Određivanje područja u mirnoj slici koja privlače pažnju gledatelja

Mataić, Marko

Undergraduate thesis / Završni rad

2017

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:200:551332

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**

Repository / Repozitorij:

Faculty of Electrical Engineering, Computer Science and Information Technology Osijek

zir.nsk.hr

Image not found or type unknown

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I INFORMACIJSKIH TEHNOLOGIJA

Stručni studij

ODREĐIVANJE PODRUČJA U MIRNOJ SLICI KOJA PRIVLAČE PAŽNJU GLEDATELJA

Završni rad

MARKO MATAIĆ

Osijek, 2017.

SADRŽAJ

1. UVOD 1
1.1 Zadatak završnog rada 2
2. MIRNE SLIKE 3
2.1. Karakteristike mirne slike 4
2.2. Vizualna pažnja 6
2.3 Privlačenje vizualne pažnje 18
3. EKSPERIMENTI ODREĐIVANJA PODRUČJA U MIRNOJ SLICI KOJI PRIVLAČE PAŽNJU GLEDATELJA 20
3.1. Baza slika 20
3.2. Aplikacija za odabir točke pažnje 23
3.3. Određivanje točaka koje privlače pažnju 24
3.4 Analiza rezultata testiranja 35
4. ZAKLJUČAK 37
LITERATURA 38

1. UVOD

Mirne slike su već godinama interes proučavanja različitih znanstvenih disciplina, jer spoznaje vezane za mirne slike i ljudski vizualni sustav mogu uvelike unaprijediti čovjekov život, njegovu sigurnost kao i tehnološki razvoj vezan za prodaju proizvoda ili zabavni život.

Tema ovog završnog rada je određivanje područja u mirnoj slici koja privlače pažnju gledatelja. Pri gledanju mirne slike različita područja promatrane slike mogu privući pažnju gledatelja. Koje područje slike će privući pažnju nekog gledatelja ovisi o nizu faktora kao što su: sadržaj slike, kvaliteta slike, osobni interes gledatelja, ranije spoznaje gledatelja, obrazovanje, itd. Analizirana je literatura vezana za područja psihologije, neurobiologije i računalne znanosti vezano za ispitivanje dijelova slike koji najviše privlače pažnju gledatelja. U radovima objavljenim u literaturi vidi se da najčešće pažnju privlači najistaknutiji dio slike koji može biti u prvom planu, ali i ne mora. Pažnju gledatelja privlače intenzivne boje od kojih je najistaknutija crvena pa će crveni detalj na slici biti najčešće u centru pažnje.

U eksperimentalnom dijelu rada željele su se provjeriti spoznaje do kojih se došlo proučavajući literaturu. U tu svrhu odabrano je 10 slika koje tvore bazu slika. Studenti Fakulteta elektrotehnike, računarstva i informacijskih tehnologija (FERIT) u Osijeku, koji su bili promatrači, subjektivno su ocijenili odabrane slike. Dobiveni podaci su se koristili za stvaranje određenih zaključaka. Grupu promatrača tvorilo je deset studenata (5 muškog i 5 ženskog spola) FERIT-a u životnoj dobi od 21-24 godine. Svaki promatrač dobiva sliku na promatranje i vrijeme od 4 sekunde da se izjasni koji dijelovi slike najviše privlače njegovu pažnju. Za eksperimentalni dio koristio se Adobe Photoshop CS6.

Rezultati dobiveni eksperimentom uspoređeni su s rezultatima opisanim u literaturi. Želi se ispitati postoji li razlika u privlačenju pažnje između muške i ženske populacije. Metode koje su korištene u završnom radu su: metoda analize, metoda sinteze, metoda konkretizacije, metoda deskripcije, metoda klasifikacije, metoda komparacije, metoda kompilacije i metoda generalizacije. Navedene metode uključene su u procesima prikupljanja, sistematizacije i analize dosadašnjih spoznaja iz područja izabranog predmeta istraživanja.

U drugom poglavlju ovog rada dane su karakteristike mirnih slika i ljudskog vizualnog sustava. U istom poglavlju su opisani eksperimenti koje su pojedini autori provodili u određenim vremenskim razdobljima kako bi utvrdili koji dijelovi slike privlače pažnju gledatelja. Treće poglavlje se odnosi na bazu slika, vlastiti eksperiment za ispitivanje područja koja privlače pažnju u mirnoj slici i aplikaciju za odabir točaka pažnje pri gledanju mirnih slika. Zadnje poglavlje se odnosi na zaključne misli.

1.1 Zadatak završnog rada

Zadatak završnog rada je analizirati odgovarajuću literaturu i iznijeti rezultate provedenih eksperimenata koji su u njoj opisani, a vezani su za područja psihologije, neurobiologije i računalnih znanosti. U praktičnom dijelu rada potrebno je odabrati bazu slika i provesti eksperiment ispitivanja područja koja privlače pažnju u slici s najmanje 10 gledatelja. Potrebno je usporediti rezultate dobivene eksperimentom s rezultatima koji su opisani u literaturi.

2. MIRNE SLIKE

Mirne slike predstavljaju način digitalnog ili kemijskog zapisivanja, prostora i stvarnosti na sloju materijala koji je osjetljiv na svjetlost koja pada na njega. To je način bilježenja događaja, likovnih elemenata kao i stvari iz svijeta koji nas okružuje. Mirna slika predstavlja vizualnu umjetnost pa se može promatrati kao likovna umjetnost. Autor mirne slike uz pomoć svog znanja i određenih tehničkih pomagala bilježi svijet oko sebe i zatim ga prezentira javnosti ili ga koristi u tehničke, medicinske ili druge svrhe. Mirna slika može predstavljati dokument, umjetničku fotografiju, portret, mrtvu prirodu, reklamu, strip itd.

Mirne slike su imale svoj povijesni razvoj tijekom kojeg se morao rješavati problem kako sliku stvoriti i zadržati na nekom foto-osjetljivom materijalu. Rješavanje te problematike i tehnološki razvoj doveli su do pojave digitalnih fotografija.

Digitalne slike mogu nastati na više načina pa tako postoje slike [1]:

- digitalizirane skenerom
- digitalizirane digitalnom kamerom
- rendgenske slike
- ultrazvučne slike
- nastale hvatanjem video okvira
- kreirane grafičkim paketom
- generirane računalnim programom iz matematičkih funkcija
- pohranjene u digitalnim bibliotekama i sl.

Tehnika koja se koristi pri stvaranju digitalnih slika načinjena je od mreže pojedinačnih fotoosjetljivih ćelija. Svaka ćelija osjetljiva je na svjetlost i na temelju jakosti primljenog svijetla stvara signal odgovarajuće jakosti. U većini senzorskih mreža svaka je ćelija pokrivena crvenim, plavim i zelenim filtrom pa tako reagira samo na jednu od primarnih boja. Filtri se raspoređuju u skupine od po četiri. Dva zelena na svaki plavi i crveni par. Dodatni zeleni filter prisutan je zato što je ljudsko oko najosjetljivije na zelenu svjetlost. Da bi se informacija pretvorila u digitalni oblik signal se mora digitalizirati odnosno kvantizirati, pri čemu se svakom signalu dodjeljuje određeni broj. Nakon toga informacija se može vrlo lagano obraditi računalom.

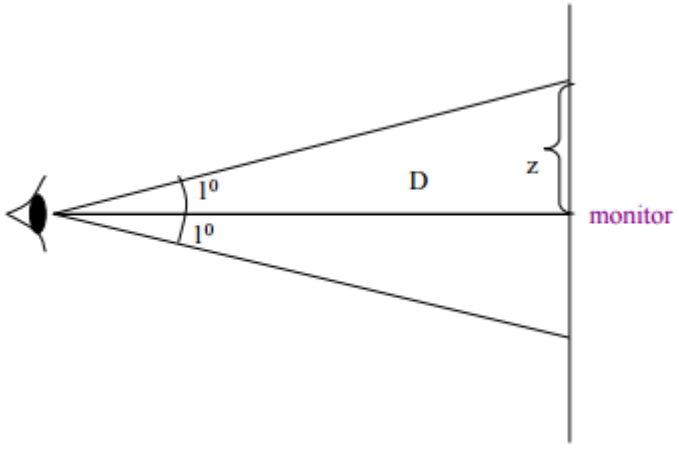
2.1. Karakteristike mirne slike

Za svaku promatranu sliku koja se želi vizualno ili objektivno valorizirati potrebno je voditi računa o nekim njezinim karakteristikama kao što su [2]:

- prostorna rezolucija
- prostorna frekvencija
- spektralna rezolucija
- šum.

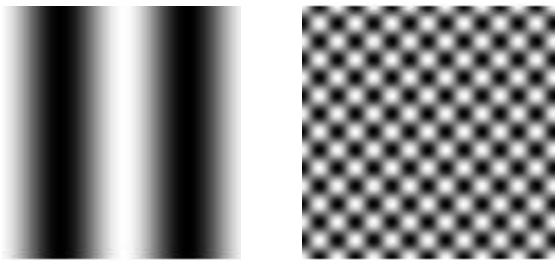
Prostorna rezolucija bi se mogla definirati kao mjera kako uređaj aproksimira kontinuiranu sliku koristeći točan broj elemenata slike, ili jednostavnije, to bi bio broj točaka po jedinica duljine (engl. *dots per inch* - dpi). Različiti uređaji imaju različitu prostornu rezoluciju pa tako pisači imaju obično od 600-2700 dpi, skeneri 300-3600 dpi. Rezoluciju se obično koristi za označavanje broja elemenata slike na duljini jednog inča.

Prostorna frekvencija slike se može definirati kao broj perioda sinusne funkcije unutar 1° vizualnog kuta. Jedinica za prostornu frekvenciju je (perioda/1°). Prostorna frekvencija signala prikazanog na zaslonu ovisi o udaljenosti gledatelja i područja zaslona obuhvaćenog s 1° vizualnog kuta. *D* predstavlja udaljenost oka od zaslona (cm), *z* određuje duljinu područja zaslona (cm) obuhvaćenog s 1° vizualnog kuta [2].



Slika 2.1. Veza udaljenosti gledatelja i područja zaslona obuhvaćenog s 1° vizualnog kuta [2].

S obzirom da slika predstavlja dvodimenzionalni slučajni signal može se govoriti o horizontalnoj (*u*) i vertikalnoj prostornoj frekvenciji (*v*).



(a) (b)

Slika 2.2 Prikaz prostornih sinusnih funkcija s a) u=2, v=0 i b) u=7, v=7 [2].

Ako se sliku želi pretvoriti u digitalni oblik, mora se definirati rezolucija intenziteta odnosno s koliko nijansi sive boje se želi kvantizirati sliku. Ako se koristi 8-bitna rezolucija, na raspolaganju stoji 2^8 tj. 256 nijansi. Nakon toga mora se definirati prostorna frekvencija uzimanja uzorka. Prostorna frekvencija bi se mogla objasniti kao niz ponavljajućih pojava. Visoka frekvencija će postojati i prema tome u područjima slike s puno detalja, a niska frekvencija u područjima slike s malo detalja.

Spektralna rezolucija se može definirati kao različite valne duljine koje određeni senzor može prepoznati. Ako je spektralna rezolucija viša moguće je preciznije raspoznati sastav slike bez obzira što ona predstavlja: vrstu materijala, kemijski spoj, pojavu u atmosferi itd. Spektralnom rezolucijom se smatra i mogućnost prepoznavanja valnih duljina odbijenog zračenja pa se ona koristi pri različitim snimanjima u medicinskoj dijagnostici. Što je spektralna rezolucija viša, veća je mogućnost raspoznavanja objekata na snimci.

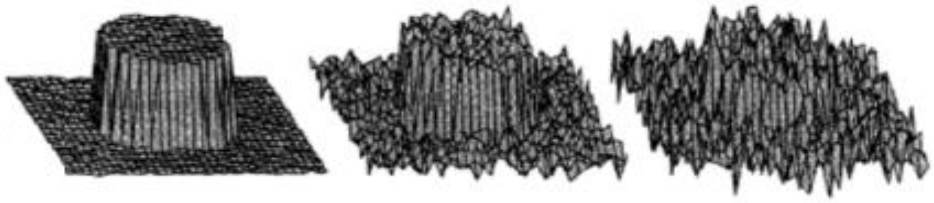
Ljudsko oko može prepoznati samo vidljivi dio spektra. Vidljivi dio spektra predstavljaju elektromagnetski valovi valnih duljina između 380 nm i 730 nm određenog intenziteta. Slike koje sadrže boju uvijek su promatraču prihvatljivije jer su estetski gledano bolje. Spektar boja može se rastaviti u šest dijelova i to ljubičasti, plavi, zeleni, žuti, narančasti i crveni. Da bi se moglo snimiti svjetlosno zračenje u određenom rasponu valnih duljina mora se imati senzor koji može detektirati zračenje u tom istom rasponu.

Boju se može promatrati kao jedan fenomen koji je potaknut svjetlom ili kao osjećaj koji u mozgu izaziva svjetlost koju emitira neki izvor. Kao izvor može poslužiti Sunce, žarulja, reflektor, svijeća itd. Kao izvor svjetla može biti i svjetlost koju reflektira neka površina. Različite boje površina, predmeta ili slika vide se zahvaljujući činjenici da dolazi do djelomičnog odbijanja

svjetla. Predmet kojeg vidimo kao crvenu boju upija sve druge valne duljine iz bijelog spektra, a propušta odnosno reflektira crvenu boju.

Stari televizijski zasloni i računalni monitori s katodnom cijevi izrađeni su od tri vrsta zrnaca fosfora različite vrste koji zrače dominantne valne duljine crvene, zelene i plave boje. Za prikaz određene boje odabire se prikladan intenzitet elektronskog snopa katodne cijevi koji regulira intenzitet emitirane svjetlosti. Optičko mišljenje svjetlosti koju emitiraju fosforna zrnca za svaki element slike daje doživljaj boje za dani element slike [1].

Jedna od karakteristika mirne slike je i šum. Može se razlikovati više vrsta šumova npr. statistički, šum izazvan elektronikom sustava, šum koji nastaje diskretizacijom signala u detektoru... Problem velikog šuma je u tome što se informacije koje određuju kvalitetu slike mogu izgubiti, što može dovesti do krivih zaključaka, posebno kod medicinske dijagnostike. Na slici 2.3 prikazane su tri slike s različitim razinama šuma. Postupno se gube informacije na slici s porastom nivoa šuma [3].



(a) (b) (c)

Slika 2.3. Slike s različitim razinama šuma: (a) s malom količinom šuma (b) s većom količinom šuma (c) s najvećom količinom šuma [3].

2.2. Vizualna pažnja

Kroz ljudsku evoluciju vizualna pažnja je mijenjala svoju ulogu. Njezina prvobitna uloga je bila osigurati opstanak ljudske vrste. Vizualna percepcija je omogućavala čovjeku pronalazak hrane i skrovišta, odabir partnera za reprodukciju i izbjegavanje opasnosti. Prvobitno je postojala relacija čovjek-priroda, gdje je vizualna percepcija osiguravala njegov opstanak. Vremenom su ljudi počeli proučavati vizualnu percepciju kako bi upoznali uzročno-posljedične veze vizualne percepcije i ponašanja ljudi.

Pojavile su se nove discipline unutar postojećih znanosti koje su se bavile vizualnom percepcijom pa se tako dolazi do kognitivne psihologije, psihofizičke, neurobiologije i računalnog vida. Uloga novih disciplina jest da spoznaje do kojih su dolazili ispitujući percepciju promatrača iskoriste u svrhe bolje promidžbe proizvoda ili kreiranja stavova i mišljenja. Odnos čovjek – priroda i dalje ostaje na sceni, ali se javlja novi odnos čovjek – čovjek. Vizualna psihofizička se može definirati kao disciplina koja istražuje odnos između fizikalnog podražaja i percepcijske reakcije koju podražaj izaziva. Ona proučava sve oblike ljudske percepcije. Za područje grafičke reprodukcije najznačajnije polje proučavanja je vizualna psihofizička. Minimalna vrijednost nekog fizikalnog podražaja koji može izazvati percepcijsku reakciju se naziva prag vizualne percepcije.

Von Helmholz je (1925) u svojim istraživanjima vizualnu pažnju promatrao kao osnovu vizualne percepcije. Njegova istraživanja su pokazala da se vizualna pažnja usmjerava prema onome što je novo. Ustanovio je da se pažnja može kontrolirati i pokazao je da čovjek može svjesno koristiti periferni vid, a da pri tome ne čini nikakve pokrete očima. Njega je prvenstveno zanimalo gdje je usmjerena vizualna pažnja [4].

Guy Thomas Buswell (1935) u svom istraživanju „*How people look at pictures*“, daje novi pogled na vizualnu percepciju. On je koristio uređaj AUPEM (engl. *Apparatus Used for Photographing Eye Movement*). On je prvi puta izvršio objektivno mjerenje dinamike percepcije vizualnog sadržaja. Buswell je utvrdio da veći interes pokazuje veći broj fiksacija ali i da fiksacije koje su vremenski duge dovode do teže obrade sadržaja [4].

Gibson (1941) je ustanovio da način gledanja i način reagiranja na vizualnu informaciju ovisi o prethodnom iskustvu. Prethodno iskustvo i kontekst u kojem se neka informacija pojavljuje može utjecati na njezino dekodiranje, a na promjenu značenja i percepciju mogu utjecati i očekivanja [4].

Deutsch i Deutsch (1963) naglašavaju da će na nastajanje vizualne pažnje bitno utjecati važnost primljene poruke. Primatelj može filtrirati primljene poruke i važna poruka postaje ona koja je za svijest pojedinca bitna. Sve poruke nemaju jednaku važnost [4].

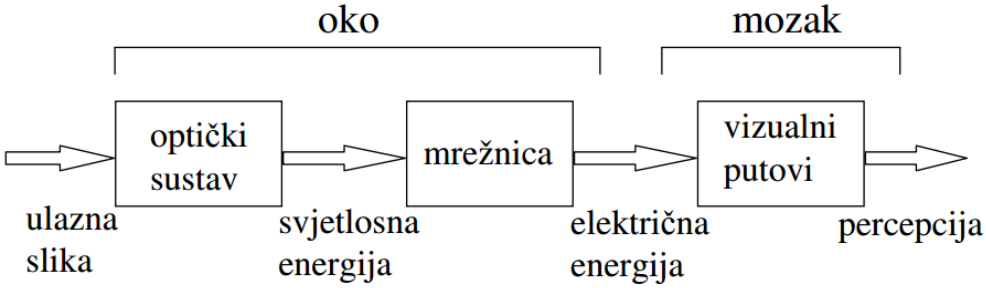
Razvojem tehnologije uvodi se računalno praćenje pogleda oka u istraživanju vizualne pažnje. Ta istraživanja dovode do boljeg razumijevanja pokreta oka. Osnovne pokrete čine brzi simultani pokreti oba oka koji se nazivaju sakade (engl. *saccades*). Ovi pokreti služe pozicioniranju fovee na novu lokaciju u vizualnom okruženju. Pokreti mogu biti namjerni i refleksni. Vremensko trajanje pokreta je od 10-100 ms. Osim sakada postoje i pokreti finog praćenja (engl. *smooth pursuit*). Ti pokreti omogućavaju praćenje objekta u pokretu i njegovu fiksaciju. Fiksacije su pokreti oka koji omogućavaju da se oko zadrži na objektu interesa. Za

vrijeme fiksacije oči nisu mirne nego se događaju mali pokreti koji se nazivaju mikrosakade. Vrijeme fiksacije je obično od 150-600 ms. Svaki od ovih dijelova pokreta imaju svoju ulogu i pojedinac njima namjerno upravlja. Fiksacija se koristi za namjerno održavanje pažnje na području interesa, fini pokreti imaju istu zadaću samo se odnosi na objekte u pokretu, a sakade služe za namjerno i svjesno određivanje područja interesa.

Vizualna pažnja se može podijeliti u dvije faze. U prvoj fazi se pronalazi vizualna meta, a u drugoj vizualna pažnja stvara vizualnu informaciju. U zadnjih 50 godina za praćenje pokreta oka koriste se različite tehnologije koje su iznjedrile tri osnovna zaključka:

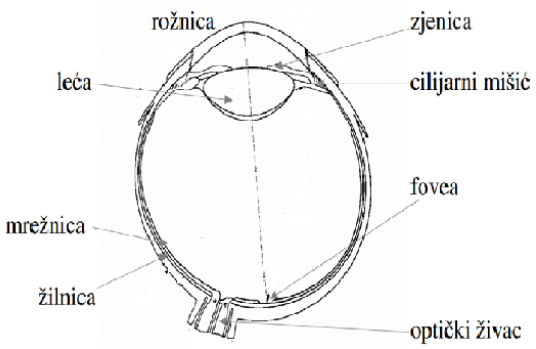
1. Fiksacije pogleda se pojavljuju u vizualnim područjima koja sadrže visok stupanj semantičke ili vizualne informacije.
2. Fiksacije pogleda su odgovorne za percepciju i općenito se smatraju refleksijom pojedinačne kognitivne strategije.
3. Sekvence fiksacije pogleda dopuštaju dekodiranje, spremanje i ponovnu rekonstrukciju vizualnih podataka.

Vizualna percepcija neke slike, događaja ili predmeta odvija se unutar vrlo kompliciranog procesa ljudskog vizualnog sustava. Ta percepcija nije fotografija objektivne stvarnosti nego je ona zapravo interpretacija te stvarnosti. Primljenim podražajima, premda su isti, svaki čovjek daje drugačiji smisao s obzirom na svoje prethodno znanje, njegove stavove, motive, očekivanja i osjetilne osobine ličnosti. Zato percepcija istih objekata i situacija ne mora biti ista. Sustav za vizualnu percepciju kod ljudi je vrlo složen i on nije savršen nego pokazuje mnoge nedostatke. Na slici 2.4 dan je općeniti model ljudskog vizualnog sustava [5].



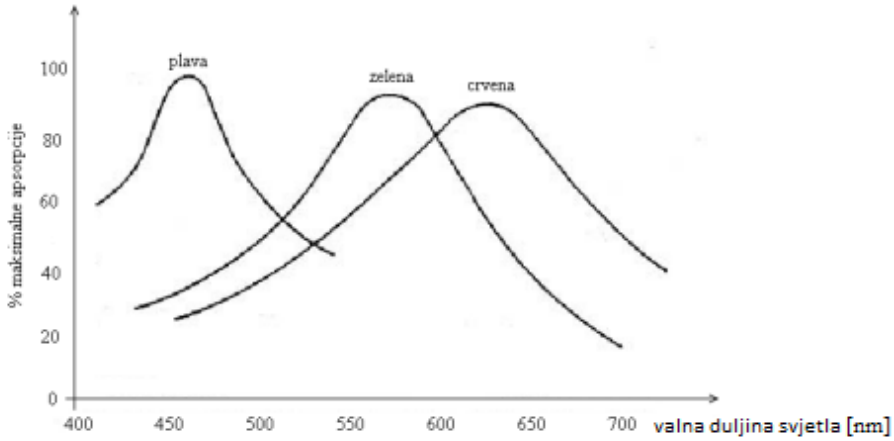
Slika 2.4. Općeniti model ljudskog vizualnog sustava [5].

Ljudsko oko je građeno od mrežnice, rožnice, fovee, leće, zjenice, optičkog živca, cilijarnih mišića [5]. Na slici 2.5 dana je struktura ljudskog oka.



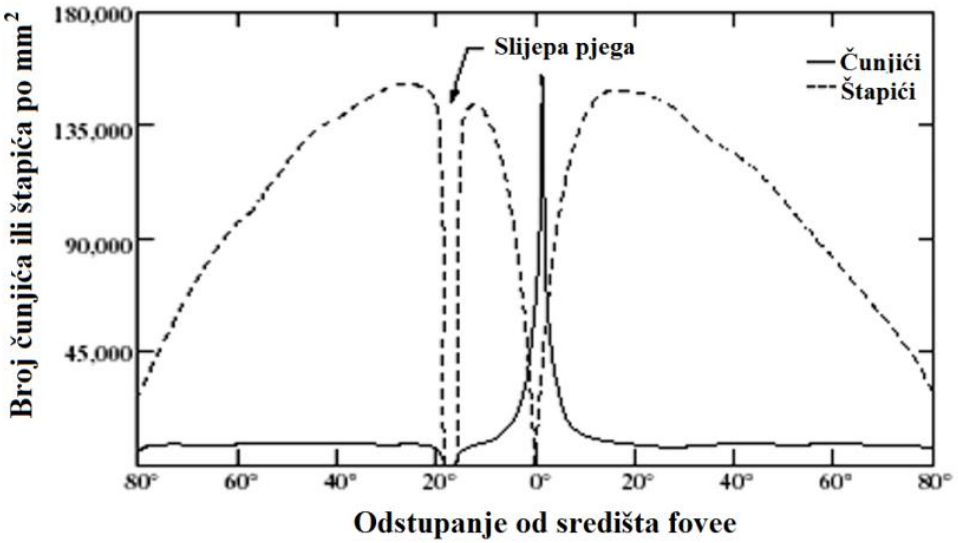
Slika 2.5. Struktura ljudskog oka [5].

Uloga zjenice je da regulira količinu svjetla odnosno dubinsku oštrinu dok je mrežnica na stražnjem dijelu oka i ona sadrži foto-osjetljive receptore tj. štapiće i čunjiće. Čunjića ima od 6-7 milijuna i oni su osjetljivi na boju. Svaki čunjić je povezan na svoj vlastiti živac i njegova je zadaća da omogući oštru i detaljnu sliku pri jakom svjetlu (engl. *photopic* ili *bright-lightvision*). Postoje tri osnovna tipa stanica koje dijele vidljivi dio spektra u tri opsega: crveni, zeleni i plavi. Ove tri boje su označene kao osnovne boje ljudskog vida. Štapića ima puno više. Njihov broj se kreće od 75-150 milijuna. Na jedan živac je obično vezano nekoliko štapića što smanjuje oštrinu vida. Štapići nisu osjetljivi na boju, daju općenitu tj. široku sliku scene i služe za gledanje pri slabom svjetlu (engl. *scotpic* ili *dim-lightvision*). Štapići su raspršeni periferno izvan fovee pa pri slabom svjetlu ne možemo raspoznavati boje. Na slici 2.6 prikazana je osjetljivost triju tipova fotoreceptorskih stanica na različite valne duljine svjetla [6].



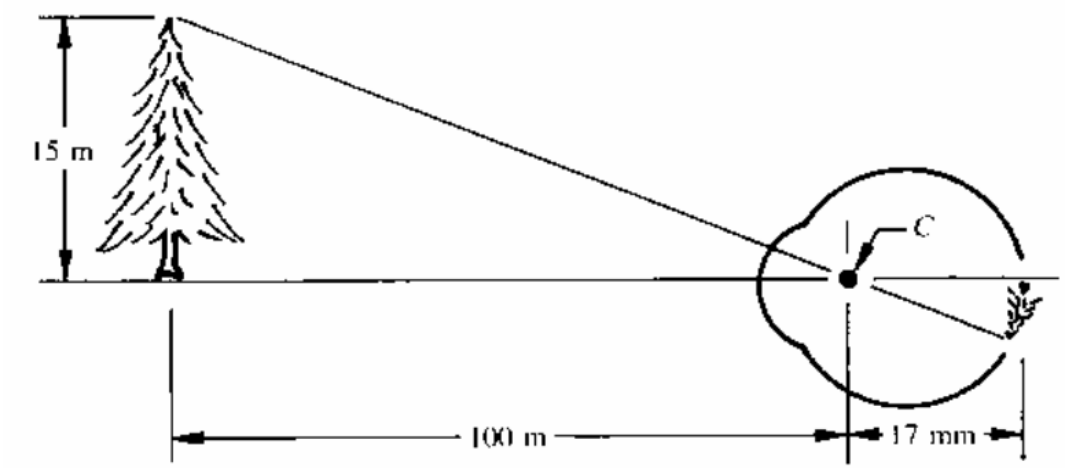
Slika 2.6. Osjetljivost fotoreceptorskih stanica ljudskog oka [6].

Prema psihofizičkim mjerenjima, CIE(Commision Internationale de l´Eclairage) krivulje sa slike 2.6. predstavljaju osjetljivost prosječnog promatrača za tri navedene boje. Najveća gustoća čunjića se nalazi na području žute pjege, a idući prema periferiji njihova gustoća opada. Raspodjela čunjića i štapića na mrežnici prikazana je na slici 2.7 [1].



Slika 2.7. Raspodjela čunjića i štapića na mrežnici [1].

U središtu mrežnice se nalazi malo područje, fovea, u kojem se projicira slika koju fokusiramo okom. Fovea ne sadrži štapiće, a gustoća čunjića može biti i do 300 000 mm^2. Slika se formira u mrežnici, a obrada slike počinje u očima te se nastavlja u mozgu, dokle se prenosi pomoću optičkog živca. Udaljenost od leće do mrežnice je oko 17 mm [4]. Na slici 2.8 prikazano je formiranje slike na mrežnici [4].

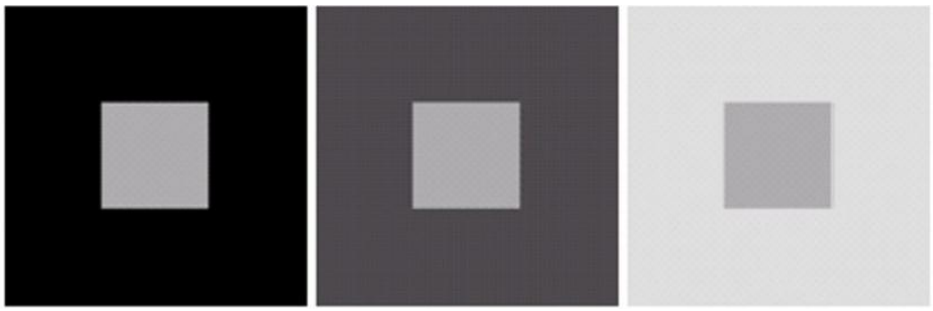


Slika 2.8. Formiranje slike na mrežnici [4].

Ljudski vizualni sustav ima određene karakteristike vezane za [4] :

- dinamički opseg svjetla;
- adaptaciju na svjetlinu ;
- osjetljivost na kontrast.

Doživljaj svjetline ne ovisi samo o apsolutnom intenzitetu svjetline nego i o svjetlini okolnih objekata tj. kontrastu. Ljudski vizualni sustav ne radi istovremeno u cijelom rasponu svjetline. Ljudsko oko se može prilagoditi svjetlini u velikom rasponu, ali je raspon svjetline koji se može razlikovati istovremeno malen. Na slici 2.9 prikazan je doživljaj svjetline ovisno o pozadini objekta od interesa [1].



Slika 2.9. Doživljaj svjetline ovisno o pozadini objekta od interesa [1].

Gledajući sliku 2.9. imamo osjećaj da su kvadrati u sredini slika sve tamniji kako idemo s lijeva na desno, iako nisu jer je okolina koja okružuje kvadrat sve svjetlija. Iz toga se može zaključiti da opažanje svjetline ne ovisi o apsolutnom intenzitetu svjetline nego i o okolini.

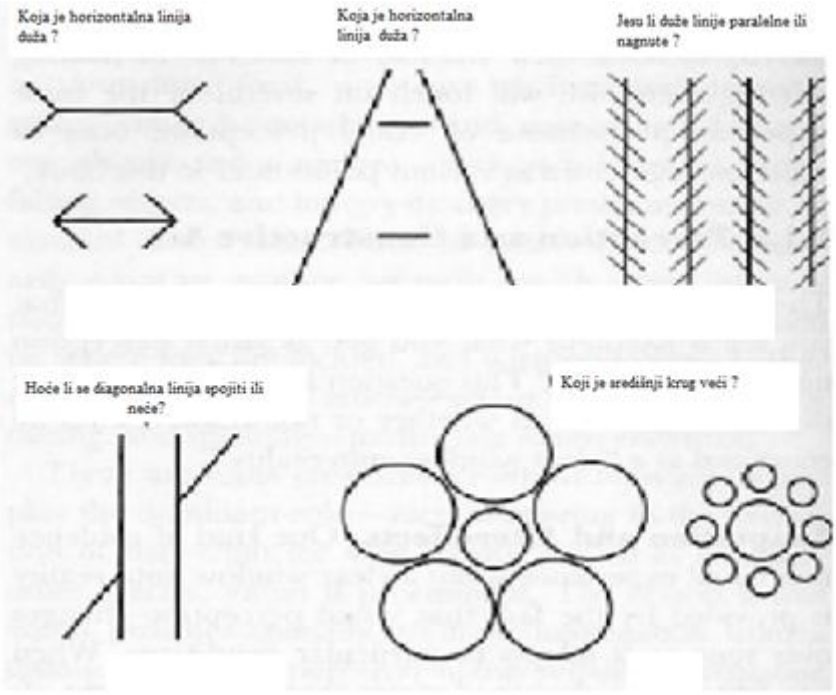
Prema Weber-ovom zakonu ljudski vid je osjetljiv na kontrast, što zapravo predstavlja relativni odnos, a ne apsolutni iznos svjetline. Ako se mijenja intenzitet svjetlosti jedne valne duljine, odgovor vizualnog sustava R bit će proporcionalan logaritmu intenziteta I_0. To je poznati Weber-Fechner-ov zakon [3]. R predstavlja vizualni sustav dok I_0 predstavlja intenzitet svjetlosti.

$$R=\log(I_0). \qquad (2\text{-}1)$$

Kontrast zapravo predstavlja razliku svjetlina dviju susjednih površina. Apsolutna vrijednost svjetline nekog objekta zapravo je od manjeg značaja od relativne svjetline tj. kontrasta. Objekti koji imaju istu stvarnu vrijednost svjetline mogu izazvati različiti subjektivni osjećaj svjetline.

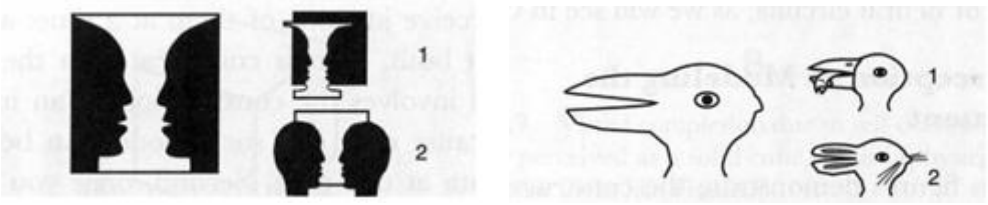
Vizualni sustav čovjeka je vrlo složen. U pojedinim situacijama ne dobivamo točne rezultate percepcije nego dolazi do vizualne iluzije. Vizualne iluzije pokazuju da rezultat

percepcije nije samo temeljen na slici koju vidimo nego i na radu našeg vizualnog sustava. Naš vizualni sustav ponekad griješi. Na slici 2.10 prikazani su primjeri vizualnih iluzija [5].



Slika 2.10. Primjeri vizualnih iluzija [5].

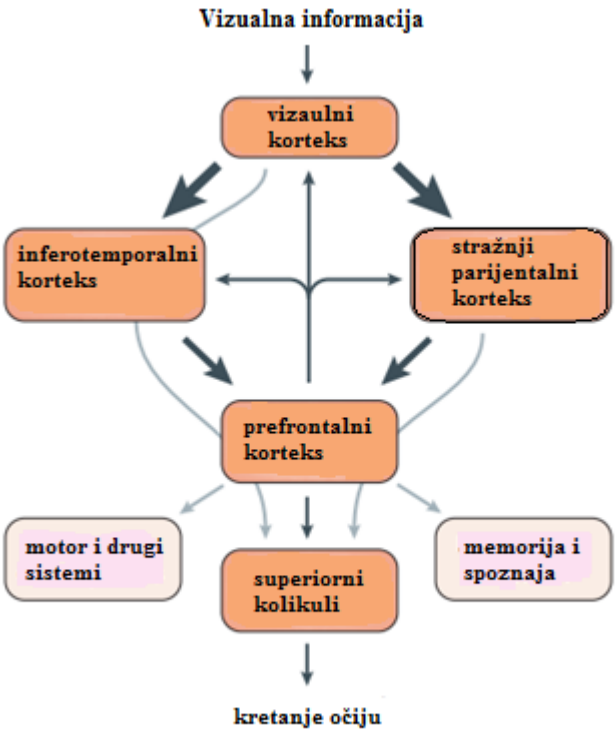
Vizualna percepcija ima veliku ulogu u evoluciji pojedinih vrsta jer uvelike povećava šansu za opstanak. Ona pomaže vrsti u traženju hrane, traženju skloništa, izbjegavanju opasnih situacija i predatora kao i traženju partnera. Da bi se ostvarili ti ciljevi pomažu sva osjetila. Za čovjeka je najvažnije osjetilo vizualne percepcije tj. vid. Ista slika kod različitih promatrača može izazvati različite percepcije. Na slici 2.11 su prikazani a) Vaza/Lica i b) Patka/Zec [5].



a) b)

Slike 2.11. Različite percepcije: (a) Vaza/Lica , (b) Zec/Patka [5].

Regije mozga koje sudjeluju u razvoju vizualne pažnje uključuju većinu područja odgovornih za ranu obradu vizualnih informacija. Pojednostavljeni prikaz dan je u shemi na slici 2.12 [7].



Slika 2.12. Regije mozga koje sudjeluju u vizualnoj pažnji [7].

Vizualne informacije (podaci) dolaze u primarno vidno područje većinom preko *corpus genuculatum laterale* (lateralno koljenasto tijelo) (nije prikazan), a manjim dijelom drugim putevima npr. preko gornjih kolikula. Iz primarnog vidnog područja podaci se zatim simultano šalju u 2 područja iste hijerarhijske razine.

Kortikalna područja unutar dorzalne linije (uključujući i stražnji parijetalni korteks) zadužena su za prostornu orijentaciju i usmjeravanja pažnje i pogleda prema objektima interesa. Dorzalna linija se smatra mjestom razvoja kontrole pažnje.

Kortikalna područja unutar ventralne linije (uključujući i infratemporalni režanj) zadužena su za prepoznavanje i indentifikaciju vizualnih informacija. Iako nisu direktno povezana s kontrolom pažnje dokazano je da područja unutar ventralne linije dobivaju modulacije putem povratne sprege modulacije i uključena su u prikazivanje okoline i objekata (ograničavanje podataka koji idu na višu razinu).

Vjeruje se da nekoliko područja viših moždanih funkcija sudjeluje u usmjeravanju pažnje, a oštećenja istih dovode do zanemarivanja određenih dijelova okoline (prizora).

Prema shemi ventralna i dorzalna linija moraju međusobno komunicirati budući da su za razumijevanje okoline (prizora) potrebni prepoznavanje i prostorna orijentacija. Jedno od mjesta međusobne komunikacije koje se dosta istražuje je prefrontalni korteks. Područja u prefrontalnom korteksu su dvosmjerno povezana sa stražnjim parijetalnim korteksom i infratemporalnim

režnjem. Osim planiranja radnje (npr. pokreti oka preko gornjih kolikula) područja u prefrontalnom korteksu imaju važnu ulogu u modulaciji ventralne i dorzalne linije putem povratne sprege.

Vizualni eksperimenti vezani za pokrete oka kao psihofizički i psihološki testovi su doveli do određenih rezultata. Prema tim rezultatima postoji niz faktora koji utječu na vizualnu pozornost i na pokrete oka.

Postoje dva pristupa u objašnjavanju detekcije istaknutih dijelova slike i to su [8]:

- odozgor prema dolje (engl. *top-down)*
- pristup odozdo prema gore (engl. *bottom-up).*

Prva metoda se temelji na kognitivnim spoznajama ljudskog mozga i to je zapravo spontani proces. Prije samog procesa detekcije, informacije o traženom objektu su na poznate pa je ova metoda zapravo vođena ciljem ili zadatkom.

Druga metoda je vođena vizualnim podražajima. Ona se temelji na reakciji tj. odzivu ljudskog vizualnog sustava na vanjske podražaje kao što su: osvijetljenost, boja, oblik koji se značajno razlikuje od okoline, kontrast, neuobičajeni pokret i neke druge značajke.

Pozornost promatrača će privući određeni dio slike, ovisno o [9]:

- kontrastu;
- veličini regije;
- obliku;
- boji;
- lokaciji;
- prednjem planu/pozadini;
- ljudima;
- kontekstu.

Slijedi pojašnjenje:

Kontrast - kontrast je vrlo jaki *bottom-up* vizualni podražaj. Dijelovi slike, regije koji imaju visoki kontrast (jače su istaknuti na slici) privlače veću pozornost od pozadine i imat će veću vizualnu važnost.

Veličina regija - veće regije privlače veću pažnju od manjih regija . Razlike u veličini regija imaju svoju granicu zasićenja.

Oblik - nepredvidivi oblici privlače veću pažnju od predvidivih oblika. Boja je vrlo jak vizualni podražaj. Veliki utjecaj na percepciju ima korištenje različitih boja za centralni objekt i njegovu pozadinu. Najveću pozornost privlači crvena boja.

Lokacija - eksperimenti praćenja pokreta oka su pokazali da je fiksacija promatrača usmjerena prema sredini dok je mali broj promatrača usmjeren izvan centralnog dijela.

Prednji plan/pozadina - veća je vjerojatnost da će pažnju promatrača privući objekti koji se nalaze u prvom planu u odnosu na one izvan toga .

Ljudi - mnoge studije pokazuju da kada gledatelj promatra sliku scene mnoštva ljudi posebnu pažnju privlače njihova lica, oči, usta i ruke.

Kontekst - pokrete oka gledatelja možemo mijenjati ovisno o uputama koje mogu biti dane prije ili za vrijeme promatranja slike. Neki drugi *bottom-up* faktori mogu utjecati na pažnju promatrača kao što su svjetlina, orijentacija rubova i linija. Zna se da brojni faktori utječu na vizualnu pažnju, ali je malo kvantitativnih podataka kojima se to može potvrditi. Da bi se moglo ustanoviti vrednovanje različitih čimbenika i njihov međusobni odnos, potrebno je izvršiti veliki broj eksperimenata na velikom broju gledatelja mijenjajući spektar poticajnih materijala.

Problemi računalnog vida nisu uspješno riješeni do danas. Postoji više računalnih modela, ali ni jedan ne rješava kompletnu problematiku. Računalni vid bi trebao povezati detekciju najistaknutijeg objekta i segmentaciju točnih granica tog objekta. Kod nekih računalnih modela se detekcija i segmentacija izvode simultano. U fazi detekcije se ne mora detektirati samo jedan objekt. Većina modela se može koristit za pronalaženje nekoliko objekata u sceni.

Većina istraživača smatraju da dobar model detekcije treba zadovoljiti barem tri slijedeća kriterija [10]:

- dobra detekcija
- računalna efikasnost
- visoka rezolucija

Kod modela detekcije objekata na temelju mapa ispupčenosti važno je poznavati što je slično, a što različito između predviđanja fiksacije, segmentacija i predložaka objekata. Temeljem razumijevanja ljudskog vizualnog sustava i poznavanja problematike kretanja očiju mogu se načiniti modeli predviđanja fiksacije. Modeli za detekciju istaknutih objekata imaju za cilj prepoznati i segmentirati najistaknutiji objekt crtajući točke siluete objekta.

Model fiksacije ima za cilj predvidjeti točke u koje ljudi gledaju u nekakvom vremenskom trajanju koje najčešće iznosi od 3-5 s. Problem modela je: ako dobro rješava pitanje detekcije onda ne rješava dobro pitanje fiksacije. S obzirom da oba modela generiraju slične mape ispupčenosti mogu se koristiti naizmjenično i to je u praksi najčešći slučaj .

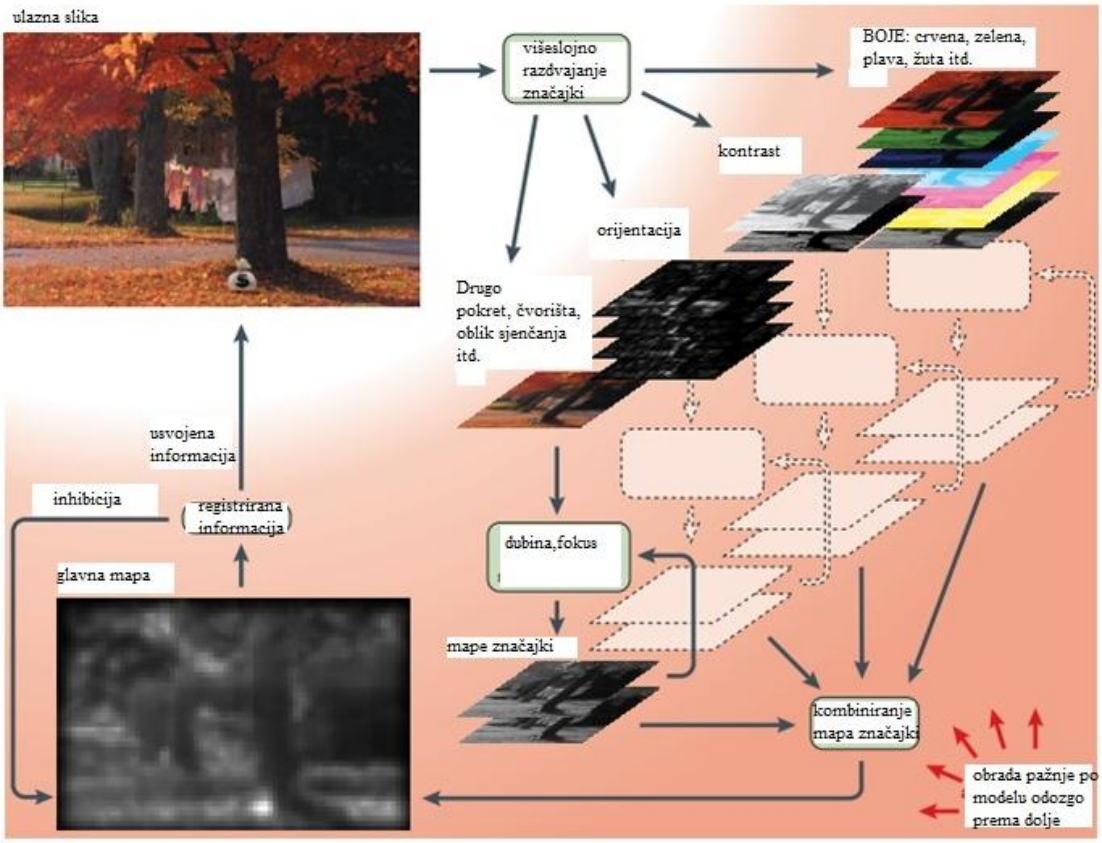
U računalnom vidu dobro istraženo područje je područje segmentacije slike. Kod segmentacije svakom elementu slike dodjeljuje se oznaka pomoću koje se detektira da li pripada objektu ili pozadini. Kod modela za detekciju istaknutih objekata prvenstveno se vodi računa o

istaknutom objektu i segmentacija se promatra kao binarni problem tj. problem objekt-pozadina. U praksi se najčešće segmentira cijela scena a zatim odabire najistaknutiji objekt.

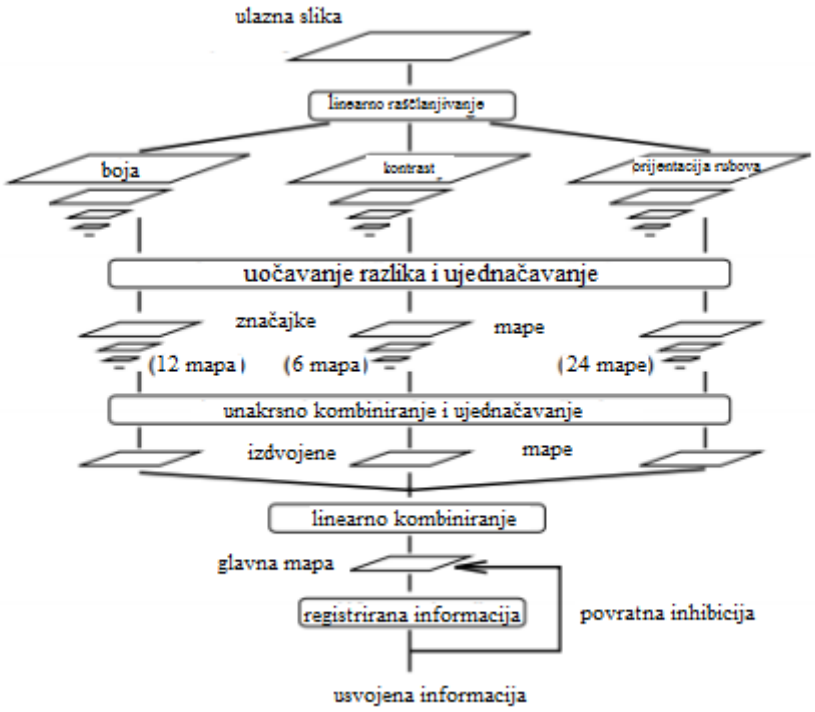
U posljednje vrijeme se pojavljuje dosta primjera za identificiranje ispupčenja na slici. Većina primjera nastoji prvo definirati vizualne podskupine odnosno stvoriti mapu ispupčenosti, a zatim sve mape integrira u cjelinu koja definira ispupčenost objekta .Kao pod skupovi mogu se javiti regije, blokovi, elementi slike ili super elementi slike. Blokovi nastaju ako sliku uzrkujemo u obliku manjih pravokutnih segmenata (eng.*patch*). Blokovi koji imaju dimenzije 1x1 su elementi slike, a percepcijski homogeni segmenti koji su usklađeni s intenzitetom rubova predstavljaju super elemente slike i regije. Većina postojećih modela mogu se podijeliti u dvije skupine. Prvu skupinu čine modeli koji su temeljeni na blokovima, a drugu skupinu modeli koji su temeljeni na regijama.

Vizualno okruženje se može kodirati skupom topografskih kortikalnih mapa i ovaj princip se naziva rana reprezentacija. Rana reprezentacija se sastoji od različitih vizualnih mapa koje u sebi sadrže elementarne osobine kao što su: boja, disparitet, orijentacija rubova itd. Teorija integracije značajki (eng. *Feature Integrationtheory)* uključuje modele oponašanja svojstava ranih procesa kod vizualnog sustava u primata. Slika (vizualni ulaz) se prvo rasloji na skup topografskih mapa značajki. Svaka mapa ima mnogo ispupčenosti na različitim lokacijama, ali opstaju samo one koje se ističu s obzirom na svoju okolinu. Zatim se sve mape značajki spajaju u glavnu mapu koja topografski opisuje objekte koji se ističu unutar vizualne scene po modelu odozdo prema gore. Vjeruje se da je takva mapa smještena u stražnjem parijetalnom korteksu. Slika 2.13 prikazuje tipičan model za kontrolu pažnje po *bottom-up* metodi [7].

Kao ulaz se koristi slika u boji. Zatim se od jedne stvara devet slika različitih veličina upotrebom Gausove piramide. Gausova piramida služi kao progresivni nisko propusni filtar. Njezina zadaća je da poduzorkuje ulaznu sliku reducirajući dimenzije slike u horizontalnom i vertikalnom smjeru. Na slikama se primjenjuju operacije koje su srodne vizualnim perceptivnim poljima. Vizualni neuroni imaju veliku osjetljivost na signal u malom području tj. u središtu, a udaljavanjem od središta odziv neurona se smanjuje. Ovaj princip se može koristi za pronalaženje razlika dviju istih slika koje imaju različitu rezoluciju. Slika koja ima veću rezoluciju se koristi kao središte, a slika manje rezolucije koristi se kao okruženje. Na slici 2.14 prikazana je opća arhitektura Itti/Koch modela [7].



Slika 2.13. Tipičan model za kontrolu pažnje po bottom-up metodi [7].



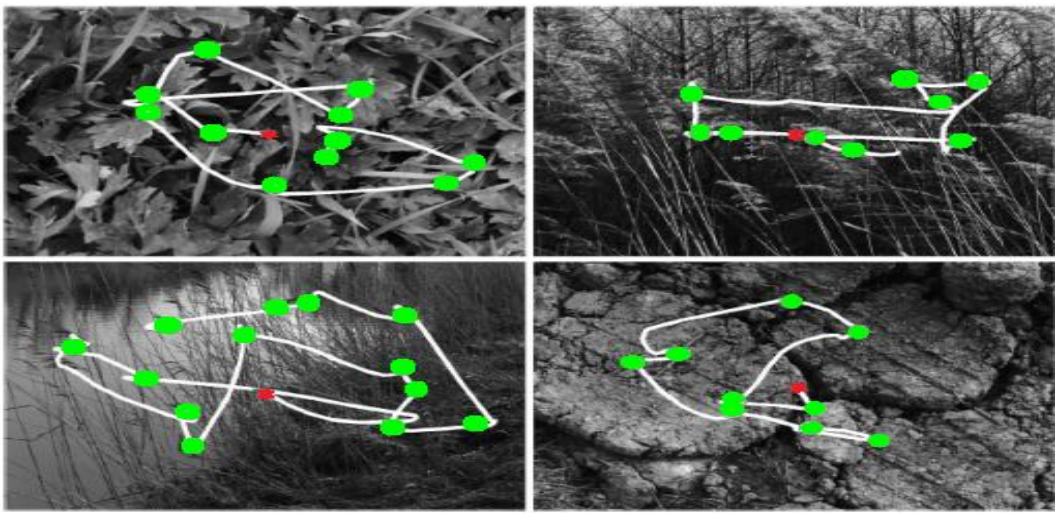
Slika 2.14. Opća arhitektura Itti/Koch modela [7].

2.3 Privlačenje vizualne pažnje

Kada ljudsko oko promatra sliku ono fiksira neku točku tj. dio slike. Osjetljivost na pogrešku najveća je u toj točki. Zato je važno znati koja područja u signalu slike i videosignalu privlače pažnju gledatelja. Te informacije se koriste u sustavima za kodiranje tih signala. Eksperimenti koji su provedeni pokazali su da pažnja gledatelja nije jednoliko raspoređena na sva područja slike. Svaki gledatelj promatra sliku na sebi svojstven, subjektivan način. U eksperimentima ispitivanja područja koja privlače vizualnu pažnju [11], Osberger i Rohaly su zaključili da veću pažnju privlače dijelovi slike s većom razinom kontrasta. U eksperimentu opisanom u [12] autori su zaključili da najveću pažnju privlače područja blizu središta okvira, što je logično jer kod snimanja signala slike i videosignala objekti koji se snimaju nalaze se u fokusu scene.

Istraživanjem vizualne pažnje bavili su se autori Van der Linde, Rajashekar, Bovik, Cormack [9]. Oni su proveli istraživanja s 29 gledatelja koji su gledali 101 sliku. Istraživali su pokrete oka koristeći uređaj za praćenje pokreta visoke preciznosti i načinili su bazu podataka s približno 3000 točaka fiksacije. U ovim eksperimentima je korišten veliki broj gledatelja i veliki broj različitih slika pa se dobiveni rezultati mogu smatrati visoko preciznim i mogu se koristiti za modeliranje vizualne pažnje.

Na slici 2.15 su primjeri slika iz eksperimenta provedenog u [9]. Na slikama su prikazane putanje pokreta oka jednog gledatelja. Polazna točka fiksacije označena je zvjezdicom. Gledanje slike je trajalo 5 sekundi, a točke prikazuju mjesta na koja je gledatelj usmjeravao svoju pažnju. Ova istraživanja pokazuju da najveću pažnju gledatelja privlače područja oko središta scene.



Slika 2.15 Primjeri slika koje prikazuju putanju pokreta oka jednog gledatelja [9].

U svojim istraživanjima iz 2011. autori Mittal, Moorthy, Geisler, Bovik [13] su pratili točke koje je oko gledatelja fiksiralo. Gledatelji su gledali 20 različitih video materijala nepoznatih sadržaja u trajanju od 30 sekundi. Nepoznati sadržaji su korišteni da se izbjegne učinak pamćenja ako je gledatelj ranije vidio videosignal. Gledatelji su gledali videosignal u tri različita izobličenja: bez kompresije, s niskom i visokom razinom kompresije. U eksperimentu je sudjelovalo 12 gledatelja, a pratili su se pokreti oka gledatelja uz 2 različita zadatka. U prvom zadatku su gledatelji trebali ocijeniti kvalitetu videomaterijala, a u drugom su trebali prepričati sadržaj videomaterijala. Temeljem ovog eksperimenta zaključeno je da pažnju gledatelja privlače područja oko središta okvira, područja s većim kontrastom i područja sa sporijim pokretima. Vrlo često pažnju gledatelja privlače jaka izobličenja u sceni, što je važno znati kod dizajniranja algoritma za ocjenu kvalitete signala slike i videosignala.

3. EKSPERIMENT ODREĐIVANJA PODRUČJA U MIRNOJ SLICI KOJI PRIVLAČE PAŽNJU GLEDATELJA

Eksperimentalni dio rada sastojao se od odabira 10 testnih slika za koje je 10 promatrača označavalo područja koje im u tim slikama privlače pažnju. U ovom dijelu rada opisana je baza slika korištenih u eksperimentu kao i sam način provođenja eksperimenta.

Privlačenje vizualne pažnje može se mjeriti subjektivnim i objektivnim metodama. Subjektivne metode su najpouzdanije. Iako svaki gledatelj različito pristupa slici, ipak se mogu izvući zajednički zaključci za sve njih. Gotovo svi gledatelji se usredotoče na centralni dio slike, detalj koji je najizražajniji po obliku ili boji i dio slike koji prenosi snažne emocije. Subjektivno ocjenjivanje privlačenja pažnje od strane gledatelja je neophodno jer je ono temelj za ispitivanja pažnje objektivnim metrikama (koristeći računalne metode) [14].

3.1. Baza slika

U provođenju subjektivnog eksperimenta koji je imao za cilj odrediti koji dijelovi mirne slike privlače pažnju gledatelja sudjelovalo je 10 studenata FERIT-a, 5 muškog i 5 ženskog spola. Za provođenje eksperimenta korišten je Photoshop. Bazu čini 10 slika. Svi gledatelji su gledali 10 slika iz baze slika. Svaka slika je gledana 4 sekunde. Usredotočenost ljudskog vizualnog sustava je vremenski ograničena pa je potrebno dobiti što veću pažnju u što kraćem vremenu. Gledatelju je objašnjen cilj eksperimenta i na jednoj slici koja nije iz baze slika je mogao provjeriti kako funkcionira Photoshop. Gledatelj odabire svoju boju koja je unaprijed dogovorena kako bi se mogli pratiti rezultati eksperimenta i kada otvori sliku, aktivira se vrijeme i on počinje zaokruživati dijelove slike koji privlače njegovu pažnju. U zadanom vremenu može zaokružiti jedan ili više dijelova mirne slike. Svaki je gledatelj sliku gledao samo jednom. Nakon isteka vremena nije se mogao vraćati na prethodnu sliku i vršiti izmjene prethodnih odluka. Za svakog gledatelja uvjeti eksperimenta su bili isti. Eksperiment je proveden u izoliranom prostoru, kako ništa na bi odvlačilo pažnju gledatelja. Svaki gledatelj je gledao niz od 10 slika. Između pojedinog gledanja je pravljena pauza od 2 minute kako bi se oko odmorilo. Slike su gledane na istom monitoru. Pozadina monitora je bila crna. Zbirni podaci eksperimenta dobiveni su stapanjem pojedinačnih podataka translatacijom. Tablica 3.1 prikazuje kratki opis mirnih slika korištenih u bazi slika. Sve slike iz baze su JPEG formata.

Tablica 3.1. Kratki opis mirnih slika korišteni u bazi slika.

Cjelovito ime mirne slike i skraćeni naziv u zagradi	Rezolucija [elemenata slike]	Opis mirne slike
Pločnik	5284x3523	Popločana staza, iz spojišta staze sa zidom se šire grane bršljana
Slapovi	1920x1080	Izvor se preko kamenitog dijela slijeva u jezero
Djevojka	640x965	Oči pune straha, ispaćeno lice omotano rupcem u dronjcima
Hrvatska	943x531	Nogometni klub istrčava na teren, navijači u Pozadini
Konji	640x480	Brdoviti teren, stijene u pozadini, zeleni pašnjak, konji različitih boja
Navijači	640x424	Jednolična masa, puno sitnih detalja, zastupljene samo 4 boje
Nogomet	1024x768	Igrači u pokretu, zelena podloga, dvije boje sportske opreme
More	4752x3168	Mirnoća vode, kontrast stijena, plavetnilo neba
Suncokret	600x590	Polje suncokreta, jedan suncokret u prvom planu, plavetnilo neba
Ulica	1920x1080	Uske popločane ulice, stare građevine sa mnogo detalja

Za ispitivanje područja pažnje u mirnim slikama odabrano je 10 slika. Slike su raznolikog sadržaja od prirode, preko okupljanja ljudi do portreta. To je nužno kako bi se testirali svi zaključci iz relevantne literature. Slike iz baze su prikazane na slici 3.1.



(a)



(b)



(c)



(d)



(e)



(f)



(g)



(h)



(i)



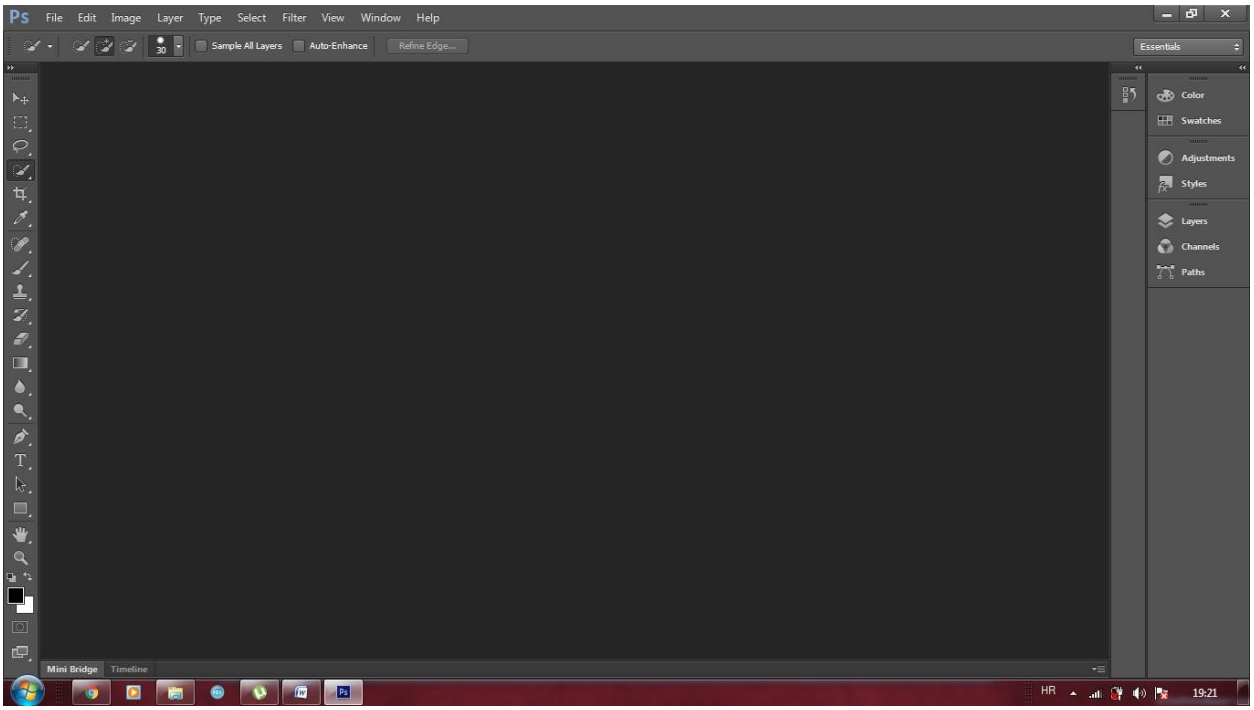
(j)

Slika 3.1 Slike iz baze za testiranje (a) Pločnik (b) Slapovi (c) Djevojka (d) Hrvatska (e) Konji (f) Navijači (g) Nogomet (h) More (i) Suncokret (j) Ulica

3.2. Aplikacija za odabir točke pažnje

Photoshop je najjednostavniji grafički računalni program za obradu slika. U ovom eksperimentu je korištena CS6 verzija Photoshopa. Ova verzija je objavljena 2012. godine i predstavlja trinaestu generaciju programa. Program je razvila i izdala američka tvrtka Adobe Systems. To je najpoznatiji računalni program za obradu slika. Dodani su novi kreativni alati s ciljem poboljšanja preformansi.

Photoshop je nastao 1988. godine. Autori programa su Thomas i John Knoll. Od 1988. godine Photoshop je postao industrijski standard u uređivanju slika. Ovim programom se mogu uređivati i sažimati slike u više slojeva. Program ima veliku podršku za grafičke formate datoteka, ali koristi svoje PSD i PSV formate datoteka. Osim digitalnih slika ima ograničene mogućnosti uređivanja i prikaza vektorske grafike, 3D grafike i videa. Od 2002 uvode se nove oznake za Photoshop. Oznake su CS kojima se dodaje određeni broj. Na slici 3.2. prikazano je sučelje Photoshopa.



Slika 3.2 Sučelje Photoshopa

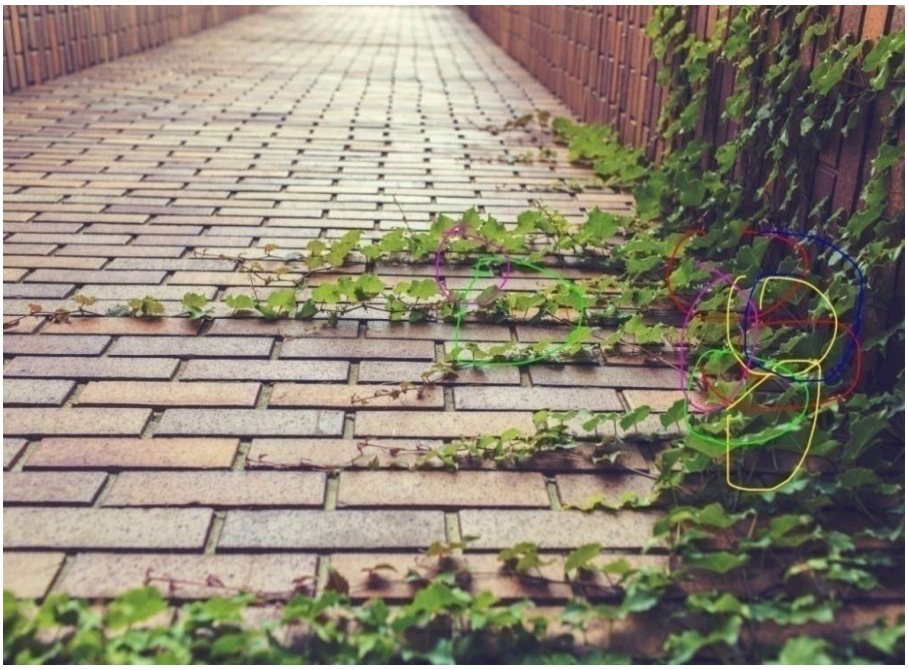
3.3. Određivanje točaka koje privlače pažnju

Svaki promatrač dobio je na promatranje sve slike iz baze slika . U vremenu od 4 sekunde promatra sliku i alatom iz aplikacije photoshop CS6 zaokružuje detalje slike koji mu privlače pažnju. Prvo zaokružuje detalj koji mu prvi privuče pažnju, zatim slijedi drugi, treći itd. dok ne isteke vrijeme od 4 sekunde. Istu sliku promatra drugi promatrač i ponavlja eksperiment kao što je navedeno za prvog promatrača. Prva slika obradi se za deset promatrača. Na temelju njihovih promatranja dobiju se sve točke koje su privukle pažnju i odredi se njihov redoslijed. Ovaj eksperiment ponavlja se za svih deset slika. Na kraju eksperimenta sažimaju se rezultati. Svakom promatraču se dodijelila boja, a zatim su se rezultati saželi metodom stapanja u Photoshopu.

Na slici 3.3. prikazani su rezultati za 5 ženskih i 5 muških promatrača za sliku Pločnik.



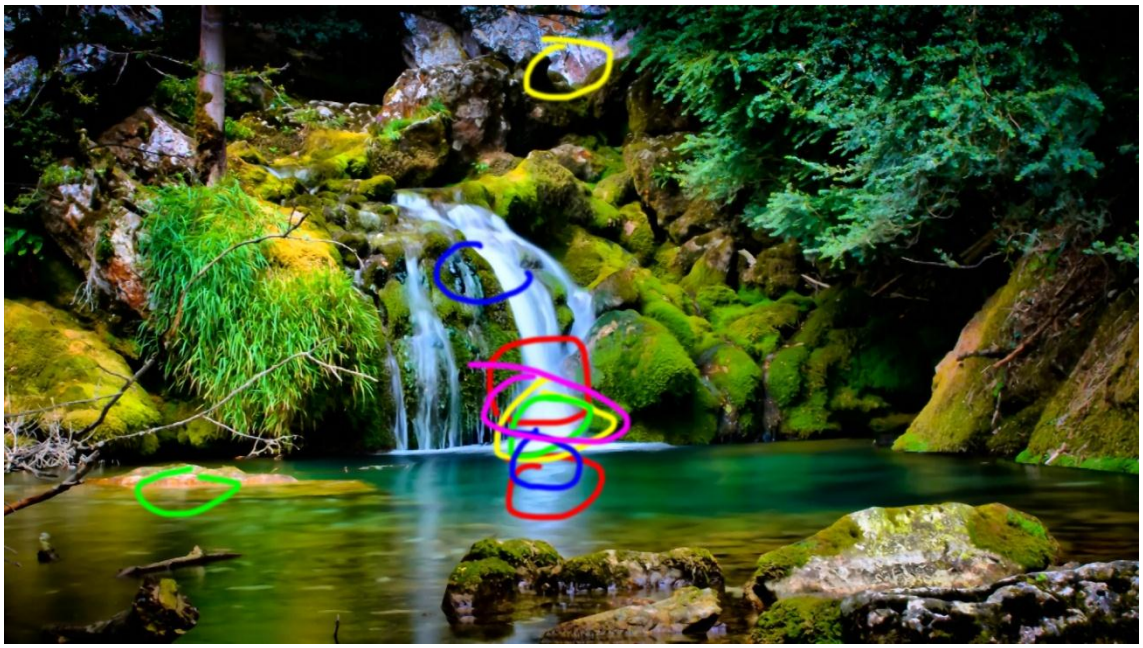
(a)



(b)

Slika 3.3 Rezultati privlačenja pažnje za (a) 5 ženskih promatrača (b) 5 muških promatrača za sliku Pločnik.

Na slici 3.4. prikazani su rezultati za 5 ženskih i 5 muških promatrača za sliku Slapovi.



(a)



(b)

Slika 3.4 Rezultati privlačenja pažnje za (a) 5 ženskih promatrača (b) 5 muških promatrača za sliku Slapovi.

Na slici 3.5. prikazani su rezultati za 5 ženskih i 5 muških promatrača za sliku Djevojka.



(a)



(b)

Slika 3.5. Rezultati privlačenja pažnje za (a) 5 ženskih promatrača (b) 5 muških promatrača za sliku Djevojka.

Na slici 3.6. prikazani su rezultati za 5 ženskih i 5 muških promatrača za sliku Hrvatska.



(a)



(b)

Slika 3.6. Rezultati privlačenja pažnje za (a) 5 ženskih promatrača (b) 5 muških promatrača za sliku Hrvatska.

Na slici 3.7. prikazani su rezultati za 5 ženskih i 5 muških promatrača za sliku Konji.



(a)



(b)

Slika 3.7. Rezultati privlačenja pažnje za (a) 5 ženskih promatrača (b) 5 muških promatrača za sliku Konji.

Na slici 3.8. prikazani su rezultati za 5 ženskih i 5 muških promatrača za sliku Navijači.



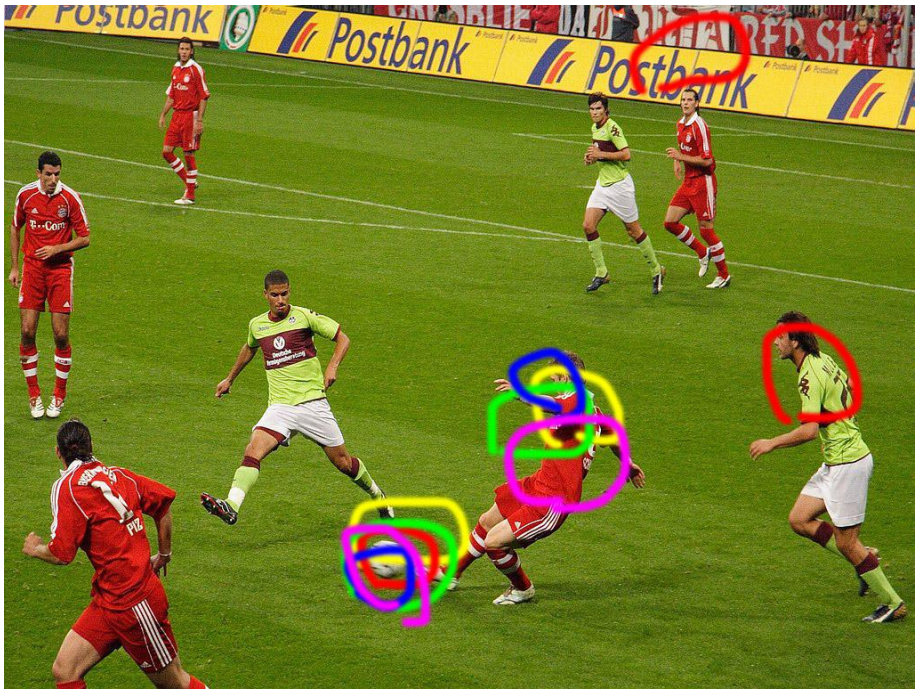
(a)



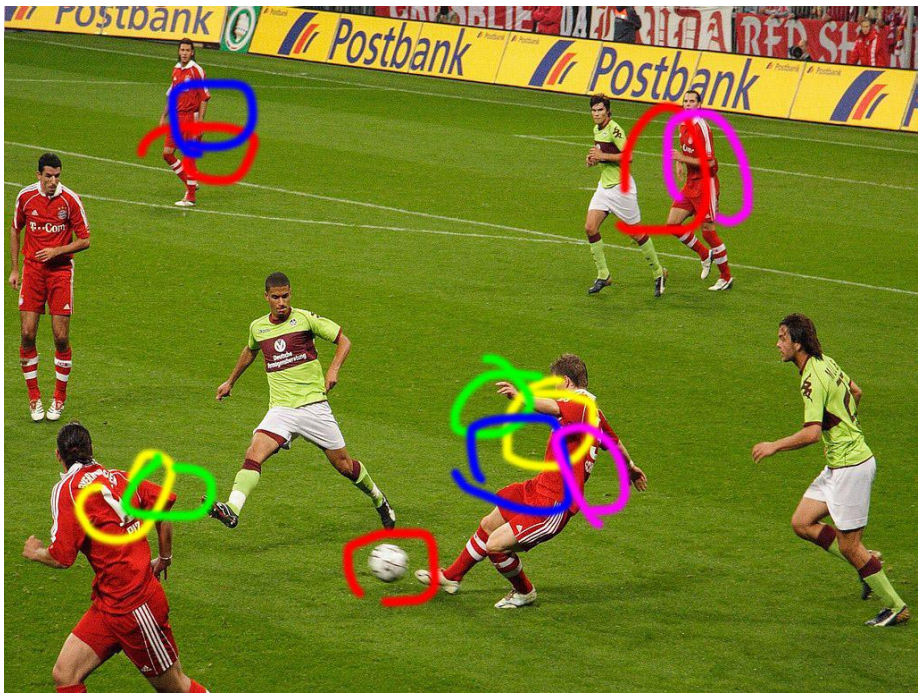
(b)

Slika 3.8. Rezultati privlačenja pažnje za (a) 5 ženskih promatrača (b) 5 muških promatrača za sliku Navijači.

Na slici 3.9. prikazani su rezultati za 5 ženskih i 5 muških promatrača za sliku Nogomet.



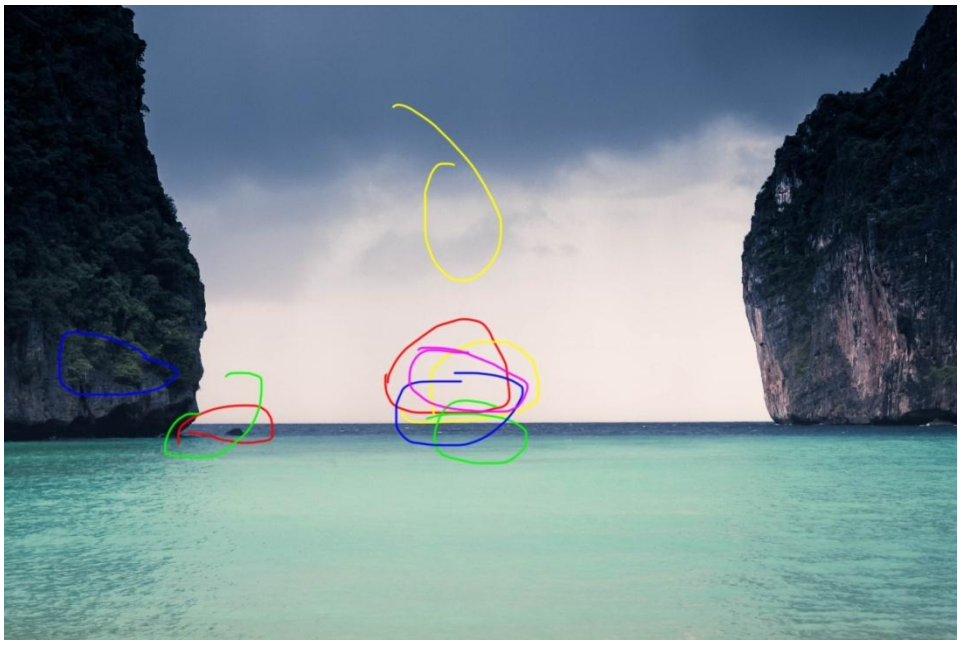
(a)



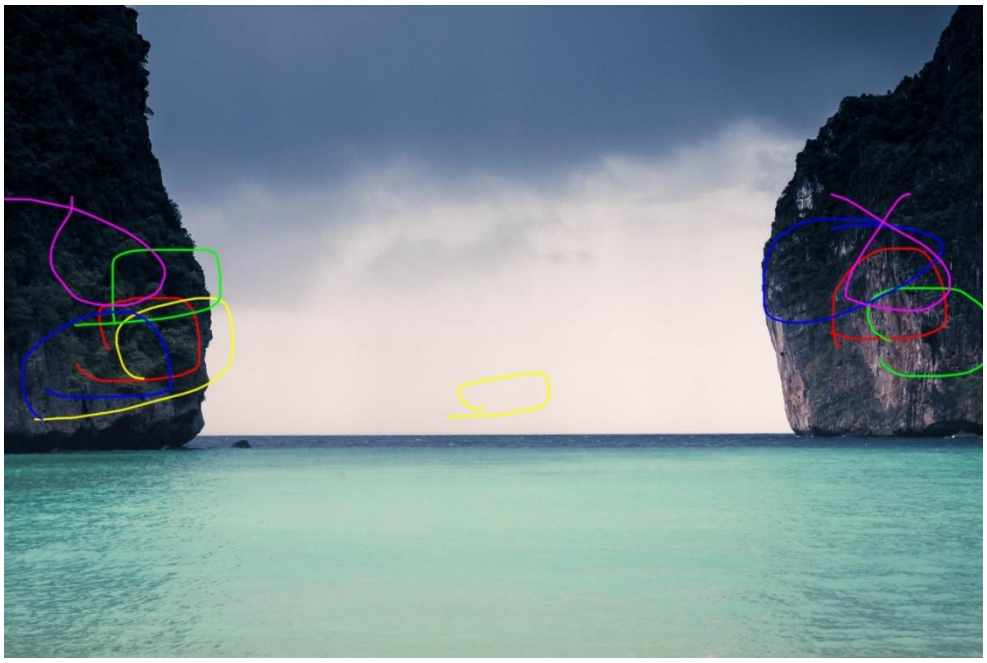
(b)

Slika 3.9. Rezultati privlačenja pažnje za (a) 5 ženskih promatrača (b) 5 muških promatrača za sliku Nogomet.

Na slici 3.10. prikazani su rezultati za 5 ženskih i 5 muških promatrača za sliku More.



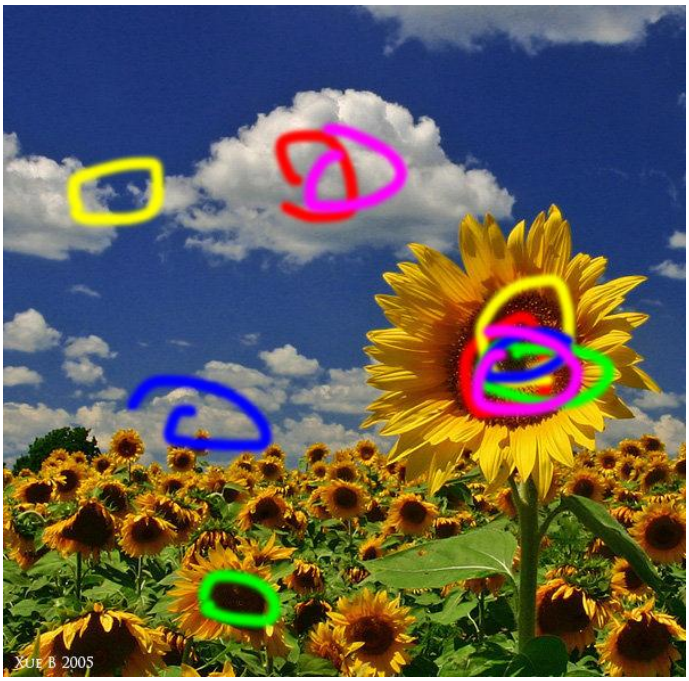
(a)



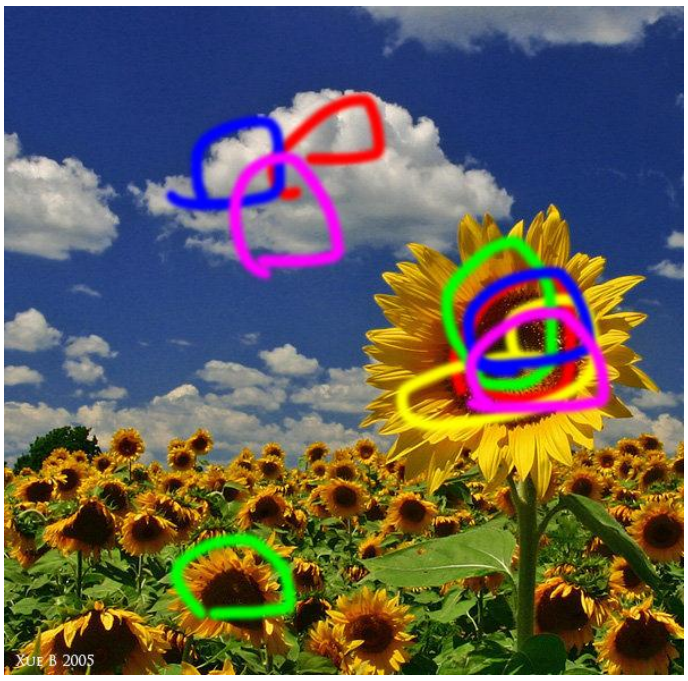
(b)

Slika 3.10. Rezultati privlačenja pažnje za (a) 5 ženskih promatrača (b) 5 muških promatrača za sliku More.

Na slici 3.11. prikazani su rezultati za 5 ženskih i 5 muških promatrača za sliku Suncokret.



(a)



(b)

Slika 3.11. Rezultati privlačenja pažnje za (a) 5 ženskih promatrača (b) 5 muških promatrača za sliku Suncokret.

Na slici 3.12. prikazani su rezultati za 5 ženskih i 5 muških promatrača za sliku Ulica.



(a)



(b)

Slika 3.12. Rezultati privlačenja pažnje za (a) 5 ženskih promatrača (b) 5 muških promatrača za sliku Ulica.

3.4 Analiza rezultata testiranja

U tablici 3.2. sažeti su rezultati ispitivanja područja koje privlače pažnju u 10 mirnih slika odabranih za testiranje u ovom završnom radu.

Tablica 3.2. Rezultati ispitivanja područja koje privlače pažnju u 10 mirnih slika odabranih za testiranje.

BROJ SLIKE	FOKUS ŽENSKIH PROMATRAČA	FOKUS MUŠKIH PROMATRAČA
Pločnik	Fokus je u sredini, detalji u sredini slike različite boje.	Fokus je desni dio slike, detalji tamnije boje.
Slapovi	Fokus je donji središnji dio slike, refleksija vodopada na jezeru.	Slično kao kod ženskih promatrača.
Djevojka	Fokus je na očima, kontrast bijele i zelene boje, zeleni detalji odjeće.	Fokusirani su isti dijelovi kao kod ženskih promatrača.
Hrvatska	Fokus je centralni dio slike, lica.	Fokusi slika su isti kao kod ženskih promatrača.
Konji	Pažnja je vrlo raspršena , biraju se crni detalji koji su najveći objekt i čovjek kao izdvojeni detalj.	Fokus se kreće prema donjem središnjem dijelu slike, više pomaknut u lijevo.
Navijači	Fokus je centralni dio slike, zastava.	Fokusi slika su slični kao kod ženskih promatrača.
Nogomet	Fokus je u donjem središnjem dijelu slike, ženski promatrači uočavaju prvo loptu.	Fokus je u istom dijelu slike kao i kod ženskih ispitanica, muški promatrači se fokusiraju na igrača desno od lopte.
More	Fokus je sredina slike, sitni detalji lijevo ili desno koji se uočavaju perifernim vidom.	Fokus nije u sredini slike nego su u fokusu krupni detalji lijeve i desne strane.
Suncokret	U fokusu je suncokret u desnoj donjoj četvrtini jer je u prvom planu i njemu kontrastni bijeli oblaci.	Fokusi slika su isti kao kod ženskih promatrača.
Ulica	Fokus je sredina slike, detalji u desnom i lijevom središnjem dijelu slike.	U fokusu je središnji i lijevi središnji dio slike.

Gledajući rezultate mogu se donijeti slijedeći zaključci.

- središnji dio slike najviše privlači pažnju
- pažnju privlače i izdvojeni objekti koji ne moraju nužno biti u središtu slike
- pažnju privlače dijelovi slike s većim kontrastom

Rezultati eksperimenta potvrdili su rezultate prethodnih istraživanja. U ovom radu može se još dodatno analizirati razlike u područjima koje privlače pažnju ženskih i muških promatrača. Razlike su uočene na slikama Pločnik i More. Na slici Pločnik pažnja ženskih promatrača je bila usmjerena na centar slike, a kod muških je desni dio slike. Ženski gledatelji su zapažali detalje različitih boja, a muški gledatelji su bili usredotočeni na tamnije detalje. Na slici More pažnja ženskih gledatelja bila je u sredini slike, a kod muških gledatelja pažnju su privlačili krupni detalji lijeve i desne strane. Općenito gledano, za slike korištene u ovom eksperimentu, nema neke velike razlike u područjima koje privlače pažnju za različite spolove.

4. ZAKLJUČAK

Ovaj se rad bavi problematikom dijelova slike koji najviše privlače pažnju gledatelja. Da bi se mogle spoznati uzročno posljedične veze slike i gledatelja, bilo je potrebno upoznati se s funkcioniranjem ljudskog vizualnog sustava. Iz relevantne literature predstavljeni su faktori koji mogu utjecati na vizualnu pažnju promatrača.

U eksperimentalnom dijelu došlo se do zaključka da se gledatelji uglavnom fokusiraju na centralni dio slike, a potom na neki detalj koji se po nečem razlikuje od svoje okoline. Ako je na slici bio prisutan efekt refleksije svjetla on je gotovo uvijek bio u fokusu promatrača.

Fokus promatrača uglavnom su privlačile intenzivne boje koje su se razlikovale od okoline, poglavito crvena. Ukoliko detalj koji se nalazi u prvom planu slike nije u sredini, bio je u fokusu pažnje promatrača.

Muški i ženski promatrači su uglavnom fokusirali iste dijelove slike. Razlike su se primijetile kod slike Pločnik i More, ali to nije dovoljno reprezentativan uzorak da bi se na temelju njega moglo donositi određene zaključke za različite spolove. Istraživanje provedeno u završnom radu je potvrdilo navode sličnih eksperimenata opisanih u literaturi.

LITERATURA

[1] M. Vranješ, 02 - Mirne slike - 1.dio, predavanje iz kolegija Multimedijska tehnika, Fakultet elektrotehnike, računarstva i informacijskih tehnologija, Osijek, 2013.

[2] M. Vranješ, 02 - Mirne slike - 2.dio, predavanje iz kolegija Multimedijska tehnika, Fakultet elektrotehnike, računarstva i informacijskih tehnologija, Osijek, 2013.

[3] A. Lagumdžija, Komparacija parametara kvalitete slike različitih tipova uređaja u kompjuterizovanoj tomografiji, Magistarski rad, Prirodno-matematički fakultet, odsjek za fiziku, Sarajevo, 2012.

[4] D. Mustić, Modeli grafičkog oblikovanja medijskih konvergiranih sadržaja, Doktorski rad, Grafički Fakultet, Zagreb, 2012.

[5] S. Lončarić, Temelji digitalne obrade slika, predavanje iz kolegija Obrada informacija, Fakultet elektrotehnike i računarstva, Zagreb, 2008.

[6] V. Risojević, Percepcija i digitalizacija slike, predavanje iz kolegija Multimedij, Elektrotehnički fakultet, 2015, Banja Luka.

[7] L. Itti, C. Koch, Computational Modeling of Visual Attention, Nature Reviews Neuroscience, vol. 2, no. 3, 2001, str. 194-203.

[8] W. Osberger, A.M.Rohaly, Automatic Detectionof Regions ofInterestin Complex Video Sequences, U: Proc. SPIE Human Visionand Electronic Imaging VI, vol. 4299, 2001, str. 361-372.

[9] I. Van der Linde, U. Rajashekar, A.C. Bovik, L.K. Cormack, DOVES: A database of visual eye movements, Spatial Vision, vol. 22, no. 2, 2009, str. 161-177.

[10] Ž. Marušić, Detekcija ispupčenih objekata, Kvalifikacijski doktorski ispit, Fakultet elektrotehnike, strojarstva i brodogradnje, Split, 2016

[11] W. Osberger, A.M.Rohaly, Automatic Detection of Regions of Interest in Complex Video Sequences, U: Proc. SPIE Human Vision and Electronic Imaging VI, vol. 4299, 2001, str. 361-372.

[12] J. You, J. Korhonen, A. Periks, Attention Modeling for Video Quality Assessment: Balancing Global Quality and Local Quality, The 2010 IEEE International Conference on Multimedia and Expo, Singapur, 2010, str. 914-919

[13] A. Mittal, A.K. Moorthy, W.S. Geisler, A.C. Bovik, Task Dependence of Visual Attention on Compressed Videos: Point of Gaze Statistics and Analysis, U: Proc. SPIE Human Vision and Electronic Imaging XVI, vol. 7865, 2011.

[14] M. Vranješ, Objektivna metrika kvalitete slike zasnovana na prostorno-vremenskim značajkama videosignala i prostorno ovisnoj percepciji, Doktorska disertacija, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek , 2012.

SAŽETAK

Pri gledanju mirnih slika različita područja promatrane slike mogu privući pažnju gledatelja .U ovom radu je analizirana literatura vezana za područje psihologije, neurobiologije i računalne znanosti vezano za ispitivanje dijelova slike koji najviše privlače pažnju gledatelja. Provedeni su i eksperimenti ispitivanja područja koja privlače pažnju u mirnim slikama. Fokus promatrača su uglavnom privlačile intenzivne boje koje su se razlikovale od okoline, poglavito crvena, te se taj fokus nalazio u većini slučajeva u sredini.

Ključne riječi: mirne slike, vizualna pažnja, fokus promatrača

DETERMINATION OF IMAGE REGIONS WHICH ATTRACT THE VIEWERS ATTENTION

ABSTRACT

While viewing still images, different areas of observed images can attract the attention of viewers. In this thesis the literature in the field of psychology, neurobiology and computer science is analyzed, related to the testing of image parts that attracted attention of the viewers the most. We conducted testing that examines which part in still image attracts the most attention of the viewers. The focus of observers is based on intense colors, that are different from the environment, particularly red, and in the most cases, the focus was located in the center of the image.

Keywords: still images, visual attention, focus of the beholder

ŽIVOTOPIS

Marko Mataić rođen je 11 prosinaca 1991.godine u Slavonskom Brodu. U vremenskom razdoblju 1998-2006 pohađao je osnovnu školu Bogoslav Šulek, Bukovlje. 2006. godine upisuje srednju Tehničku školu Slavonski brod, smjer tehničar za elektroniku. 2010. godine završio je srednju školu te se upisuje na Sveučilište J. J. Strossmayera Osijek, Elektrotehnički fakultet Osijek. Izvrsno poznaje rad na računalu. Od svjetskih jezika govori i piše engleski.