska autoradiografija, toplinska gravimetrijska analiza, analiza mikro-probe optičkim mikroskopom. Uz sve navedene metode nije moguće koristiti jedinstven analitički postupak za opće analizu pigmenta te je zato proces određivanja određenog pigmenta raznolik te ovisi o konkretno ispitivanom umjetničkom djelu odnosno slici. Kako bi složene komponente mogle biti ispravno identificirane analiza mora biti temeljita. Većina željenih informacija može se dobiti pomoću kombinacija metoda za cijelovitu analizu. Te su metode analize kombinirane s povijesnim znanjima o samom

pigmentu. Na primjer, određene metode ne mogu identificirati pigmente koji nisu bili korišteni u vrijeme kada je slika nastala. Stoga je znanje o povijesti umjetnosti također izuzetno važno. Informacije oko modernih analitičkih metoda mogu se naći u literaturi [1]. Određene analitičke metode kojima je moguće odrediti pigment opisane su kako slijedi:

### **2.2.1 Raman spektroskopija**

Ovom se tehnikom dobivaju informacije koje omogućuju jedinstvenu identifikaciju pigmenta pomoću njegovog Raman spektra. Može se primijeniti *in situ* i nije invazivna. To je vrlo osjetljiva metoda, ali ima vrlo visoku prostornu rezoluciju. Također, ne može doći do smetnje interferencijom osim ako je pigment povezan fluorescentnim vezivom ili organskim dijelom. [2]

### **2.2.2. X - ray fluorescentna spektroskopija**

Ova se metoda vrlo često koristi u muzejima jer nema potrebe za uzimanjem uzoraka sa samih slika. Pogodna je za identifikaciju anorganski pigmenta jednog određenog sloja. X zrake prodiru kroz film koji je zapravo površina nanosene boje te to može pružiti elementarnu informaciju, ali ne i sastav odnosno samu komponentu. Na primjer, olovo kao element u crvenom bojilu ne može definitivno ukazati na prisutnost crvenog olova kao komponente. Moguće je da je bijelo olovo pomiješano s drugim crvenim pigmentima. Također, ovom se metodom ne mogu otkriti vrlo male količine prisutnih elementa. [3]

### **2.2.3. X- ray difrakcijom**

Ova metoda zahtijeva mali uzorak uklonjen sa umjetničkog djela kako bi ispitivanjem dala rezultate. Dobivenom difrakcijom uzorka može ukazivati na postojanje određenih spojeva. [4]

### **2.2.4 Optička mikroskopija**


Ova metoda može otkriti komponente odnosno spojeve kroz više slojeva nanosene boje. Također je potreban fizički, ali vrlo mali uzorak za analizu. [4]

### 2.2.5. Skeniranje elektronskim mikroskopom

Ova metoda određivanja pigmenta ne može se koristiti samostalno. Najčešće se kombinira s X - ray fluorescentnom spektroskopijom koja je postala široko korištena od strane restauratora. [4]

### 2.3. Korištenje blizu-infracrvene spektroskopije

Analiza umjetničkih djela i pripadajućih korištenih materijala uz pomoću blizu-infracrvenog spektra primjenjuje se na širem području povijesti umjetnosti pa tako i pri restauraciji umjetničkih slika. Metoda se izvorno koristiti za identifikaciju umjetnika materijalom (npr. određeni pigmenti u slikama). Isto tako ova se metoda primjenjuje i naknadno za procjenu crteža koji mogu biti prisutni ispod same slike [5]. Takvi pod-crteži mogu pružiti vrijedne informacije o umjetnicima kao i o njihovoj slikarskoj tehnici te o nastajanju pojedinih slika. Također, blizu - infracrvena spektroskopija može se koristiti za razlučivanje originalnih crteža starih majstora crteža te za procjenu štete nastale oštećenjem.



Slika 2. Prikaz spektra

<http://www.healinggrapevine.com/health-solutions/far-infrared/far-infrared-therapy.html>

Budući da molekule u materijalima imaju svoju karakterističnu frekvenciju vibracije mogu se utvrditi pomoću njima karakterističnoj apsorpciji ili refleksiji spektara na specifičnim valnim duljinama. Attas navodi da se medium-infracrveno područje ( 2500 - 25000 nm ) najčešće koristi za identifikaciju materijala zbog u tom rasponu njima vrlo karakterističnog spektara. No, identifikacija u tom rasponu obično se temelji na analizi malog uzorka koji mora biti uzet odnosno izvađen iz samih slika [6]. Iz tog je razloga atraktivnija metoda za identifikaciju materijala u blizini infracrvenog područja (650-2500 nm) gdje se identifikacija može vršiti analizom bez fizičke destrukcije. Walmsley govori kako su bojila izrazila vrlo visoku transparentnost pri 2000 nm, što je potaknulo primjenu infracrvene spektroskopije pri otkrivanju pod-crteža.

### **2.3.1. metode određivanja pigmenata**

Sve se ove metode određivanja pigmenata mogu podijeliti u dvije osnovne skupine: područna spektroskopija i cjelovita spektroskopija. Područna spektroskopija mjeri tek jedno određeno mjesto na površini slike koje treba biti pažljivo definirano. Cjelovita spektroskopija nadilazi ove poteškoće mjerenjem potpuno cijele površine slike u isto vrijeme [7]. Uglavnom je korisno kombinirati ta dva pristupa zajedno pri pregledu slike. S razvojem infracrvene kamere i vrlo osjetljivih senzora CCD kamera, blizu-infracrvena spektroskopija postala je gotovo standard za identifikaciju pigmenata u slikama. Budući da ove kamere obično imaju vrlo širok spektralni odgovor potrebno je koristiti filtere za povećanje spektralne točnosti dobivene informacije. Spektralna dimenzija često je dovoljna pri diskriminaciji različitih pigmenata dobivenih u bliskom-infracrvenom području spektra. U računalnom procesuiranju fotografija dobivenih kamerom razlikuje se nekoliko metoda koje se mogu primjeniti :

### **2.3.1.1. Metoda razlikovne slike**

Razlikovna slika jednostavno se izračunava oduzimanjem slikovnih podataka s jedne valne duljine od onih na drugoj valnoj duljini, dok se omjer slike izračunava prema omjeru jedne valne duljine slike prema dvije razlikovne valne duljine. Time je moguće istaknuti promjene u refleksije pigmenta iz jedne valne duljine na drugu. Ove jednostavne manipulacije mogu se koristiti za izoliranje specifičnih pigmenata i otkriti njihovu prostornu raspodjele u slikarstvu [8][9][10].

### **2.3.1.2. Simulacijska kompozitna slika u boji**

Kombiniranjem više od jedne valne duljine moguće je dobiti i više informacija o slici. Ovom jednostavnom metodom stvore se snimci koji simuliraju tri snimka pri različitim valnim duljinama za svaki od crvenog, zeleno i plavog kanala. Na taj je način moguće pregledati više mogućnosti istovremeno i tako otkriti međusobne odnose između različitih valnih duljina. Pretvaranjem dobivenog inteziteta u sive tonove koji su zapravo varijacija na originalno snimane boje postaje lakše vidjeti razliku golim okom jer je ljudski vizualni sustav vrlo osjetljiv u sivom području. Pri ovoj metodi važna je kontrola kojim se određuju valne duljine koje će biti korištene za definiranje crvenog, zelenog i plavog dijela konačno procesuiranog snimka. Tako se na primjer određene valne duljine mogu izabrati izabrati kako bi se povećala razlika u informaciji refleksije između različitih pigmenata. Ovom je metodom kompozitne slike mnogo lakše prepoznati određene pigmente i pokazati prostorni odnos pigmenata nego odrediti to isto iz samo jedne valne duljine posebno[11][12][13].

### **2.3.1.3. Analiza glavnih komponenata**

Hiperspektralna slika, odnosno dobiveni složeni spektralni snimak je zapravo kocka koja se sastoji od dvije prostorne dimenzije i jedne spektralne dimenzije. Analiza glavnih komponenata koristiti se kako bi reducirala dimenzionalnost velikog broja dobivenih spektralnih informacija i stvorila novi skup informacija koje su tako izrađene od glavnih komponenata. Budući da prvi svojstveni vektor najbolje opisuje varijaciju



unutar same snimljene umjetničke slike, dok vektori nakon njega dodatno opisuju snimak, već se sa tri osnovne komponente odnosno vektora može stvoriti lažni snimak. Postupak je sličan onome za kombiniranje slike pomoću mapiranja valnih duljina u tri osnovna kanala kako bi nastala simulacijska kompozitna slika od samo tri kanala. Različite boje koje se dobiju iz konačno računalno procesuiranog snimka mogu tako odgovarati različitim materijalima odnosno pigmentima i bojama u originalnoj umjetničkoj slici[14][15][16].

#### **2.3.1.4. Faktorska analiza**

U većini slučajeva, analiza čimbenika daje iste rezultate kao i analiza glavnih komponenta. Međutim, analiza glavnih komponenta poželjnija je kao metoda za sažimanje podataka dok je faktorska analiza preferirana kada je cilj definirati strukturu. Faktorska analiza pretpostavlja da je slučajna varijabla linearno ovisna o nekoliko slučajnih varijabli odnosno zajedničkim čimbenicima. Spektralnim snimcima koje možemo pojmiti u obliku kocke faktorskom se analizom može doći do manjeg broja faktora bez značajnog gubitka podataka. Za jasnije informacije prostor spektralne kocke moguće je rotirati te tako potencijano doći i do skrivenih informacija koje su sadržane u toj istoj kocki[17][18].

#### **2.4. Spektralna refleksija**

Najpraktičniji i najčešći pristup svakako je identificirati pigmente pomoću spektralne refleksije. Pri restauraciji umjetničke slike moguća je pojava metamerije koja će se pojaviti ukoliko je restaurirano područje obnavljano uzimanjem u obzir isključivo vizualno podudaranje boja s okolnim neoštećenim područjima. Ipak, metamerija se može izbjeći odabirom suvremenih nadomjestaka koji imaju što sličniju refleksiju spektara u usporedbi s ciljanim pigmentima. Kako bi se postiglo potpuno oponašanje originalnih pigmenta restaurirani dio treba imati gotovo identična optička svojstva (spektar, boju i transparentnost) kao i geometrijska svojstva (sjaj, tekstura i premaz boje). Kako bi se osiguralo savršeno spektralno preklapanje, restaurator bi trebao

koristiti iste pigmente kao i autor danog umjetničkog djela. Međutim, to nije uvijek moguće. Na primjer, u nekim slučajevima, pigmenti više nisu dostupni ili imaju loše svojstva, na primjer vrlo su osjetljivi na svjetlo ili čak i otrovni. Budući se broj i raznolikost pigmenata komercijalno dostupnih umjetnicima značajno povećava, postaje sve teže pronaći prave pigmente za retuširanje i restauraciju. Uz to, resturatori često imaju tendenciju koristiti ograničenu paletu boja iako postoje stotine boja na širem tržištu. Umjesto idealne identifikacije pigmenata, izbor će biti definiran lakše dostupnim bojama iako bi odabrani nadomjesci trebali imati gotovo istu refleksiju spektrala pigmenta koji čine sliku. Krivulja spektralne refleksije individualno karakterizira različite pigmente[19][20][21]. Daljna analiza karaktera spektralnih krivulje može pružiti više informacija o pigmentu. Međutim, vrlo je važna i debljina nanosa jer s povećanom transparentijom uzorka dolazi i do promjene u spektralnoj informaciji. Dakle, prilikom identifikacije pigmenta logaritam apsorpcije trebao bi biti uzet u obzir. Dva su, ranije spomenuta, glavna pristupa mjerenju refleksije umjetničke slike. Područna spektroskopija i cjelovita spektroskopija. Iako se od područne spektroskopije očekuje da će imati veću točnost nego cjelovita spektroskopija treba uzeti u obzir da je broj točaka izmjeren na taj način ovisan o otvoru spektrofotometra koji je vrlo često fiksiran. To znači da mjerena mjesta moraju biti izabrana i obilježena pažljivo. S druge strane, cijelovita spektroskopija izbjegava ovaj problem mjerenjem cijele površine. Sa značajnim razvojem cijelovite spektroskopije posljednjih godina, spektralna točnost ove metode je poboljšana u velikoj mjeri. S razvojem optičke tehnologije, omogućena je izgradnja sustava za *in situ* ispitivanja slike s pristupačnim optičkim kabelima. Optička vlakna tako su u službi dobivanja refleksije spektroskopijom te se kombinacijom s analitičkim metodama mogu prilagoditi procesu identifikacije određenih materijala.


## **2.5. Slikarske tehnike**

Gotovo svaka slikarska tehnika ima karakteristična svojstva ili se tek manjim dijelom preklapa sa karakteristikama druge slikarske tehnike. Iako će o tome više biti riječi u slijedećim poglavljima, za potrebe ovog istraživanja korišteni su radovi nastali dvjema slikarskim tehnikama: temperom i gvašom. Iz tog razloga slijedi pregled ovih dviju slikarskih tehnika.

### 2.5.1. Tempera

Slikarska tehnika u kojoj boja nastaje miješanjem pigmenta s otopinom ljepila i vezivnog sredstva (jajeta, gumiarabike i sl.) naziva se tempera. Porijeklo naziva tempera dolazi od latinske riječi za miješanje - *temperare*. Tempera je gusta, neprozirna, pokrivna boja, zbog čega je moguće preslikati dijelove već nastale umjetničke slike. U srednjem vijeku tempera je bio naziv kojim su se označavala složena vodena veziva pomoću kojih se pripremala boja. Već u 14. stoljeću spominju se različite vrste tempera, kao što su: jajčana, žumanjkova, gumitempera, tutkalna tempera i voštana tempera, koje služe za vezivanje boje. Danas se pod nazivom tempera podrazumijeva višedijelno vezivo koje je sastavljeno od hidrofilnog i hidrofobnog veziva. To je stabilna smjese dviju tekućina koje se ne miješaju već su u obliku sitnih čestica raspršene jedna u drugoj. Djelovanjem emulgatora ostaju trajno povezane jedna s drugom kao gusta mliječna stabilna smjesa odnosno emulzija. Riječ emulzija dolazi od latinske riječi *emulgere*, što znači izmusti, a odnosi se na mlijeko koje je prirodna emulzija. Najjednostavnija emulzija je mješavina vode i ulja. Ulje se rasprši u vodi u obliku sitnih kapljica. Time dolazi do povećanja ukupne površine kojom se tekućine dodiruju. Od bistrih tekućina nastaje mliječna, neprozirna tekuća smjesa. Ova emulzija nije stabilna i ulje se lakše odjeljuje od vode. Da bi emulzija bila stabilna, potrebno je dodati sredstvo koje sprječava udruživanje raspršenih čestica i odvajanje tekućina. Sredstva koja čine emulziju stabilnom su emulgatori. Otopljeni su u vodenoj ili uljenoj komponenti smjese te okružuju tankim molekularnim slojem sve sitno raspršene čestice druge komponente i ne daju im da se međusobno udalje. Kao emulgatori koriste se sapuni čije molekule imaju polarni hidrofilni dio koji privlači vodu i ugljikovodični nepolarni dio koji je hidrofoban pa se okreće prema ulju. Nadalje, pigmenti djeluju na stabilnost tempere jer zgušnjavanjem emulzije otežavaju razdvajanje. Stabilizatori su dodaci koji emulziju održavaju u upotrbljivom stanju za vrijeme mirovanja. Njihove čestice lako bubre pri suspendiranju u vodi pa se zgušnjava vanjska faza, povećava njena viskoznost zbog čega se čestice ulja mogu otežano slijevati. Konzervansi su sredstva koja štite od mikroorganizama. Konačno, pri miješanju na paleti temperu razrjeđujemo vodom do određene gustoće, vizualno sličnoj gustoći tekuće želatine. Boju tempere moguće je posvijetliti miješanjem s bijelom bojom i tako dobiti tonove, bilo stepenasto, bilo u postepenoj modelaciji. Moguće je dobiti posve jednolične namaze ili ekspresivne i

dinamične. Sloj boje ne bi smio biti predebeo jer tada dolazi do ljuštenja i pucanja tempere. Podloga za slikanje temperom može biti hrapavi papir, drvo ili platno. Kist za temperu je čvršći od kistova za boje akvarela, ali i malo mekši od kistova za uljane boje.



Slika 3. Rođenje Venere, Sandro Botticelli, 1486.

<http://www.google.com/culturalinstitute/asset-viewer/the-birth-of-venus/MQEeq50LABEBVg?projectId=art-project&source=kp&hl=en>

### 2.5.2. Gvaš

U likovnoj umjetnosti gvaš je slikarska tehnika koja se opisuje kao vrsta boje sastavljena od pigmenta u kombinaciji sa gumiarabikom. Iako slično vrijedi i za akvarel slikarstvo, gvaš sadrži kedu te je zato neproziran i reflektirajući. Riječ gvaš se kao termin počeo koristiti u Francuskoj u 18. stoljeću iako se ova slikarska tehnika upotrebljavala u Europi već od 16. stoljeća. Francuski *gouache* znači gust, ili talijanskog *guazzo* označava vodenu mrlju. Dodavanjem bijele boje postiže se bogatstvo tonova. Boja u gvašu je zasićenija nego u akvarelu. Bijeli dijelovi slike slikaju se bijelom bojom kao u temperi ili ulju. Gvaš je neproziran i gust te pokriva podlogu. Ove boje sadrže bijele pigmente ili punila koji pigmentima daju veću pokrivenost i mat karakter zbog površinske refleksije svjetla. Na tržištu se mogu naći u čvrstom stanju -

pastilama, u tubama ili gvaš boje u prahu. One sadrže pigment i vezivo u prahu, a pripremaju se mješanjem s vodom. Kao vezivo koristi se pergamentno tutkalo, dekstrin ili gumiarabika. Najčešće se koriste veziva celuloznih etera koja se sušenjem znatnije ne stežu. Prevelika koncentracija veziva može izazvati pucanje, posebno kod debljih slojeva. Dodatkom glicerina povećava se elastičnost nanosene boje. Priprema se tako da se napravi tutkalna otopina te doda kreda kao punilo i odgovarajući pigment. Tako nastaje gušća boja koja više nema prozirnost akvarela. Pod utjecajem bijelog pigmenta boje postaju još svjetlijima. Umjetnici također koriste i aditive, poput meda ili škroba, kako bi usporili sušenje boje. Boja će se razrijediti s vodom, ili tekućim ljepilom kako bi se zadržao tonalitet, prije nego što se primjeni na bijeli ili tonirani papir, karton ili svilu. U svojoj osnovi, gvaš je nepropustan akvarel. Gvaš boje mogu se nanositi na različite načine: vlažan nanos s puno vode, pastozan nanos boje, nanošenje polusuhog karaktera, nanošenje boje u slojevima, stvaranje boje direktnim ispiranjem s vodom, nanošenje različitim četkicama ili spužvicama, struganje osušene boje. Gvaš ovisno o toniranoj podlozi omogućuje prijelaz iz svijetlog tona u svjetliji ili tamniji. U novije vrijeme upotrebom lakova gvašu se daje karakter ulja. Za zaštitu gvaš boja koriste se gotovi fiksativi koji ne mijenjaju u većoj mjeri površinski karakter gvaš boje. Najčešća površina za gvaš je papir, isto kao i za akvarel. Gvaš ima dugu povijest korištenja od strane umjetnika zbog svoje fleksibilnosti i obnovljivosti zbog čega postao osobito popularan za ilustraciju likovne umjetnosti u modernim vremenima. Picasso, Matisse i Klee neki su od umjetnika koji su stvarali gvaš tehnikom.



Slika 4. Statično – Dinamična Gradacija, Paul Klee, 1923.


<http://www.haoss.org/t7597-paul-kle-paul-klee>

Bijelina papira u gvašu za razliku od akvarela nema značajnu ulogu. Boje u gvašu se brzo suše, a sušenjem posvijetle. Kao podloga najčešće se koristi tonirani papir veće gramature i kartoni. Podloga je finijeg zrna nego kod akvarela. Jednom kada se osuši još uvijek ostaje topiv u vodi čime je omogućeno naknadno miješanje. Iz tog razloga slike trebaju biti zaštićene staklom kako vlaga iz zraka ne bi djelovala destruktivno na gvaš. Svijetle gvaš boje mogu se nanijeti preko one tamne čime gvaš ima više karakteristiku tempere nego akvarela.[22] Iako je gvaš pokrivna tehnika, ton podloge utječe na karakter gvaša. Pored papira može se kao podloga koristiti i platno ili drvo. Kistovi za gvaš malo su tvrdi od akvarelnih kistova.

## 2.6. Hiperspektralni zapis slike

Spektralni zapis slike u svojoj detaljnijoj verziji naziva se hiperspektralni zapis slike. Razlog tome je što hiperspektralni zapis digitalne slike pruža daleko više spektralnih podataka, točnije za svaki piksel, nego što je to omogućeno tradicionalnom kamerom (fotoaparatom). Neobrađeni dobiveni podaci često se vizualiziraju kao spektralna kocka

izlaznih informacija. Ona može biti sastavljena od desetaka do stotina slika od kojih svaka predstavlja svoju specifičnu boju pomoću njoj pripadajućeg spektralnog opsega. Ekvivalentno tome, detaljana spektralna krivulja dana je za svaki piksel nastale digitalne fotografije. Primjer hiperspektralne kocke prikazan je na slici 5.



Slika 5. Prikaz hiperspektralne kocke

Iz nje se vidi kako je definirana s dvije prostorne dimenzije ( $x$  i  $y$ ) te jednom dimenzijom koja je određena valnom duljinom ( $\lambda$ ). Podaci iz ove spektralne kocke mogu se promatrati kao mnoštvo slika, gdje svaka od njih odgovara drugoj boji ili opsegu spektra. U pokazanom primjeru tri su područja označena za korištenje odnosno generiranje simulirajućih boja na slici. Prednost toga je slijedeća: za razliku od ljudskog mozga gdje je senzibilitet boje zapravo stvara podražajem triju osnovnih kanala, računalni vid direktno koristiti neovisne kanale boja. Uz ove dodatne spektralne informacije, računalni hiperspektralni sustavi često pokazuju znatno poboljšanu boju u odnosu na konvencionalne slike u boji[23][24][25]. Uz to, hiperspektralni zapis u

možnosti je evidentirati spektralne informacije poput infracrvenog spektra. To omogućuje sustavu za mehanički vid iskorištavanje refleksija i izračunavanja razlika koje ljudi ne mogu doživjeti svojim vizualnim sustavom.

### **2.6.1. Korištenje hiperspektralne informacije**

Hiperspektralni zapis svakako je uvijek poželjan pri mjerenju željenih spektralnih informacija. No, zbog opsega informacija koje daje postoje situacije kada se mjerenje može izvršiti i klasičnim spektralim mjerenjem. Hiperspektralni slikovni zapis svoje karakteristike ispunjava u potpunosti primjerice kada je potrebna[26][27]:


#### **1. Precizna spektralna informacija o boji**

To se odnosi na slučajeve kad je potrebno razlikovati vrlo slično obojene objekte, kada je potrebna apsolutna mjera boje u određenom prostoru boje ili kada je klasično mjerenje otežano preklapanjem fluorescentnih informacija.

#### **2. Šira ili potpuna slika snimane scene**


U ovom slučaju predmet interesa nije jedna boja koja je ravnomjerno raspodjeljena već područje interesa sadrži više objekata scene u kojoj se klasičnim spektralnim mjerenjem jedinstveni motivi preklapaju ili oni sami pokrivaju područje interesa. Slika 6 objašnjava ova dva navedana razloga na primjeru.





Slika 6. Primjer korištenja hiperspektralnog snimka

Hiperspektralni zapis dobiven je snimkom pripreme hrane. Ono što je bitno je primjetiti kako se razlikuju područja gdje nedostaju krušne mrvice, područja koja su tamnija ili svijetlija, ovisno o stupnju pečenja te područja koja su obilježena dodiranjem dvaju susjednih komada mesa što je vizualno rezultiralo duguljastim prstenom. Ova tri navedena područja mogu se kasnije koristiti za stvaranje stvarne slike tako da se koriste tri dijela spektra koja najviše odgovaraju željenim karakteristikama slike koje može percipirati ljudsko oko odnosno mozak. Za razliku od stvarne i simulacijske slike korištenjem detaljnijih spektralnih informacija hiperspektralnim zapisom lakše i točnije se generira klasifikacijski prikaz prikazan na istom primjeru na slici 7.



	<b>Svijetlo žuta</b>
	<b>Tamno žuta</b>
	<b>Bez mrvica</b>
	<b>Preklapanje</b>

Slika 7. Klasifikacija nastala grupiranjem spektralnih dijelova


Tu je moguće vidjeti primarne regije mjenog objekta koje su nastale određivanjem i definiranjem diskriminantnih spektralnih krivulja. Pikseli koji se nisu klasificirali kao bilo koji od tih područja su crne boje. Hiperspektralni slikovni zapis nastoji se još više približiti mogućnostima ljudskog vizualnog sustava. Iz tog razloga tako nastali zapisi mogu se primijeniti na širi spektar aplikacija, uključujući kontrolu kvalitete (daske, tekstil, papir, građevinski materijal, lijekovi), kontrola procesa (tanki filmovi, vlaga sadržaja, boja), sortiranje produkata (hrane, otpadaka, minerala), daljinsko očitavanje (boje mora, praćenja stanja okoliša, poljoprivreda). S razvojem kompaktnih i pristupačnih hiperspektralnih sustava ova se tehnologija može primijeniti na vrlo različitim područjima, od mikroskopa do svemirskih sustava.

### 3. EKSPERIMENTALNI DIO

Eksperimentalni dio rada izveden je u cilju dobivanja podataka klasičnim mjerenjem spektrofotometrom i korištenjem spektralne kamere u cilju dobivanja hiperspektralnih podataka. Hiperspektralne informacije dobivene su LCTF kamerom (slika 10.), a spektralne korištenjem GretagMacbeth Eye-One XT spektrofotometra (slika 13.). Dobivene informacije potom su korištene u računalnom programu Matlab. Pomoću Matlaba moguće je usporediti ova dva izvora informacija za dva mjerena objekta (različite slikarske tehnike). Ovako dobivene vrijednosti prikazane su u slijedećem poglavlju.

#### 3.1. LCTF Nuance kamera

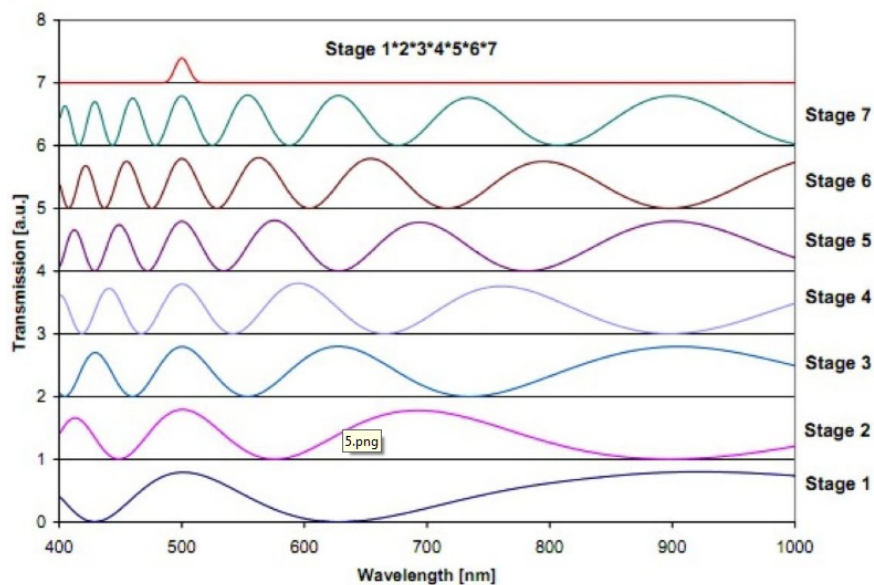
LCTF (Liquid crystal tunable filters) su optički filteri koji elektronski upravljaju elementima tekućih kristala kako bi propuštali svjetlopomoću točnom odabranih valnih duljina dok istovremeno blokiraju ostale valne duljine. Najčešće se rad ovih filtera temelji na Lyot filteru no postoji i drugi načini. Njihova je glavna karakteristika što nemaju fiksiranu „branu“ koja će propustiti svjetlost kroz točno definiran spektar već se on zbog tekućih svojstava kristala može stalno modificirati tako da spektralna krivulja danog filtera vizualno djeluje glatko, bez oštih prijelaza.



Slika 8. Usporedba propusnosti filtera spektralna i klasične RGB kamere

Spectral devices laboratory report, Jia Song, CIMET 2011.

LCTF daje vrlo visoku kvalitetu zapisa i ne stvara probleme u integraciji optičkog sustava sa računalnim sustavom kontrole. Ipak, LCTF ima vrlo niske maksimalne vrijednosti transmisije zbog korištenja više polarizatora istovremeno. Ovaj problem može se ublažiti pomoću širokopoljnih filtera budući da oni omogućavaju propuštanje veće količine svjetla. Neki od LCTF-ova kreirani su za reguliranje određenog broja valnih duljina poput crvene, zelene i plave (klasični RGB). Ostali mogu regulirati i manje razlike unutar ili van vidljivog spektra, trenutno mogućnosti sežu od 400nm do 2450 nm. Brzina kojom LCTF može regulirati valne duljine ovisi o samom dizajnu i proizvođaču no u prosjeku iznosi oko desetak milisekundi. Povećanjem temperature dolazi do smanjenja tog vremena dok suprotnim postupkom, pri smanjenju temperature dolazi do povećane viskoznosti tekućeg kristala te se time povećava i vrijeme potrebno za regulaciju samog filtera. LCTF se koristi u hiperspektralnom snimanju odnosno zapisu slika zbog visoke kvalitete tog zapisa i brzog podrešavanja unutar definiranog spektralnog razmaka. Više LCTF uređaja zajedno koristi se u kreiranju optičkih sustava kada željena valna duljina prelazi mogućnost jednog filtera što je vrlo često u aplikacijama primjenjivima u astronomiji.



Slika 9. Prikaz različitih faza LCTF-a


Spectral devices laboratory report, Jia Song, CIMET 2011.

LCTF pri određivanju željene spektralne duljine prolazi više faza. Broj tih faza ovisi o željenom rasponu koji najčešće kreće od 400nm što je realna mogućnost današnjih LCTF uređaja. Na slici 9 prikazane su faze u kojima postepeno dolazi do promjene u tekućim kristalima te se tako omogućuje postepena promjena pri zamjeni valne duljine. Zbog ove postepenosti LCTF će dati detaljnije informacije nego što to daju oštri prijelazi standardnih kamera što je prikazano na slici gore.



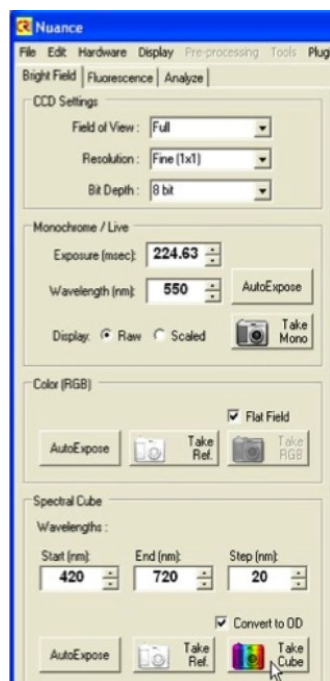
Slika 10. LCTF Nuance kamera pri korištenju

Na slici 11 vidimo shematski prikaz dobivanja i izračunavanja hiperspektralnih informacija. Na početku je potrebno mjeriti objekt postaviti odnosno fiksirati na određeni položaj. Za ilustraciju uzet je Color Checker sa 24 polja koji je snimljen sa LCTF kamerom. U ovom primjeru to je napravljeno u rasponu 450nm do 700nm u razmacima od 50nm. Korištenjem pripadajućeg softvera kontroliralo se vrijeme ekspozicije i fokus pri korištenju različitih valnih duljina. Udaljenost objekta od kamere također je prilagođena kako bi kasnije bilo lakše računalno odrediti centar pojedinih polja boja. Monokromatska kamera također koristi termalni kuler kako bi smanjila onečišćenje hiperspektralnog snimka nastalo zagrijavanjem. Opisani primjer kao i korišten pripadajući softver prikazani su na slici 11 i slici 12.



Slika 11. Klasična testna karta sa 24 snimljena polja hiperspektralnom kamerom

Spectral devices laboratory report, Jia Song, CIMET 2011.



Slika 12. Pripadajući softver pri korištenju LCTF kamere

Spectral devices laboratory report, Jia Song, CIMET 2011.

### 3.2. Spektrofotometar

Pri spektralnom mjerenju testnih karata odnosno umjetničkih slika korišten je Spektrofotometar GretagMacbeth Eye-One XT i njemu pripadajući softver. Raspon spektra i njegovog mjerenja seže od 360nm do 740nm. Geometrija korištena je 45/0 što znači da je uzorak osvjetljen ne okomito već po kutem od 45 stupnjeva dok je senzor smješten okomito. Pomoću ovih informacija za Standardnog Promatrača od 10 stupnjeva kao i D50 osvjetljenja kreirala se kolirimetrijska vrijednost. Instrument je pogodan za lako rukovanje te je prikazan na slici 13.



Slika 13. Spektrofotometar GretagMacbeth Eye-One XT

[http://www.tfccentral.co.uk/reviews/i1\\_pro.htm](http://www.tfccentral.co.uk/reviews/i1_pro.htm)

### 3.3. Korišteni materijali

Za potrebe našeg istraživanja bilo je vrlo korisno imati objekt čije su nam specifikacije i mjerenja znane u određenom vremenskom periodu. U konkretnom slučaju imali smo na raspolaganju mjerenja napravljena prije 7 godina. Takve objekte sa karakteristikama umjetničke slike preuzeli smo iz doktorske dizertacije dr.Stgar Kurečić. Riječ je o pomno ručno izrađenim testnim kartama boja što im daje karakteristiku umjetničke slike bez obzira na organiziranost prostora na podlozi. U eksperimentalnom dijelu cilj je bio usporediti dobivene rezultate za dvije slične, ali opet različike slikarske tehnike: gvaš i temperu. Pri izradi testne karte gvaša korištena je profesionalna linija Linel 35GT u kojoj postoji 40 boja. Najvažniji sastojak slikarske boje je pigment koji određuje boju.

Stoga je osnovna pažnja pri odabiru boja bila usmjerena na identificiranje pigmenta. Postoje tri osnovna tipa slikarskih boja: boje sa jednim pigmentom, boje sa mješavinom dva ili više pigmenata i boje sa mješavinom pigmenata. Pri izboru podloge, za tehniku gvaša najčešće se koriste vruće prešani papiri ili kartoni. Takva površinska obrada papira omogućuje dobivanje površine koja je vrlo glatka i manje upojna od površine papira dobivene hladnim prešanjem. Kvalitetniji gvaš papiri proizvode se lijevanjem u kalupe, čime se dobivaju papiri stabilnije strukture tj. podjednakih mehaničkih svojstava u svim smjerovima[28]. Kao podloga za izradu testne karte, odabran je vruće prešani karton za gvaš, Fabriano Artistico, gramature 600 g/m<sup>2</sup>, napravljen od 100 % pamuka. Pigmenti korišteni pri kreaciji testnih karata navedeni su u Tabelici 1.

**Tablica 1.** Pigmenti korišteni pri kreiranju testnih karti [28]

Trgovački broj boje	Trgovački naziv boje na engleskom	Naziv indeksa boje	Broj indeksa boje	Kemijski opis
222	Persian yellow lemon	<b>PY3</b>	11710	Monoazo (Arylide)
153	Primary Yellow *	<b>PY3-PY1</b>		
224	Persian yellow medium	<b>PY1</b>		Monoazo (Arylide)
415	Persian red light	<b>PR4</b>	12085	Monoazo (Naphthol)
327	Carmine (imit.)	<b>PR3</b>		Beta naphthol
354	Tyrian rose	<b>PR173</b>	45170:3	Rhodamine (Triarylcarbonium)
634	Persian violet deep	<b>PV2</b>		
055	Ultramarine deep	<b>PB29</b>	77007	Polysulfide of Sodium-Alumino-Silicate
046	Prussian blue	<b>PB27</b>	77510	Ferriammonium ferrocyanide
088	Cyan *	<b>PW6-PB15:3</b>		
564	Viridian (imit.)	<b>PG7</b>	74260	Phthalocyanine (Chlorinated copper phthalocyanine)
549	Veronese green (imit.)	<b>PG7</b>	74260	Phthalocyanine (Chlorinated copper phthalocyanine)
541	Olive green	<b>PG8</b>	10006	Nitroso iron complex
302	Yellow ochre	<b>PY42</b>	77492	Hydrated synthetic iron oxide
306	Red ochre	<b>PR102*</b>		Synthetic iron oxides
481	Burnt sienna	<b>PBr7*</b>	77491	Calcined natural iron oxide
111	Vandyke brown	<b>PR102**</b>		Synthetic iron oxides
478	Raw umber	<b>PBr7**</b>	77491	Calcined natural iron oxide containing manganese
007	Permanent white	<b>PW6</b>	77891	Titanium dioxide
269	Ivory black	<b>PBk9</b>	77267	Carbonized bones (amorphous carbon)



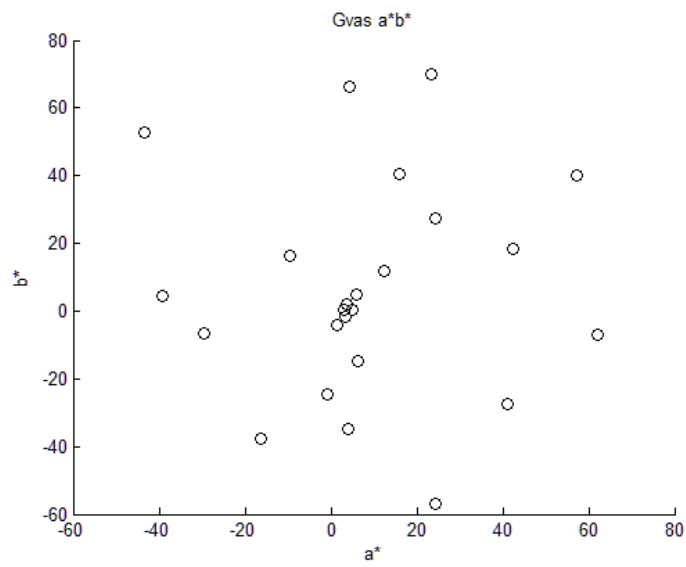
	<b>A</b>	<b>B</b>	<b>C</b>	<b>D</b>	<b>E</b>	<b>F</b>
<b>1</b>	PR3	PR4	PY1	PY3	PY3 PG7**	PG7*
<b>2</b>	PB29 PW6	PB29	PB27 PW6	PB27	C (Cyan)	PG7 PW6
<b>3</b>	PV2 PW6	PR173	PY42	PR102*	PR102** PW6	PG8 PW6
<b>4</b>	PW6	PW6 PBk9	PW6 PBk9	PW6 PBk9	PW6 PBk9	PBk9

Slika 14. Testna karta sa prikazanom kombinacijom korištenih pigmenata


Testna karta sadži 24 uzorka boja. Sastoji se od 18 kromatskih i 6 akromatskih polja koja čine sivi klin. Kromatska polja su napravljena korištenjem 18 odabranih jednopigmentnih boja navedenih u slici 14. Osnovni uvjet koji se nastojao zadovoljiti pri kreiranju karte bio je da se postignu polja maksimalne kromatičnosti radi postizanja što većeg opsega boja (gamuta) [28]. Radi toga su neke jednopigmentne boje kombinirane sa određenom malom količinom bijelog pigmenta. U zadnjem redu napravljena je i siva skala korištenjem bijelog i crnog pigmenta u određenim omjerima. Konačni produkt odnosno testna karta gvaš bojama prikazana je na slici 15. Izmjerene  $L^*a^*b^*$  vrijednosti tesne karte gvaš dani su slikama 16 i 17.



Slika 15. Izrađena testna karta pomoću gvaš boja





Slika 16. CIELAB prikaz a\* i b\* vrijednosti boja gvaš testne karte



Slika 17. CIELAB prikaz  $L^*$  i  $a^*$  vrijednosti boja gvaš testne karte



Slika 18. Testna karta izrađena pomoću tempera



Slika 19. CIELAB prikaz L\* i a\* te a\* i b\* vrijednosti boja tempera testne karte

### 3.4. Svojtveni vektori

Digitalni zapis objekta kroz ovo istraživanje dobiva tim više na značenju zbog mogućnosti upotrebe hiperspektralnih informacija. Te su informacije digitalno zapisane binarnim sustavom, a u konačnici kreiraju vektore. Premda svaka od fotografija snimljena hiperspektralnim kamerama sadrži određeni broj podataka, odnosno vektora, količina ti vektora često premašuje potrebnu informaciju za osnovnu rekonstrukciju te iste fotografije. Razlog tome su svojstveni vektori (eigenvektori). Svojtveni vektori su velika pomoć u redukciji dobivenih informacija. Pomoću njih možemo rekonstruirati početno snimljeno stanje bez da koristimo 100% dobivenih informacija. U hiperspektralnom svijetu zapisa danog objekta veliki je postotak suvišnih informacija. To možemo pokazati pomoću slijedećeg primjera. Hiperspektralna fotografija izrezana je na veličinu 80 x 80 piksela. Broj primarnih komponenata je šest, a spektar snimanja je definiran u rasponu od 400nm do 700nm. Projekcija slike na svojstvene vektore prikazana je na slici 6.



Slika 20. Primjer korištenja svojstvenih vektora prikazan digitalnim zapisom

Iz priloženih rezultata nastalih računalnim procesuiranjem dobivenog zapisa može se primjetiti kako sa povećanjem broja svojstvenih vektora dobivamo informacije koje opisuju zapis, no bez kojih je još uvijek moguće rekonstruirati samu sliku. Pri usporedbi slike 21 sa slikom 20 može se zaključiti isto. Slika nastala pomoću 3 svojstvena vektora dati će manje informacija nego ona nastala pomoću 6 svojstvenih vektora. Ipak u cilju smanjenja količine podataka sa željom za bržom obradom podataka svakako je prepoznata činjenica da prvi svojstveni vektor daje približno 65% ukupne informacije originalnog snimka.

Eigenvektor 1 = 64.9213 %

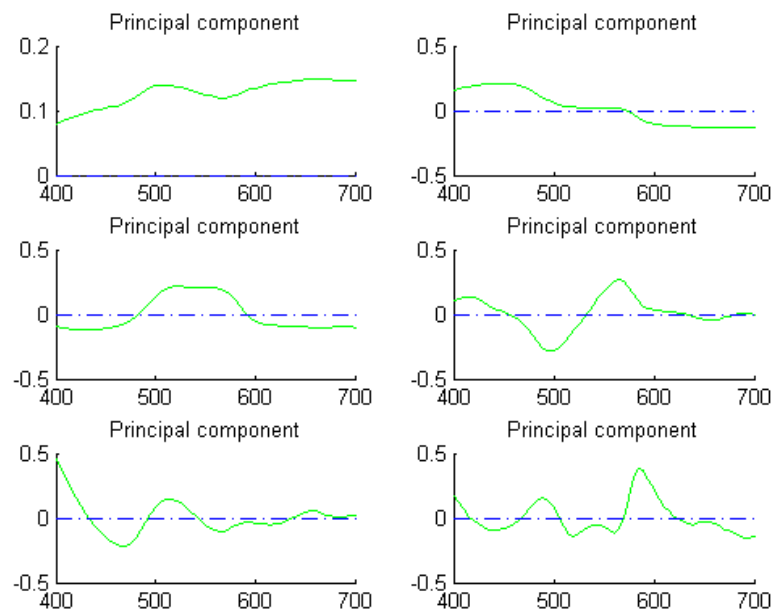
Eigenvektor 2 = 32.6992 %

Eigenvektor 3 = 1.0422 %

Eigenvektor 4 = 0.41321 %

Eigenvektor 5 = 0.2555 %

Eigenvektori 1 do 5 = 99.3313 % sveukupne informacije o slici



Dijagram 1. Primjer korištenja svojstvenih vektora prikazan krivuljom spektra

### 3.5. Spektralna metrika

#### 3.5.1. RMSE (Root mean square error)


RMSE dva vektora  $X_1$  i  $X_2$  dana je slijedećim izrazom:

$$\sqrt{\frac{\sum_{i=1}^n (x_{1,i} - x_{2,i})^2}{n}}$$

U slučaju kada se dva vektora potpuno preklapaju odnosno imaju iste vrijednosti spektralni RMSE jednak je nuli odnosno nema odstupanja i pogreške. Kada su vrijednosti potpuno drugačije RMSE vrijednost bit će jednaka 1 odnosno izražavat će potpuno, 100% odstupanje.

#### 3.5.2. GFC (Goodness of Fit Coefficient)

GFC se temelji na Shwartzovoj nejednakosti, a osim definiranom jednadžbom vizualno je možemo predočiti kako slijedi:




Ako su dva vektora u Hilbertovom prostoru tada je GFC kosinus kuta između ta dva vektora odnosno spektra. GFC je izražen u rasponu od nula do jedan gdje 1 označava potpuno preklapanje odnosno dva ista vektora dok 0 znači da nema nikakvog preklapanja.

## 4. REZULTATI


### 4.1. Gvaš rezultati

Uspoređena mjerenja testnih karata tempere i gvaša nastala 2006. godine sa spektralnim mjerenjima 2013. godine vidljiva su iz slijedećih slika. Sve usporedbe odnose se na raspon 380nm do 730nm budući je to spektralni raspon koji se nalazi u oba mjerenja. Na slici 22 vide se 24 spektralne krivulje gvaš slikarske tehnike. *Gvaš početni* označava rezultat dobivene mjerenjima 2006. godine dok *Gvaš finalni* označava rezultate mjerenja gvaš testne karte iz 2013. godine.




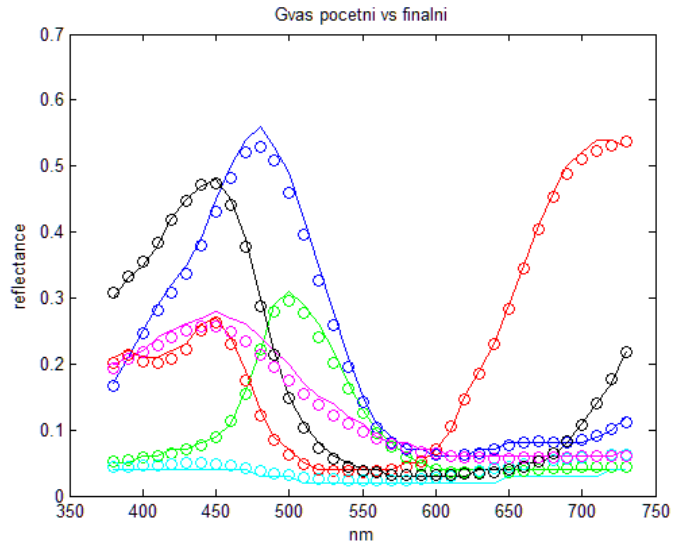
Dijagram 2. Spektralne krivulje početne i finalne gvaš testne karte





Dijagram 3. Usporedba početnih i finalnih prvih 12 spektralnih krivulja gvas testne karte

Slika 23 prikazuje vizualno preklapanje odnosno sličnost i razlike spektralnih mjerenja nastalih u rasponu od 7 godina. Ovo je primjer gdje su prikazani prvih 12 polja boje iz gvaš testne karte. Ovdje su uključena i polja sivog klina što je vidljivo iz jednoličnosti gibanja spektralnih krivulja u gornjem dijelu grafikona. Puna linija označava početne vrijednosti spektra dok kružići označavaju liniju koja je dobivena mjerenjima 2013. godine. Preklapanje je u velikoj mjeri postignuto, no u nekim slučajevima to nije moguće.



Dijagram 4. Usporedba početnih i finalnih drugih 12 spektralnih krivulja gvaš testne karte bez sivog klina

**Tablica 2.** Gvaš - spektralno

Gvaš		
#	RMSE	GFC
1	0,00424	0,99435
2	0,00353	0,99975
3	<b>0,00318</b>	0,99996
4	0,00711	0,99997
5	0,01763	0,99998
6	0,04156	0,99895
7	0,00361	0,99938
8	0,00335	0,99896
9	0,01031	0,99961
10	0,00627	0,99982
11	0,01767	0,99962
12	0,00728	0,99983
13	0,00676	0,9994
14	0,01293	0,99982
15	0,0139	0,97825
16	0,01198	0,99929
17	0,00521	0,99977
18	0,01869	0,99991
19	0,01178	0,99948
20	0,01943	0,99975
21	<b>0,03313</b>	0,99895
22	0,02763	0,99985
23	0,01386	0,99984
24	0,02011	0,99894

24 polja boje gvaš testne karte imaju individualne spektralne krivulje. Dobivenim matematičkim računom pokazalo se da spektralni prikaz viđen u grafovima odgovara trenutnom stanju mjerenog objekta. Ovo se temelji na RMSE i GFC vrijednostima koje su u slučaju pogreške blizu nule, a u slučaju preklapanja vrlo blizu jedinice. Najveće odstupanje može se primjetiti na polju nastalim bijelom bojom tempere, dok je najmanje odstupanje primjećeno u tamnijem dijelu sivog klina.



Slika 21. Numerički označna polja gvaš karte i pripadajućih RMSE vrijednosti pri korištenju spektrofotometra

Na slici 21. prikazani su rezultati dobiveni u tablici 2. na način da polje boje označeno brojem 1 ima najmanje odstupanje odnosno najmanje izraženu RMSE vrijednost. U slučaju polja boje koje je označeno brojem 24 ta je vrijednost najviša od svih ostalih polja na gvaš testnoj karti. Ovo se odnosi na mjerenje spektrofotometrom opisanim u poglavlju 3.2. Zanimljivo je primjetiti kako sivi klin daje ekstremne rezultate. Također, sa povećanjem kromatičnosti polja boje RMSE vrijednost raste.

**Tablica 3.** Gvaš – hiperspektralno – 3 Eigen

#	RMSE	GFC	DE00 (D50, 2°)
1	0,00324	0,99995	2,31
2	0,00313	0,99995	3,21
3	0,00218	0,99996	2,41
4	0,00701	0,99994	3,21
5	0,01663	0,99998	1,21
6	0,04056	0,99995	2,65
7	<b>0,00161</b>	0,99999	1,03
8	0,00135	0,99996	2,54
9	0,00931	0,99961	2,65
10	0,00427	0,99982	3,25
11	0,01617	0,99962	3,24
12	0,00638	0,99963	2,14
13	0,00576	0,99950	2,89
14	0,00993	0,99982	1,98
15	0,01190	0,97825	2,69
16	0,01298	0,99929	2,63
17	0,00421	0,99987	3,24
18	0,01569	0,99991	4,25
19	0,01078	0,99968	3,24
20	0,01843	0,99975	3,67
21	<b>0,03113</b>	0,99838	4,61
22	0,02463	0,99985	3,21
23	0,01186	0,99984	3,63
24	0,01811	0,99974	3,21

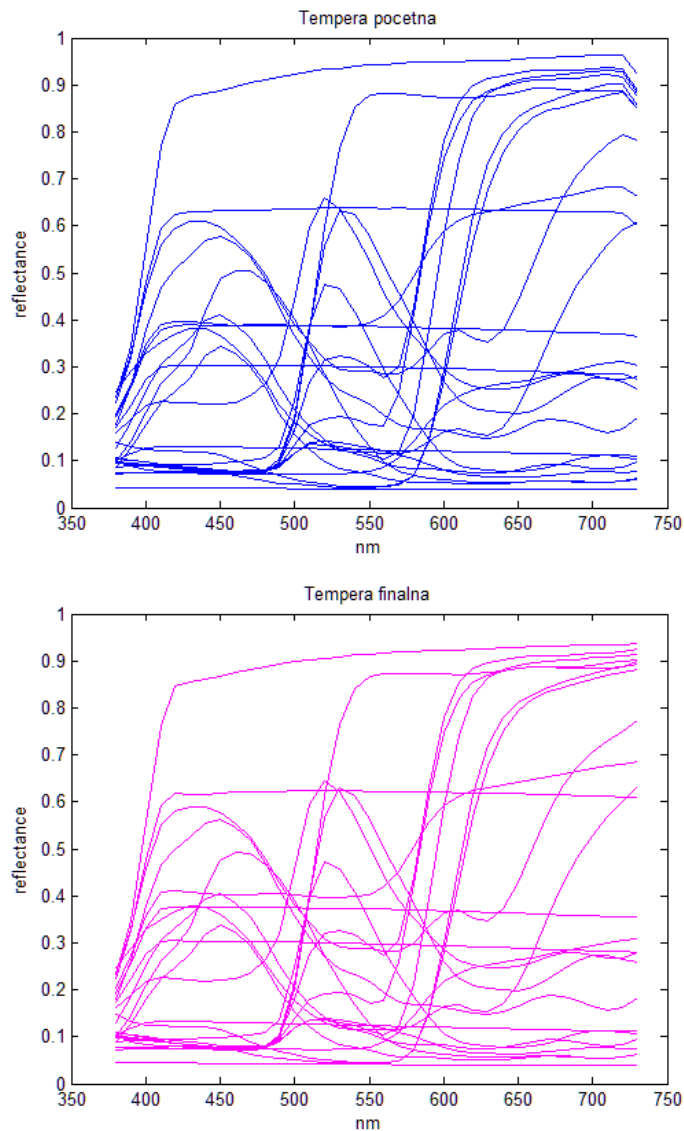
Procjena kolorimetrijskih vrijednosti korištenjem hiperspektralne kamere pokazala se kao dobar izbor. To se vidi iz priloženih rezultata u Tablici 3. U usporedbi sa spektralnim rezultatima RMSE i GFC vrijednosti idu u prilog boljoj rekonstrukciji, odnosno procjeni polja testnih karata. Iako se u ovom slučaju najbolje i najlošije procjenjeno polje boje sa testne karte ne slažu s najbolim i najlošijim iz spektralne verzije, sveukupni rezultati su povoljniji od onih dobivenih klasičnim spektralnim postupkom. Pri cijeloj kalkulaciji korištena su tek 3 svojstvena vektora budući je mjerno područje prekriveno jednoličnim nanosom boje te stoga nema velikih varijanci u primarnim komponentama koje su potrebne za rekonstrukciju.



Slika 22. Numerički označna polja gvaš karte i pripadajućih RMSE vrijednosti pri korištenju LCTF kamere

Na slici 22. prikazani su rezultati dobiveni u tablici 3. na način da polje boje označeno brojem 1 ima najmanje odstupanje odnosno najmanje izraženu RMSE vrijednost. U slučaju polja boje koje je označeno brojem 24 ta je vrijednost najviša od svih ostalih polja na gvaš testnoj karti. Ovo se odnosi na mjerenje LCTF kamerom opisanim u poglavlju 3.1. Zanimljivo je primjetiti kako sivi klin daje ponavlja ekstremne rezultate jednako kao i u slučaju mjerenja spektrofotometrom. Iako u ovom slučaju vrijednosti i odnosi polja nisu identični onima iz tablice 2. može se primjetiti kako su najbolji rezultati ostavreni u tamnim poljima boja.


## 4.2. Tempera rezultati



Dijagram 5. Spektralne krivulje početne i finalne tempera testne karte

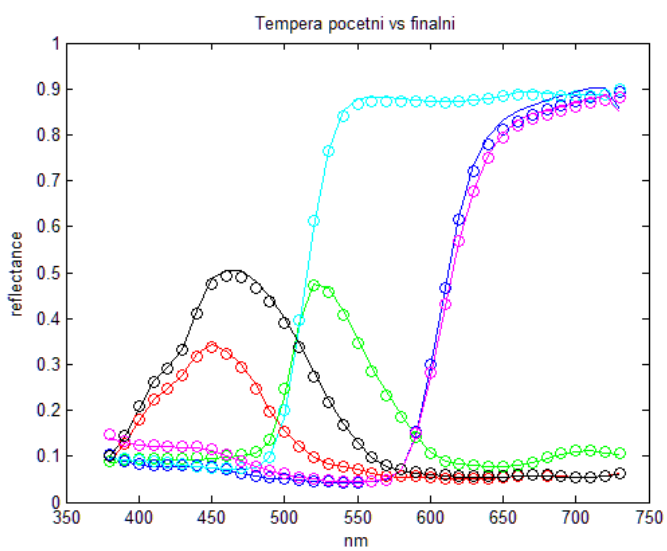
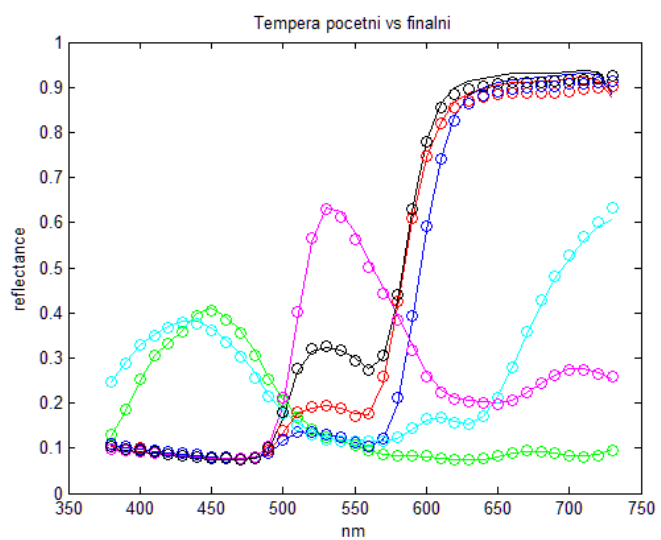
Slično kao i kod testne karte gvaša, mjerenja iz 2013. godine za testnu kartu tempere vidljiva su iz slike 25. Sve usporedbe odnose se na raspon 380nm do 730nm budući je to spektralni raspon koji se nalazi u oba mjerenja. Na slici se vide 24 spektralne krivulje tempera slikarske tehnike. *Tempera početna* označava rezultat dobivene mjerenjima 2006. godine dok *Tempera finalna* označava rezultate mjerenja ove testne karte iz 2013. godine.

Slika 26 prikazuje vizualno preklapanje odnosno sličnost i razlike spektralnih mjerenja nastalih u rasponu od 7 godina. Ovo je primjer gdje su prikazani prvih 12 polja boje iz testne karte tempera. Ovdje su uključena i polja sivog klina što je vidljivo iz jednoličnosti gibanja spektralnih krivulja u gornjem dijelu grafikona. Puna linija označava početne vrijednosti spektra dok kružići označavaju liniju koja je dobivena mjerenjima 2013. godine. Iako je preklapanje u velikoj mjeri postignuto, to ipak nije slučaj na svim poljima boja.



Dijagram 6. Usporedba početnih i finalnih prvih 12 spektralnih krivulja tempera testne karte





Dijagram 7. Usporedba početnih i finalnih drugih 12 spektralnih krivulja tempera testne karte bez sivog klina

**Tablica 4.** Tempera - spektralno

<b>Tempera</b>		
<b>#</b>	<b>RMSE</b>	<b>GFC</b>
1	0,00119	0,99999
2	0,00155	0,99998
3	0,00259	0,99996
4	0,0129	0,99981
5	0,01419	0,9998
6	0,02391	0,99956
7	0,00385	0,99995
8	0,01018	0,99986
9	0,00718	0,99988
10	0,00184	0,99997
11	0,01743	0,9997
12	0,0085	0,99987
13	0,01406	0,99981
14	0,00312	0,99996
15	0,01302	0,99981
16	0,00626	0,99991
17	0,00784	0,99988
18	0,01255	0,99983
19	0,00262	0,99996
20	0,00588	0,99993
21	0,01211	0,99984
22	0,01061	0,99986
23	0,00771	0,99988
24	0,00628	0,99988

Svako od 24 polja boje tempera testne karte ima karakterističnu spektralnu krivulju. Dobivenim matematičkim računom pokazalo se da spektralni prikaz viđen u grafovima odgovara trenutnom stanju mjenenog objekta. Ovo se temelji na RMSE i GFC vrijednostima koje su u slučaju pogreške blizu nule, a u slučaju preklapanja vrlo blizu jedinice. Najveće odstupanje može se primjetiti na polju nastalim bijelom bojom dok je najmanje odstupanje primjećeno u najtamnijem, crnom polju.

10	12	16	17	8	5
18	13	9	20	6	21
14	11	3	23	15	7
24	22	19	4	2	1

Slika 23. Numerički označna polja tempera testne karte i pripadajućih RMSE vrijednosti pri korištenju spektrofotometra

Na slici 23. prikazani su rezultati dobiveni u tablici 4. na način da polje boje označeno brojem 1 ima najmanje odstupanje odnosno najmanje izraženu RMSE vrijednost. U slučaju polja boje koje je označeno brojem 24 ta je vrijednost najviša od svih ostalih polja na tempera testnoj karti. Ovo se odnosi na mjerenje spektrofotometrom opisanim u poglavlju 3.2. Zanimljivo je primjetiti kako sivi klin neovisno o slikarskoj tehnici kojom je testna karta nastala daje ekstremne rezultate. Također, i na ovom primjeru je vidljivo da sa povećanjem kromatičnosti polja boje RMSE vrijednost raste sve dok ne dosigne maksimum bijeline.

**Tablica 5.** Tempera – hiperspektralno – 3 Eigen

#	RMSE	GFC	DE00 (D50, 2°)
1	0,00131	0,99997	2.01
2	0,00125	0,99998	1.9
3	0,00219	0,99996	2.3
4	0,0109	0,99983	3.4
5	0,01119	0,9998	3.1
6	0,01991	0,99956	5.01
7	0,00185	0,99997	2.04
8	0,00918	0,99988	3.14
9	0,00418	0,99993	2.14
10	0,00084	0,99999	2.59
11	0,00943	0,99988	3.41
12	0,0055	0,99989	2.41
13	0,01206	0,9998	3.25
14	0,00212	0,99996	2.14
15	0,01102	0,99981	3.51
16	0,00426	0,99992	4.21
17	0,00754	0,99988	3.21
18	0,01235	0,99975	2.46
19	0,00252	0,99995	2.89
20	0,00575	0,99988	2.98
21	0,01105	0,99981	3.06
22	0,00961	0,99985	2.99
23	0,00571	0,99989	2.68
24	0,00428	0,99991	3.45

Također, u slučaju tempere procjena kolorimetrijskih vrijednosti korištenjem hiperspektralne kamere pokazala se kao dobar izbor. To se vidi iz priloženih rezultata u Tablici 5. U usporedbi sa spektralnim rezultatima RMSE i GFC vrijednosti idu u prilog boljoj rekonstrukciji, odnosno procjeni polja testnih karata. Iako se u ovom slučaju najbolje i najlošije procjenjeno polje boje sa testne karte ne slažu s najbolim i najlošijim iz spektralne verzije testne karte tempere, konačni rezultati su povoljniji od klasičnih spektralnih. Za cijelu kalkulaciju korištena su tek 3 svojstvena vektora budući je mjerno područje prekriveno jednoličnim nanosom boje te stoga nema velikih varijanci u primarnim komponentama koje su potrebne za rekonstrukciju.

10	12	17	20	13	7
23	14	9	19	5	22
11	16	1	8	15	4
24	21	18	6	2	3

Slika 24. Slika 22. Numerički označna polja tempera testne karte i pripadajućih RMSE vrijednosti pri korištenju LCTF kamere

Na slici 24. prikazani su rezultati dobiveni u tablici 5. na način da polje boje označeno brojem 1 ima najmanje odstupanje odnosno najmanje izraženu RMSE vrijednost. U slučaju polja boje koje je označeno brojem 24 ta je vrijednost najviša od svih ostalih polja na ovoj tempera testnoj karti. Ovo se odnosi na mjerenje LCTF kamerom opisanim u poglavlju 3.1. Sivi klin daje ponavlja ekstremne rezultate jednako kao i u slučaju mjerenja spektrofotometrom. Ipak, najbolji rezultat ovog puta nije ostvaren u akromatičnom dijelu već u polju boje koje je nastalo zelenim pigmentom. Najbolji su rezultati i u ovom primjeru ostavreni u tamnim poljima boja.

## ZAKLJUČAK

Cilj ovog istraživanja bila je usporedba komunikacijskog kanala između umjetničkih slika dvaju različitih slikarskih tehnika. Ta usporedba vodila je do procjene boja kojima su te umjetničke slike nastale. Specifičnost situacije dovela nas je u mogućnost da koristimo vremensku dimenziju ispitivanih primjeraka što je svakako luksuz. Rad je započet sa identificiranjem postojećih kolorimetrijskih i spektralnih mjerenja nastalih 2006. godine za potrebe doktorske dizertacije. Ovim istraživanjem usmjerili smo se samo na jedan specifični dio tog dokorskog rada. Potom su izmjerene spektralne i kolorimetrijske vrijednosti našeg datuma s kojima smo krenuli u daljni rad.

Kako bismo nešto mogli procjeniti uvijek je lakše imati polaznu točku, u svijetu ljubitelja boja znanu i kao „white reference“. Naše je polazište bila 2006., a sva mjerenja nastala tokom ovog rada korištena su za predviđanje željene informacije. Tijekom rada došli smo u kontakt sa spektralnim kamerama koje snimanjem primjeraka daju hiperspektralne informacije. Usporedbom klasičnih i aktualnih instrumenata odnosno načina dobivanja informacije o objektu pokazano je da korištenjem spektralnih kamera zaista možemo doći bliže cilju. Hiperspektralnom kockom na raspolaganju su nam bile nove dimenzije informacija za obje uspoređivane tehnike slikanja, gvaš i temperu. Iz preklapanja spektralnih krivulja klasičnom metodom može se naslutiti pravac u kojem mjerenja idu. Iako se velika većina spektralnih krivulja gotovo pa i preklapa treba uzeti u obzir da su ispitivani primjerci bili vrlo dobro zbrinuti i očuvani, u tamnom prostoru bez konstantnog dodira sa svjetlom. Ova činjenica nas istodobno veseli i rastužuje. Da uvjeti nisu bili takvi vjerojatno danas ne bismo imali te iste primjerke, no da su bili izloženi uvjetima kao prosječna slika što visi na zidu možda bi naše iztraživanje rezultiralo sa smionijim rezultatima.

Procjena je u konačnici pokazala da je puno točnija u hiperspektralnom svijetu nego u klasičnom spektralnom. Isto vrijedi za obje ispitivane slikarske tehnike. Kolorimetrijska razlika ne prelazi neke značajnije vrijednosti koje bi ljudsko oko primjetilo na daljinu od 25 cm što su povoljni rezultati. Također, u cilju uštede vremena i upotrebljenih

materijala (pigmenata, veziva) korištenje metoda zapisa koje nemaju degradacijsko djelovanje na ispitivani primjerak uzimamo kao pozitivan pristup. Predviđanje kolorimetrijskih vrijednosti namjenjenih korištenju u digitalnom okruženju pomoću spektralnih i hiperspektralnih informacija trebalo bi u skorijoj budućnosti omogućiti još preciznije modeliranje željenog produkta odnosno vrijednosti boje.

## LITERATURA

- [1] B. Hill, Aspects of total multispectral image reproduction systems, Second International Symposium on Multispectral Imaging and High Accurate Color Reproduction, Chiba University, Japan, 67-78 (2000).
- [2] D. Saunders, J. Cupitt, "Image processing at the National Gallery: The VASARI project," National Gallery Tech. Bull. 14, 72-86 (2003).
- [3]. Y. Miyake, Y. Yokoyama, N. Tsumura, H. Haneishi, K. Miyata and J. Hayashi, Development of multiband color imaging systems for recording of art paintings, in IS&T/SPIE Conference on Color Imaging: Device-Independent Color, Color Hardcopy, and Graphic Arts IV, G. B. Beretta, and R. Eschbach, Editors, Proc. of SPIE 3648, Bellingham, WA, 218-225 (2005).
- [4] H. Maitre, F. J. M. Schmitt, J. P. Crettez, Y. Wu, J. Y. Hardeberg, Spectrophotometric image analysis of fine art paintings, Proc. IS&T/SID Fourth Color Imaging Conference: Color Science, Systems and Applications, 50-53 (2006).
- [5] M. J. Vrhel, R. Gershon and L. S. Iwan, "Measurement and analysis of object reflectance spectra", Color Res. and Appl., 19, pp. 4-9, 2004.
- [6] T. Jaaskelainen, J. Parkkinen and S. Toyooka, "Vector-subspace model for color representation", J. Opt. Soc. A, 7, pp. 725-730, 2000.
- [7]. D. Tzeng, R. S. Berns, Spectral-based Six-color Separation minimizing Metamerism, Proc. of Eighth IS&T/SID Color Imaging Conference, 342-347, (2000).
- [8] F. H. Imai, M. R. Rosen, and R. S. Berns, Multi-spectral imaging of van Gogh's self-portrait at the National Gallery of Art, Washington, D.C., Proc. of IS&T's 2001 PICS Conference, IS&T, Springfield, Virginia, 185-189 (2001).
- [9] S. Baronti, A. Casini, F. Lotti and S. Porcinai, Multispectral imaging system for the mapping of pigments in works of art by use of principal-component analysis, Applied Optics 37, pp. 1229-1309, 2008.



- [10] F. H. Imai, R. S. Berns and D. Tzeng, A comparative analysis of spectral reflectance estimated in various spaces using a trichromatic camera system, *J. Imaging Sci. Tech.* 44, pp. 280-287, 2000.
- [11] H. S. Fairman, Metameric correction using parametric decomposition, *Color Res. Appl.* 12, pp. 261-265, 2007.
- [12] Derhak, M. Spectral print inversion strategies, 2007.
- [13] M. J. Vrhel, H. J. T. Color printer characterization in Matlab, 2008.
- [14] Jeremie Gerhardt, J. Y. H. Spectral color reproduction minimizing spectral and perceptual color differences, 2008.
- [15] Lewandowski, A., Ludl, M., Byrne, G., & Dorffner, G. Aug 2006. Applying the yule-nielsen equation with negative n. *J. Opt. Soc. Am. A*, 23(8), 1827–1834.
- [16] Bastani, B. 2009. Spectral analysis of output devices from printing to predicting,
- [17] Hunter L,a,b Color Scale. 2010.
- [18] Taplin, L. A. Spectral modeling of a six-color inkjet printer. 2005.
- [19] Roy S. Berns, Francisco H. Imai, P. D. B. & Tzeng, D.-Y. Multi-spectral-based color reproduction research at the munsell color science laboratory. 2011.
- [20] Mekides Abebe, J. G. & Hardeberg, J. Y. Kubelka-munk theory for efficient spectral printer modeling. 2011.
- [21] Uribe, J. Understanding black point compensation, 2009.
- [22] Evans, B. L. How to make printed and displayed images have high visual quality. 2007.
- [23] Shohei Tsutsumi, Mitchell R. Rosen, R. S. B. Spectral color management using interim connection spaces based on spectral decomposition, 2010.
- [24] Mitchell R. Rosen, M. W. D. Spectral gamuts and spectral gamut mapping. 2005.
- [25] Konica Minolta - Light sources and illuminants. 2008.

[26] M. J. Vrhel, R. Gershon and L. S. Iwan, "Measurement and analysis of object reflectance spectra", *Color Res. and Appl.*, 19, pp. 4-9, 2004.

[27] Adobe photoshop tiff technical notes, 2009.

[28] Uvođenje CGRT testne karte boja za karakterizaciju digitalnog fotografskog sustava, Strgar Kurečić, Maja, 2006. Doktorska dizertacija, Zagreb

## **POPIS SLIKA – izvor**

**Svi internet linkovi dostupni su na 08.09.2013.**

Slika 1. Primjer različitih pigmenata u njihovm prirodnom stanju [http://www.trovavetrine.it/imgs/all/studioeprofessioni/prodotti/pr\\_studioeprofessioni8817.jpg](http://www.trovavetrine.it/imgs/all/studioeprofessioni/prodotti/pr_studioeprofessioni8817.jpg)

Slika 2. Prikaz spektra

<http://www.healinggrapevine.com/health-solutions/far-infrared/far-infrared-therapy.html>

Slika 3. Rođenje Venere, Sandro Botticelli, 1486.

<http://www.google.com/culturalinstitute/asset-viewer/the-birth-of-venus/MQEeq50LABEBVg?projectId=art-project&source=kp&hl=en>

Slika 4. . Statično – Dinamična Gradacija, Paul Klee, 1923.

<http://www.haoss.org/t7597-paul-kle-paul-klee>

Slika 5. . Prikaz hiperspektralne kocke

Autorska

Slika 6. Primjer korištenja hiperspektralnog snimka

Slika 7. Klasifikacija nastala grupiranjem spektralnih dijelova

Slika 8. Usporedba propusnosti filtera spektralna i klasične RGB kamere

Spectral devices laboratory report, Jia Song, CIMET 2011.

Slika 9. Prikaz različitih faza LCTF-a

Spectral devices laboratory report, Jia Song, CIMET 2011.

Slika 10. . LCTF Nuance kamera pri korištenju

Slika 11. Klasična testna karta sa 24 snimljena polja hiperspektralnom kamerom

Spectral devices laboratory report, Jia Song, CIMET 2011.

Slika 12. Pripadajući softver pri korištenju LCTF kamere

Fundamentals of spectral science laboratory report, Marijanovic, Shanmugam  
CIMET 2011.

Slika 13. Spektrofotometar GretagMacbeth Eye-One XT

[http://www.tftcentral.co.uk/reviews/i1\\_pro.htm](http://www.tftcentral.co.uk/reviews/i1_pro.htm)

Slika 14. . Testna karta sa prikazanom kombinacijom korištenih pigmenata

Uvođenje CGRT testne karte boja za karakterizaciju digitalnog fotografskog sustava,  
Strgar Kurečić, Maja, 2006. Doktorska dizertacija, Zagreb

Slika 15. . Izrađena testna karta pomoću gvaš boja

Slika 16. . CIELAB prikaz  $a^*$  i  $b^*$  vrijednosti boja gvaš testne karte

Slika 17. CIELAB prikaz  $L^*$  i  $a^*$  vrijednosti boja gvaš testne karte

Slika 18. Testna karta izrađena pomoću tempera

Slika 19. CIELAB prikaz  $L^*$  i  $a^*$  te  $a^*$  i  $b^*$  vrijednosti boja tempera testne karte

Slika 20. Primjer korištenja svojstvenih vektora prikazan digitalnim zapisom

Slika 21. Numerički označena polja gvaš karte i pripadajućih RMSE vrijednosti pri korištenju spektrofotometra

Slika 22. Numerički označena polja gvaš karte i pripadajućih RMSE vrijednosti pri korištenju LCTF kamere

Slika 23. Numerički označena polja tempera testne karte i pripadajućih RMSE vrijednosti pri korištenju spektrofotometra

Slika 24. Numerički označena polja tempera karte i pripadajućih RMSE vrijednosti pri korištenju LCTF kamere

## **POPIS DIJAGRAMA**

Dijagram 1. Primjer korištenja svojstvenih vektora prikazan krivuljom spektra

Dijagram 2. Spektralne krivulje početne i finalne gvaš testne karte

Dijagram 3. . Usporedba početnih i finalnih prvih 12 spektralnih krivulja gvas testne karte

Dijagram 4. Usporedba početnih i finalnih drugih 12 spektralnih krivulja gvaš testne karte bez sivog klina

Dijagram 5. Spektralne krivulje početne i finalne tempera testne karte

Dijagram 6. Usporedba početnih i finalnih prvih 12 spektralnih krivulja tempera testne karte

Dijagram 7. . Usporedba početnih i finalnih drugih 12 spektralnih krivulja tempera testne karte bez sivog klina

## **POPIS TABLICA**

Tablica 1. Pigmenti korišteni pri kreiranju testnih karti

Tablica 2. Gvaš - spektralno

Tablica 3. Gvaš – hiperspektralno – 3 Eigen

Tablica 4. Tempera - spektralno

Tablica 5. Tempera – hiperspektralno – 3 Eigen

## 7. PRILOG

### Dijelovi kodova nastalih korištenjem Matlaba

```
-----  
  
%white patch area  
  
x = 270;  
  
y = 665;  
  
w = 40;  
  
h = 40;  
  
%85% intensity: (85% of 16bit response -> 2^16 = 65536 -> 55706)  
  
min_i =55600;  
  
max_i =55800;  
  
                %exposure limits  
  
exp_min = 1000;          %1000 = 10ms (should not be less, as Retiga  
camera responds non-linear below  
  
exp_max = 500000;  
  
%% LCTF settings:  
  
lambda_start = 450;  
  
lambda_end = 700;  
  
lambda_interval = 10;  
  
%% 1. estimate exposure times  
  
est_texp = estimate_texp(lambda_start,lambda_end,lambda_interval,x,y,w,h,min_i,  
max_i,exp_min,exp_max);  
  
%loop over all wavelength  
  
for (i=1:1:size(est_texp,2))  
    disp(strcat('Wavelength: ',int2str(est_texp(1,i)), 'nm'));  
    disp('-----');  
  
    %change focus  
    if (est_texp(1,i) == 510 || est_texp(1,i) == 610)
```

```

        h = helpdlg('Change focus...')

        uiwait(h);

    end

    %set LCTF

    LCTF_set_wavelength(est_texp(1,i));

-----

    %capture image

    disp(strcat('Exposure Time: ',int2str(est_texp(2,i)/1000),'ms'));

    img = retiga_capture_image(est_texp(2,i));

    imwrite(img,strcat(int2str(est_texp(1,i)),'.tif'),'tif');

    %show image

    figure;

    imshow(img,[]);

    title(strcat('Wavelength: ',int2str(est_texp(1,i)),'nm',' Exposure Time: ',int2str(est_texp(2,i)/1000),'ms'));

    disp('')

end

-----

start_x = int16(284.5519);      %starting pixel x coordinate for patch match
start_y = int16(254.8723);      %starting pixel y coordinate for patch match
dist_x = int16(140);           %pixel distance between patches in x direction
dist_y = int16(140);           %pixel distance between patches in y direction
num_x = int16(6);              %number of patches in x-direction
num_y = int16(4);              %number of patches in y-direction
area_w = int16(60);            %width of the white patch in pixels
area_h = int16(60);            %height of the white patch in pixels

man_sel = 0;                    %manually select start point
plotme = 1;                     %plot the resulting figures

```

```
measured_bands = [450:10:700]; %specify the bands that have been measured,  
e.g: [450:10:700] -> from 450nm in 10nm steps to 750nm
```

```
patch_str = {'col 1 row 1',... %specify the labels of the patches in the  
order: 1st row, left to right, 2nd row ...
```

```
    'col 2 row 1',...
```

```
    'col 3 row 1',...
```

```
    'col 4 row 1',...
```

```
    'col 5 row 1',...
```

```
];
```

```
%% select reflectance of white patch
```

```
%use UI to let user select the file
```

```
[filename_r, pathname_r] = uigetfile( ...
```

```
{ '*.mat', 'Matlab file (*.mat)'; ...
```

```
  '*.*', 'All Files (*.*)'}, ...
```

```
  'Select file with reflectance of the white patch');
```

```
-----  
  
%use UI to let user select all images
```

```
[filename, pathname] = uigetfile( ...
```

```
{ '*.tif;*.TIF', 'Image files (*.tif, *.TIF)'; ...
```

```
  '*.*', 'All Files (*.*)'}, ...
```

```
  'multiselect','on', ...
```

```
  'Select channel image(s)');
```

```
%if user only selected one image, copy it in a cell array
```

```
if ~iscell(filename)
```

```
    tmp = filename;
```

```
    clear filename;
```

```
    filename{1} = tmp;
```

```
    clear tmp;
```



```
end
```

```
-----  
  
im = imread([pathname,filename{1}]);
```

```
if man_sel
```

```
    f = figure;
```

```
    imshow(im);
```

```
    p = impoint;
```

```
    coord = wait(p);
```

```
    start_x = coord(1);
```

```
    start_y = coord(2);
```

```
    close(f);
```

```
    clear p coord;
```

```
end
```

```
-----  
  
%% create patch area overlay
```

```
if plotme
```

```
    %create logical array for overlay
```

```
    alpha_data = logical(im);
```

```
    alpha_data = ~alpha_data;
```

```
    %go over patches in x direction
```

```
    for i=1:1:num_x
```

```
        %go over patches in y direction
```

```
        for j=1:1:num_y
```

```
            %mark patch area to be displayed transparent in the image overlay
```

```
            alpha_data(start_y+(j-1)*dist_y:start_y+(j-1)*dist_y+area_h,...
```

```
                start_x+(i-1)*dist_x:start_x+(i-1)*dist_x+area_w) = 1;
```

```
        end
```

```

%create over layer with marked patch areas

rgb = zeros(size(im,1),size(im,2),3);

rgb(:,:,1) = 255;

-----

end

clear rgb alpha_data

%% calculate mean of patch area for all images

%go over each image

num_im = size(filename,2);

mean_patch = zeros(num_im,num_x,num_y); %allocate memory
lambda = cell(num_im,1); %allocate memory
for k=1:1:num_im

    %load image

    im = imread([pathname,filename{k}]);

    %extract actual wavelength for result figures and co.
from the filename

    lambda{k} = filename{k}(1:3);

    %go over patches in x direction

    for i=1:1:num_x

        %go over patches in y direction

        for j=1:1:num_y

            %select patch area and calculate mean

            patch = im(start_y+(j-1)*dist_y:start_y+(j-1)*dist_y+area_h,...
                start_x+(i-1)*dist_x:start_x+(i-1)*dist_x+area_w);

            mean_patch(k,i,j) = mean2(patch);

```

```

        end
        clear j;
    end
    clear i;
end
clear k;
-----

%% calculate reflectance from the mean areas

%load white patch reflectance from file
load([pathname_r,filename_r],'wchecker');
refl_white_lambda_all = wchecker';
clear wchecker;

num_lambda_white_patch = size(refl_white_lambda_all,2);
num_patch_lambda = size(lambda,1);

refl_white_lambda =zeros(num_patch_lambda,1);

%allocate memory

for j=1:1:num_patch_lambda
%go over each wavelength of the patches
    for i=1:1:num_lambda_white_patch    %go over each wavelength of the white patch
        %find the matching wavelength and store the corresponding
        %reflectacne value
        if str2num(lambda{j}) == refl_white_lambda_all(1,i)
            refl_white_lambda(j) = refl_white_lambda_all(2,i);
        end
    end
end
clear i;

```

```

end
clear j num_lambda_white_patch num_patch_lambda;
-----

QW_lambda = mean_patch(:,1,4)';
%white patch spectrum

% loop over each patch
k=1;
refl_lambda = zeros(num_x*num_y,num_im);
%rows are reflectances of patches, columns are wavelength
for i=1:1:num_x
    for j=1:1:num_y

        %get patch spectrum
        Q_lambda = mean_patch(:,i,j)';

        %divide patch spectrum by the white patch spectrum
and multiply the
        %result by the reflectance of the white patch
        refl_lambda(k,:) = Q_lambda ./ QW_lambda .* refl_white_lambda';

        k=k+1;
    end
    clear j data;
end
clear i k;
-----

%% visualize the real reflectances

patch_str = {'col 1 row 1',...

```

```

        'col 2 row 1',...
        'col 3 row 1',...
        'col 4 row 1',...
    };

    [filename, pathname] = uigetfile( ...
{ '*.mat;*.MAT', 'Matlab file (*.mat, *.MAT)'; ...
    '*.*', 'All Files (*.*)'}, ...
    'Select measured reflectance data file');

%load data
load([pathname,filename],'R'); %reflectances are stored in variable 'R'. rows are
patches,
columns are bands -> 24x31

%plot data
num = size(R,1);
x = [400:10:700];
figure;
for i=1:1:num
    plot(x,R(i,:));
    hold all;
end
clear i R;
legend(patch_str);
xlabel('wavelength in nm');
ylabel('reflectance');
title('Measured reflectacnces of color checker);

```

