

Grafički fakultet Sveučilišta u Zagrebu

Ivan Pučić

Utjecaj međuspremnika na očitanje i percepciju otiska

Magistarski rad

Zagreb, 2011.

UDK:	- 655.3.024:658.562:681.65
Znanstveno područje:	- područje tehničkih znanosti
Znanstveno polje:	- grafička tehnologija
Voditelj rada:	- Izv.prof.dr.sc. Nikola Mrvac
Broj stranica:	- 103
Broj slika:	- 58
Broj tabela:	- 20
Broj grafova:	-
Broj literaturnih referenci:	- 41
Datum obrane:	- 21.12.2011.
Sastav povjerenstva za obranu:	doc. dr.sc. Igor Zjakić, član izv.prof. dr.sc. Nikola Mrvac, član dr.sc. Marin Milković, član doc.dr.sc. Damir Modrić, zamjenik člana izv.prof. Danijel Radošević, zamjenik člana u biblioteci Grafičkog fakulteta Sveučilišta u Zagrebu
Rad je pohranjen:	

Sa velikim poštovanjem želim zahvaliti svima koji su mi na bilo koji način pomogli pri izradi ove disertacije.

Posebno zahvaljujem svom mentoru prof.dr.sc.Nikoli Mrvcu, kao i svim članovima povjerenstva za ocjenu ove disertacije koji su svojim sugestijama pridonijeli kvaliteti ovoga rada.

Sažetak

U današnjem grafičkom okruženju prijenos informacija nužna je i standardna procedura. Uporaba međuspremnika jedan je od čestih načina prijenosa koji nije ispitana sa strane prijenosa slikovnih informacija korištenjem međuspremnika operativnog sustava. Zbog postojanja različitih standarda po kojima rade grafički alati i sami operativni sustavi, korištenjem međuspremnika dolazi do prilagodbe informacija novom radnom okruženju.

Prilagodba vrijednosti boja dovodi do odstupanja reprodukcije od originalnog slikovnog elementa već i prije procesa otiskivanja. Nakon što se proizvod otisne ta se razlika dodatno povećava, što potvrđuju i ispitivanja izvršena u okviru ovog rada.

Kao elementi za istraživanje uzeti su kalibracijski klin generiran iz programa Monaco Profiler i dodatne fotografije koje su upotrijebljene za vizualni dio istraživanja. Na osnovu vrijednosti očitanih iz kalibracionih klinova izvedena je analiza numeričkih vrijednosti, koja je ukazala na nastale velike promjene u vrijednostima izmjerениh boja. Ujedno su na osnovi tih mjerena izrađene testne kartice za vizualnu analizu razine promjene boje. Nakon dobivenih rezultata, koji su ukazali na velike promjene pojedinačnih boja, istraživanje je provedeno na otisnutim fotografijama i pokazalo je da ovisno o motivu postoje veće ili manje sličnosti originalu.

Sveukupno promatraljući, može se uočiti da ovakav način rada nije prikladan za upotrebu u grafičkoj industriji prilikom reprodukcije proizvoda visoke kakvoće.

KLJUČNE RIJEČI: grafički alati, međuspremnik, sustavi boja, operativni sustav

Sadržaj

1. Teoretski dio	2
1.1. Uvod.....	2
1.2. Vizualni sustav.....	3
1.2.1. Građa oka.....	3
1.2.2. Defekti vida.....	4
1.2.3. Psihofizika (psihologija).....	6
1.2.3.1. Kategorije vizualnih eksperimenata.....	7
1.2.3.2. Granica vizualne percepције.....	7
1.2.4. Boja – teorije, modeli.....	8
1.2.4.1. Što je svjetlo?.....	10
1.2.4.2. Modeli ljudskog vida.....	10
1.2.4.3. Modeli boja.....	12
Intuitivni modeli boja.....	13
Modeli boja uređaja.....	18
Kolorimetrijski modeli boja.....	21
1.2.4.4. Kolorimetrija.....	26
CIE standardni promatrač.....	28
Vizualno ocjenjivanje otiska.....	31
Denzitometarsko mjerjenje otiska.....	31
Spektrofotometrija.....	32
1.2.4.5. Modeli za matematičko određivanje razlike boja.....	34
1.3. Tehnike ispisa.....	39
1.3.1. Razvoj tiskarstva.....	39
1.3.2. Ink-jet tehnologija.....	41
1.3.3. Elektrofotografija.....	43
1.4. Računalni sustavi.....	45
1.4.1. Operativni sustav.....	45
1.4.2. Međuspremnik u operativnom sustavu.....	47
1.4.3. Grafički programi.....	50
1.4.4. Formati zapisa podataka.....	51
2. Eksperimentalni dio.....	54
2.1. Uvod.....	54
2.2. Plan istraživanja.....	54
2.3. Priprema materijala za ispitivanje.....	56
2.3.1. Korišteni strojevi i uređaji.....	59
Xerox DC700.....	59
Spektrofotometar X-rite DTP41.....	60
Korišteni materijal.....	61
2.4. Spektrofotgarsko ispitivanje otiska i matematička obrada rezultata.	62
2.5. Vizualno ispitivanje.....	77
2.6. Diskusija rezultata.....	91
3. Zaključak.....	93
4. Literatura.....	95
5. Popis tabela.....	98
6. Popis formula.....	99
7. Popis slika.....	101

1. Teoretski dio

1.1. Uvod

Razvojem tehnologije unutar grafičke industrije dolazi do izrazito uske integracije sa informatičkim sustavima. Današnji sustavi prijenosa informacija, kod različitih proizvodnih procesa, u načelu uvijek se za konačni medij oblikuju na kraju same proizvodnje^{1,2}. Prijenosom podataka između grafičkih sustava korištenjem slikovnih informacija i njihovim izravnim uvozom u različite grafičke alate ne dolazi do promjene numeričkih vrijednosti uvezenih podataka, ukoliko korisnik ne odredi prilagodbe pri uvozu, što znači da takva informacija zadržava svoja svojstva i nakon što je stavimo u novi dokument, tj. zapis.

Korištenjem operativnog sustava kao medija za prijenos podataka između različitih grafičkih alata, informacije se prevode u lancu izvorni grafički alat - operativni sustav - završni grafički alat. Prilikom takvog rada koriste se unutarnja podešenja svakog programa i samog operativnog sustava kao medija u kome alati rade pri čemu svaki alat radi po jednom od standarda međuspremnika. Prijelazom iz alata u alat mijenjaju se i standardi po kojima ti alati rade, te se prilagođavaju vrijednosti elemenata prema standardu ciljnog dokumenta. Time dolazi do promjena vrijednosti boja u slici. Kao posljedicu toga u tisku dobivamo otiske promijenjenih boja. S obzirom da je cilj ispitati promjene koje nastaju u grafičkoj proizvodnji prije samog procesa otiskivanja, samo otiskivanje izvršit će se na stroju za digitalni tisk elektrofotografskim načinom otiskivanja te će se na temelju njih odrediti i pripremiti uzorci za vizualni dio ispitivanja. Na temelju instrumentalne analize donijet će se zaključak o postavljenom problemu, kojeg će vizualni dio ispitivanja potvrditi ili negirati sa strane ljudske percepcije samog problema.

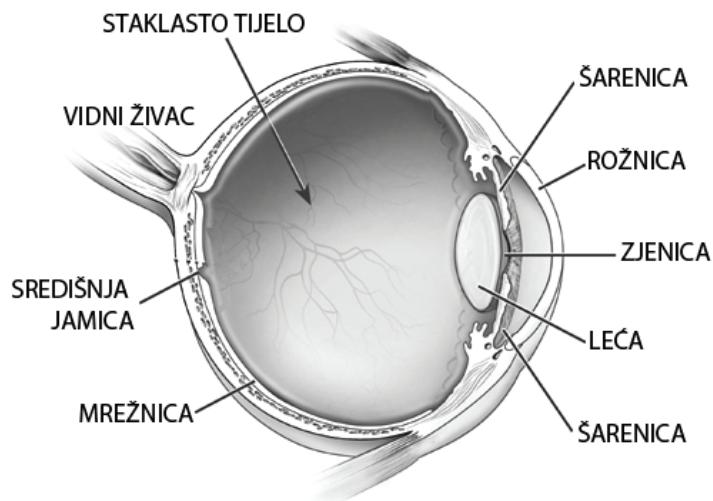
1.2. Vizualni sustav

Za razumijevanje prikaza boje u različitim uvjetima koristimo modelie boja koji su zasnovani na osnovi ljudskog vida. Samim time je za dobro razumijevanje modela boje potrebno razumjeti anatomiju i ponašanje ljudskog vizualnog sustava.

1.2.1. Građa oka

Ljudsko oko je organ osjetljiv na svjetlo namijenjen pretvaranju vidljivog dijela elektromagnetskog spektra u niz impulsa koji se živcima prenose do mozga. Sastoji se od očne jabučice (bulbus), uložene u očnu šupljinu (orbita), gornja i donja vjeđa (palpebra), obrve, trepavice i spojnica (conjunctiva). Kao zaštita oka služe gornje i donje vjeđe (palpebra), obrve, trepavice i spojnica (conjunctiva).

Prvi signal vida kreće iz oka. Na našu percepcijuvida jako utječe struktura oka. Ljudsko oko radi na principu kamere. Rožnica i leća zajedno se ponašaju kao leća kamere, fokusirajući sliku na mrežnicu, koja snima sliku.



Slika 1 Struktura oka

Rožnica je prozirna ovojnica oka kroz koju prolazi svjetlo. Ona je najvažniji element stvaranja slike, jer prijelaz svjetla iz zraka u rožnicu stvara najveći indeks loma svjetlosti u cijelom optičkom sustavu oka. Najčešće bolesti oka poput kratkovidnosti, dalekovidnosti i astigmatizma nastaju u rožnici i ovise o njenom obliku.

Leća služi za fokusiranje predmeta. Svojom slojevitom pomičnom strukturom mijenja indeks loma svjetla. Pri promatranju bliskih predmeta leća se zadeblja, povećavajući optičku snagu i omogućujući izoštravanje bliskih predmeta. Za promatranje udaljenih predmeta leća se stoji i izoštrava udaljene predmete. Starenjem leća gubi svoju pokretljivost te se razvija staračka dalekovidnost. Mijenja se i boja leće, što dovodi do drugačijeg osjećaja boje. Zahvaljujući kromatskoj adaptaciji vidnog sustava te su promjene teško uočljive u normalnom životu. Jako su uočljive u istraživanjima usporedbe boja. Najveća je promjena u ružičastim objektima. Stara leća najviše apsorbira plavi spektar reflektiran od ružičastog objekta, pa stariji promatrači opisuju predmet kao crveniji nego mladi promatrači³.

Šarenica je mišić koji kontrolira veličinu zjenice. Šarenica je pigmentirana i daje ljudskom oku njegovu boju. Boju očiju određuje količina i raspored melanina unutar šarenice. Zjenica koja se nalazi u središtu šarenice definira svojom propusnošću svjetla količinu svjetla koja pada na mrežnicu.

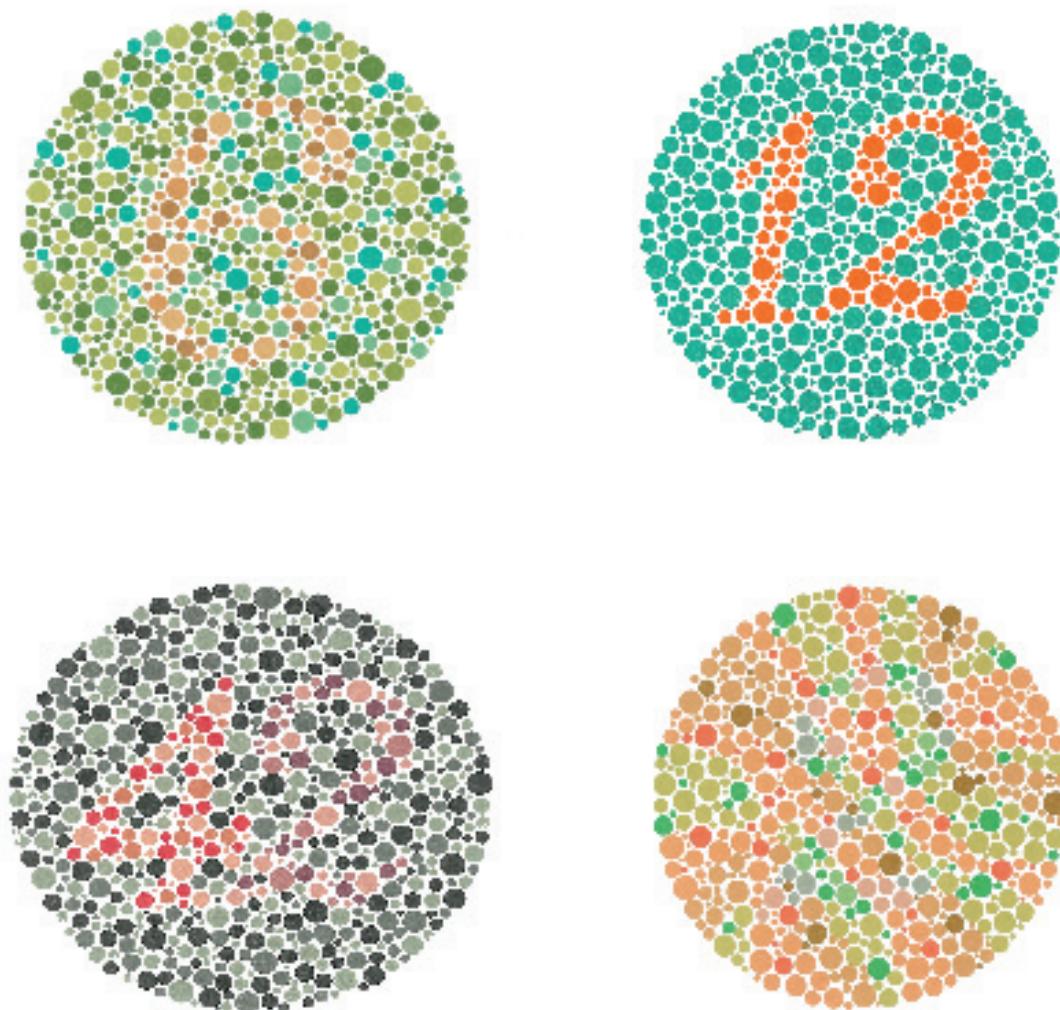
Optička slika se dolaskom na mrežnicu pretvara u živčani signal. Na mrežnici se nalaze fotoreceptori, čunjići i štapići, koji optičku sliku pretvaraju u kemijske i električne signale koji se prenose dalje u vizualnom sustavu. Najbolja slika prima se u središnjoj jamici. Kada gledamo objekt, izoštravamo sliku usmjeravajući pogled da slika pada na središnju jamicu. Ona pokriva vidni kut od otprilike dva stupnja u središnjem vidnom polju. Zadnja razina obrade slike u oku je optički živac. Sačinjen od cca 130 milijuna fotoreceptora, zadužen je za pretvaranje primljenih podražaja u električne impulse i njihov prijenos do mozga.

1.2.2. Defekti vida

Zbog svoje građe ljudski vid je podložan greškama u percepciji boja. Tzv. defekti vida podrazumijevaju određena oštećenja vidnih organa i fiziološke anomalije. Jedan od češćih tipova defektnog vida je nerazlikovanje suprotnih parova boja, ljubičasto-plave i žute te zelene i crvene boje. Taj tip vida nazivamo daltonizam.

Za otkrivanje defekata vida danas je dominantan Ishihara test. Radi se o karticama za testiranje osjetljivosti vida na boje. Na kartici se nalaze točke

različite veličine i boje. Unutar uzorka nalaze se boje koje stvaraju brojeve vidljive osobama sa zdravim vidom, a nevidljive ljudima s određenim defektom vida.



Slika 2 Ishihara testna polja za ispitivanje vizualne defekcije

Ishihara test vida se sastoji od 38 različitih kartica, ali je defekt vida vidljiv već nakon par kartica. Prve 24 kartice daju prilično točnu sliku defekta vida.

Nerazlikovanje boja jednim je dijelom povezano i sa spolom. Prema istraživanju Verrelli i Tikhoff⁴, prirodna genetička selekcija dala je ženama jaču sposobnost razlikovanja boja nego muškarcima. Nagađa se da sposobnost dolazi iz vremena kada su žene bile primarni skupljači biljaka te im je ta sposobnost bila potrebna.

1.2.3. Psihofizika (psihologija)

Psihofizika je znanost odnosa između izmjerena fizikalnih vrijednosti i osjećaja koje te vrijednosti uzrokuju kod promatrača⁵. Namjena psihofizike je iznošenje kvantitativnih mjerena percepcije koja se sama po sebi smatraju subjektivnima. Pravilno izvršenim ispitivanjima dobivaju se objektivni rezultati iste vrijednosti kao i fizički izmjereni podaci. Glavna je razlika što su tolerancije psihofizikalnih mjerena znatno veće od onih izvršenih mjernim instrumentima.

Vizualne psihofizikalne studije većinom se bave određivanjem granice percepcije na kojoj počinje reakcija na fizički stimulus. Granicu percepcije definiramo kao minimalnu vrijednost fizičkog stimulusa potrebnu da se izazove perceptualna reakcija ili promijeni doživljaj percepcije⁶.

Postoje tri principa psihofizikalnih mjerena⁷:

- Princip zajedničkog faktora koji polazi od pretpostavke da promatranje može biti više ili manje točno. Ovaj princip podrazumijeva tri mogućnosti:
 - percepciju - Promatrač vidi predmet kakav je
 - iluziju - Promatrač vidi predmet, ali je on iskrivljen. Primjerice, krug izgleda kao elipsa, boja izgleda svjetlijie ili tamnije ili promatrač vidi drugu boju pod različitim uvjetima promatranja
 - halucinaciju - Daje dojam da se nešto vidi, dok u stvari nema ničega.
- Princip fenomena: ako ispitaniku izgleda da postoji nešto što izgleda kao da ima određenu osjećajnu kvalitetu, onda postoji nešto čega je ispitanik svjestan, što posjeduje tu osobinu⁸.
- Princip reprezentacije koji govori da su vizualna iskustva namjerna ili reprezentativna.

Većina teorija percepcije odbacuje jedan ili više principa.

1.2.3.1. Kategorije vizualnih eksperimenata

Vizualna istraživanja obično ulaze u dvije kategorije⁵:

- **deskriptivne** - za mjerjenje vizualne osjetljivosti na male promjene u uzorku
- **analitičke** - namijenjene za stvaranje odnosa između fizikalnih i perceptivnih razlika u stimulusu.

Deskriptivna mjerena su prikladna za mjerjenje prisustva podražaja ili za mjerena razlike u promjenama. Njima je moguće provjeriti osjetljivost na promjene poput promjene boja korištenjem raznih modela boja ili razine kompresije koja se može primijeniti na slikovnom elementu, a da se zadrži potrebna kvaliteta slike. Rezultat deskriptivnih mjerena je u pravilu opis doživljaja.

Za određivanje odnosa među stimulansima koristimo analitičke metode. Njima je moguće odrediti odnos mjerljivih kolorimetrijskih vrijednosti poput CIE Lab sa svjetlinom, zasićenjem i tonom. Merenja se smatraju analitičkim kada se provode mjernim uređajima i kao rezultat daju matematički opis ispitivanja.

1.2.3.2. Granica vizualne percepcije

Granica vizualne percepcije predstavlja graničnu vrijednost koja razdvaja dva podražaja doživljaja vida. Istraživanja je moguće podijeliti u tri osnovne skupine⁶:

- absolutna granica vizualne percepcije
- razlikovna granica vizualne percepcije
- prirastna granica vizualne percepcije.

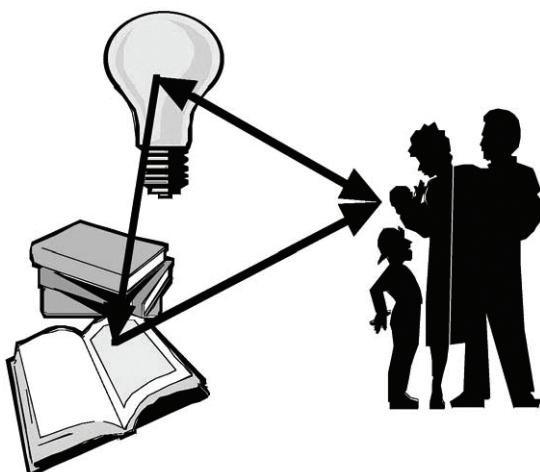
Absolutna granica traži minimalnu vrijednost podražaja potrebnu da bi se izazvala perceptivna reakcija. Razlikovna i prirastna granica predstavljaju različitost u doživljaju koju izazivaju dva mjerena podražaja.

Granica vizualne percepcije koristi se za određivanje je li razlika između mjerenoj i referentnog uzorka vidljiva ili ne.

1.2.4. Boja – teorije, modeli

Boja je optički fenomen, senzorski utjecaj, protumačen suradnjom oka i mozga. Boja nije fizička varijabla te samim time nema fizikalnu jedinicu. Čovjekov osjećaj boje izazvan je elektromagnetskim zračenjem valne duljine u rasponu od 380 do 750 nm. Obojenje predmeta događa se u oku ili mozgu promatrača⁹. Objekt nije obojan sam po sebi, ali je osjećaj boje izведен kao rezultat osvjetljavanja svjetлом. Sunčeve svjetlo, koje izgleda bijelo, osvjetjava objekt i djelomično se odbija. Objekt koji odbija svjetlo u vidljivom dijelu spektra izgleda obojan. Objekt koji u potpunosti odbija vidljivi dio spektra izgleda bijelo, dok onaj koji potpuno upija izgleda crno¹. Samim time, boja kao obojenje podložna je promjeni "izgleda" pri promjeni uvjeta pod kojima gledamo određeni objekt. Ovisi o tri komponente:

1. spektralnim osobinama izvora svjetla koji osvjetjava objekt
2. fizičkim i kemijskim osobinama objekta, koje moduliraju elektromagnetsku energiju koja dolazi od izvora svjetla
3. sustavu ljudskog vida



Slika 3 Trokut boje. Boja postoji zbog interakcije izvora svjetla, objekta i ljudskog vida

S obzirom da su sve tri komponente potrebne za definiciju boje, one se moraju definirati:¹⁰

- izvori svjetla kroz spektralnu distribuciju energije i određeni kao standardni izvor svjetla.
- fizički objekti se definiraju geometrijskom i spektralnom distribucijom energije koju odbijaju (reflektiraju)
- ljudski vid se definira kroz svoju sposobnost identifikacije boja. Oko pomoću fotoreceptora preuzima sliku i šalje je živčanim sustavom u mozak, koji proizvodi osjećaj boje.

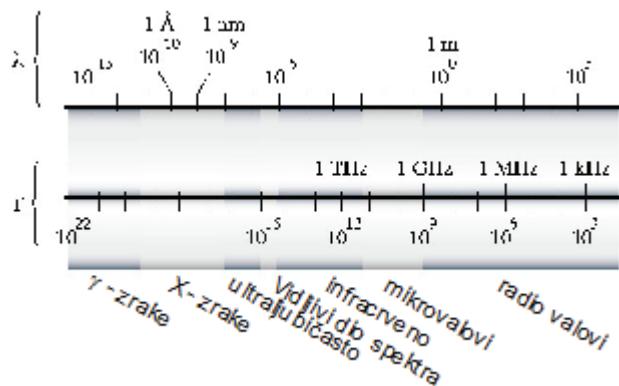
Važno je napomenuti da izvor svjetla djeluje ne samo na promatrani objekt nego i na promatrača te time ima važnu ulogu u izgledu boje objekta kromatskom adaptacijom. Kromatska adaptacija je sposobnost ljudskog vida da prilagodi, u velikoj mjeri, osjetljivost na boje prema boji osvjetljenja¹⁰.

Tri sastojka za nastajanje boje predstavljaju tri grane klasične znanosti: fiziku, kemiju i biologiju. Za razumijevanje svjetla potrebna je fizika svjetla. Kemiju koristimo za razumijevanje površinske kemije, tj. apsorpciju svjetla u molekulama, biologija nam objašnjava prirodu promatrača, posebno rad oka i mozga.

Osim stvaranja slike pomoću koje se krećemo, ljudski vizualni sustav rješava i jedan veliki problem - kako iz dvodimenzionalne slike razumjeti svijet koji je u tri dimenzije. Za rekonstrukciju trodimenzionalnog svijeta potrebno je mnogo pretpostavki o strukturi čovjekova okoliša. Kao posljedica tih pretpostavki javlja se pojam vizualnih iluzija. Kada se povrijede pretpostavke po kojima ljudski vid radi, dolazi do prividnog stvaranja novih elemenata poput miješanja boja i prividnog nastajanja novih elemenata. Za stvaranje vizualnih iluzija potrebno je pogoditi specifičnu kombinaciju boja, kontrasta, oblika i osvjetljenja. Postojanje vizualnih iluzija pokazuje da je ljudski vizualni sustav nelinearan i da različite osobine podražaja međusobno reagiraju na neočekivane načine¹¹.

1.2.4.1. Što je svjetlo?

Vidljivi dio spektra elektromagnetskog zračenja koje čovjek može vidjeti nazivamo svjetlo. S obzirom da svjetlo putuje kroz okolinu kao zračenje ono i reagira s predmetima u toj okolini. Reakcija svjetla događa se na različite načine poput rasipanja, polarizacije, refleksije i refrakcije na fizikalnoj razini i difrakcije, interferencije i disperzije na kemijskoj molekularnoj razini. Vid prosječnog promatrača reagira na valnu duljinu od 380 do 780 nm.



Slika 4 Prikaz spektra elektromagnetskog zračenja i njegova podjela

Vidljivi dio spektra zauzima samo mali dio elektromagnetskog spektra i podudara se s rasponom valnih duljina koje dobro reagiraju s materijalima. Dulje valne duljine griju objekte, a kraće valne duljine su dovoljno jake da djeluju na strukturu molekula i uništavaju je. Samo valne duljine vidljivog dijela spektra reagiraju s materijalima na način da stvaraju osjećaj boje.

1.2.4.2. Modeli ljudskog vida

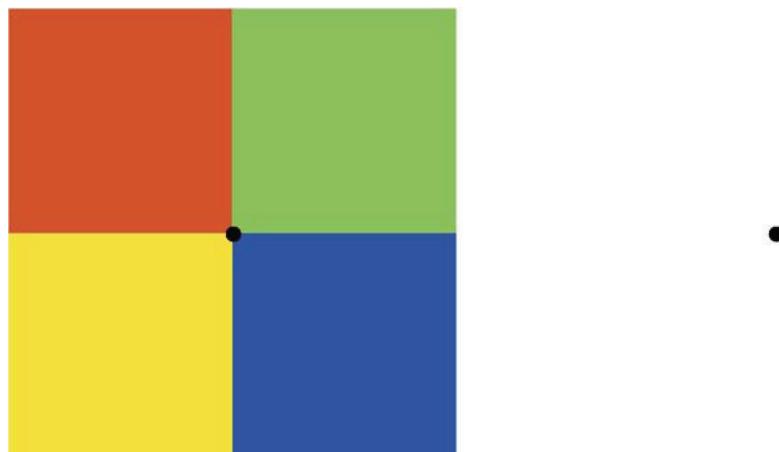
U svrhu definiranja ljudskog vida stvoreno je nekoliko teorija.

Prvu je hipotezu dao Isaac Newton 1664. godine, kada je propustio sunčevu svjetlo kroz staklenu prizmu i razdvojio je u spektar obojenog svjetla. Ujedno je otkrio da je moguće takvo raspršeno svjetlo spojiti u jednu zraku bijelog svjetla. Također je otkrio da je moguće odvojiti jednu boju propuštanjem kroz filter. Njegovo istraživanje je dogradio Thomas 1802. godine, pokazavši da se bijelo svjetlo može dobiti miješanjem tri svjetla uskog spektra crvene, zelene i plave. Iznio je teoriju da umjesto da oko sadrži receptore za svaki dio spektra, ono sadrži tri različita fotoreceptora od kojih je svaki osjetljiv na drugi dio vidljivog

spektra. Pedeset godina kasnije Hermann Von Helmholtz, dokazao je da je moguće stvoriti sve boje vidljivog dijela spektra korištenjem tri valne dužine. Izjavio je da oko ima tri vrste receptora osjetljivih na plave, zelene i crvene valne dužine. Kombinacija tih triju receptora u mozgu bi se interpretirala kao jedna boja, koju bi određivali odnosi snaga impulsa sva tri receptora. To je postala Young-Helmholtzova teorija obojenog vida¹².

Iako Young-Helmholtzova teorija obojenog vida dobro predviđa ishod pokusa predviđanja boja, ona ne objašnjava događanja u ljudskom vidu, posebno anomalije povezane sa sljepilom na boje. Kod sljepila na boje istovremeno dolazi do gubitka parova boja. Parovi su uvijek crvena i zelena ili žuta i plava. Javlja se i problem kod definiranja subjektivnoga iskustva miješanih boja, primjerice miješanja crvene i zelene u žutu, a ne crvenkasto-zelenu.

Usporedno s razvojem trikromatske teorije, Hering je predložio teoriju protivnih signala boje. Hering je izjavio da postoje tri vrste vizualnih bipolarnih receptora koji primaju svijetlo-tamno, crveno-zeleno i žuto-plavo. Ova teorija uspješno objašnjava promjene boja koje Young-Helmholtzova teorija ne može objasniti¹¹.



Slika 5 Demonstracija Heringove teorije protivnih signala. Fiksirajte crnu točku u sredini obojenih kvadrata oko 30 sekundi. Nakon toga gledajte crnu točku na bijeloj površini. Primjetit ćete pozadinsku sliku sukladno prvoj gledanoj slici.

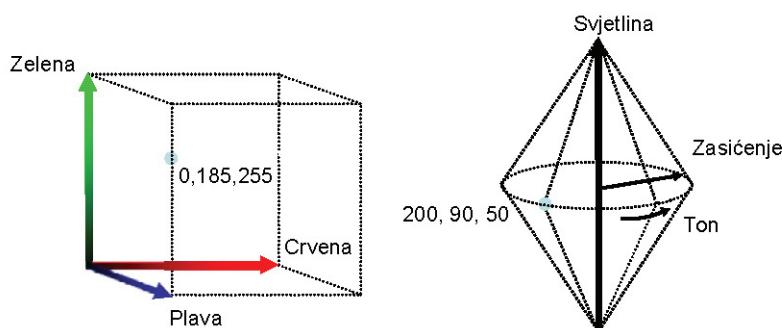
Današnja dvoprocesna teorija objedinjuje ove dvije teorije, s time da je prva faza trikromatska teorija, a druga teorija protivnih signala. Oko preuzima sliku trikromatskom teorijom u tri vrijednosti koje očitavaju očni receptori i obrađuje informacije kaol svijetlo-tamno, crveno-zeleno i žuto-plavo i šalje taj signal u

mozak. Iako su ove teorije potvrđene i neuropsihološkim mjeranjima, one ne daju potpunu sliku ljudskog vida.

1.2.4.3. Modeli boja

Model boja je skupina brojčanih vrijednosti zasnovanih na različitim primarnim bojama. Miješanjem primarnih boja u različitim vrijednostima dobivaju se različite boje¹³.

Modeli boja potrebni su za geometrijsko obilježavanje ili mapiranje boja. Time se dobiva suvremeni sustav rasporeda boja koji stavlja svaku boju na određeno mjesto i definira je kao kombinaciju osobina modela boja. Najčešće se boja opisuje pomoću tri ili četiri vrijednosti sustava boja. Matematičkom definicijom svih boja nastaje sustav boja, koji prikazuje vezu između boje, izvora svjetla i promatrane površine.



Slika 6 Prikaz iste boje u dva različita prostora boja. Ista je boja definirana različitim koordinatama

Postoji više načina za opisivanje boje:

- intuitivni modeli boja – pokušavaju opisati boju na osnovi ljudskog iskustva o međusobnom odnosu među bojama. Boja se razvrstava i prema određenim perceptualnim karakteristikama unosi u atlase boja ili neki drugi katalog
- modeli boja uređaja – opis boja vezan je uz karakteristike i namjenu uređaja unutar kojeg rade. Glavni predstavnici su RGB i CMY prostori boja. RGB je svoju namjenu našao u obradi vizualnih signala električkih uređaja poput računala, skenera, digitalnih i video kamera i sličnim uređajima. CMY je glavnu svrhu našao u tiskanim medijima i medijima koji se koriste suptraktivnom sintezom boja

- kolorimetrijski modeli boja. Razvijeni su da nadopune RGB i CMY modele boja i ne ovise o uređajima na kojima se reproduciraju. U mogućnosti su definirati sve realne boje i omogućiti kvalitetan prijelaz između različitih modela boja. Nastaju matematičkim prijenosom CIE trostimulusnih vrijednosti u ujednačene (uniformne) prostore boja poput CIELAB i CIELUV.

Intuitivni modeli boja

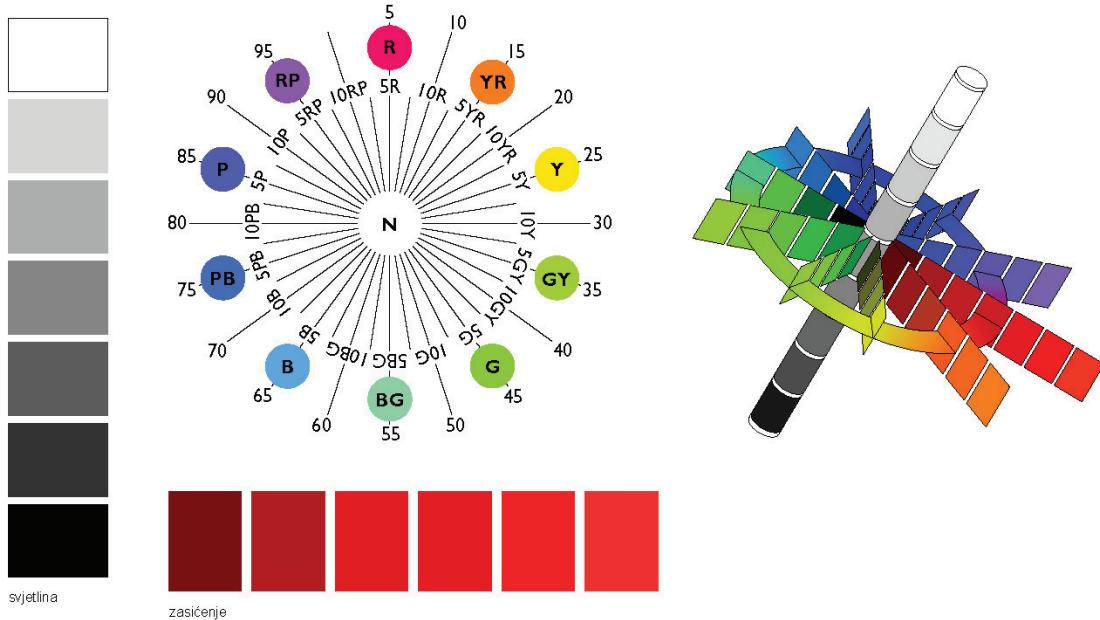
Intuitivni modeli boja (Colour Notation Systems) pokušavaju na osnovi ljudskog osjećaja boje, iste organizirati prema redoslijedu zasnovanom na perceptualnim karakteristikama boja. Boje se opisuju pojmovima poput zasićenje, ton, kromatičnost, sličnost, svjetlina, jačina i dr.

Predstavnici intuitivnih modela su Munsell, Pantone, Natural Colour System (NCS), OSA, Oswaldov krug boja, Tintometar, HSB, HLS, LCH, Pantone, TekHVC i drugi. Ovi sustavi daju skup simbola koji točno opisuju boju.

Albert Munsell razvio je 1905. godine sustav koji se sastoji od:

- skupa materijalnih uzoraka čije boje čine osnovne referentne boje. Oni su pravilno raspoređeni tako da obuhvate prostor boja jednoliko i što je moguće potpunije
- atlasa boja u kome se nalaze pomno načinjene kopije originalnih uzoraka boja
- definicije boje pomoću kojih se može opisati i naći svaka boja u sustavu.

Boje u Munsellovom modelu definirane su trima vrijednostima: tonom H (Munsell hue), zasićenjem C (Munsell chroma) i svjetlinom (Munsell value)^{11,14}. Prvi puta objavljen je 1915. godine. Verziju koja je i danas u uporabi definiralo je 1931. godine Optičko udruženje Amerike (Optical Society of America – OSA). Izvršili su kolorimetrijska mjerena uzorka i na osnovi njih generirali Munsellov atlas boja sa standardnim promatračem 2° i CIE standardnim izvorom svjetla.



Slika 7 Munsellov prikaz boja

Svjetlina predstavlja sivi stupnjevani klin koji ima jedinice od 0 do 10 (0= idealna crna boja; 10=apsolutna bijela boja).

Ton je podijeljen na 10 cjelina. Pet je osnovnih tonova: 5R – crvena, 5Y – žuta, 5G – zelena, 5B – plava i 5P – purpurna i 5 međutonova: 5YR, 5BG, 5GY, 5RP, 5PB. Svaka je cjelina podijeljena u još 10 cjelina, što daje ukupno 100 tonova.

Zasićenost je definirana kao pomak tona prema neutralnoj akromatskoj osi, u vrijednostima od 0 (neutralne sive) do 10 ili 14, ovisno o rasponu gamuta medija.

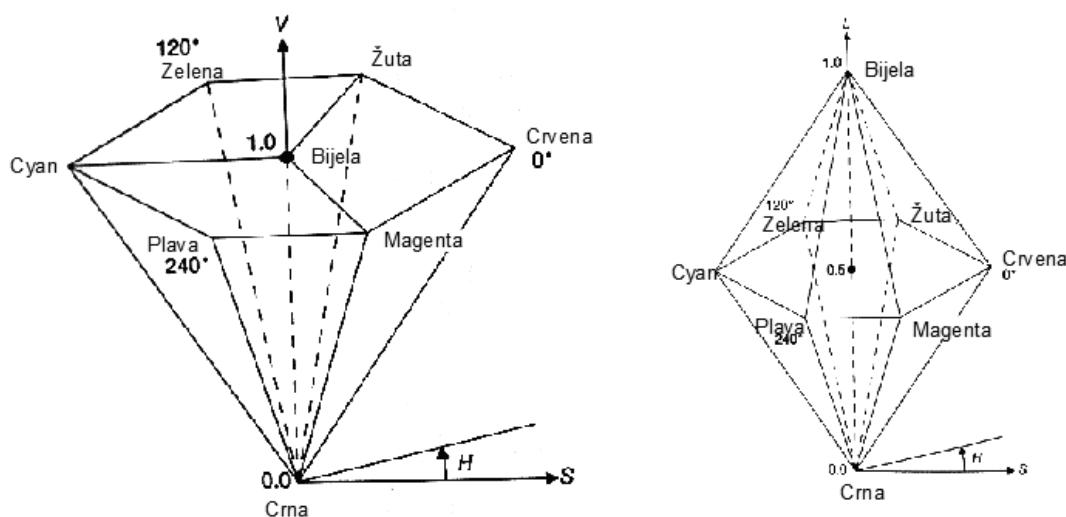
Ton se označava slovima i brojem, zasićenje vrijednostima od 0 do 14, a svjetlina također brojevima. Tako definicija boje u Munsellovu sustavu izgleda "2.5R 8/4", gdje je 2.5R ton boje, 8 predstavlja svjetlinu, a 4 zasićenje boje.

Lijevi 3D prikaz je cilindrični prikaz Munsellovog modela boja. Ton predstavlja kutna koordinata, linearna koordinata predstavlja svjetlinu, a radijus zasićenje.

HSB sustav boja stvorio je A. R. Smith 1978. godine na osnovi RGB modela boja. Temelji se na trima vrijednostima - tonu (hue), zasićenju (saturation) i svjetlini (brightness). Model boja predstavlja krug u kojem se na 120° razdaljine nalaze primarne boje aditivne sinteze: crvena, zelena i plava, a između njih se nalaze primarne boje suptraktivne sinteze. Ovaj razmještaj boja odgovara teoriji

suprotnih tonova ljudske percepcije prema Heringovoj teoriji suprotnih procesa. Problem je što HSB model ne postiže linearost svjetline, pa svjetlina od 50% ovisi o boji koju promatramo. Problem je što se maksimalna vrijednost svjetline nalazi na istoj plohi heksagona kao i čiste boje.

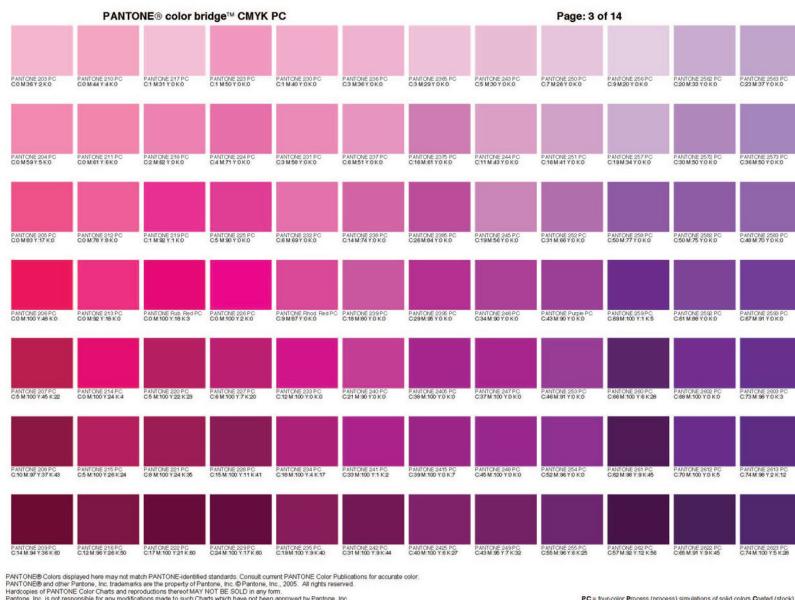
HLS sustav stvorila je kompanija Tektronix 1977. godine, kao nadogradnju HSB sustava. HLS definira svjetlo kao ton (hue), osvjetljenost (luminescence) i zasićenje (saturation). Model je izведен s dva heksagona spojena na svojim ravnim plahama, što je omogućilo dvostruko veći prostor za opis svjetline nego kod HSB modela. Oba modela imaju veliku primjenu kod računalnih sustava, zbog odvojene veličine svjetline i samog tona boje¹⁵.



Slika 8 Konstrukcija HSB (lijevo) i HSL modela boja (desno)

Boja se kod oba sustava definira kao polarna koordinata u rasponu od 0 do 356.9° . Obojenje H se prikazuje kao kut od 0 do 360° vrijednosti, pri čemu je 0° crvena (red), 60° žuta (yellow), 120° zelena (green), 180° zeleno-plava (Cyan), 240° plava (Blue) i 300° pururna (Magenta). Zasićenost S raste s udaljenošću od središta modela. Izražava se u postocima od 0 do 100. Svjetlina B kod HSB modela i L kod HLS modela prikazuje se u postocima od 0 do 100%.

Za grafičku industriju jedan od najznačajnijih intuitivnih sustava je Pantone sustav boja. Pantone atlas boja dolazi u dvije varijante. Kao atlas boja sa spot bojama s omjerima miješanja i u varijanti s omjerima za dobivanje spotnih boja iz CMYK sustava boja.



Slika 9 Izvadak iz Pantone atlaza boja

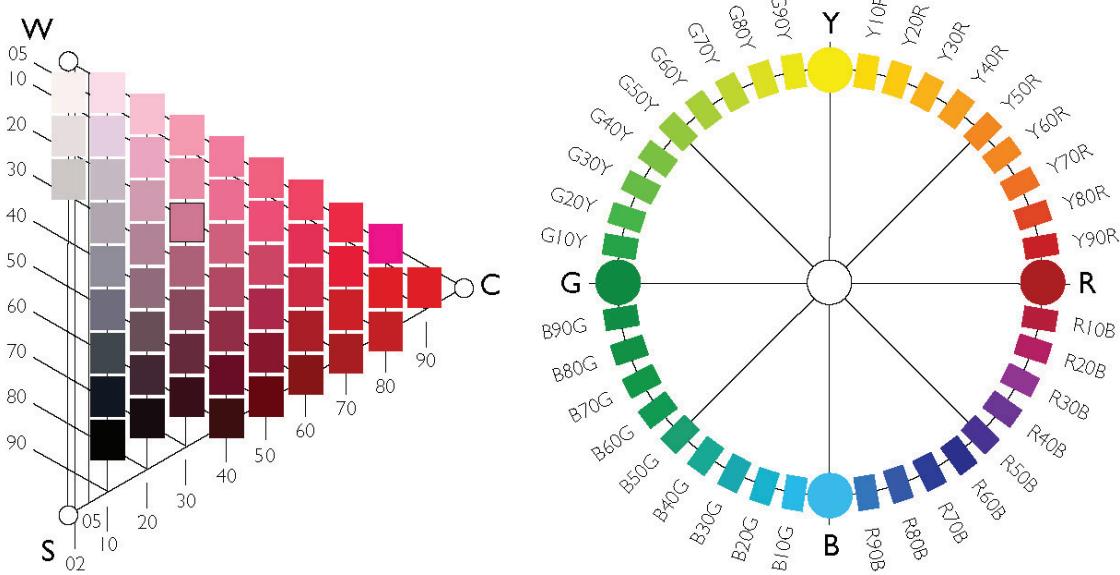
Za svaku vrstu papira radi se posebni atlas boja prilagođen za postizanje navedenih vrijednosti.

Na osnovi logičke organizacije HSB sustava boja nastao je atlas boja s više od 2000 uzoraka otisnutih procesnim CMYK bojama. Sustav je perceptualno organiziran od Pantone sustava. Omogućuje korisnicima računalnih programa odabir i otiskivanje uzorka na pisaču ili tiskarskom stroju, te uspoređivanje boja između percepcije na monitoru i otisku. Time se određuje točnija specifikacija željene boje.

Švedski sustav prirodnih boja (NCS – Natural Color System) zasnovan je na šest osnovnih boja: crvenoj, zelenoj, plavoj, žutoj, crnoj i bijeloj. Zasnovan je na teoriji da za promatranje boje koristimo tri nezavisna mehanizma: crveno-zeleni, plavo-žuti i crno-bijeli. Boje se nalaze u NCS atlasu boja. Jedinice za definiciju boje su crnoća, kromatičnost i ton.

Pri ispitivanju se od ispitanika traži da ocijeni boju po šest sličnosti u vrijednostima NCS sustava. Postoje i ograničenja: prvo je da niti jedna boja ne može sličiti crvenoj i zelenoj ili plavoj i žutoj. Ton se određuje po relativnoj sličnosti stimulusa s ove četiri boje. Drugo ograničenje je da suma kromatičnosti i sličnosti crnoj i bijeloj mora biti 100. Ova ograničenja omogućuju definiranje boje pomoću tri vrijednosti: dvije sličnosti tona koje ne mogu biti 0 i crnoće.

Normalizacijom se definiraju crnoća, kromatičnost i ton kao jedinice definicije boje.



Slika 10 Prikaz NCS sustava boja

Standardna NCS geometrija unutar tona definirana je u trokutu boja. Okomica definira kromatičnost, a dijagonalna linija crnoću. Odabir tona vrši se u krugu boja.

Jedan od intuitivnih modela načinjen na osnovi CIE kolorimetrijskih osnova je CIE LCH_{ab} sustav boja. Izведен iz CIE LAB modela boja, namijenjen je za prikazivanje boje kroz kromatičnost (chroma), svjetlinu (lightness) i ton boje (hue). Ne postoji mogućnost prikaza zasićenosti boje. Osnovni atlas boja sadrži 1229 uzoraka unutar 18 razina svjetline.

Definira se kao:

$$L^* = 116/(Y/Y_0)^{1/3} - 16 \quad [1]$$

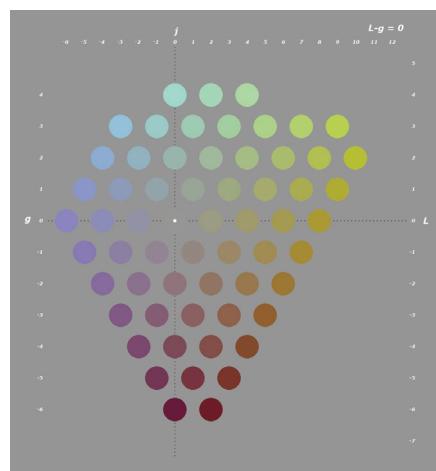
$$C^* = (a^{*2} + b^{*2})^{1/2} \quad [2]$$

$$h^0 = \arctan(b^*/a^*) \quad [3]$$

gdje je L* svjetlina u rasponu od 0 do 100, s istom vrijednosti kao i kod CIE Lab modela. C* je kromatičnost boje u rasponu od -60 do +60 i definira se kao vektorska razdaljina od centra dijagrama do željene boje. h⁰ predstavlja ton u

rasponu od 0° do 360° , pri čemu kut od 0° označava crvenu, 90° žutu boju, 180° zelenu, a kut od 270° ljubičasto plavu boju.

OSA Sustav boja (OSA Uniform Color Scale) definiran je tako da je perceptualna razlika između susjednih uzoraka jednaka, dok se uzorci razlikuju u tonu, zasićenju i svjetlini. Osnovno mjerilo sustava je perceptualna razlika u uzorcima. Svaki je uzorak definiran kao: L – svjetlina, j – plavost-žutost i g crvenost-zelenost. Odbor koji je bio zadužen za njegov razvoj zaključio je da diskriminacije boje nisu jednolike i da ga ne preporučuju za općenitu definiciju razlike među bojama¹⁶.



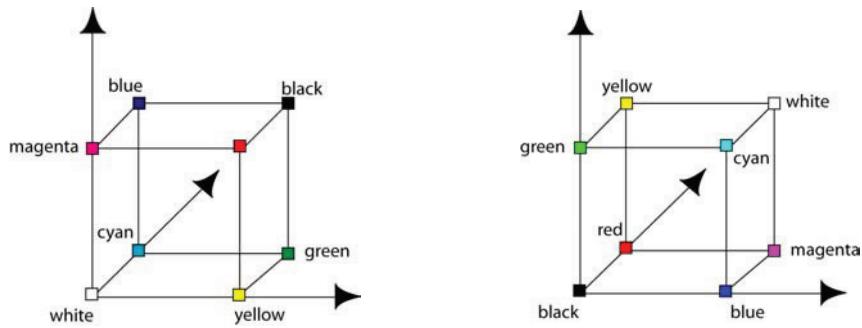
Slika 11 Prikaz OSA sustava boja

Ocenjivanje se provodi uz izvor svjetla D65 i s neutralnom pozadinom uz 30% refleksije.

Modeli boja uređaja

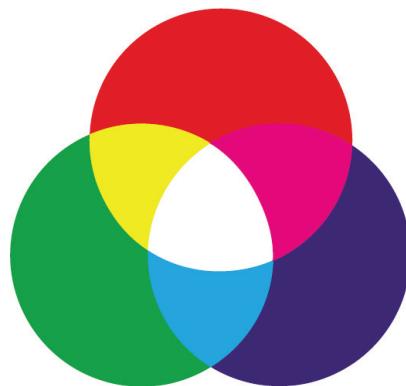
Dva najčešća uređaja za reprodukciju boja su ekran i otisak. Zbog njihove ovisnosti o karakteristikama medija reprodukcije, oni prikazuju boju u skladu s mogućnostima uređaja, a ne prema psihofizikalnim potrebama.

RGB i CMY modeli prikazuju se kao trodimenzionalno tijelo (kocka). Kod RGB-a su osnovne koordinate crvena (red), zelena (green) i plava (blue), dok su kod CMY-a koordinate zeleno-plava (cijan), purpurna (magenta) i žuta (yellow). U primarima RGB-a nalaze se zeleno-plava (cyan), purpurna (magenta) i žuta (yellow), a u primarima RGB-a crvena, zelena i ljubičasto plava boja¹⁷.



Slika 12 Prikaz CMY i RGB trodimenzionalnih tijela

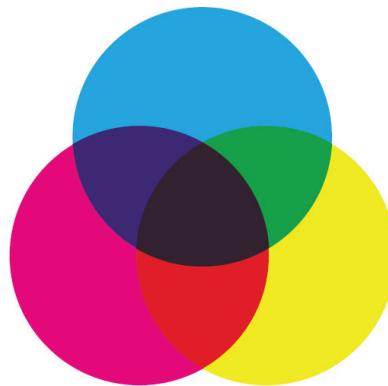
RGB model boja zasnovan je na primarnim bojama aditivne sinteze (R - crvena, G - zelena, B - plava). Prikaz svih primarnih boja u najvećem intenzitetu daje bijelu boju. Aditivnu sintezu omogućuje trikromatska struktura ljudske mrežnice.



Slika 13 Aditivno miješanje boja

Zbrajanjem različitih boja svjetla u različitim omjerima moguće je dobiti sve druge boje vidljivog dijela spektra. Miješanjem pojedinih valnih dužina dobivamo nove boje. Miješanjem crvene i zelene boje dobivamo žutu boju. Miješanjem crvene i plave dobivamo magentu, a miješanjem zelene i plave cijan. To su ujedno i primarne boje supktrativnog miješanja boja.

CMY model boja zasnovan je na suptraktivnom miješanju primarnih boja suptraktivne sinteze cijana, magente i žute. Boja nastaje uklanjanjem primarnih boja iz bijele. Maksimalni intenzitet svih boja daje crnu. Zbog nečistoća samih pigmenata u praksi se koristi crna boja za postizanje punog zacrnjenja.



Slika 14 Subtraktivno mješanje boja

U tisku boja cijan znači da apsorbira duge valne duljine, posebno crveni dio vidljivog dijela spektra. Magenta apsorbira srednje valne duljine – zelenu, a žuta apsorbira kratke valjne duljine – plavu. Aditivna i suptraktivna miješanja boja odvijaju se u modernim uređajima i njihov prikaz ovisi o osobinama tih uređaja. Prikaz RGB boja izgleda drugačije na svakom uređaju isto kao što i otisak otisnut različitim bojama daje različit otisak.

Problem s trodimenzionalnim RGB i CMY modelima boja je što nisu intuitivni. Kada se navedu tri broja teško je zamisliti koja je to boja. Slične boje u tim sustavima nisu susjedne, pa mala razlika u numeričkim vrijednostima često daje veliku razliku u percepciji boja.

Najveći nedostatak modela boja ovisnog o uređaju je što ista numerička boja na različitim uređajima izgleda različito. Taj se problem rješava kalibracijom uređaja i karakterizacijom prostora boja. Kalibracijom se izlazni signal uređaja namješta na standardne vrijednosti. Karakterizacija određuje odnose između prostora boja i lineariziranih CIE prostora boja.

S obzirom da RGB model boja ovisi o uređaju na kome se reproducira, u pokušaju standardizacije, CIE je 1998. godine definirao sRGB model boja kao standard za primjenu kod uređaja koji koriste RGB model za reprodukciju. sRGB je usko povezan sa CIE sustavima.

Kolorimetrijski modeli boja

Same po sebi numeričke vrijednosti nisu dovoljne za reprodukciju boja na određenom uređaju. Svaki uređaj ima svoj raspon prikaza boja, koji treba uskladiti s ljudskim vidom. U tu su svrhu razvijeni prostori boja. Prostor boja detaljno definira model boja i povezuje ga s primarnim bojama uređaja.

Kolorimetrijski modeli boja su neovisni o uređaju (device independent models), što znači da mogu prikazati sve realne boje i omogućiti njihov vjeran prikaz u različitim modelima boja.

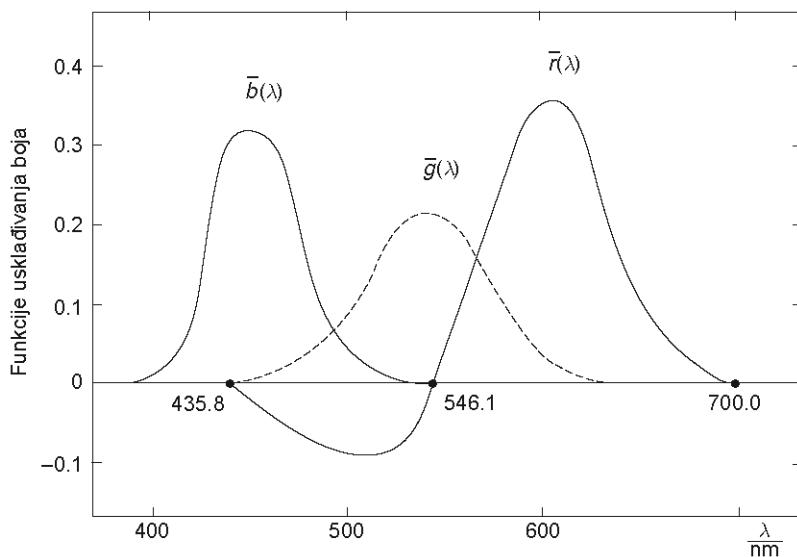
Glavni cilj kolorimetrije je razvoj modela boja koji u potpunosti uzima u obzir ljudsku percepciju boja. Kolorimetrijski model mora zadovoljiti sljedeće uvjete:

- svaka boja mora imati svoje točno određeno mjesto unutar modela. Dvije boje iste kolorimetrijske vrijednosti u definiranim uvjetima se moraju percipirati jednako. Ovaj je zahtjev ostvaren usklađenjem ispitivanja za CIE standardnog promatrača za kut od 2° i 10° .
- kolorimetrijske vrijednosti moraju biti povezane s karakteristikama osnovnih atributa modela boje
- razlika u percepciji mora biti proporcionalna razlici između numeričkih vrijednosti dvaju uspoređivanih boja.

Za modeliranje perceptualne reakcije standardnog promatrača, upotrijebljeni su eksperimentalni podaci dobiveni u trostimulusnom vizualnom eksperimentu korištenjem Grassmanovih zakona. Trostimulusni eksperiment usklađivao je odnose triju stimulusa primarnih boja s namjerom usklađivanja s testnim stimulusom. Time je omogućen opis svake boje kombinacijom primarnih boja aditivne sinteze crvene, zelene i plave prema formuli:

$$Q = R_Q R + G_Q G + B_Q B \quad [4]$$

Slika prikazuje funkcije usklađivanja RGB boja korištenjem dominantnih valnih duljina 700.0, 546.1 i 435.8 nm za primare boje R, G, B, kako bi se uskladila percepcija doživljaja tri osnovne boje s monokromatskim stimulusom koji služi kao original.



Slika 15 Funkcije usklađivanja RGB boja u trostimulusnom prostoru boja¹⁸

Krivulje funkcija usklađivanja boje imaju nejednak vrh krivulje, što predstavlja različitu osjetljivost tri podudarajuća očna fotoreceptora. Samo crvena krivulja na oko 522 nm ima negativni predznak, kao posljedicu vanjskog miješanja krivulja. Ako specifikacija podražaja odgovara valnoj duljini primara, druga dva primara i njihove funkcije su 0. Te vrijednosti odgovaraju valnim duljinama od 435.8, 546.1 i 700 nm.

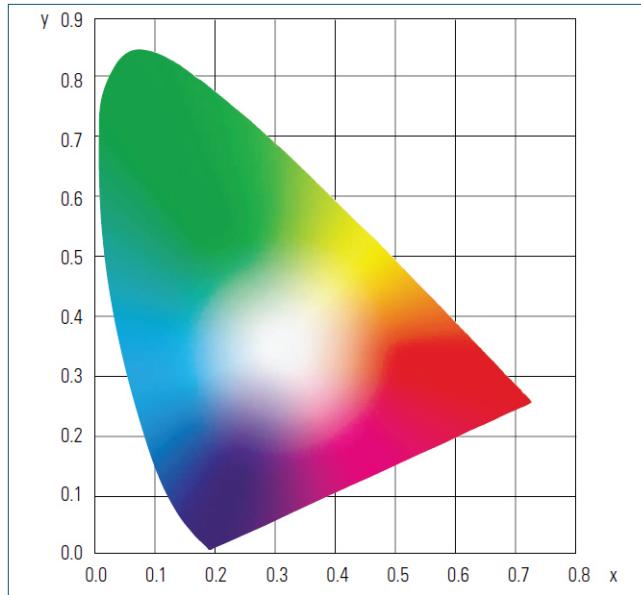
Potrebno je napomenuti da su trostimulusna ispitivanja izvršena na nekoliko ljudi, pod kutom gledanja od 2° i u tamnoj prostoriji. Ostala istraživanja još nisu provedena.

CIE modeli boja

CIE znači Commission Internationale de l'Eclairage (Međunarodno udruženje za osvjetljenje). To je međunarodna agencija koja razvija standarde za kolorimetriju.

Za točnu reprodukciju boja potrebno je razumjeti percepciju ljudskog vida. U tu su svrhu razvijeni matematički sustavi boja CIE XYZ i CIE Lab. Kod njih je skala boja definirana u skladu s ljudskim vidom. Određene vrijednosti boja uvijek definiraju istu boju. Ti su sustavi boja neovisni o uređajima koji ih reproduciraju, jer su zasnovani na tome kako ih vidi promatrač.

Korištenjem brojčanih vrijednosti za određivanje boja moguće je definirati raspon ljudskog vida.



Slika 16 CIE dijagram kromatičnosti¹

CIE XYZ dobiven je mjeranjima izvršenim na ljudima. Ispitanici su gledali bijeli ekran, s jedne strane osvijetljen referentnom lampom, a s druge monokromatskim izvorom crvenog, zelenog i plavog svjetla. Ispitanik je trebao namjestiti crveno, zeleno i plavo svjetlo sve dok nije dobio istu boju kao i referentna boja. Postupak je ponovljen s istim ispitanicima i intenzitetima svjetla, samo pod različitim osvjetljenjima. Nastao je CIE sustav za određivanje boja (CIE color matching functions), koji opisuje kako promatrač vidi boju.

CIE XYZ vrijednosti računaju se na temelju sustava za određivanje boja. Vrijednosti se prilagođavaju trenutnom osvjetljenju. Kada se cijeli sustav podesi, bijela površina uvijek ima vrijednost $Y = 100$.

$$X = k \sum_{i=1}^N S(\lambda_i) R(\lambda_i) \bar{x}(\lambda_i) \Delta \lambda \quad [5]$$

$$Y = k \sum_{i=1}^N S(\lambda_i) R(\lambda_i) \bar{y}(\lambda_i) \Delta \lambda \quad [6]$$

$$Z = k \sum_{i=1}^N S(\lambda_i) R(\lambda_i) \bar{z}(\lambda_i) \Delta \lambda \quad [7]$$

gdje su $R(\lambda_i)$ spektralna reflektancija, $S(\lambda_i)$ spektralna snaga distribucije izvora, $x(\lambda_i)$, $y(\lambda_i)$ i $z(\lambda_i)$ standardne funkcije namještanja boje (standard color matching functions) te $\Delta\lambda$ interval valne duljine¹⁸. Spektralna snaga distribucije izvora $S(\lambda_i)$ i standardne funkcije namještanja boje $x(\lambda_i)$, $y(\lambda_i)$ i $z(\lambda_i)$ odabranog standardnog promatrača treba uzeti iz tablice intervala valne duljine $\Delta\lambda$ koja je određena uvjetima mjerena.

Konstanta k ovisi o odabranom izvoru svjetla, standardnoj funkciji namještanja boje $y(\lambda_i)$ i intervalu valne duljine $\Delta\lambda$.

S obzirom da je standardna vrijednost boje mjera za svjetlinu boje, CIE je odredila idealno rasipno polje svjetla kao $Y = 100.000$ za svaki izvor svjetla.

$$k = \frac{100.000}{\sum_{i=1}^N S(\lambda_i) \bar{y}(\lambda_i) \Delta\lambda} \quad [8]$$

Tri standardne vrijednosti XYZ su vrijednosti bez dimenzije, s obzirom da su refleksija i transmisija bez vrijednosti i bez dimenzije. Standardne vrijednosti X i Z nisu podložne daljnjim promjenama uvjeta i mogu se razlikovati od 100.000, što je prikazano na tabeli:

Tabela 1 Standardizirane vrijednosti boje različitih izvora svjetla

Izvor svjetla	Standardni promatrač 2°		Standardni promatrač 10°	
	X _n	Z _n	X _n	Z _n
D65	95,047	108,883	94,811	107,304
A	109,85	35,585	111,144	35,2
C	98,074	118,232	97,285	116,145
FL 2	99,186	67,393	103,279	69,027
FL 7	95,041	108,747	95,792	107,686
FL 11	100,962	64,35	103,863	65,607

Sve standarde vrijednosti boja X, Y, Z nastaju iz tri čimbenika, odgovorna za utjecaj boje na nesvijetleće boje¹⁸:

- izvor svjetla $S(\lambda_i)$

- uzorak boje, određen spektralnom reflektancijom $R(\lambda_i)$ ili transmisijom $T(\lambda_i)$
- promatrač kao standardni promatrač 2° ili 10° .

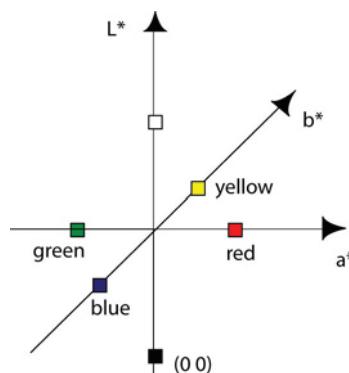
Kao prostor za grafičku industriju razvijen je CIE Lab model boja, u kojem svaki pomak iz jedne koordinate u drugu predstavlja jednak pomak boje. CIE Lab je trodimenzionalni sustav boja, koji sadrži sve vidljive boje ljudskog vida. Isti pomak u jednom području primjerice žutom i u zelenom području daje istu razliku u boji neovisno o lokaciji.

Koordinate su definirane kao:

L - svjetlina

a - crveno - zelena koordinata. Vrijednost $+a$ definira crvenu, $-a$ zelenu

b - žuto - plava koordinata. Vrijednost $+b$ definira žutu, $-b$ plavu.



Slika 17 Prikaz Lab sustava boja

CIE Lab nije potpuno uniforman. Istraživanja su pokazala da je standardni promatrač osjetljiviji na razlike u tonu nego u zasićenju. Najmanje je osjetljiv na svjetlinu.

Nove vrijednosti nastaju iz empirijskih jednadžbi:

$$L^* = 116 \cdot f(Y/Y_n) - 16 \quad [9]$$

$$a^* = 500 \{f(X/X_n) - f(Y/Y_n)\} \quad [10]$$

$$b^* = 200 \{f(Y/Y_n) - f(Z/Z_n)\} \quad [11]$$

Izračun L^* , a^* i b^* vrijednosti vrši se na osnovi CIE XYZ vrijednosti i odabranog izvora svjetla. Funkcije f izračunavaju se na osnovi:

$$f(q) = \begin{cases} q^{1/3} & \text{za } q > (24/116)^3 \\ (841/108) \cdot q + 16/116 & \text{za } q \leq (24/116)^3 \end{cases}$$

[12]

gdje q predstavlja odnose X/X_n , Y/Y_n i Z/Z_n . Treći korijen je određen psihološkim stimulusom iz Weber-Fechnerova zakona. Brojevi u nastavku određeni su Paulijevim produžetkom¹⁹, po kome je konstantnost $f(q)$ i njegova derivata $f(q)'$ postignuta na položaju $(24/116)^3$.

1.2.4.4. Kolorimetrija

Čovjekov osjećaj vida i njegova percepcija okoline znatno su obogaćeni njegovom percepcijom boje. Iako je načinjen veliki napredak u objašnjenju nastanka boje, ljudskog vida i ljudske percepcije, mnogo je toga ostalo nedefinirano. Kao posljedica našeg nedovoljnog poznavanja, za praktičnu upotrebu boje potrebno je odrediti određena empirijska pravila.

Određivanjem tih pravila bavi se znanost o boji - kolorimetrija. Zasnovana na dugogodišnjim eksperimentima i promatranju, pravila čine empirijsku osnovu kolorimetrije i daleko su od savršenih. Gledano iz perspektive fizike, osjećaj određene boje uzrokuje određena valna duljina zračenja u vidljivom dijelu spektra ljudskog vida. Te izmjerene vrijednosti su ujedno i početne kod kolorimetrijskih mjeranja. Kod čovjeka na boju utječe i pozadina gledanog predmeta, osvjetljenje i kut gledanja. Početni zadatak kolorimetrije bio je definirati samo te valne duljine svjetla, ali je razvojem same znanosti došlo do spoznaje da kod čovjeka boju definira i njegova subjektivna percepcija boje. To je utjecalo na dodatna istraživanja koja traju i danas. Razvojem teorija percepcije i znanosti poput fizike, kemije, biologije i matematike dolazi do razvoja matematičkih modela boja koji u sebi sadrže i predviđanja kako će boju vidjeti čovjek. Iako neprecizna, ona nam daju korisne rezultate koji se koriste u svakodnevnom životu i dalnjem proučavanju boje.

Kao znanstveno područje kolorimetrija proučava utjecaj fizikalno definiranog svjetla pod strogo definiranim uvjetima na percepciju standardnog promatrača. Pokušava definirati svjetlo pod određenim uvjetima u malom broju parametara (od tri do četiri), ovisno o broju fotoreceptora za koje vjerujemo da stvaraju osjećaj boje. Većinom pokušava predvidjeti male razlike u obojenju između dva

uzorka kada se oni ne podudaraju. Cilj kolorimetrije nije predvidjeti koju će boju promatrač vidjeti, nego definirati fizikalne jedinice stimulusa boje²⁰.

Kolorimetriju možemo podijeliti na vizualnu i instrumentalnu. S obzirom da je teško opisati boju određene distribucije spektralne energije, potrebno je opis boje vezati uz ljudsku percepciju.

Kada opisujemo boju predmeta koristimo subjektivne izraze poput svijetlotamno, bijedo-jako, bijelo-crno, te boje poput crveno, zeleno, žuto ili plavo. Zbog toga je potrebno specificirati i izmjeriti boju u skladu s ovim subjektivnim opisima običnog promatrača.

Za postizanje i održavanje kvalitete otiska potrebno je vršiti očitanja tijekom proizvodnje grafičkog proizvoda. Postoje tri glavne vrste strojnog mjerjenja obojenja: spektralno, kolorimetrijsko i denzitometarsko mjerjenje. Uz njih postoje i dodatna mjerjenja poput kutova refleksije, površina materijala i sl²⁰.

Tijekom godina razvijeni su mnogi modeli. Prikaz većine njih vidljiv je u sljedećoj tabeli²¹:

Tabela 2 Povijesni prikaz većine modela razlike boja od razvoja CIE kolorimetrijskog sustava

Kategorija formule	Prilagođeno Munsellovim podacima	Prilagođeno MacAdam podacima	Linearna transformacija do	Drugo
Prije 1976				
1935			Judd	
1936	Index of Fading			
1937			MacAdam	
1939	Balinkin			
1942			JHNBS	
1943	Munsell Renotation			
1944	ANLAB			
1946	Saunderson & Milner			
1951	Godlove			
1955				DIN
1958	Reilley cube root	Simon-Goodwin	Hunter LAB	
1963			CIEU*V*W*	
1965		Friele		
1967		FMC-I		
1969	Moton cube root			
1971	MLR	FMC-II		

Kategorija formule	Prilagođeno Munsellovim podacima	Prilagođeno MacAdam podacima	Linearna transformacija do	Drugo
1972	MCR			
1974	DeltaEa			OSA
1976	CIELAB		CIELUV	
Poslije 1976				
1978		FCM		
1980	JPC79	LABHNU		
1984	CMC	ATD		
1986		SVF		
1987	BFD			
1991	KC-III			
1995	CIE94			
1997	LCD			
1999	Kuehni			
2001	CIEDE2000	Oleari		

CIE standardni promatrač

Među definiranim vrijednostima, crvena komponenta jedina pokazuje negativnu vrijednost, što nastaje kao posljedica miješanja primarnih boja. Ovisno o podražaju boja, crvena vrijednost može pokazati pozitivni ili negativni predznak, što znači da se kolorimetrijski ne može jasno definirati. Negativne se vrijednosti ne mogu izbjegći zbog distribucije spektralne energije izvora svjetla.

Kao posljedica nemogućnosti jasne definicije boja, 1931. godine CIE je definirala takozvane virtualne primarne boje XYZ¹⁸. One su izvedene iz numeričkih transformacija R, G, B primarnih boja, tako da zadovoljavaju sljedeće kriterije:

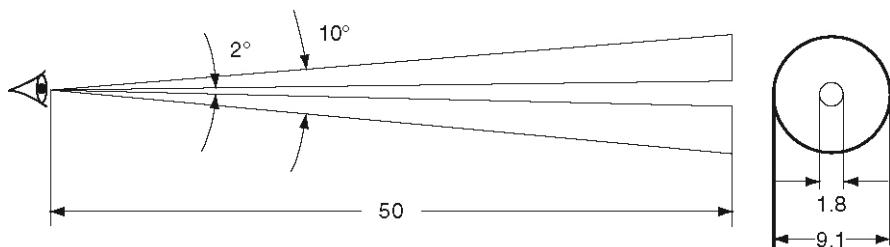
- vrijednosti X, Y, Z međusobno su nezavisne i ne mogu se dobiti miješanjem
- novi model boja uvijek ima vrijednost jednaku ili veću od nule i nastavlja sa na prethodne funkcije mjerjenja boja prema transformaciji standardnih vrijednosti boje
- vrijednosti XYZ namještene su tako da im je vrijednost zasićenja spektra jednaka: $X = Y = Z$

- dvije primarne boje tako su odabrane da je samo vrijednost Y proporcionalna svjetlini boje.

Nove vrijednosti XYZ zovemo standardne vrijednosti boje (*standard color matching functions*), a povezane su s prijašnjim vrijednostima matricom:

$$\begin{pmatrix} \bar{x}(\lambda) \\ \bar{y}(\lambda) \\ \bar{z}(\lambda) \end{pmatrix} = \begin{pmatrix} 2.768892 & 1.751748 & 1.130160 \\ 1 & 4.590700 & 0.060100 \\ 0 & 0.056508 & 5.594292 \end{pmatrix} \begin{pmatrix} r(\lambda) \\ g(\lambda) \\ b(\lambda) \end{pmatrix} \quad [13]$$

Ove su standardne vrijednosti boje povezane sa standardnim promatračem 2° , isto nazvanim i CIE 1931 promatrač. Na temelju njih se izračunavaju vrijednosti XYZ.



Slika 18 Prikaz veličine uzorka i udaljenost kod CIE 1931 i CIE 1964 standardnog promatrača (2° i 10°).

Uzorak kod 2° promatrača je malen, zato što pokriva samo područje zjenice, gdje je najveća koncentracija čunjica u oku. Iako je najveća koncentracija čunjica u zjenici oka, ona nije dovoljna za pravilnu procjenu boje, pa je 1964. godine CIE predstavio promatrača 10° , poznatog kao CIE 1964. promatrač.

Tabela 3 Usporedba standardnih promatrača 2° i 10°

Promatrač	2°	10°
Veličina uzorka	1,8 cm	8,8 cm
Udaljenost gledanja	50 cm	50 cm
Podudaranja valnih duljina		
R	700.0	645.2
G	546.1	526.3
B	435.8	444.4

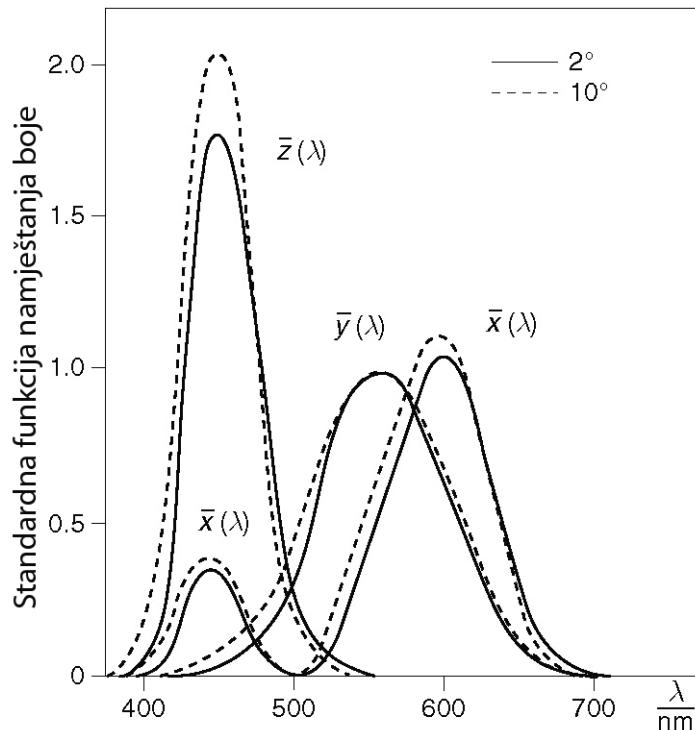
Dalnjim istraživanjima CIE je preporučila 2° promatrača za vizualne kutove 1 do 4° , a promatrača 10° za vizualne kutove iznad 4° . Promatrač 10° definiran je matricom:

$$\begin{pmatrix} \bar{x}_{10}(\lambda) \\ \bar{y}_{10}(\lambda) \\ \bar{z}_{10}(\lambda) \end{pmatrix} = \begin{pmatrix} 0.341080 & 0.189145 & 0.387529 \\ 0.139058 & 0.837460 & 0.073160 \\ 0 & 0.039553 & 1.026200 \end{pmatrix} \begin{pmatrix} \bar{r}_{10}(\lambda) \\ \bar{g}_{10}(\lambda) \\ \bar{b}_{10}(\lambda) \end{pmatrix} \quad [14]$$

Vrijednosti se od promatrača 2° razlikuju po broju 10 u indeksu. Numeričke vrijednosti u formuli za promatrača 2° i 10° nastale su kao posljedica činjenice da pripradaju različitim primarnim bojama i različitim poljima gledanja.

Maksimum funkcija je definiran na $\lambda = 555$ nm kao vrijednost 1.0. Ista boja pod drugim promatračem izgleda različito, zbog različitih vidnih polja promatrača.

Njihova nelinearna krivulja onemogućava pretvaranje vrijednosti iz jednog promatrača u drugog.

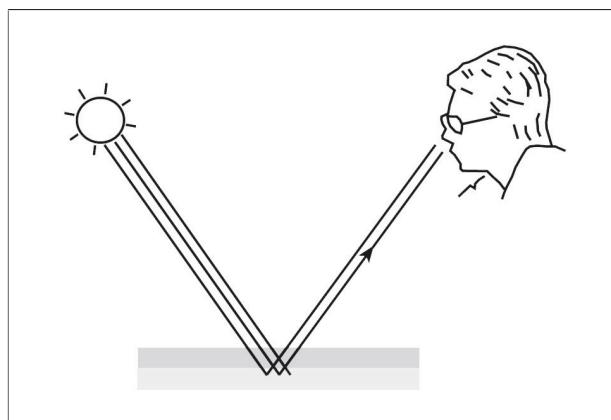


Slika 19 Usporedni prikaz osjetljivosti standardnih promatrača CIE 1931 i CIE 1964. Skoro sve formule za razliku obojenja razvijene su s ciljem mjerjenja razdaljine između dvije boje ili kalibracijskih klinova. Sve se više javlja potreba mjerjenja razlika između parova slika. Trenutne formule ne podržavaju komponente za prostorne varijacije u slikama²².

Vizualno ocjenjivanje otiska

Kao jedini način kontrole kvalitete otisaka, dugi niz godina korišteno je vizualno ocjenjivanje. S obzirom da vizualna kontrola ovisi o promatraču, ona ne zadovoljava potrebe današnje industrijske proizvodnje. Za kvalitetno vizualno ocjenjivanje potrebno je definirati standardnog promatrača i standardni izvor svjetla pri kojem se provodi ocjenjivanje kvalitete otiska. Subjektivno vizualno ocjenjivanje unosi u ocjenu i psihološki element.

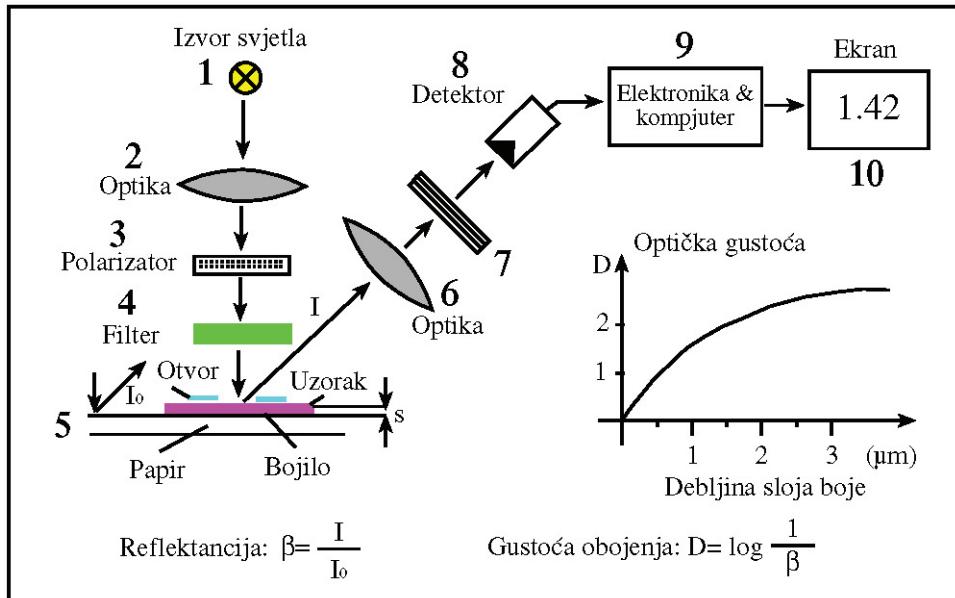
Jedino rješenje za objektivno ocjenjivanje kvalitete otiska je mjerljivost. Otisak se mjeri denzitometarski ili spektrofotometarski s ciljem postizanja objektivno kvalitetnog otiska kroz cijelo vrijeme tiska¹



Slika 20 Princip vizualnog ocjenjivanja

Denzitometarsko mjerjenje otiska

Denzitometrija je učinkovita metoda mjerjenja nanosa boje na tiskovnu površinu. Pouzdana je s crno-bijelim reprodukcijama i procesnim bojama cijanom, magentom, žutom i crnom.



Slika 21 Prikaz rada denzitometra

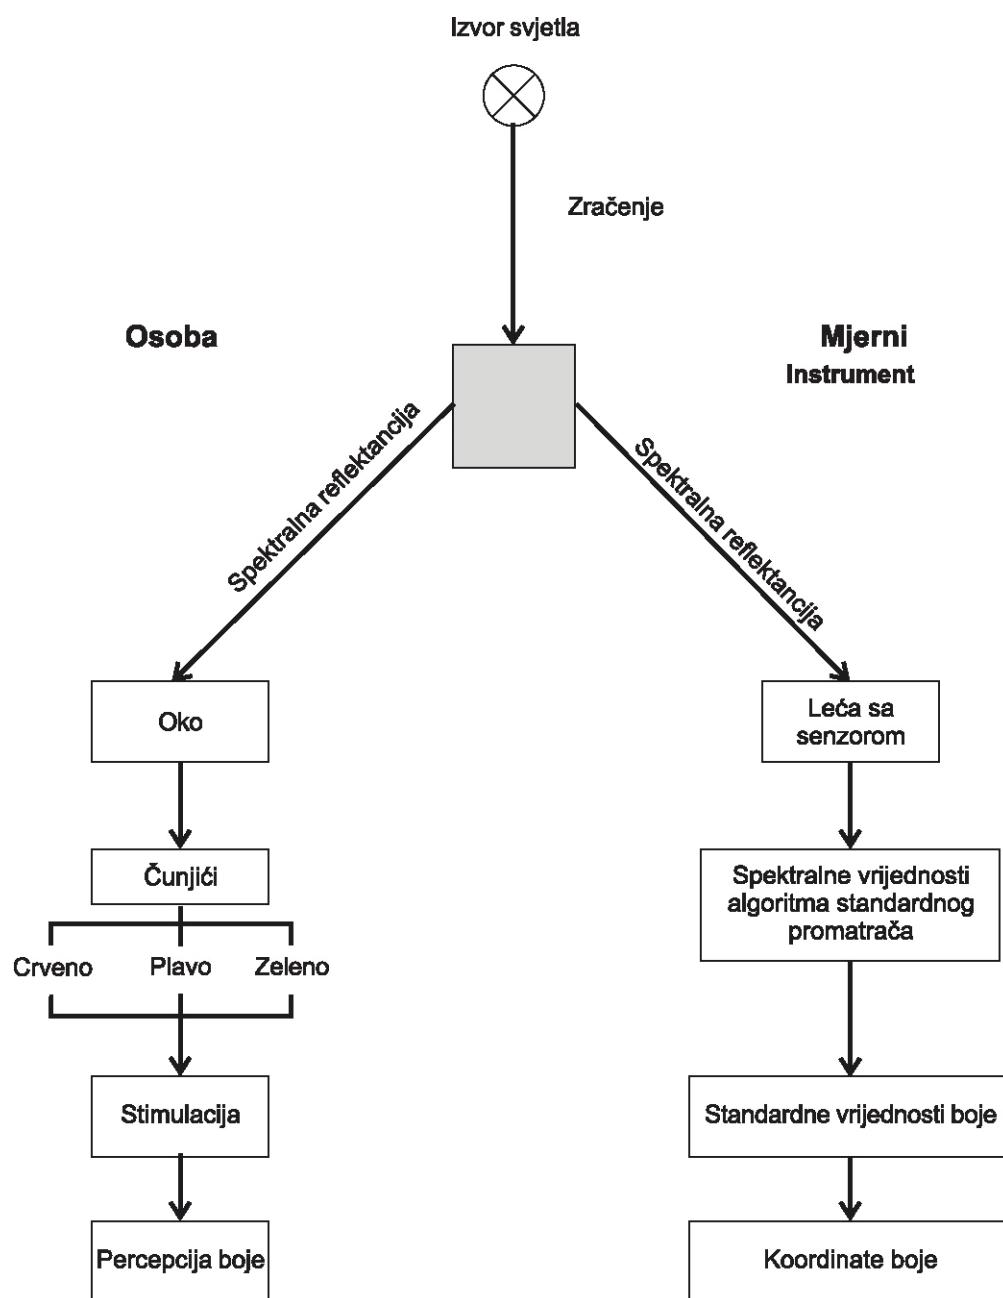
Postoje dvije vrste denzitometa: transmisijski denzitometri koji mjere zacrnjenje filma i refleksioni denzitometri koji mjere zacrnjenje otiska. Kod refleksijskih denzitometa izvor svjetla osvjetjava mjereno polje, svjetlost se jednim dijelom apsorbira u boju, a dio se reflektira. Reflektirani dio svjetla očitava denzitometar, koji ga pretvara u jedincu zacrnjenja. Za očitanje cyana, magente i žute koriste se filteri za boju. Loša strana denzitometra je što njegovi podaci nemaju nikakve sličnosti s ljudskom percepcijom. Isti nanos boje ne daje uvijek isti osjećaj boje. Čim se upotrijebi druga boja ili papir osjećaj boje se mijenja. Zato se probni otisci otisnuti na drugom papiru ili s drugom bojom ne mogu koristiti za namještanje bojanika. Javlja se i problem kod mjerjenja spotnih boja, zbog nepostojanja prikladnih filtera, što dovodi do prikazane niske gustoće zacrnjenja i netočno prikazanih vrijednosti prinosa boje rasterskih elemenata.²³

Spektrofotometrija

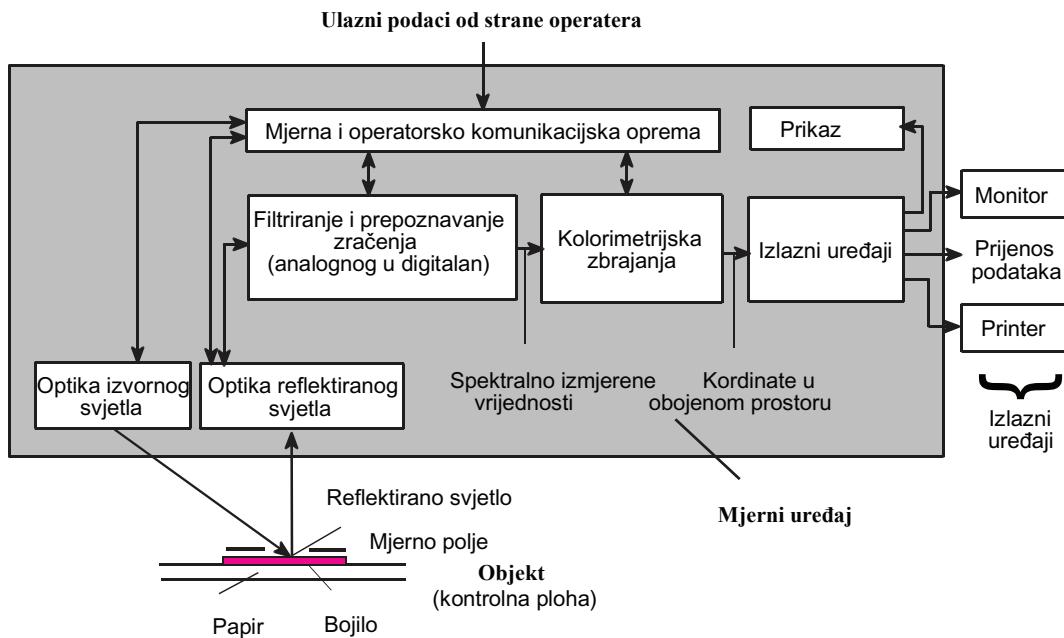
Spektrofotometrija je znanost mjerjenja spektralne refleksije. U grafičkoj industriji spektrofotometarski mjerimo vidljivi dio spektra. Mjerjenje se provodi očitavanjem vrijednosti u svim valjnim duljinama vidljivog dijela spektra, za razliku od denzitometra, koji mjeri samo ukupno zasićenje mjerenoj polja.

Način rada svih kolorimetrijskih uređaja je zasnovan na vidu i percepciji čovjeka. Kolorimetrijski uređaji emuliraju čovjekov prirodni vid. Otisnuti uzorak

se osvjetjava pod standardnim osvjetljenjem i reflektirano svjetlo prolazi kroz leće i dolazi na senzor, koji očitava svjetlo i šalje u računalo. Podaci se potom obrađuju korištenjem CIE algoritama za standardnog promatrača. Dobivene CIE XYZ vrijednosti potom se pretvaraju u prostor boja, primjerice CIELAB.



Slika 22 Usporedba rada vida i spektrofotometra²³



Slika 23 Prikaz rada spektrofotometra¹

1.2.4.5. Modeli za matematičko određivanje razlike boja

Razvojem znanosti i modela boja pojavila se potreba matematičkog određivanja razlike između dvije mjerene boje¹¹.

Odbor za mjerjenje boje "Society of Dyers and Colourists" razvio je 1984. godine formulu za razliku boje "CMC difference metric". Usporedno je formulu razvijala organizacija CIE, koja je 1994. objavila formulu $\Delta E94$, a kasnije i $\Delta E2000$.

CMC formula za razliku boja

CMC formula je razrada CIE L*a*b formule za razliku boja. Bolje je podešena na djelovanje zasićenih boja zbog vidljivosti malih pogrešaka u bijelom balansu slika²⁴. Ljudskom oku osjetljivost na male razlike kod sličnih akromatskih signala daje akromatski poticaj koji nadjačava crveno-zelene i žuto-plave signale.

Mjerenje je potrebno provoditi pod D65 osvjetljenjem, uz vidni kut 10° standardnog promatrača. Za izračun CMC razlike boja prvo se računaju dvije međuvrijednosti nastale iz CIE LCH vrijednosti¹¹:

$$f = \sqrt{\frac{(\bar{C}^*)^4}{(\bar{C}^*)^4 + 1900}} \quad [15]$$

$$t = \begin{cases} 0.36 + 0.4 |\cos(35 + \bar{H})| & \text{ako je } H \leq 164^\circ \text{ v } H > 345^\circ \\ 0.56 + 0.2 |\cos(168 + \bar{H})| & \text{ako je } 164^\circ < \bar{H} \leq 345^\circ \end{cases} \quad [16]$$

Vrijednosti S_L , S_C i S_H određuju alipsoid u LCH prostoru boja:

$$S_L = \begin{cases} \frac{0.040975L^*}{1 + 0.01765\bar{L}^*} & \text{za } L^* > 16 \\ 0.51 & \text{za } L^* \leq 16 \end{cases} \quad [17]$$

$$S_C = \frac{0.0638\bar{C}^*}{1 + 0.0131\bar{C}^*} + 0.638 \quad [18]$$

$$S_H = S_C(f\bar{t} + 1f) \quad [19]$$

Vrijednosti S_L , S_C i S_H određuju elipsoid u LCH prostoru boja:

U gornjim formulama $L^* = 0.5(L_1 + L_2)$ slično se računaju i C i H. Razlika ΔE_{CMC} se računa pomoću:

$$\Delta L_{CMC} = \frac{L_1^* - L_2^*}{lS_L} \quad [20]$$

$$\Delta C_{CMC} = \frac{C_1^* - C_2^*}{cS_C} \quad [21]$$

$$\Delta H_{CMC} = \frac{H_1^* - H_2^*}{S_H} \quad [22]$$

$$\Delta E_{CMC} = \sqrt{\Delta L_{CMC}^2 + \Delta C_{CMC}^2 + \Delta H_{CMC}^2} \quad [23]$$

Ova formula definira vidljivu razliku između dvije boje prema vrijednostima $L_1C_1H_1$ i $L_2C_2H_2$.

Formula za razliku obojenja CIE 1994

Načinjena s ciljem ujednačenja mjerjenja razlike boja, CIELAB ΔE L^*a^*b jednadžba zasnovana je na brojnim empirijskim podacima. Jedna od više

korištenih modifikacija je CMC formula za razliku boja⁵, koja je zasnovana na vizualnim eksperimentima razlike boja kod tkanina.

Napredak u istraživanju razlike boja pokazao je da je moguće različito definirati razlike u tonu, zasićenju i svjetlini u svrhu postizanja veće točnosti izmjerениh podataka. Razlika u dobivenim rezultatima objašnjena je različitim uvjetima istraživanja. To je sve uzeto u obzir pri razvoju CIE94 modela razlike boja, pa ovaj model uključuje i standardne uvjete pod kojima se rade istraživanja²⁰.

Referentni uvjeti su:

- osvjetljenje: D65
- snaga svjetlosti: 1000 lx
- promatrač: normalni vid u boji
- pozadina: siva s L* 50
- način promatranja: predmet
- veličina uzorka: iznad 4°
- odvajanje uzorka: jedan uz drugi s rubovima u izravnom kontaktu
- raspon razlika u obojenju: 0 – 5 CIELAB jedinica
- struktura uzorka: jednolična površina bez vidljivog uzorka

CIE 1994 formulu za izračun razlike boja između dva uzorka definiramo kao²⁰:

$$\Delta E_{94}^* = \left[\left(\frac{\Delta L^*}{k_L S_L} \right)^2 + \left(\frac{\Delta C_{ab}^*}{k_C S_C} \right)^2 + \left(\frac{\Delta H_{ab}^*}{k_H S_H} \right)^2 \right]^{1/2} \quad [24]$$

gdje je:

$$S_L = 1 \quad [25]$$

$$S_C = 1 + 0.045C_{ab}^* \quad [26]$$

$$S_H = 1 + 0.015C_{ab}^* \quad [27]$$

pri čemu je C_{ab}^* zasićenje standardnog uzorka. U definiranim uvjetima ispitivanja K_L , K_C i K_H imaju vrijednost 1. Kada su vrijednosti K_L , K_C i K_H različite od standarda, nakon simbola treba staviti simbol poput CIE94(2:1:1).

Formula za razliku obojenja ΔE 2000

Formulu za izračunavanje industrijskih razlika u boji, CIEDE2000 izdala je organizacija CIE 2001. godine²⁵. Formula osigurava unaprijeđene postupke za izračun industrijskih razlika u boji. Metodologija za razvoj formule uzeta je iz eksperimentalnih podataka razlike boja iz istraživanja koja su proveli Luo, Cui i Rigg²⁶.

Razvojem matematičkih modela, zasnovanih na istim korijenima (CIE vrijednostima), javila se mogućnost i potreba za usporedbom dobivenih vrijednosti²⁷. Donešena je i podjela vrijednosti pa je tako u proizvodnji vrijedi sljedeće⁹:

0-2 - smatra se nedostižnom zbog mnogih varijabli u tiskarskoj proizvodnji

3-6 - je dobra komercijalna kvaliteta

7- je velika razlika u boji.

Formula uključuje interaktivni odnos između razlike tona i zasićenja za bolje predviđanje razlika plave boje i skalirajući faktor za bolje predviđanje kretanja skoro neutralnih razlika boja. Vrijednost se računa da su L' , C_{ab} i h_{ab} aritmetička sredstva za L' , C_{ab} i h_{ab} vrijednosti za uzorke 1 i 2.

$$G = 0.5 \left(1 - \sqrt{\frac{\overline{C}_{ab}^*}{\overline{C}_{ab}^{*7} + 25^7}} \right) \quad [27]$$

$$L' = L^* \quad [29]$$

$$a' = (1+g)a^* \quad [30]$$

$$b' = b^* \quad [31]$$

$$C_{ab}^* = \sqrt{(a')^2 + (b')^2} \quad [32]$$

$$\Delta h'_{ab} = \left(\frac{180^\circ}{\pi} \right) \tan^{-1} \frac{b'}{a'}, \quad [33]$$

$$\Delta L' = L'_1 - L'_2 \quad [34]$$

$$\Delta C'_{ab} = C'_{ab,1} - C'_{ab,2}, \quad [35]$$

$$\Delta h'_{ab} = h'_{ab,1} - h'_{ab,2} \quad [36]$$

$$\Delta H'_{ab} = 2\sqrt{C'_{ab,1}C'_{ab,2}} \sin\left(\frac{\Delta h'_{ab}}{2}\right) \quad [37]$$

$$\Delta H'_{ab} = \sqrt{\left(\frac{\Delta L'}{k_L S_L}\right)^2 + \left(\frac{\Delta C'}{k_C S_C}\right)^2 + \left(\frac{\Delta H'}{k_H S_H}\right)^2 + R_T \left(\frac{\Delta C'_{ab}}{k_C S_C}\right)^2 \left(\frac{\Delta H'}{k_H S_H}\right)^2} \quad [38]$$

gdje je

$$S_L = 1 + \frac{0.015(\bar{L}' - 50)^2}{\sqrt{20 + (\bar{L}' - 50)^2}} \quad [39]$$

$$S_C = 1 + 0.045\bar{C}_{ab}^* \quad [40]$$

$$S_H = 1 + 0.015\bar{C}_{ab}^* T \quad [41]$$

s

$$T = 1 - 0.17 \cos(\bar{h}_{ab}) - 30^\circ + 0.24 \cos(2\bar{h}_{ab}) + 0.32 \cos(3\bar{h}_{ab}) + 6^\circ - 0.20 \cos(4\bar{h}_{ab}) + 63^\circ \quad [42]$$

i

$$R_T = -\sin(2\Delta\theta)R_C \quad [43]$$

gdje je

$$\Delta\theta = 30 \exp\left[-\left(\frac{\bar{h}_{ab} - 275}{25^\circ}\right)^2\right] \quad [44]$$

$$R_C = 2\sqrt{\frac{\bar{C}_{ab}^{*7}}{\bar{C}_{ab}^{*7} + 25^7}} \quad [45]$$

Pri izračunu h_{ab} i \bar{h}_{ab} koristi se jedinica stupanj°. Ako je potrebno, svi se kutevi prebacuju u pozitivne dodatkom 360°. S obzirom da je kut zasićenja periodička funkcija od 360°, \bar{h}_{ab} se računa na način da se provjeri je li razlika kutova između 2° i 180°. Ukoliko je \bar{h}_{ab} aritmetička sredina, a ako nije od šireg kuta se oduzima 360° i određuje aritmetička sredina. Primjerice, kod kuteva od 90° do 360°, aritmetička sredina se računa tako da prvo oduzmemo 360° od 300°. Dobivši -60°, uzimamo aritmetičku sredinu s 90 ° i dobijamo ispravnu aritmetičku sredinu (-60=+90°)/2 = 15.

1.3. Tehnike ispisa

1.3.1. Razvoj tiskarstva

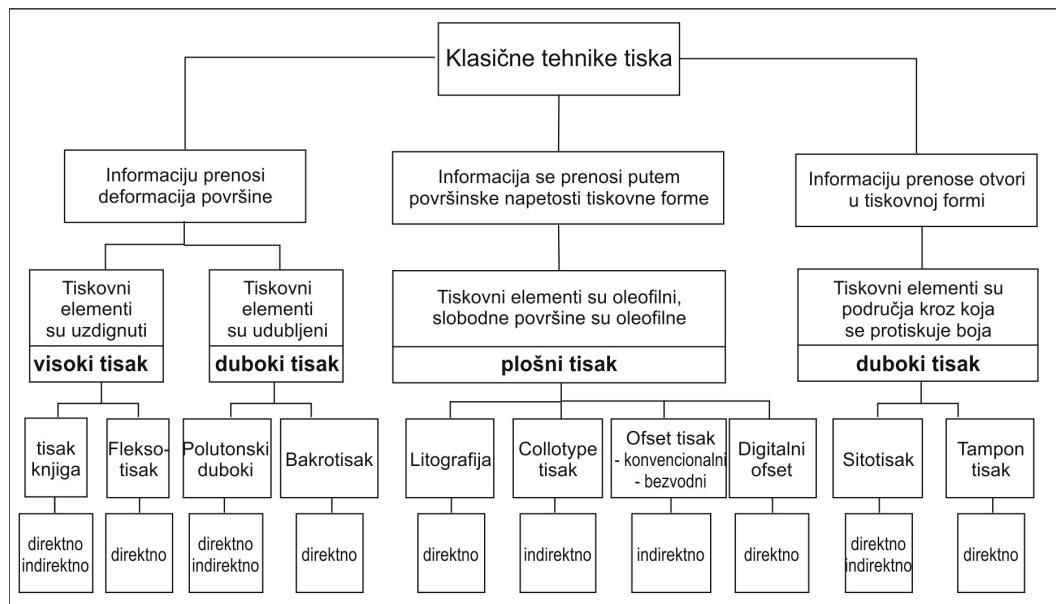
Tijekom razvoja ljudskog društva, nastali su brojni načini umnožavanja ljudske misli i znanja. Od ručne izrade jednog primjerka, razvijale su se brojne tehnike umnožavanja, a kao najpogodniji medij pokazao se papir, čiji se počeci prate od 105. godine u Kini. Zajedno s razvojem proizvodnje papira razvijaju se i tehnike tiska. Prvi poznati otisci potječu iz kineske dinastije Tang iz 700 godine. Kao prva tiskovna forma javlja se u Kini u 11. stoljeću reljefnidrvorez. Daljnji doprinos donio je Johann Guttenberg izradom pojedinačnih slovnih znakova i konstrukcijom prve tiskarske preše 1444. godine. To je ujedno i početak suvremene grafičke industrije²⁸.

Daljnji razvoj i prijelaz u industrijsku granu donio je Alois Senefelder razvojem litografije 1796. godine, kao prve tehnike plošnog tiska. Litografija je ujedno i temelj tehnike ofsetnog tiska, kao glavne tiskarske tehnike 20 stoljeća²⁹.

Danas su komercijalne tiskarske tehnike podijeljene na:

- tehnike sa fizičkom tiskovnom formom ili klasične tehnike tiska. Kao glavni predstavnici u ovu skupinu spadaju ofset, fleksotisak, bakrotisak i sitotisak. Promjenom tehnologija udio klasičnih tehnika tiska se smanjuje, a raste udio digitalnih tehnologija. Danas se u industrijskoj proizvodnji koriste ofset i fleksotisak, dok su sitotisak i bakrotisak u znatnom padu.
- NIP (Non impact printing) tehnologija ima virtualnu tiskovnu formu te je pogodna za izradu malih naklada. Tu pripadaju ink-jet tehnologije, elektrofotografija, ionografija, magnetografija, termografija i fotografija. Kao glavni predstavnici danas se koriste ink-jet i elektrofotografske tehnike tiska.

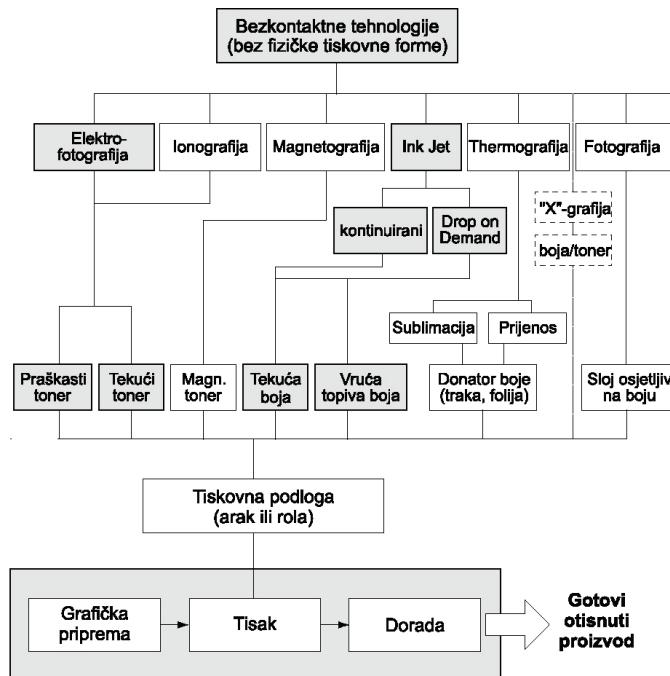
Prikaz klasičnih tehnika tiska vidljiv je na sljedećoj slici¹:



Slika 24 Prikaz klasičnih tehnika tiska

Princip klasičnih tehnika tiska zasniva se na fiksnoj tiskovnoj formi. Tiskovna forma se izrađuje fotokemijskim procesima te se gotova stavlja u tiskarski stroj. Sve se informacije prenose s tiskovne forme na tiskovnu podlogu djelomičnim prijenosom bojila s tiskovne forme. Informacije se prenose putem tiskovnih elemenata koji sadrže informacije, pa time i bojila i slobodnih površina koje ne sadrže bojilo.

Prikaz bezkontaktnih (NIP) tehnika tiska vidljiv je sljedećoj slici¹:



Slika 25 Prikaz bezkontaktnih (NIP) tehnika tiska

Vodeći predstavnici NIP tehnologija, ink-jet i elektrofotografija pokrivaju odvojena komercijalna područja:

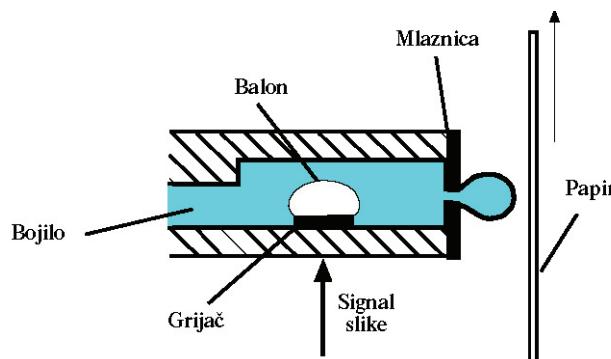
- elektrofotografija: manji formati arka, male naklade. Koristi se za izradu posjetnica, kataloga, letaka i sl.
- ink jet: male naklade velikih formata poput jumbo plakata i malih formata s premalom nakladom za otisak u ofset tehnologiji. Ujedno se koristi i za dobivanje kvalitetnih otisaka poput fotografija i probnih otisaka za kontrolu u tiskarskoj proizvodnji.

1.3.2. Ink-jet tehnologija

Ink-jet je beskontaktna tehnika tiska koja ne zahtijeva prijenosni medij za slikovnu informaciju, kao što je slučaj u elektrofotografiji. Bojilo se nanosi izravno na slikovnu podlogu. Ink-jet tehnologija se dijeli na:

- ink-jet koji formira kapljice bojila na zahtjev, tzv. "drop on demand". Najvažnije "drop on demand" tehnologije su termalni i piezo ink-jet sustavi

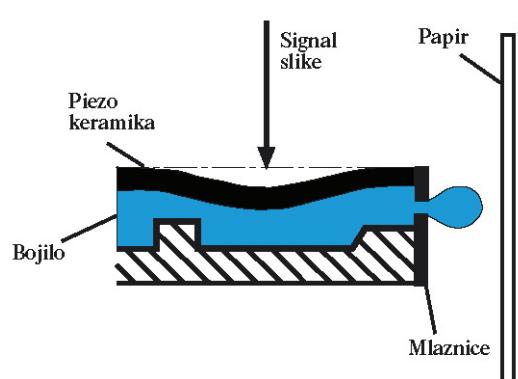
Termalni ink-jet stvara kapljicu grijanjem i isparavanjem tekućine u komori. Nanos bojila ovisi o veličini stvorenog mjeđura, odnosno temperaturi mikrogrijača.



Slika 26 prikaz termalnog ink jeta

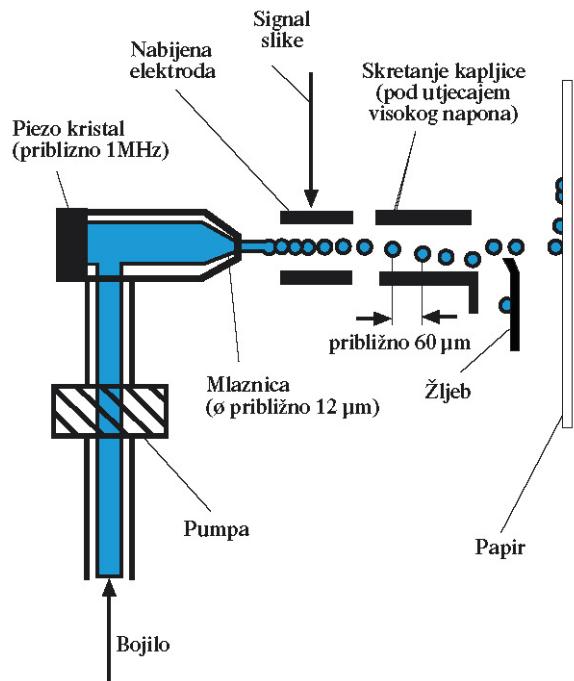
- piezo tehnologija formira kapljicu deformacijom mlazne komore. Računalno slanjem signala piezo elementu izaziva deformaciju samog

piezo elementa. Deformacijom piezo elementa dolazi do smanjenja volumena mlazne komore i dolazi do izbacivanja bojila kroz mlaznicu



Slika 27 Prikaz piezo ink jeta

- kontinuirani ink jet s bojilom koje teče konstantno, ali se bojilo kontrolira električnim nabojem. Nabijene čestice se ulaskom u električno polje skreću i vraćaju natrag u sustav, a nenabijene čestice dolaze na tiskovnu podlogu. Samo mali dio bojila dolazi do tiskovne podloge.



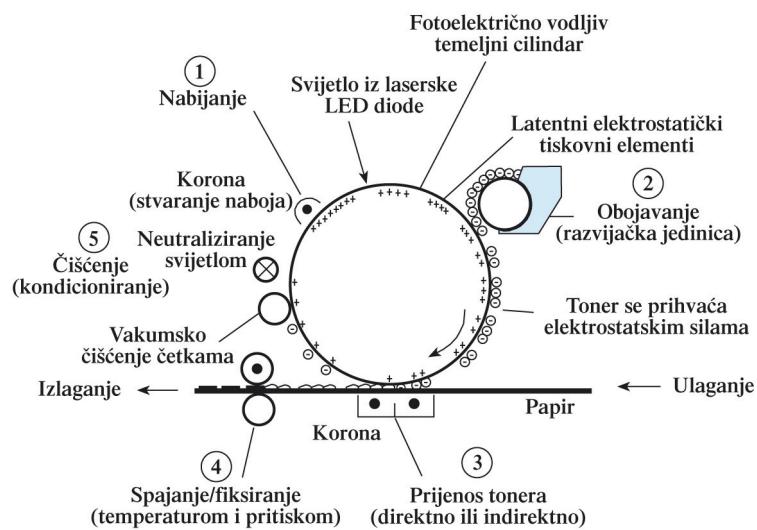
Slika 28 Prikaz rada kontinuiranog ink jeta

1.3.3. Elektrofotografija

Jednu od danas vodećih "non impact printing" tehnologija izumio je Chaster Carlson 1938. godine i patentirao 1942.

Elektrofotografija se temelji na fotoelektričnom efektu, a sam postupak otiskivanja može se podijeliti u 5 faza:

1. nabijanje tiskovne forme
2. nanašanje tonera na tiskovnu formu
3. prenošenje tonera na tiskovnu podlogu
4. fiksiranje tonera na tiskovnoj podlozi
5. čišćenje tiskovne forme od ostataka tonera.



Slika 29 Prikaz elektrofotografskog načina otiskivanja

Virtualna tiskovna forma formira se na pozitivski ili negativski način. Postupak otiskivanja počinje nabijanjem fotoosjetljive površine temeljnog cilindra statickim elektricitetom, s ciljem stvaranja homogene površine na bubenju. Izvorom svjetla (laserom ili LED diodama) mijenja se naboј na tiskovnoj formi i formiraju tiskovne i slobodne površine različitog energetskog potencijala.

Sliku u elektrofotografiji formiraju specijalna bojila - toneri. Toneri dolaze u dvije vrste: tekući i praškasti. Većina tonera je u praškastom obliku. Praškasti toneri su zrnate strukture veličine čestica od 6 do 35 μm . Prijenos tonera na tiskovnu podlogu postiže se koronom, koja elektrostatski privlači toner. Takav je otisak

nestabilan te ga je potrebno fiksirati, što se najčešće postiže u kontaktu sa zagrijanim valjcima, koji ga rastale te time fiksiraju na papir.

Nakon otiskivanja, temeljni cilindar se čisti električki i mehanički i time priprema za ponovno otiskivanje.

Elektrofotografija je danas najzastupljenija tehnika digitalnog tiska za tisk manjih naklada (do 200 primjeraka), poput knjiga, časopisa, posjetnica i sličnih materijala. Pogodna je za tisk na manje formate papira do za sada B3 formata, male naklade i varijabilni tisk poput računa ili personalizirnih oglasa.

1.4. Računalni sustavi

1.4.1. Operativni sustav

Osnovna komponenta suvremenog informatičkog sustava je operativni sustav.

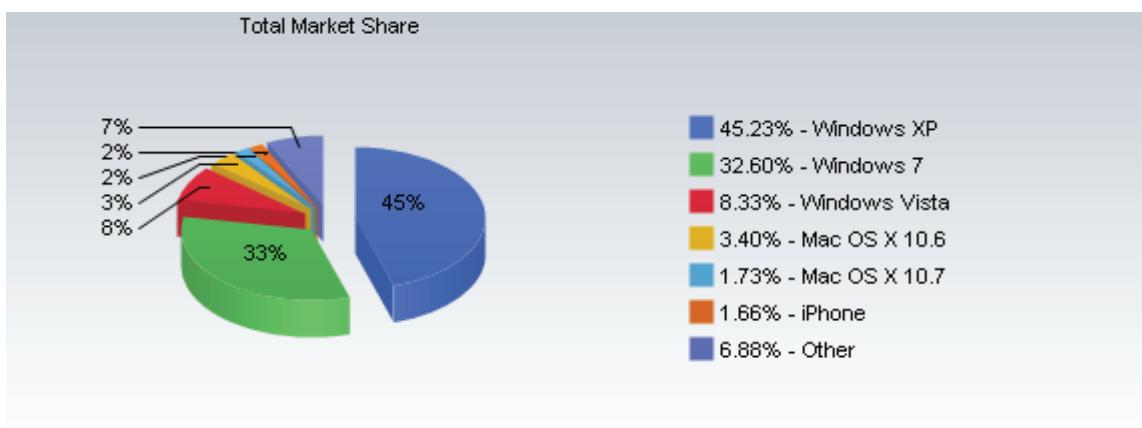
Operativni sustav je program koji omogućuje računalu komunikaciju i rad s računalnim programima. Računalo je beskorisno bez operativnog sustava.

Tabela 4 Razvoj operativnih sustava³⁰

Generacija	Godina	Korišteni elektronički uređaji	Vrsta operativnog sustava i uređaja
Prva	1945-55	Vakuumske cijevi	Utične ploče
Druga	1955-1965	Tranzistori	Batch sustav
Treća	1965-1980	Integrirani krugovi	Višeprogramiranje
Četvrta	Nakon 1980	Visoko integrirani krugovi	Osobno računalo

Operativni sustav radi kao posrednik između ulaznih i izlaznih jedinica te među programima. Danas se nalaze na skoro svim uređajima, od mobilnih telefona do igracijskih konzola, TV uređaja, računala, mrežnih servera do super računala.

U moderne operativne sustave spadaju Android, iOS, Linux, Mac OSX te Microsoft Windows.



Slika 30 Stanje na tržištu operativnih sustava (studen 2011 godine)³¹

Razvoj operativnih sustava unio je velike promjene u grafičku industriju. Kao nadogradnja razvijeni su mnogi alati koji su izmijenili cijelo društvo. Od nekadašnjih efekata rađenih ukopiravanjem slika i primjenom različitih filtera na

reprofotografskim kamerama, današnja grafička industrija primjenjuje mnoge alate koji su izmijenili izgled i koncepciju grafičkog proizvoda.

Današnji operativni sustavi imaju tri važne funkcije³⁰:

- jednostavnost – operativni sustav čini računalo jednostavnijim za korištenje
- efikasnost – omogućuje efiksno korištenje resursa računala
- mogućnost razvoja – mora omogućiti razvoj novih funkcija bez ometanja rada.

Operativni sustav Microsoft Windows za rad s bojom koristi Microsoft Windows Color System (WCS)³². WCS koristi CIECAM02 sustav prikaza boja. To znači da su promjene boje primijenjene na dokument određene poznatim izlaznim uređajima. S obzirom da različiti programi koriste sustave za colour management, postoji pitanje na koji se način boja obrađuje u informatičkim sustavima. Pri razvoju alata programer može odrediti obradu u CIECAM02 modelu prikazu boja ili modeliranje boje prethodno definiranim transformacijama putem ICC profila.

Model CIECAM02 omogućuje istovremeno prilagođavanje prikaza (*run time*) boje trenutno potrebnim realnim uvjetima. Kao osnova za konstrukciju ICC profila uobičajeno se koriste modeli prikaza boja poput CIECAM02. Trenutna prilagodba slike potrebnim uvjetima moguća je i putem ICC profila, ali glavni modeli i danas koriste prethodno definirane transformacije, jer je korisnicima ICC profila uvijek bila važnija kvaliteta, predvidivost i mogućnost ponovne reprodukcije od fleksibilnosti trenutne prilagodbe sustava boja.

Veća kvaliteta koju omogućuju ICC profili nastaje kao posljedica njihove specijalizacije za određeni medij. S obzirom da različiti načini reprodukcije dokumenata po svojim tehničkim karakteristikama drugačije reproduciraju boje, korištenje transformacijskih tabela za točno određen medij daje i točnije rezultate reprodukcije.

Svi modeli boje i kontrola boje putem ICC profila zasnovani su na CIE kolorimetrijskim mjeranjima izvršenima 1931. godine. Time se dobiva osnova za konstantno pretvaranje boja kod mehanizama renderiranja i modela prikaza

boja intergriranih unutar samog profila. Kod trenutne transformacije boja, promjena se vrši kromatskom adaptacijom i podacima o uvjetima promatranja iz ICC profila. ICC profili nastali su kao rezultat opsežnih stručnih istraživanja. S obzirom da su ICC profili postali standard za prikaz boja na mnogim uređajima, Microsoft planira omogućiti podršku za ICC profile unutar WCS sustava. Smjer daljnog razvoja ICC profila ići će prema primjeni trenutnih prilagodbi prikaza boja, uz zadržavanje dosadašnjih preddefiniranih transformacija. Glavni problem koji se javlja kod prevelike kompatibilnosti ovakvih standarda je što dokumenti u kojima se ti standardi nalaze ne smiju previše narasti u memoriskom smislu. Prevelika veličina datoteke profila stvarala bi probleme u prijenosu takvih dokumenata i usporila bi same sustave zbog previše informacija.

1.4.2. Međuspremnik u operativnom sustavu

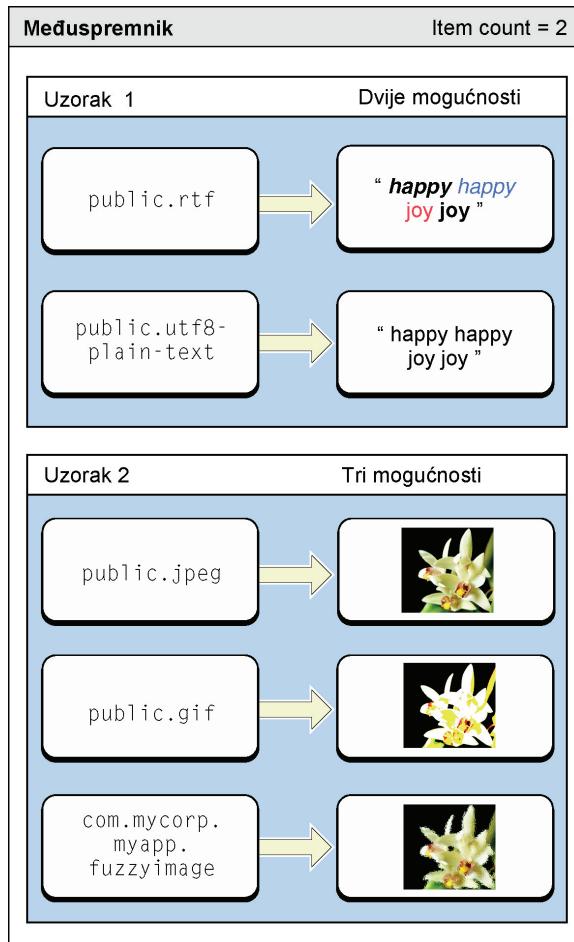
Međuspremnik je dio operativnog sustava koji se može koristiti za privremeno spremanje podataka i za prijenos podataka unutar jednog i između jednog programa u drugi. Memoriski objekt može biti u bilo kojem, tzv. clipboard formatu³³. Sustavi koriste više vrsta formata:

- standardni formati koji su definirani u samom operativnom sustavu (u ovom slučaju Microsoft Windows)
- registrirani formati - da ne dođe do gubitka podataka pri prijenosu u međuspremnik svaki program može stvoriti svoje formate
- privatni formati - koriste se samo unutar programa koji ih koristi i brišu se iz sustava pri gašenju programa.

Tabela 5 Prikaz dijela formata za prijenos slikovnih informacija u operativnom sustavu Microsoft Windows

Konstanta/vrijednost	Opis
CF_DIB 8	Memorijski objekt koji sadrži BITMAPINFO strukturu, nakon koje slijede bitovi slike.
CF_DIBV5 17	Memorijski objekt koji sadrži BITMAPV5HEADER nakon koje slijede podaci o modelu boja slike i bitovi slike.
CF_DSPBITMAP 0x0082	Format zapisa slike povezan s privatnim formatom.
CF_DSPENHMETAFILE 0x008E	Unaprijeđeni metafile format povezan s privatnim formatima.
CF_DSPMETAFILEPICT 0x0083	Metafile slikovni format povezan s privatnim formatom.
CF_METAFILEPICT 3	Veza s metafile slikovnim formatom po definiciji METAFILEPICT strukture.
CF_PALETTE 9	Veza s paletama boja. Svaki puta kad program u međuspremnik smjesti podatke koji ovise ili sadrže paletu boja, trebao bi staviti i tu paletu u međuspremnik. Ako međuspremnik koristi podatke u CF_PALETTE (logičkoj paleti boja), program bi trebao usporediti podatke u međuspremniku s logičkom paletom.
CF_TIFF 6	Tagged-image file format. TIFF slikovni zapis.

Pri prijenosu podataka dolazi do pretvaranja podataka u standard po kojem radi novi program te samim time i do mijenjanja podataka. Moguće je direktno pretvoriti samo međusobno kompatibilne formate, dok je za ostale prvo potrebno pretvoriti podatke u format sustava. U tekstualnim podacima moguće je da dođe do promjene korištenih pisama, boja i sl., ovisno o razlici u standardima između početne i krajnje točke³⁴. Promjena tekstualnih podataka događa se i zbog prilagodbe stilova između dokumenata, čime se podaci prilagođavaju dotičnom dokumentu. Pri unosu u međuspremnik, moguće je vezati podatke za više standarda, što povećava mogućnost ispravnog prijenosa u drugi program.



Slika 31 Slika predstavlja mogućnost različite interpretacije istih podataka³⁵

Pri prijenosu slikovnih podataka dolazi do prilagodbe prostora boja između početne i krajnje točke. U slikovnim podacima dolazi do prilagodbe numeričkih vrijednosti boja prijenosom informacija.

Međuspremnik ima više uloga³⁶:

- najuočljivija je kopiraj-zalijepi, kod koje se podaci odaberu u jednom programu i prenose u isti ili drugi program
- opcija "drag and drop". Odabirom podataka i njihovim vučenjem podaci se automatski prebacuju u međuspremnik. Ako operacija završi s ispuštanjem u odgovarajućem programu koji ih može preuzeti, program uzima podatke iz međuspremnika
- ako se koristi usluga prijevoda, program uzima podatke koje treba obraditi i obrađuje ih u međuspremniku. Obradjeni podaci spremaju se u međuspremnik.

Naizgled jednostavnu funkciju nadopunjava mogućnost različitog predstavljanja podataka, čime se dobije kompleksan dio sustava.

1.4.3. Grafički programi

Postoji više vrsta programa napravljenih za upotrebu u grafičkoj industriji. Svaka od tih vrsta pokriva specifičnu uporabu. Vektorski programi načinjeni su za rad s krivuljama, posebno s malim elementima poput logotipa, koji zahtijevaju veliku preciznost i detalje. Vektorski element moguće je neograničeno povećavati bez gubitka kvalitete, s obzirom da ga čine matematičke krivulje. Rasterski programi predviđeni su za rad s fotografijama ili umjetničkim slikama. Načinjeni su od pixela i njihova kvaliteta ovisi o broju pixela ili razlučivosti. Što je veća razlučivost, može se prikazati više detalja. Rasterske slike se mogu samo smanjivati, čime se odbacuju detalji same slike. Povećanjem računalni sustav mora dodati piksele putem algoritma, što rezultira mutnijom slikom.



Slika 32 Na lijevoj strani slike nalazi se element u krivuljama, a na desnoj u rasteru.

Završetak grafičke pripreme nude programi za prijelom teksta. U njima se spajaju vektorski i rasterski elementi³⁷.

Tabela 6 Podjela programa za grafičku pripremu i predstavnici industrije u podjeli

Programi za obradu vektorskih elemenata	Programi za obradu rasterskih elemenata – slike	Programi za prijelom teksta
Adobe Illustrator	Adobe Photoshop	Adobe Indesign
Corel Draw	Corel Photopaint	Adobe Framemaker
Inkscape	Gimp	Quark XPress
Macromedia Freehand		Scribus

Uz komercijalne programe koji su trenutno najzastupljeniji na tržištu, postoje i besplatni programi razvijeni pod GNU licencom (General Public licence). Njih razvijaju programeri i korisnici udruženi u neprofitne organizacije. Neki od predstavnika su Inkscape, Gimp i Scribus. Oni zauzimaju mali dio tržišta, ali se kvalitetom, ako ne i mogućnostima polako približavaju komercijalnim alatima.

Računalne grafike su grafike koje stvara računalo i općenito prezentacija slikovnih podataka od strane računala uz pomoć specijaliziranih programa i računala. Izraz "računalna grafika" koristi se za gotovo sve na računalima što nije tekst ili zvuk³⁸. Slike obično proizvode optički uređaji poput ogledala, leća, kamere, mikroskopa, ljudskog oka i sl. Digitalna slika predstavlja slikovni zapis u binarnom formatu kao niz jedinica i nula. Digitalne slike uključuju i vektorske i rasterske slike. Svaki uređaj za prijenos slike u električni zapis snima sliku po svojim postavkama. Samim time je svaka slika, mada snimljena u istim uvjetima, ali različitim uređajem različita u opisu boje.

1.4.4. Formati zapisa podataka

Što god radili u informatičkom okruženju, kada želimo nešto sačuvati ili prenijeti negdje drugdje, podatke moramo zapisati u datoteku. Svaki program ima svoju vrstu zapisa u koji spremi podatke, a kompatibilnost među programima postiže se filterima za uvoz podataka. Korištenjem filtera program zna kako interpretirati podatke koje je zapisao drugi program. Kao i kod svega što se prenosi između različitih programa, postoji problem s kompatibilnošću. Tako će program dobro pročitati zapis koji on sam radi na sličan način, dok će ono što ne podržava zanemariti. S ciljem da se izbjegnu problemi s kompatibilnošću, razvijeni su standardi za razmjenu dokumenata, koji ako su ispravno napravljeni daju ispravan prikaz željenog dokumenta. Glavni predstavnik ovih zapisa je Adobe Document Portable Format ili pdf zapis. To je otvoreni standard poznat pod

nazivom ISO 32000³⁹. Moguće ga je prikazati na gotovo bilo kojoj platformi. Načinjen je da održava izgled izvornog dokumenta i sačuva izvorene informacije (tekst, crtež, fotografije, video, zvuk, 3D i poslovne podatke). Pogodan je za stvaranje digitalnih arhiva, knjižnica i općenito razmjenu informacija.

Tabela 7 Prikaz dijela zapisa podataka koji se koriste u grafičkoj industriji

Program	Ime zapisa	Vrsta zapisa
Adobe Framemaker	.fm	Privatni zapis programa
Adobe Illustrator	.ai	Privatni zapis programa
Adobe Indesign	.indd	Privatni zapis programa
Adobe Photoshop	.psd	Privatni zapis programa
Corel Draw	.cdr	Privatni zapis programa
Corel Photopaint	.cpt	Privatni zapis programa
	.pdf	Zapis za distribuciju podataka. Zadržava strukturu informacija na svim platformama
	.html	Zapis za distribuciju podataka. Otvara se u internet pretraživačima i prilagođava podatke računalu

U grafičkoj industriji se danas gotovo isključivo koristi pdf dokument za komunikaciju. Slanjem otvorenih dokumenata poput Adobe Indesigna, Quark Xpressa, Microsoft Worda, Corel Drawa, Adobe Photoshopa i dr. Zapisi su podložni promjenama u prezentaciji podataka, drugačijim prostorima boja koji se koriste u samim operativnim sustavima i sl. Ispravno napravljen pdf zapis sprečava pojavu većine grešaka. Kao profesionalni standardni alat u grafičkoj industriji za pregled pdf dokumenata koristi se program Adobe Acrobat.

Tiskarska industrija koristi samo maleni dio njegovih mogućnosti. On omogućuje manualno i automatsko pregledavanje pogodnosti dokumenata primjerice za tisak. S obzirom da pdf dokumenti podržavaju daleko više nego što je to potrebno grafičkoj industriji, tako i alati poput Adobe Acrobat-a podržavaju reprodukciju i umetanje audio i video sadržaja, obrazaca, komentara i uz upotrebu dodatnih programa (plug-ins) mnogih dodatnih mogućnosti.

Kao i svaki standard, pdf se tijekom vremena razvijao pa se danas koriste različite verzije dokumenata. Prelaskom Adobe pdf zapisa u ISO standard, gubi se broj verzije i razvijaju standardi⁴⁰:

- PDF/X – podgrupa PDF zapisa namijenjena uporabi u grafičkoj industriji. Obično su takvi dokumenti pouzdani i trebali bi biti točno otisnuti na bilo kojem Postscript uređaju poput pisača i osvjetljivača tiskovnih formi
- PDF/E – namijenjen je industrijskoj upotrebi kako bi osigurao podudaranje zapisa industrijskih dizajna i nacrti pdf standardu
- PDF/A – namijenjen je arhiviranju podataka i sigurnom otvaranju dokumenata u budućnosti.

U razvoju su i drugi standardi poput:

- PDF/UA – namijenjen je za olakšavanje pregledavanja dokumenata ljudima s poteškoćama u vidu ili pokretu
- PRC – za prikaz različitih vrsta 3D podataka i spremanje u kompaktni 3D format zapisa
- PDF/VT – za stvaranje, pregledavanje i tisk varijabilnih podataka poput bankovnih izvadaka i poslovnih računa.

2. Eksperimentalni dio

2.1. Uvod

Sve veća integracija raznih sustava dovodi do sve veće potrebe za kompatibilnošću dijelova sustava, koji do nedavno nisu bili korišteni na sve načine koje su podržavali. Uporaba međuspremnika za prijenos informacija normalan je radni postupak koji je dugo u uporabi. Međuspremnik nije bio korišten za prijenos slikovnih informacija u grafičkoj industriji, te za to nije niti ispitana. Osim u rijetkim slučajevima kada su programski međuspremnički kompatibilni, podaci se uvijek prilagođavaju novom prostoru u koji ulaze.

Definicijom testnih klinova, njihovim ispitivanjem u obliku izlaznog pdf dokumenta i otisnutog uzorka želi se ispitati promjena boje u svim dostupnim koracima izrade.

2.2. Plan istraživanja

Eksperiment je osmišljen tako da omogući instrumentalno očitanje uzorka.

S obzirom da je namjera bila vidjeti ponašanje u standardnom sustavu, svi programski alati bili su namješteni na tvorničke postavke, što znači da nisu mijenjana namještanja rada s bojom. Isto tako, originalni dokument je rađen kao tif (tagged image format) bez profila za definiciju boja.

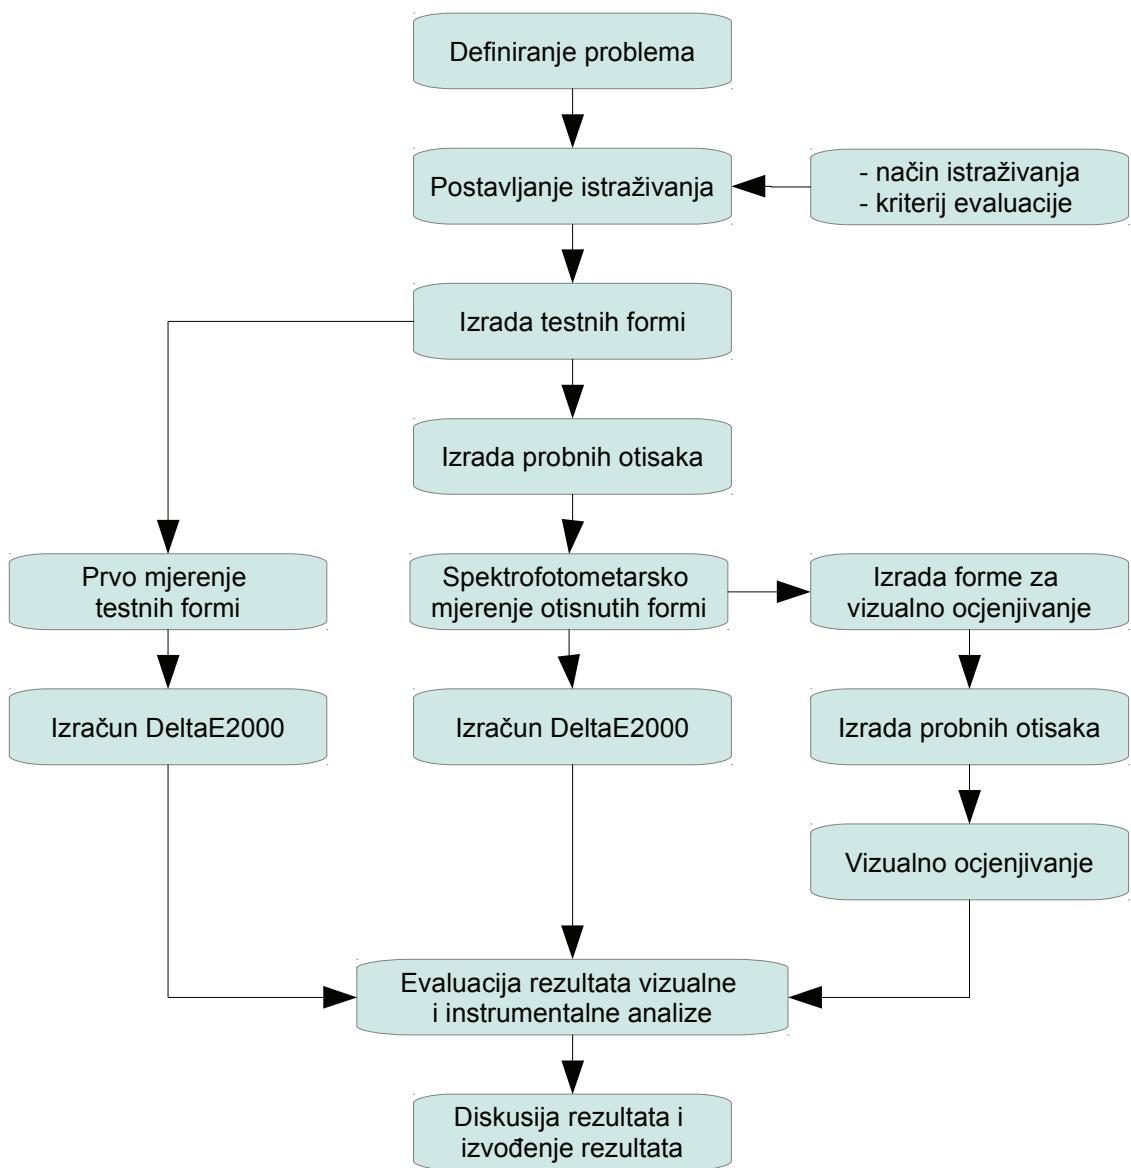
Originalni dokument čini kalibracijski klin generiran iz programa Monaco Profiler. Namijenjen je za automatsko očitanje vrijednosti pomoću spektrofotometra.

Originalni dokument se umeće u polazišni program, odakle se putem međuspremnika prebacuje u sve ostale programe. Nije rađeno usklađivanje standarda međuspremnika, nego je sve rađeno po standardnim postavkama sustava.

Iz završnih programa radi se pdf dokument koji se pomoću alata CHROMiX ColorThink očitava. Očitane Lab vrijednosti koriste se za prvi dio mjerjenja. Iz njih se očitavaju vrijednosti prije otiskivanja izrađenih uzoraka. Dobivene vrijednosti daju prvi izračun $\Delta E2000$ vrijednosti.

Izrađeni pdf dokument se potom otiskuje na stroju za digitalni tisak Xerox DC700.

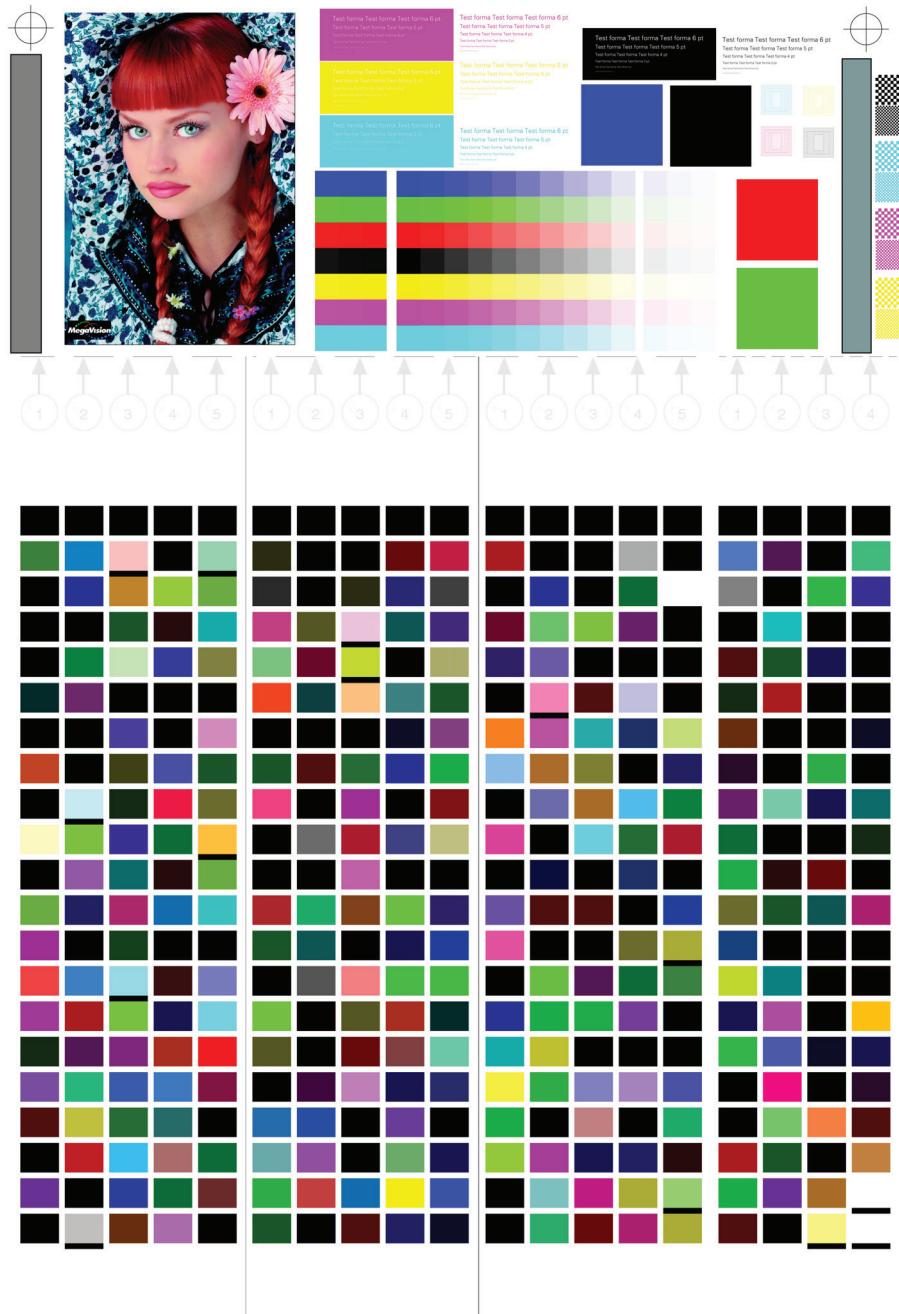
Otisnuti uzorci se očitavaju putem spektrofotometra X-rite DTP 41 i programa Monaco Profiler. Iz izmjerениh uzoraka računa se drugi dio $\Delta E2000$ te se na temelju dobivenih vrijednosti uzimaju najveće $\Delta E2000$ vrijednosti. Elementi testnog klina koji imaju najveće vrijednosti upotrijebljeni su za izradu uzorka za vizualno ispitivanje. Uzorak je izrađen na osnovu izmjerениh vrijednosti.



Slika 33 Shematski prikaz plana istraživanja

2.3. Priprema materijala za ispitivanje

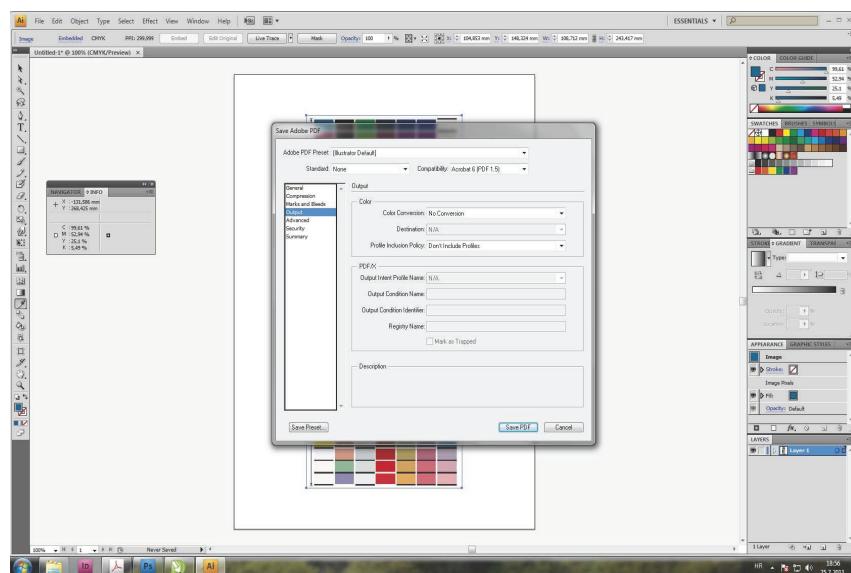
Za potrebe ovog istraživanja upotrijebljen je testni klin za mjerjenje gamuta s 378 polja. Original je u tif zapisu, CMYK modela boja, bez uključenih profila za boje te je kao takav i uvezen u izvorni program, bez promjene podataka slike, što je potvrđeno izradom pdf dokumenta po press opcijama u programu Acrobat Distiller. Press opcije su izmijenjene samo u detalju da je opcija "Leave color unchanged" uključena¹. U izrađenom dokumentu nije bilo nikakvih promjena.



Slika 34 Izgled testne forme. Sadrži klin za automatsko očitanje na X-rite spektrofotometru X-Rite DTP41, uzorak fotografije te dodatna polja za kontrolu tiska.

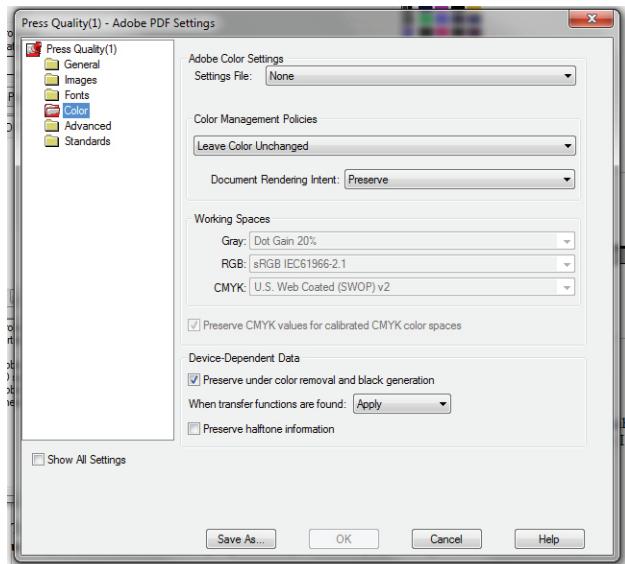
Uvezeni uzorak je potom putem međuspremnika prebačen u standardne grafičke programe. Nije bilo moguće prebaciti podatke iz svakog programa u sve korištene. U nekim smjerovima nije bilo prijenosa podataka, a s obzirom da nije javljena greška, pretpostavka je da je uzrok tome nekompatibilnost samih zapisa. Dobiveni dokumenti su potom po gore navedenim uputama pretvoreni u Adobe pdf zapis. Iz ovih dokumenata moguće je očitati promijenjene podatke, koji se ovisno o smjeru prijenosa podataka vide u većoj ili manjoj mjeri.

Za izradu probnog otiska upotrijebljena je testna forma koja uz kalibracijski klin sadrži i sliku ženskog lica te dodatna polja za kontrolu otiska.



Slika 35 Prikaz podešavanja programa da ne utječu na boju dokumeta pri izradi postscript dokumenta u programima CorelDraw X5 i Adobe Photoshop CS4. Princip podešavanja isti je za sve korištene alate.

Podešenjem programa da ne vežu dokument ili samu sliku s ICC profilom, dobivena je neutralnost samog dokumenta, s obzirom da bi izlazni uređaji prilikom obrade dokumenta (RIP-anja) upotrijebili ICC profil za tumačenje vrijednosti same slike.



Slika 36 Press opcije u programu Adobe Acrobat Distiller

Prijenos podataka izvršen je između programa Adobe Photoshop CS4, Adobe Illustrator CS4, Adobe Indesign CS4, Corel Draw X5 te Corel Photopaint X5, prema tabeli:

Tabela 8 Smjer kretanja slikovnih podataka

Početni program	Završni program
Corel Draw X5	Adobe Illustrator CS4
Corel Draw X5	Adobe Indesign CS4
Corel Draw X5	Adobe Photoshop CS4
Adobe Illustrator CS4	Corel Draw X5
Adobe Illustrator CS4	Adobe Indesign CS4
Adobe Illustrator CS4	Adobe Photoshop CS4
Corel Photopaint X5	Adobe Indesign CS4
Corel Photopaint X5	Adobe Photoshop CS4
Adobe Photoshop CS4	Corel Draw X5
Adobe Photoshop CS4	Adobe Indesign CS4
Adobe Photoshop CS4	Adobe Illustrator CS4
Adobe Photoshop CS4	Corel Photopaint X5

Upotrijebljeni alati su standardni za uporabu u grafičkoj industriji te su iz tog razloga i primijenjeni.

2.3.1. Korišteni strojevi i uređaji

Tisk uзорака извршен је на Xerox DC700 stroju за digitalni tisk. Stroj је kalibriran pomoћу uređaja X-Rite DTP21 koji је integriran у самоме stroju.

Xerox DC700

Xerox DC700 је tiskarski stroj koji radi na principu elektrofotografije. Kao и сvi strojevi te generације, konstruiran је за minimalno održavanje. Većina dijelova se при квару или трошњу mijenja, чиме се максимално pojednostављује и убрзава рукovanje strojem те се изbjegава nepotrebno заустављање stroja zbog održavanja.

Tabela 9 Prikaz karakteristika Xerox DC700 tiskarskog stroja

Veličina slike	Max. 323 x 480 mm
Veličina papira	Max. 330 x 488 mm
Produktivnost	31 stranica 320x450mm u minuti на 64-176 g/m ² ofsetnom papiru
	22 stranica 320x450mm u minuti на 177-256 g/m ² ofsetnom papiru или 106-176 g/m ² papiru за уметнички тисак
	15 stranica 320x450mm u minuti на 257-300 g/m ² ofsetnom papiru или 177-300 g/m ² papiru за уметнички тисак
Preporučena мјесечна производња	20000 до 75000 stranica мјесечно
Rezolucija	2400 x 2400 dpi
RIP	Xerox FreeFlow® Print Server
Ulagani формати	Adobe PostScript, PDF, eps, tiff
Automatski обострани отисак	Да – до 220g/m ²
Vanjski uređaji	скенер
Mogući dodaci	Atomatsko preokretanje araka Elektronsko sabiranje Klamanje Bušenje Savijanje



Slika 37 Shema prolaza tiskovnog arka kroz stroj

Na gornjoj slici prikazan je Xerox DC700, od ulagačih stolova, kroz tiskovnu jedinicu, do modularnog doradnog dijela. Pri kupnji ovakvih strojeva moguć je odabir i ulagače dijela te različitih varijanti doranog dijela, ovisno o potrebi svake tiskare.

Spektrofotometar X-rite DTP41

Ispitivanje je provedeno na X-Rite DTP41 automatskom spektrofotometru.



Slika 38 Spektrofotometar X-Rite DTP 41

Osobine uređaja X-Rite DTP41

Tabela 10 Tehnološke karakteristike X-Rite DTP41

Geometrija mjerenja	45°/0° po ANSI/ISO 5-4 (IT2.17) (refleksija)	
	180°/0° po ANSI/ISO 5-2 (IT2.19) (transparencija)	
Veličina točke očitanja	1.8mm (.070 in) u smjeru skeniranja, 2.5mm (.097 in) širina	
Raspon očitanja spektra	400nm do 700nm	
Izvori svjetla	A, C, D50, D55, D65, D75, F2, F7, F11, & F12	
Standardni promatrač	2° i 10°	
Vrijeme očitanja	Cca 0.25 sekunde po polju (7mm polja)	
Mjerenje refleksije (DTP41 & DTP41/T)		
	Raspon mjerenja	0.00D do 2.50 D; 0 do 160% R
	Mogućnost ponavljanja na bijeloj boji	0.2 ΔE max; Δ0.01D max
	Linearnost	+/- .01D ili 1%
Mjerenje transparentnih stripova (DTP41/T)		
	Raspon mjerenja	0.00D do 5.00 D; 0 do 110% T
	Mogućnost ponavljanja	+/- 0.01D ili 1% 0 do 3.5 D (Visual)
Kalibracija	Pomoću stripa za kalibraciju	

X-Rite DTP41 je 24 bitni mjerni instrument za obojenja koji mjeri denzitometarske, kolorimerijske i spektralne podatke. Namijenjen je za automatsko očitavanje programski definiranih kalibracijskih klinova otisnutih na velike arke bez rezanja.

Korišteni materijal

Za otiskivanje uzoraka korišten je 250 g/m² papir za umjetnički tisk Magno Satin proizvođača Sappi. Papir je prije provedbe procesa tiska bio u istoj prostoriji 48 sati, uz propisane standardne uvjete (23°C temperatura i relativna vлага od 55%).

Tabela 11 Osnovne karakteristike papira za umjetnički tisk

Parametar	Standard	Jedinica		Tolerancije
Gramatura	ISO 536	g/m ²	250	± 4 %
Svjetlina (izvor svjetla D65/10°)	ISO 2470	%	100	± 2
Gruboća	DIN 8791-4	µm	1,4	± 0,5
Pokritnost	ISO 2471	%	98,5	-1
Relativna vлага (23°C)	TAPPI 502	%	50	± 5
PH vrijednost	ISO 6588	0	>7	0
Specifični volumen	ISO 534	cm ³ /g	0,89	± 6 %

2.4. Spektrofotometarsko ispitivanje otiska i matematička obrada rezultata

Dobivene Lab vrijednosti obrađene su po ΔE 2000 formuli, s ciljem ispitivanja razlike s očitanim vrijednostima ispisanog originala. Tablicu za izračun ΔE 2000 priložili su kao dodatak svom istraživanju G. Sharma, W. Wu i E.N. Dalal⁴¹.

Donja tabela sadrži maksimalne izmjerene vrijednosti ΔE 2000 i broj izmjereno polja. Zbog obima podataka prikazano je samo 10 najvećih izmjerениh razlika.

Tabela 12 Prikaz deset izmjerenih polja s najvećim ΔE 2000 u svakom uzorku.

Photoshop u Illustrator		Photoshop u Indesign		Photoshop u Corel Draw		Photopaint u Photoshop		Photoshop u Photopaint	
Polje	ΔE 2000	Polje	ΔE 2000	Polje	ΔE 2000	Polje	ΔE 2000	Polje	ΔE 2000
285	14,0516	171	16,9381	233	17,1139	285	16,3285	364	14,0499
351	12,6016	233	16,6597	171	16,6859	122	12,6015	17	13,6380
17	11,2838	351	15,0722	234	15,1190	54	12,4884	363	13,1603
373	10,5615	234	14,3192	315	15,0038	217	12,3797	351	12,7713
10	10,0505	315	13,6004	351	14,1186	373	12,2414	172	12,1561
8	9,9580	223	13,2849	223	13,6910	220	12,0944	377	11,7583
45	9,9516	377	13,0226	377	12,8566	254	11,6270	214	11,6915
109	9,5797	24	12,8071	17	12,7550	114	11,5938	202	11,5616
220	9,1446	172	12,4322	24	12,6301	337	11,5034	366	11,0896
364	8,8958	17	12,4113	36	11,8181	109	10,9556	326	11,0708

Photopaint u Indesign		Illustrator u Photoshop		Illustrator u Indesign		Illustrator u Corel Draw	
Polje	ΔE2000	Polje	ΔE2000	Polje	ΔE2000	Polje	ΔE2000
17	5,3508	199	6,5214	17	4,6046	171	16,9279
288	3,9183	17	5,5498	24	4,5929	233	15,2338
123	3,5995	233	4,8581	45	4,4960	351	15,2016
351	3,4989	162	4,5774	288	3,9746	234	14,4447
24	3,4417	273	4,4211	154	3,6579	249	13,4588
33	3,3825	317	4,4200	351	3,6529	315	13,2835
19	3,3553	45	4,4155	33	3,4865	377	13,2355
69	3,3422	205	4,2546	115	3,4306	223	12,9053
45	3,2475	170	3,9596	230	3,2363	24	12,8796
160	3,2173	281	3,7834	14	3,2205	17	12,8594

Corel Draw u Photoshop		Corel Draw u Indesign		Corel Draw u Illustrator		Photoshop u Illustrator	
Polje	ΔE2000	Polje	ΔE2000	Polje	ΔE2000	Polje	ΔE2000
122	13,7758	233	20,1208	351	13,6261	364	14,0499
285	12,9393	171	19,2322	240	11,7277	17	13,6380
125	12,3993	234	16,6224	364	11,6136	363	13,1603
351	11,9038	315	15,9332	230	11,4748	351	12,7713
109	11,6674	24	15,6626	133	11,4684	172	12,1561
52	11,5669	223	15,2542	17	11,2997	377	11,7583
190	11,2877	351	15,1576	131	10,8447	214	11,6915
230	11,0229	125	14,2550	199	10,8294	202	11,5616
220	10,8058	273	13,7685	332	10,4442	366	11,0896
17	10,7244	288	13,2693	321	10,2810	326	11,0708

Iz svih izmjerениh vrijednosti dobivena je prosječna ΔE2000 za svaki izmjereni kalibracijski klin. Korištena je formula

$$\text{Srednja vrijednost } \Delta E2000 = \frac{\text{zbroj svih vrijednosti } \Delta E2000 \text{ u klinu}}{\text{broj izmjerenih polja}} \quad [46]$$

Mjeranjem vrijednosti unutar pdf dokumenta i otiska dobivene su sljedeće srednje ΔE2000 vrijednosti:

Tabela 13 Srednje $\Delta E2000$ vrijednosti izmjerene za svaki uzorak i razlika između istog uzorka prije i poslije tiska

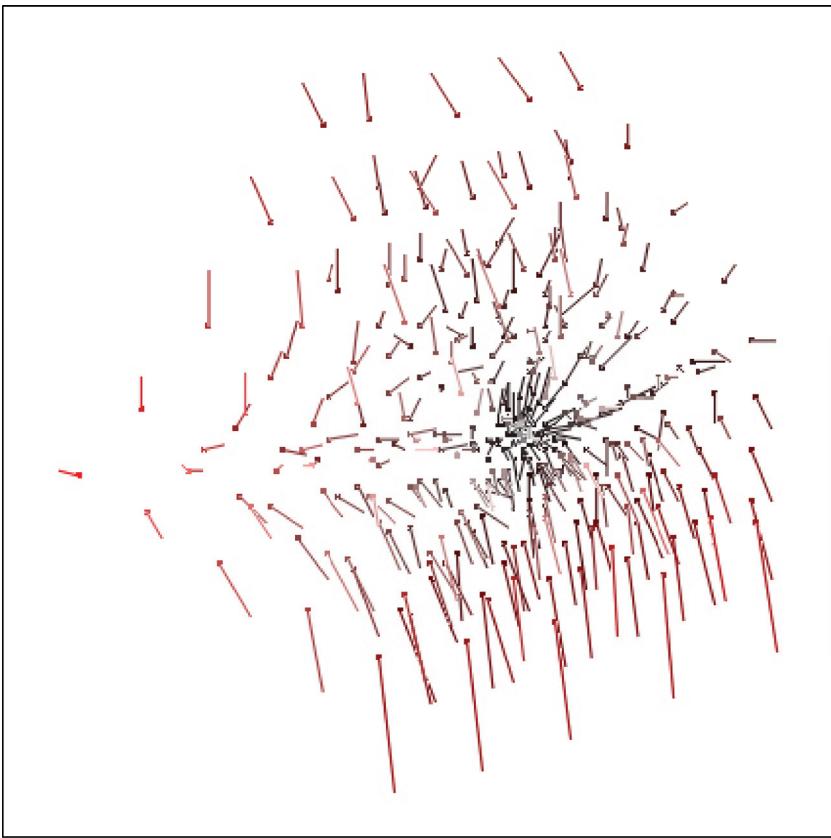
Početni u ciljni program	$\Delta E2000$ mjerena iz otiska	$\Delta E2000$ mjerena iz pdf dokumenta	Razlika između dvije $\Delta E2000$ vrijednosti
Photoshop u Illustrator	2,8129631316	2,2357402303	0,5772229013
Photoshop u Indesign	5,5137308077	6,0970499576	0,5833191499
Photoshop u Corel Draw	5,4941775513	6,1032853553	0,609107804
Photopaint u Photoshop	5,0413339848	3,8933578907	1,1479760941
Photopaint u Indesign	1,30762958	0,0923133102	1,2153162698
Illustrator u Photoshop	1,5758191581	0	1,5758191581
Illustrator u Indesign	1,2610539971	0,0923133102	1,1687406869
Illustrator u Corel Draw	5,4927144588	6,0666949717	0,5739805129
Corel Draw u Photoshop	4,2235323054	3,2796740129	0,9438582925
Corel Draw u Indesign	5,7794304514	4,5354229619	1,2440074895
Corel Draw u Illustrator	5,9392373658	5,7407295356	0,1985078302
Photoshop u Photopaint	5,2327743585	5,4262971101	0,1935227516

U ovom slučaju, broj izmjerениh polja je 378. Dobiveni pdf dokument je prije otiskivanja izmjeren alatom za mjerjenje boje (color picker) te je utvrđeno da su CMYK vrijednosti iste kao i u originalnom dokumentu u sljedećim uzorcima: Photopaint u Indesign, Illustrator u Photoshop i Illustrator u Indesign. Razlika u $\Delta E2000$ vrijednostima iznosi do 1,57. što označava i razinu promjena koje se događaju tijekom tiska na danom stroju.

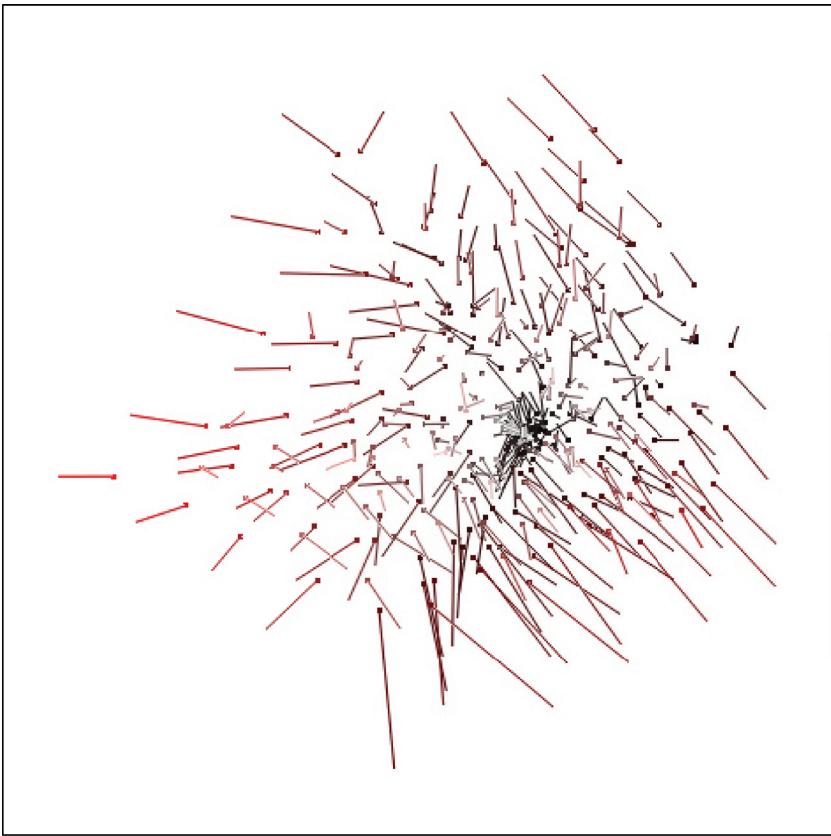
Kada se isključe uzorci koji odgovaraju originalu, vidljivo je da je vrijednost $\Delta E2000$ u pravilu iznad 5.

Promjena vrijednosti elemenata slike nastalih tijekom prijenosa putem pasteboarda uočljiva je očitanjem u pdf dokumentu. Iz dobivenih vrijednosti uočljivo je da je nastala razlika velika i jasno uočljiva.

Na donjim slikama vidljiv je prikaz promjene boje od očitanog originala prema uzorku. U idealnoj situaciji poklapale bi se točke originala i "kopije", dok se u ovoj situaciji primjećuje da je kretanje veliko i bez zajedničkog faktora po kome bi se mogao razviti uzorak kretanja promjena.



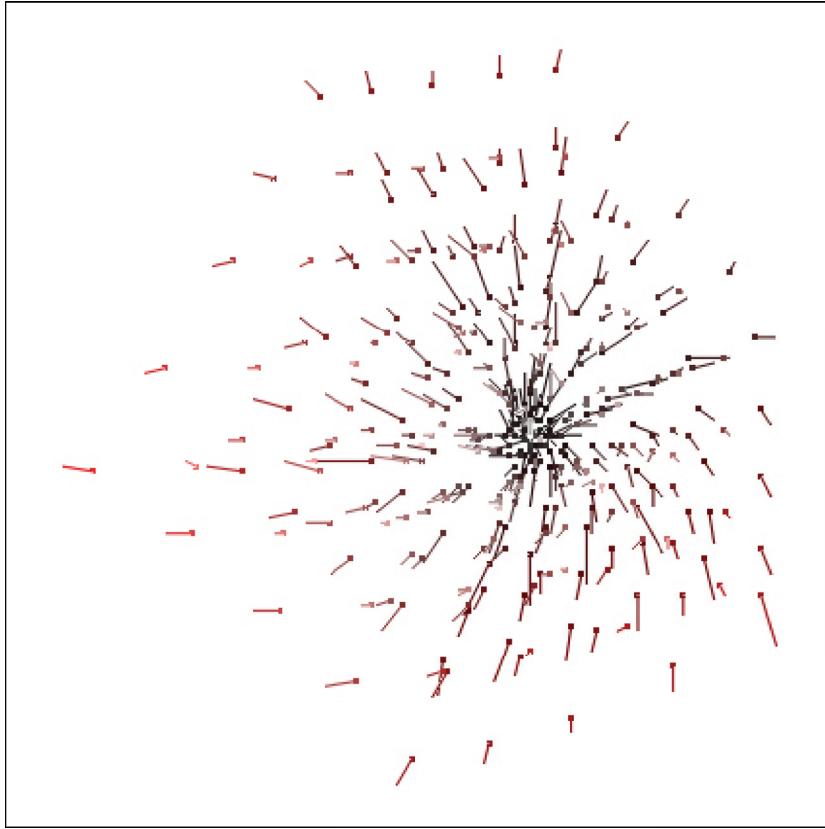
PDF Corel Draw u Adobe Indesign



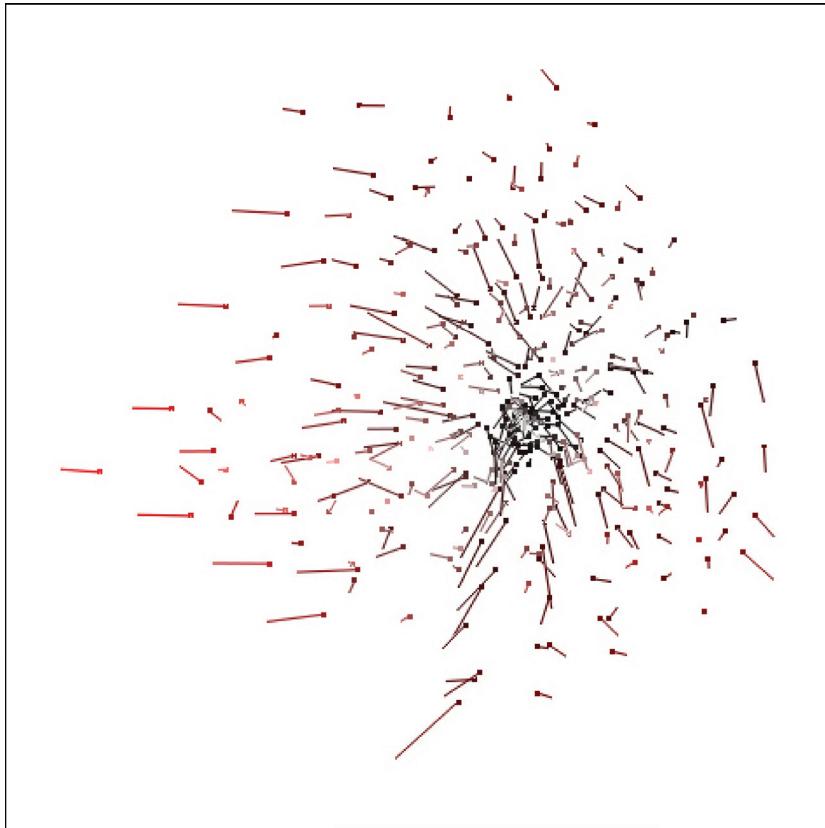
Corel Draw u Adobe Indesign

Prikaz promjene boje načinjen u programu za analizu informacija boje Chromix ColorThink u 2D prikazu. Na lijevoj slici nalazi se prikaz promjene boje na otisku, dok se na desnoj strani nalaze iste vrijednosti izmjerenе unutar pdf dokumenta. Ta je slika označena s prefiksom PDF. Uspoređuju se originalni i završni dokument. Krajnja točka svakog pomaka označena je točkom na kraju linije.

Slika 39 Prikaz promjene boja prilikom prijenosa podataka Corel Draw u Adobe Indesign



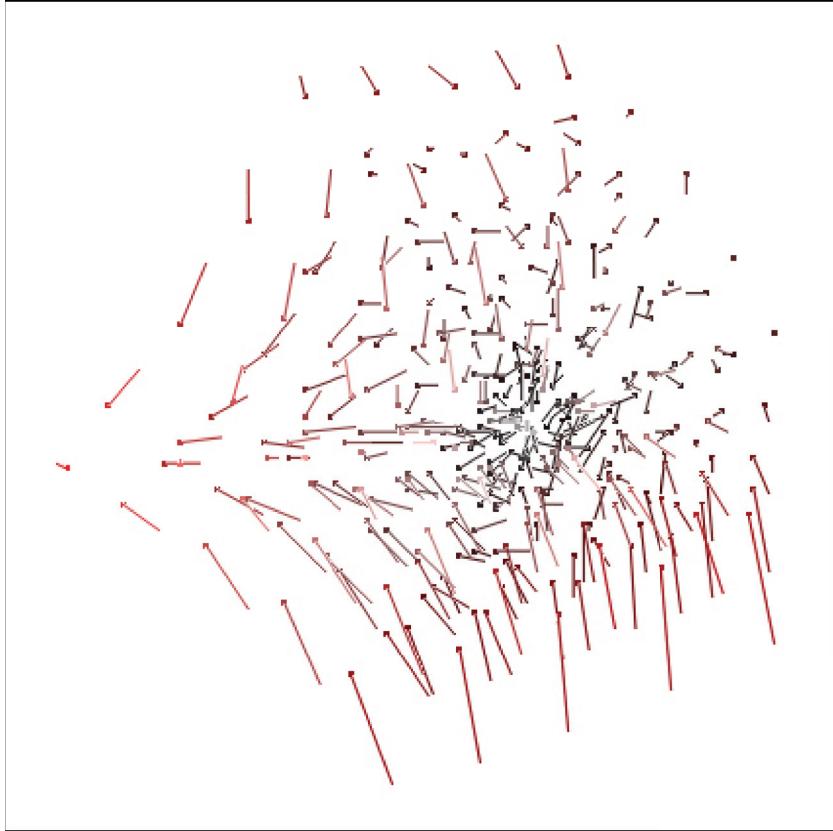
Corel Draw u Adobe Photoshop



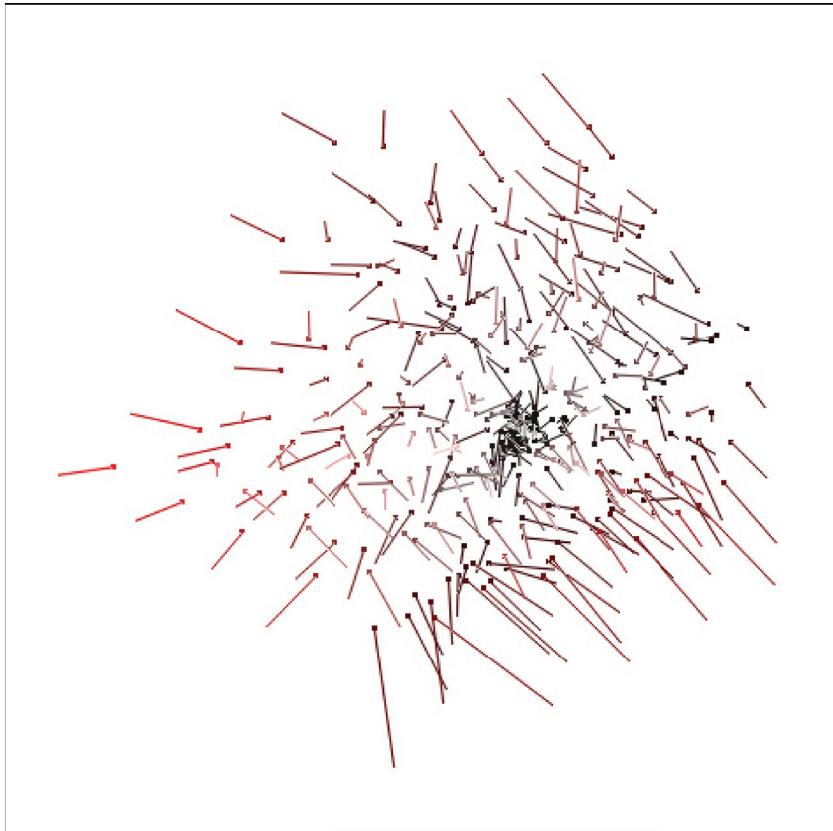
PDF Corel Draw u Adobe Photoshop

Prikaz promjene boje načinjen u programu za analizu informacija boje Chromix ColorThink u 2D prikazu. Na lijevoj slici nalazi se prikaz promjene boje na otisku, dok se na desnoj strani nalaze iste vrijednosti izmjerene unutar pdf dokumenta. Ta je slika označena s prefiksom PDF. Uspoređuju se originalni i završni dokument. Krajnja točka svakog pomaka označena je točkom na kraju linije.

Slika 40 Prikaz promjene boja prilikom prijenosa podataka Corel Draw u Adobe Photoshop



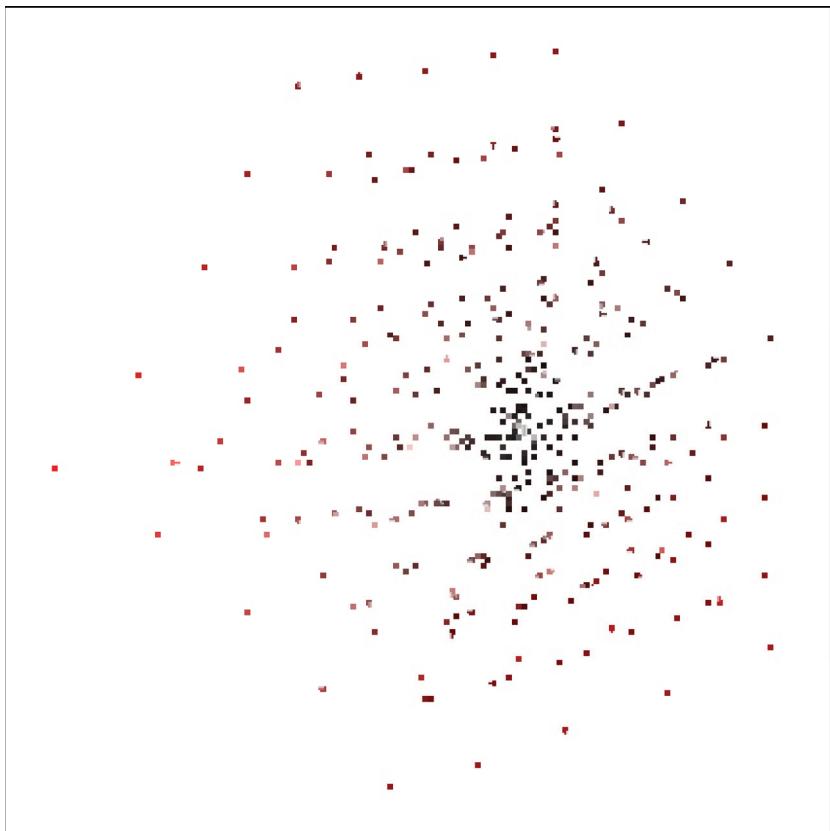
Adobe Illustrator u Corel Draw



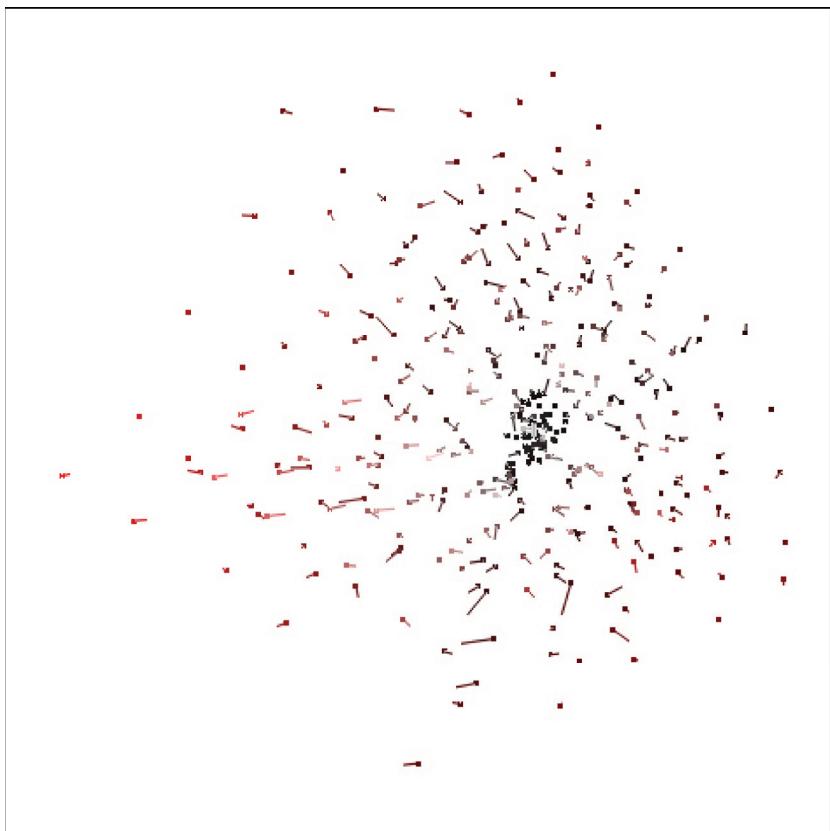
Corel Draw u Adobe Illustrator

Prikaz promjene boje načinjen u programu za analizu informacija boje Chromix ColorThink u 2D prikazu. Na lijevoj slici nalazi se prikaz promjene boje na otisku, dok se na desnoj strani nalaze iste vrijednosti izmjerene unutar pdf dokumenta. Ta je slika označena s prefiksom PDF. Uspoređuju se originalni i završni dokument. Krajnja točka svakog pomaka označena je točkom na kraju linije.

Slika 41 Prikaz promjene boja prilikom prijenosa podataka Adobe Illustrator u Corel Draw



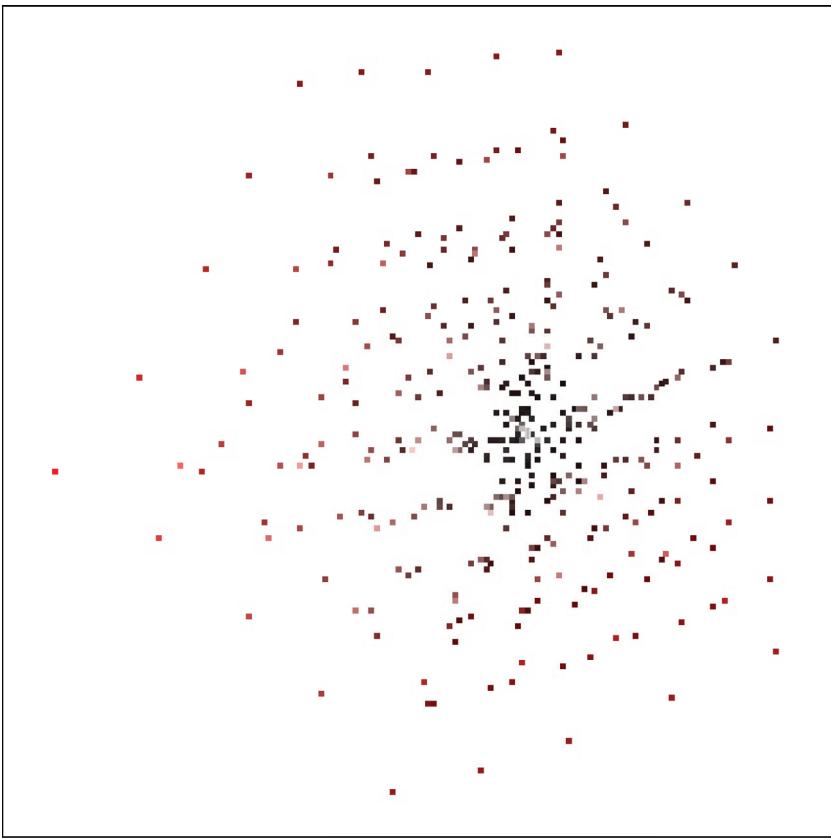
PDF Adobe Illustrator u Adobe InDesign



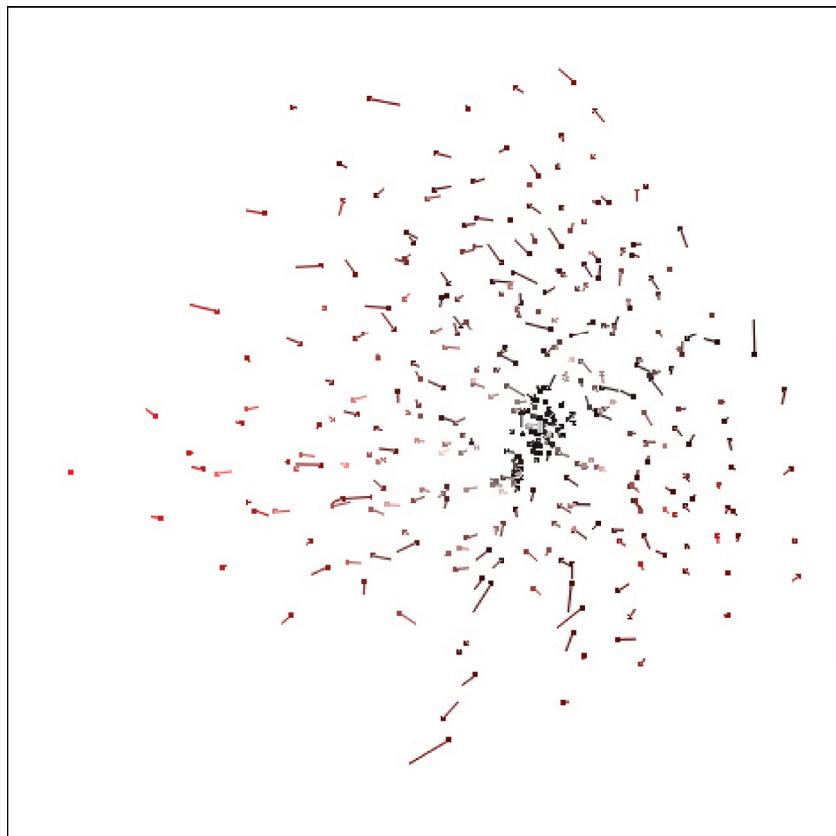
Adobe Illustrator u Adobe InDesign

Prikaz promjene boje načinjen u programu za analizu informacija boje Chromix ColorThink u 2D prikazu. Na lijevoj slici nalazi se prikaz promjene boje na otisku, dok se na desnoj strani nalaze iste vrijednosti izmjerene unutar pdf dokumenta. Ta je slika označena s prefiksom PDF. Uspoređuju se originalni i završni dokument. Krajnja točka svakog pomaka označena je točkom na kraju linije.

Slika 42 Prikaz promjene boja prilikom prijenosa podataka Adobe Illustrator u Adobe InDesign



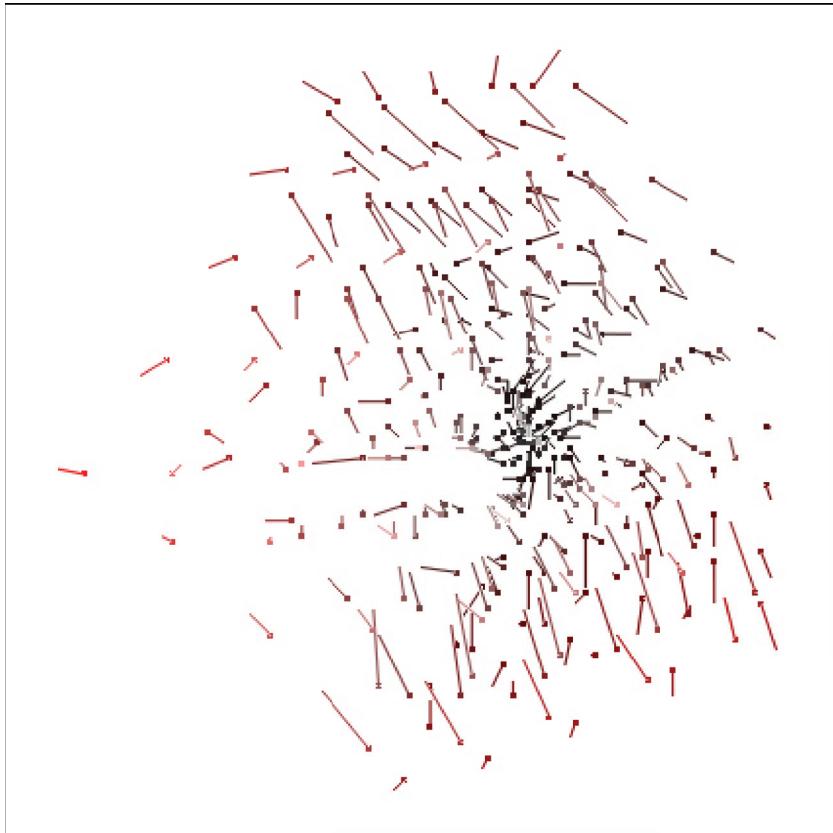
PDF Adobe Illustrator u Adobe Photoshop



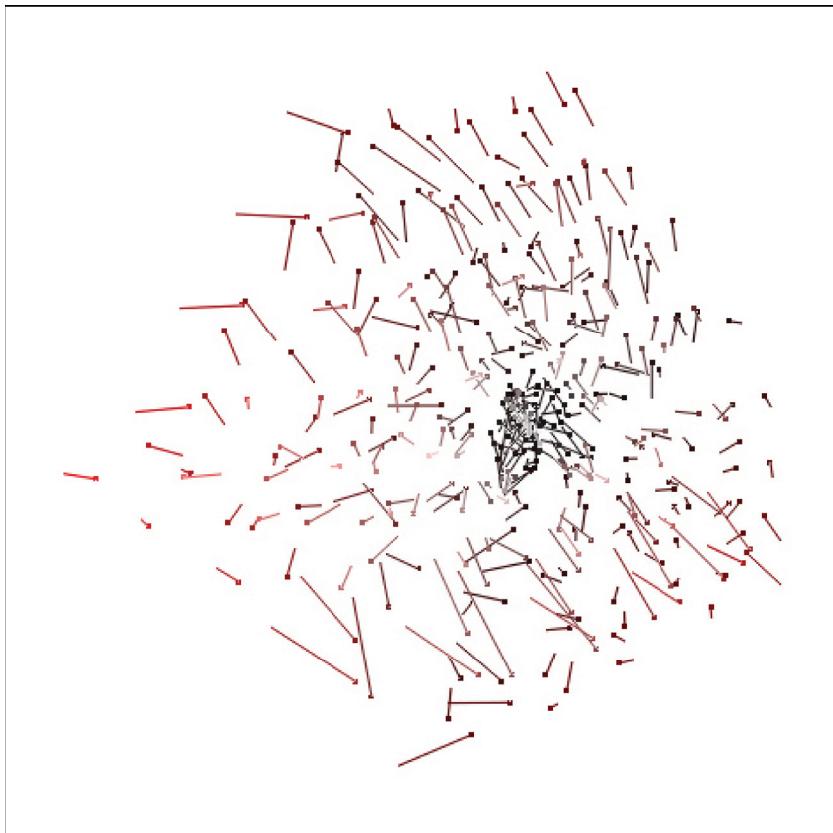
Adobe Illustrator u Adobe Photoshop

Prikaz promjene boje načinjen u programu za analizu informacija boje Chromix ColorThink u 2D prikazu. Na lijevoj slici nalazi se prikaz promjene boje na otisku, dok se na desnoj strani nalaze iste vrijednosti izmjerene unutar pdf dokumenta. Ta je slika označena s prefiksom PDF. Uspoređuju se originalni i završni dokument. Krajnja točka svakog pomaka označena je točkom na kraju linije.

Slika 43 Prikaz promjene boje prilikom prijenosa podataka Adobe Illustrator u Adobe Photoshop



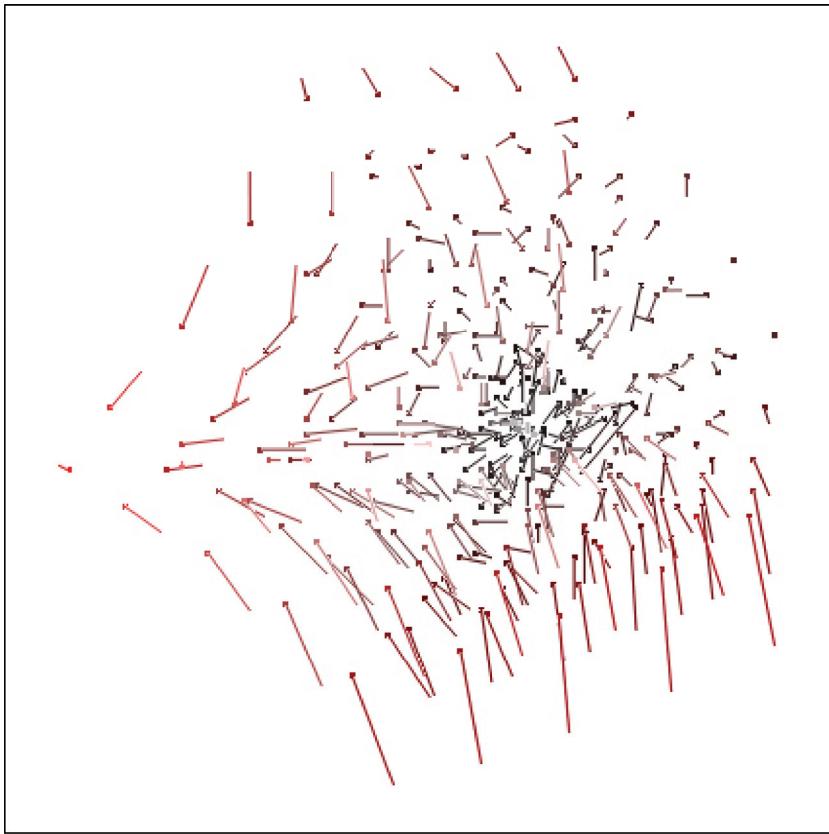
PDF Corel Photopaint u Adobe Photoshop



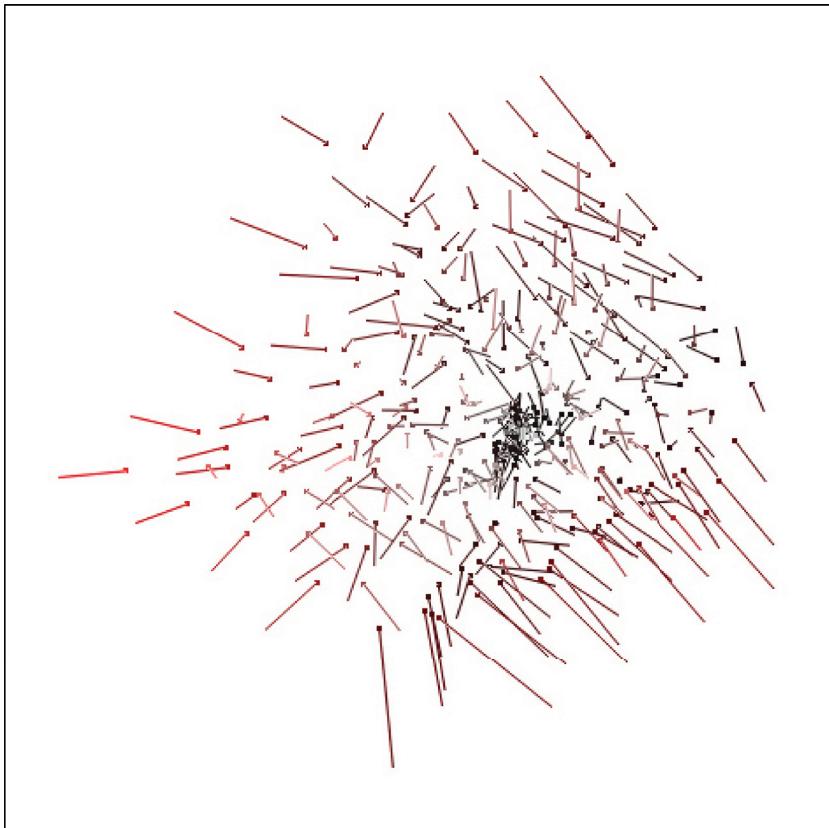
Corel Photopaint u Adobe Photoshop

Prikaz promjene boje načinjen u programu za analizu informacija boje Chromix ColorThink u 2D prikazu. Na lijevoj slici nalazi se prikaz promjene boje na otisku, dok se na desnoj strani nalaze iste vrijednosti izmjerene unutar pdf dokumenta. Ta je slika označena s prefiksom PDF. Uspoređuju se originalni i završni dokument. Krajnja točka svakog pomaka označena je točkom na kraju linije.

Slika 44 Prikaz promjene boje prilikom prijenosa podataka Corel Photopaint u Adobe Photoshop



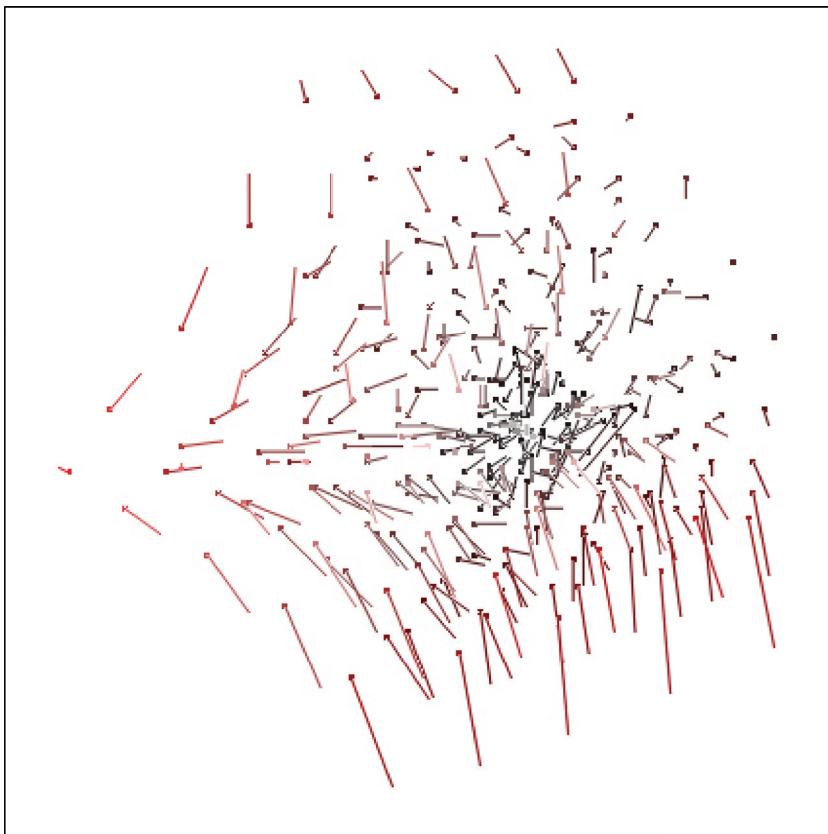
PDF Adobe Photoshop u Adobe Indesign



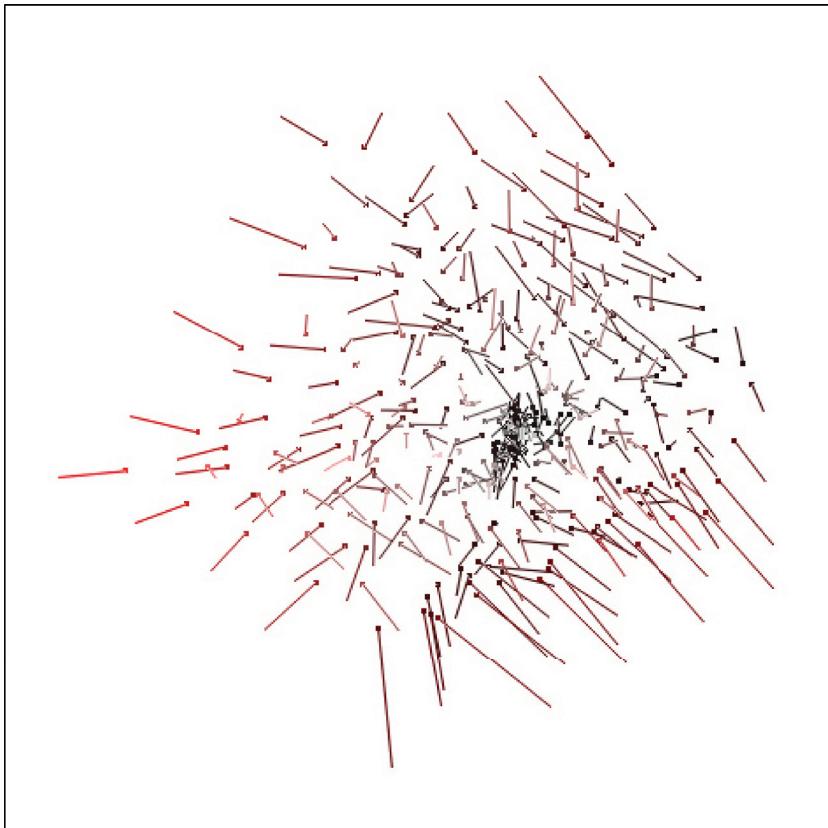
Adobe Photoshop u Adobe Indesign

Prikaz promjene boje načinjen u programu za analizu informacija boje Chromix ColorThink u 2D prikazu. Na lijevoj slici nalazi se prikaz promjene boje na otisku, dok se na desnoj strani nalaze iste vrijednosti izmjerene unutar pdf dokumenta. Ta je slika označena s prefiksom PDF. Uspoređuju se originalni i završni dokument. Krajnja točka svakog pomaka označena je točkom na kraju linije.

Slika 45 Prikaz promjene boja prilikom prijenosa podataka Adobe Photoshop u Adobe Indesign



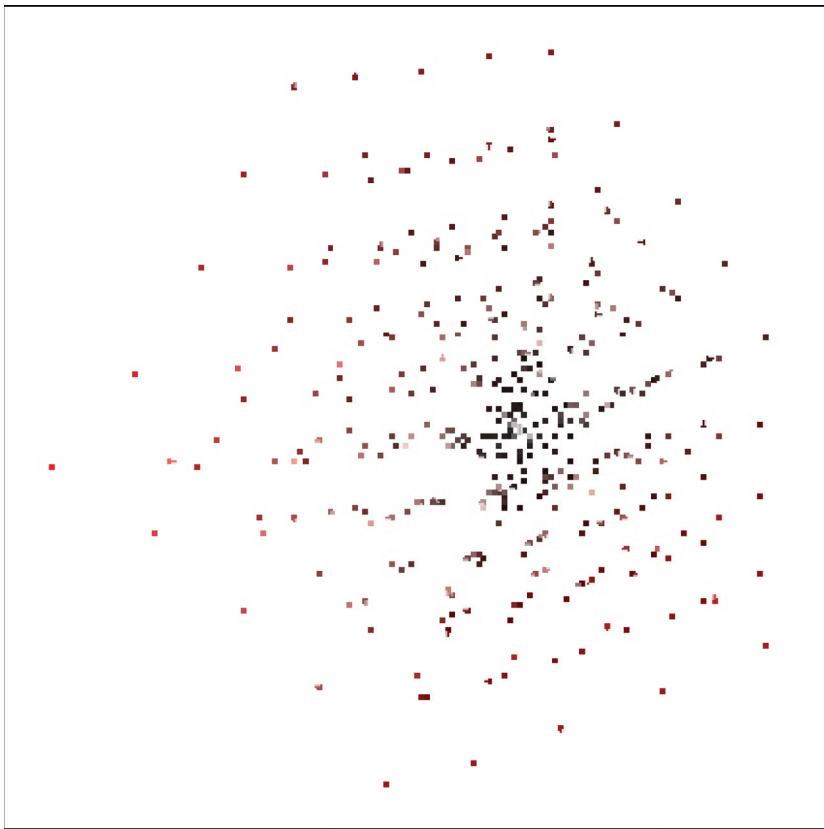
PDF Adobe Photoshop u Adobe Indesign



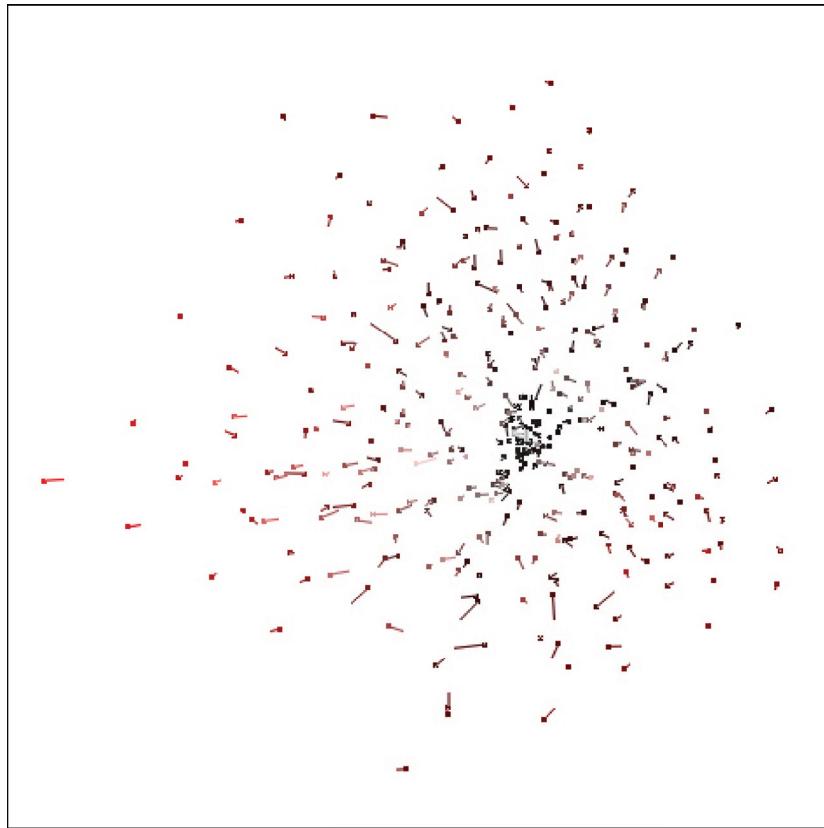
Adobe Photoshop u Adobe Indesign

Prikaz promjene boje načinjen u programu za analizu informacija boje Chromix ColorThink u 2D prikazu. Na lijevoj slici nalazi se prikaz promjene boje na otisku, dok se na desnoj strani nalaze iste vrijednosti izmjerene unutar pdf dokumenta. Ta je slika označena s prefiksom PDF. Uspoređuju se originalni i završni dokument. Krajnja točka svakog pomaka označena je točkom na kraju linije.

Slika 46 Prikaz promjene boja prilikom prijenosa podataka Adobe Photoshop u Adobe Indesign



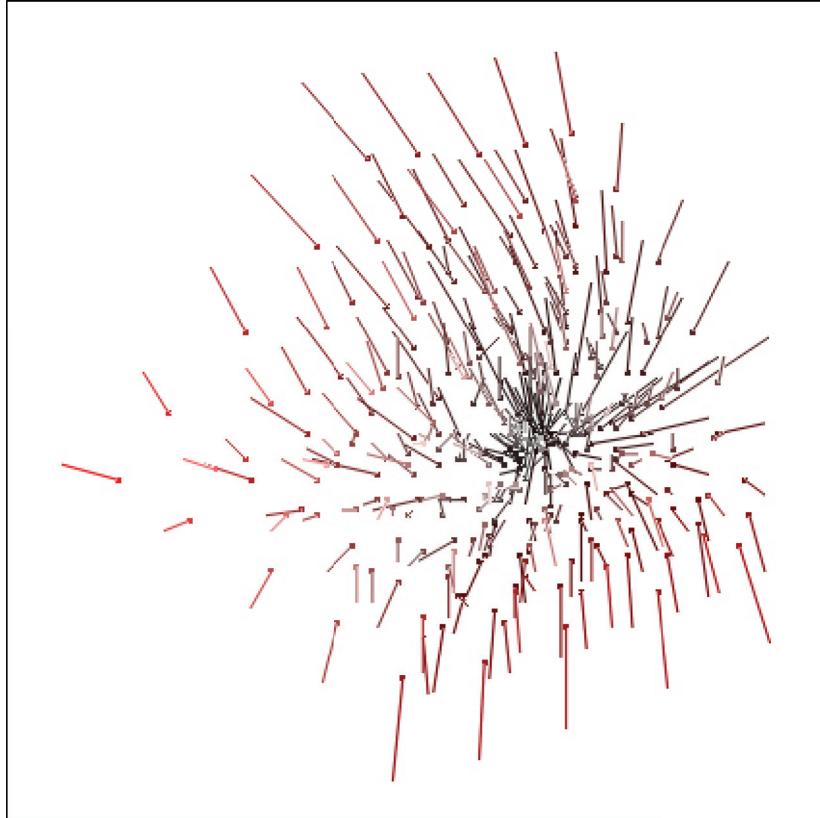
PDF Corel Photopaint i Adobe indesign



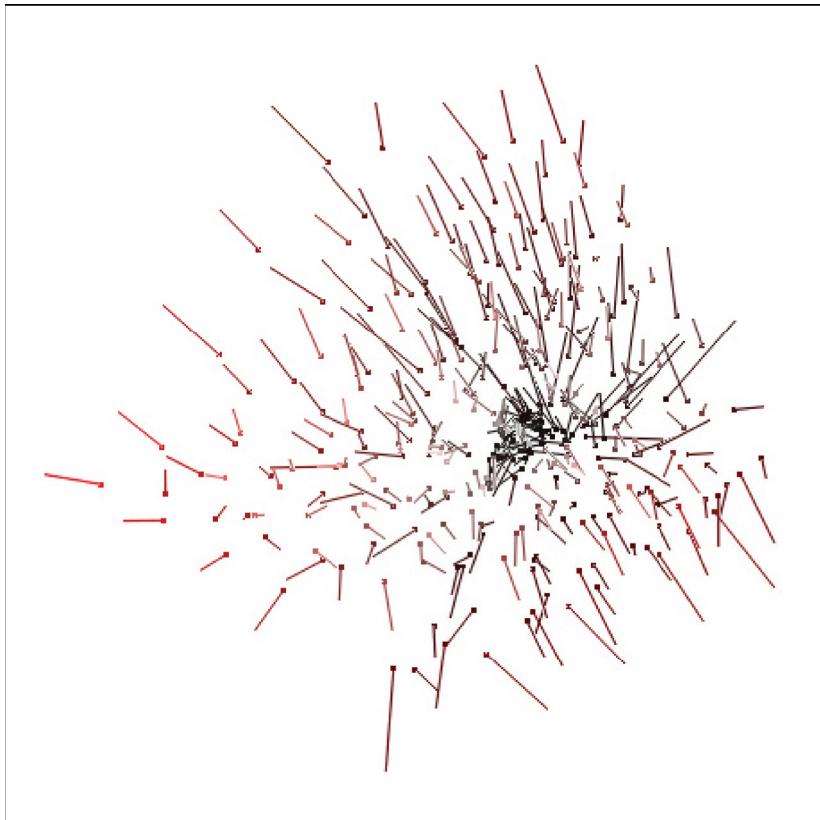
Corel Photopaint i Adobe indesign

Prikaz promjene boje načinjen u programu za analizu informacija boje Chromix ColorThink u 2D prikazu. Na lijevoj slici nalazi se prikaz promjene boje na otisku, dok se na desnoj strani nalaze iste vrijednosti izmjerene unutar pdf dokumenta. Ta je slika označena s prefiksom PDF. Uspoređuju se originalni i završni dokument. Krajnja točka svakog pomaka označena je točkom na kraju linije.

Slika 47 Prikaz promjene boje prilikom prijenosa podataka Corel Photopaint u Adobe Indesign



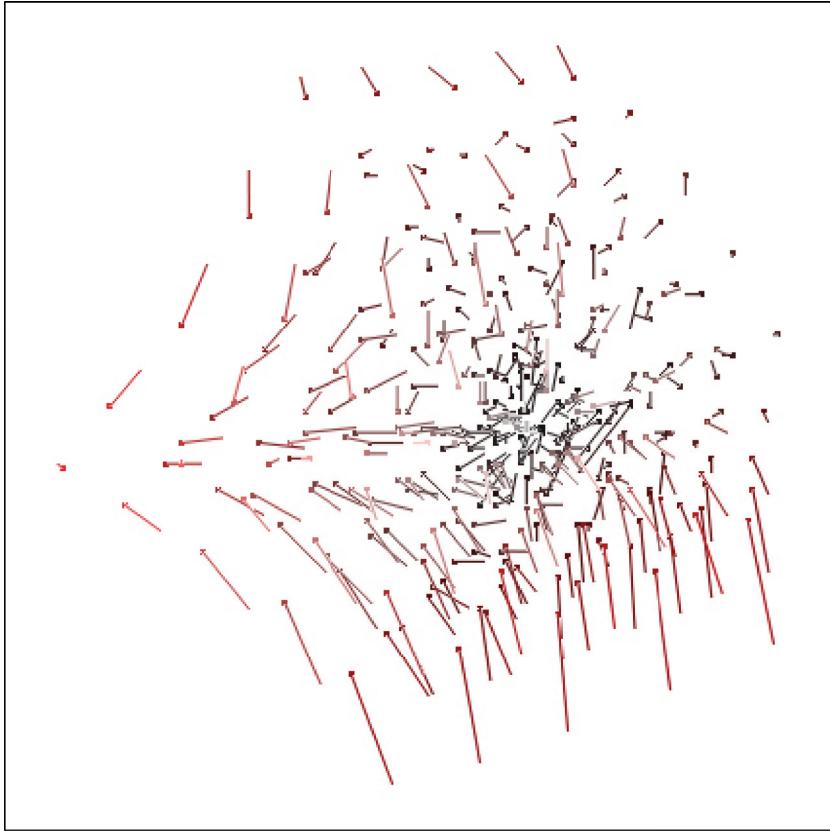
PDF Adobe Photoshop u Corel Photopaint



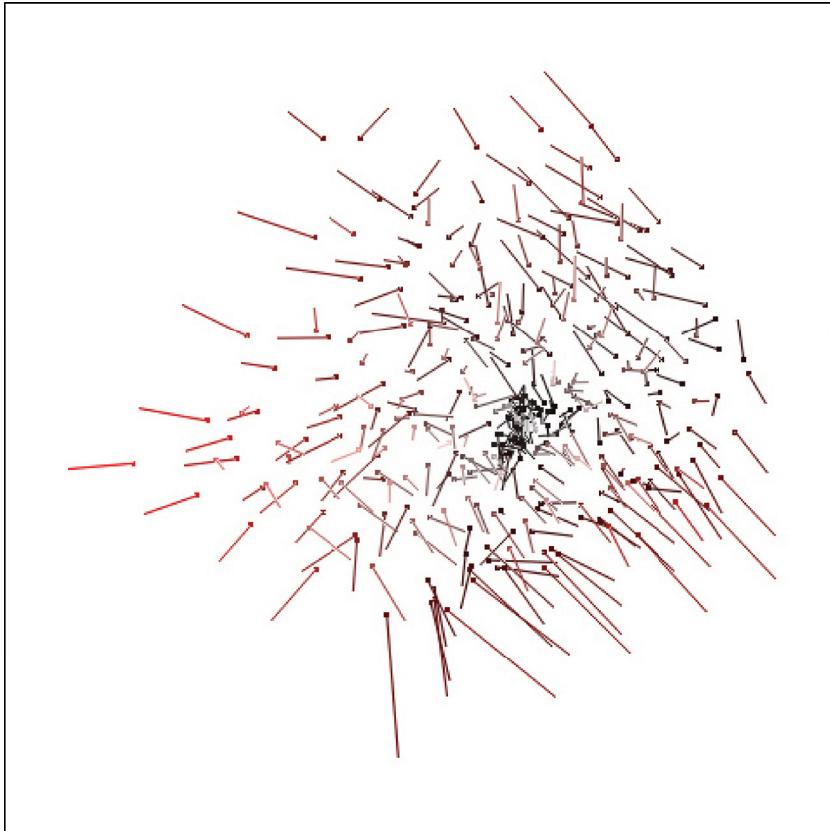
Adobe Photoshop u Corel Photopaint

Prikaz promjene boje načinjen u programu za analizu informacija boje Chromix ColorThink u 2D prikazu. Na lijevoj slici nalazi se prikaz promjene boje na otisku, dok se na desnoj strani naže iste vrijednosti izmjerene unutar pdf dokumenta. Ta je slika označena s prefiksom PDF. Uspoređuju se originalni i završni dokument. Krajnja točka svakog pomaka označena je točkom na kraju linije.

Slika 48 Prikaz promjene boje prilikom prijenosa podataka Adobe Photoshop u Corel Photopaint



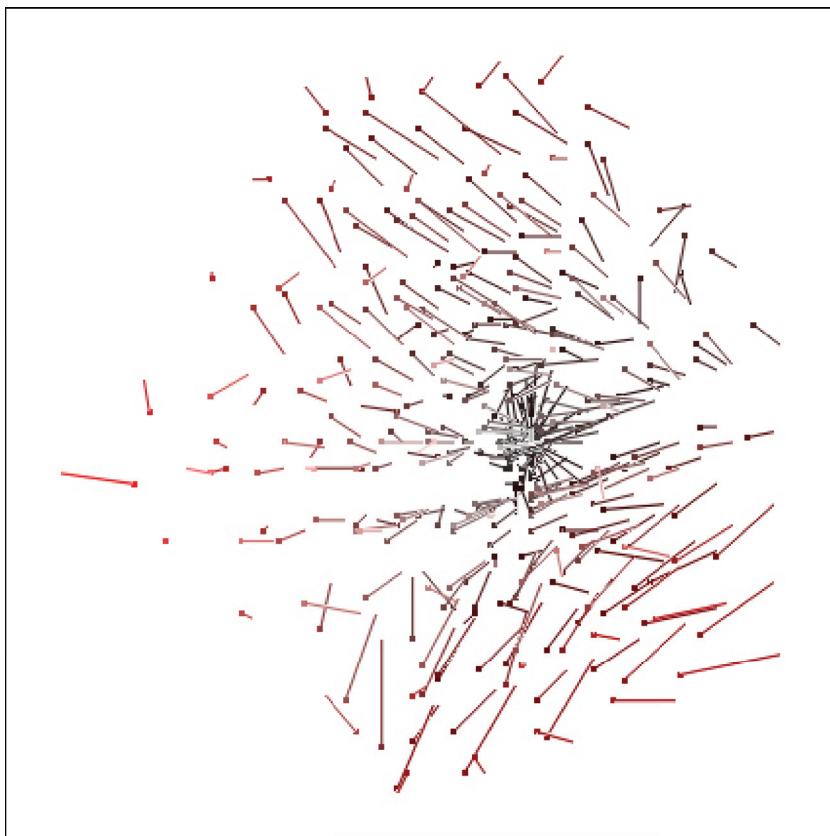
PDF Adobe Photoshop u Corel Draw



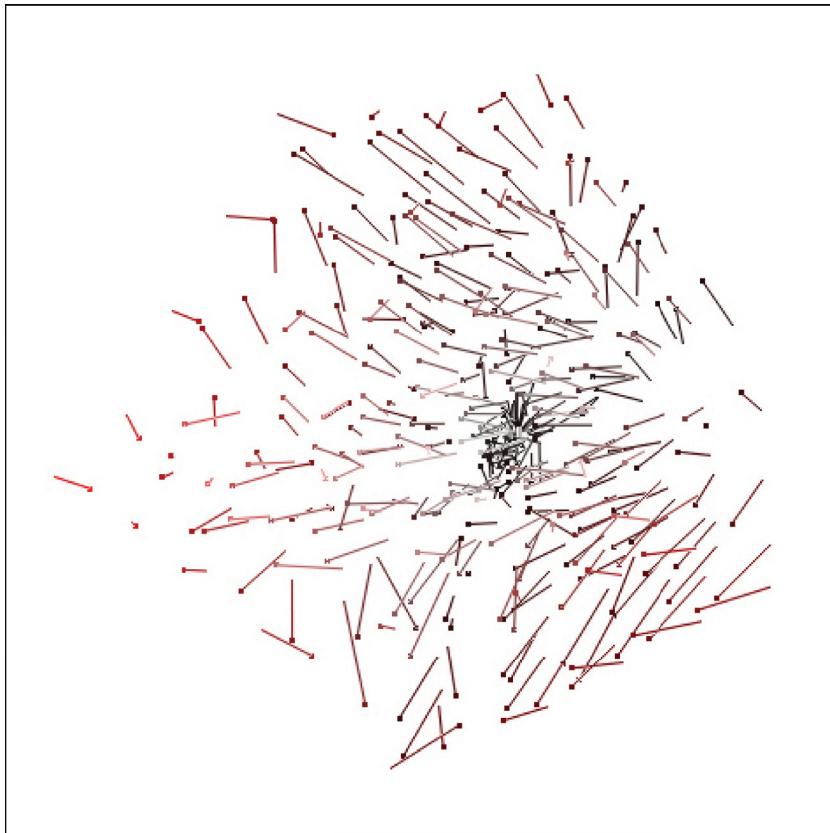
Adobe Photoshop u Corel Draw

Prikaz promjene boje načinjen u programu za analizu informacija boje Chromix ColorThink u 2D prikazu. Na lijevoj slici nalazi se prikaz promjene boje na otisku, dok se na desnoj strani nalaze iste vrijednosti izmjerene unutar pdf dokumenta. Ta je slika označena s prefiksom PDF. Uspoređuju se originalni i završni dokument. Krajnja točka svakog pomaka označena je točkom na kraju linije.

Slika 49 Prikaz promjene boja prilikom prijenosa podataka Adobe Photoshop u Corel Draw



PDF Corel Draw u Adobe Illustrator



Corel Draw u Adobe Illustrator

Prikaz promjene boje načinjen u programu za analizu informacija boje Chromix ColorThink u 2D prikazu. Na lijevoj slici nalazi se prikaz promjene boje na otisku, dok se na desnoj strani nalaze iste vrijednosti izmjerene unutar pdf dokumenta. Ta je slika označena s prefiksom PDF. Uspoređuju se originalni i završni dokument. Krajnja točka svakog pomaka označena je točkom na kraju linije.

Slika 50 Prikaz promjene boja prilikom prijenosa podataka Corel Draw u Adobe Illustrator

Idealni uvjeti koje nije moguće dobiti na otisku vidljivi su na grafu uzorka Pdf Corel Photopaint u Adobe Indesign. Čak i kada bi svi alati i operativni sustav radili po istim standardima, u tisku se događaju prirasti boje, koje je moguće smanjiti, ali ih nije moguće ukloniti. U realnim uvjetima nije moguće idealno podesiti sve uvjete i dobiti idealan otisak.

Na osnovu izmjerениh vrijednosti moguće je uočiti velike razlike između originala i reprodukcija. Međutim, kako bi se ustanovilo koliko to doista rezultira percepcijom smanjene kvalitete konačnog grafičkog proizvoda, potrebno je provesti vizualno istraživanje.

2.5. Vizualno ispitivanje

Za vizualno ispitivanje korištena je skupina od 18 ispitanika. Ispitanici su prošli Isihara test vida i ocjenjuju uzorke načinjene na osnovu očitanih vrijednosti i fotografija. Ispitivanje će se provesti u standardnim uvjetima osvjetljenja.

Promjene će se utvrditi za svako ispitivanje posebno, pa će se tako odvojiti ispitivanje percepcije obojenja pomoću testnih polja i fotografija.

Ispitivanje na osnovi testnih polja dat će razinu promjene pojedinačne boje i njen odnos sa svojim reprodukcijama, a ispitivanje fotografija dat će utjecaj cjelokupne promjene na percepciju cijele slike.

Mjerenjem otisnutih uzoraka izdvojena su polja s najvećom ΔE . Na temelju tih vrijednosti izrađeni su testni uzorci za vizualno ocjenjivanje. U tabeli 14. su prikazani su testni uzorci s najvišom ΔE .

Tabela 14 Deset polja s najvećom ΔE za svaku varijantu

	Photoshop u Illustrator	Photoshop u Indesign	Photoshop u Corel Draw	Photopaint u Photoshop	Photopaint u Indesign	Illustrator u Photoshop	Illustrator u Indesign	Illustrator u Corel Draw	Corel Draw u Photoshop	Corel Draw u Indesign	Corel Draw u Illustrator	Photoshop u Photopaint
Polje	285	171	233	285	17	199	17	171	122	233	351	364
$\Delta E2000$	14,0516	16,9381	17,1139	16,3285	5,3508	6,5214	4,6046	16,9279	13,7758	20,1208	13,6261	14,0499
Polje	351	233	171	122	288	17	24	233	285	171	240	17
$\Delta E2000$	12,6016	16,6597	16,6859	12,6015	3,9183	5,5498	4,5929	15,2338	12,9393	19,2322	11,7277	13,6380
Polje	17	351	234	54	123	233	45	351	125	234	364	363
$\Delta E2000$	11,2838	15,0722	15,1190	12,4884	3,5995	4,8581	4,4960	15,2016	12,3993	16,6224	11,6136	13,1603
Polje	373	234	315	217	351	162	288	234	351	315	230	351
$\Delta E2000$	10,5615	14,3192	15,0038	12,3797	3,4989	4,5774	3,9746	14,4447	11,9038	15,9332	11,4748	12,7713
Polje	10	315	351	373	24	273	154	249	109	24	133	172
$\Delta E2000$	10,0505	13,6004	14,1186	12,2414	3,4417	4,4211	3,6579	13,4588	11,6674	15,6626	11,4684	12,1561
Polje	8	223	223	220	33	317	351	315	52	223	17	377
$\Delta E2000$	9,9580	13,2849	13,6910	12,0944	3,3825	4,4200	3,6529	13,2835	11,5669	15,2542	11,2997	11,7583
Polje	45	377	377	254	19	45	33	377	190	351	131	214
$\Delta E2000$	9,9516	13,0226	12,8566	11,6270	3,3553	4,4155	3,4865	13,2355	11,2877	15,1576	10,8447	11,6915
Polje	109	24	17	114	69	205	115	223	230	125	199	202
$\Delta E2000$	9,5797	12,8071	12,7550	11,5938	3,3422	4,2546	3,4306	12,9053	11,0229	14,2550	10,8294	11,5616
Polje	220	172	24	337	45	170	230	24	220	273	332	366
$\Delta E2000$	9,1446	12,4322	12,6301	11,5034	3,2475	3,9596	3,2363	12,8796	10,8058	13,7685	10,4442	11,0896
Polje	364	17	36	109	160	281	14	17	17	288	321	326
$\Delta E2000$	8,8958	12,4113	11,8181	10,9556	3,2173	3,7834	3,2205	12,8594	10,7244	13,2693	10,2810	11,0708

Uspoređivanjem polja izdvojena su sva polja koja se ponavljaju u tabeli te su izdvojena polja za vizualnu usporedbu. Polja za vizualnu usporedbu označena su sivom bojom. Od 12 varijanti uzoraka uzeto je pet polja. Ukoliko se neko polje ponavljalo kod prethodne varijante, ono nije uzeto za istraživanje kod sljedeće ili sljedećih varijanti.

Vizualnom usporedbom može se ustanoviti da je do promjene najviše dolazilo kod tamnijih tonova.

Kod 12 različitih varijanti uzoraka određeni broj polja se značajno više puta pojavljivao kao jedno od pet polja s najvećom ΔE . U tabeli 15. prikazana su polja i njihov broj pojavljivanja u poljima s najvećom ΔE .

Tabela 15 Broj ponavljanja istih polja među poljima s najvećom $\Delta E2000$ razlikom

Polje	Broj pojavlivanja	Polje	Broj pojavlivanja	Polje	Broj pojavlivanja
8	1	154	1	249	1
10	1	160	1	254	1
14	1	162	1	273	1
17	10	170	1	273	1
19	1	171	4	281	1
24	6	172	1	285	3
33	2	172	1	288	3
36	1	190	1	315	4
45	4	199	2	317	1
52	1	202	1	321	1
54	1	205	1	326	1
69	1	214	1	332	1
109	3	217	1	337	1
114	1	220	3	351	10
115	1	223	4	363	1
122	2	230	2	364	3
123	1	230	1	366	1
125	2	233	5	373	2
131	1	234	4	377	4
133	1	240	1		

Polja 17, 24, 45, 171, 223, 233, 234, 315, 351 i 377 pojavila su se 4 ili više puta. To su uzorci u plavim, zelenim, crnim i smeđim nijansama. Nijanse crvene boje se isto tako mijenjaju, ali po ΔE vrijednostima ne ulaze u polja s najvećim promjenama boje.

Usporedbom uzorka ustanovljeno je da kod pdf dokumenta nije bilo promjene prilikom prijenosa informacija o boji korištenjem međuspremnika kod varijanti Photopaint u Indesign, Illustrator u Photoshop i Illustrator u Indesign. Sve numeričke vrijednosti očitanih klinova su manje od 0,01 ΔE , što je manje od moguće pogreške uređaja.

Tabela 16 Prikaz najvećih izmjerjenih ΔE kod uzorka na osnovi kojih je određen 1. uzorak
čije su vrijednosti jednake originalu.

Illustrator u Indesign		Photopaint u Indesign		Illustrator u Photoshop	
Polje	$\Delta E2000$	Polje	$\Delta E2000$	Polje	$\Delta E2000$
1	0,278531	1	0,278531	1	0
3	0,367929	3	0,367929	2	0
22	0,277275	22	0,277275	3	0
50	0,290739	50	0,290739	4	0
61	0,310604	61	0,310604	5	0
63	0,271767	63	0,271767	6	0
118	0,27662	118	0,27662	7	0
233	0,356607	233	0,356607	8	0
237	0,324069	237	0,324069	9	0
243	0,282727	243	0,282727	10	0
Prosječni DeltaE2000 cjelokupnog kalib. klina		Prosječni DeltaE2000 cjelokupnog kalib. klina		Prosječni DeltaE2000 cjelokupnog kalib. klina	
0,0923133102		0,0923133102		0	

Dalnjom analizom utvrđene su velike sličnosti u dobivenim vrijednostima.

Sukladno tome, za potrebe vizualnog ispitanja, s obzirom da je ΔE uzorka varijanti Adobe Illustrator u Corel Draw, Photoshop u Corel Draw i Photoshop u Indesign zanemariv ($\Delta E < 0,4$), za te varijante formiran je zajednički uzorak.

Tabela 17 Prikaz najvećih izmjerjenih ΔE kod uzorka na osnovi kojih je određen 2. uzorak

Illustrator-Corel Draw i Photoshop u Indesign		Corel Draw-Photoshop i Corel Draw-Illustrator		Illustrator-Corel Draw i Photoshop u Indesign	
Polje	$\Delta E2000$	Polje	$\Delta E2000$	Polje	$\Delta E2000$
76	6,143922	20	1,031962	4	1,031962
96	3,790987	55	0,949274	18	1,036272
116	2,139808	98	1,130862	29	1,107067
169	3,866186	99	1,036272	77	0,949274
181	6,740755	122	0,953625	101	1,399212
182	3,534319	147	1,107067	136	1,130862
211	4,947652	152	1,096263	161	0,953625
214	2,302185	301	0,957638	257	1,314102
301	6,232017	323	1,399212	304	1,096263
324	2,725219	359	1,314102	353	0,995814
Prosječni DeltaE2000 cjelokupnog kalib. klina		Prosječni DeltaE2000 cjelokupnog kalib. klina		Prosječni DeltaE2000 cjelokupnog kalib. klina	
0,32567		0,379396		0,379396	

Kod pojedinih polja varijanti Adobe Illustrator-Corel Draw i Photoshop-Indesign postoje i velike razlike, međutim, ukupan ΔE cjelokupnog klini je nizak ($\Delta E < 0,4$).

Na ovaj način pojednostavljuje se istraživanje i smanjuje opterećenje ispitanika dodatnim uzorcima koji nisu relevantni za postavljeno istraživanje.

Na osnovi svega prethodno iznesenog formirana su dva uzorka, koja predstavljaju pojedine skupine.

Tabela 18 Prikaz pojedinih skupina sa zajedničkim uzorkom

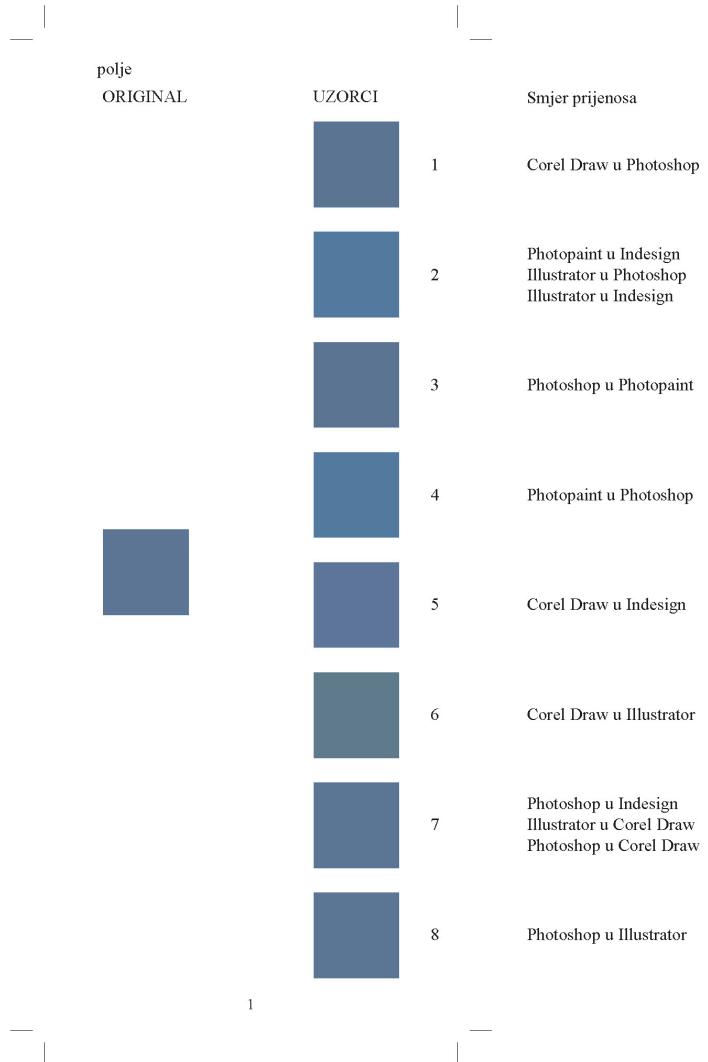
1. uzorak	2. uzorak
Corel Photopaint u Adobe Indesign	Adobe Illustrator u Corel Draw
Adobe Illustrator u Adobe Photoshop	Adobe Photoshop u Corel Draw
Adobe Illustrator u Adobe Indesign	Adobe Photoshop u Adobe Indesign

U skladu s time formirani su konačni testni uzorci.

Tabela 19 Prikaz uzoraka

Redni broj	Smjer prijenosa
1	Photoshop u Illustrator
2	Photoshop u Indesign Illustrator u Corel Draw Photoshop u Corel Draw
3	Photopaint u Photoshop
4	Photopaint u Indesign Illustrator u Photoshop Illustrator u Indesign
5	Corel Draw u Photoshop
6	Corel Draw u Indesign
7	Corel Draw u Illustrator
8	Photoshop u Photopaint

Kartice za vizualno ispitivanje napravljene su u formatu 100x240 mm. S lijeve strane kartice stavljen je uzorak originalne boje, a s desne izmjereni uzorci.



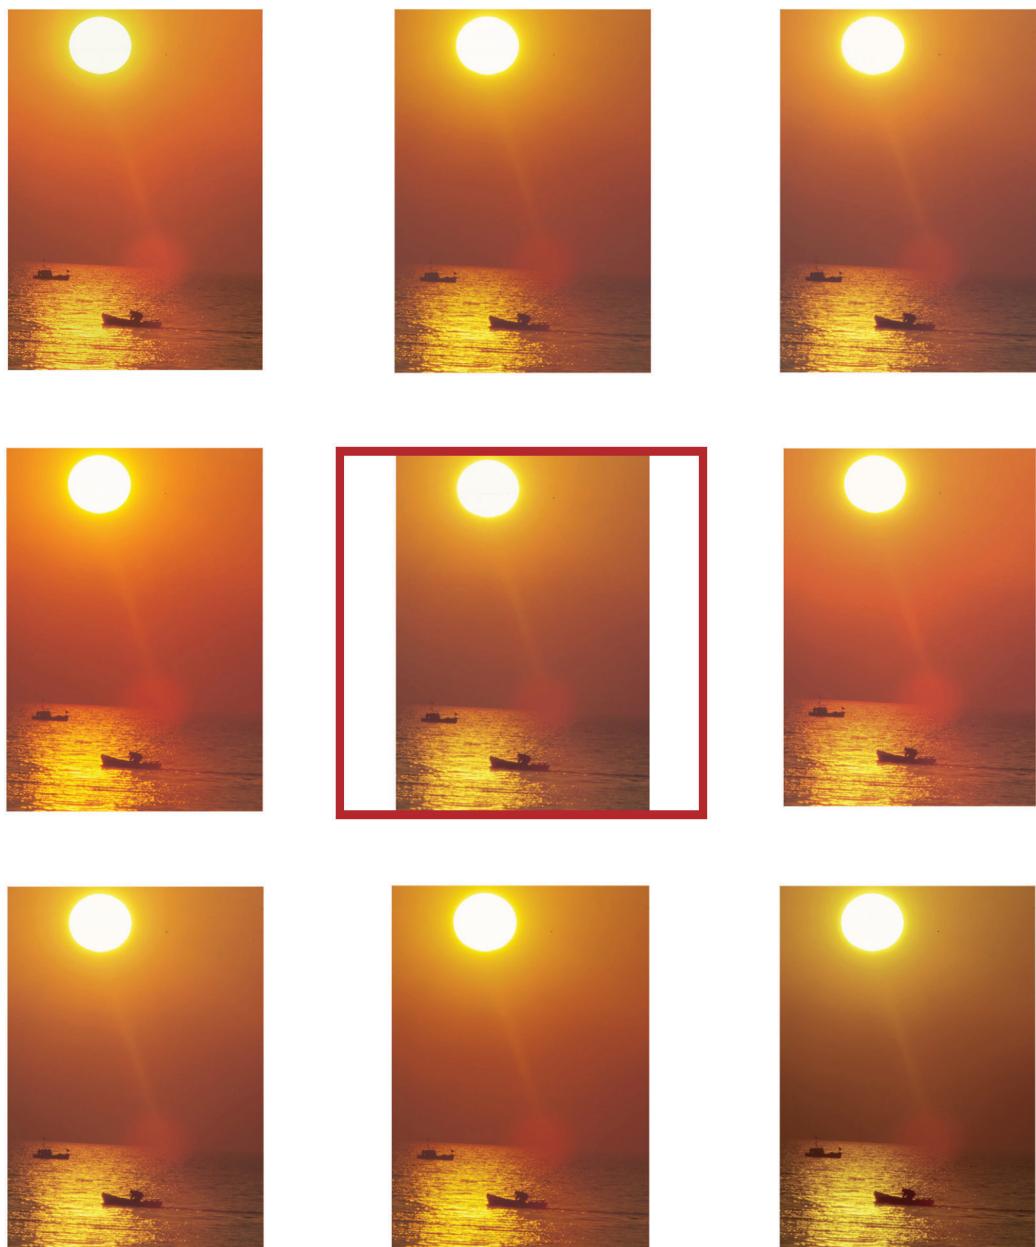
Slika 51 Izgled uzorka za vizualno ocjenjivanje. Van uzorka je navedeno porijeklo pojedinog uzorka, koje se ne vidi na otisku

Na isti način izrađena su 44 testna uzorka. Međutim, s obzirom da je razlika bila lako uočljiva (za svih 18 ispitanika) te s obzirom da u realnoj grafičkoj proizvodnji u načelu rijetko prenosimo samo određenu boju – već je to najčešće neka slika - istraživanje je prošireno tako da su napravljeni novi testni uzorci s različitim motivima. Odabранo je 7 motiva – s time da je kod 6 motiva bila određena neka boja kao dominantna te motiv ljudskog lica.

Sukladno tome dobiveno je sedam setova testnih uzoraka. Zadatak svakog ispitanika je bio odrediti koji je od testnih uzoraka najviše odgovarao originalu za svih sedam setova.

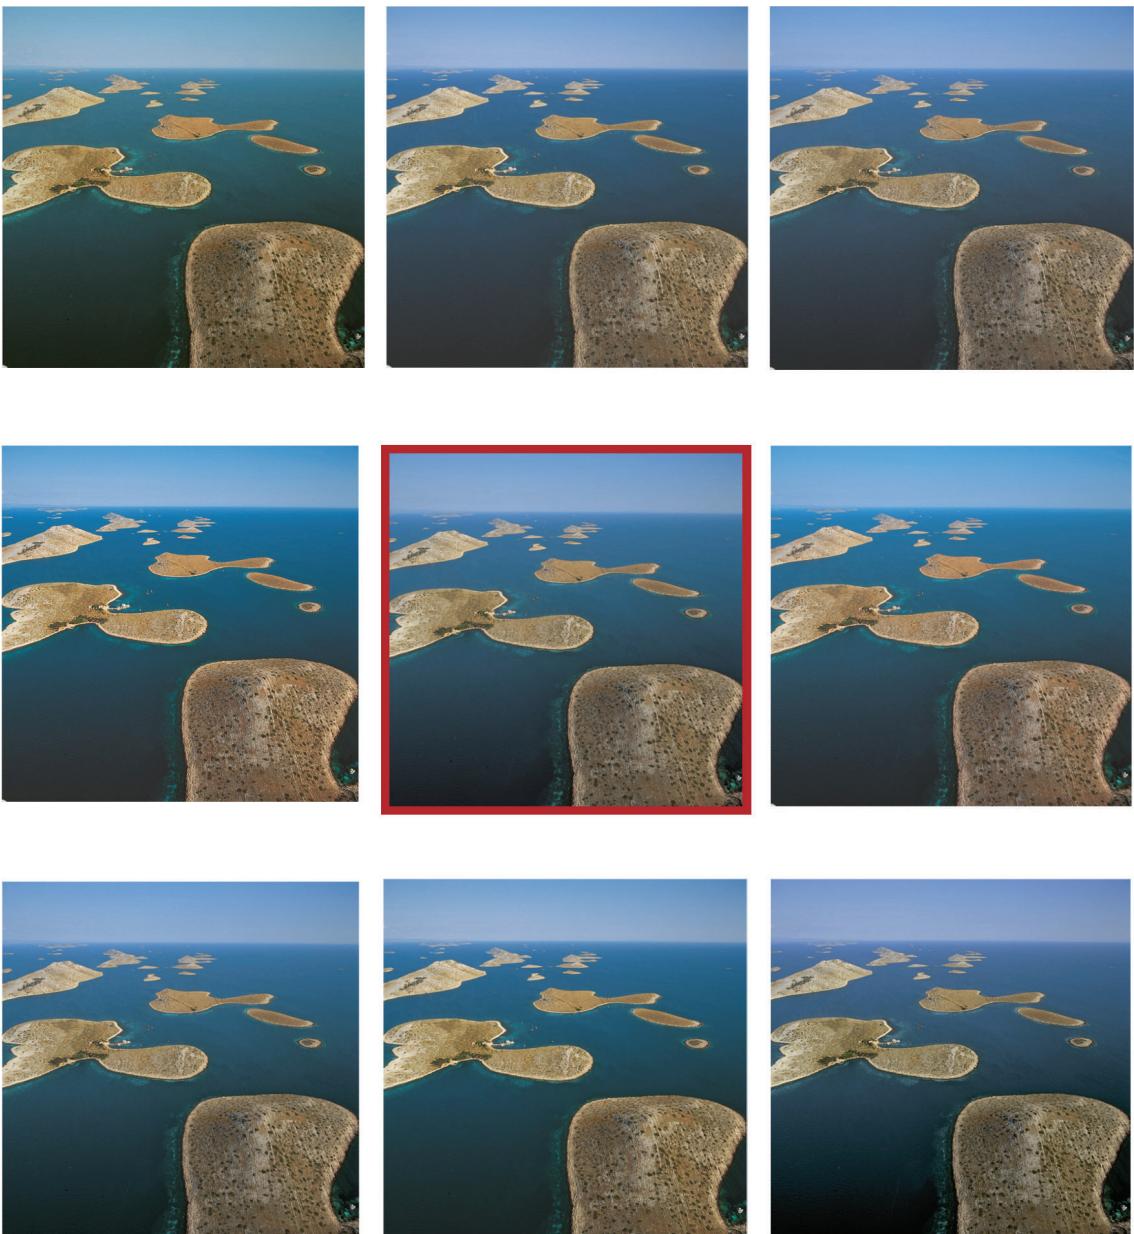


Slika 52 Prikaz 1. motiva i njegovih reprodukcija.
Original se nalazi u sredini, okružen crvenim rubom.



Slika 53 Prikaz 2. motiva i njegovih reprodukcija.

Original se nalazi u sredini, okružen crvenim rubom.



Slika 54 Prikaz 3. motiva i njegovih reprodukcija.
Original se nalazi u sredini, okružen crvenim rubom.



Slika 55 Prikaz 4. motiva i njegovih reprodukcija.
Original se nalazi u sredini, okružen crvenim rubom.



Slika 56 Prikaz 5. motiva i njegovih reprodukcija.

Original se nalazi u sredini, okružen crvenim rubom.



Slika 57 Prikaz 6. motiva i njegovih reprodukcija.
Original se nalazi u sredini, okružen crvenim rubom.



Slika 58 Izgled fotografije lica korištene u ocjenjivanju.

Fotografija lica kod slike 58. preuzeta je iz pdf dokumenata. Na njoj se također može uočiti da se iste fotografije u načelu mogu podijeliti u dvije skupine. Prvu

skupinu čine fotografije smanjenog kontrasta i manje zasićenosti boja, a druga je nasuprot tome zasićenija od originala.

U skladu s time, ispitanici su relativno brzo i lako odredili reprodukciju najbližu originalu. Međutim, razmjerno velik problem im je predstavljalo poredati ostale reprodukcije, a s obzirom na veliku razliku u odnosu na originalu.

Pri ocjenjivanju sličnosti slikovnog originala s reprodukcijom znatno je teže odrediti kvalitetu, zbog međusobnog utjecaja svih elemenata slike na doživljaj same slike.

Tabela 20 Prikaz uzorka koji je određen kao najbliži originalu

MOTIV	Uzorak 1	Uzorak 2	Uzorak 3	Uzorak 4	Uzorak 5	Uzorak 6	Uzorak 7	Uzorak 8
Motiv 1	5	1		9				1
Motiv 2	6			12				
Motiv 3	7	3		1	8			
Motiv 4	6	1		2	5			3
Motiv 5	5			3	6	3		
Motiv 6	4	2		7				4
Motiv 7	10			6				2
UKUPNO	44	7		40	19	3		10

Kao najbolje definirani uzorci pokazali su se Uzorak 1 (Adobe Photoshop u Adobe Illustrator) i Uzorak 4 (Corel Photopaint u Adobe Indesign; Adobe Illustrator u AdobePhotoshop; Adobe Illustrator u Adobe Indesign).

Dok je kod vizualne ocjene testnih klinova situacija jasna, vizualna procjena fotografije mnogo je složenija. Fotografije se naočigled mogu ocijeniti kao tamnije, svjetlijе, plavije, zelenije, žuće, crvenije, ali vizualno sve ispunjavaju svoju svrhu. One prenose informaciju o nekom mjestu, događaju, osobi i sl.

Tabela 21 Prikaz uzorka koji je određen kao najdalji originalu

MOTIV	Uzorak 1	Uzorak 2	Uzorak 3	Uzorak 4	Uzorak 5	Uzorak 6	Uzorak 7	Uzorak 8
Motiv 1		3	4				6	
Motiv 2		5					10	
Motiv 3			7			3		
Motiv 4			13				3	1
Motiv 5			9			1		4
Motiv 6			10				4	3
Motiv 7		4	12		2			
UKUPNO		12	55		2	4	23	8

Dok su kod najboljih rezultata podjednake kvalitete dva uzorka, najlošije rezultate daje Uzorak 4 (Photopaint u Photoshop).

Ispitanici su prilikom ispitivanja relativno lako određivali reprodukciju najbližu originalu, dok su kod ostalih reprodukcija imali dosta problema, s obzirom na preveliku razliku od originala.

Pri ocjenjivanju poklapanja slikovnog originala s reprodukcijom znatno je teže odrediti kvalitetu zbog međusobnog utjecaja svih elemenata slike na doživljaj same slike.

2.6. Diskusija rezultata

Sintezom rezultata istraživanja nastoji se odgovoriti na pitanje je li ovakav način rada prikladan grafičkoj industriji s obzirom na sve veće zahtjeve suvremenog društva za sve većom kvalitetom i višim standardima.

Instrumentalna analiza ukazala je na relativno velike razlike u promjenama boje. Događaju se promjene na razini zasićenja i pomaka od neke boje prema nekoj drugoj. U tom smislu primjerice nijansa zelene boje može prijeći u plavu nijansu i sl.

S obzirom na iste rezultate, promatrajući samo određene segmente (pojedina polja kalibracijskog klina), možemo ustanoviti da se prilikom prijenosa podataka između pojedinih grafičkih alata upotrebot međuspremnika događaju velike promjene, tako da je u tom smislu za ozbiljnu grafičku proizvodnju jedino prihvatljiva upotreba originalnog dokumenta.

Vizualna kontrola određenih segmenata (pojedinih polja kalibracijskih klinova) potvrđuje rezultate instrumentalne analize.

Međutim, prilikom korištenja slike kao elementa koji se prenosi, stvari su puno kompleksnije te ukazuju na utjecaj niza drugih parametara poput motiva.

Kod različitih motiva postignuti su različiti rezultati. Najčešće ispitanici, na osnovu iskustva očekuju da je primjerice more plavo. U skladu s tim iskustvom i nizom drugih utjecaja uglavnom zaključuju da je neka reprodukcija u redu – iako se ona može znatno razlikovati od originala.

U skladu s time, ispitanici uglavnom lako odrede da je reprodukcija različita od originala, ali u načelu tu razliku teško mogu opisati.

3. Zaključak

U suvremenoj grafičkoj proizvodnji upotreba međuspremnika je gotovo svakodnevna rutina. Međutim, prilikom korištenja istog moguće je nastanak niza problema koji mogu rezultirati smanjenom kvalitetom konačnog grafičkog proizvoda. U većini slučajeva, ti problemi prvenstveno nastaju zbog korištenja različitih grafičkih alata, a ovise u najvećoj mjeri o vrsti podataka koji se prenose korištenjem međuspremnika te o samim grafičkim alatima, kao i smjeru prijenosa.

Kod vektorskih podataka može doći po promjene boje i definicije krivulja. Kod prijenosa tekstualnih podataka moguće su promjene u obliku pisma, veličini, boji i sl. Sve su te promjene vidljive i profesionalci ih očekuju i relativno lako ispravljaju. Međutim, to je znatno komplikiranje prilikom prijenosa slikovnih informacija. Lako prilikom prijenosa slikovnih informacija iz jednog programa u drugi dolazi do promjena informacija o boji, u većini slučajeva te se promjene zanemaruju.

S obzirom da suvremeno društvo zahtijeva sve bolju kvalitetu, grafička industrija godinama intenzivno radi na kvaliteti grafičkog proizvoda i uspostavi standarda u svim segmentima grafičke proizvodnje.

S obzirom da postoje dva osnovna načina unosa slike u radni dokument, potrebno je napomenuti da je stariji i danas još uvijek prevladavajući način unosa slike iz originalnog dokumenta najbolji i najkvalitetniji za tu svrhu. Međutim, tijekom godina, suvremena proizvodnja naglašava jednostavnost i brzinu kao također izuzetno bitan parametar, koji stalno dobiva na važnosti. U tom smislu u tijeku je stalna potraga za bržim i lakšim načinom izrade nekog proizvoda. Upotreba međuspremnika je jedan takav način, iako to može utjecati na konačnu kvalitetu grafičkog proizvoda.

Prilikom prijenosa informacija upotrebom međuspremnika u načelu uvijek dolazi do prilagodbi tih informacija, što može rezultirati do promjenom obojenja slike. Ovisno o smjeru prijenosa informacije i prevladavajućim bojama unutar nekog dokumenta, ta promjena može biti neprimjetna, ali i vidljiva.

Vizualnim ispitivanjem ustanovljeno je da se te promjene lakše uočavaju kod određenih vrsta motiva. U tom smislu ispitanici su znatno lakše uočavali te promjene kod motiva ljudskog lica, kao i kod mora i šuma, odnosno kod motiva gdje postoji više detalja za razliku od primjerice zimskih motiva, gdje je općenito manje informacija o boji.

Od motiva koji su bili reproducirani i koji su poslužili za reprodukciju testnih uzoraka, razlika je najlakše uočavana kod motiva ljudskog lica, a najteže kod testnih uzoraka s motivima kod kojih je dominirala crvena boja.

Iako i instrumentalna i vizuelna analiza potvrđuju da se korištenjem međuspremnika prilikom prijenosa informacija događaju promjene, u realnoj grafičkoj proizvodnji isti se koristi, radi jednostavnosti i potrebe za bržom reakcijom.

U skladu s time, a radi postizanja većeg nivoa standardizacije, upotreba međuspremnika u profesionalne svrhe zahtijevat će dodatne prilagodbe operativnih sustava i grafičkih alata.

4. Literatura

1. Kipphan H. Handbook of print media: technologies and production methods. Berlin ;;New York: Springer; 2001.
2. Marius Pedersen¹, Nicolas Bonnier², Jon Y. Hardeberg¹, and Fritz Albregtsen³; ¹Gjøvik University College (Norway), ²Océ Print Logic Technologies SA (France), and ³University of Oslo (Norway). Attributes of a New Image Quality Model for Color Prints. Springfield VA: IS & T-Society for Imaging Science and Technology; 2009.
3. Schefrin BE, Werner JS. Age-related changes in the color appearance of broadband surfaces. *Color Research & Application*. 1993;18(6):380–9.
4. Verrelli BC, Tishkoff SA. Signatures of Selection and Gene Conversion Associated with Human Color Vision Variation. *The American Journal of Human Genetics*. 2004;75(3):363–75.
5. Fairchild M. Color appearance models. 2nd ed. Chichester West Sussex England ;;Hoboken NJ: J. Wiley; 2005.
6. Norton TT, Corliss DA, Bailey JE, Bailey JE. The psychophysical measurement of visual function [Internet]. Butterworth-Heinemann; 2002. Available from: <http://books.google.com/books?id=N-CbQgAACAAJ>
7. Fish W. Philosophy of perception : a contemporary introduction. London ;;New York: Routledge; 2009.
8. Robinson H. Perception [Internet]. London ; New York: Routledge; 1994. Available from: <http://books.google.hr/books?id=u-oOAAAAQAAJ&lpg=PA264&ots=8i8FAsfXaE&dq=isbn%200415033640&pg=PP1#v=onepage&q&f=false>
9. Fraser B. Real world color management : industrial-strength production techniques. 2nd ed. Berkeley CA: Peachpit Press; 2005.
10. Allen E. The manual of photography. 10th ed. Oxford: Focal; 2011.
11. Reinhard E. Color imaging : fundamentals and applications. Wellesley Mass: A K Peters; 2007.
12. Young-Helmholtz three-colour theory -- Britannica Online Encyclopedia [Internet]. [cited 2011 Sep 10];Available from: <http://www.britannica.com/EBchecked/topic/654047/Young-Helmholtz-three-colour-theory>
13. Andrew Rodney. The role of working spaces in Adobe applications. 2006;
14. Wyszecki G, Stiles WS. Color science: concepts and methods, quantitative data, and formulae [Internet]. John Wiley & Sons; 2000. Available from:

http://books.google.com/books?id=_51HDcjWZPwC

15. Lilley C, Science U of MD of C, Unit MCCCG, Initiative ITT. Colour in computer graphics [Internet]. CVCP/USDU; 1993. Available from: <http://books.google.com/books?id=IzrZAQAAACAAJ>
16. Optical Society of America., Shevell S. The science of color. 2nd ed. Amsterdam ;;Boston ;[United States]: Elsevier ;;Optical Society of America; 2003.
17. Sundell J. Colour proof quality verification. Institutionen för teknik och naturvetenskap; 2004.
18. Klein G. Industrial color physics. English ed. New York: Springer; 2010.
19. Pauli H. Proposed extension of the CIE recommendation on Uniform color spaces, color difference equations, and metric color terms. *J. Opt. Soc. Am. Journal of the Optical Society of America*. 1976;66(8).
20. Lee H-C. Introduction to color imaging science. Cambridge UK ;;New York: Cambridge University Press; 2005.
21. Luo MR. Colour difference formulae: Past, present and future. *CIE Expert Symposium*. 2006;14:13–5.
22. Zhang X, Wandell BA. A spatial extension of CIELAB for digital color-image reproduction. *Journal of the Society for Information Display*. 1997;5(1):61–3.
23. heidelberg expert_guide_color.pdf.
24. McDonald R. Acceptability and Perceptibility Decisions Using the CMC Color Difference Formula. *Textile Chemist and Colorist*. 1988 Jun;20(6).
25. International Commission on Illumination. Improvement to industrial colour difference evaluation. Vienna: CIE Central Bureau; 2001.
26. Luo MR, Cui G, Rigg B. The development of the CIE 2000 colour-difference formula: CIEDE2000. *Color Research & Application*. 2001;26(5):340–50.
27. Ohta N. Colorimetry : fundamentals and applications. Chichester: John Wiley; 2005.
28. Mesić V. Tehnologija knjigotiska. Grafički školski centar; 1970.
29. Walenski W. Der Offsetdruck : eine Einführung in Theorie und Praxis. Köln: DuMont; 1991.
30. Dhotre IA. Operating Systems [Internet]. Technical Publications; 2009. Available from: <http://books.google.com/books?id=iQzqVqFz3IsC>

31. Operating system market share [Internet]. [cited 2011 Nov 17];Available from: <http://marketshare.hitslink.com/operating-system-market-share.aspx?qprid=10>
32. Green P. Colour management. Chichester: John Wiley; 2007.
33. About the Clipboard (Windows) [Internet]. [cited 2011 Sep 11];Available from: [http://msdn.microsoft.com/en-us/library/ms649012\(v=VS.85\).aspx](http://msdn.microsoft.com/en-us/library/ms649012(v=VS.85).aspx)
34. Clipboard Formats (Windows) [Internet]. [cited 2011 Sep 11];Available from: [http://msdn.microsoft.com/en-us/library/ms649013\(v=VS.85\).aspx#_win32_Standard_Clipboard_Formats](http://msdn.microsoft.com/en-us/library/ms649013(v=VS.85).aspx#_win32_Standard_Clipboard_Formats)
35. Pasteboard Programming Guide: Introduction [Internet]. MAC OS X Developer library. [cited 2011 Nov 11];Available from: http://developer.apple.com/library/mac/#documentation/cocoa/Conceptual/PasteboardGuide106/Introduction/Introduction.html#/apple_ref/doc/uid/TP40008100-SW1
36. Pasteboard Programming Guide: Introduction [Internet]. [cited 2011 Nov 11];Available from: http://developer.apple.com/library/mac/#documentation/cocoa/Conceptual/PasteboardGuide106/Introduction/Introduction.html#/apple_ref/doc/uid/TP40008100-SW1
37. Bleicher S. Contemporary color theory and use [Internet]. Thomson/Delmar Learning; 2005. Available from: <http://books.google.ca/books?id=YgbI5pPylsYC>
38. What is Computer Graphics? [Internet]. [cited 2011 Nov 18];Available from: <http://www.graphics.cornell.edu/online/tutorial/>
39. PDF files | Adobe Portable Document Format - Acrobat [Internet]. [cited 2011 Nov 21];Available from: <http://www.adobe.com/products/acrobat/adobepdf.html>
40. Padova T. Adobe Acrobat PDF bible. Hoboken N.J. ;Chichester: Wiley ;;John Wiley [distributor]; 2008.
41. G. Sharma, W. Wu, E. N. Dalal. The CIEDE2000 Color-Difference Formula: Implementation Notes, Supplementary Test Data, and Mathematical Observations. *Color Research and Application*. 2005 Feb;30(1):21–30.

5. Popis tabela

Tabela 1 Standardizirane vrijednosti boje različitih izvora svjetla

Tabela 2 Povijesni prikaz većine modela razlike boja od razvoja CIE kolorimetrijskog sustava

Tabela 3 Usporedba standardnih promatrača 2° i 10°

Tabela 4 Razvoj operativnih sustava

Tabela 5 Prikaz dijela formata za prijenos slikovnih informacija u operativnom sustavu Microsoft Windows

Tabela 6 Podjela programa za grafičku pripremu i predstavnici industrije u podjeli

Tabela 7 Prikaz dijela zapisa podataka koji se koriste u grafičkoj industriji

Tabela 8 Smjer kretanja slikovnih podataka

Tabela 9 Prikaz karakteristika Xerox DC700 tiskarskog stroja

Tabela 10 Tehnološke karakteristike X-Rite DTP41

Tabela 11 Osnovne karakteristike papira za umjetnički tisk

Tabela 12 Prikaz deset izmjerениh polja s najvećim ΔE_{2000} u svakom uzorku

Tabela 13 Srednje ΔE_{2000} vrijednosti izmjerene za svaki uzorak i razlika između istog uzorka prije i poslije tiska

Tabela 14 Deset polja s najvećom ΔE za svaku varijantu

Tabela 15 Broj ponavljanja istih polja među poljima s najvećom ΔE_{2000} razlikom

Tabela 16 Prikaz izmjerenih ΔE kod uzorka na osnovu kojih je određen 1. uzorak čije su vrijednosti jednake originalu

Tabela 17 Prikaz izmjerenih ΔE kod uzorka na osnovu kojih je određen 2. uzorak

Tabela 18 Prikaz pojedinih skupina sa zajedničkim uzorkom

Tabela 19 Prikaz uzorka

Tabela 20 Prikaz uzorka koji je određen kao najbliži originalu

Tabela 20 Prikaz uzorka koji je određen kao najdalji originalu

6. Popis formula

- 1 - Wyszecki G, Stiles WS. Color science: concepts and methods, quantitative data, and formulae [Internet]. John Wiley & Sons; 2000. strana 168, 3.3.7
- 2 - Wyszecki G, Stiles WS. Color science: concepts and methods, quantitative data, and formulae [Internet]. John Wiley & Sons; 2000. strana 168, 3.3.8
- 3 - Wyszecki G, Stiles WS. Color science: concepts and methods, quantitative data, and formulae [Internet]. John Wiley & Sons; 2000. strana 168, 3.3.9
- 4- Wyszecki G, Stiles WS. Color science: concepts and methods, quantitative data, and formulae [Internet]. John Wiley & Sons; 2000. str 120, 3.3.2
- 5 - Klein G. Industrial color physics. English ed. New York: Springer; 2010., str 137, 3.1.1.
- 6 - Klein G. Industrial color physics. English ed. New York: Springer; 2010., str 137, 3.1.2.
- 7 - Klein G. Industrial color physics. English ed. New York: Springer; 2010., str 137, 3.1.3.
- 8 - Klein G. Industrial color physics. English ed. New York: Springer; 2010., str 137, 3.1.4.
- 9 - Klein G. Industrial color physics. English ed. New York: Springer; 2010. str 142, 3.1.8
- 10 - Klein G. Industrial color physics. English ed. New York: Springer; 2010. str 142, 3.1.9
- 11 - Klein G. Industrial color physics. English ed. New York: Springer; 2010. str 142, 3.1.10
- 12 - Klein G. Industrial color physics. English ed. New York: Springer; 2010. str 142, 3.1.11
- 13 - Klein G. Industrial color physics. English ed. New York: Springer; 2010., str 125, 2.4.21
- 14 - Klein G. Industrial color physics. English ed. New York: Springer; 2010., str 126, 2.4.22
- 15 - Reinhard E. Color imaging : fundamentals and applications. Wellesley Mass: A K Peters; 2007. str 460 8.87.a
- 16 - Reinhard E. Color imaging : fundamentals and applications. Wellesley Mass: A K Peters; 2007., str 460 8.87.b
- 17 - Reinhard E. Color imaging : fundamentals and applications. Wellesley Mass: A K Peters; 2007., str 460, 8.88a
- 18 - Reinhard E. Color imaging : fundamentals and applications. Wellesley Mass: A K Peters; 2007., str 460, 8.88b
- 19 - Reinhard E. Color imaging : fundamentals and applications. Wellesley Mass: A K Peters; 2007., str 460 8.88c
- 20 - Reinhard E. Color imaging : fundamentals and applications. Wellesley Mass: A K Peters; 2007., str 460, 8.89a
- 21 - Reinhard E. Color imaging : fundamentals and applications. Wellesley Mass: A K Peters; 2007., str 8.89b str 460
- 22 - Reinhard E. Color imaging : fundamentals and applications. Wellesley Mass: A K Peters; 2007., str 8.89c str 460
- 23 - Reinhard E. Color imaging : fundamentals and applications. Wellesley Mass: A K Peters; 2007., str 8.89d str 460
- 24 - Reinhard E. Color imaging : fundamentals and applications. Wellesley Mass: A K Peters; 2007., str 113, 6.49
- 25 - Reinhard E. Color imaging : fundamentals and applications. Wellesley Mass: A K Peters; 2007., str 113, 6.50
- 26 - Reinhard E. Color imaging : fundamentals and applications. Wellesley Mass: A K Peters; 2007., str 113, 6.51

- 27 - Reinhard E. Color imaging : fundamentals and applications. Wellesley Mass: A K Peters; 2007., str 113, 6.52
- 28 - Lee H-C. Introduction to color imaging science. Cambridge UK ;;New York: Cambridge University Press; 2005. str 114, 6.53
- 29 - Lee H-C. Introduction to color imaging science. Cambridge UK ;;New York: Cambridge University Press; 2005. str. 114, 6.54
- 30 - Lee H-C. Introduction to color imaging science. Cambridge UK ;;New York: Cambridge University Press; 2005. str. 114, 6.55
- 31 - Lee H-C. Introduction to color imaging science. Cambridge UK ;;New York: Cambridge University Press; 2005. str. 114, 6.56
- 32 - Lee H-C. Introduction to color imaging science. Cambridge UK ;;New York: Cambridge University Press; 2005. str. 114, 6.57
- 33 - Lee H-C. Introduction to color imaging science. Cambridge UK ;;New York: Cambridge University Press; 2005. str. 114, 6.58
- 34 - Lee H-C. Introduction to color imaging science. Cambridge UK ;;New York: Cambridge University Press; 2005. str. 114, 6.59
- 35 - Lee H-C. Introduction to color imaging science. Cambridge UK ;;New York: Cambridge University Press; 2005. str. 114, 6.60
- 36 - Lee H-C. Introduction to color imaging science. Cambridge UK ;;New York: Cambridge University Press; 2005. str. 114, 6.61
- 37 - Lee H-C. Introduction to color imaging science. Cambridge UK ;;New York: Cambridge University Press; 2005. str. 114, 6.62
- 38 - Lee H-C. Introduction to color imaging science. Cambridge UK ;;New York: Cambridge University Press; 2005. str. 114, 6.63
- 39 - Lee H-C. Introduction to color imaging science. Cambridge UK ;;New York: Cambridge University Press; 2005. str. 114, 6.64
- 40 - Lee H-C. Introduction to color imaging science. Cambridge UK ;;New York: Cambridge University Press; 2005. str.114, 6.65
- 41 - Lee H-C. Introduction to color imaging science. Cambridge UK ;;New York: Cambridge University Press; 2005. str. 114, 6.66
- 42 - Lee H-C. Introduction to color imaging science. Cambridge UK ;;New York: Cambridge University Press; 2005. str. 114, 6.67
- 43- Lee H-C. Introduction to color imaging science. Cambridge UK ;;New York: Cambridge University Press; 2005. str. 114, 6.68
- 44 - Lee H-C. Introduction to color imaging science. Cambridge UK ;;New York: Cambridge University Press; 2005. str. 114, 6.69
- 45 - Lee H-C. Introduction to color imaging science. Cambridge UK ;;New York: Cambridge University Press; 2005. str. 114, 6.70

7. Popis slika

Slika 1 Struktura oka

Slika 2 Ishihara testna polja za ispitivanje vizualne defekcije

Slika 3 Trokut boja. Boja postoji zbog interakcije izvora svjetla, objekta i ljudskog vida

Slika 4 Prikaz spektra elektromagnetskog zračenja i njegova podjela

Slika 5 Demonstracija Heringove teorije protivnih signala

Slika 6 Prikaz iste boje u dva različita prostora boja. Ista je boja definirana različitim koordinatama

Slika 7 Munsellov prikaz boja

Slika 8 Konstrukcija HSB i HSL modela boja

Slika 9 Izvadak iz Pantone atlasa boja

Slika 10 Prikaz NCS sustava boja

Slika 11 Prikaz OSA sustava boja

Slika 12 Prikaz CMY i RGB trodimenzionalnih tijela

Slika 13 Aditivno miješanje boja

Slika 14 Subtraktivno miješanje boja

Slika 15 Funkcije usklađivanja RGB boja u trostimulusnom prostoru boja

Slika 16 CIE dijagram kromatičnosti

Slika 17 Prikaz Lab sustava boja

Slika 18 Prikaz veličine uzorka i udaljenost kod CIE 1931 i CIE 1964 standardnog promatrača (2° i 10°)

Slika 19 Usporedni prikaz osjetljivosti standardnih promatrača CIE 1931 i CIE 1964

Slika 20 Princip vizualnog ocjenjivanja

Slika 21 Prikaz rada denzitometra

Slika 22 Usporedba rada vida i spektrofotometra

Slika 23 Prikaz rada spektrofotometra

Slika 24 Prikaz klasičnih tehnika tiska

Slika 25 Prikaz bezkontaktnih tehnika tiska

Slika 26 Prikaz termalnog inkjeta

Slika 27 Prikaz piezo inkjeta

Slika 28 Prikaz rada kontinuiranog inkjeta

Slika 29 Prikaz elektrofotografskog načina otiskivanja

Slika 30 Stanje na tržištu operativnih sustava (studen 2011. godine)

Slika 31 Slika predstavlja mogućnost različite interpretacije istih podataka

Slika 32 Na lijevoj strani slike nalazi se element u krivuljama, a na desnoj u rasteru

Slika 33 Shematski prikaz plana istraživanja

Slika 34 Izgled testne forme. Sadrži klin za automatsko očitanje na X-rite spektrofotometru X-Rite DTP41, uzorak fotografije te dodatna polja za kontrolu tiska

Slika 35 Prikaz podešavanja programa da ne utječu na boju dokumeta pri izradi postscript dokumenta u programima CorelDraw X5 i Adobe Photoshop CS4

Slika 36 Press opcije u programu Adobe Acrobat Distiller

Slika 37 Shema prolaza tiskovnog arka kroz stroj

Slika 38 Spektrofotometar X-Rite DTP 41

Slika 39 Prikaz promjene boja prilikom prijenosa podataka Corel Draw u Adobe Indesign

Slika 40 Prikaz promjene boja prilikom prijenosa podataka Corel Draw u Adobe Photoshop

Slika 41 Prikaz promjene boja prilikom prijenosa podataka Adobe Illustrator u Corel Draw

Slika 42 Prikaz promjene boja prilikom prijenosa podataka Adobe Illustrator u Adobe Indesign

Slika 43 Prikaz promjene boja prilikom prijenosa podataka Adobe Illustrator u Adobe Photoshop

Slika 44 Prikaz promjene boja prilikom prijenosa podataka Corel Photopaint u Adobe Photoshop

Slika 45 Prikaz promjene boja prilikom prijenosa podataka Adobe Photoshop u Adobe Illustrator

Slika 46 Prikaz promjene boja prilikom prijenosa podataka Adobe Photoshop u Adobe Indesign

Slika 47 Prikaz promjene boja prilikom prijenosa podataka Corel Photopaint u Adobe Indesign

Slika 48 Prikaz promjene boja prilikom prijenosa podataka Adobe Photoshop u Corel Photopaint

Slika 49 Prikaz promjene boja prilikom prijenosa podataka Adobe Photoshop u Corel Draw

Slika 50 Prikaz promjene boja prilikom prijenosa podataka Corel Draw u Adobe Illustrator

Slika 51 Izgled uzorka za vizualno ocjenjivanje. Van uzorka je navedeno porijeklo pojedinog uzorka, koje se ne vidi na otisku

Slika 52 Prikaz 1. motiva i njegovih reprodukcija. Original se nalazi u sredini, okružen crvenim rubom

Slika 53 Prikaz 2. motiva i njegovih reprodukcija. Original se nalazi u sredini, okružen crvenim rubom

Slika 54 Prikaz 3. motiva i njegovih reprodukcija. Original se nalazi u sredini, okružen crvenim rubom

Slika 55 Prikaz 4. motiva i njegovih reprodukcija. Original se nalazi u sredini, okružen crvenim rubom

Slika 56 Prikaz 5. motiva i njegovih reprodukcija. Original se nalazi u sredini, okružen crvenim rubom

Slika 57 Prikaz 6. motiva i njegovih reprodukcija. Original se nalazi u sredini, okružen crvenim rubom

Slika 58 Izgled fotografije lica korištene u ocjenjivanju