Sveučilište u Zagrebu

Filozofski fakultet

Kristian Đokić

GUSTOĆA INFORMACIJA I VIZUALNA AKTIVNOST U DINAMIČNIM SLIKAMA

DOKTORSKI RAD

Mentor:

Prof. dr.sc. Tomislava Lauc

Zagreb, 2018.

University of Zagreb

Faculty of Humanities and Social Sciences

Kristian Đokić

INFORMATION DENSITY AND VISUAL ACTIVITY IN DYNAMIC PICTURES

DOCTORAL THESIS

Supervisor:

Prof. dr.sc. Tomislava Lauc

Zagreb, 2018.

Informacije o mentorici

Dr. sc. Tomislava Lauc je redovita profesorica na Odsjeku za informacijske i komunikacijske znanosti Filozofskog fakulteta Sveučilišta u Zagrebu. Nositeljica je kolegija na preddiplomskom, diplomskom i poslijediplomskom studiju. Njeno područje interesa je multimedijski instrukcijski dizajn.

Zahvala

Zahvaljujem se mentorici prof.dr.sc. Tomislavi Lauc za sav trud i sate provedene u nastojanjima da u realne okvire postavi moje često preambiciozne ideje.

Zahvaljujem se supruzi Ivani i djeci Marku i Jakovu na strpljenju svih ovih godina rada na disertaciji.

Kristian Đokić

SAŽETAK

Zbog velikog utjecaja na društvo vizualni mediji tema su kontinuiranog istraživanja u ovom i u prošlom stoljeću. U ovoj disertaciji predložen je i provjeren model mjerenja vizualne aktivnosti medija koji se temelji na algoritmima za uklanjanje pozadine poznatim u području računalnog vida. Algoritmi za uklanjanje pozadine obrađuju video sadržaje na način da se kao izlaz obrade dobije dvobojni video sadržaj, pri čemu je jedna boja detektirani pokretni objekt, dok je druga nepomična pozadina. Koristeći omjer broja točaka detektiranih pokretnih objekata i ukupnog broja točaka u nekom video sadržaju može se kvantificirati količina pokreta, što je ključna ideja ove disertacije. S obzirom da je dostupno nekoliko desetaka različitih algoritama za uklanjanje pozadine, za izbor odgovarajućeg algoritma korišten je Model ograničenog kapaciteta obrade motiviranih posredovanih poruka, kojim je moguće kvantificirati gustoću informacija video sadržaja.

Nakon izbora algoritma za uklanjanje pozadine, predloženi model uspoređen je s postojećim modelom za mjerenje vizualne aktivnosti, tj. Cuttingovim Indeksom vizualne aktivnosti pri čemu je dobiven vrlo visok koeficijent korelacije $r_s = 0,823$. Potom je testirana robusnost obaju modela s obzirom na šum. Provjera predloženog modela provedena je na skupu od 50 filmova koji su dobili nagradu *Academy Award for Best Picture* između 1965. i 2014. godine, te 30 video spotova koji su dobili nagradu *MTV Best Music Video* između 1984. i 2013. godine. Uočen je statistički značajan rast vrijednosti, odnosno predložena mjera ukazuje na porast vizulane aktivnosti kroz vrijeme.

KLJUČNE RIJEČI: gustoća informacija, vizualna aktivnost, Indeks vizualne aktivnosti, algoritmi za uklanjanje pozadine, LC4MP

EXTENDED SUMMARY

Due to their large influence on the society visual media have been a subject of research in the last two centuries. New opportunities for analysis of visual media have been created through digitisation and development of information and communication technologies. A phenomenon observed by many authors is constant growth of video content activity**.** This thesis puts forward the method of visual media activity measurement based on the background subtraction algorithms that are known for computer vision systems. Gibson (1954) defines the term visual activity as the totality of movement of objects and people along a constant background and visual information gained through movement of the observer. The problem of visual activity measurment stems from the fact that it is desirable to include the recipient of the information because the amount of emitted visual information and perceived visual activity are not necessarily in a correlation.

The background subtraction algorithms process video content in such manner that output of the processing is a two-colour video content where one colour is a detected movable object, while the other is stationary background. The key concept in this thesis is that it is possible to quantify movement by using a ratio of the number of pixels of the detected movable objects and the total number of pixels in the given video content. Since several dozen different background subtraction algorithms are available, the Limited Capacity Model of Motivated Mediated Message Processing was used in order to select the suitable one. It is a model capable of quantification of video information density. The model itself also includes recipients of visual information.

Following the selection of the background subtraction algorithms, the proposed model for visual activity measuring was compared with the existing visual activity measurement model – Cutting's visual activity index – and a strong correlation of $r_s = 0.823$ was observed. It is obvious that both models take into consideration similar properties of video content.

Furthermore, due to properties of the underlying algorithms themselves, the proposed visual activity measurement model based on background subtraction algorithms is significantly less susceptible to noise than Cutting's visual activity index. That has also been proven by introduction of noise in video content which led to significant increases of the visual activity index – even in cases of comparably low noise levels – while the same was not observed with the background subtraction visual activity index. It is to be expected that the visual activity mesuring model based on background subtraction will be less sensitive to application of varying levels of video content compression than Cutting's visual activity index.

The final testing of the proposed model was performed using two groups of video content. The first group consisted of 50 recipients of the Academy Award for Best Picture presented by the Academy of Motion Picture Arts and Sciences between 1965 and 2014. The second group consisted of recipients of the MTV Best Music Video award presented between 1984 and 2013. The Mann-Kendall Trend Test was used to test background subtraction visual activity index changes concerning the award-winning feature films in the above 5-decade period. It was revealed that the value grew in the period. The same test was applied to test the changes in the award-winning music videos in the above 3-decade period – likewise revealing a growth of the background subtraction visual activity index.

As an alternative to the Cutting's visual activity index, the background subtraction visual activity index shall allow scientists in the field of humanities and social sciences to quantify visual activity which is hitherto described in qualitative terms in their works. A potential opportunity for further development and automation of the Limited Capacity Model of Motivated Mediated Message Processing is also introduced because measurement of certain aspects of information density could be automated.

KEY WORDS: information density, visual activity, visual activity index, background subtraction algorithms, LC4MP

Sadržaj

1. UVOD 1

1.1. Uvod u istraživanje 1

1.2. Ciljevi, doprinos i hipoteze istraživanja 7

2. VIZUALNA AKTIVNOST U MEDIJIMA 10

2.1. Vizualni mediji 10

2.2. Pojam vizualne aktivnosti 17

2.3. Mjerenje vizualne aktivnosti 19

2.3.1. Mjerenje dužine kadrova 19

2.3.2. Vizualni otisak prsta 24

2.3.3. Filmski oblaci 26

2.3.4. Indeks vizualne aktivnosti 26

2.4. Utjecaj različitih razina vizualne aktivnosti 32

2.4.1. Utjecaj vezan uz brzinu promjene kadra 32

3. GUSTOĆA INFORMACIJA 36

3.1. Definicija informacije 36

3.2. Definicija gustoće informacija 38

3.2.1. Objektivna gustoća informacija 38

3.2.2. Subjektivna gustoća informacija 41

3.3. Informacijsko preopterećenje 42

3.3.1. Čimbenici nastanka informacijskog preopterećenja 44

3.3.2. Srodni pojmovi 46

3.3.3. Teorijski okviri 48

3.3.3.1. Kvalitativni teorijski okviri 48

3.3.3.2. Kvantitativni teorijski okviri 55
4. ALGORITMI ZA UKLANJANJE POZADINE 67
4.1. Računalni vid 67
4.1.1. Osnovne podatkovne strukture 71
4.1.2. Vrste deskriptora 75
4.2. Algoritmi računalnog vida 77
4.2.1. Podjela algoritama računalnog vida 78
4.2.2. Algoritmi za detekciju pokretnih objekata 79
4.3. Algoritmi za uklanjanje pozadine 81
5. MODEL, PODATCI I METODOLOGIJA 88
5.1. Model zasnovan na algoritmima za uklanjanje pozadine 88
5.1.1. Izbor BGS algoritma na temelju korelacije između gustoće informacija i vrijednosti dobivene BGS algoritmima 91
5.1.2. Analiza utjecaja varijable „Složenost strukture“ 112
5.2. Hipoteza 1 113
5.3. Hipoteza 2 116
5.4. Hipoteza 3 123
5.4.1. Analiza filmske produkcije 123
5.4.2. Analiza glazbenih video spotova 134
6. REZULTATI I RASPRAVA 141
7. ZAKLJUČAK 146
8. PREGLED NAJVAŽNIJIH DOPRINOSA 148
9. LITERATURA 149
10. PRILOZI 171
10.1. Programski kod u Microsoft Visual C++ 2010 Express 171

10.2. Programski kod u programu MATLAB za mjerenje vrijednosti VAI (prilagođeno od Cutting)....176
10.3. Programski kod u MATLAB-u za dodavanje šuma u video isječke....178
10.4. Popis video isječaka Annie Lang korištenih u radu....182
10.5. Histogrami korištenih podataka po pojedinim dimenzijama....187
10.6. Postavke za algoritme uklanjanja pozadine koji su korišteni u radu....192
10.7. Izlazni rezultati Spearmanove korelacije iz SPSS-a između BGSVAI vrijednosti i pojedinih dimenzija Gustoće informacija....199
10.8. Izlazni rezultati Spearmanove korelacije varijabli VAI i BGSVAI u SPSS-u uz 1. hipotezu....200
10.9. Izlazni rezultati Wilckoxonovog testa u SPSS-u uz 2. hipotezu....200
10.10. Adrese korištenih glazbenih video spotova na servisu www.youtube.com....202
11. Popis objavljenih radova i životopis....204

Popis tablica

Tablica 1- Modaliteti vizualnih medija (Bernsen, 1994) 15
Tablica 2– Modaliteti dinamičnih vizualnih medija (Bernsen, 1994) 16
Tablica 3– Primjeri dinamičkih vizualnih modaliteta (Bernsen, 1994) 16
Tablica 4– Metrika gustoće informacija (Hammouda, 2000) 41
Tablica 5 – Količina informacija različitih informacijskih struktura (Lurie, 2004) 55
Tablica 6 – Sažeti prikaz područja 74
Tablica 7 – Metode uklanjanja pozadine (Benezeth et al, 2010) 83
Tablica 8 – Kategorije, algoritmi, idejni autori algoritma i osobe koje su ga prilagodile za upotrebu 91
Tablica 9 – Spearmanove korelacije za osnovne metode 96
Tablica 10 – Spearmanove korelacije za algoritme bazirane na neodređenoj (eng. Fuzzy) logici 98
Tablica 11 - Spearmanove korelacije za algoritme bazirane na Gaussovoj distribuciji 99
Tablica 12 - Spearmanove korelacije za algoritme bazirane na Gaussovoj distribuciji (višestruke) 100
Tablica 13 - Spearmanove korelacije za algoritme bazirane na neodređenoj (eng. Fuzzy) logici drugog tipa 103
Tablica 14 - Spearmanove korelacije za algoritme bazirane na više značajki 104
Tablica 15 - Spearmanove korelacije za algoritme bazirane na neparametrijskim metodama 105
Tablica 16 - Spearmanove korelacije za algoritam baziran na podprostoru 107
Tablica 17 – Rezultati za pojedine algoritme 109
Tablica 18 – Vrijednosti parcijalnih korelacija uz isključivanje utjecaja varijable Složenost strukture 113
Tablica 20 - VAI i BGS VAI vrijednosti za video isječke 113
Tablica 21 – Slike i vrijednosti dodanog šuma 118
Tablica 22 – Vrijednosti VAI I BGS VAI za različite varijance distribucije šuma 119
Tablica 23 – Vrijednosti VAI I BGS VAI uz različite varijance šuma 120
Tablica 24 – Popis obrađenih filmova 125
Tablica 25 – Karakteristike obrađenih filmova 127
Tablica 26 – BGS VAI vrijednosti za obrađene filmove 130
Tablica 27 – Popis dobitnika nagrade MTV Best Music Video od 1984. do 2013. godine 135

Tablica 28 – Podatci za glazbene video spotove.....137

Popis slika

Slika 1 – Hijerarhijska struktura za klasifikaciju medija (Sutcliffe, 2008) 12
Slika 2– ASL za 150 filmova između 1935 i 2010 – (Cutting et al, 2011) 21
Slika 3– ASL vrijednosti za 9400 filmova na engleskom jeziku (Cutting et al, 2015a) 21
Slika 4– ASL vrijednosti za 1500 filmova koji nisu na engleskom jeziku (Cutting et al, 2015a) . 22
Slika 5– Distribucije frekvencija dužina kadrova za film A Night at the Opera (DeLong et al, 2013) 23
Slika 6- Vizualni „otisci prsta“ za 16 filmova (Brodbeck, 2011). 25
Slika 7– Filmski oblak (Grijalva 2014) 26
Slika 8 – Distribucija vrijednosti VAI (Cutting, 2011) 28
Slika 9– VAI vrijednosti za 145 filmova koji su producirani u različitim periodima (Cutting, 2011) 29
Slika 10 – VAI vrijednosti kategorizirane po filmskim vrstama (Cutting, 2011) 30
Slika 11- VAI vrijednosti s obzirom na proporcije vremena trajanja dijela scene (Cutting, 2012) 32
Slika 12 – Shematski prikaz sažimanja podataka (Whitaker, 2005) 39
Slika 13 – Invertirana U-krivulja pojave informacijskog preopterećenja (Schroeder, 1967, po Eppler et al, 2004). 43
Slika 14 - Kategorizacija čimbenika informacijskog preopterećenja (Ho&Tang, 2001) 45
Slika 15 – Model informacijskog preopterećenja (Schneider, 1987) 49
Slika 16- Konceptualni okvir za strukturno istraživanje informacijskog preopterećenja (Eppler & Mengis, 2004). 52
Slika 17 - Rast količine informacija (izvor: Kirsh, 2000) 58
Slika 18 – Konceptualni model informacijskog preopterećenja (Jackson & Farzaneh, 2012) 60
Slika 19 – Dualni odnos računalnog vida i računalne grafike (Rockwood et al, 1999) 68
Slika 20 – Tumačenje slike na temelju modela (Barrow et al, 1981) 69
Slika 21 – Slijed obrade informacija kod računalnog vida (Hornberg, 2017) 70
Slika 22 – Slika u nijansama sive boje uzorkovana (Jimenez-Fernandez, 2016) 72
Slika 23 – Nastanak višebojne slike (BrainHQ, 2016) 73
Slika 24 – Dva područja (Loomis, 1998) 74
Slika 25 – Različite konture preciznije od piksela (Steger, 2017). 75

Slika 26 – Deskriptor srednje razine u odnosu na ostale (Martinet et al, 2012) 76
Slika 27 – Primjer deskriptora srednje razine (Martinet et al, 2012) 77
Slika 28 – Proces uklanjanja pozadine (Bouwmans, 2012) 81
Slika 29 – Klasifikacija metoda uklanjanja pozadine za detekciju stacionarnih objekata (Bayona et al, 2009) 83
Slika 30 – Prozor otvoren u sklopu izvršavanja programa sa brojem slike koja se obrađuje 93
Slika 31 – Dva prozora otvorena u sklopu izvršavanja programa 94
Slika 32 – Graf korelacija po dimenzijama za osnovne metode 96
Slika 33 – Graf korelacija po algoritmima za osnovne metode 97
Slika 34 - Graf korelacija po dimenzijama za algoritme bazirane na neodređenoj (eng. Fuzzy) logici 98
Slika 35 - Graf korelacija po algoritmima za algoritme bazirane na neodređenoj (eng. Fuzzy) logici 99
Slika 36 - Graf korelacija po dimenzijama za algoritme bazirane na Gaussovoj distribuciji 100
Slika 37 - Graf korelacija po algoritmima za algoritme bazirane na Gaussovoj distribuciji 100
Slika 38 - Graf korelacija po dimenzijama za algoritme bazirane na Gausovoj distribuciji (višestruke) 101
Slika 39 - Graf korelacija po algoritmima za algoritme bazirane na Gausovoj distribuciji (višestruke) 102
Slika 40 - Graf korelacija po dimenzijama za algoritme bazirane na neodređenoj (eng. Fuzzy) logici drugog tipa 103
Slika 41 - Graf korelacija po algoritmima za algoritme bazirane na neodređenoj (eng. Fuzzy) logici drugog tipa 104
Slika 42 - Graf korelacija po dimenzijama za algoritme bazirane na više značajki 105
Slika 43 - Graf korelacija po algoritmima za algoritme bazirane na više značajki 105
Slika 44 - Graf korelacija po dimenzijama za algoritme bazirane na neparametrijskim metodama 106
Slika 45 - Graf korelacija po algoritmima za algoritme bazirane na neparametrijskim metodama 107
Slika 46 - Graf korelacija po dimenzijama za algoritam baziran na podprostoru 107
Slika 47 - Graf korelacija po algoritmima za algoritam baziran na podprostoru 108

Slika 48 – Graf korelacija po dimenzijama za sve algoritme 111
Slika 49 – Grafički prikaz povezanost VAI i BGS VAI vrijednosti za video isječke 116
Slika 50 – Varijanca 0 118
Slika 51 – Varijanca 0,0001 118
Slika 52 – Varijanca 0,001 118
Slika 53 – Varijanca 0,01 118
Slika 54 – Varijanca 0,1 119
Slika 55 – Varijanca 1 119
Slika 56 – VAI vrijednosti za različite varijance šuma za jedan video isječak 119
Slika 57 – BGS VAI vrijednosti za različite varijance šuma za jedan video isječak 120
Slika 58 – Vrijednosti VAI za izabrane video isječke 121
Slika 59 – Vrijednosti BGS VAI za izabrane video isječke 122
Slika 60 – Produkcija filmova na globalnoj razini u 2003. godini (Nationmaster, 2017) 124
Slika 61 - Produkcija filmova na globalnoj razini u 2013. godini (Nationmaster, 2017a) 125
Slika 62 – Grafički prikaz trajanja obrađenih filmova u sekundama 128
Slika 63 – BGS VAI vrijednosti za filmove 131
Slika 64 – BGS VAI vrijednosti nakon zamjene filmova “The Artist” i “Schindler's List” 132
Slika 65 – Grafički prikazani BGSVAI podatci testirani Mann-Kendalovim testom za trendove 133
Slika 66 – Testiranje periodičnog ponavljanja u programu R Studio 134
Slika 67 – BGS VAI vrijednosti za glazbene video spotove 138
Slika 68 - Grafički prikazani BGSVAI podatci testirani Mann-Kendalovim testom za trendove 139
Slika 69 - Testiranje periodičnog ponavljanja u programu R Studio 140

Popis korištenih kratica

LC4MP	**Limited Capacity Model of Motivated Mediated Message Processing**
VAI	**Visual Activity Index**
ASL	**Average Shot Length**
MTV	**Music Television**
ASD	**Average Shot Duration**
ABC	**American Broadcasting Company**
CBS	**Columbia Broadcasting System**
NBC	**National Broadcasting Company**
JPG	**Joint Photographic Experts Group**
RSVP	**Rapid Serial Visual Presentation**
EEG	**Elektroencefalograf**
OR	**Orienting Response**
CARE	**Cognitive Appraisal of Risky Events**
IPC	**Information Processing Capacity**
IPR	**Information Processing Requirements**
STRT	**Secondary Task Response Time**
LC3MP	**Limited Capacity Model of Mediated Message Processing**
I^2	**Information Introduced**
CC	**Camera Changes**
CV	**Computer Vision**
CG	**Computer Graphics**

LLD	**Low-level descriptor**
HLD	**High-level descriptor**
MLD	**Mid-level descriptor**
OpenCV	**Open Computer Vision**
ROI	**Region of Interest**

I TEORIJSKA RAZMATRANJA

Man should devote a lot of time to himself,
to his thoughts and to reflection in seclusion.
We should not be overburdened by pictures
received through the media.
Ivan Supek (Medijska istraživanja, 1999.)

1. UVOD

1.1. Uvod u istraživanje

Posljednjih nekoliko godina svjedoci smo znatnim promjenama koje se događaju na području medija i načina na koji komuniciramo. Slikovit prikaz intenziteta tih promjena dao je Williams koji je period od trenutka pojave govorne komunikacije do danas, što je po njemu oko 36000 godina, prikazao kao period od jednog dana. Izum pisma starih Sumerana prije 4000 godina u periodu od 24 sata bi se dogodio oko 20 sati, a Homerova Ilijada je napisana oko 22 sata. Tiskarski stroj je izumljen u 23:38, a parni stroj u 23:53. U dvije minute prije ponoći pojavljuje se televizija u boji. Najveće promjene u tom simboličkom prikazu su se dakako dogodile zadnjih minuta i još se događaju (Williams, 1982, prema Malović, 2014).

Razvoj medija, a posebno pojava novih medija, u pravilu se doživljava sa skepsom i pesimizmom. Za novine se smatralo da potiču na zločine samim izvještavanjem o njima, dok se za operu smatralo da potiče brutalnost. Za telefon se smatralo da ugrožava zdravlje dok se za radio smatralo da je prijetnja roditeljskom autoritetu (Malović, 21, 2014). Vremenom bi se takve predrasude odbacile, a Ogburn je tu pojavu nazvao „*culture lag*“. Radi se o situaciji kada se različita područja ne razvijaju usklađeno, konkretno na području komunikacija ova se pojava očituje kroz brz razvoj tehnologija, dok se ostala područja tome prilagođavaju i na neki način „kasne“ za razvojem tehnologija (Ogburn, 1922, prema Malović, 2014).

Vezano uz utjecaj masovnih medija, Malović iznosi da posljedice istih „izravno i neizravno djeluju na znanje, mišljenje, stavove, nazore, osjećaje i ponašanje na individualnoj i sistemskoj razini“ (Malović, 22, 2014.). Maletzke smatra da „utjecaj u najširem smislu označava sve procese ponašanja i doživljavanja koji se mogu svesti na činjenicu da je čovjek recipijent masovne komunikacije“ (Maletzke 1963. po Kunczik, 2006).

Maletzke komunikaciju dijeli na predkomunikacijski, komunikacijsku i postkomunikacijsku fazu, te u tom kontekstu autor razrađuje utjecaje masovnih medija kao „procese koji se u postkomunikacijskoj fazi odvijaju kao posljedice masovne komunikacije, a s druge strane u pravoj komunikacijskoj fazi to su svi oblici ponašanja koji su rezultat sučeljavanja ljudi s iskazima masovne komunikacije“ (Maletzke 1963. po Kunczik, 2006). Komunikacijska faza uključuje po autoru emocionalni procesi i procesi percepcije, tijek pažnje, problemi razumijevanja i estetski moment. Postkomunikacijski utjecaji mogu se klasificirati na niz različitih načina, pa tako imamo namjerne i nenamjerne efekte, zatim fizičke i psihičke efekte, a s obzirom na veličinu grupe utjecaj možemo podijeliti na individualnu razinu, razinu skupine i razinu socijalnog sustava.

U literaturi se spominju četiri faze istraživanja utjecaja medija:

1. Faza – Svemoć medija (1900-1940) – u tom periodu smatralo se da mediji mogu utjecati na primatelje i to na način da se kod svih izazove ista reakcija koju je komunikator namjeravao izazvati,
2. Faza – Mediji bez utjecaja (1940-1965) – u tom periodu empirijski se dokazalo da individualne razlike u strukturi osobe, kao i socijalno okruženje imaju znatan utjecaj na reakcije primatelja,
3. Faza – Ponovno otkrivanje snažnog utjecaja medija (1965-1980) – u tom periodu se ponovno smatra da mediji imaju velik utjecaj na primatelje, mada se fokus istraživanja iz tog perioda prebacuje sa komunikatora i sadržaja na aktivno ponašanje primatelja. U tom periodu raste gledanost televizije, a obrada podataka putem računala omogućila je provjeru složenih teorijskih postavki.
4. Faza – (od 1980) –u ovoj fazi se uvodi pojam „transakcijske perspektive“ koja naglašava jaku poziciju publike uz jaku poziciju medija. Pri tome mediji konstruiraju slike realnosti, koju publika pod utjecajem socijalnog okruženja pretvara u predodžbu društvene stvarnosti (Kunczik, 157, 2006.)

Ne ulazeći dublje u analizu navedenih istraživanja utjecaja i površnim pregledom može se zaključiti da se u radovima najčešće obrađuje utjecaj sadržaja na primatelja kroz poruke komunikatora. Ipak, u novije vrijeme proučavaju se i drugi utjecaji medija, pa tako Sigman navodi područja na koja mediji imaju utjecaj i bila su predmet istraživanja kod djece:

a) Hormoni
b) Metabolizam

c) Kardiovaskularne bolesti
d) Mortalitet
e) Fizička spremnost
f) Mozak
g) Poremećaji spavanja
h) Autizam
i) Poremećaji pažnje
j) Mentalno zdravlje
k) Komunikacija u obitelji
l) Empatija (Sigman, 2010)

Gore su navedeni podnaslovi u radu u kojem autor daje pregled objavljenih radova koji pokrivaju spomenuta područja. Značajno je spomenuti da na svakom području postoje radovi koji ukazuju na povezanost vremena provedenim prateći program ili koristeći neki medij uključujući i Internet, na učestalost odnosno vjerojatnost pojave nekih problema vezanih uz pojam u naslovu. Da treba biti svjestan ozbiljnosti utjecaja medija ukazuje i u literaturi često spominjan *Pokemon* fenomen. Radi se o incidentu koji se zbio u Japanu 16. prosinca 1997. pri čemu je oko 700 djece hospitalizirano zbog neuroloških problema nakon što su gledali epizodu crtane televizijske serije *Pokemon* (Furusho et.al. 2002).

Jedan od radova koji je imao velik utjecaj, te se često citirao u medijima je rad Angeline Lillard u kojem ona analizira utjecaj različitih vrsta televizijskog programa na kognitivne funkcije predškolske djece. U istraživanju su predškolska djeca podijeljena u tri grupe te je prva grupa gledala dinamičan (eng. *fast-paced*) televizijski crtani film, druga grupa je gledala manje dinamičan (eng. *slow-paced*) obrazovni crtani film dok je treća grupa crtala u periodu od 9 minuta. Nakon toga sve tri grupe su rješavale testove kognitivnih funkcija., a rezultati ukazuju da je grupa koja je gledala dinamičan televizijski crtani film riješila testove značajno lošije od druge dvije grupe. Autorica je pri tome razliku između dinamičnog i obrazovnog crtanog filma opisala kvalitativno, te nije pri tom koristila kvantitativne mjere da iskaže razliku među tim crtanim filmovima.

Za pojam dinamike na televiziji autori su koristili izraz *pacing*, ali su ga tumačili na različite načine. Watt i Krull ga definiraju kao učestalost verbalnih iskaza i promjena pozadine, dok ga prvi autor s drugim suradnikom desetak godina kasnije definira kao nepredvidljivost, odnosno razlike u razini svjetla na ekranu kroz vrijeme (Watt et al, 1974)(Watt et al 1983).

Cooper i kolege pojam *pacing* tumače kao učestalost promjena kuta kamere, dok Lang i suradnici taj pojam definiraju kao broj prijelaza s jedne scene na drugu, a u svom radu kvantificiraju taj broj na tri razine (Cooper 2009) (Lang et al 1999). Anderson i suradnici su koristili isti pojam u svom istraživanju, te klasifikaciju dinamike, odnosno tempa bazirali na: učestalosti pomaka kamere i obrade videa, učestalosti promjene na potpuno novu scenu, postotak žive glazbe, postotak aktivnosti koja se očituje u kretanju i duljinu kadra (Anderson et al 1977). Huston i suradnici definiraju pojam *pace* kao učestalost promjene scena i likova, te u istraživanju navode dvije komponente od kojih se sastoji pojam, a to su varijabilnost i tempo. Varijabilnost je broj različitih scena, dok je tempo mjera promjene među scenama i likovima (Huston et al 1981). Očigledno ne postoji konsenzus među autorima te svatko tumači pojam na drugi način, mada je očito da su opisi slični.

Većini autora navedenih u prethodnom odlomku zajdničko je to da *pacing* najčešće mora izmjeriti ili kategorizirati obučeni opažač, te se u nekim situacijama ne može izbjeći subjektivnost pri mjerenju ili kategoriziranju. Isto tako se može primijetiti da većina autora prepoznaje prosječno trajanje kadra kao pojavu koja se povezuje s pojmom *pacing*. Mjera prosječnog trajanja kadra (eng. *Average Shot Lenght*) se spominje u literaturi, pa tako Bordwell daje pregled prosječnog trajanja kadra za filmove unazad nekoliko desetljeća, te navodi da je između 1930. i 1960. ASL bio u prosjeku između 8 i 11 sekundi. Krajem šezdesetih godina prošlog stoljeća ASL je bio između 6 i 8 sekundi, da bi se sedamdesetih smanjio na vrijednosti između 5 i 8 sekundi. Na prijelazu stoljeća ASL je bio između 3 i 6 sekundi što je očigledno daljnji pad. Autor navodi da je u prošlom stoljeću film sa najmanjom vrijednosti ASL imao 1,8 sekundi, a treba spomenuti da se analiza odnosi na filmove producirane u Sjedinjenim Američkim Državama (Bordwell, 2002).

Katie M. Palmer je analizirala kratke reklame za filmove (eng. *trailers*) unazad sedamdeset godina, te je mjerila broj izmjena kadrova u minuti da bi također uočila konstantan rast vrijednosti za navedenu mjeru proteklih godina. Autorica navodi da je prosječan broj izmjena kadra u minuti pedesetih godina prošlog stoljeća iznosio 12, dok je devedesetih narastao na 38. Da bi dobili ASL vrijednosti iz vrijednosti koje prezentira autorica, potrebno je 60 podijeliti s brojem izmjena kadra u minuti (Palmer, 2013).

Cutting i suradnici u svom radu također uočavaju spomenute trendove na svom uzorku od 150 filmova, gdje je vrijednost ASL sredinom prošlog stoljeća bila preko 10 sekundi, da bi do kraja stoljeća pala na ispod 5 sekundi. Autori navode da je ista pojava uočena i na znatno

većem uzorku od oko 13000 filmova koje je analizirao Salt, pri čemu je ASL padao od vrijednosti 12 koja je bila najčešća u periodu pojave zvučnog filma, pa do 5 sekundi krajem devedesetih godina prošlog stoljeća. (Cutting, 2011)(Salt 2006, po Cutting 2011).

Cutting je sa suradnicima otišao korak dalje pa je razvio model za mjerenje vizualne aktivnosti unutar kadra. Kod definicije pojma vizualna aktivnost (eng. *Visual Activity*), autor upućuje na Gibsona koji definira pojam *motion* kao promjenu mjesta objekata ili ljudi u kadru s nepomičnom pozadinom, te pojam *movement* kao vizualnu informaciju nastalu kretanjem promatrača, odnosno kamere ako se radi o filmu (Gibson, 1954). Cutting pojam vizualne aktivnosti definira kao zbroj aktivnosti opisanih kao *motion* i *movement*. Autor računa korelacije između točaka (eng. *pixel*) susjednih pojedinačnih slika (eng. *frame*) u filmu, te njihov medijan oduzimanjem od broja 1 pretvara u mjeru koju naziva Indeksom vizualne aktivnosti (eng. *Visual Activity Index*). Na taj način u slučaju da nema nikakve vizualne aktivnosti na filmu, VAI ima vrijednost 0, dok mu je najveća teorijska vrijednost 2. Autori u svom radu analiziraju pojedinačne filmove te iznose da je VAI vrijednost od 1935. do 2005. uvećana oko 3 puta. Za filmove iz godine 1935. VAI vrijednost je bila 0,02, dok je za filmove iz 2005. godine bila 0,06 (Cutting, 2012)(Cutting, 2015).

James E. Cutting i njegov kolega Jordan E. DeLong najistaknutiji su autori na području analize vizualne aktivnosti u medijima, a razvijeni model daje Indeks vizualne aktivnosti koji je trenutno najpoznatija mjera vizualne aktivnosti. Autori ukazuju da postoji značajna negativna korelacija između ASL i VAI vrijednosti kod analiziranih filmova, te da iznosi -0,46, odnosno -0,55 kada je ASL postavljen na logaritamskoj skali.

Spomenuti model u potpunosti isključuje gledatelja, odnosno primatelja medijskog sadržaja. U nekim situacijama je moguće da vrijednost VAI prilično visoka, a primatelj medijskog sadržaja tu aktivnost praktički uopće ne primjećuje. Primjer za to bi bio snimak drveta na kojem se lišće pomiče na vjetru. Na tragu toga se nazire i druga primjedba, a to je osjetljivost na šum u video sadržaju koji može utjecati na konačnu vrijednost VAI, a opet je moguće da primatelj sadržaja uopće ne registrira šum.

Rješenje navedenih problema moglo bi se naći u području računalnog vida. Jahne i Haussecker definiraju računalni vid kao „niz tehnika za prikupljanje, obradu, analizu i razumijevanje složenih višedimenzionalnih podataka iz našeg okruženja za tehničku i znanstvenu primjenu“ (Jahne et al, 2000). Na tom području razvijen je niz algoritama koji se konstantno usavršavaju, a jedna grupa algoritama služi za uklanjanje pozadine, odnosno

detekciju pokretnih objekata video sadržaja. Prvi algoritmi te namjene korišteni su već sedamdesetih godina prošlog stoljeća (Jain, 1979), dok ih danas ima niz na raspolaganju i izbor odgovarajućeg algoritma ovisi o prednostima i nedostacima istog u ovisnosti o specifičnostima primjene. Pojednostavljeno, algoritmi obrađuju video sadržaje na način da se kao izlaz obrade dobije dvobojni video sadržaj pri čemu je jedna boja detektirani pokretni objekt dok je druga nepomična pozadina. Koristeći omjer broja točaka (eng. *pixel*) detektiranih pokretnih objekata i ukupnog broja točaka u nekom video isječku može se kvantificirati količina pokreta u video sadržaju što je ključna ideja u disertaciji, a taj pristup će detaljno biti analiziran i istražen. Takav pristup bi trebao biti robusniji kod analize video sadržaja sa znatnom količinom šuma pod uvjetom da se koriste algoritmi za uklanjanje pozadine koji su otporni na šum.

Kao što je navedeno, predlaže se pristup koji do sada nije spominjan u literaturi i prema kojemu se za kvantificiranje količine pokreta u video sadržaju koristi omjer broja točaka (eng. *pixel*) detektiranih pokretnih objekata i ukupnog broja točaka, a za detektiranje pokretnih objekata koristit će se neki od algoritama za uklanjanje pozadine. Pitanje koje se nameće je koji od nekoliko desetaka algoritama daje najbolje rezultate kod detekcije odnosno potrebno je definirati kriterij izbora odgovarajućeg algoritma. Navedeni algoritmi su dosta često razvijani za potrebe industrije i to za neke specifične namjene, te samim tim ostaje otvoreno pitanje u kojoj su mjeri dovoljno pogodni za mjerenje dinamike video sadržaja kako je percipiraju gledatelji. Radi izbora najboljeg algoritma polazna je pretpostavka da je potrebno uključiti određeni provjereni model s područja komunikacijskih znanosti koji pokriva usko područje dinamike video sadržaja. U radu se stoga koristi Model ograničenog kapaciteta obrade motiviranih posredovanih poruka (eng. *Limited Capacity Model of Motivated Mediated Message Processing*) autorice Annie Lang. U literaturi se za taj model često koristi kratica LC4MP (Lang et al, 2007).

Model pretpostavlja da primatelji audio vizualnih sadržaja imaju ograničene resurse obrade informacija te kada potrebni resursi prekorače dodijeljene resurse dolazi do informacijskog preopterećenja pri kojem se dio poruke gubi. Proces alokacije resursa kod primatelja je složen i ovisi o nizu čimbenika, a odvija se automatski ili kontrolirano. Razrada LC4MP modela uvela je nove značajke i to „složenost strukture“ (broj izmjena kadra u sekundi) kao mjeru dodijeljenih resursa i „gustoću informacija“ (novouvedene informacije) kao mjeru potrebnih resursa, što omogućuje dalju razradu i usavršavanje modela kao i praktičnu primjenu istog (Lang et al, 2007). Za dobivanje vrijednosti varijable „složenost strukture“ postoji niz automatskih metoda dobro opisanih u literaturi, a za manje količine sadržaja vrijednost se može

odrediti i praćenjem izmjene kadrova (Hanjalic, 2002)(Boreczky, 1996). Vrijednost varijable „gustoća informacija“ određuju obučeni opažači praćenjem sadržaja (Lang et al, 2007). Važnost opisanog modela za ovu disertaciju je u tome što će on biti temelj pri algoritma za uklanjanje pozadine koji će se koristiti u predloženoj metodi.

Naslov ove disertacije osim naziva „gustoća informacija“ i „vizualna aktivnost“ koji su spomenuti prethodno, sadrži i naziv „dinamične slike“ koje se kao element multimedija koriste za prikaz slikovnih sadržaja (Mikelić, 2003). Neki autori koriste izraz dinamične slike za koncept interaktivnih animacija u kojima korisnik mijenjajući neke parametre trenutno vidi utjecaj te promjene (Wittenmark, 1998). Osim toga izraz se u novije vrijeme koristi kao oblik prezentacije videa u kontekstu dubokog učenja kada se koriste konvolucijske neuronske mreže (Bilen et al, 2017). Isto tako izraz se često susreće u stručnoj literaturi vezanoj uz programski jezik *JavaScript* pri čemu označava grafičke objekte koji najčešće mijenjaju izgleda kod postavljanja pokazivača na sliku i slično (Fergusson et al, 2013). U nastavku će se taj pojam koristiti u njegovom općenitijem značenju u kojem uključuje video sadržaje nastale snimanjem stvarnih situacija bez obzira na tehnologiju nastanka, kao i računalne animacije koje ne prikazuju realne situacije. Pri tome će se koristiti klasifikacija koju navodi A.G. Sutcliffe, a koji navodi da je granična brzina izmjene statičnih slika iznad koje se niz slika više ne može nazvati statičnim - 10 slika u sekundi. Sve više od te vrijednosti u nastavku će se nazivati dinamičnim slikama, bez obzira na tehnologiju izrade i realnost prikazanog. Treba spomenuti da neki autori kao graničnu vrijednost prijelaza iz statične u dinamične slike navode i veće vrijednosti od 10 slika u sekundi (Sutcliffe, 1998).

1.2. Ciljevi, doprinos i hipoteze istraživanja

Problem na koji ukazuje A.S. Lillard, a koji se sastoji u kratkoročno negativnim utjecajima crtanih filmova bržeg tempa, govori o mogućim posljedicama izloženosti medijima različitog tempa i kroz različite periode. Kao što je navedeno, znanstvenici s određenih područja prepoznaju razlike u tempu video sadržaja, ali te razlike opisuju na kvalitativnoj razini, što ukazuje na potrebu uvođnja mjere kojom bi se te razlike mogle iskazati kvantitativno.

Pristup mjerenju „gustoće informacija“ temeljen na algoritmima za uklanjanje pozadine koji se predlaže u ovom radu do sada nije predstavljen od drugih autora. U ovom pristupu početno je potrebno proučiti algoritme za uklanjanje pozadine. Algoritama ima nekoliko desetaka opisanih u literaturi, te je potrebno provesti analizu i pregled istih. S obzirom na dinamiku razvoja algoritama za uklanjanje pozadine te njihovu klasifikaciju, većina dostupnih

pripada u kategoriju algoritama za rad s nepomičnom kamerom, dok se u novije vrijeme sve češće pojavljuju i algoritmi koji su efikasni i u radu s pokretnom kamerom. Algoritme predviđene za rad sa nepomičnom kamerom je A. Sobral podijelio u sljedeće nabrojene kategorije: osnovni algoritmi bazirani na promjeni srednje vrijednosti i varijance po vremenu, algoritmi bazirani na neodređenoj (eng. *fuzzy)* logici, jednostruki algoritmi bazirani na Gaussovoj vjerojatnosti, višestruki algoritmi bazirani na Gaussovoj vjerojatnosti, algoritmi bazirani na neodređenoj (eng. *fuzzy)* logici drugog tipa, metode bazirane na više svojstava, neparametrijske metode, metode bazirane na podprostoru, neuralne i *neuro-fuzzy* metode. U radu će se koristiti podjela predložena od spomenutog autora Sobral (Sobral, 2013). Nakon toga potrebno je izabrati algoritam koji „najbolje" kvantificira vizualnu aktivnost. Za to će se koristiti video isječci koje su autorica A. Lang i suradnici koristili u radu pod nazivom „*Cognition and Emotion in TV Message Processing: How Valence, Arousing Content, Structural Complexity, and Information Density Affect the Availability of Cognitive Resources*" iz 2007. godine (Lang et.al., 2007). Značaj tog istraživanja je potvrda LC4MP modela i tumačenje pojma informacijskog preopterećenja kod gledatelja. U radu se koristilo 144 video isječka dužine 30 i 60 sekundi, ali iz tehničkih razloga neki od tih isječaka više nisu dostupni te je za potrebe ove disertacije pribavljeno 135 video isječaka od autorice. Spomenuti video isječci iskoristit će se na način da se vrijednosti koje čine varijablu gustoća informacija LC4MP modela usporede s vrijednostima dobivenim različitim algoritmima za uklanjanje pozadine. Kako algoritmi za uklanjanje pozadine kao rezultat vraćaju dvobojni video isječak u kojem jedna boja predstavlja pozadinu, a druga prednji plan, vizualna aktivnost dobivena kao rezultat spomenutih algoritama bit će iskazana kao ukupan broj točaka (eng. *pixel*) koji predstavljaju pokretne objekte u odnosu na ukupan broj točaka video isječka. Odabir algoritama provodit će se na temelju podudarnosti između vizualne aktivnosti izmjerene određenim algoritmom i varijabli LC4MP modela.

Sljedeći cilj je usporedba predloženog modela koji se temelji na izabranom algoritmu za uklanjanje pozadine s postojećim, već spomenutim Indeksom vizualne aktivnosti. Pri tom će se koristiti spomenutih 135 video isječaka koje je koristila A. Lang u svom radu. Video isječci obradit će se koristeći algoritme za uklanjanje pozadine te će se izračunati koeficijent korelacije između postojećeg Indeksa vizualne aktivnosti i predloženog Indeksa vizualne aktivnosti temeljenog na algoritmima za uklanjanje pozadine. Indeks vizualne aktivnosti računat će se koristeći originalan algoritam u MATLAB-u autora J.E. Cuttinga.

S obzirom da se predloženi model zasniva na algoritmima za uklanjanje pozadine od kojih je većina otporna na šum u sadržaju na način da se šum ne registrira kao objekt koji se kreće, može se očekivati da će model biti robusniji kod analize video sadržaja sa znatnom količinom šuma od Indeksa vizualne aktivnosti. Cilj je pokušati dokazati robusnost predloženog modela na način da se za video isječke s različitim razinama šuma izračuna Indeks vizualne aktivnosti i vrijednost vizualne aktivnosti bazirana na algoritmima za uklanjanje pozadine. Usporedbom tih vrijednosti uz različite razine šuma koji će biti dodan video isječcima utvrdit će se postoji li razlika u registriranju šuma kao vizualne aktivnosti.

Na kraju je potrebno provjeriti predloženi model te utvrditi postoji li porast vizualne aktivnosti u vizualnim medijima unazad nekoliko desetljeća. Za ostvarenje tog cilja koristit će se filmovi koji su nagrađeni nagradom *Best Picture Academy Award* i to u periodu između 1965. i 2014. godine. Spomenuta nagrada se dodjeljuje od tridesetih godina prošlog stoljeća, ali zbog nedostupnosti pojedinih filmova obradit će se filmovi nagrađeni u navedenom periodu. Filmovi će biti obrađeni izabranim algoritmom za uklanjanje pozadine te će na osnovu toga biti izmjerena vizualna aktivnost za svaki film. Te će se vrijednosti prikazati na vremenskoj osi, a statistička značajnost promjene u vremenu testirati prikladnim metodama. Kod dokazivanja treće hipoteze koristit će se i glazbeni video spotovi nagrađeni nagradom *MTV Best Music Video*. S obzirom da se spomenuta nagrada dodjeljuje od 1984. godine na raspolaganju je bilo tridesetak video spotova. Spotovi će biti obrađeni odabranim algoritmom za uklanjanje pozadine te će biti izmjerena vizualna aktivnosta za svaki spot. Potom će se dobivne vrijednosti prikazati na vremenskoj osi te će se također statistička značajnost promjene u vremenu testirati prikladnim metodama,

Očekivani znanstveni doprinos očituje se u razvoju i provjeri modela mjerenja vizualne aktivnosti u dinamičnim slikama. Korištenjem „gustoće informacija“ definirane Modelom ograničenog kapaciteta obrade motiviranih posredovanih poruka (LC4MP) autorice A. Lang kao kriterija za izbor algoritma za uklanjanje pozadine, u predloženoj metodi mjerenja vizualne aktivnosti (BGSVAI, eng. *Background Subtraction Visual Activity Index*) uvodi se i potencijalna mogućnost daljeg razvoja i automatizacije LC4MP modela (eng. *Limited Capacity Model of Motivated Mediated Message Processing*).

Predložena metoda mjerenja vizualne aktivnosti u dinamičnim slikama kao alternativa postojećoj metodi koja koristi Indeks vizualne aktivnosti, omogućit će znanstvenicima na

području humanističkih i društvenih znanosti da kvantificiraju vizualnu aktivnost koju su do sada u radovima u pravilu opisivali kvalitativno.

Kako bi se postigli ciljevi istraživanja, postavljene su sljedeće hipoteze:

H1 - Vizualna aktivnost u dinamičnim slikama mjerljiva je uporabom algoritama za uklanjanje pozadine: očekuje se statistički značajna povezanost vizualne aktivnosti mjerene algoritmima za uklanjanje pozadine i postojećeg Indeksa vizualne aktivnosti

H2 – Metoda mjerenja vizualne aktivnosti odabranim algoritmom za uklanjanje pozadine, kod uvođenja različitih razina šuma u video sadržaje, robusnija je u odnosu na postojeću metodu koja koristi Indeks vizualne aktivnosti: očekuje se postojanje statistički značajne razlike rezultata mjerenja vizualne aktivnosti temeljenog na algoritmima za uklanjanje pozadine i Indeksa vizualne aktivnosti, kod uvođenja različitih razina šuma u video sadržaje

H3 - Mjerenje vizualne aktivnosti odabranim algoritmom za uklanjanje pozadine ukazuje na trend rasta vizualne aktivnost u dinamičnim slikama u zadnjih nekoliko desetljeća

2. VIZUALNA AKTIVNOST U MEDIJIMA

U ovom poglavlju definira se pojam vizualne aktivnosti u medijima. S obzirom na moguća različita tumačenja, u nastavku je prije svega definirano u kojim medijima se pojavljuje vizualna aktivnost, kao i specifičnosti tih medija. Nadalje sam pojam vizualna aktivnost može se sagledati sa aspekta subjekta ili objekta, te je tu naglašena razlika poimanja. U nastavku su navedene metode mjerenja vizualne aktivnosti. S obzirom da ih ima nekoliko i razlikuju se u pristupima, navedene su sve, a posebno je obrađen Indeks vizualne aktivnosti. Na kraju je obrađen utjecaj vizualne aktivnosti sadržaja na gledatelje, a podijeljen je na analizu utjecaja promjene kadra i analizu različitih vrijednosti Indeksa vizualne aktivnosti sadržaja.

2.1. Vizualni mediji

Riječ medij dolazi od latinske riječi *medius*, što označava nešto što je između ili srednji, odnosno posrednika u komunikaciji. U širem značenju medij može biti i osoba, ali češće se radi o fizičkom nositelju komunikacije što može biti radio val, papir ili gramofonska ploča (Peruško, 2011). U engleskom jeziku riječ *medium* označava između ostalog „određeni oblik ili sustav za komunikacije (kao što su novine, radio i televizija)“ (Webster, 2016).

Definiciju medija za početak nalazimo u službenom glasilu Republike Hrvatske, Narodnim novinama, gdje piše da su mediji „novine i drugi tisak, radijski i televizijski programi, programi novinskih agencija, elektroničke publikacije, teletekst i ostali oblici dnevnog ili periodičnog objavljivanja uredнички oblikovanih programskih sadržaja prijenosom zapisa, glasa, zvuka ili slike“. U nastavku je definirano i što ne pripada medijima, pa tako piše: „Mediji nisu knjige, udžbenici, bilteni, katalozi ili drugi nositelji objavljivanja informacija koji su namijenjeni isključivo obrazovnom, znanstvenom i kulturnom procesu, oglašavanju, poslovnoj komunikaciji, unutarnjem radu trgovačkih društava, zavoda i ustanova, udruga, političkih stranaka, vjerskih i ostalih organizacija, školska glasila, »Narodne novine« Republike Hrvatske, službena glasila jedinica lokalne i područne (regionalne) samouprave i ostala službena priopćenja, plakati, letci, prospekti i transparenti, te video stranice bez žive slike i druge besplatne obavijesti, osim ako ovim Zakonom nije drukčije propisano“ (Zakon o medijima, 2003).

Pojam medija nalazi se i u radu koji spada u temelje informacijskih i komunikacijskih znanosti – Matematičkoj teoriji komunikacije, gdje se navodi da je „kanal medij za prijenos signala od odašiljača do prijemnika. Medij može biti parica, koaksijalni kabel, radijske frekvencije, snop svjetlosti, itd“ (Shannon, 1948).

Fiske za medij navodi da je to tehničko ili fizičko sredstvo pretvorbe poruke u signal koji se može prenijeti duž komunikacijskog kanala. Autor predlaže podjelu medija u tri osnovne kategorije:

a) Prezentacijski medij – glas, lice i tijelo. Radi se o izgovorenoj riječi i gesti, pokretima tijela, što nužno traži prisutnost komunikatora u trenutku komunikacije.
b) Reprezentacijski medij – knjige, slike, fotografije, rukopisi, arhitektura, dekoracija interijera. Mogu postojati neovisno o komunikatoru i produciraju aktivnosti komunikatora.
c) Mehanički medij – telefon, radio, televizija. Oni služe za prijenos prethodno nabrojene dvije kategorije medija. Za razliku od reprezentacijskih medija, mehanički koriste kanale, te su podložni većim tehnološkim ograničenjima (Fiske, 1990)

Medije možemo podijeliti i po drugim kriterijima, a Black i Bryant ih dijele u sljedeće tri kategorije: masovni, osobni i telekomunikacijski. U masovne spadaju novine, knjige, radio, televizija i film. U osobne medije autori svrstavaju uređaje za reprodukciju audio vizualnog

sadržaja (CD, DVD, gramofonska ploča, video kazeta, računalo), ali i za snimanje istog (kamera). Ključna razlika je u tome što korisnik ima kontrolu nad reprodukcijom i snimanjem sadržaja te njime upravlja. U telekomunikacijske spadaju telefoni, umrežena računala i svi drugi uređaji koji omogućuju komunikaciju (Black & Bryant, 1992, po Malović et al 2014).

Peruško na drugi način gleda na medije, pa ih prema vrsti dijeli na knjige, tisak, film, televiziju, radio, te nosače slike i zvuka, pri čemu autorica smatra da navedene vrste spadaju u masovne medije. Nadalje kategorije podjele po autorici su još prema geografskoj razini, obliku vlasništva, te prema bliskosti matici javnog i političkog mišljenja (Peruško, 2011).

Autori koji proučavaju multimedij razvili su donekle drugačiju kategorizaciju medija, pa tako Sutcliffe nudi klasifikaciju prikazanu na slici broj 1 (Sutcliffe, 2008).

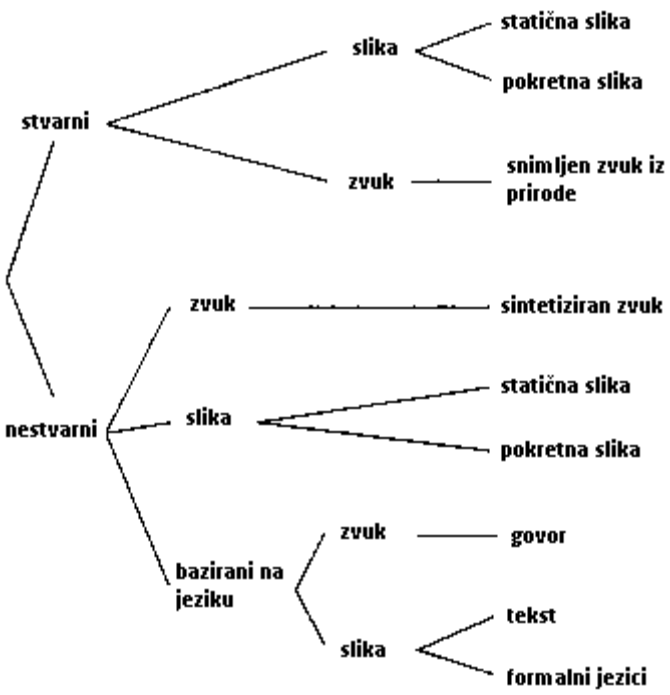

Slika 1 – Hijerarhijska struktura za klasifikaciju medija (Sutcliffe, 2008)

Slika 1 prikazuje hijerarhijsku strukturu klasifikacije medija. Autor dijeli medije na stvarne, odnosno realne koje dobivamo snimanjem stvarnog svijeta. Primjeri za to su fotografija krajolika ili zvučni snimak pjeva ptice. Osim stvarnih u drugu kategoriju spadaju oni koji su nastali aktivnošću čovjeka (nestvarni), a kao granični slučaj u toj kategoriji mogla bi se navesti prilično realistična slika krajolika nacrtana u tehnici akvarel. Na sljedećoj razini klasifikacije susrećemo podjelu na zvuk, sliku i medije bazirane na jeziku, s tim da se posljednja navedena kategorija pojavljuje samo u tzv. nestvarnim medijima. Dublje u strukturi klasifikacije

nailazimo na podjelu medija na statične i pokretne, pri čemu autor navodi da je granična brzina izmjene slika iznad koje se niz slika naziva pokretnim slikama – 10 slika u sekundi. S druge strane za niz statičnih slika navodi se primjer PowerPoint prezentacije sa 5 slika u 60 sekundi.

Po navedenoj klasifikaciji vizualni mediji se pojavljuju u šest kategorija i to:

a) stvarna statična slika - fotografija
b) stvarna pokretna slika – video snimak
c) nestvarna statična slika - crtež
d) nestvarna pokretna slika – animirani film
e) nestvarna slika teksta - tekst
f) nestvarna slika formalnog jezika – matematički izraz

S obzirom da je tema rada vizualna aktivnost koja se pojavljuje samo kod stvarnih i nestvarnih pokretnih slika, ostale kategorije biti će zanemarene. Prije dalje analize vizualnih medija treba spomenuti i Bernsena koji znatno dublje ulazi u načine interakcije računala i čovjeka te koristi nekoliko ključnih svojstava koja služe za jasnu distinkciju različitih modela interakcije. Na prvi pogled zbog područja kojim se autor bavi izgleda kao da se odmičemo od pojma medija, ali autor među svojstvima navodi tri vrste medija i to vizualne, zvučne i taktilne, samo što ih klasificira po četiri druga svojstva. Ta svojstva su sljedeća (Bernsen, 1994):

a) lingvističke / ne-lingvističke
b) analogne / ne-analogne
c) proizvoljne / ne-proizvoljne
d) statične / dinamične

Ukupan teorijski broj kombinacija navedenih svojstava je 48, ali autor navodi da iz različitih razloga neke kombinacije nisu moguće te da je za dalju analizu ostalo 28 kombinacija. Autor dalje analizira preostale kombinacije, a u nastavku je tablica u kojoj su dani modaliteti vizualnih medija. Zvučni i taktilni nisu prikazani.

	LI	-LI	AN	-AN	AR	-AR	STA	DYN	GRA	SOU	TOU	MODALITET
1	X		X			X	X		X			**Statički analogni grafički jezik**
2	X		X			X		X	X			**Dinamički analogni grafički jezik**
5	X			X		X	X		X			**Statički ne-analogni grafički jezik**
6	X			X		X		X	X			**Dinamički ne-analogni grafički jezik**
9		X	X			X	X		X			**Statičke slike dijagrama**
10		X	X			X	X		X			**Statički slike stvarnog svijeta**
11		X	X			X	X		X			**Statički grafovi**
12		X	X			X		X	X			**Animirani dijagrami**
13		X	X			X		X	X			**Dinamičke slike stvarnog svijeta**
14		X	X			X		X	X			**Dinamički grafovi**
21		X		X	X		X		X			**Statički proizvoljni dijagrami**
22		X		X	X			X	X			**Animirani proizvoljni dijagrami**
25		X		X		X	X		X			**Statičke grafičke strukture**
26		X		X		X		X	X			**Dinamičke grafičke strukture**

Tablica 1- Modaliteti vizualnih medija (Bernsen, 1994)

U prvom redu su navedene kratice koje je koristio i autor, a značenje im je LI – lingvistički, AN – analogni, AR – arbitrarni, STA – statični, DYN – dinamični, GRA – grafički, SOU – zvučni i TOU – taktilni. U slučaju negativnog predznaka ispred kratice radi se o negaciji svojstva. S obzirom da se rad bavi dinamičkim vizualnim medijima u nastavku su izlučeni modaliteti kategorizirani po prethodno navedenim svojstvima, ali isključivo dinamički i vizualni. Rezultat se vidi u tablici broj 2.

	LI	-LI	AN	-AN	AR	-AR	STA	DYN	GRA	SOU	TOU	MODALITET
2	X		X			X		X	X			**Dinamički analogni grafički jezik**
6	X			X		X		X	X			**Dinamički ne-analogni grafički jezik**
12		X	X			X		X	X			**Animirani dijagrami**
13		X	X			X		X	X			**Dinamičke slike stvarnog svijeta**
14		X	X			X		X	X			**Dinamički grafovi**
22		X		X	X			X	X			**Animirani proizvoljni dijagrami**
26		X		X		X		X	X			**Dinamičke grafičke strukture**

Tablica 2– Modaliteti dinamičnih vizualnih medija (Bernsen, 1994)

Autor daje i primjere za navedene izlučene modalitete, a u nastavku je prilagođena tablica autora s primjerima.

MODALITET	PRIMJER
Dinamički analogni grafički jezik	**Gestikulacijski jezik**
Dinamički ne-analogni grafički jezik	**Dinamičan prikaz slova, brojeva i drugih grafičkih znakova**
Animirani dijagrami	**Animirani dijagrami**
Dinamičke slike stvarnog svijeta	**Filmovi i video isječci**
Dinamički grafovi	**Grafovi koji evoluiraju u grafičkom prostoru**
Animirani proizvoljni dijagrami	**Dijagrami koji se sastoje od geometrijskih elemenata**
Dinamičke grafičke strukture	**Dinamički okviri, odnosno prozori**

Tablica 3– Primjeri dinamičkih vizualnih modaliteta (Bernsen, 1994)

Od navedenih podjela Bernsen je dao prilično detaljnu analizu modaliteta interakcije između čovjeka i računala, mada nam za dalju analizu nije potrebno raščlanjivanje na tako niskom nivou. S obzirom da predmet istraživanja nije interakcija, nego analiza dinamičkih vizualnih medija, bitno je biti svjestan opisanih modaliteta, ali im pristupiti na isti način bez obzira radilo se o video isječcima ili animiranim dijagramima.

2.2. Pojam vizualne aktivnosti

Izraz „vizualna aktivnost“ ima višestruko značenje. Ključna podjela u područjima u kojima se ovaj pojam koristi je na vizualnu aktivnost subjekta i vizualna aktivnost objekta. U nastavku je razjašnjena razlika među njima.

Vizualnom aktivnošću subjekta bave se prije svega posebne grane medicine pri čemu se vizualnom aktivnošću općenito smatra aktivnost mišića oka, te postoje razne metode mjerenja te aktivnosti. Jones-Jordan i suradnici upotrebljavaju pojam vizualne aktivnosti u smislu aktivnosti mišića oka, ali je kategoriziraju s obzirom na okruženje u kojem se odvija. U svom radu proučavaju utjecaj vremena provedenog u aktivnostima koje se odvijaju unutar i izvan zatvorenog prostora na kratkovidnost kod djece, a podatke dobivaju anketiranjem roditelja (Jones-Jordan, 2011). Navedeno značenje pojma koristi i neuropsiholog J. F. Fulton prije gotovo stotinu godina, pri čemu vizualnom aktivnošću smatra čitanje novina u istraživanju utjecaja mentalnog opterećenja na protok krvi kroz mozak (Fulton, 1928).

Isti pojam Land i Lee koriste također za aktivnost mišića oka, ali je mjere neposrednije. Za potrebe istraživanja vizualne aktivnosti kod vozača izradili su poseban uređaj koji snima oči vozača i vidokrug ispred vozila (Land & Lee, 1994), a Kaminski i suradnici predlažu korištenje takvih uređaja za analizu prometnica i otkrivanje dionica cesta koje su posebno opasne (Kaminski, 2012). Kaminski navodi tri osnovne kategorije uređaja koji se koriste za mjerenje vizualne aktivnosti i to:

a) indukcijsko praćenje oka
b) optičko praćenje oka bez kontakta
c) električno praćenje oka (Kaminski, 2012).

J. Findlay detaljno analizira problematiku praćenja vizualne aktivnosti zbog mogućnosti korištenja različitih mišića pri promjeni točke u koju gledamo. Pri tome navodi i slučaj potpuno funkcionalne osobe koja je rođena bez funkcionalnih očnih mišića, te za promjenu u koje gleda koristi vratne mišiće (Findlay, 1998). Grobelny sa suradnicima snima vizualnu aktivnost korisnika za istraživanje obrazaca praćenja vizualnih sadržaja na web stranicama (Grobelny et al, 2015).

Prethodno navedeni i kratko opisani radovi ukazuju na poimanje vizualne aktivnosti kod subjekta, odnosno osobe koja prima vizualni podražaj. U nastavku disertacije se pojam vizualne aktivnosti neće koristit u kontekstu subjekta, odnosno osobe koja prima vizualni podražaj.

Drugo navedeno značenje vizualne aktivnosti je vizualna aktivnost objekta, pri čemu se misli na kretanje objekta s obzirom na subjekt, odnosno promatrača. U nastavku rada će se koristiti ovo drugo značenje pojma „vizualna aktivnost“ i to isključivo vezano uz dinamičke vizualne medije.

Vizualnu aktivnost susrećemo samo kod jednog dijela vizualnih medija. Kategorizaciju i jasan kriterij na osnovu kojeg možemo utvrditi postojanje vizualne aktivnosti daje Sutcliffe koji dijeli medije na statične i pokretne, pri čemu navodi da je granična brzina izmjene slika iznad koje se niz slika naziva pokretnim slikama – 10 slika u sekundi. Za niz statičnih slika navodi se primjer računalne prezentacije sa 5 slika u 60 sekundi. Prethodno je opisana kategorizacija spomenutog autora, koji je vizualne medije podijelio u šest kategorija, dok se vizualna aktivnost susreće u samo dvije i to:

a) stvarna pokretna slika – video snimak
b) nestvarna pokretna slika – animirani film (Sutcliffe, 2008)

Pojam vizualne aktivnosti u filmu definira J. J. Gibson kao ukupnost kretanja objekata i ljudi uz stalnu pozadinu i vizualne informacije dobivene kretanjem opažača. U engleskom jeziku kretanje objekata i ljudi uz stalnu pozadinu naziva se *motion*, a u filmu se radi o kadru s nepomičnom kamerom u kojem dolazi do kretanja objekata i ljudi. Kretanje opažača u engleskom jeziku naziva se *movement*, a u filmu se dobiva pomicanjem kamere ili leće na kameri. U hrvatskom jeziku se radi o kretanju i pomicanju (Gibson, 1954). U nastavku će se koristiti navedena definicija pojma vizualne aktivnosti.

Teoretičari filma su od samih početaka bili svjesni da pokretne slike, odnosno vizualna aktivnost objekta utječe na vizualnu aktivnost subjekta. Da bi se taj utjecaj mogao analizirati trebalo je pričekati da se razvije tehnologija kojom bi se navedeno moglo pratiti. Krajem prošlog stoljeća tehnologija je došla do faze kada je analiza pokreta oka gledatelja bila jednostavno izvediva, te su Stelamch i suradnici analizirali vizualnu aktivnost gledatelja, odnosno lokaciju koja im je bila u fokusu dok su gledali različite video isječke. Područje njihovog interesa bila je optimizacija prijenosa video sadržaja na način da se područja video isječka koja nisu u fokusu gledatelja kodiraju i prikazuju u nižoj kvaliteti što bi rezultiralo manjom količinom prenesenih podataka. Autori su otkrili da i u najgorem slučaju više od 40% od 24 gledatelja fokusiraju isto područje, a kako količina pokreta i promjene u video isječku raste, taj postotak se također povećava. Na kraju se autori slažu da je moguće razviti kodiranje bazirano na području fokusiranja gledatelja (Stelmach et al, 1991).

Godlstein i suradnici su također proučavali vizualnu aktivnost gledatelja i fokusiranost na zajedničke točke tokom projekcije video sadržaja. Mjerenjem su utvrdili da su polovicu vremena od 37,5 minuta 20 gledatelja fokusirali područje veličine 12% ekrana, a zanimljivo je da podatci ukazuju da je veća vjerojatnost da muškarci i starije osobe fokusiraju zajedničko područje, nego žene i mlađe osobe (Goldstein et al, 2007)

2.3. Mjerenje vizualne aktivnosti

Ako za polazište uzmemo definiciju vizualne aktivnosti koju predlaže Gibson, možemo zaključiti da uočavamo razlike u vizualnoj aktivnosti različitih vrsta pokretnih slika. U pravilu je vizualna aktivnost akcijskih filmova veća od vizualne aktivnosti dokumentarnih filmova. Isto tako se može generalizirati i pretpostaviti da su animirani filmovi američke produkcije vizualno aktivniji od animiranih filmova češke produkcije iz perioda sedamdesetih godina prošlog stoljeća. Dovoljno je pogledati nekoliko animiranih filmova iz serije „*Tom and Jerry*“ Williama Hanna i Josepha Barbera, odnosno „*Krtek*“ Zdeněka Milera. Ipak, kada bi htjeli tu vizualnu aktivnost kvantificirati, velika većina gledatelja vjerojatno ne bi znala kako to izraziti brojem.

U nastavku su četiri pristupa koji se mogu naći u literaturi, a služe za kvantificiranje vizualne aktivnosti pokretnih slika, bilo da se radi o realnim pokretnim slikama (filmovima, televizijskim emisijama) ili nerealnim pokretnim slikama (animiranim filmovima).

2.3.1. Mjerenje dužine kadrova

Najpoznatija metoda kvantificiranja pokretnih slika je mjerenje, odnosno izračunavanje prosječne dužine kadra, koja se na engleskom jeziku naziva *Average Shot Length (ASL).*

Turković definira kadar i kaže da je „jedinica film. izlaganja, dio filma u kojemu se bez ikakvih promatračkih prekida prati prizorno zbivanje.“ Nadalje isti autor definira od čega se može sastojati kadar, te pri tom navodi da „ se može sastojati i od jedne sličice (kadar-sličica), ali se obično sastoji od više njih, povezanih tako da tipično izazivaju dojam prividnoga kretanja.“ (Turković, 2008).

Najjednostavnija metoda za izračunavanje prosječne dužine kadra je brojanje izmjena kadrova, te dijeljenje vremena trajanja filma sa brojem kadrova u filmu. Navedenu mjeru prvi put spominje Salt u radu iz 1974. godine, u kojem na osnovu mjerenja zaključuje da filmovi pojedinih autora najčešće imaju vrlo slične prosječne dužine kadra. Autor je analizirao pedesetak filmova, te je osim navedene mjere proučavao i distribucije frekvencija dužine kadra

za koje zaključuje da su najbliže Poissonovoj distribuciji (Salt, 1974). Analiza literature vezane uz prosječnu dužinu kadra jasno ukazuje da je ta mjera najčešće u fokusu jedne uske grane znanosti koja se naziva *Cinemetrics*, odnosno na hrvatskom jeziku bi to bila „kinometrika“, mada autor ove disertacije nije uspio naći navedeni pojam u radovima na hrvatskom jeziku. Baxter za pojam „kinometrike“ kaže da je to „statistička analiza kvantitativnih podataka, opisa struktura i sadržaja filmova koje bi mogli promatrati kao aspekte stila“ (Baxter, 2014). Brunick i suradnici su kasnije predložili da se navedena mjera preimenuje u *Average Shot Duration (ASD)* budući da se naziv *Shot Length* koristi i za mjeru fokalne dužine kod kamera (Brunick et al, 2013).

Prosječna dužina kadra može se uspoređivati u filmovima jednog autora, pri čemu se u pravilu nalaze sličnosti, a može se sagledati i razlika u prosječnim dužinama kadra kroz filmsku povijest. Analize povijesti filma ukazuju na postojanje praktički dva perioda u kojima se uočavaju pravilnosti:

a) period nijemog filma
b) period zvučnog filma

U periodu nijemog filma prosječna dužina kadra bila je vrlo kratka iz jednostavnog razloga što nije bilo zvuka u filmu što se kompenziralo kadrovima sa tekstom. Dolaskom zvuka u film, prosječna dužina kadra se naglo značajno povećala da bi nakon toga kontinuirano padala. Na slici broj 2 vidi se grafikon autora Cutting i suradnika u kojem su oni linearno interpolirali rezultate prosječne dužine kadra za 150 filmova produciranih između 1935 i 2010. godine. Smanjenje prosječne dužine kadra je očigledno (Cutting et al, 2011).

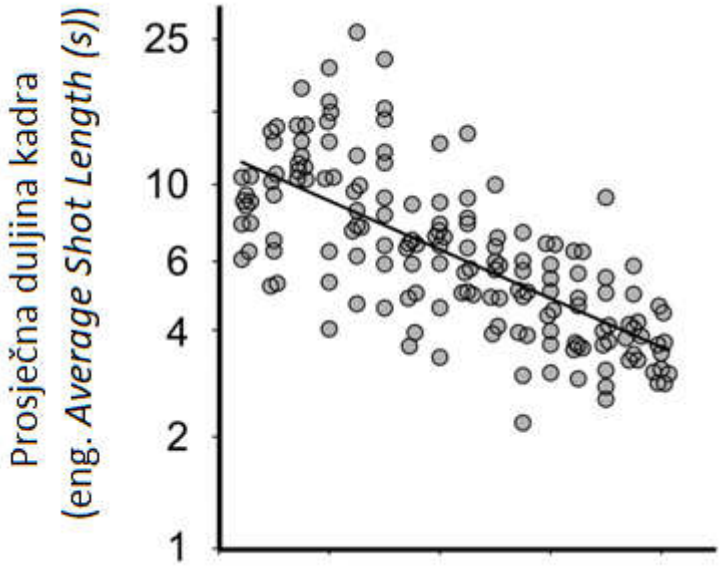

Slika 2– ASL za 150 filmova između 1935 i 2010 – (Cutting et al, 2011)

Na slici 3 isti autor sa suradnicima u drugom radu prikazuje prosječne vrijednosti dužine kadrova za oko 9400 filmova na engleskom jeziku, pri čemu se također vidi opisani trend (Cutting et al, 2015a).

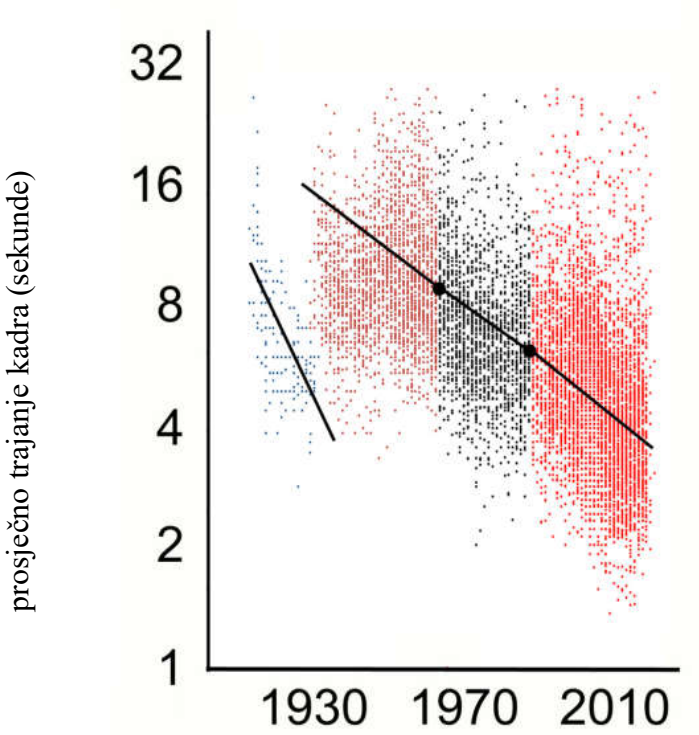

Slika 3– ASL vrijednosti za 9400 filmova na engleskom jeziku (Cutting et al, 2015a)

U istom radu autor analizira prosječne vrijednosti dužine kadrova za oko 1500 filmova na drugim jezicima osim engleskom, pri čemu je trend pada dužine kadra manje izražen. Na slici 4 je prikazana linearna aproksimacija prosječnog trajanja kadra (Cutting et al, 2015a).

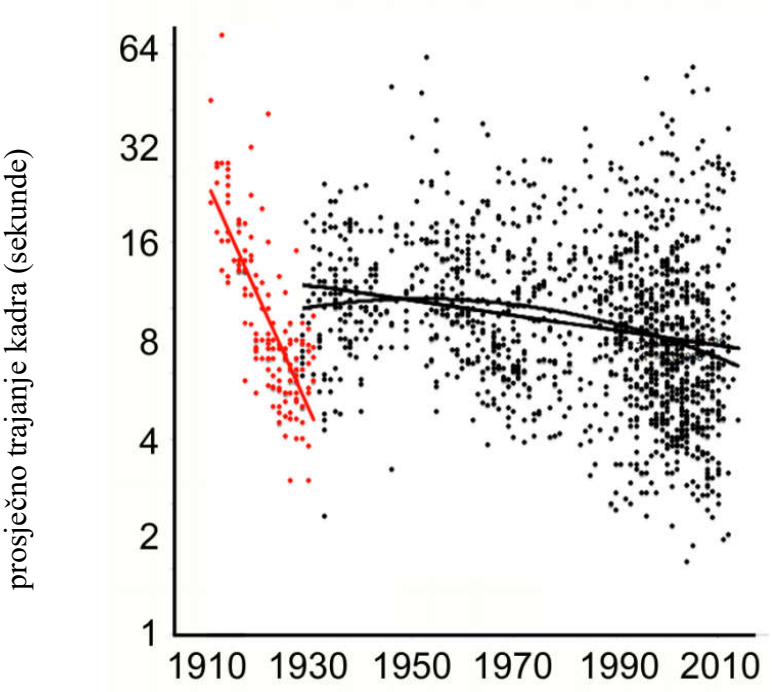

Slika 4– ASL vrijednosti za 1500 filmova koji nisu na engleskom jeziku (Cutting et al, 2015a)

Tsivian ukazuje da se podatak o prosječnoj dužini kadra treba ipak uzeti sa rezervom, odnosno naglašava da to nije jedini faktor koji utječe na dinamiku filma. Za primjer navodi film *Dragnet girl* režisera Yasujiro Ozu iz 1933. godine, te film *Rashomon* režisera Akira Kurosawe iz 1950. godine. Prvi ima prosječnu dužinu kadra 4 sekunde, dok je za drugi ta vrijednost 13 sekundi što navodi na zaključak da je prvi film znatno dinamičniji. Poznavatelji se s pravom neće složiti s tim zaključkom, a razlog je što Kurosawa izmjenjuje duže i kraće kadrove što se ne vidi iz prosječne dužina kadra (Tsivian, 2009).

DeLong i suradnici ukazuju na još jedan nedostatak mjerenja prosječne dužine kadra, a on je uzrokovan činjenicom da distribucija dužina trajanja kadrova u filmovima ne prati krivulju normalne distribucije, nego se prije radi o log-normalnoj distribuciji. Razlog tome je što je većina kadrova kratko, a nekoliko dugačkih utječu na povećanje srednje vrijednosti. Autori zaključuju da je bolja mjera medijan, što je očigledno i iz analize distribucije dužine kadrova prikazane na slici broj 5. Radi se o distribuciji frekvencija dužina kadrova za film *A Night at the Opera* (DeLong et al, 2013).

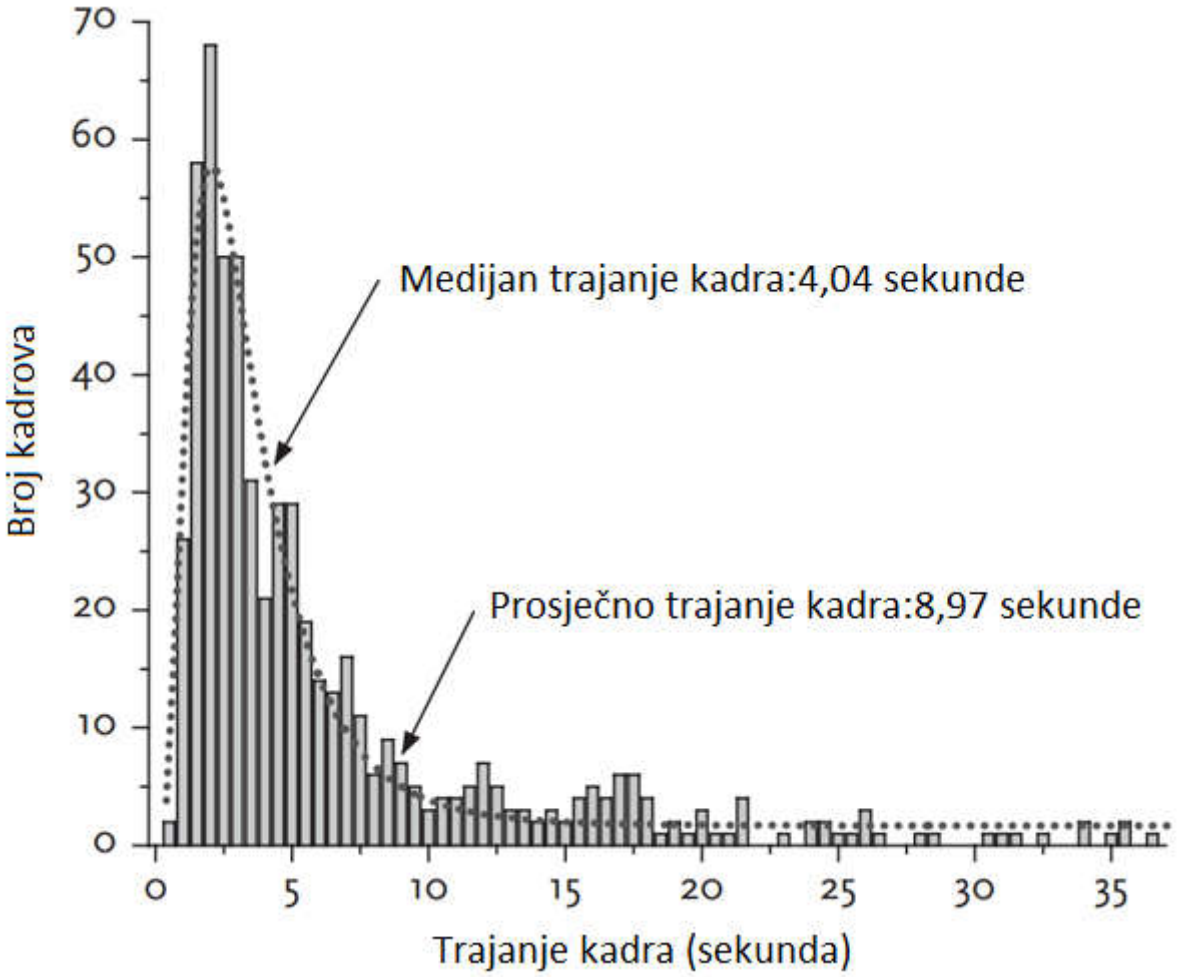

Slika 5– Distribucije frekvencija dužina kadrova za film A Night at the Opera (DeLong et al, 2013)

Medijan kao mjeru kod dužine kadrova koriste Schaefer i suradnici, ali u svom radu analiziraju dužine kadrova u večernjim polusatnim televizijskim vijestima koje su emitirale tri glavne komercijalne medijske tvrtke *American Broadcasting Company* (ABC), *Columbia Broadcast System* (CBS) i *National Broadcasting Company* (NBC). Analiza je napravljena za period između 1969. i 2005. godine, a uzorak osim navedenih godina uključuje i polusatne televizijske emisije s vijestima iz 1983. i 1997. godine. Statistički značajan pad dužine kadra se uočava između 1969. godine i 1983. godine, kao i između 1997. godine i 2005. godine (Schaefer, 2009).

Vezano uz pretpostavku da su dužine kadrova distribuirane po log-normalnoj distribuciji, u znanstvenoj zajednici došlo je do suprotstavljanja stavova i argumenata u prilog i protiv navedene pretpostavke. Redfern tu pretpostavku opovrgava u svom radu, da bi Baxter ukazao na neke nedostatke u metodologiji koju koristi Redfern. U svakom slučaju još ne postoji konsenzus vezan uz stav o distribuciji dužine kadrova (Redfern, 2012)(Baxter, 2013).

Većina radova koji obrađuju prosječnu dužinu kadra u filmovima napisani su u posljednjih desetak godina, a jedan od razloga je taj što je na web adresi www.cinemetrics.lv, unazad nekoliko godina dostupna baza sa vrijednostima prosječne dužine kadrova za nekoliko desetaka tisuća filmova. Baza se stalno nadopunjuje, te broj obrađenih filmova kontinuirano raste. Na izradi baze pridonijeli su istraživači i entuzijasti iz cijelog svijeta, te su rezultati javno dostupni svima. Baza je nastala na inicijativu već spomenutog Yuria Tsiviana, koji je na web stranici postavio i program pod nazivom *CineMetrics* kojim se vrlo jednostavno može mjeriti dužina kadrova filma. Bez spomenutog programa je samo mjerenje dužina kadrova bilo znatno sporije, a istraživači su bez javno dostupne baze bili prisiljeni sami obrađivati filmove koje su analizirali.

2.3.2. Vizualni otisak prsta

Mjeru koju autor opisuje kao vizualni otisak prsta, a kategorizira kao metodu koja pripada već spomenutoj „kinometriji“, predložio je Brodbeck. Metoda uključuje ekstrakciju i analizu strukture filma, boje, govorne komunikacije i pokreta i transformira te informaciju u kružni oblik grafičke reprezentacije. U tom novom obliku se filmovi vrlo jednostavno mogu interpretirati i uspoređivati. Oblik koji predstavlja film je dinamička struktura, te dinamika pojedinih dijelova daje vizualnu informaciju o količini pokreta u pojedinim dijelovima filma. Autor daje i kompletan kod u programskom jeziku *Python* koji služi za izradu već spomenutih dinamičkih struktura. U nastavku je primjer dinamičke strukture, ali naravno na slici nije vidljiva dinamika koja se može vidjeti na web stranici na kojoj je autor predstavio metodu (Brodbeck, 2011).

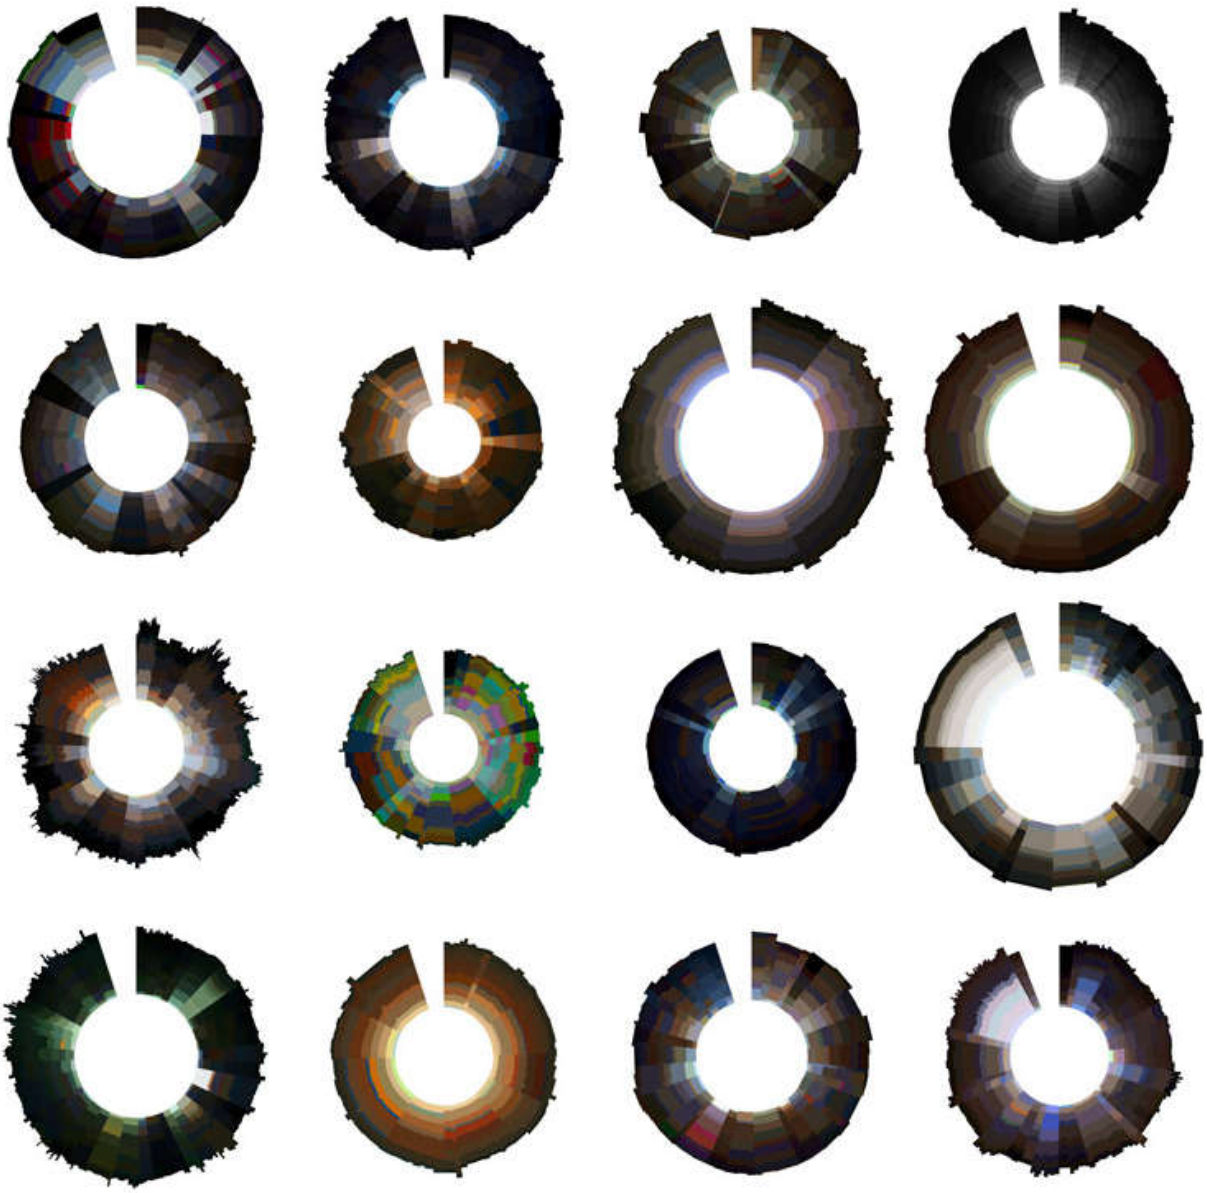

Slika 6- Vizualni „otisci prsta“ za 16 filmova (Brodbeck, 2011).

U literaturi se opisana metoda spominje u nekoliko radova. Lim i suradnici je spominju i opisuju kao estetski ugodnu, ali da ne govori puno o strukturi filma. Isto tako spominju kao nedostatak metode i činjenicu da za svaki okvir uzima prosječnu boju (Lim et al, 2016). Metodu spominju Burghardt i Wolff, pri čemu spominju prikaz boja u filmovima (Burghardt et al, 2016). Grijalva također spominje opisanu metodu, te naglašava da ju je koristio kao osnovu za razvoj svoje metode koja dublje ulazi u analizu govora u filmu (Grijalva, 2014). Autor metode nije ju opisivao u formi stručnog ili znanstvenog članka, ali interesantno je da je sličan način vizualizacije opisao u drugom članku kao suradnik, mada se vizualizacija koristila za prikaz prijetnji informacijskoj sigurnosti (Li et al, 2016).

2.3.3. Filmski oblaci

M. Grijalva u svom radu također mjeri vizualnu aktivnost u filmovima, te je zajedno sa bojama i frekvencijom korištenih riječi u filmu prikazuje u obliku takozvanih filmskih oblaka. Autor je analizirao 5 filmova, te generirao po jedan filmski oblak za svako poglavlje pojedinog filmskog naslova. S obzirom da je filmski oblak dinamičan objekt u kojem se vide najčešće korištene riječi u poglavlju DVD medija, rezultat njegova rada se može vidjeti samo na dinamičnoj web stranici http://mgrijalva.github.io/filmclouds/.

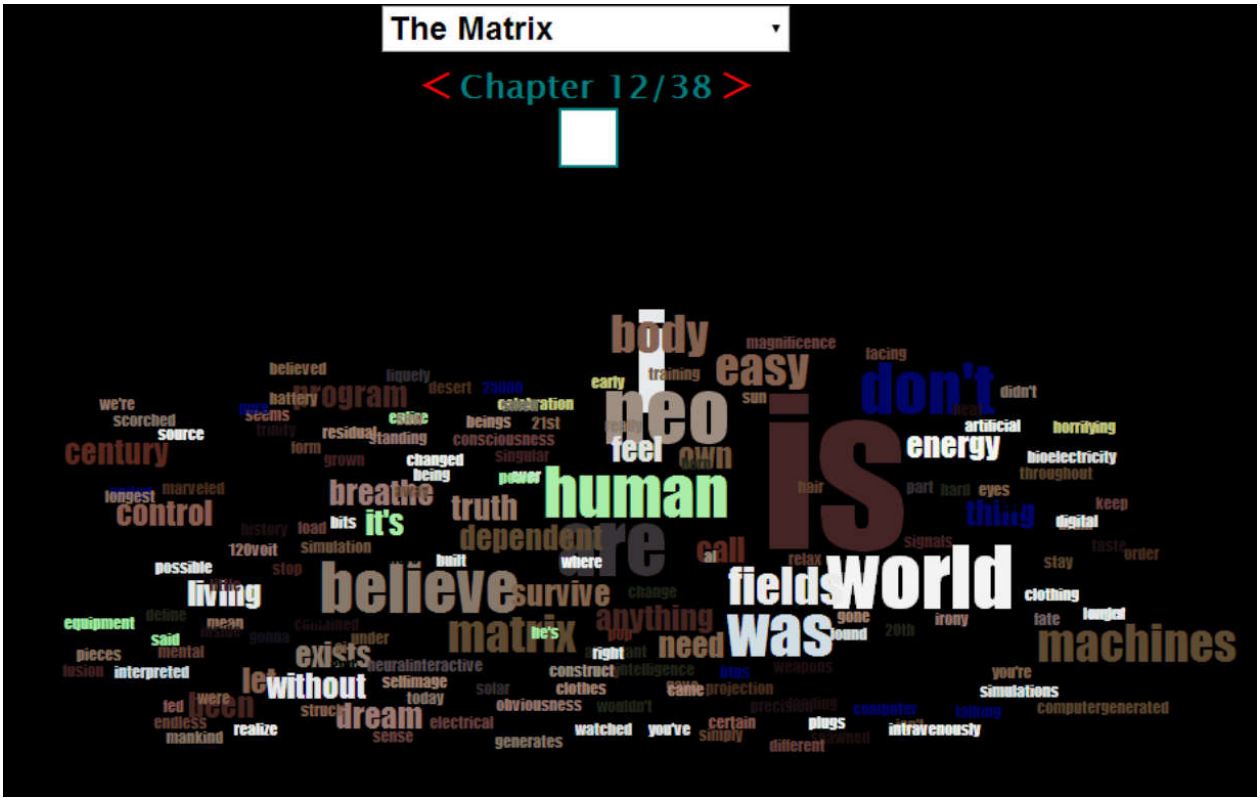

Slika 7– Filmski oblak (Grijalva 2014)

Iz samog filmskog oblaka nije vidljivo kolika je količina vizualne aktivnosti u pojedinom poglavlju na analiziranim DVD medijima, odnosno filmovima, u obliku brojčane vrijednosti, ali s obzirom da je autor priložio i kod programa napisanih u programskom jeziku *Python*, te opisao metodu u radu, dio koda koji je autor koristio za mjerenje pokreta u filmu može se izlučiti i analizirati (Grijalva 2014).

2.3.4. Indeks vizualne aktivnosti

„Indeks vizualne aktivnosti“ u literaturi susrećemo kod više autora, a koristi se za mjerenje različitih pojava. U nastavku su dani opisi tri različite mjere pod istim nazivom.

Indeks vizualne aktivnosti prvi put je u svom radu spomenuo C.J. Bruce koji je sa suradnicima tu mjeru definirao kao omjer aktivnosti u vizualnom zadatku i aktivnosti u vizualno vođenom zadatku. Rad je iz područja psihologije, a sam definicija Indeksa vizualne aktivnosti ne odgovara području kojim se bavi disertacija (Bruce, 1985).

Indeks vizualne aktivnosti spominje u svom radu Bertolo. On je sa suradnicima tu mjeru koristio u istraživanjima vezanim uz vizualizaciju, a radilo se o postotku izgovorenih riječi vezanih uz vizualno u odnosu na ukupan broj izgovorenih riječi nakon sna. Autor je tim pojmom nadogradio poznatu metodu, Hall – Van de Castle, za analizu sadržaja sna. Navedeno značenje „Indeksa vizualne aktivnosti“ spominje se s ciljem ukazivanja na postojanje pojma u znanstvenoj literaturi koji ima potpuno isti naziv, ali drugo značenje (Bertolo, 2003)

Indeks vizualne aktivnosti (*Visual Activity Index*, VAI) uvodi J.E. Cutting sa suradnicima 2011. godine, a s ciljem da izmjere količinu pokreta u filmu. Autori za tu mjeru navode da ona „mjeri količinu kretanja objekata u kadru, kao i same kamere, u cijelom filmu“. Rezultat koji se dobiva mjerenjem je broj između 0 i 2, s tim da manja vrijednost označava manje kretanja u filmu.

Način mjerenja Indeksa vizualne aktivnosti koji je odedio Cutting svodi se na smanjenje svake pojedinačne slike u filmu na veličinu od 256 točaka (eng. *pixel*) visine i 256 točaka širine. Osim toga svaka slika se pretvara u slikovnu datoteku u formatu JPG, te se uklanjaju boje i svaka točka poprima vrijednost nijanse sive boje između 0 i 255. Rezultat prethodno opisane pripreme je oko 165000 pojedinačnih parova slika po filmu, a zbog hibridnih slika pri NTSC kodiranju u sljedećem koraku uspoređuju se slike odvojene jednom slikom između, odnosno 1 i 3, 2 i 4 i tako dalje do zadnje slike. Autori su računali Pearsonov koeficijent korelacije za uspoređivanje slika, pri čemu korelacija poprima vrijednost 1 u slučaju da su dvije slike identične. U slučaju veće vizualne aktivnosti, slike će biti manje slične i korelacija će biti manja. Konačna vrijednost Indeksa vizualne aktivnosti dobiva se oduzimanjem vrijednosti korelacije od broja 1, što daje teorijski opseg za Indeks vizualne aktivnosti između 0 i 2 (Cutting, 2011)

Zbog velike sličnosti između pojedinačnih slika dobivenih na opisani način, autori su u radu dobivali vrijednosti vrlo bliske nuli, a medijan Indeksa vizualne aktivnosti za 25 milijuna uspoređenih slika koliko su obavili u sklopu svog rada iznosio je 0,034. Autorima je važna i distribucija vrijednosti Indeksa vizualne aktivnosti, pri čemu ukazuju da ona nije normalno distribuirana. Distribucija vrijednosti za dva filma prikazana je na slici broj 8.

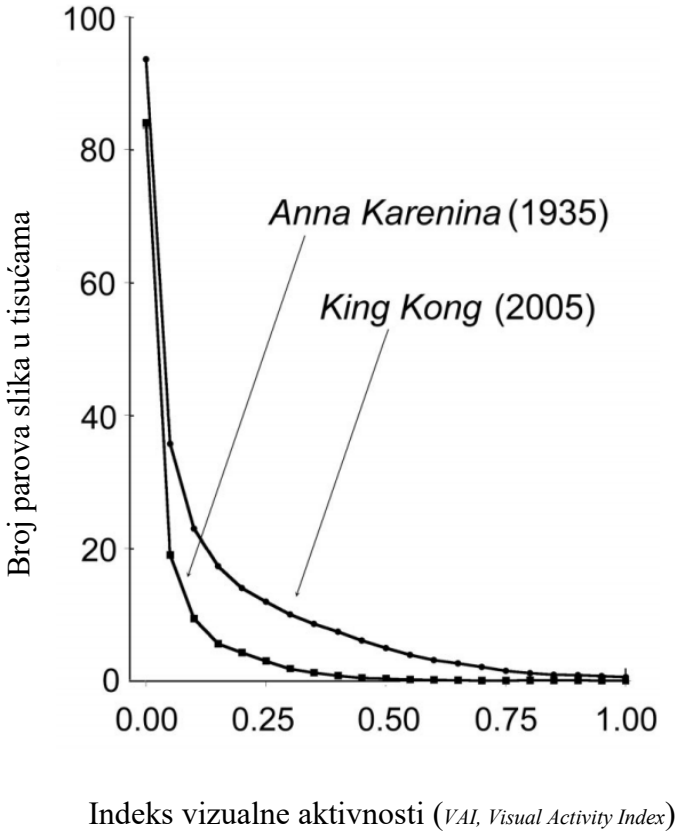

Slika 8 – Distribucija vrijednosti VAI, eng. *Visual Activity Index*, (Cutting, 2011)

Autori su u radu obradili 145 filmova produciranih između 1935. godine i 2005. godine u *Hollywood*-skim studijima, te za njih izračunali vrijednosti Indeksa vizualne aktivnosti. Kao što se vidi na slici broj 9 vrijednost Indeksa vizualne aktivnosti je u tom periodu rasla. Ravna crta, odnosno linearna funkcija kojom su vrijednosti interpolirane, ima vrijednost 0,02 za 1935. godinu, dok je za 2005. godinu ta vrijednost 0,06. Radi se jasno o trostrukom rastu vrijednosti u promatranom periodu od 70 godina.

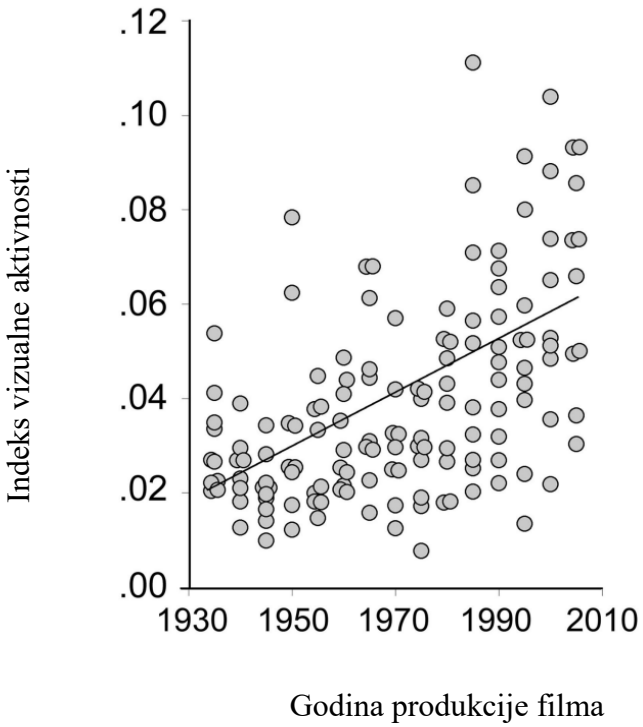

Slika 9– VAI vrijednosti za 145 filmova koji su producirani u različitim periodima (Cutting, 2011)

Autori ukazuju da postoji razlika u vrijednostima Indeksa vizualne aktivnosti između različitih žanrova filma. Prikazali su to i grafički, pa se tako na slici broj 10 vide različite vrijednosti Indeksa vizualne aktivnosti prikazane za različite kategorije filmova. Očigledno je da su akcijski i avanturistički filmovi dosta slični i bliski općem trendu prikazanom na slici 10, dok je taj trend manje izražen u komedijama i dramama. Animirani filmovi se razlikuju od prethodno nabrojenih žanrova, a očigledno je da su neki od starijih filmova imali više vizualne aktivnosti mada vrijednosti ne ukazuju na neki značajan trend. U radu autori analiziraju velik broj obrađenih filmova, te komentiraju na koji način pojedini čimbenici utječu na Indeks vizualne aktivnosti. Pod čimbenicima se misli na npr. neke specifičnosti kod animiranja gdje se broj slika u sekundi u sporijim dijelovima smanjuje, a s druge strane se analizira i sam sadržaj filmova koji utječe na Indeks vizualne aktivnosti.

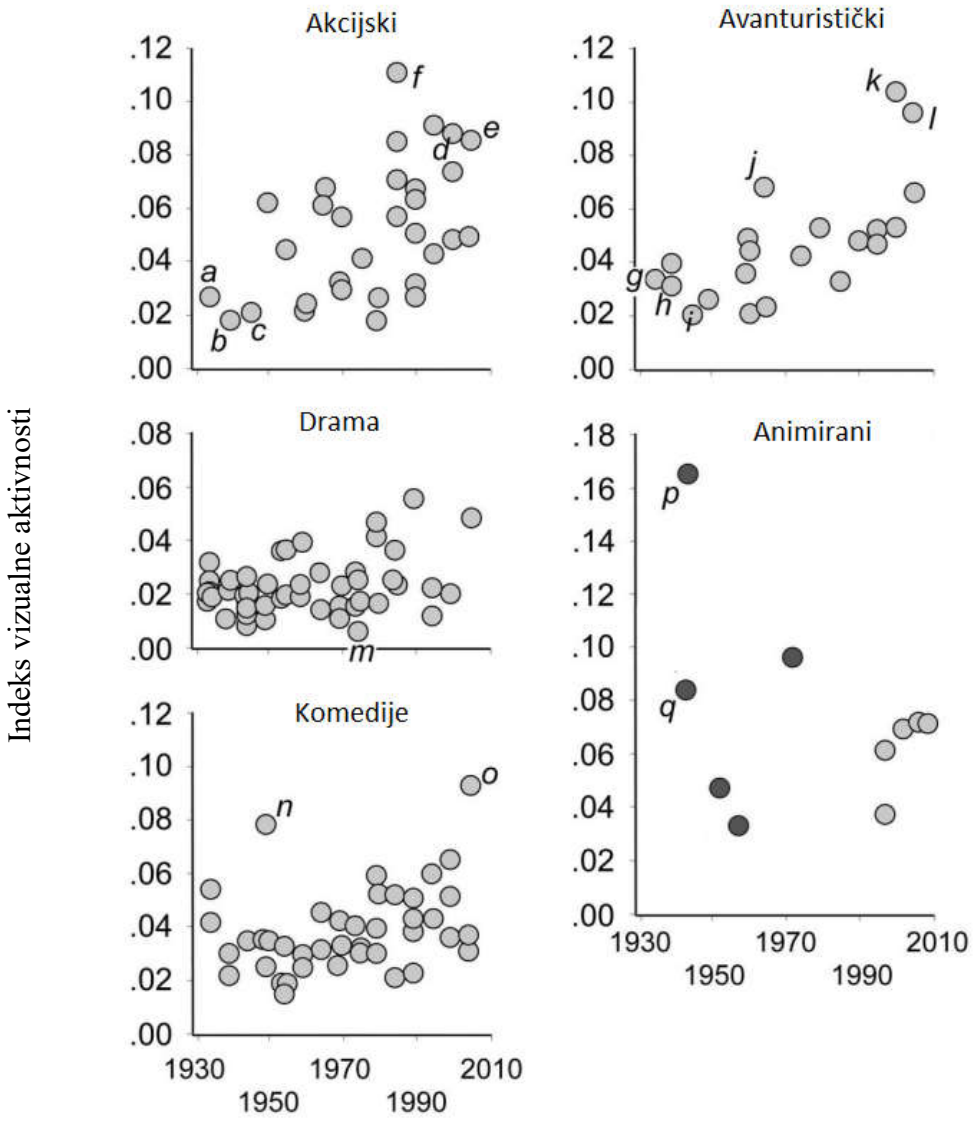

Slika 10 – VAI vrijednosti kategorizirane po filmskim vrstama (Cutting, 2011)

Današnji ljubitelji filmske umjetnosti očekuju veću količinu vizualne aktivnosti u filmovima od one koje su očekivali njihovi roditelji, odnosno još starije generacije. Autori pretpostavljaju da se taj obrazac očituje i kod ponovljenih izdanja pojedinih filmova pri čemu bi novije izdanje u pravilu trebalo imati veću vrijednost Indeksa vizualne aktivnosti. Iz uzorka autori navode nekoliko filmova koji nisu ponovljena izdanja, ali se radi o nastavcima serijala koji također prate isti trend. Konkretno autori navode dva nastavka serijala Zvjezdani ratovi, pri čemu film iz 2005. godine naslova Osveta Sitha (eng. *The Revenge of the Sith*) ima vrijednost VAI od 0,05, dok film iz 1980. naslova Imperija uzvraća udarac (eng. *The Empire Strikes Back*) ima vrijednost VAI od 0,027.

Indeks vizualne aktivnosti predstavljen od autora 2011. godine se spominjao više puta u radovima, pa ga tako Salt koristi u svom radu u kojem analizira parove filmova koji su snimljeni po istom scenariju, ali s razmakom od nekoliko desetljeća (Salt, 2016). DeLong i suradnici koriste Indeks s ciljem utvrđivanja gornje granice do koje se isti može povećavati, a da još uvijek gledatelj uspije prepoznati sadržaj. Pri tom koriste rezultate Potter-a koji je razvio metodologiju pod imenom Brza serijska vizualna prezentacija (eng. *Rapid Serial Visual Presentation - RSVP*) uz pomoć koje je došao do gornje granice prepoznavanja sadržaja niza uzastopnih slika, te on iznosi 100 ms. Drugim riječima, ako se gledatelju prikazuju različite slike brzinom od 10 slika u sekundi, to je gornja granica pri kojoj je sadržaj slika još uvijek prepoznatljiv. Autori ukazuju da je takav niz prihvatljiv gledateljima vrlo kratko vrijeme, a prosječni RSVP nizovi slika imaju Indeks vizualne aktivnosti oko 0,80 (DeLong, 2012)(Potter, 1976).

Cutting i suradnici koriste Indeks vizualne aktivnosti nedugo nakon predstavljanja istog u analizi dijelova scena (*subscene*) pri čemu u radu koriste 24 filma. Scena je „dio film. izlaganja u kojemu se netremice prati neko prizorno zbivanje, obično kroz niz kadrova te uz kontinuirane montažne prijelaze među kadrovima unutar scene, a diskontinuiranim montažnim prijelazima na njezinim granicama prema drugim scenama ili drugim montažnim sklopovima.“ (Turković, 2008a). Nužnost postojanja pojma *subscene* autori obrazlažu preklapanjem događaja u vremenu, ali ne i u prostoru tokom jedne scene, te navode primjer koji je čest u akcijskim filmovima gdje se prikazuju dva suparnika svaki u svom okruženju, pri čemu se kamera prebacuje sa jednog na drugog naizmjenično sve do njihovog susreta i okršaja. Autori uočavaju određenu pravilnost kada se dijelovi scena koji predstavljaju prostornu cjelinu (*subscene*) analiziraju po Indeksu vizualne aktivnosti i to da u prvih 5% vremena dolazi do rasta vizualne aktivnosti nakon kojeg slijedi pad. S obzirom da su trajanja pojedinih dijelova scena različita, autori su ih podijelili proporcionalno na 200 dijelova da bi ih mogli usporediti. Osim toga utvrdili su da je količina vizualne aktivnosti veća u prvih 23,5% trajanja nego u ostatku od 76,5% trajanja. Navedene vrijednosti vidljive su i iz grafikona na slici 11 (Cutting, 2012)(Cutting, 2015).

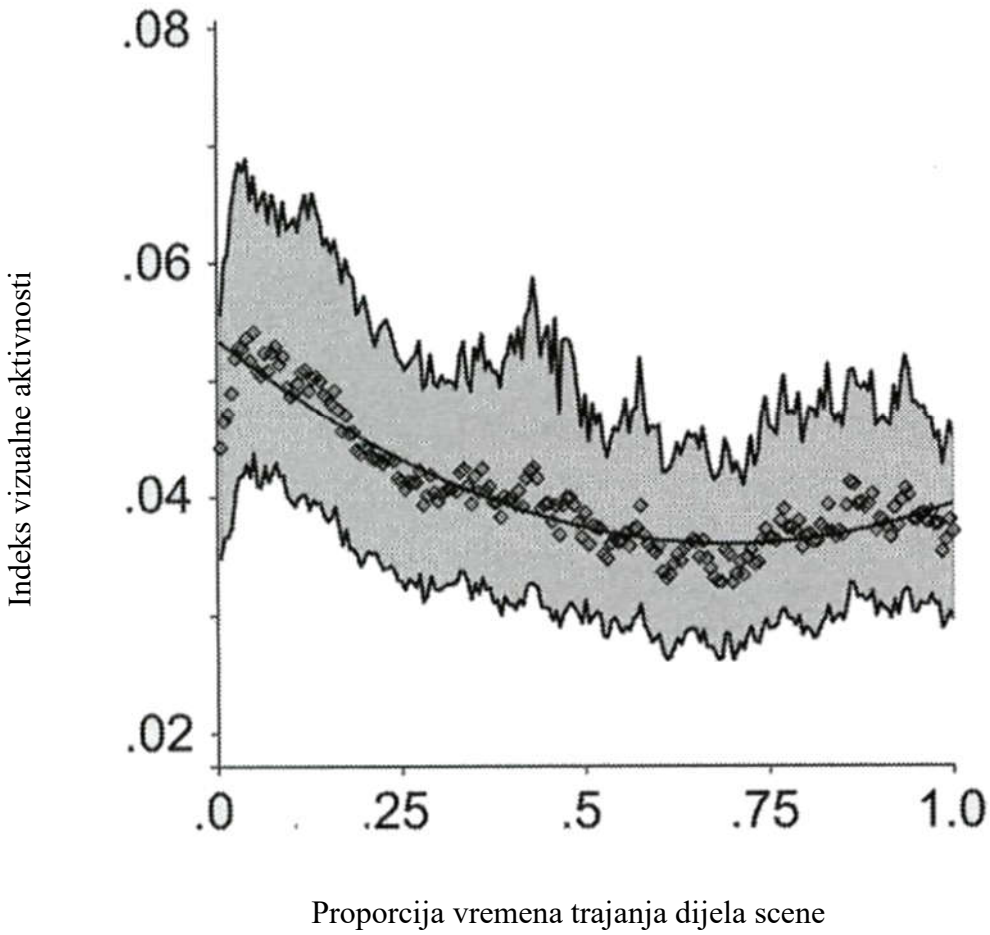

Slika 11- VAI vrijednosti s obzirom na proporcije vremena trajanja dijela scene (Cutting, 2012)

2.4. Utjecaj različitih razina vizualne aktivnosti

Vizualna aktivnost je nužna i očekivana u dinamičnim vizualnim medijima, a Potter je definirao i gornju granicu vizualne aktivnosti nakon koje neke dijelove sadržaja gledatelj uopće ne registrira. U nastavku je dan pregled radova koji pokrivaju utjecaj različitih razina vizualne aktivnosti na gledatelja (Potter, 1976)

2.4.1. Utjecaj vezan uz brzinu promjene kadra

Kao što je navedeno u prethodnom tekstu, prosječna dužina kadra je najčešća mjera koja se susreće u literaturi vezana uz mjerenje vizualne aktivnosti. Kako sam kadar ima svoju dužinu, poznate su i njegove granice, koje se nazivaju montažnim prijelazima. Turković za montažni prijelaz navodi da je on „granica i veza između dvaju kadrova u slijedu. Obilježava ga skokovita promjena u promatranju. Može biti kontinuiran, kada iz kadra u kadar pratimo nadovezan

nastavak istoga prizornog zbivanja usprkos skokovitoj promjeni promatranja, a može biti i diskontinuiran, kada po montažnom prijelazu pratimo posve drugi prizor, drugi dio prizora, ili pratimo isto zbivanje, ali ne u neposrednom nastavku. Može se izvesti rezom, ali i postupnim optičkim transformacijama, protežnim montažnim sponama.“ (Turković, 2008b). Pod montažnim sponama isti autor navodi pretapanje, zatamnjenje i odtamnjenje, te zavjesu (Turković, 2008c). Cutting navodi da se montažne spone koje su bile česte u filmskoj produkciji šezdesetih godina prošlog stoljeća danas rijetko koriste. Suvremena filmska produkcija u 99% slučajeva kadrove razdvaja sa rezom (Cutting, 2011). Zbog toga je potrebno prije analize ASL-a obratiti pažnju na utjecaj pojedinačnog reza na gledatelja.

Više autora je proučavalo što se događa sa gledateljem nakon reza u video sadržajima. Jedna od metoda koju su koristili naziva se *Secondary Task Response Time* (STRT), a služi za utvrđivanje razlike u količini alociranih kognitivnih resursa u različitim situacijama. Metoda se sastoji se od mjerenja vremena od trenutka emitiranja zvuka iz zvučnika do reakcije gledatelja koja je prethodno dogovorena za taj podražaj, a to je u pravilu pritisak tipke. Na taj način se mjeri količina alociranih kognitivnih resursa dodijeljenih primarnom zadatku koji je u slučaju istraživanja s ovog područja, praćenje video sadržaja. Sekundarni zadatak je spomenuto pritiskanje tipke na zvučni podražaj. Što je gledatelj više usredotočen na video sadržaj, njegova reakcija nakon zvučnog signala je sporija, što navodi na zaključak da je više kognitivnih resursa dodijeljeno primarnom zadatku. Geiger navodi da je vrijeme reakcije nakon reza u video sadržaju duže u usporedbi sa vremenom reakcije prije reza, što navodi na zaključaj da je nakon reza više kognitivnih resursa alocirano za analizu novog kadra. Autor je osim toga utvrdio da u slučaju kada su dva kadra nepovezana sadržajno gledatelj alocira više kognitivnih resursa s ciljem povezivanja informacija iz novog kadra s informacijama iz prethodnog, dok je u slučaju kada rez dijeli kadrove s povezanim sadržajem količina alociranih resursa manja (Geiger et al., 1993). Carroll i Bever potvrđuju alociranje više kognitivnih resursa kod gledatelja nakon reza između dva kadra svojim istraživanjem u kojem su pokazali da se dijelovi video sadržaja brže prepoznaju od kada se nalaze iza reza, nego kada se nalaze neposredno ispred reza (Carroll, 1976).

Postoji niz radova u kojima su opisane fiziološke promjene kod gledatelja nakon rezova u video sadržajima. Reeves i suradnici navode da pola sekunde nakon reza, pa sve do 1,5 sekunde nakon reza količina moždanih alfa valova mjerena elektroencefalografom (EEG) pada, da bi nakon 2 sekunde opet porasla. Autori navode da je to u skladu s literaturom s tog područja u kojoj stoji da nakon uvođenja novog poticaja, odnosno stimulacije dolazi do oštrog pada

količine alfa valova, a nakon toga dolazi do postupnog oporavka na prethodnu razinu (Reeves et al, 1985). Autori povezuju tu pojavu sa pojmom *orienting response* (OR), a na području medija se ta pojava „promjene pažnje“ događa kao rezultatu strukturnih svojstava televizijskog programa (Rothschild et al, 1986)(Anderson et al, 1977). Između ostalog, pod strukturnim svojstvima televizijskog programa podrazumijevaju se rezovi između kadrova. Psihološka i fiziološka reakcija engleskog naziva *orienting response* nije usko vezana za medije, te se može dogoditi pri svakoj neočekivanoj senzorskoj stimulaciji (Lynn, 1966).

A. Lang je proučavala vezu između brzine otkucaja srca i okolnosti pod kojima se pojavljuje spomenuta promjena pažnje, te ukazala na postojanje veze između strukturnih svojstava televizijskog programa i brzine otkucaja srca na način da nakon prijelaza između kadrova dolazi do blagog usporavanja otkucaja srca (Lang, 1990). Promjena pažnje (eng. *orienting response*) se u pravilu mjeri u otkucajima srca i traje 10 otkucaja, što u prosjeku iznosi 8,33 sekunde, što navodi na zaključak da ne može svaki rez izazvati navedenu promjenu pažnje, jer se rezovi dosta često u medijima pojavljuju i češće (Smith, 2005).

Video sadržaje različitih ASL vrijednosti koristili su Chandler i Pronin, pri čemu su tri trominutna video isječka imala ASL vrijednosti: 0,75 s, 1,5 s i 3 s. Video isječci su prikazani učesnicima eksperimenta (studentima) koji su prethodno bili podijeljeni u tri grupe, te su autori potvrdili hipotezu da su učesnici koji su gledali video isječak s najmanjom ASL vrijednosti procjenjivali brzinu svojih misli najvišom (eng. *reported thinking fastest*), a pratila ih je grupa sa srednjom te s najvećom ASL vrijednosti. Osim toga rezultati *Cognitive Appraisal of Risky Events* (CARE) testova koji se koriste predviđanje rizičnog ponašanja u budućnosti su ukazali da učesnici koji su gledali video isječak s najmanjom ASL vrijednosti imaju veću sklonost ka rizičnom ponašanju u sljedećih 6 mjeseci. Kako je ASL vrijednost rasla, tako je i sklonost rizičnom ponašanju bila manja. Sudionici izloženi manjim ASL vrijednostima su imali nižu razinu percepcije da rizično ponašanje ima negativne posljedice, a rastom ASL vrijednosti je rasla i razina te percepcije. Autori u zaključku navode da bi svi trebali biti svjesni ove pojave, a posebno ljudi na odgovornim i rukovodećim pozicijama. Osim toga ukazuju i na trenutnu situaciju u kojoj su roditelji i zakonodavci ponekad zabrinuti neprihvatljivim sadržajem u medijima kojima su izložena djeca (nasilje, erotika), te potvrđuju da su u pravu, ali da problem naravno nije samo u sadržaju (Chandler & Pronin, 2012).

Pronin i Wegner su koristili *PowerPoint* prezentacije u kojima su sudionicima istraživanja prikazivali dvije vrste izjava u dvije brzine, te su na taj način testirali utjecaj brzine

razmišljanja na raspoloženje. Izjave se sastoje od niza slova koja su se pojavljivala brzinama od 40 ms, odnosno 170 ms, dok je prosječna brzina čitanja oko 80 ms po jednom slovu. Nakon što bi cijela izjava bila prikazana na ekranu, prezentacija bi prelazila na sljedeći slajd s pauzom od 320 ms, odnosno 4000 ms. Autori u radu dokazuju hipotezu da postoji veza između brzine razmišljanja i pozitivnog raspoloženja, bez obzira na sam sadržaj izjava koje su prezentirane. U istraživanju su sudionicima koji su bili podijeljeni u dvije grupe bile prikazivane izjave depresivnog i poticajnog sadržaja, ali to nije imalo utjecaj na pozitivnije raspoloženje grupe kojoj su izjave bile prikazivane većom brzinom. Mada se u radu ne spominje pojam prosječne dužine kadra (ASL), on je na neki način prisutan jer za svaki slajd se može reći da se radi o jednom kadru, a veća brzina prikazivanja ima četiri puta manju prosječnu dužinu kadra od manje brzine (Pronin & Wagner, 2006).

Indeks vizualne aktivnosti (VAI, *Visual Activity Index*) predstavljen je znanstvenoj zajednici 2011. godine, a Candan i suradnici su ga koristili u istraživanju sposobnosti pamćenja s obzirom na oblik prikazanog sadržaja pri čemu su se koristili video isječci sa izmjenama kadrova i statične slike sa izmjenama slika. Autori su ukazali da se bolje pamte sadržaji koji su prikazani u obliku video isječaka, a pri tome vrijednosti Indeksa vizualne aktivnosti pojedinih video isječaka nemaju utjecaj na pamćenje. Autori zaključuju da sama prisutnost kretanja, a ne količina istog utječe na bolje pamćenje. Sadržaji s video isječaka u kojima je bilo prisutno kretanje bolje se pamte bez obzira na količinu kretanja izraženu kao Indeks vizualne aktivnosti, u odnosu na statične sadržaje sa slika (Candan, 2016).

3. GUSTOĆA INFORMACIJA

S obzirom „gustoća informacija“ nije jednoznačno definirana, za potrebe rada krenuti će se od definicija informacije, a potom na pojašnjenje pojma gustoća informacija. Pri tome će se koristiti radovi autora koji su pojam spominjali u različitim kontekstima.

U nastavku će se obraditi „informacijsko preopterećenje“, pojam koji se povezuje prije svega s gustoćom informacija, a kao stanje ga vezujemo prvenstveno uz živa bića. Očekivano je da će u prvom redu biti riječi o ljudima, ali postoje radovi koji ukazuju da na stanje informacijskog preopterećenja nisu imune ni životinje.

U zadnjem dijelu poglavlja bit će riječi o modelu A. Lang pod nazivom Model ograničenog kapaciteta obrade motiviranih posredovanih poruka (eng. *Limited Capacity Model of Motivated Mediated Message Processing*) koji je provjeren u nizu istraživanja te objašnjava koji čimbenici utječu na pojavu informacijskog preopterećenja.

3.1. Definicija informacije

Pojam informacije definiran je u Webster-ovom engleskom rječniku na više načina, a između ostalog i kao „znanje dobiveno istraživanjem, proučavanjem ili uputom“ (Webster, 2017).

U *Cambridge Dictionary of Philosophy* informacija je definirana kao „objektivni entitet koji može biti generiran ili prenesen porukom (riječju, rečenicom) ili drugim načinom kognicije (interpretacije). Informacija može biti kodirana i prenesena, ali informacija postoji nezavisno od kodiranja i prijenosa.“ (Audi, 1999, po Floridi, 2005)

Informaciju povezujemo sa smanjivanjem neizvjesnosti. Neizvjesnost događaja se mjeri vjerojatnošću njegovog događanja i obrnuto je proporcionalna toj vrijednosti. Autor fundamentalnog rada kojim je postavio temelje teorije informacija je C. E. Shannon sa radom „*A Mathematical Theory of Communication*“ iz 1948. godine. Autor je u radu definirao neizvjesnost, odnosno entropiju diskretne slučajne varijable i to kao:

$$\mathrm{H} = -\sum_{i=1}^{n} p_i \log p_i$$

pri čemu slovo H označava entropiju događaja čije su vjerojatnosti $p_1,\ldots,p_n$. (Shanon, 1948). Na taj način entropijom se mjeri gubitak informacija o stanju sustava.

Shannon nekoliko desetljeća nakon objave navedenog rada navodi da su mnogi autori na različite načine definirali pojam informacije, te je svjestan da se teško može očekivati da bi jedna univerzalna definicija mogla zadovoljiti sve pristupe tom pojmu. Isto tako vjeruje da će neke od definicija i koncepata drugih autora biti priznate i biti temelj za dalja istraživanja i priznanje znanstvene zajednice (Shannon, 1993).

Nužnost postojanja različitih pristupa prijenosu informacija uočio je Weaver nedugo nakon objave spomenutog rada Shanona iz 1948. godine. Weaver je predložio da se osim pristupa koji je koristio Shanon, pojam prijenosa informacija sagleda na još dva načina. Treba naglasiti da se autor u svom radu usredotočio na pojam komunikacije, ali s ciljem prijenosa informacija. Osim tehničkog aspekta komunikacije, odnosno prijenosa informacija, Weaver je uočio da se problem treba sagledati i sa aspekta semantike, kao i sa aspekta utjecaja. Pri tome pod semantičkim problemima prijenosa informacija prije svega prepoznaje problem tumačenja značenja primljenih informacija primatelja u usporedbi sa značenjem koje su te informacije imale kod pošiljatelja. Autor navodi govornu komunikaciju u kojoj se teži semantičke teškoće smanjiti na prihvatljivu razinu, a jedna od osnovnih pretpostavki za to je da su pojmovi u jeziku prethodno jasno definirani. Treći problem se tiče utjecaja ili učinkovitosti, odnosno očekuje se da primljena informacija kod primatelja izazove određeno ponašanje. Autor navodi da sama ta izjava ima negativne implikacije, mada je u širem smislu razumljivo da primanje informacija izaziva, odnosno ne izaziva promjenu u ponašanju primatelja. Isti autor je razjasnio da pojam informacije u Shannonovom modelu ne govori što je preneseno, nego koliko može biti preneseno informacija po komunikacijskom kanalu, pri čemu naglašava da se sam pojam informacije ne koristi u smislu značenja kao što je uobičajeno. Ključna podjela je poimanje

informacije s tehničkog, odnosno matematičkog aspekta, odnosno poimanje informacije s aspekta semantike (Weaver, 1949).

3.2. Definicija gustoće informacija

S obzirom na prethodno navedene definicije informacije, za očekivati je da ne postoji jednoznačna definicija gustoće informacija. Navedeni kriterij podjele na matematičko tehnički, odnosno semantički aspekt informacija ima utjecaj i na poimanje gustoće informacija. Slična podjela na objektivnu i subjektivnu gustoću informacija koristit će se dalje u radu, pri čemu je ključan kriterij podjele prisutnosti, odnosno odsustvo subjektivne procjene.

3.2.1. Objektivna gustoća informacija

Pod objektivnom gustoćom informacija bit će navedene definicije i tumačenja pojma kada u procesu mjerenja nije uključen ljudski faktor i subjektivnost.

Gustoća informacija često se povezuje s medijima za pohranu podataka jer se na njima pohranjuju podatci različite gustoće najčešće s obzirom na iskorištenu površinu. Pri pohrani se često koristi sažimanje podataka s ciljem efikasnijeg korištenja samog medija, ali sažimanje se koristi i pri prijenosu podataka s ciljem efikasnijeg korištenja prijenosnog kanala.

Slika 12 prikazuje općenit proces sažimanja koji uključuje sažimanje bez i sa gubitkom. Podatci iz izvora se dijele u blokove i sažimaju se nekim algoritmom, te pohranjuju na nekom mediju. U idealnom slučaju kada nema gubitka podataka iz sažetih podataka se dobivaju izvorni. U slučaju da se radi o sažimanju s gubitkom, može doći do razlike između izvornih podataka i podataka dobivenih iz sažetih podataka (Whitaker, 2005).

Razina sažimanja može se izračunati iz izraza:

$$R = n / k,$$

pri čemu je n prosječan broj bitova koji su potrebni za pohranu k izvronih bitova. Što je R manji, sažimanje je efikasnije, a entropija veća (Whitaker, 2005).

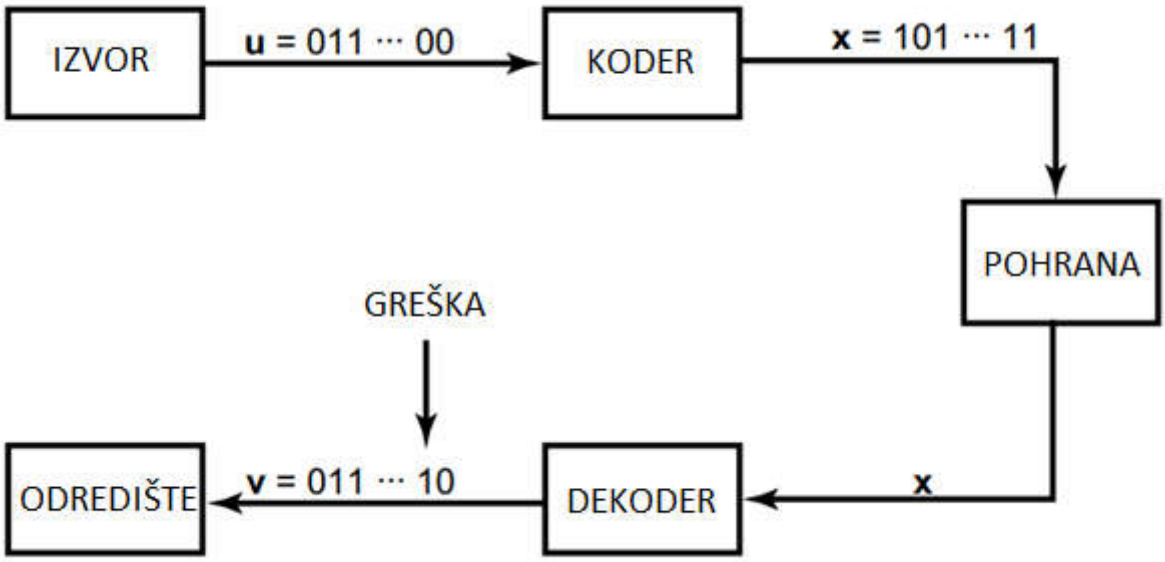

Slika 12 – Shematski prikaz sažimanja podataka (Whitaker, 2005)

Ipak, potrebno je razlučiti terminološku razliku između sažimanja podataka i gustoće informacija, pri čemu je sažimanje vezano uz način i efikasnost kodiranja podataka, dok je entropija mjera količine informacija koju sadrže podatci. Očigledno je da između entropije i gustoće informacija postoji veza, ali entropija je egzaktan pojam u informacijskim znanostima dok pojam gustoće informacija autori koriste na različite načine što se može vidjeti u nastavku.

Pojam gustoće informacija spominje se u pravilu konstantne gustoće informacija (eng. *Principle of Constant Information Density*) koje se primjenjuje u kartografiji kod inteligentnog zumiranja. U kartografiji je to pravilo postavio Topfer pri čemu je isto izrazio i formulom:

$$n_f = n_a * \sqrt{m_a/m_f}$$

pri čemu je m_a trenutno mjerilo karte, m_f sljedeće mjerilo karte, n_a broj objekata trenutnog mjerila i n_f broj objekata sljedećeg mjerila. Ako se to pravilo primjeni na vidljivo područje karte umjesto na mjerilo karte, broj objekata po prikazanoj površini treba biti konstantan. Gustoćom informacija autori smatraju broj objekata prikazanih na vidljivom području. (Frak et al, 1964, po Topfer et al, 1994).

Jednu od sličnih definicija također na području prikaza objekata predložio je Jahnke pri čemu ju je bazirao na broju svojstava po jedinici površine. Njegova definicija vezana je uz područje trodimenzionalnih modela u kartografiji, pri čemu se vidi da u realizaciji autor pod svojstvima smatra detalje tekstura trodimenzionalnih objekata (Jahnke et al, 2011).

U svom radu Perrin spominje gustoću informacija , ali je ne pokušava kvantitativno izraziti. S obzirom da se rad bavi analizom komunikacije uz pomoć višestrukih slika, autor navodi da je gledatelj kojem se istovremeno prikazuju višestruke slike ili video sadržaji izložen većoj gustoći informacija od gledatelja kojem se prikazuje samo jedna slika ili video sadržaj. U radu se analiziraju prednosti i nedostaci metode, a sama definicija je vrlo slična prethodno opisanoj mada se koristi u potpuno drugačijem kontekstu. Naime, u radu se analizira primjena višestrukih istovremeno prikazanih slika u obrazovanju (Perrin, 1969).

Pojam gustoće informacija koriste Chang i suradnici u radu u kojem testiraju utjecaj različitih metoda prezentacije informacija (istovremeno i uzastopno) na sposobnost traženja i pamćenja. Pri tome su koristili matricu od četiri stupca i četiri retka u kojoj su prikazivali četiri, osam i dvanaest točaka. Autori su gustoću informacija izražavali u postotku, kao 25%, 50% i 75%, te je očigledno da autori smatraju da veći broj objekata, konkretno točaka na ekranu linearno utječe na povećanje gustoće informacija (Chang et al, 2012).

Pojam gustoće informacija nalazimo u radovima koji se bave korisničkim sučeljem. Gabillon i suradnici proučavali su korisnička sučelja općenito, te smatraju da se gustoća informacija odnosi na radno opterećenje korisnika sa kognitivnog aspekta i aspekta percepcije i pri tom se u obzir treba uzeti cjelovit niz informacija prezentiranih korisniku. Model koji su predložili sastoji se od jedanaest komponenti čije vrijednosti se izražavaju brojčano pa se mjerenje može automatizirati te se na taj način izbjegava subjektivan utjecaj dizajnera pri izradi sučelja (Gabillon et al, 2013).

Ziefle također spominje pojam gustoće informacija u svom radu u kojem analizira utjecaj gustoće informacija i veličine znakova na brzinu navigacije na mobilnim telefonima. Ovaj rad se također bavi korisničkim sučeljem i pri tome autorica koristi gustoću informacija kao zavisnu varijablu u istraživanju. Taj pojam autorici označava broj mogućnosti u izborniku koji u slučaju analiziranog generičkog sučelja može poprimiti pet vrijednosti, odnosno broj pojmova u izborniku može biti između jedan i pet (Ziefle, 2010)

Hammouda se također bavio analizom sučelja u svom radu, te je metriku vezanu uz gustoću informacija sučelja podijelio u dvije kategorije s obzirom na vrstu sučelja kao što se vidi u tablici broj 4. Autor navodi da je glavni problem gustoće vizualnih informacija neravnomjerna distribucija podataka, te nudi drugačiji pogled na problem iz perspektive ekologije (Hammouda, 2000).

	Vrsta sučelja	
	Grafičko	Tekstualno
Metrika	vrhovi/jedinici površine objekti/jedinici površine dijelovi pravaca/jedinici površine popunjene točke/jedinici površine	znakova/jedinici površine riječi/jedinici površine

Tablica 4– Metrika gustoće informacija (Hammouda, 2000)

Gustoću informacija spominje i Kokol u svom radu u kojem sa kolegama analizira gustoću informacija literarnih djela kroz povijest. Pri tome je analizirano stotinjak djela na slovenskom jeziku koja su objavljena od 16. do kraja 20. stoljeća. Autori definiraju gustoću informacija kao inverziju entropije, odnosno kada je entropija minimalna, gustoća informacija je maksimalna. Minimalnu gustoću informacija, odnosno maksimalnu entropiju imala su djela iz perioda baroka, što autori tumače pojavom obogaćivanja jezika u tom periodu. Autori su koristili metodu koju je predstavio Schenkel sa suradnicima (Schenkel et al, 1993)(Kolok et al, 2006).

3.2.2. Subjektivna gustoća informacija

Pod subjektivnom gustoćom informacija su navedene definicije koje u procesu mjerenja uključuju ljudski faktor i subjektivnost u većoj ili manjoj mjeri. Mada neki od autora egzaktno definiraju mjeru gustoće informacija, ako pri analizi sudjeluje osoba moguće su razlike u mjerenju zbog različitog tumačenja pojmova.

Gustoću informacija Chu i Li definiraju na drugačiji način od prethodno navedenih. U svom radu u kojem uspoređuju gustoću informacija mobilnih web trgovina autori definiraju istu kvantitativno koristeći dužinu web stranice i ukupan broj objekata na web stranici. Dužinu stranice izražavaju kao relativan broj u odnosu na predloženu konstantnu razlučivost ekrana dok objektima koji se broje na web stranici smatraju poveznice, slike, video isječke, naslove, odlomke i natpise. Uz pomoć navedenih kvantitativnih mjera računaju omjer istih i dobivaju novu mjeru koju nazivaju gustoćom prikaza (Chu & Li 2012).

Gustoću informacija definirala je i A. Lang u sklopu Modela ograničenog kapaciteta obrade motiviranih posredovanih poruka (eng. *Limited Capacity Model of Motivated Mediated Message Processing*) kao količinu novih uvedenih informacija po svakoj poruci. Mjerom uvedenih informacija (eng. *information introduced*) mjeri se količina informacija uvedena

svakim pomakom kamere i to na skali od sedam različitih varijabli, odnosno dimenzija. Te dimenzije su:

a) promjena žarišnog objekta
b) novi žarišni objekt
c) povezanost
d) udaljenost
e) perspektiva
f) emocija
g) izmjena oblika

Svaka od dimenzija može poprimiti vrijednosti 0 ili 1. Analizu i mjerenje vrše dvije osobe koje su prethodno obučene i čija točnost je veća od 0,97. Gustoća informacija za pojedinu poruku izračunava se kao zbroj prethodno navedenih dimenzija koje su zabilježene u poruci, odnosno video isječku, podijeljene sa dužinom poruke (brojem sekundi). Bez obzira na navedeni kriterij točnosti i prethodno testiranje osoba koje vrše mjerenje, očigledno je da i ovdje može doći do određenog odstupanja uzrokovanog subjektivnošću opažača (Fox et al, 2007)

Bez obzira na različite pristupe te navedenu podjelu na subjektivnu i objektivnu gustoću informacija može se zaključiti da je gustoća informacija količina informacija na različitim razinama apstrakcije mjerena u vremenskoj, odnosno prostornoj domeni. Definicija je dovoljno općenita da obuhvati i interpretaciju gustoće informacija u slučaju subjektivne procjene.

3.3.Informacijsko preopterećenje

Za razliku od pojma gustoće informacija koji je prilično široko definiran kao što se vidi u prethodnom dijelu, pojam informacijskog preopterećenja (eng. *information overload*) je konkretniji i u radovima se veže uz žive organizme. Na tom području postoji nekoliko teorijskih okvira, ali očigledno je da se autori uglavnom slažu oko osnovne definicije. Rogers i Agarwala-Rogers za informacijsko preopterećenje kažu da je to „stanje osobe ili sustava u kojem isti ne može obrađivati i koristiti prekomjernu količinu ulaznih podataka što dovodi do neuspjeha, odnosno kvara“ (Rogers et al, 1975, po Jones, 2003). Sličnu definiciju nudi i Feather koji u svom radu iznosi da se informacijsko preopterećenje može opisati kao stanje u kome je na raspolaganju toliko informacija da se ne mogu efektivno iskoristiti (Feather, 1998). Schroder pojavu informacijskog preopterećenja grafički prikazuje invertiranom U-krivuljom prikazanom na slici 13, pri čemu rast informacijskog opterećenja povećava točnost u odlučivanju, ali do

određene točke nakon koje dolazi do informacijskog preopterećenja i točnost u odlučivanju pada (Schroeder, 1967, po Eppler et al, 2004).

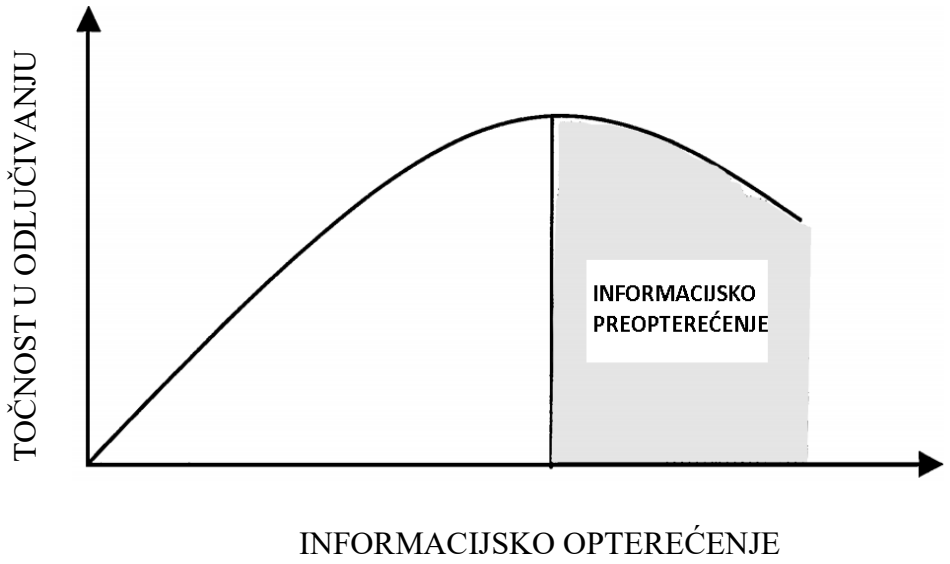

Slika 13 – Invertirana U-krivulja pojave informacijskog preopterećenja (Schroeder, 1967, po Eppler et al, 2004).

Sam pojam se ipak sagledava iz različitih aspekata, te tu postoje određene razlike. Problemom informacijskog preopterećenja bavili su se prije svih psiholozi jer su davno uočili da čovjek ima ograničene kapacitete obrade i pohrane informacija. Tim problemom bavili su se i autori sa područja ekonomije (marketing i menadžment), a osim njih informacijsko preopterećenje tema je kojom se bave autori s područja medija. Postoji niz radova i s područja komunikacije posredovane računalom, a u novije vrijeme informacijskim preopterećenjem bave se i pedijatri.

Eppler sa suradnicima u pregledu literature vezane uz informacijsko preopterećenje navodi i nekoliko sličnih definicija. Neke od tih definicija su u nastavku. Chewning i suradnici za informacijsko preopterećenje kažu da se zbiva kod donositelja odluka „kada količina informacija stvarno integrirana u odluku počinje opadati“ (Chewning et al., 1990). Malhorta i suradnici promatraju informacijsko preopterećenje s aspekta potrošača te navode da „potrošači mogu obraditi ograničenu količinu informacija u jedinici vremena. Ako se ta granica prekorači dolazi do preopterećenja i potrošači postaju zbunjeni te donose lošije odluke.“ (Malhorta et al., 1982). Galbraith definiciju gustoće informacija sagledava iz perspektive organizacijskog dizajna te iznosi da se informacijsko preopterećenje događa kada zahtjevi za obradu informacija budu veći od kapaciteta obrade informacija (Galbraith, 1974). Schick et al. pak smatraju da se „informacijsko preopterećenje događa pojedincu kada se zahtjevi za obradu informacija u

vremenu prelaze izvor ili kapacitet vremena dostupnog za tu obradu“ (Schick et al., 1990). Owen sagledava problem informacijskog preopterećenja s aspekta marketinga te navodi da se radi o „situaciji kada kupac griješi u odabiru u uvjetima velikog informacijskog opterećenja“ (Owen, 1992)(Eppler & Mengis, 2004).

Wilson problem informacijskog preopterećenja promatra s razine osobe, te iznosi da se „informacijsko preopterećenje može definirati kao percepcija pojedinca ili promatrača i da je protok informacija vezan uz aktivnost veći od količine kojom se može učinkovito upravljati, kao i percepcija da nastalo preopterećenje stvara stupanj stresa za koju osoba nema učinkovite strategije“ (Wilson, 2001).

3.3.1. Čimbenici nastanka informacijskog preopterećenja

Pojam informacijskog preopterećenja razni autori su podijelili s obzirom na niz čimbenika. U nastavku je pregled nekih od tih podjela s kratkim tumačenjem.

Između niza različitih pristupa i kategorizacija čimbenika informacijskog preopterećenja, Ho i Tang nude kategorizaciju s obzirom na uzrok informacijskog preopterećenja koja je prikazana na slici broj 14. Autori su stava da se prevelika važnost kod analize informacijskog preopterećenja daje kvantiteti informacija, a da se zanemaruje kvaliteta i format koji također mogu utjecati na pojavu informacijskog preopterećenja (Ho & Tang, 2001).

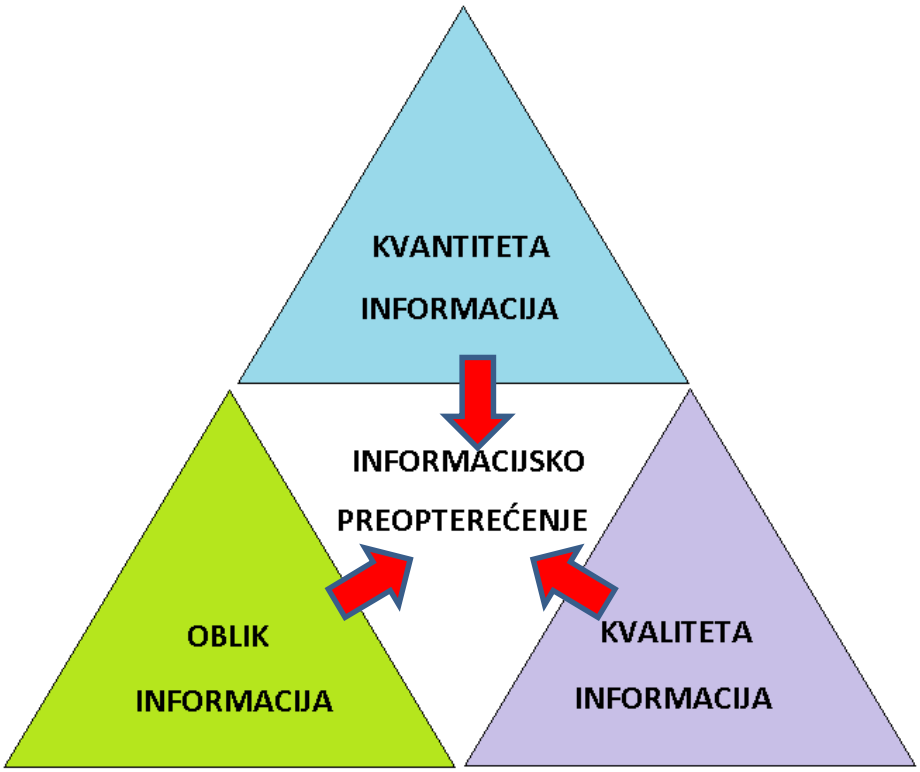

Slika 14 - Kategorizacija čimbenika informacijskog preopterećenja (Ho&Tang, 2001)

Eppler i Mengis su u pregledu literature vezane uz informacijsko preopterećenje definirali tri grupe situacija u kojima dolazi do iste, i to:

a) preuzimanje, organizacija i analiza informacija
b) odlučivanje
c) komunikacija

U svakoj grupi na osnovu pregledanih radova izdvojili su situacije u kojima dolazi do informacijskog preopterećenja.

U prvoj grupi (preuzimanje, organizacija i analiza informacija) naveli su sljedeće situacije: pretraživanje Interneta, pretraživanje informacija vezane uz medicinu, analiza financijskih neprilika, analiza mogućnosti proizvoda, analitičke aktivnosti, investicijska analiza i upravljanje knjižnicama.

U drugoj grupi (odlučivanje) izdvojene su sljedeće situacije: menadžerske odluke općenito, izbor proizvoda u trgovačkim centrima, proces predviđanja bankrota, proces budžetiranja kapitala, odlučivanje o tipu i količini socijalne pomoći, izbor inovacija, određivanje cijena, izbor medija za oglašavanje, strateški razvoj, odlučivanje liječnika, odlučivanje u financijskom sektoru, odlučivanje kupca (izbor brenda) i odlučivanje u zračnom transportu.

U trećoj grupi (komunikacija) su navedene sljedeće situacije: sastanci, telefonski razgovori, upotreba aplikacija za grupni rad i komunikaciju, neposredna rasprava, elektronički sastanci, elektronička pošta, interakcija u gradovima i poslovno savjetovanje (Eppler & Mengis, 2004).

3.3.2. Srodni pojmovi

Uz informacijsko preopterećenje u radovima i publikacijama se pojavljuju srodni pojmovi pa tako imamo informacijsku anksioznost, informacijsko zagađenje i preopterećenje prekidima. Pojmovi su objašnjeni u nastavku.

Informacijsku anksioznost (eng. *Information anxiety*) u svojoj knjizi spominje Wurman (Wurman, 2001). Autor ne definira pojam egzaktno, nego više koristeći simbole, pa tako u jednom dijelu za informacijsku anksioznost piše da je „crna rupa između podataka i znanja“, te da „se događa kada nam informacije ne govore ono što želimo saznati“. Autor navodi da informacijska anksioznost može imati više oblika, navedenih u nastavku:

a) frustracija zbog nemogućnosti „držanja koraka“ s količinom podataka koji su prisutni u svakodnevnom životu,
b) frustracija zbog kvalitete informacija kojima smo izloženi koristeći medije, a posebno onim što se naziva „novost“ bez obzira na medij,
c) frustracija zbog osjećaja krivnje povezanih sa nedovoljnom informiranošću,
d) specifična vrsta oholosti koju pojedinci temelje na činjenici da su prvi upoznati s nekom informacijom (Wurman, 2001).

Termin „informacijsko zagađenje“ (eng. *Information Pollution*) koristi Nielsen te naglašava da je Internet najveći „zagađivač“. Navodi neželjenu elektroničku poštu u kontekstu „kradljivca pažnje“ (eng. *attention theft*), dok web naziva „uređajem za odugovlačenje“ (eng. *procrastination apparatus*) (Nielsen, 2003). Autor u drugom radu uspoređuje elektroničku poštu i sinkroniziranu razmjenu poruka (eng. *instant messaging*), te upozorava da je razmjena poruka lošija od elektroničke pošte iz razloga što prekida tijek posla i zahtijeva trenutnu pažnju. Autor navodi da jednominutni prekid smanjuje produktivnost u periodu od deset minuta (Nielsen, 2004).

Cameron i suradnici definiraju „informacijsko zagađenje“ kao prikrivanje komercijalnih izvora poruka, pri čemu primatelji poruke pretpostavljaju da je izvor poruke uredništvo. Područje kojim se bave Cameron i suradnici je tisak (Cameron et al., 1995).

Utjecaj prekidanja poslovnih aktivnosti kod zaposlenika se proučava već desetljećima. Kreifeldt i suradnici su proučavali utjecaj prekida na točnost i brzinu unosa podataka pri čemu su koristili dva različita pristupa unosa u računalne kalkulatore te uočili prednost s obzirom na točnost i brzinu pri korištenju obrnute poljske notacije (Kreifeldt, 1981). Czerwinski i suradnici su proučavali utjecaj prekida uzrokovanih porukama sustava za sinkronu komunikaciju porukama (eng. *Instant Messaging*), te su uočili da prekidi imaju različit utjecaj s obzirom na fazu u kojoj su se dogodili, kao i s obzirom na povezanost dolazne informacije koja prekida trenutni posao, sa tim istim poslom. U slučaju da je dolazna informacija bila povezana sa poslom, negativan utjecaj u smislu vremena potrebnog za nastavak posla, bio je manji (Czerwinski et al, 2000). Adamczyk i Bailey su također analizirali utjecaj prekida aktivnosti u različitim vrstama aktivnosti, te su uočili kako i prethodni autori da negativan utjecaj prekida ovisi o fazi u kojoj se djelatnik nalazio za vrijeme prekida. Autori ukazuju na mogućnost izrade osobnog informacijskog sustava za upravljanje pažnjom (eng. *attention manager*) koji bi od aplikacija dobivao podatke o vjerojatnom kognitivnom opterećenju korisnika te ga na osnovu tih podataka prekidao u trenutku kada je negativan utjecaj najmanji (Adamczyk et al, 2004). Bailey i Konstan su također došli do sličnog zaključka na osnovu istraživanja te najavljuju razvoj sustava koji bi trebao unaprijediti interakciju između računala i čovjeka na način da će sustav prekidati čovjeka u trenutku kada taj prekid ima najmanje negativnih posljedica (Beiley et al, 2006).

O'Connell je svoj rad naslovio „Preopterećenje prekidima“ (eng. *Interruption overload*), te navodi da prekidi uzrokovani elektroničkom poštom, telefonskim pozivima i drugim komunikacijskim kanalima imaju dubok efekt na produktivnost. Pri tom se navodi da po nekim istraživanjima prekidi „troše“ 28% radnog vremena zaposlenika, što je trošak za ekonomiju Sjedinjenih Američkih Država od 588 milijardi dolara godišnje. Najveći problem autor uočava u činjenici da konstantno prekidanje privremeno smanjuje koeficijent inteligencije za 10 bodova što odgovara smanjenju koje se uočava nakon neprospavane noći (O'Connell, 2008).

Iqbal i Bailey također navode uzroke preopterećenja prekidima i to: „asistenti“ web preglednicima, sustavi za sinkronu komunikaciju porukama i „agenti“ elektroničke pošte. Autori navode da druga istraživanja ukazuju da prekidi ometaju rad i emocionalno stanje, ali da bi se ometanje moglo ublažiti na način da se prekidi događaju za vrijeme manjeg mentalnog opterećenja. Autori predlažu sustav koji ublažuje problem na način da se prate obrasci gledanja u ekran s ciljem otkrivanja perioda manjeg mentalnog opterećenja (Iqbal et al, 2004).

Okoshi i suradnici za razliku od prethodno navedenih autora daju i definiciju pojma preopterećenja prekidima te kažu da je to „oblik ometanja uzrokovan prekomjernim i neodgovarajućim obavijestima koje dolaze od računalnih sustava“. Autori predlažu korištenje *middleware* aplikacije za upravljanje prekidima, pod nazivom Attelia, koja otkriva najpogodnije trenutke za prekid korisnika te ga u tim trenutcima i prekida bez obzira kada se prekid pojavio (Okoshi et al, 2015).

Neki autori koji se bave gustoćom informacija u medijima su zbog praktičnih i etičkih razloga u izučavanju utjecaja medija odabrali drugačiji pristup postavljanjem modela prekomjerne stimulacije na miševima, te su proučavali utjecaj kroz period od 6 tjedana pri čemu su miševi u eksperimentalnoj skupini bili izloženi svakodnevnoj prekomjernoj stimulaciji u trajanju od 6 sati. Autor je povukao paralelu između prekomjerne stimulacije u modelu i DVD sadržajima kojima su izložena djeca, a istraživanje ukazuje da su miševi iz grupe koja je bila izložena prekomjernoj stimulaciji pokazivali lošiju kratkotrajnu memoriju, oslabljenu sposobnost učenja, te veću sklonost preuzimanju rizika (Christakis, 2012).

3.3.3. Teorijski okviri

Više je teorijskih okvira koji obrađuju i tumače pojam informacijskog opterećenja i preopterećenja. U nastavku su dani neki od njih koji se češće spominju u literaturi. Teorijski okviri su podijeljeni u dvije kategorije i to u kvalitativne i kvantitativne. Ključna razlika je da kvantitativni teorijski okviri uključuju kvantitativne pokazatelje, dok se kvalitativni zasnivaju na tumačenju procesa, pojmova i klasifikaciji.

3.3.3.1. Kvalitativni teorijski okviri

Schneider u svom radu predstavlja model informacijskog preopterećenja koji uključuje čimbenike koji prethode preopterećenju i posljedice preopterećenja. Očigledno je da autorica na problem informacijskog preopterećenja promatra s organizacijske razine. Slika 15 prikazuje njen model informacijskog preopterećenja (Schneider, 1987).

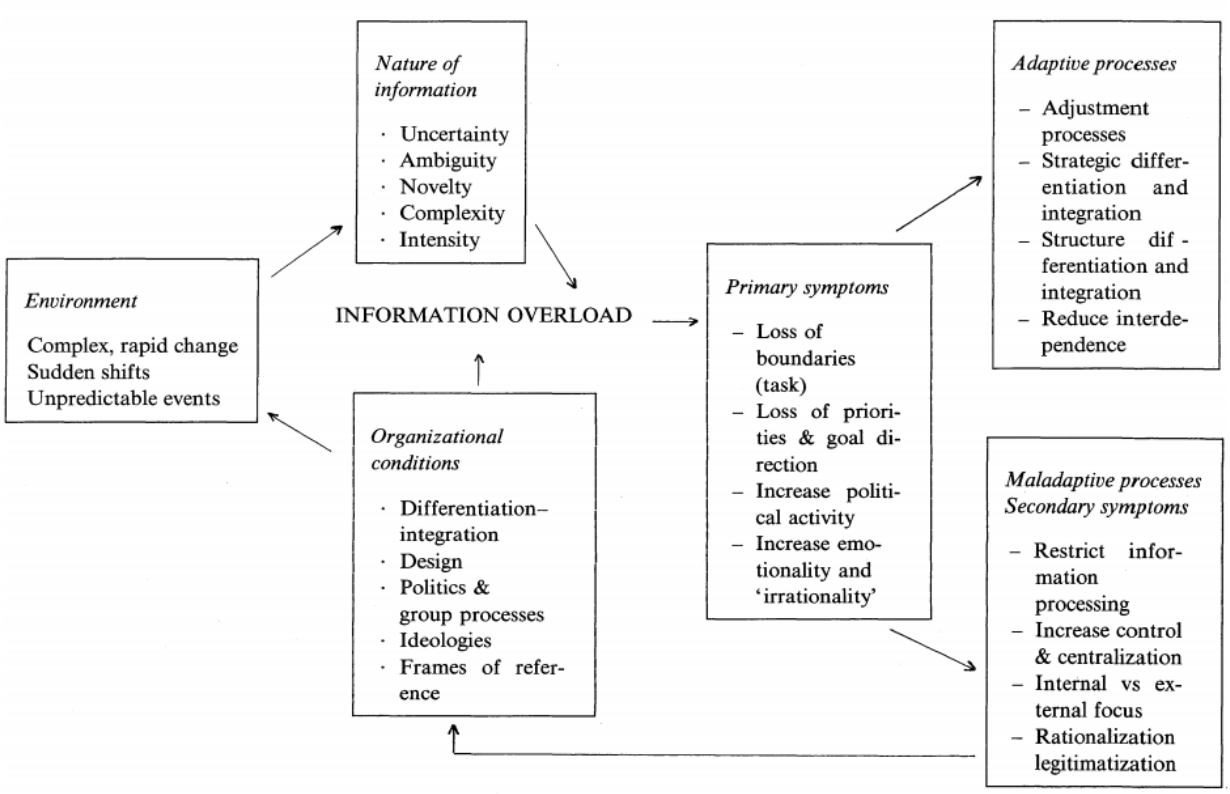

Slika 15 – Model informacijskog preopterećenja (bez prijevoda) (Schneider, 1987)

Schneider smatra da se čimbenici koji prethode informacijskom preopterećenju mogu podijeliti u tri kategorije:

a) Organizacijski uvjeti
b) Okruženje
c) Svojstva informacija (Schneider, 1987).

Pod organizacijskim uvjetima Schneider smatra razine diferencijacije i integracije, organizacijski dizajn, politike, ideologije, kao i referentni okviri. Razine diferencijacije i integracije (eng. *Differentiation and integration*) odnose se na granice organizacije koje reguliraju ulaz i izlaz informacija, te čine bitan segment organizacije. S obzirom da različite organizacijske razine imaju potrebu za različitim informacijama, optimalno postavljeni kriteriji diferencijacije i integracije su ključni za izbjegavanje informacijskog preopterećenja. Organizacijski dizajn (eng. *Organization design*) ima utjecaj na način kako se informacije obrađuju, a autorica opisuje funkcionalan dizajn u kojem je naglašena funkcionalna specijalizacija i matričnu organizaciju kod koje je naglašena integracija na nižim razinama. Organizacijska politika (eng. *Organizational politics*) je širi pojam i pod njim autorica smatra čimbenike koji utječu na tumačenje informacija s različitim ciljevima koji u dosta slučajeva nisu optimalni za opstojnost same organizacije. Ideologije, autorica smatra imaju utjecaj na obradu informacija, a kao primjer navodi stavove i vjerovanja. Referentni okviri (eng. *Frames ofreference*) su posljednji čimbenik iz grupe organizacijskih uvjeta i definiraju načine na koje se informacije prikupljaju, analiziraju i verificiraju. U slučaju da referentnim okvirom nije predviđeno prikupljanje određene vrste informacija, one bivaju zanemarene u organizaciji bez obzira na njihovu važnost (Schneider, 1987).

Pod okruženjem (eng. *Environment*) Schneider smatra vanjske čimbenike koji imaju utjecaj na organizaciju i to iznenadna zbivanja, kompleksne veze, te brze i neočekivane promjene. Autorica je stava da ti čimbenici nisu u svim situacijama u potpunosti objektivni, nego su dosta često subjektivni, odnosno na taj način su doživljeni od članova organizacije (Schneider, 1987).

Značajke informacija (eng. *Nature of Information*) Schneider dijeli u pet kategorija i to: neizvjesnost, dvosmislenost, novina, složenost i intenzitet. Neizvjesnost (eng. *Uncertainty*) je nerazmjer potrebnih i dostupnih informacija, a može biti uzrokovan nedostupnošću informacija, nedostatak znanja vezano uz uzroke i posljedice, kao i nesposobnost procjene vjerojatnosti. Pod dvosmislenošću (eng. *Ambiguity*) autorica smatra situacije kada ista informacija može biti

protumačena na više načina. Novina (eng. *Novelty*) je situacija kada je informacija nova i nema razrađene procedure interpretacije iste. Složenost (eng. *Complexity*) se odnosi na specifičnosti okoline koje imaju utjecaj na organizaciju, a radi se o širokom pojmu koji uključuje zakonsku regulativu, konkurenciju, dobavljače, dostupne tehnologija itd. Intenzitet (eng. *Intensity*) je posljednja značajka informacije i odnosi se na učestalost dolaska i važnost informacija (Schneider, 1987).

Posljedice informacijskog preopterećenja Schneider dijeli na primarne i sekundarne, a opisuje i procese prilagodbe koje organizacija koristi kao odgovor za informacijsko preopterećenje, a uključuje kombinaciju adaptacije i manipulacije, te obrane i napada (Schneider, 1987).

Eppler i Mengis su u svom radu predložili konceptualni okvir za istraživanje informacijskog preopterećenja. Slika 16 prikazuje njihov konceptualni okvir na kojem se vidi da čimbenike informacijskog preopterećenja autori dijele u pet kategorija i to:

a) informacija (eng. *information*)
b) osoba (eng. *person*)
c) zadatak (eng. *task*)
d) organizacija (eng. *organization*)
e) IT (eng. *information technologies*)

Do informacijskog preopterećenja ne dolazi samo zbog jedne od navedenih grupa čimbenika, nego kombinacijom više njih. Grupe navedenih čimbenika po autorima imaju utjecaj na dvije ključne varijable i to kapacitet obrade informacija (IPC - *Information Processing Capacity*) i potrebni resursi za obradu informacija (IPR - *Information Processing Requirements*). Kapacitet obrade informacija je po autorima svojstvo osobe, dok su potrebni resursi definirani poslom ili procesom.

Pod svojstvima informacije kao uzroka informacijskog preopterećenja autori navode da osim količine informacija važnu ulogu imaju i karakteristike informacije te se pri tome pozivaju na već spomenutu Schneider i navode sljedeće karakteristike: neizvjesnost, dvosmislenost, novina, složenost i intenzitet. Osim toga podizanje razine kvalitete informacija smanjuje vjerojatnost informacijskog preopterećenja, pri čemu treba izbjegavati loše strukturirane i nejasne informacije (Schneider, 1987) (Eppler & Mengis, 2004).

Pod svojstvima osobe autori navode stavove, kvalifikacije i iskustvo kao bitne čimbenike, te citiraju starije radove i autore koji su ukazali na ograničenja u količini informacija koje osoba može o braditi (npr. Jacoby et al., 1974). Osim toga pod svojstvima osobe su i motivacija (Muller, 1984) i osobne vještine (Owen, 1984).

Pod svojstvima zadataka i procesa autori citiraju Tuschman-a koji u svom radu zadatke razlikuje po svojstvu predvidljivosti. Ako se zadaci u nekom procesu mogu predvidjeti sa velikom sigurnošću, resursi za obradu se mogu unaprijed pripremiti. Primjer za to su takozvani rutinski poslovi koji uključuju niz međusobno neovisnih aktivnosti i koji se mogu unaprijed planirati, dok kompleksniji poslovi unose veću razinu neizvjesnosti zbog svoje kompleksnosti ili međusobne ovisnosti aktivnosti koje su uključene u posao ili zadatak (Tushman & Nadler, 1978).

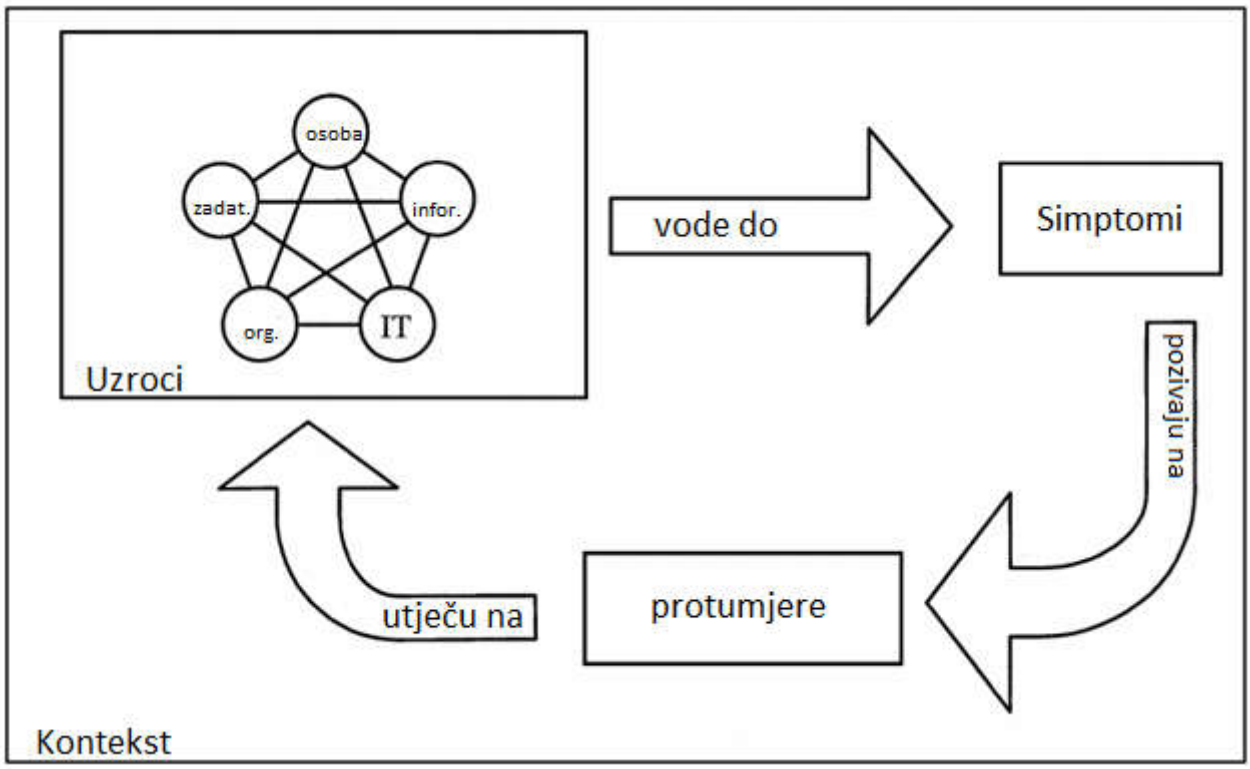

Slika 16- Konceptualni okvir za strukturno istraživanje informacijskog preopterećenja (Eppler & Mengis, 2004)

Swellerova Teorija kognitivnog opterećenja pripada u grupu teorija učenja, a zanimljiva je s aspekta poimanja informacijskog preopterećenja koje naglašava razlike u kognitivnom opterećenju kod učenja. Teorija pretpostavlja da se uzrok kognitivnog opterećenja nalazi u takozvanoj kognitivnoj arhitekturi osobe. Radi se o relativno nepoznatom pojmu, a autor postojanje iste bazira na nizu eksperimentalnih istraživanja. Prije svega autor citira Millerova istraživanja obrade informacija koja ukazuju na ograničen kapacitet kratkotrajne memorije, dok

za dugotrajnu memoriju tvrdi da pohranjuje sofisticirane strukture koje nam omogućuju da primamo i obrađujemo podatke dobivene čulima, razmišljamo i rješavamo probleme (Miller, 1960). Autor te strukture naziva „shemama“ i one omogućavaju pohranu objekata sa različitim svojstvima kao jedan element. Tokom života osoba stječe i nadograđuje sheme, a kako se radi o kompleksnim objektima moguće je da jedna shema u sebi sadrži više drugih.

Teorija ukazuje da je razlika između stručnjaka i početnika u nekom područje u tome što stručnjak ima razvijene sheme, te može lakše obrađivati informacije s nekog specifičnog područja. Sheme imaju po autoru dvije funkcije:

a) osiguravaju efikasniju organizaciju znanja i pohranu u dugoročnu memoriju
b) smanjuju opterećenje radne memorije

Kao što je navedeno, neke situacije kod početnika izazvat će veće kognitivno opterećenje jer bez razvijenih shema broj pohranjenih pojedinačnih pojmova vrlo brzo će doseći gornju granicu. Teorija nadalje daje smjernice za prilagođavanje materijala kognitivnoj arhitekturi osobe (Sweller, 1988)(Sweller, 1994).

Jacoby i suradnici su vjerojatno prvi istraživali ponašanje potrošača u kontekstu informacijskog opterećenja, odnosno preopterećenja. Autor i suradnici su definirali informacije kao vanjski objektivni stimulans, a količinu informacijskog opterećenja izražavali su umnoškom broja proizvoda i broja atributa istih tih proizvoda. Autor i suradnici su dokazali da povećanjem broja atributa uz isti broj proizvoda dovodi do pada kvalitete izbora, te ukazali da se radi o informacijskom preopterećenju (Jacoby et al, 1974a)(Jacoby, 1974b)(Jacoby, 1977).

Navedeni radovi su u kratko vrijeme dobili određene kritike od drugih autora koji su prije svega primijetili da su brendovi, odnosno proizvodi i atributi brenda konceptualno različite dimenzije, te da ih ne bi trebalo množiti da bi dobili ukupnu količinu informacija. Osim toga ukazali su da je vjerojatnost točnog izbora brenda, odnosno proizvoda, obrnuto proporcionalna broju brendova, te da se ta vjerojatnost treba uzeti u obzir pri zaključivanju, kao i na donekle sporan način izbora najboljeg proizvoda koji je prilagođen svakom ispitaniku, ali zbog korištenja ordinalne ljestvice nije u potpunosti pouzdan (Wilkie, 1975)(Summers, 1974)(Russo, 1974).

Malhorta i suradnici predlažu da se podatci iz istraživanja vezanih uz točan izbor brenda analiziraju linearnim logističkim modelom i pri tome analizirajući dostupne podatke iz prethodnih istraživanja dokazuju da se vjerojatnost točnog izbora brenda odnosno proizvoda

povećava rastom broja atributa koji su dostupni o brendu, odnosno proizvodu. To je u suprotnosti sa temeljnom pretpostavkom teorije što navodi i autor. Osim toga nije uspio dokazati statističku značajnost povezanosti rasta broja brendova, odnosno proizvoda, na točnost izbora (Green et al, 1977)(Malhorta et al, 1982).

Neki autori su pokušali usavršiti osnovni model povezanosti koji je predložio Jacoby, pa tako Keller i Stealin u svom radu ukazuju da se osim kvantitete treba uzeti u obzir i kvaliteta informacija. Oni su ukazali da pri konstantnoj kvaliteti informacija, rast količine informacija, odnosno atributa, negativno utječe na kvalitetu izbora proizvoda. S druge strane ako je kvantiteta atributa konstantna, rastom kvalitete informacija povećava se i kvaliteta izbora proizvoda. Osim toga konstantna kvaliteta uz rast količine informacija rezultira padom samouvjerenosti kupca, dok konstantna količina informacija uz rast kvalitete rezultira rastom samouvjerenosti kupca (Keller et al, 1987)(Keller et al, 1989).

U novije vrijeme bez obzira na kritike i dalje se teorija informacijskog preopterećenja uzima kao temelj za istraživanja na tom području. Chen i suradnici analiziraju utjecaj različitih čimbenika na kupce na Internetu te zaključuju da su kupci svjesni stanja informacijskog preopterećenja kada su izloženi velikoj količini informacija, a isto tako se uz pomoć sustava filtracije implementirane u Internet trgovinu mogu ublažiti percepciju informacijskog preopterećenja. Osim toga autori ukazuju da je iskustvo čimbenik koji ima utjecaj na informacijsko preopterećenje pri čemu izgleda da iskusniji kupci bolje procesuiraju informacije od neiskusnih kupaca. Nadalje, autori ukazuju da veća razina informacijskog preopterećenja dovodi do lošijeg raspoloženja samog kupca (Chen et al, 2009).

Lee i suradnici također analiziraju informacijsko preopterećenje pri kupovini na Internetu te konstatiraju da uz konstantne razine atributa i rast broja atributa, kvaliteta izbora kupca pada. S druge strane ne nalaze povezanost broja proizvoda sa kvalitetom izbora, na što ukazuju i drugi autori u slučajevima kada je broj alternativa između 10 i 25. Autori su u radu napravili pomak prema kvantifikaciji količine informacija te su je izražavali u bitovima, što navodi da bi se informacijsko opterećenje u nekim od modela mjerenja moglo izražavati i kvantitativno (Lee et al, 2004).

3.3.3.2. Kvantitativni teorijski okviri

Za razliku od kvalitativnih modela i teorijskih okvira, kvantitativni modeli uključuju mjerenje i kvantificiranje nekih varijabli u modelu.

Teorija informacijskog preopterećenja navedena je u prethodnoj grupi kvalitativnih teorijskih okvira, ali njenom razradom neki autori su pokušali kvantificirati neke od varijabli. Sam naziv za teoriju je donekle sporan jer zbog različitih pristupa još uvijek nije donesena jasna definicija teorije i konkretan model, što je s druge strane i očekivano zbog niza različitih čimbenika koji utječu na informacijsko preopterećenje. Lurie navodi da tradicionalni pristup mjerenja količine informacija danih kupcu uključuje jednostavno brojanje alternativa i atributa te se na osnovu toga procjenjuje kvaliteta izbora kupca. On polazi od pretpostavke da je taj model prejednostavan te da se osim broja alternativa i atributa u obzir moraju uzeti i broj različitih razina atributa koji su povezani s istim i distribucija razina atributa kroz alternative. Autor u svom radu navodi da se kao alternativa tradicionalnom pristupu može upotrijebiti Shannon-ova mjera količine informacija ,

$$I(A) = -\sum_{i=1}^{m} p(a_i) \log_2 p(a_i),$$

pri čemu su a_i (a_1, a_2, … a_m) diskretni izlazi. U domeni izbora kupca, a_i (a_1, a_2, … a_m) mogu biti razine atributa A, a $p(a_i)$ je relativna frekvencija pojavljivanja a_i. U radu je autor izračunao količinu informacija za četiri različita slučaja, pri čemu ih naziva informacijskim strukturama. Konkretno se radilo o kalkulatorima pri čemu je autor kupcima ponudio 18 ili 27 modela čiji su atributi bili jednoliko, odnosno nejednoliko distribuirani. Radilo se o sedam atributa, a samo sa četiri se manipuliralo (dužina jamstva, težina, memorija, veličina ekrana), te su oni mogli poprimiti tri razine vrijednosti. U jednolikoj distribuciji tri razine svakog od četiri atributa su bili jednoliko distribuirani kroz 18 odnosno 27 alternativa, dok su u nejednolikoj distribuciji sedam devetina kalkulatora imali jednu razinu, jedna devetina drugu razinu i jedna devetina treću razinu za svaki od četiri atributa. Sa preostala tri atributa se nije manipuliralo (prilagodljivost, jednostavnost upotrebe, vijek baterije). Tablica 5 je preuzeta i prilagođena od Lurie i prikazuje različite količine informacija za različite informacijske strukture (Lurie, 2004).

Nejednolika distribucija		Jednolika distribucija	
18 alternativa (36,28 bita)	27 alternativa (41,37 bita)	18 alternativa (46,26 bita)	27 alternativa (52,75 bita)

Tablica 5 – Količina informacija različitih informacijskih struktura (Lurie, 2004)

Ne ulazeći dublje u sam rad iz razloga što je tematski vezan za područje marketinga, važno je naglasiti da je rad značajan iz razloga što kvantificira količinu informacija ponuđenu kupcu, te

na osnovu količine informacija istražuje mogućnost informacijskog preopterećenja (Lurie, 2004).

Jackson i Farzaneh su definirali dvije, odnosno tri grupe čimbenika koji utječu na informacijsko preopterećenje i to unutarnji, vanjski, te kombinirani. Unutarnji čimbenici su ključni uzroci informacijskog preopterećenja i imaju direktan utjecaj, dok vanjski indirektno doprinose opterećenju i imaju utjecaj na unutarnje čimbenike. Pod unutarnjim čimbenicima autori navode:

a) Količina informacija - pod količinom informacija Jackson i suradnici navode niz definicija pa tako navode da je količina informacija ukupnost informacija koje postoje i dostupne su osobi, a vezane su uz određenu temu. Previše zatraženih ili dostupnih informacija je najvažniji čimbenik koji utječe na pojavu informacijskog preopterećenja. Količina informacija ima direktan utjecaj na informacijsko preopterećenje, što znači da više dostupnih informacija povećava vjerojatnost informacijskog preopterećenja (Nelson, 1994)(Jackson & Farzaneh, 2012).
b) Kapacitet obrade informacija – pod pojmom kapaciteta se podrazumijeva svojstvo osobe odnosno njeno ograničenje u pogledu količine informacija koje osoba može obraditi i količine pojmova koje može pohraniti, odnosno zapamtiti. Cooper navodi da se pamćenje dijeli u tri kategorije i to: senzoričko pamćenje, kratkotrajno pamćenje i dugotrajno pamćenje (Cooper, 1998). Područje pamćenja je prilično dobro proučeno, a Miller je došao do zaključka da prosječan broj pojmova koji osoba može imati pohranjene u radnoj memoriju iznosi sedam. Osim toga jasno je i da je taj broj ovisan o osobi (Miller, 1960)(Jackson & Farzaneh, 2012).
c) Dostupno vrijeme – posljednji od unutarnjih faktora je dostupno vrijeme, a smanjenjem dostupnog vremena za obavljanje neke aktivnosti povećava se vjerojatnost informacijskog preopterećenja. U situaciji kada je za obavljanje aktivnosti dostupno više vremena, vjerojatnost informacijskog preopterećenja je manja (Schick et al, 1990.)(Jackson & Farzaneh, 2012).

Pod vanjskim čimbenicima autori podrazumijevaju:

a) Karakteristike informacije – navedeni pojam Schneider naziva Prirodom informacija (eng. *Nature of information*), a svojstva tog pojma autori opisuju kroz sljedeće karakteristike:
    a. nesigurnost – omjer potrebnih i dostupnih informacija,

b. dvosmislenost – nejasno značenje informacija,
c. novitet – kod potpuno novih informacija postoji opasnost od nepostojanja poznatog modela obrade, te posljedično odbacivanja iste,
d. složenost – postojanje većeg broja različitih aspekata, odnosno svojstava informacije koji se međusobno isprepliću,
e. intenzitet – učestalost i važnost pojavljivanja informacija u vremenu (Schneider, 1987).

Jackson i Farzaneh pri opisu ovog čimbenika spominju i Bawdena koji navodi i raznolikost informacija (eng. *Diversity of information*) kao bitan čimbenik koji utječe na informacijsko preopterećenje. Bawden navodi da povećanje raznolikosti informacija može dovesti do informacijskog preopterećenja i to iz dva razloga. Prvi razlog je povećanje količine informacija koje su dostupne o nekoj temi, a rezultat su analiza iz različitih perspektiva, dok je drugi razlog nemogućnost obrade tih informacija u postojećem kognitivnom okviru same osobe koja informacije treba obraditi (Bawden, 2008)(Jackson & Farzaneh, 2012).

b) Kvaliteta informacija – Stvilia i suradnici za kvalitetu informacija navode da je prije svega teško mjerljiva, a sama kvaliteta određuje kvalitetu odluka donesenim na osnovu tih informacija. Sa organizacijskog aspekta kvaliteta informacija utječe na aktivnosti i rezultate organizacija i društva u cjelini (Stvilia, 2005). Schneider kvalitetu informacija sagledava također sa aspekta odlučivanja, pri čemu nedovoljno integrirane informacije mogu uzrokovati informacijsko preopterećenje na strateškoj razini odlučivanja (Schneider, 1987). Sličnog stava je i Ackof koji navodi da obilje nebitnih informacija također vodi do informacijskog preopterećenja. Autor rada starog praktički pola stoljeća navodi da se menadžerima dostavlja tolika količina podataka koju ne mogu iskoristiti niti da cijelo vrijeme samo analiziraju te podatke s ciljem razdvajanja bitnog od nebitnog (Ackof, 1967). Kirsh je razliku u rastu količine kvalitetnih informacija u odnosu na ukupnu količinu informacija izrazio grafički, što se vidi na slici Slika 17 (Kirsh, 2000) (Jackson & Farzaneh, 2012).

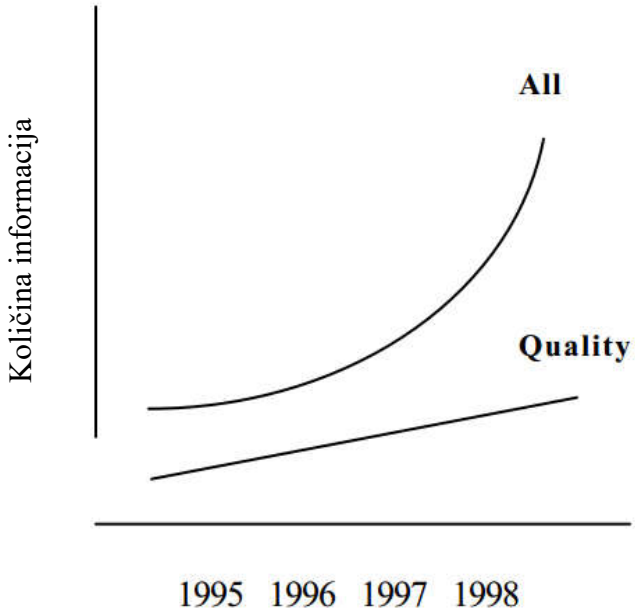

Slika 17 - Rast količine informacija (izvor: Kirsh, 2000)

c) Svojstva zadatka i procesa – više autora ukazuju na različite čimbenike koji spadaju u kategoriju svojstava zadatka i procesa koji treba izvršiti, odnosno završiti. Tu po Jacksonu i Farzanehu spadaju između ostalog prekidi procesa, neizvjesnost i kompleksnost. Prekide procesa su opisali Speier i suradnici, te oni navode da prekidi pozitivno utječu na proces donošenja odluka u slučaju kada se radi o jednostavnim zadacima, dok u slučaju kompleksnih zadataka prekidi imaju negativan utjecaj (Speier et al, 1999). Tushman i Nadler u svom radu naglašavaju da se zadaci, odnosno procesi razlikuju po razini predvidljivosti, odnosno količini neizvjesnosti s kojom se susreću osobe koje zadatak rješavaju. Pri tome se s jedne strane navode rutinski zadaci čije rješavanje se može unaprijed planirati i koji zahtijevaju minimalne potrebe za obradom informacija. S druge strane postoje kompleksni zadaci koji se ne mogu unaprijed planirati i koji su povezani sa visokom razinom neizvjesnosti (Tushman & Nadler, 1978). Kompleksnost zadataka je područje kojim se bavio Campbell te on navodi da se kompleksnost može analizirati s više aspekata i to s aspekta psihologije, interakcije osobe i zadatka i sa aspekta objektivne kompleksnosti zadatka. Na objektivnu kompleksnost po autoru utječu četiri čimbenika i to: postojanje više načina rješavanja problema, postojanje više ciljeva, postojanje ovisnosti između načina rješavanja i ciljeva koji se isključuju, postojanje veza između načina rješavanja i ciljeva koje imaju različite razine vjerojatnosti. Autor navodi da svaki od navedenih čimbenika povećava informacijsko opterećenje (Campbell, 1988)(Jackson & Farzaneh, 2012).

d) Značajke osobe – osobnost i razlike između osoba također su vanjski čimbenik po Jackson-u i Farzaneh-u. Owen to uočava na području prodaje gdje naglašava da iskustvo osobe može utjecati na trenutak u kojem dolazi do preopterećenja. Pri tome „iskusni“ kupci, odnosno poznavatelji određene skupine proizvoda doživljavaju informacijsko preopterećenje kasnije u usporedbi sa „neiskusnim“ kupcima kojima je određena skupina proizvoda relativno nepoznata (Owen, 1992). Jackson i Farzaneh navede i motiviranost kao značajku osobe, a Muller u svom radu u kojem proučava vezu između informacijskog opterećenje i motiviranosti pri kupovini ne uočava povezanost između navedenih čimbenika (Muller, 1984)(Jackson & Farzaneh, 2012). Osim toga Jackson i Farzaneh navode ostale značajke osobe i to prethodna iskustva i kognitivne stilove.

Posebna kategorija su čimbenici vezani uz vrstu izvora informacija i oni mogu biti unutarnji i vanjski. Jackson i Farzaneh navode dvije vrste izvora informacija i to oni kod kojih informacije dolaze na zahtjev (end. *pulled information*) i oni kod kojih se informacije šalju bez utjecaja primatelja (eng. *pushed information*). U drugom slučaju u pravilu se radi o novim tehnologijama koje imaju određene prednosti, ali s aspekta informacijskog preopterećenja povećava se vjerojatnost primanja beskorisnih informacija, a osim toga dolazi do prekida trenutne aktivnosti primatelja zbog dolaska nove informacije (Jackson & Farzaneh, 2012).

Jackson i Farzaneh u svom radu daju konceptualni model informacijskog preopterećenja koji uključuje sedam različitih mjera, koje se donekle preklapaju sa već nabrojenim čimbenicima i to:

- Mjera 1 – Količina informacija
- Mjera 2 – Karakteristike informacija
- Mjera 3 – Kvaliteta informacija
- Mjera 4 – Kapacitet obrade informacija
- Mjera 5 – Dostupno vrijeme
- Mjera 6 – Svojstva zadatka i procesa
- Mjera 7 – Čimbenici vezani uz osobu

Model uključuje takozvanu točku prekretnice (eng. *Tipping point*) u kojoj dolazi do informacijskog preopterećenja, odnosno to je točka u kojoj se izmjenjuju stanje preopterećenja i stanje u kome preopterećenje nije prisutno. Prethodno navedene mjere imaju utjecaj na pojavu informacijskog preopterećenja, a dijele se u grupu čiji rast povećava vjerojatnog preopterećenja i grupu čiji rast smanjuje vjerojatnost preopterećenja. Slika 18 prikazuje svih sedam mjera te se

vidi da rast vrijednosti mjera 2, 4 i 5 smanjuje vjerojatnost preopterećenja (nalaze se na lijevoj strani), dok rast vrijednosti mjera 1, 3, 6 i 7 povećavaju vjerojatnost preopterećenja (nalaze se na desnoj strani) (Jackson & Farzaneh, 2012).

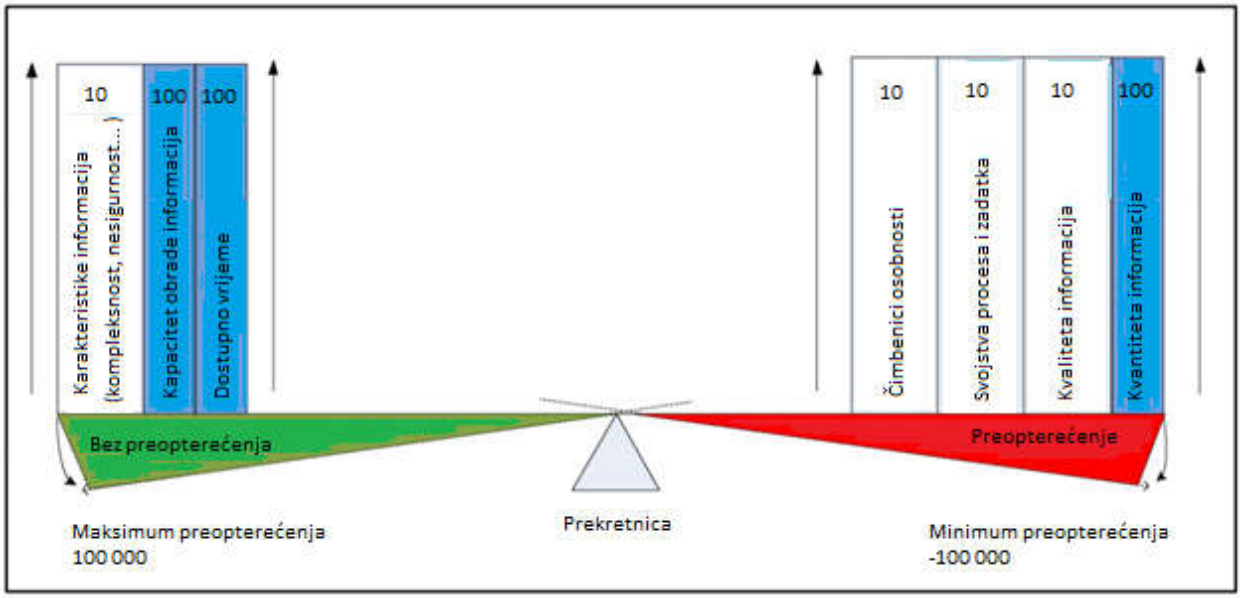

Slika 18 – Konceptualni model informacijskog preopterećenja (Jackson & Farzaneh, 2012)

Autori navode da sustav ima dva stanja, a točka prekretnice je na prijelazu između dva stanja. Ta stanja su:

a) Bez preopterećenja – prvo stanje sustava kada osoba može obrađivati informacije koje prima,
b) Preopterećenje – drugo stanje sustava kada osoba ne može obrađivati informacije koje prima.

Razlog iz kojeg ovaj model pripada kvantitativnim modelima je u tome što su autori postavili konkretne vrijednosti za navedenih sedam mjera te osim toga dali i formulu koja bi trebala poslužiti za izračun da li se osoba nalazi u jednom od prethodno navedena dva stanja. Forma je sljedeća:

Information preopterećenje =

(Karakteristike informacija

× Kapacitet obrade informacija

× Dostupno vrijeme**)**

− **(**Čimbenici vezani uz osobu

× Svojstva zadatka i procesa

× Kvaliteta informacija

× Količina informacija**)**

Autori su svjesni da je izračun nekih vrijednosti kompleksan i nepouzdan, ali sugeriraju da bi se postavljeni model i vrijednosti trebale dalje razrađivati i usavršavati. Slika 18 prikazuje minimalne i maksimalne vrijednosti pojedinih mjera, te se vidi da je umnožak maksimalnih vrijednosti s lijeve strane jednak broju 100000. S desne strane umnožak je također 100000 te je razlika tih vrijednosti nula, a u tom slučaju sustav se nalazi u već spomenutoj točki prekretnice. U slučaju da je vrijednost veća od nule nije došlo do informacijskog preopterećenja, a ako je vrijednost manja od nule tada je informacijsko preopterećenje prisutno. Na slici je vidljivo da mjere u tamnijim pravokutnicima mogu poprimiti vrijednosti do 100, dok u svjetlijim pravokutnicima mogu poprimiti vrijednosti do 10. Razlika je u tom što su u tamnijim pravokutnicima mjere koje pripadaju grupi unutarnjih čimbenika, dok su u svjetlijim mjere koje pripadaju grupi vanjskih čimbenika (Jackson & Farzaneh, 2012).

Za model ograničenog kapaciteta obrade motiviranih posredovanih poruka (eng. *Limited Capacity Model of Motivated Mediated Message Processing*) često se u literaturi koristi kratica LC4MP, pa će se ista koristiti i u nastavku. Početne pretpostavke temeljene su na pretpostvakama da ljudi imaju ograničene kognitivne kapacitete za obradu i pohranu informacijama, a kognitivni procesi se dijele na kodiranje, pohranu i kasniji pristup, odnosno dohvat informacija. Značaj ovog modela za samu disertaciju je u određivanju okolnosti u kojima dolazi do informacijskog preopterećenja, pri čemu se koristeći metode poznate na području psihologije uspijeva otkriti kada je došlo do informacijskog preopterećenja.

Model (LC4MP) je izvorno nazvan Model ograničenog kapaciteta obrade posredovanih poruka (eng. *Limited Capacity Model of Mediated Message Processing*), a kratica za tu kraću verziju je bila LC3MP (Lang, 2000). Ta verzija iz 2000. godine očigledno nije uključivala motivaciju, te je ona dodana u sljedećoj verziji.

LC4MP model zasniva se na metodi pod nazivom Vrijeme reakcije na sekundarni podražaj (eng. *Secondary task reaction time*) za koju se često koristi kratica STRT te će se ista koristiti u nastavku. Ova metoda je godinama zbunjivala autore na području komunikacijskih

znanosti i tek ju je A. Lang sa suradnicima uspjela do kraja rastumačiti. Pri STRT testiranju sudionici obavljaju primarni zadatak koji im je prethodno postavljen, a u isto vrijeme im je rečeno da obrate pažnju na sekundarni signal koji može biti vizualan ili zvučan. Kada začuju ili vide sekundarni signal trebaju što je brže moguće pritisnuti zadanu tipku. Pretpostavka je da će vrijeme reakcije biti duže u slučaju kada je primarni zadatak kompleksniji jer za sekundarni zadatak ostaje manje kognitivnih resursa. Isto tako, vrijeme reakcije trebalo bi biti kraće kada je primarni zadatak relativno jednostavan jer samim tim više kognitivnih resursa ostaje za obradu sekundarnog zadatka. Ako se STRT metoda primjeni na području istraživanja medija, pretpostavka je da će kod kompleksnijih poruka vrijeme reakcije biti duže. Autori su godinama bili zbunjeni jer su eksperimentalna istraživanja ukazivala da je vrijeme reakcije kod kompleksnijih poruka kraće za razliku od vremena reakcije kod jednostavnijih poruka koje je bilo duže. Taj paradoks uočio je Britton sa suradnicima, koji je najčešće koristio tekstualne poruke različite kompleksnosti u istraživanjima (Britton et al, 1982) (Britton et al, 1978). a uočio ga je i Reeves sa suradnicima koji se bavio televizijom (Reeves et al, 1985) (Reeves et al, 1986). Osim skraćenja vremena reakcije kod kompleksnijih poruka primijećeno je da dolazi i do značajnijeg pada kognitivnih sposobnosti vezanih uz obradu podataka primarnog zadatka, što u praksi znači da su sudionici eksperimenta u trenutku kada je kompleksnost poruke bila veća i vrijeme reakcije na sekundarni signal kraće, znatno lošije memorirali podatke vezane uz primarni zadatak. LC4MP model riješio je navedeni paradoks objašnjenjem da povećanjem kompleksnosti primarnog zadatka, odnosno poruke, u jednom trenutku dovodi do kognitivnog preopterećenja te se kognitivni resursi automatski dodjeljuju sekundarnom zadatku (Basil, 1994)(Fox et al, 2007).

S obzirom na značaj LC4MP modela za disertaciju nužno je ući detaljnije u obrazloženje dato od autora. Pri tumačenju STRT metodologije autori su upozorili da su početne pretpostavke o resursima koji se mjere STRT-om bile krive. Definirali su četiri pojma koji se pojavljuju u STRT metodologiji i koje su detaljnije objasnili. To su:

a) ukupni resursi (eng. *total resource pool*),
b) potrebni resursi (eng. *resources required*),
c) alocirani resursi (eng. *resources allocated*),
d) preostali resursi (eng. *remaining resources*),
e) dostupni resursi (eng. *available resources*).

Paralela koja pomaže razumijevanju funkcioniranja metode je primjer kupovine nekog proizvoda. Kada osoba ide u kupovinu, ima određenu količinu novca u novčaniku, a to bi u modelu bili ukupni resursi. Kada osoba kupi neki proizvod on ima svoju cijenu, a ta cijena bi u modelu bila količina potrebnih resursa. Kada trgovcu kupac da novce, to bi u modelu bili alocirani resursi, a u novčaniku kupcu ostaju preostali resursi. Dostupni resursi bi bila razlika između cijene i količine novca koji je kupac dao trgovcu. Odnosi među navedenim pojmovima mogu biti prikazani i formulama:

preostali resursi = ukupni resursi – alocirani resursi (*resources remaining = total resources – resources allocated*)

dostupni resursi = potrebni resursi – alocirani resursi (*available resources = resources required – resources allocated*)

A. Lang je još 1998. posumnjala da je STRT mjera preostalih resursa što je ionako bila hipoteza koja je zbunjivala znanstvenike, pa je sa suradnicima dokazala da se STRT-om može mjeriti samo količina dostupnih resursa. Drugim riječima, STRT-om se mjeri razlika između alociranih i potrebnih resursa, a vrijednost hipotetski može biti veća ili manja od nule, ali i nula u situaciji kada su alocirani i potrebni resursi jednaki (Lang et al, 1998).

U sklopu provjeravanja LC4MP modela na području medija, autorica je sa suradnicima uvela novu mjeru za potrebne resurse, koju je nazvala Uvedene informacije (eng. *information introduced*). U literaturi se često za tu mjeru koristi kratica I^2. Njome se mjeri količina informacija za svaku promjenu kadra. Za promjene kadra (eng. *Camera Changes*) se u LC4MP modelu koristi kratica CC, a radi se o mjeri za potrebne resurse. Autorica naziva tu mjeru i Složenošću strukture u situaciji kad je izražena u jedinici vremena (eng. *Structural Complexity*), pri čemu je definira kao „broj promjena kadra u sekundi“. Mjeru Uvedenih informacija naziva Gustoćom informacija (eng. *Information density*) kada je izražena u jedinici vremena. U nastavku će te dvije mjere biti detaljnije objašnjene (Lang et al, 2007)(Lang et al, 2006).

A. Lang uvodi pojam „Gustoća informacija“ 2007. godine u radu pod naslovom „Cognition and Emotion in TV Message Processing: How Valence, Arousing Content, Structural Complexity, and Information Density Affect the Availability of Cognitive Resources“ gdje navodi da se radi o prethodno spomenutoj mjeri I^2 po jedinici vremena, odnosno sekundi. „Uvedene informacije“ (eng. *information introduced*), odnosno I^2 definirane su u radu iz 2006. godine pod naslovom „Parsing the Resource Pie: Using STRTs to Measure

Attention to Mediated Messages“. U nastojanju da što egzaktnije definiraju „Uvedene informacije“, autori su odabrali sedam dimenzija i to su:

a) promjena žarišnog objekta
b) novi žarišni objekt
c) povezanost
d) udaljenost
e) perspektiva
f) emocija
g) izmjena oblika

Svaka dimenzija može poprimiti vrijednost 0 ili 1, a mjerenje se vrši kod svake promjene kadra.

Promjena žarišnog objekta je prva od dimenzija i pri promjeni kamere žarišni objekt može biti isti, ali se može i izmijeniti. Pri izmjeni dolazi do alokacije resursa, a istraživanja ukazuju da opažanje novog objekta rezultira alokacijom kognitivnih resursa (Kahneman, 1973) (Lang et al, 2006).

Kod promjene žarišnog objekta on može biti već viđen u poruci ili novi. U slučaju da se pojavljuje novi objekt bit će potrebno više resursa, odnosno pažnje, za obradu informacija i autori definiraju novu dimenziju baziranu na tome. Njen naziv je *Novi žarišni objekt*, što je donekle prilagođen prijevod (eng. *Novelity*)(Berlyne et al, 1976) (Lang et al, 2006).

Dimenzija nazvana *Povezanost* bazirana je na radu u kojem Geiger i suradnici ukazuju da potrebni resursi za obradu informacija ovise o količini informacija koje su povezane sa informacijama prikazanim prije promjene kamere, odnosno u prethodnom kadru. Povezani kadrovi zahtijevaju manje kognitivnih resursa od nepovezanih, a ako su kontekst i priča između kadrova povezani, tada općenito postoji povezanost. Ako nema logičke veze između kadrova, tada se povećava količina potrebnih resursa za obradu (Geiger et al, 1993) (Lang et al, 2006).

Dimenzija pod nazivom *Udaljenost* temelji se na istraživanjima koja ukazuju da objekti koji se približavaju izazivaju veći interes kod promatrača od onih koji se udaljavaju. Iz evolucijske perspektive navedeno se temelji na činjenici da bliži, odnosno veći objekti predstavljaju i veću prijetnju (Franconeri, 2003). Drugi autori navode da veći objekti zahtijevaju više resursa za obradu od udaljenih i malih objekata (Reeves et al, 1999). Dimenzija *Udaljenost* kod promjene kamere, odnosno kadra, ima vrijednost 1 u slučaju kada je objekt iz prethodnog kadra bliži pri promjeni kadru (Lang et al, 2006).

Dimenzija pod nazivom *Perspektiva* temelji se na stavu struke da promjena perspektive izaziva niz psiholoških efekata. Anderson je tu pojavu izučavao kod interpretacije, odnosno prepričavanja događaja iz različitih perspektiva (Anderson et al, 1978). Kraft se bavio utjecajem kuta pod kojim kamera snima scenu, te navodi da „kut kamere ima značajan i predvidljiv učinak na prosudbu fizičkih i osobnih karakteristika snimljenih osoba, te na prisjećanje navedenih karakteristika i sadržaja snimljene scene“ (Kraft, 1987). Autori koji se bave filmom općenito također su stava da promjena perspektive ima određene psihološke utjecaje na gledatelje (Andrew, 1976)(Eisenstein et al, 1949). Iz navedenih razloga Lang i suradnici su pretpostavili da će promjena perspektive zahtijevati dodatne resurse za obradu novih informacija, te su predložili i spomenutu dimenziju (Lang et al, 2006).

Sljedeća dimenzija pod nazivom *Emocija* bila je predmet izučavanja A. Lang sa suradnicima kao i drugih autora te je A. Lang opravdava činjenicom da emocionalni sadržaj poruke zahtijeva više resursa za obradu od sadržaja u kojem nema emocija. Pri promjeni kamere, odnosno kadra, pojava emocionalne poruke bez obzira na to da li je pozitivna ili negativna se registrira (Lang et al, 1999)(Lang et al, 1995)(Lang et al, 1996)(Lang et al, 1990)(McKenna et al, 1995)(Lang et al, 2006).

Posljednja sedma dimenzija pod nazivom *Izmjena oblika* vezana je uz izmjenu formalnih svojstava scene pri promjeni kamere, a u nastavku su navedeni neki primjeri:

a) promjena iz crno bijelog snimka u snimak u boji,
b) promjena iz slike u tekst
c) promjena iz animacije u stvaran snimak, itd.

Ako pri promjeni kamere dođe i do izmjene formalnih svojstava scene, biti će potrebno više resursa za obradu, te se to također registrira (Fox et al, 2004)(Lang et al, 2006).

Kao što je navedeno „Uvedene informacije“, odnosno I^2, mjeri se kod svake promjene kamere i s obzirom da mjera ima sedam dimenzija može poprimiti vrijednost između 0 i 7. Mjera se dobiva zbrajanjem vrijednosti navedenih dimenzija za svaku promjenu kamere, odnosno kadra. Ako vrijednost „Uvedene informacije“ podijelimo s trajanjem poruke dobiva se mjera za potrebne resurse u jedinici vremena, za koju Lang uvodi pojam *Gustoća informacija*.

Složenost strukture (eng. *Structural Complexity*) je također pojam koji Lang uvodi 2007. godine u radu pod naslovom „*Cognition and Emotion in TV Message Processing: How*

Valence, Arousing Content, Structural Complexity, and Information Density Affect the Availability of Cognitive Resources“ gdje navodi da se radi o mjeri „Promjena kamere“ (eng. *Camera Changes*) za koji je kratica CC, ali po jedinici vremena. Kao što je navedeno radi se o mjeri za alocirane resurse. Lang i suradnici koriste navedene pojmove i dalje u svom istraživačkom radu (Lang et al, 2006)(Lang et al, 2007)(Lang et al, 2012)(Lang et al, 2013).

4. ALGORITMI ZA UKLANJANJE POZADINE

U ovom poglavlju dan je pregled algoritama za uklanjanje pozadine. Prije svega je razjašnjen pojam računalnog vida u koji navedeni algoritmi pripadaju, a nakon toga su dane različite podjele algoritama računalnog i strojnog vida.

Algoritmi za uklanjanje pozadine su detaljnije opisani i podijeljeni po načinu funkcioniranja. S obzirom da se radi o području koje se intenzivno razvija, navedena podjela i broj algoritama u pojedinim kategorijama su podložni promjenama.

4.1.Računalni vid

Od svih osjetila koja čovjek koristi vid je svakako najvažniji, a omogućuje percepciju okoline bez direktnog kontakta s istom. Čovjekov vid nije moguć bez prisutnosti svjetla, odnosno elektromagnetskog zračenja određene valne dužine. Vizualna percepcija je mogućnost detekcije svjetla kod ljudskih bića i nekih životinja, na osnovu koje nastaje znanje o okolini koje povećava vjerojatnost preživljavanja (Sarkar, 2016).

Za znanost koja se općenito bavi vidom može se reći da „proučava kako biološki sustavi i uređaji mogu koristiti svjetlo za prikupljanje informacija iz okruženja“ (Bajcsy, 2014). Autorica prethodne definicije dalje navodi da se radi o širokom području koje uključuje niz podpodručja kao što su: obrada signala, kognitivne znanosti, informacijske znanosti, neurofiziologija, optika, percepcija i srodna područja. Motivi i ciljevi razvoja navedenog područja mogu se podijeliti u dvije grupe predstavljene pitanjima:

a) kako izraditi model biološkog procesa vida i time objasniti fenomen vizualne percepcije,
b) kako dizajnirati uređaje koji će na osnovu ulaznih vizualnih podataka davati željeni izlaz (Bajcsy, 2014).

Za računalni vid Fischler navodi da je „znanstvena disciplina koja se bavi problemom kombiniranja slike dobivene senzorima, prethodno stečenog modela snimane slike, globalnog znanja i poznavanja obrade slika, kako bismo izgradili eksplicitni opis ili model okruženja“ (Fischler et al, 1987). Jahne i Haussecker definiraju računalni vid kao „niz tehnika za prikupljanje, obradu, analizu i razumijevanje složenih višedimenzionalnih podataka iz našeg okruženja za tehničku i znanstvenu primjenu“ (Jahne et al, 2000). Huang navodi za računalni vid iz inženjerske perspektive da „ima za cilj izgraditi autonomne sustave koji bi mogli obavljati

neke od zadataka koje može i vizualni sustav čovjeka (a u mnogim slučajevima to može odraditi bolje)“ (Huang, 1996). Znatno općenitiju definiciju daju Shapiro i Stockman koji navode da je „cilj računalnog vida donositi korisne odluke vezane uz stvarne fizičke objekte i prizore bazirane na snimljenim slikama“ (Shapiro et al, 2000). Ballard i Brown smatraju da je računalni vid „aktivnost automatizacije i integracije širokog raspona procesa i prikaza s ciljem vizualne percepcije“. Autori su stava da se sustav percepcije kod ljudskih bića dugo razvijao i specijalizirao, a velik dio tog sustava još nije u potpunosti razjašnjen. Računalni vid ima za cilj na neki način napraviti kopiju sustava kojim se koriste ljudska bića, ali koristeći digitalne tehnologije (Ballard et al, 1982).

Računalni vid autori često smatraju područjem znanosti koje pripada umjetnoj inteligenciji. Vijipriya i suradnici računali vid smještaju među ostala područja poput neuronskih mreža, robotike, ekspertnih sustava, prepoznavanja govora, strojnog učenja itd., te su stava da su to područja koja pripadaju umjetnoj inteligenciji. Autori naglašavaju da se pojam *Computer vision* razlikuje od pojmova *Computational vision* i *Machine vision*, pri čemu je *Computational vision* više vezan uz niže razine obrade slike, dok je *Machine vision* više vezan uz primjenu na konkretnim proizvodima i ostvarenje doprinosa živim bićima i okolišu (Vijipriya et al, 2016).

Za računalni vid autori često navode da je u dualnom odnosu prema računalnoj grafici. Na računalu se uz pomoć slike generira računalni model. Sa desne strane kružnice je kratica CV od izraza *Computer Vision*, a slijeva kratica CG od izraza *Computer Graphics*. Slika 19 prikazuje navedeni smjer transformacije iz slike u model i obratno (Rockwood et al, 1999).

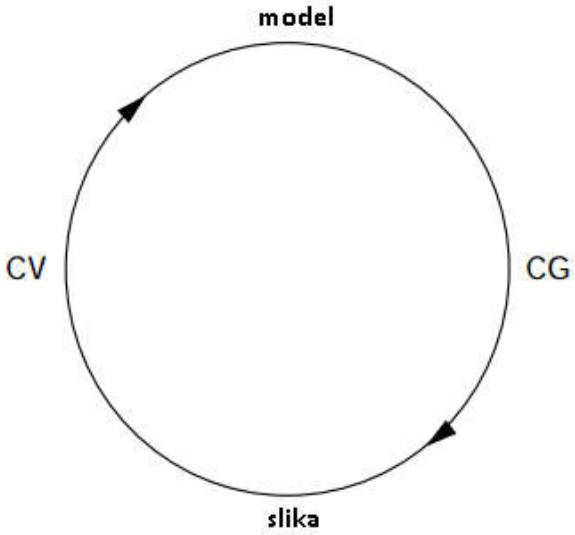

Slika 19 – Dualni odnos računalnog vida i računalne grafike (Rockwood et al, 1999)

U samim početcima razvoja računalnog vida sustavi koji su razvijani imali su specifičnu namjenu i u pravilu su rješavali jedan praktičan problem. Primjeri za to su sustavi namijenjeni obradi snimljenih slika iz zraka (Tanenbaum et al, 1979), analizi gotovih proizvoda u industriji (Perkins, 1978) ili analizi radioloških snimaka (Ballard et al, 1976). Vrlo brzo je postalo jasno da bi se računalni vid trebao razvijati na način da bude univerzalno primjenjiv za rješavanje bilo kojeg problema. Slika 20 prikazuje jednostavan model koji je upućivao na potrebu složene interpretacije slike i izrade modela scene početkom osamdesetih godina prošlog stoljeća (Barrow et al, 1981).

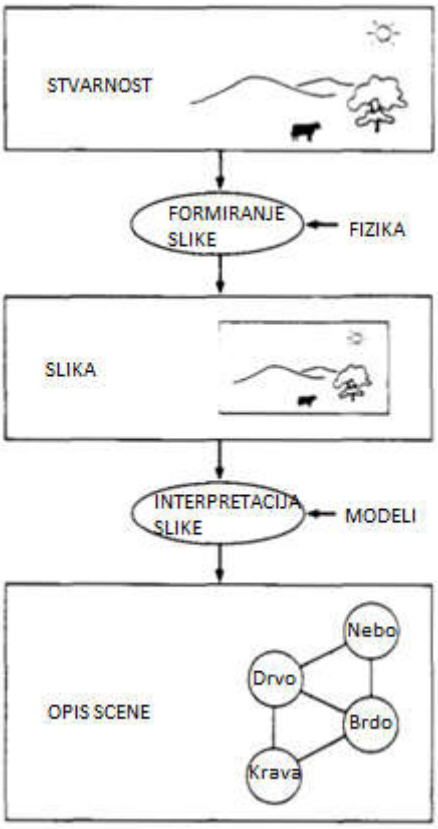

Slika 20 – Tumačenje slike na temelju modela (Barrow et al, 1981)

U prvom pravokutniku autor je za primjer uzeo krajolik, odnosno scenu koji ima sve tri dimenzije. Kreiranjem slike scene u drugom pravokutniku dobivamo polje vrijednosti razina osvjetljenja, odnosno zračenja različitih valnih dužina, a u stvari se radi o dvodimenzionalnoj projekciji koja je snimljena kamerom ili nekim drugim funkcionalno sličnim uređajem. Slika može biti u boji, a tada se sastoji od nekoliko projekcija pri čemu svaka sadrži informacije o različitim valnim dužinama osvjetljenja. Postoji mogućnost uključivanja i dimenzije vremena, odnosno snimanjem krajolika u različitim vremenskim periodima. Razine osvjetljenja na slici ovise o nizu čimbenika, a to su: osvijetljenost krajolika, svojstva refleksije površina, orijentacija

površina u odnosu na izvor svjetla i u odnosu na mjesto snimanja, karakteristike senzora i samog uređaja za snimanje. Očigledno je da svaka pojedinačna točka (eng. *pixel*) u sebi uključuje niz informacija, ali u slici svaka točka ima samo jednu vrijednost osvjetljenja u slučaju jednobojne slike. Osim toga kako se radi o dvodimenzionalnoj projekciji, gube se i informacije o trećoj dimenziji (Barrow et al, 1981).

Da bi iz slike dobili opis odnosno model scene iz koje je slika nastala, potrebno nam je velika količina informacija i znanja. Model scene opisuje trodimenzionalni svijet u terminima površina i objekata. Površine imaju niz svojstava, od oblika i nagiba, pa do svojstava refleksije svjetla iz različitih izvora. Objekti također uključuju površine i njihova svojstva, a osim toga mogu se i kretati u različitim smjerovima i različitim brzinama ako model uključuje i vremensku dimenziju. Uz navedeno model scene uključuje i osvjetljenje koje ima cijeli niz svojstava od intenziteta osnovnog izvora, valne dužine i lokacije istog, pa preko svojstava refleksija koje ovise o objektima i površinama, te na kraju i sjena koje su također rezultat razmještaja i površina objekata. Osim navedenog u model scene treba uzeti u obzir i senzor, odnosno uređaj kojim je slika scene dobivena, jer svaki uređaj i senzor utječu na niz svojstava prilikom snimanja (Barrow et al, 1981).

Za računalni vid se može reći da je slijed obrade informacija u kojem je svaka karika značajna. Na nižim razinama apstrakcije za karike tog slijeda se može reći da pripadaju određenim inženjerskim disciplinama i to optičkom, elektro i programskom inženjeringu. Slika 21 prikazuje taj slijed kako ga predlaže Hornberg (Hornberg, 2017).

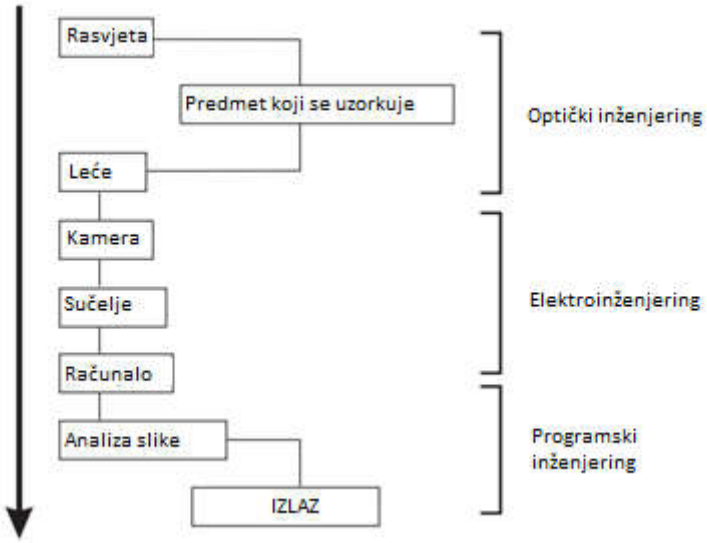

Slika 21 – Slijed obrade informacija kod računalnog vida (Hornberg, 2017)

Optički inženjering bavi se emisijom svjetlosti, uzorkovanjem iste, kao i lećama. Kamerama, sučeljima i računalima bavi se elektro inženjering, dok se programski inženjering bavi djelomično računalima, a uglavnom analizom slike i samim izlaznim informacijama cijelog slijeda.

4.1.1. Osnovne podatkovne strukture

Računalni vid je kao što je prethodno navedeno kompleksan slijed obrade podataka, a posljednji dio koji se odvija na računalima uključuje niz algoritama koji obrađuju ulazne podatke dobivene od prethodnih razina obrade. Osnovne podatkovne strukture koje se susreću na algoritamskoj razini su slike, područja i konture (Steger, 2017).

4.1.1.1. Slike

Slika je osnovna podatkovna struktura koja se nalazi pohranjena u memoriji računala. Slika se sastoji od niza točaka (eng. *pixela*), a točke se mogu opisati kao registrirani uzorci energije na senzoru za vrijeme uzorkovanja koji ovise o spektralnoj distribuciji svjetlosti i spektralnim svojstvima senzora. Najčešće se uzorkuje vidljivi spektar i infracrveno područje spektra. Za vidljivi spektar za svaku točku (eng. *pixel*) kamera šalje tri vrijednosti i to intenzitet crvene, zelene i plave boje, za što se često navodi da se radi o tri kanala. Infracrveno područje prikazuje se jednim kanalom. Ako je kamera u mogućnosti uzorkovati većom brzinom niz pojedinačnih slika nazivamo videom, a za graničnu vrijednost može se uzeti deset slika u sekundi kako je predložio Sutcliffe (Steger, 2017)(Sutcliffe, 2008).

Jedan kanal slike se može matematički prikazati kao dvodimenzionalno polje brojeva, odnosno kao matrica $g = f_{r,c}$. Varijable r i c označavaju broj redova i stupaca slike, pri čemu je $f : R \rightarrow \mathbb{R}$. Slika s više kanala može se prikazati kao funkcija $f : R \rightarrow \mathbb{R}^n$, pri čemu je n broj kanala. U većini situacija vrijednosti za pojedini točke (eng. *pixel*) će biti diskretne, a broj mogućih razina svakog kanala je konačan broj. U pravilu se kvantizira do dubine od 8 bitova, odnosno ukupan broj mogućih vrijednosti je $G_8 = \{0,\ldots,255\}$, dok se u nekim slučajevima koriste i veće vrijednosti kvantizacije. Općenito vrijedi za sliku s jednim kanalom $f : R \rightarrow G_b$, gdje je $G_b = \{0, \ldots, 2^b - 1\}$ (Steger, 2017).

Slika 22 – Slika u nijansama sive boje uzorkovana (Jimenez-Fernandez, 2016)

Slika 22 je u nijansama sive boje uzorkovana u niskoj razlučivosti s ciljem isticanja pojedinih piksela. S obzirom da navedena slika ima 30 stupaca i 30 redova te je osmobitno kvantizirana, nijansa sive boje svakog piksela je definirana prirodnim brojem između 0 i 255, te cijela slika bez kompresije zauzima 900 bajtova memorije.

Za razliku od slika prikazanih u nijansama sive boje, slike u boji zauzimaju tri puta više memorijskog prostora iz razloga što se za svaku točku treba pohraniti intenzitet primarnih boja, crvene, zelene i plave boje, uz pretpostavku da su slike pohranjene bez sažimanja. Valne duljine primarnih boja definirala je organizacija International Commision on Illumination 1931. godine i to za:

a) crvenu boju – 700 nm
b) zelenu boju – 546,1 nm
c) plavu boju – 435,8 nm (Wright, 2007)(Jones, 1943)

Slika 23 prikazuje nastanak višebojne slike kao rezultat spajanja tri slike koje uključuju primarne boje.

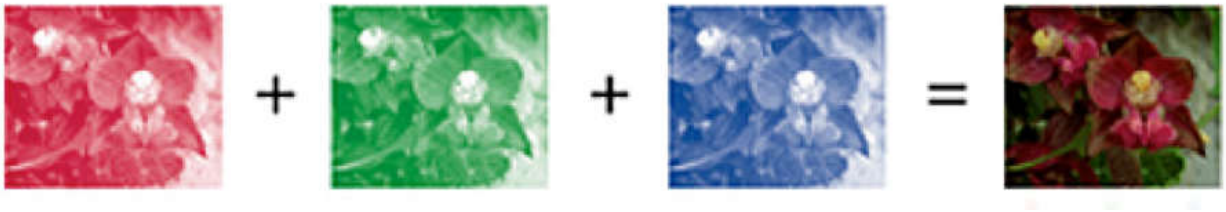

Slika 23 – Nastanak višebojne slike (BrainHQ, 2016)

4.1.1.2. Područja

Jedan od čestih zadataka računalnog vida je identifikacija područja slike koja imaju određena svojstva. Područje se može definirati kao proizvoljni podskup ravnine $R \subset \mathbb{Z}^2$, a osnovna prednost njihovog korištenja je ograničavanje veličine površine slike koja se obrađuje. Česta kratica koja se pojavljuje u literaturi za područje interesa kod slike je ROI, (eng. *Region of interest)*. Matematički područja možemo definirati na sljedeći način:

$$\chi_R(r,c) = \begin{cases} 1, (r,c) \in R \\ 0, (r,c) \notin R \end{cases}$$

Iz prethodnog izraza je jasno da će se za prezentiranje područja koristiti binarne slike, odnosno polja. Vrijednost 0 za pojedinu točku (eng. *pixel*) ukazuje da ista nije uključena u područje, dok vrijednost 1 ukazuje da je točka uključena. Ako za uključene točke koristimo cijele brojeve koji su veći od nule, dodjeljivanjem različitih brojeva možemo označavati i samim tim razlikovati više objekata na slici. Nedostatak ovakvog pristupa je u tome što je za svako područje najčešće potrebno imati polje veličine same slike iz razloga što je zbog brzine obrade praktičnije bitove zapisivati u bajtove u memoriji. Jedan od načina da se to izbjegne je zapisivanje nizova točaka koji pripadaju u područje interesa, pri čemu se ne gubi memorijski prostor za točke koji ne pripadaju u područje interesa. Slika 24 i tablica 6 prikazuju dva područja, kao i sažeti zapis područja pri čemu su zapisane samo točke koje pripadaju području interesa (Steger, 2017).

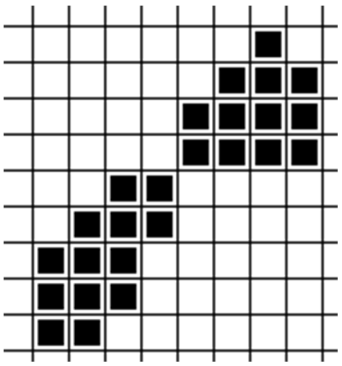

Slika 24 – Dva područja (Loomis, 1998)

Prolaz	Red	Početni stupac	Krajnji stupac
1	1	7	7
2	2	6	8
3	3	5	8
4	4	5	8
5	5	3	4
6	6	2	4
7	7	1	3
8	8	1	3
9	9	1	2

Tablica 6 – Sažeti prikaz područja

Područje se pri tome može definirati kao unija:

$$R = \bigcup_{i=1}^{n} \boldsymbol{r}_i$$

pri čemu je r_i svaki odvojeni niz piksela područja interesa slike (Steger, 2017).

4.1.1.3. Konture preciznije od piksela

Podatkovne strukture čija točnost može biti i manja od piksela su treća najčešća podatkovna struktura koja se susreće u radu s algoritmima računalnog vida. Konture se zapisuju kao niz točaka definiranih parovima brojeva s pomičnim zarezom, pri čemu jedan broj određuje vrijednost po vodoravnoj, a drugi po okomitoj osi. Konture mogu biti zatvorene i otvorene. Slika 25 prikazuje

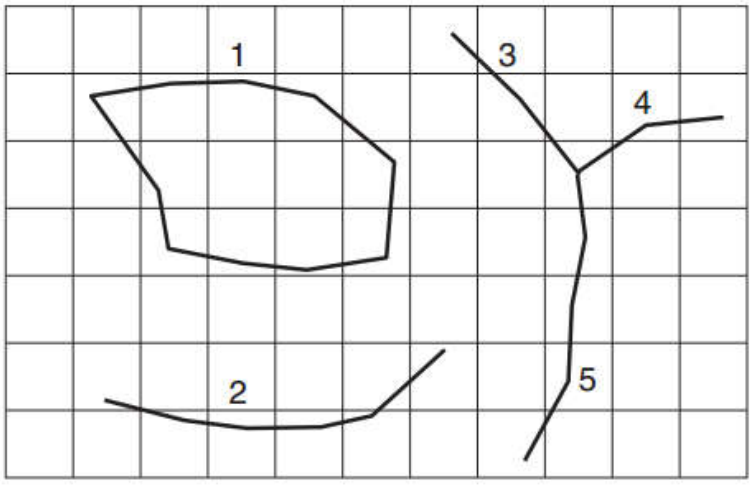

Slika 25 – Različite konture preciznije od piksela (Steger, 2017).

pet različitih kontura pri čemu je kontura broj 1 zatvorena, dok su ostale otvorene. Konture 3, 4 i 5 imaju spojnu točku ili čvorište (Steger, 2017).

4.1.2. Vrste deskriptora

Jedan od temeljnih pojmova vezanih uz računalni vid je deskriptor, a osnovna podjela je na deskriptore više i niže razine. Deskriptori mogu biti kontinuirane ili diskretne brojčane ili simboličke vrijednosti, ali isto tako i tekstualni opisi. U nastavku su razjašnjene razlike između deskriptora niže i više razine.

U deskriptore niže razine Ballard i suradnici ubrajaju granice objekata, boje i osvijetljenost objekata, udaljenosti objekata i slično. Jedan od deskriptora niže razine je percepcija objekta, odnosno mogućnost razdvajanja istog od pozadine (Ballard et al, 1982)

Martinet i Elasyad deskriptore niže razine definiraju kao „kontinuiranu ili diskretnu numeričku ili simboličku mjeru koja je izračunata direktno iz signala (npr. točka slike), lokalno u dokumentu“. Autori koriste kraticu LLD (eng. *Low-level descriptor*) te navode da se obično radi o histogramu boja, te deskriptorima tekstura i oblika. Deskriptori niže razine se izračunavaju, odnosno dobivaju direktno iz signala, odnosno slike, a mogu se dobiti iz dijela slike ili iz kompletne slike (Martinet et al, 2012).

Ballard i suradnici smatraju da se deskriptori više razine odnose na svojstva objekata na slici i razumijevanje konteksta same slike, a za to je potrebna velika količina znanja o objektima, od njihovog izgleda, preko ponašanja i ostalih svojstava (Ballard et al, 1982).

Martinet i Elasyad deskriptore više razine definiraju kao „dio semantičke informacije koju može interpretirati čovjek, a opisuje dokument ili jedan njegov dio“. Autori koriste kraticu HLD (eng. *High-level descriptor*) te navode da se obično radi o tekstualnom opisu ili skupu ključnih riječi.

4.1.2.1. Semantički jaz i modeli povezivanja deskriptora

Smeulders i suradnici ukazuju na problem semantičkog jaza koji postoji pri pretraživanju slika na bazi sadržaja, pri čemu korisnici očekuju da računala prepoznaju sadržaj slike poput njih. S jedne strane vrlo jednostavno se mogu uz pomoć algoritama izračunati

deskriptori niže razine, dok se deskriptori više razine znatno teže izračunavaju, odnosno definiraju. Autori predlažu integraciju vanjskih izvora kao rješenje, a posebice izdvajaju obradu govora i računalni vid (Smeulders et al, 2000).

Razvojem razinskog modela deskriptora scena, odnosno slika, pojavili su se autori koji smatraju da bi trebala postojati i srednja razina. Luo i Savakis su predložili kategorizaciju scena na unutrašnje (eng. *indoor*) i vanjske (eng. *outdoor*) kao metodu koja se koristi nakon primjene metoda niže razine, pri čemu su predložili korištenje postojećih informacija o svojstvima trave i neba za navedenu klasifikaciju (Luo et al, 2001) Martinet i suradnici smatraju da je rješenje spomenutog semantičkog jaza u deskriptorima srednje razine (eng. *mid-level descriptors*). Autori deskriptore srednje razine definiraju kao „kontinuiranu ili diskretnu brojčanu ili simboličku mjeru dobivenu poslije ukupne analize deskriptora niže razine, po mogućnosti primjenjujući kontrolirane ili nekontrolirane metode učenja na podskupu dokumenata u zbirci eventualno uključujući i upotrebu vanjskog znanja“. Autori za deskriptore srednje razine predlažu kraticu MLD (eng. *Mid-level descriptor*). Deskriptori srednje razine mogu biti ulazne varijable za izračun drugih deskriptora srednje ili više razine, dok ulazni varijable za izračun deskriptora srednje razine mogu biti samo deskriptori niže razine.

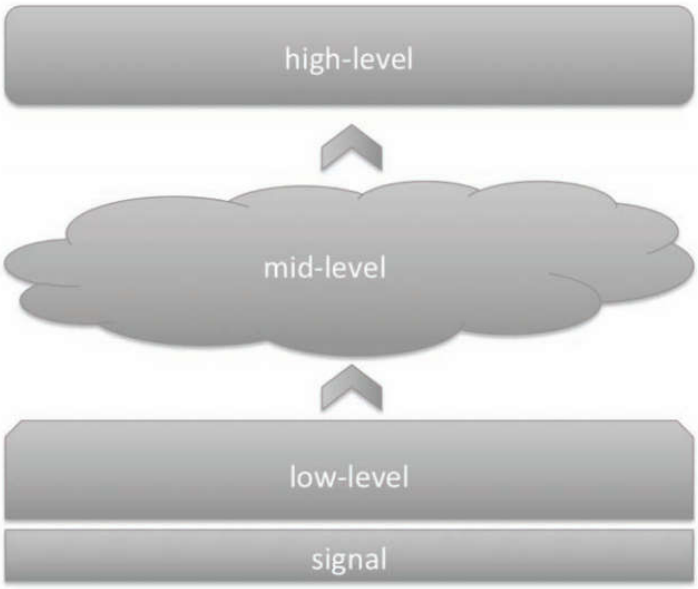

Slika 26 – Deskriptor srednje razine u odnosu na ostale (Martinet et al, 2012)

Slika 26 prikazuje odnos deskriptora srednje razine i ostalih deskriptora te ulaznog signala, odnosno slike (Martinet et al, 2012).

Slika 27 prikazuje primjer u kojem se deskriptor srednje razine i to rezultat algoritma za detektiranje lica prosljeđuje algoritmu za prepoznavanje lica. S obzirom da deskriptor više razine uključuje i značenje, izlaz algoritma za prepoznavanje lica je deskriptor više razine (Martinet et al, 2012).

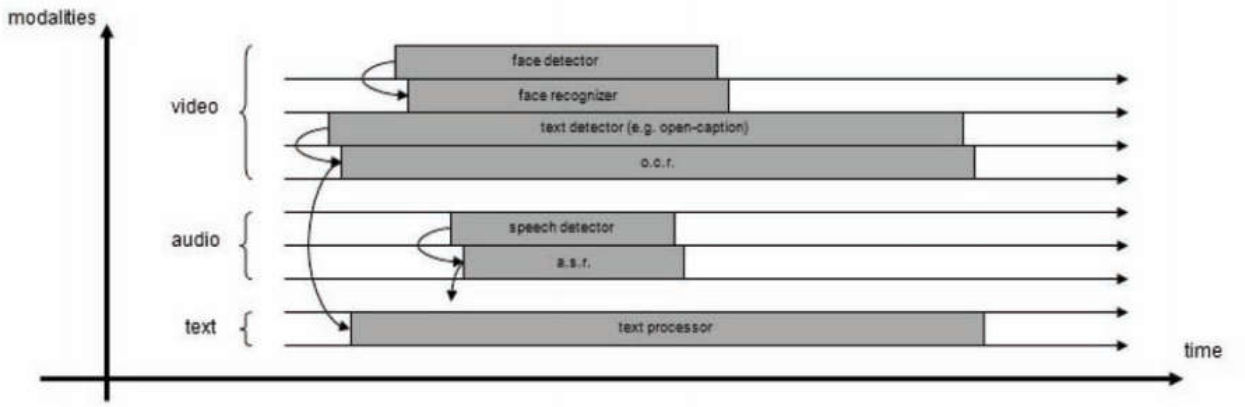

Slika 27 – Primjer deskriptora srednje razine (Martinet et al, 2012)

Novija istraživanja na području deskriptora uključuju protok informacija u oba smjera između niže i više razine. Očekivano, u počecima su deskriptori niže razine služili kao ulazni podatci višim razinama obrade i interpretacije, ali već neko vrijeme postoje autori koji koriste deskriptore sa viših razina za unaprjeđenje procesa na nižim razinama. Jedan od prvih autora koji je ukazao na tu mogućnost je Arens sa suradnicima, koji su model odnosno konceptualno znanje iskoristili za poboljšanje performansi analize na nižim razinama, a radilo se konkretno o praćenju vozila na prometnicama (Arens et al, 2004)(Hotz et al, 2008).

4.2.Algoritmi računalnog vida

Velik doprinos u poimanju računalnog vida dao je Marr sa svojom trorazinskim opisom obrade vizualnih informacija. Autor navodi sljedeće tri razine:

a) računalna teorija – definira cilj obrade, poznata ograničenja i način rješavanja problema na teorijskoj razini,
b) algoritamska razina – načini prikaza ulaznih i izlaznih podataka, kao i podataka u samoj obradi, te koji se algoritmi koriste da bi dobili željeni rezultat,
c) implementacija hardvera – kako se algoritmi implementiraju u stvarni hardver, te kako hardver utječe na izbor algoritma (Marr, 1982).

U nastavku je naglasak na algoritamskoj razini, mada se navedene razine često prožimaju i vezane su.

Razvoj algoritama računalnog vida počeo je šezdesetih godina prošlog stoljeća i to sa dosta optimizma na što ukazuje plan da će se dobar dio problema riješiti tokom ljeta 1966. godine. Navedeno se vidi u pozivu na ljetni skup jednog poznatog visokog učilišta s ciljem računalnog rješavanja problema razdvajanja objekata iz pozadine i imenovanja objekata na osnovu poznatih objekata (Papert, 1966).

4.2.1. Podjela algoritama računalnog vida

U literaturi ne postoji konsenzus s obzirom na podjelu algoritama računalnog vida. U nastavku su dane dvije podjele bez dublje analize. Ritter i Wilson dijele algoritme u jedanaest kategorija, a u samom nazivlju se izmjenjuju termini algoritam i tehnika. U nastavku je navedena njihova podjela:

a) tehnike za povećanje kvalitete slike,
b) tehnike za pronalaženje rubova i granica,
c) tehnike definiranja praga,
d) stanjivanje i izrada strukture,
e) algoritmi povezivanja komponenti,
f) morfološke transformacije i tehnike,
g) linearne transformacije slike,
h) podudaranje uzoraka i detekcija oblika,
i) svojstva slike i deskriptori,
j) geometrijske transformacije slike,
k) neuronske mreže (Ritter et al, 2001).

Steger također dijeli algoritme na jedanaest kategorija, pri čemu se neke preklapaju sa kategorijama predloženima od Ritter i Wilson:

a) algoritmi za povećanje kvalitete slike,
b) algoritmi za geometrijske transformacije,
c) algoritmi za segmentaciju,
d) algoritmi za ekstrakciju svojstava,
e) morfološki algoritmi,
f) algoritmi za pronalaženje rubova ,

g) algoritmi za usklađivanje s osnovnim geometrijskim oblicima,
h) algoritmi za kalibraciju kamera,
i) algoritmi za rekonstrukciju prikaza s dvije kamere,
j) algoritmi za podudaranje s predlošcima,
k) algoritmi za prepoznavanje znakova (Steger, 2017).

Bez obzira na isti broj kategorija, uočava se razlika u pristupu pri čemu se može reći da je podjela Ritter i Wilson na višoj razini apstrakcije, dok su kategorije predložene od Stegera znatno konkretnije i bliže razini primjene. Razlog tome je i što pojedini autori prave razliku između pojmova računalnog i strojnog vida, pri čemu je računalni vid, i pripadajući mu algoritmi, apstraktniji. Iz podjele se vidi da je Steger bliži pojmu strojnog vida.

4.2.2. Algoritmi za detekciju pokretnih objekata

Jedno od temeljnih područja računalnog vida je detekcija pokreta, odnosno pokretnih objekata. Zbog različitih pristupa u kategorizaciji ovi algoritmi se ne nalaze pod imenom iz naslova u navedenim podjelama, mada pripadaju u algoritme za segmentaciju po podjeli Steger-a, odnosno pripadaju u tehnike za pronalaženje rubova i granica u širem smislu po podjeli Ritter i Wilson.

Cilj detekcije pokretnih objekata je jasan iz samog naziva, a odvija se na način da se analizira video pri čemu se razlikuju pokretni objekti od pozadine. Shaikh i suradnici navode tri različita pristupa koji se koriste pri detekciji pokretnih objekata:

a) metoda optičkog toka,
b) metoda vremenskog razlikovanja
c) metoda uklanjanje pozadine.

Sva tri su kratko opisana u nastavku kroz primjere algoritama koji pripadaju navedenim kategorijama (Shaikh et al, 2014).

a) metoda optičkog toka; Paragios i suradnici su za detekciju i praćenje više pokretnih objekata u video sadržajima predložili model koji za detekciju pokreta koristi statistički model razlike funkcije gustoće između pojedinih slika. Model se sastoji od dvije komponente, statične (pozadina) i pokretne (objekti koji se kreću), a za definiranje pokretnih objekata koristi se početna slika video isječka na kojoj nema pokretnih objekata (Paragios et al, 2000).

b) metoda vremenskog razlikovanja; Fejes i suradnici su predložili model koji se temelji na kombinaciji projekcija polja vizualnog gibanja i kvalitativnih procjena usmjerenog gibanja. Jedna od prednosti modela je što se može koristiti i kod pokretnih kamera i pri velikim brzinama snimanih objekata (Fejes et al, 1999)
c) metoda uklanjanje pozadine; Piccardi je u svom radu dao pregled metoda za uklanjanje pozadine pri čemu navodi da se taj pristup detekcije pokretnih objekata bazira na razlici između trenutne i referentne slike koja se u pravilu naziva „slika pozadine“ ili „model pozadine“. Autor navodi da se referentna slika uzima kada nema pokretnih objekata te da se treba osvježavati po potrebi (Piccardi, 2004)

U disertaciji se koriste algoritmi za uklanjanje pozadine tako da će u nastavku biti riječi isključivo o njima, a na tom području razvijen je niz algoritama koji se konstantno usavršavaju. Prvi algoritmi te kategorije korišteni su već sedamdesetih godina prošlog stoljeća (Jain, 1979), dok ih danas ima niz na raspolaganju i izbor odgovarajućeg algoritma ovisi o prednostima i nedostacima istog u ovisnosti o specifičnostima primjene. Pojednostavljeno, algoritmi obrađuju video sadržaje na način da se kao izlaz obrade dobije dvobojni video sadržaj pri čemu je jedna boja detektirani pokretni objekt dok je druga nepomična pozadina. Koristeći omjer broja točaka (eng. *pixel*) detektiranih pokretnih objekata i ukupnog broja točaka u nekom video isječku može se kvantificirati količina pokreta u video sadržaju što je ključna ideja u disertaciji, a taj pristup će detaljno biti analiziran i istražen.

Sonka i suradnici s druge strane praktične probleme vezane uz kretanje u video sadržajima dijele u tri grupe. To su:

a) Detekcija pokreta – najjednostavnija grupa problema u kojoj se u pravilu koristi statična kamera i potrebno je samo detektirati kretanje. Najčešće se koristit u sustavima za nadzor.
b) Detekcija objekta koji se kreće i njegove lokacije – kompleksnija grupa problema u kojoj se očekuje da se definira sam objekt koji se kreće i ponekad da se predvidi dalje kretanje istog. Kamera se u nekim situacijama može i kretati pa i to treba uzeti u obzir.
c) Izvođenje svojstava trodimenzionalnog objekta od skupa dvodimenzionalnih projekcija snimljenih u različitim vremenskim trenucima gibanja objekta svakako spadaju u najkompleksniju grupu problema (Sonka et al, 1993).

Algoritmi koji će se koristiti u daljem radu pripadaju u prvu kategoriju navedene podjele. Radi se o algoritmima za uklanjanje pozadine, koji će detaljnije biti analizirani u nastavku.

4.3.Algoritmi za uklanjanje pozadine

Shaikh i suradnici navode da je „uklanjanje pozadine često korišten pristup detekcije pokretnih objekata u video sadržajima nastalih uz korištenje statičnih kamera“ (Shaikh et al, 2014).

Bouwmans opisuje i grafički prikazuje općenitu shemu funkcioniranja algoritama za uklanjanje pozadine koja se sastoji od 3 aktivnosti:

a) Inicijalizacija pozadine (eng. *Background Initialization*)– na osnovu određenog broja slika koristeći neku od metoda definira se izgled, odnosno model nepokretne pozadine,
b) Detekcija pokretnih objekata – upoređivanje trenutnih slika video isječka ili toka sa modelom nepokretne pozadine detektiraju se pokretni objekti,
c) Održavanje pozadine (eng. *Background Maintenance*) – za vrijeme detekcije model nepokretne pozadine se osvježava ovisno o promjenama u video isječku ili toku (Bouwmans, 2012).

Slika 28 grafički prikazuje proces uklanjanja pozadine (Bouwmans, 2012).

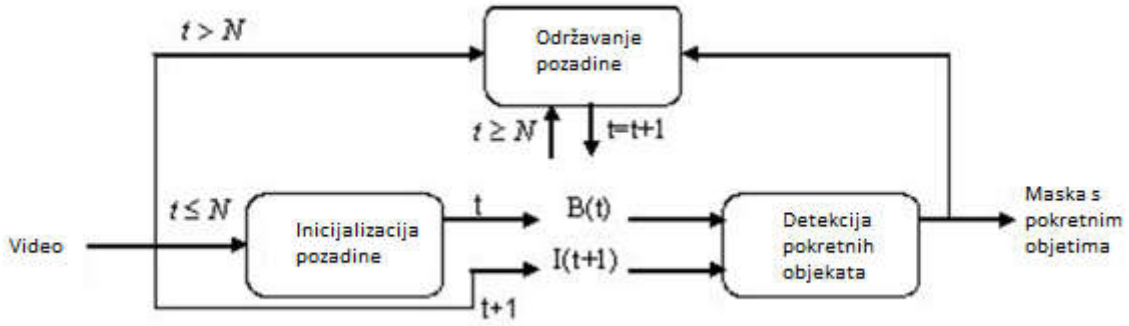

Slika 28 – Proces uklanjanja pozadine (Bouwmans, 2012)

Benezeth i suradnici navode standardnu formulu brojnih metoda uklanjanja pozadine:

$$X_t(s) = \begin{cases} 1 \; ako \; d(\mathbf{I}_{s,t}, \mathbf{B}_s) > \tau \\ 0 \; ako \; nije \end{cases}$$

pri čemu je τ prag, X_t je polje oznaka pokreta u vremenu t, d je razlika između $I_{s,t}$ (boja u vremenu t i piksela s) i $\mathbf{B}_s$ modela pozadine piksela s. Između različitih algoritama ključan je način na koji se modelira **B** i kako se računa razlika d (Benezeth et al, 2010).

U stvarnim situacijama pozadina nije u potpunosti statična te dolazi do promjena pri čemu se neznatne promjene pozadine ne bi trebale registrirati kao pokretni objekt. Shaikh i suradnici navode osnovne probleme s kojima se suočavaju autori algoritama za uklanjanje pozadine, a to su:

a) promjene osvjetljenja – do njih dolazi kada se npr. u prostoru koji se analizira uključi električna rasvjeta,
b) dinamična pozadina – radi se o promjenama u prirodi kao što su njihanje listova drveta ili pomicanje oblaka na nebu,
c) zatvaranje – pojava djelomičnog ili potpunog zaklanjanja područja snimanja,
d) „*clutter*“ – prisutnost većeg broja objekata koji se razlikuju po obliku i boji u pozadini može znatno otežati razlikovanje objekata od pozadine,
e) zakrivanje - namjerno ili nenamjerno, pojedini objekti se neznatno razlikuju od pozadine što znatno komplicira otkrivanje pokretnih objekata,
f) sjene – pojava zasjenjenja zbog točkastih izvora svjetlosti dodatno komplicira otkrivanje stvarnih granica pokretnog objekta, što je još izraženije kod preklapanja sjena,
g) pomicanje kamere – prilikom snimanja videa može doći do vibracija kamere što također može otežati otkrivanje,
h) „bootstrapping“ – ako pri pokretanju snimanja ne postoji prethodno pohranjena slika pozadine, tada se ona generira iz prve ili nekoliko prvih slika, pri čemu može doći do greške ako u početku ispred kamere nalazi neki objekt koji ne pripada pozadini,
i) šum – video signal u pravilu uključuje i šum koji može nastati zbog sažimanja video signala ili nesavršenosti senzora, te se i o tome treba voditi računa pri razvoju algoritma,
j) brzina pomicanja objekata – u slučaju sporog pomicanja objekta neki algoritmi će ga označiti kao pozadinu, dok se kod izrazito brzih objekata pojavljuje takozvani „*ghosting*“ efekt,
k) izmjena vremenskih prilika – radi se o padalinama, olujama i izmjenama krajolika zimi nakon što padne snijeg (Shaikh et al, 2014).

Tablica 7 prikazuje kategorizaciju metoda koju predlažu autori u svom radu, kao i opis samih modela (Benezeth et al, 2010).

Tablica 7 – Metode uklanjanja pozadine (Benezeth et al, 2010)

Metoda	Opis
Osnovna (eng. *Basic*)	Model je slika u boji nepokretnih objekata
1-G	Model svakog piksela je Gaussova distribucija
MinMax	Model se sastoji on minimalnih i maksimalnih vrijednosti, kao i maksimalna vrijednost između uzastopnih slika
GMM	Model svakog piksela je mješavina Gaussovih distribucija
KDE	Model svakog piksela je neparametrijska distribucija
CB_{RGB}	Model se sastoji od skupa Gaussovih distribucija
Eigen	Model nije baziran na pikselima, nego koristi svojstvene vektore

Slika 29 prikazuje klasifikaciju metoda uklanjanja pozadine koju su predložili Bayona i suradnici.

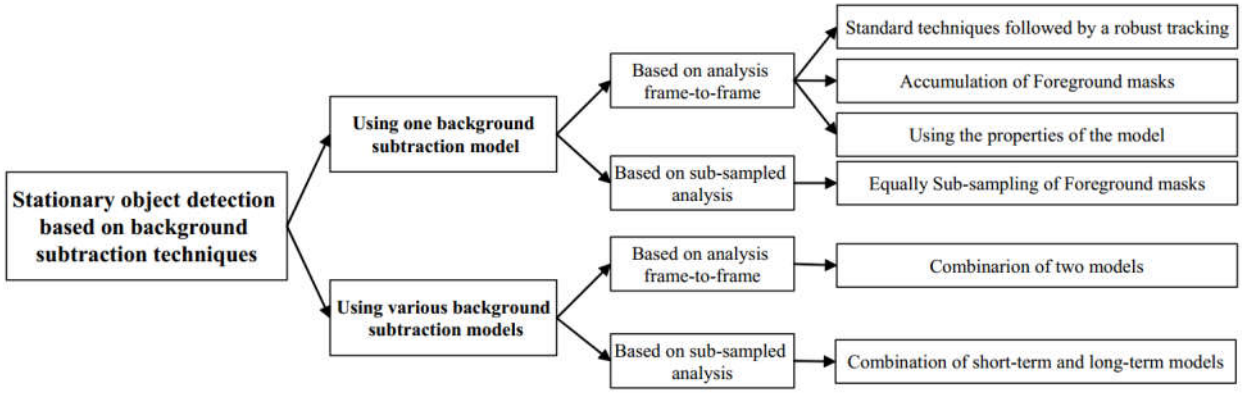

Slika 29 – Klasifikacija metoda uklanjanja pozadine za detekciju stacionarnih objekata (Bayona et al, 2009)

Piccardi je u svom pregledu metoda za uklanjanje pozadine nabrojio sedam različitih metoda i to:

a) *Running Gaussian average*
b) *Temporal median filter*
c) *Mixture of Gaussians*
d) *Kernel density estimation*(KDE)
e) *Sequential KD approximation*
f) *Cooccurence of image variations*
g) *Eigenbackgrounds* (Piccardi, 2004)

Nazivi metoda su navedeni na engleskom jeziku radi prepoznatljivosti.

Sobral je predložio drugačiju podjelu i to u devet kategorija, a njegov doprinos na području računalnog vida očituje se u tome što je pripremio nekih tridesetak kategoriziranih algoritama za uklanjanje pozadine i omogućio njihovo korištenje u obliku programske biblioteke. S obzirom da se spomenute programske biblioteke koriste u istraživačkom dijelu, u nastavku je dana kategorizacija koju je autor predložio (Sobral, 2013).

U kategoriji osnovnih metoda autor navodi:

a) statička razlika slika (eng. *Static Frame Difference*)
b) razlika slika (eng. *Frame Difference*)
c) ponderirano kretanje srednje vrijednosti (eng. *Weighted Moving Mean*)
d) ponderirano kretanje varijance (eng. *Weighted Moving Variance*)
e) prilagodljivo „učenje“ pozadine (eng. *Adaptive Background Learning*)
f) prilagodljivo selektivno „učenje“ pozadine (eng. *Adaptive Selective Background Learning*)
g) vremenska srednja vrijednost (eng. *Temporal Mean*) (Parks, 2013, po Sobral, 2013)
h) adaptivni medijan (eng. *Adaptive Median*) (McFarlane et al, 1995)
i) vremenski medijan (eng. *Temporal Median*) (Calderara et al, 2006)
j) Sigma-Delta (Lacassagne et al, 2009)

Većina algoritama koji pripadaju osnovnim metodama su implementirani u programsku biblioteku OpenCV, dok posljednja četiri nisu. Radi se o jednostavnijim algoritmima, pa tako prvi od navedenih (eng. *Static Frame Difference*) najčešće zahtijeva definiranje statičke slike na kojoj nema pokretnih objekata, a za svaki snimljenu sliku „prepoznaje“ objekt koji se kreće

na način da uspoređuje statičku sliku sa snimljenom na razini pojedinih piksela. Osnovni nedostatak te metode je činjenica da je osjetljiva na promjenu osvjetljenja. Parcijalno rješenje nedostatka navedene metode nudi drugi algoritam (eng. *Frame Difference*) kod kojeg se slika uspoređuje sa prethodnom u slučaju videa, čime se donekle rješava problem sporije izmjene osvjetljenja, ali pojavljuje se nedostatak da se pokretni objekt u mirovanju od trenutka zaustavljanja ne registrira kao pokretni objekt. U ovoj kategoriji su nazivi algoritama prevedeni na hrvatski jezik, dok su u ostalima ostavljeni u originalu (Sobral, 2013).

U kategoriji metoda zasnovanih na neodređenoj (eng. *fuzzy*) logici autor navodi:

a) *Fuzzy Sugeno Integral* (Zhang et al, 2006)
b) *Fuzzy Choquet Integral* (El Baf et al, 2008)
c) *Fuzzy Gaussian* (Sigari et al, 2008).

U ovoj kategoriji koriste se različiti pristupi, a El Baf predlaže da se osim boja za razlikovanje pozadine od pokretnih objekata koriste i teksture, odnosno njihova sličnost. Pri tome se za izračun koristi tzv. *Choquet* integral, koji se računa za svaku točku (eng. *pixel*) slike. I u ovom modelu postoji granična vrijednost koja se koristi da bi se točku slike proglasilo pokretnim objektom ili pozadinom (El Baf et al, 2008).

U kategoriji metoda zasnovanih na Gaussovoj distribuciji autor navodi:

a) *Gaussian Average* (Wren et al, 1997)
b) *Simple Gaussian* (Benezeth et al, 2008)

Prva navedena metoda pretpostavlja da su vrijednosti pojedinačnih točaka (eng. *pixel*) distribuirane po Gaussovoj distribuciji, bez obzira radilo se o pojedinačnim komponentama boja svake točke ili svjetlina ako je riječ o nijansama sive boje. Wren predlaže da se u trenutku t vrijednost za trenutnu točku slike μ_t računa iz sljedeće formule:

$$\mu_t = \alpha I_t + (1-\alpha)\mu_{t-1}$$

pri čemu je I_t trenutna vrijednost točke, a μ_{t-1} prethodni prosjek vrijednosti, dok je α vrijednost koja se izabire s ciljem postizanja stabilnosti, odnosno brzog osvježavanja. Osim navedenog standardna devijacija σ_t se također može računati na sličan način, a odluka je li pojedina točka slike pokretni objekt svodi se na izračun sljedećeg izraza:

$$|I_t - \mu_t| > k\,\sigma_t$$

pri čemu s varijablom k definiramo osjetljivost algoritma (Wren et al, 1997) (Piccardi, 2004).

Benezeth i suradnici su predložili da se razlika dviju točaka (eng. *pixel*) promatra u višedimenzionalnom prostoru, te da se koristi Mahalanobis udaljenost u izračunu (Benezeth et al, 2008).

U kategoriji metoda zasnovanih na višestrukim Gaussovim distribucijama autor navodi:

a) *Gaussian Mixture Model* (Stauffer et al, 1999)
b) *Gaussian Mixture Model* (Kaewtrakulpong et al, 2001)
c) *Gaussian Mixture Model* (Zivkovic et al, 2006)
d) *Gaussian Mixture Model* (Zivkovic et al, 2006)
e) *Gaussian Mixture Model* (Bouwmans et al, 2008)

U stvarnim situacijama često se događa da se neki dijelovi slike znatno izmjenjuju, a opet pripadaju pozadini. Dobar primjer za to je drvo ispred zgrade pri čemu u nekim trenutcima pojedine točke (eng. *pixel*) prikazuju list, dok u drugim trenutcima prikazuju zgradu. Da bi riješili taj problem gore navedeni autori predložili su više metoda u kojima pojedinoj točki može pripadati više Gaussovih krivulja. Stauffer i suradnici su predložili da je funkcija vjerojatnosti za pojedinu točku *x* u trenutku *t*:

$$P(x_t) = \sum_{i=1}^{K} \omega_{i,t}\eta(x_t - \mu_{i,t}, \Sigma_{i,t})$$ (Piccardi, 2004).

K je broj Gaussovih distribucija, a u praksi se radi o broju između 3 i 5. Autori predlažu i kriterij kojim se donosi odluka da li je točka u pozadini, na način da su kompaktnije distribucije sa većim vrijednostima vrha vjerojatno pozadine (Stauffer et al, 1999).

U kategoriji drugog tipa metoda zasnovanih na neodređenoj (eng. *Fuzzy*) logici autor navodi:

a) *Type -2 Fuzzy GMM-UM* (El Baf et al, 2008a)
b) *Type -2 Fuzzy GMM-UV* (El Baf et al, 2008a)
c) *Type -2 Fuzzy GMM-UM with MRF* (Zhao et al, 2012)
d) *Type-2 Fuzzy GMM-UV with MRF* (Zhao et al, 2012)

Kratica GMM označava eng. *Gaussians Model Mixture*, dok UM označava eng. *Uncertain Mean Vector*. Kratica UV označava eng. *Uncertain Variance Vector*, a kratica MRF dolazi od eng. *Markov Random Field*. Radi se o metodama koje su pokazale odlične rezultate kod dinamičnih pozadina, kao što je lišće na vjetru i slično.

U kategoriji metoda zansovanih na više značajki (eng. *Multiple features based methods*) autor navodi nekoliko metoda:

a) *Texture BGS* (Heikkila et al., 2006)
b) *Texture-Based Foreground Detection with MRF* (Kertesz et al, 2011)
c) *Multi-Layer BGS* (Yao et al, 2007)
d) *MultiCue BGS* (Noh et al, 2012)
e) *SuBSENSE* (St-Charles et al., 2014)
f) *LOBSTER* (St-Charles et al., 2014a)

Po samom nazivu je jasno da se u ovoj kategoriji nalaze metode koje svojstvima ne pripadaju u ostale navedene.

U kategoriji neparametrijskih metoda (eng. *Non-parametric methods*) autor navodi:

a) *Pixel-Based Adaptive Segmenter* (Hofmann et al, 2012)
b) *GMG* (Godbehere et al, 2012)
c) *VuMeter* (Goyat et al, 2006)
d) *KDE* (Elgammal et al, 2000)
e) *IMBS* (Bloisi et al, 2012)

Zajedničko za navedene metode je da koriste neparametrijske metode za model vjerojatnosti pripadanja pozadini pojedinih točaka (eng. *pixel*). Goyat navodi da je razlog ušteda memorijskog prostora (Goyat et al, 2006).

U kategoriji metoda temeljenih na podprostoru (eng. *Subspace-based methods*) autor navodi samo jednu:

a) *Eigenbackground* / SL-PCA (Oliver et al, 2000)

U kategoriji neuronskih i *neuro-fuzzy* metoda (eng. *Neural and neuro-fuzzy methods*) autor navodi:

a) *Adaptive* SOM (Maddalena et al, 2008)
b) *Fuzzy Adaptive* SOM (Maddalena et al, 2010)

U ovoj posljednjoj kategoriji metode se temelje na neuronskim mrežama koje se generiraju na osnovu video snimka pozadine bez pokretnih objekata.

II ISTRAŽIVAČKI DIO

"I hear and I forget.
I see and I remember.
I do and I understand."
Confucius, an ancient Chinese philosopher (405 B.C.)

5. MODEL, PODATCI I METODOLOGIJA

5.1. Model zasnovan na algoritmima za uklanjanje pozadine

U ovom poglavlju predstavljen je model koji će se u nastavku koristiti za mjerenje gustoće informacija.

Kao što je prethodno navedeno, za kvantificiranje količine pokreta u video sadržaju u ovoj disertaciji predlaže se korištenje omjera broja točaka (eng. *pixel*) detektiranih pokretnih objekata i ukupnog broja točaka, a za detektiranje pokretnih objekata koristit će se neki od algoritama za uklanjanje pozadine.

Količina pokreta u jednoj slici video sadržaja može se izraziti kao broj između 0 i 1 pri čemu 0 ukazuje da se niti jedna točka (eng. *pixel*) slike nije izmijenila u odnosu na prethodnu sliku. U slučaju da su se sve točke izmijenile u odnosu na prethodnu sliku, tada je količina pokreta jednaka broju 1. Za pojedinačnu sliku vrijedi:

$$Y_{[slika]} = n_{fg\,[slika]} \; / \; n_{all\,[slika]}$$

Varijabla y predstavlja količinu pokreta za pojedinu sliku, dok n_{fg} predstavlja broj točaka (eng. *pixel*) koje je algoritam za uklanjanje pozadine označio kao pokretni objekt, odnosno prednji plan (eng. *forground*). Posljednja varijabla u prethodnom izrazu je n_{all} i ona predstavlja ukupan broj točaka pojedinačne slike, koji je u pravilu konstantan u cijelom video isječku. Za cijeli video isječak vrijedi sljedeće:

$$Y_{[video]} = \sum n_{fg\,[video]} \; / \sum n_{all\,[video]}$$

pri čemu varijabla $Y_{[video]}$ predstavlja količinu pokreta za kompletan video isječak. U nastavku će oznaka za taj omjer biti BGSVAI jer se radi o Indeksu vizualne aktivnosti (eng.

Visual Activity Index) zasnovanom na algoritmima za uklanjanje pozadine (eng. *Background Subtraction*).

Pitanje koje se nameće jest koji od nekoliko desetaka algoritama daje najbolje rezultate kod detekcije pokreta, odnosno potrebno je definirati kriterij izbora algoritma. Navedeni algoritmi su dosta često razvijani za potrebe industrije i to za neke specifične namjene te je samim tim upitno jesu li najpogodniji za mjerenje gustoće video sadržaja kako je percipiraju ljudi. S ciljem izbora najboljeg algoritma bilo je potrebno je uključiti provjeren model s područja komunikacijskih znanosti koji se bavi problematikom gustoće video sadržaja, a to je već spomenuti Model ograničenog kapaciteta obrade motiviranih posredovanih poruka (eng. *Limited Capacity Model of Motivated Mediated Message Processing*) Annie Lang (Lang et al, 2007).

Model pretpostavlja da primatelji audio vizualnih sadržaja imaju ograničene resurse obrade informacija te kada potrebni resursi prekorače dodijeljene resurse dolazi do informacijskog preopterećenja pri kojem se dio poruke gubi. Proces alokacije resursa je složen i ovisi o nizu čimbenika, a odvija se automatski ili kontrolirano kod primatelja. Razrada LC4MP modela uvela je nove značajke i to „složenost strukture“ (prosječan broj izmjena kadra u sekundi) kao mjeru dodijeljenih resursa i „gustoću informacija“ (novouvedene informacije) kao mjeru potrebnih resursa, što omogućuje dalju razradu i usavršavanje modela kao i praktičnu primjenu istog (Lang et.al., 2007). Za dobivanje vrijednosti varijable „složenost strukture“ postoji niz automatskih metoda dobro opisanih u literaturi, a za manje količine sadržaja vrijednost se može odrediti i praćenjem izmjene kadrova (Hanjalic, 2002) (Boreczky, 1996). Vrijednost varijable „gustoća informacija“ određuju obučeni opažači praćenjem sadržaja, a sam pojam se spominje 2007. godine u radu pod naslovom „*Cognition and Emotion in TV Message Processing: How Valence, Arousing Content, Structural Complexity, and Information Density Affect the Availability of Cognitive Resources*“ gdje navodi da se radi o prethodno spomenutoj mjeri I^2 po jedinici vremena, odnosno sekundi. Uvedene informacije (eng. *Information introduced*), odnosno I^2 definirane su u radu iz 2006. godine pod naslovom „Parsing the Resource Pie: Using STRTs to Measure Attention to Mediated Messages“.

Autori su u želji da što egzaktnije definiraju pojam „Uvedene informacije“ proučili literaturu, te izabrali sedam dimenzija i to:

a) promjena žarišnog objekta
b) novi žarišni objekt
c) povezanost
d) udaljenost
e) perspektiva
f) emocija
g) izmjena oblika

Svaka dimenzija može poprimiti vrijednost 0 ili 1, a mjerenje se vrši kod svakog pomaka kamere.

S ciljem korištenja LC4MP modela za izbor algoritma, od autorice samog modela pribavljeni su video isječci koji su korišteni u istraživanjima 2006. i 2007. godine, kao i pripadajuća datoteka s podatcima. Na žalost autorici nisu bili dostupni svi video isječci korišteni u istraživanjima, tako da je umjesto 144 video isječka pribavljeno njih 135. U prilogu je popis video isječaka Annie Lang koji su korišteni u radu.

Podatci koji su korišteni u radu uključuju sljedeće za 135 video isječaka:

a) naziv datoteke
b) tip
c) dužina u sekundama
d) emocija (1 – negativna, 2 – pozitivna, 3 – oboje)
e) uzbuđenje (1 – bez, 2 – nešto, 3 – puno)
f) promjena žarišnog objekta
g) novi žarišni objekt
h) povezanost
i) udaljenost
j) promjena perspektive
k) promjena emocije
l) izmjena oblika
m) prosječan broj informacija u sekundi
n) prosječan broj izmjene kadra u sekundi

U predzadnjem stupcu pod nazivom „prosječan broj informacija u sekundi“, odnosno u izvornoj datoteci je naziv tog stupca *Average Info/sec*, jesu vrijednosti gustoće informacija za pojedini video isječak. U zadnjem stupcu pod nazivom „prosječan broj izmjene kadra u

sekundi“, odnosno u izvornoj datoteci je naziv tog stupca *Average Camera/s*, su vrijednosti složenosti strukture za pojedini video isječak.

5.1.1. Izbor BGS algoritma na temelju korelacije između gustoće informacija i vrijednosti dobivene BGS algoritmima

Tablica 8 prikazuje sve korištene algoritme, autore, osobe koje su ih prilagodile za upotrebu, kao i nazive kategorija u koje algoritmi spadaju. U prvoj kategoriji pod nazivom Osnovne metode nalaze se i algoritmi koji su uključeni u OpenCV biblioteke pa u tom slučaju autor nije navođen.

Tablica 8 – Kategorije, algoritmi, idejni autori algoritma i osobe koje su ga prilagodile za upotrebu

KATEGORIJA	ALGORITAM	AUTOR/PRILAGODIO
Osnovne metode	Static Frame Difference	- / OpenCV
	Frame Difference	- / OpenCV
	Weighted Moving Mean	- / OpenCV
	Weighted Moving Variance	- / OpenCV
	Adaptive Background Learning	- / OpenCV
	Adaptive Selective Background Learning	- / OpenCV
	Temporal Mean	(Parks, 2013, po Sobral, 2013) / OpenCV
	Adaptive Median	(McFarlane et al, 1995) / (Parks, 2013)
	Temporal Median	(Calderara et al, 2006) / (Parks, 2013)
	Sigma-Delta	(Lacassagne et al, 2009) / (Laugraud, 2013)
Algoritmi bazirani na neodređenoj (eng. Fuzzy) logici	Fuzzy Sugeno Integral	(Zhang et al, 2006) / (Bouwmans, 2013)
	Fuzzy Choquet Integral	(El Baf et al, 2008) / (Bouwmans, 2013)
	Fuzzy Gaussian	*(Sigari et al, 2008) / (Bender, 2013)*
Single gaussian based methods	Gaussian Average of Wren	(Wren et al, 1997) / (Parks, 2013)
	Simple Gaussian	*(Benezeth et al, 2008) / (Bender, 2013)*
Multiple gaussians based methods	Gaussian Mixture Model of Stauffer and Grimson	(Stauffer et la, 1999) / (Parks, 2013)
	Gaussian Mixture Model of KadewTraKuPong and Bowden	(Kaewtrakulpong et al, 2001) / OpenCV

	Gaussian Mixture Model of Zivkovic	(Zivkovic, 2004) (Zivkovic et al, 2006) / OpenCV
	Gaussian Mixture Model of Zivkovic	(Zivkovic, 2004) (Zivkovic et al, 2006) / (Parks, 2013)
	Gaussian Mixture Model of Laurence Bender	*(Bender, 2013) / (Bender, 2013)*
Type-2 Fuzzy based methods	Type-2 Fuzzy GMM-UM of	(Baf et al) / (Bouwmans, 2013)
	Type-2 Fuzzy GMM-UV of Baf et al	(Baf et al) / (Bouwmans, 2013)
	Type-2 Fuzzy GMM-UM with MRF	(Zhao et al) / (Bouwmans, 2013)
	Type-2 Fuzzy GMM-UV with MRF	(Zhao et al) / (Bouwmans, 2013)
Multiple features based methods	Texture BGS	(Heikkila et al., 2006) / (Parks, 2013)
	Texture-Based Foreground Detection with MRF	*(Kertesz et al, 2011) / (Kertesz et al, 2011)*
	Multi-Layer BGS	(Yao et al, 2007) / (Yao et al, 2007)
	MultiCue BGS	*(Noh et al, 2012) / (Noh et al, 2012)*
	SuBSENSE	(St-Charles et al., 2014) / (St-Charles et al., 2014)
	LOBSTER	(St-Charles et al., 2014a) / (St-Charles et al., 2014a)
Non-parametric methods	*Pixel-Based Adaptive Segmenter (PBAS)*	*(Hofmann et al, 2012) / (Hofmann, 2013)*
	GMG	(Godbehere et al, 2012) / OpenCV
	VuMeter	(Goyat et al, 2006) / (Vacavant, 2013)
	KDE	(Elgammal et al, 2000) / (Elgammal et al, 2000)
	IMBS	(Bloisi et al, 2012) / (Bloisi, 2013)
Subspace-based methods	Eigenbackground / SL-PCA	(Oliver et al, 2000) / (Parks, 2013)
Neural and neuro-fuzzy methods	*Adaptive SOM*	*(Maddalena et al, 2008) / (Bender, 2013)*
	Fuzzy Adaptive SOM	*(Maddalena et al, 2010) / (Bender, 2013)*

Algoritmi čiji nazivi su ukošeni iz različitih razloga nisu korišteni u disertaciji, a najčešće se radilo o greškama kod prevođenja programa. Navedeni algoritmi su korišteni u programu napisanom u programskom jeziku C++ u razvojnom okruženju Microsoft Visual C++ Express 2010, a program koji se koristio dostupan je u prilogu. Kao što je prethodno navedeno algoritme je prikupio Sobral te ih pripremio za korištenje u sklopu programske biblioteke OpenCV. Nakon izrade i prevođenja programa koji se poziva iz naredbenog retka, pripremljena je i skripta koja je pozivala program i kao argument mu navodila putanju do video isječka koji treba obrađivati. Izlazni podatci nakon obrade spremani su u tekstualnu datoteku, koja se po završetku uvozila u

tablični kalkulator Microsoft Excel 2010. Pokrenuti program bi po pokretanju otvorio 3 prozora. Slika 30 prikazuje prvi od navedena tri u kojem je vidljivo koliki broj pojedinačnih slika (eng. *frame*) je obrađen do sada.

Slika 30 – Prozor otvoren u sklopu izvršavanja programa sa brojem slike koja se obrađuje

Slika 31 prikazuje dva prozora od kojih su u donjem međufaze obrade video isječka, dok je u gornjem manjem rezultat rada algoritma pri čemu je crna površina pozadina slike, dok je bijela površina pokretni objekt, odnosno objekti na slici.

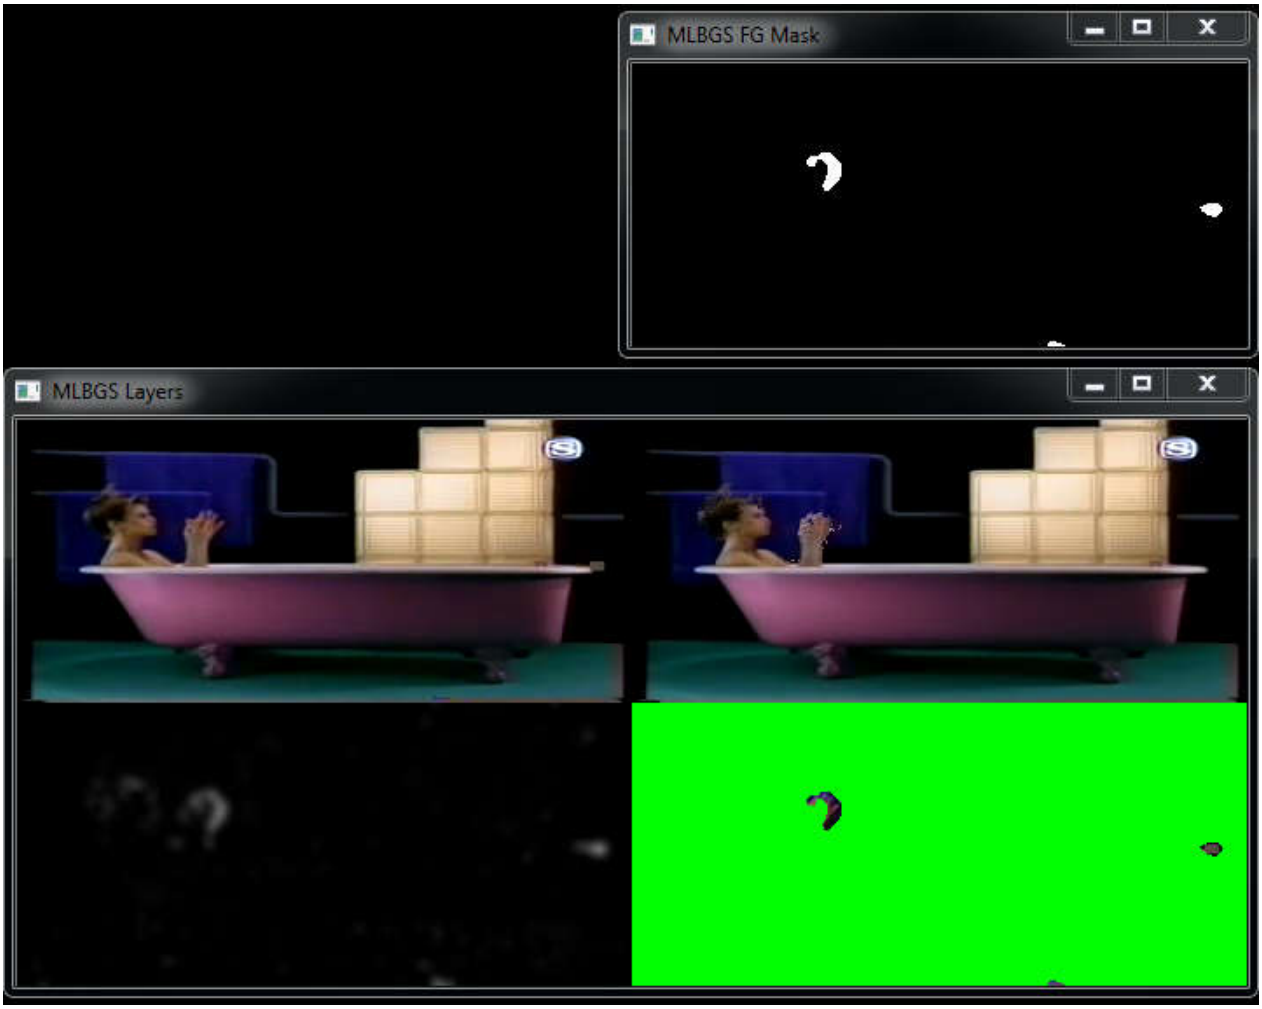

Slika 31 – Dva prozora otvorena u sklopu izvršavanja programa

Osim opisanih grafičkih prikaza rada algoritma, tokom obrade se u dvije varijable spremaju podatci o ukupnom broju točaka u video isječku i broju točaka koji pripadaju pokretnim objektima (eng. *foreground*). Po obradi posljednje dvije slike video isječka, te dvije cjelobrojne vrijednosti se upisuju u jedan red tekstualne datoteke u čitljivom obliku i kreće obrada sljedećeg video isječka od ukupno 135. Primjer dodanog reda je sljedeći:

480 720 345600 31773 92657019 621734400 1799,

pri čemu je peti broj jednak ukupnom broju točaka koji su pripadale pokretnim objektima, a šesti broj je jednak ukupnom broju točaka cijelog video isječka. Ostali brojevi su razlučivost video isječka, broj slika i slično. Za svaki algoritam dobivena je po jedna tekstualna datoteka sa 135 redova podataka koji su uvezeni u tablični kalkulator za dalju obradu.

U nastavku su navedene kategorije korištenih algoritama za uklanjanje pozadine kao podnaslovi, a u sklopu njih su rezultati Spearmanove korelacije između gustoće informacija

koje je izmjerila Lang i to po svakoj dimenziji i BGSVAI vrijednosti dobivene izabranim algoritmom. Korelacije su prikazane i grafički. Spearmanova korelacija je izabrana iz razloga što se kod gustoće informacija očigledno radi o ordinalnoj ljestvici, jer po svakoj dimenziji i promjeni kadra bilježimo prisutnost ili odsutnost pojedine dimenzije (0 ili 1) da bi ukupni zbroj na kraju podjelili s vremenom.

U kategoriji osnovnih metoda autor navodi:

a) statička razlika slika (*eng. Static Frame Difference*)
b) razlika slika (*eng. Frame Difference*)
c) ponderirano kretanje srednje vrijednosti (*eng. Weighted Moving Mean*)
d) ponderirano kretanje varijance (*eng. Weighted Moving Variance*)
e) prilagodljivo „učenje“ pozadine (*eng. Adaptive Background Learning*)
f) prilagodljivo selektivno „učenje“ pozadine (*eng. Adaptive Selective Background Learning*)
g) vremenska srednja vrijednost (*eng. Temporal Mean*)
h) adaptivni medijan (*eng. Adaptive Median*) (McFarlane et al, 1995)
i) vremenski medijan (*eng. Temporal Median*) (Calderara et al, 2006)
j) Sigma-Delta (Manzanera et al, 2004)

Tablica 9 – Spearmanove korelacije za osnovne metode

DIMENZIJA	KORELACIJA									
	statička razlika slika	*razlika slika*	*ponderirano kretanje srednje*	*ponderirano kretanje varijance*	*prilagodljivo „učenje“ pozadine*	*prilagodljivo selektivno*	*vremenska srednja vrijednost*	*adaptivni medijan*	*vremenski medijan*	*Sigma-Delta*
emocija	0,035	0,287	0,333	0,323	0,321	0,132	0,371	0,220	0,317	0,306
novi žarišni objekt	0,252	0,434	0,476	0,470	0,496	0,390	0,493	0,463	0,524	0,495
povezanost	0,211	0,381	0,385	0,383	0,390	0,298	0,390	0,371	0,410	0,405
promjena žarišnog objekta	0,254	0,496	0,545	0,543	0,569	0,367	0,583	0,416	0,577	0,577
udaljenost	0,260	0,519	0,564	0,561	0,555	0,365	0,603	0,391	0,576	0,556
perspektiva	0,290	0,585	0,630	0,628	0,639	0,399	0,667	0,433	0,636	0,648
izmjena oblika	0,124	0,231	0,234	0,225	0,295	0,278	0,231	0,411	0,342	0,302

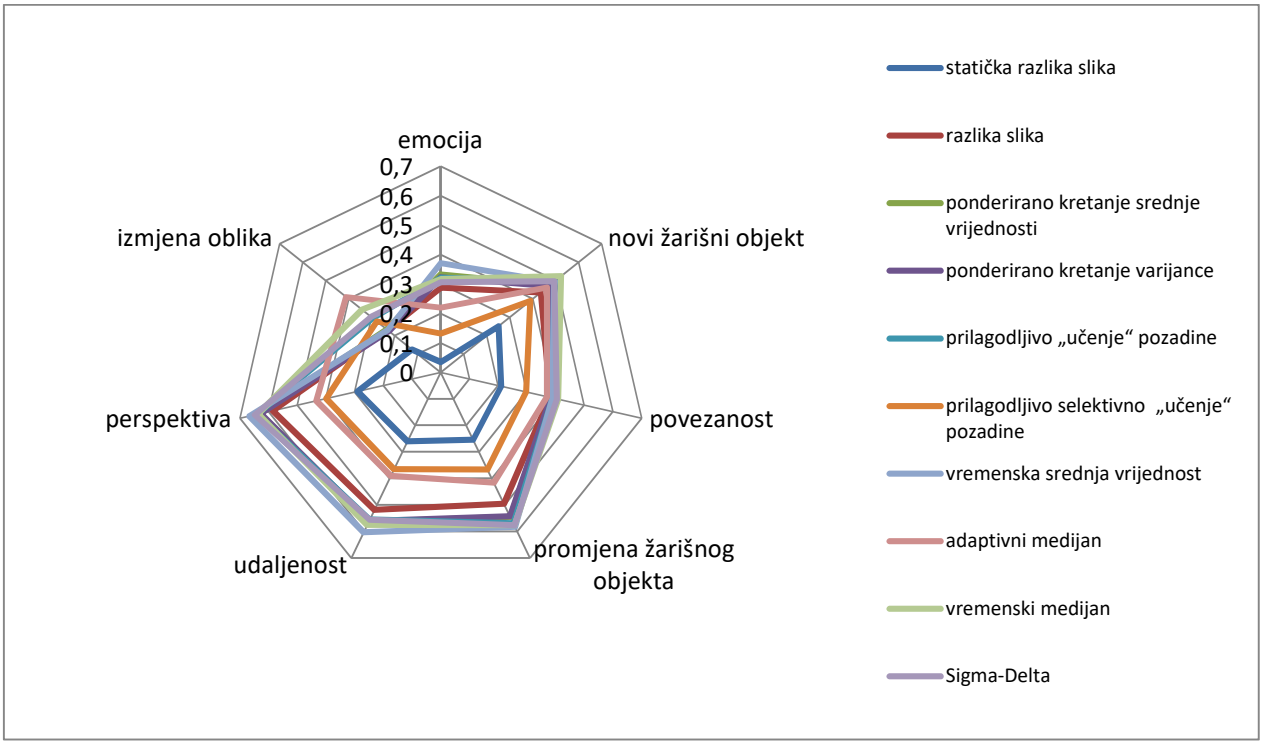

Slika 32 – Graf korelacija po dimenzijama za osnovne metode

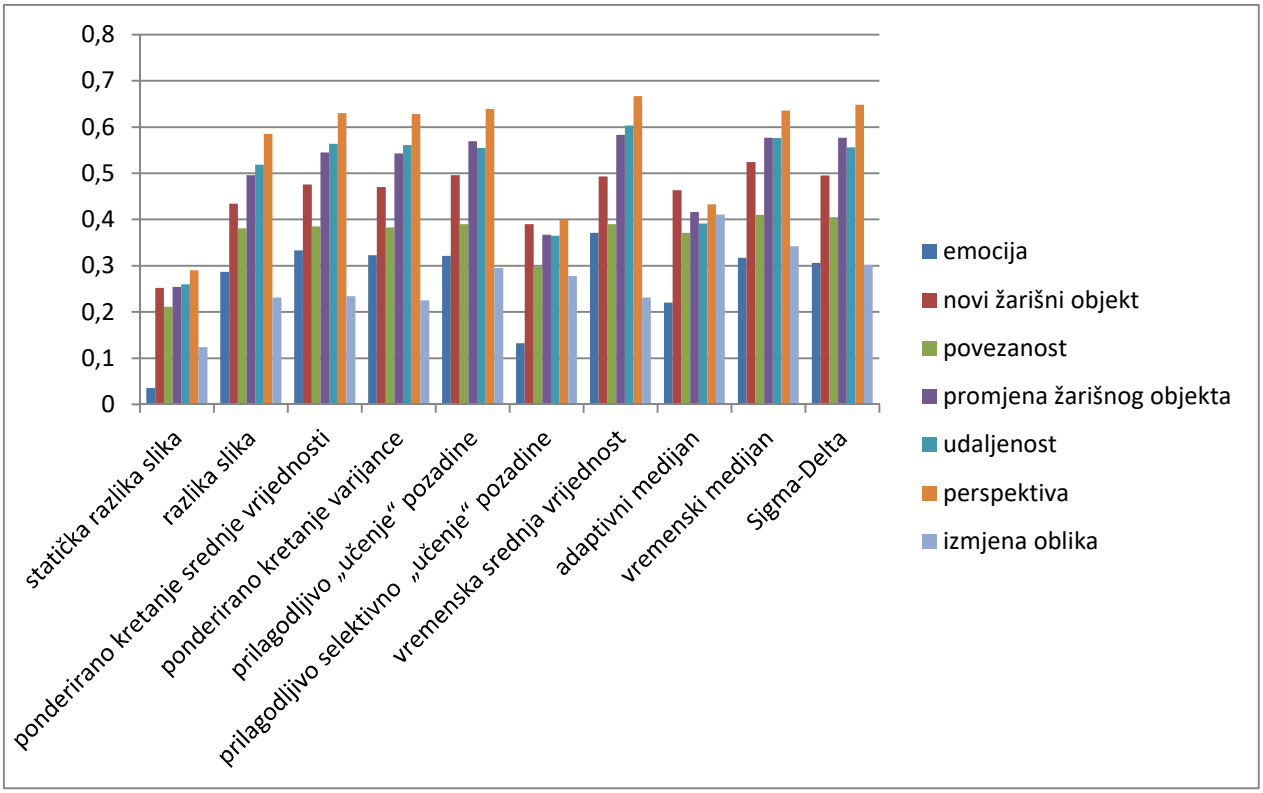

Slika 33 – Graf korelacija po algoritmima za osnovne metode

U kategoriji metoda zasnovanih na *fuzzy* logici autor navodi:

a) *Fuzzy Sugeno Integral* (Zhang et al, 2006)
b) *Fuzzy Choquet Integral* (El Baf et al, 2008)
c) *Fuzzy Gaussian* (Sigari et al, 2008)

Tablica 10 – Spearmanove korelacije za algoritme bazirane na neodređenoj (eng. Fuzzy) logici

DIMENZIJA	KORELACIJA							
	Fuzzy Sugeno Integral	*Fuzzy Choquet Integral*	*Fuzzy Gaussian*					
emocija	0,394	0,393	-					
novi žarišni objekt	0,522	0,517	-					
povezanost	0,356	0,359	-					
promjena žarišnog objekta	0,538	0,534	-					
udaljenost	0,561	0,561	-					
perspektiva	0,604	0,605	-					
izmjena oblika	0,274	0,277	-					

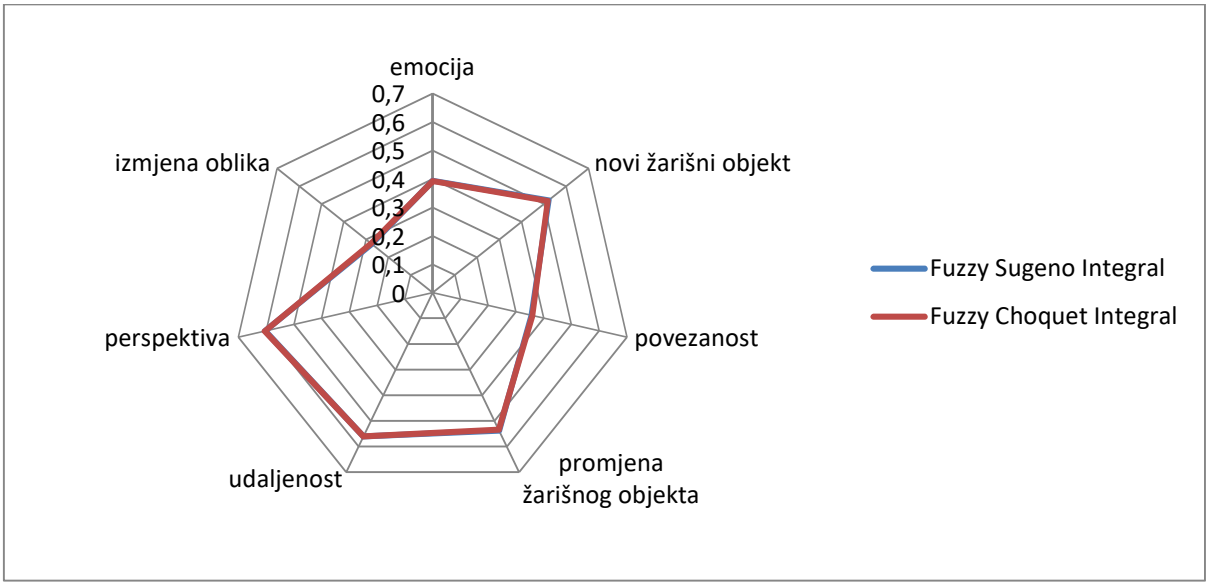

Slika 34 - Graf korelacija po dimenzijama za algoritme bazirane na neodređenoj (eng. Fuzzy) logici

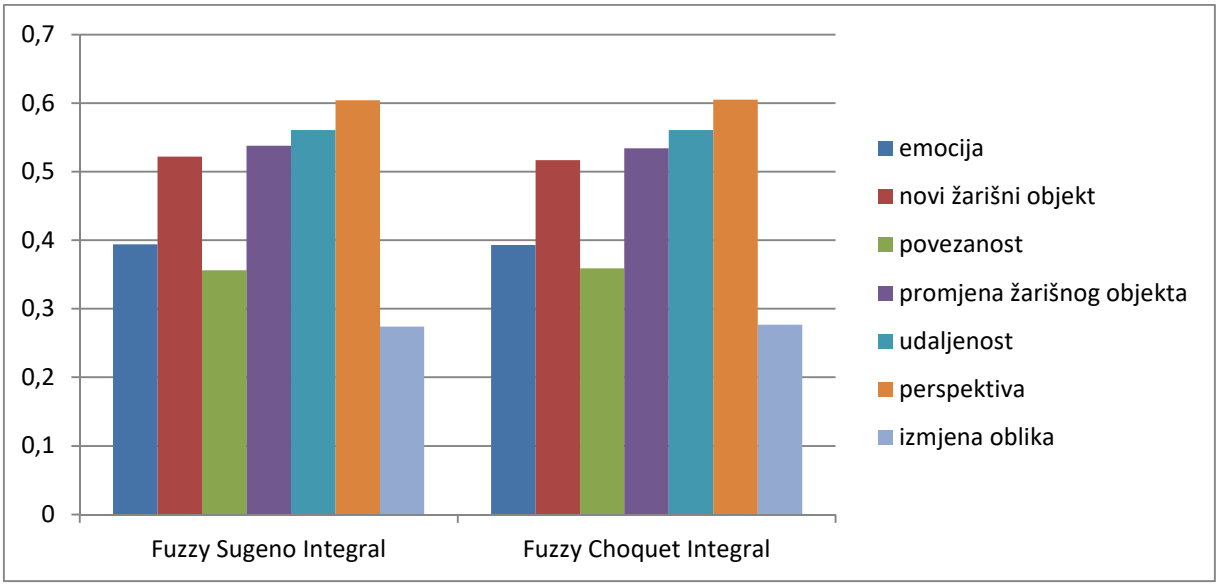

Slika 35 - Graf korelacija po algoritmima za algoritme bazirane na neodređenoj (eng. Fuzzy) logici

U kategoriji metoda zasnovanih na Gaussovoj distribuciji autor navodi:

a) *Gaussian Average* (Wren et al, 1997)

b) *Simple Gaussian* (Benezeth et al, 2008)

Tablica 11 - Spearmanove korelacije za algoritme bazirane na Gaussovoj distribuciji

DIMENZIJA	**KORELACIJA**							
	Gaussian Average	*Simple Gaussian*						
emocija	0,252	-						
novi žarišni objekt	0,489	-						
povezanost	0,385	-						
promjena žarišnog objekta	0,473	-						
udaljenost	0,450	-						
perspektiva	0,507	-						
izmjena oblika	0,421	-						

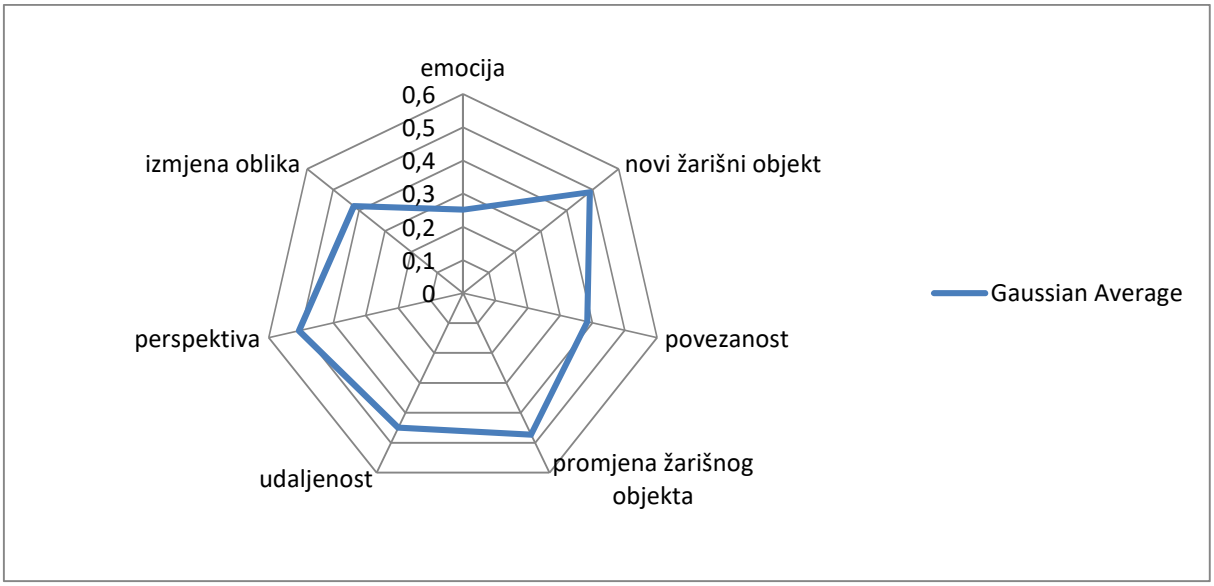

Slika 36 - Graf korelacija po dimenzijama za algoritme bazirane na Gaussovoj distribuciji

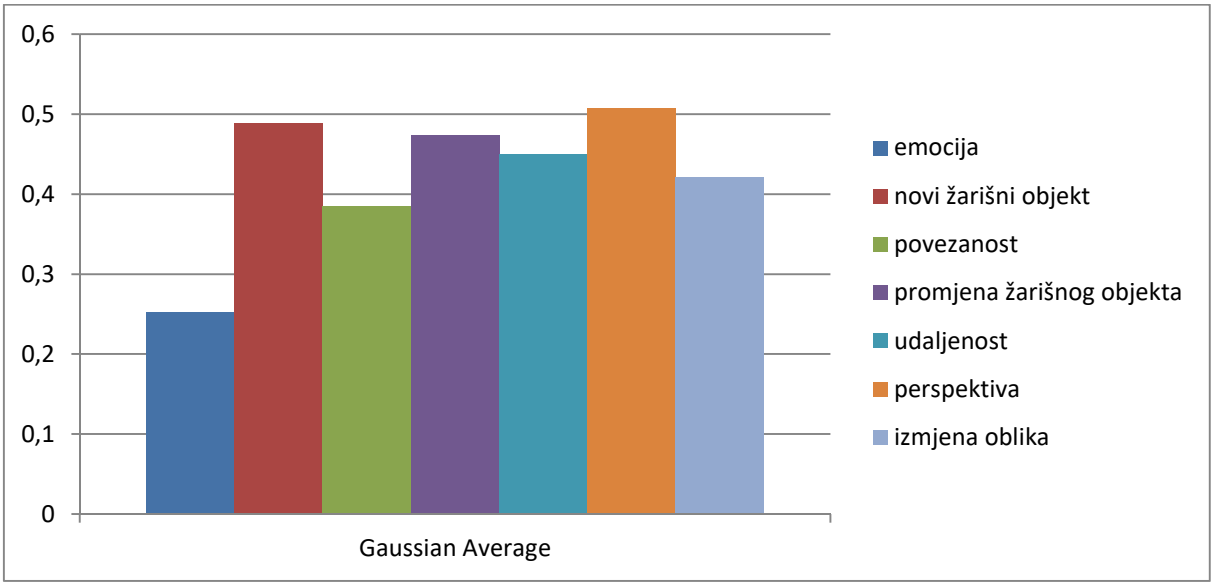

Slika 37 - Graf korelacija po algoritmima za algoritme bazirane na Gaussovoj distribuciji

U kategoriji metoda zasnovanih na višestrukim Gaussovim distribucijama autor navodi:

a) *Gaussian Mixture Model* (Stauffer et al, 1999)
b) *Gaussian Mixture Model* (Kaewtrakulpong et al, 2001)
c) *Gaussian Mixture Model* (Zivkovic, 2004)(Zivkovic et al, 2006)
d) *Gaussian Mixture Model* (Zivkovic et al, 2006)
e) *Gaussian Mixture Model* (Bouwmans et al, 2008)

Tablica 12 - Spearmanove korelacije za algoritme bazirane na Gaussovoj distribuciji (višestruke)

DIMENZIJA	KORELACIJA							
	Gaussian Mixture Model (Stauffer et al. 1999)	*Gaussian Mixture Model (Kaewtrakulpong*	*Gaussian Mixture Model (Zivkovic, 2004)*	*Gaussian Mixture Model (Zivkovic et al. 2006)*	*Gaussian Mixture Model (Bouwmans et al. 2008)*			
emocija	0,324	0,364	0,325	0,214	-			
novi žarišni objekt	0,556	0,517	0,497	0,500	-			
povezanost	0,394	0,325	0,409	0,312	-			
promjena žarišnog objekta	0,602	0,616	0,558	0,440	-			
udaljenost	0,562	0,614	0,554	0,392	-			
perspektiva	0,653	0,669	0,636	0,460	-			
izmjena oblika	0,341	0,210	0,287	0,396	-			

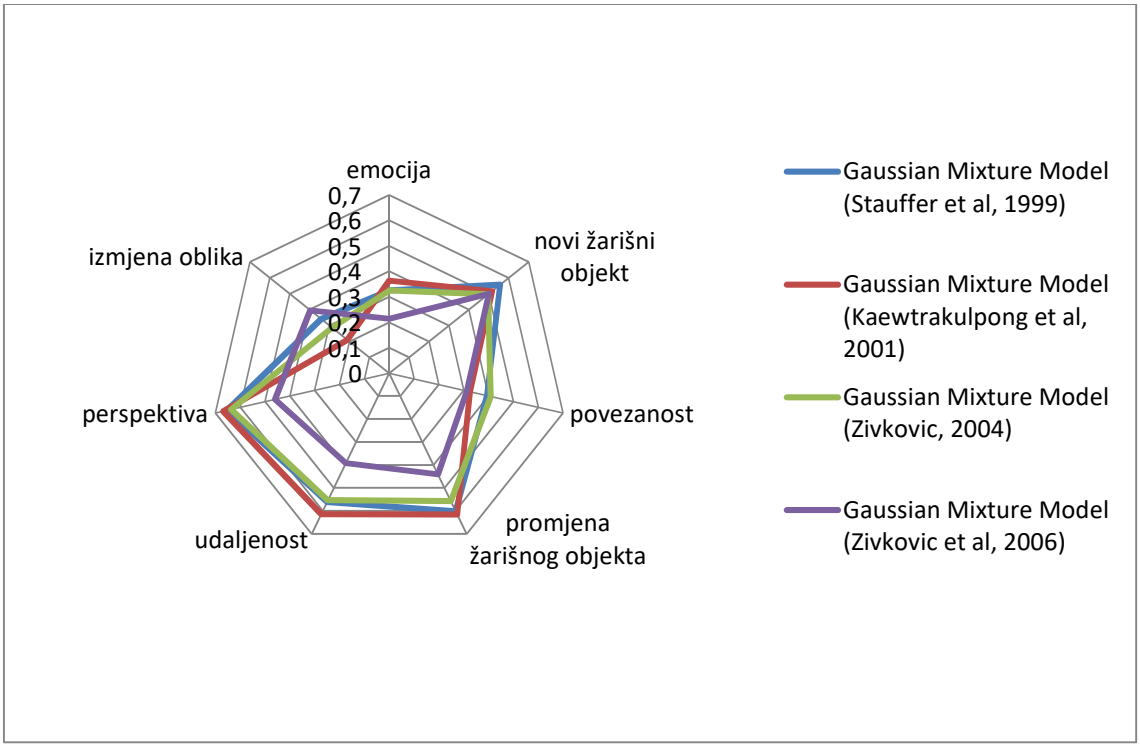

Slika 38 - Graf korelacija po dimenzijama za algoritme bazirane na Gausovoj distribuciji (višestruke)

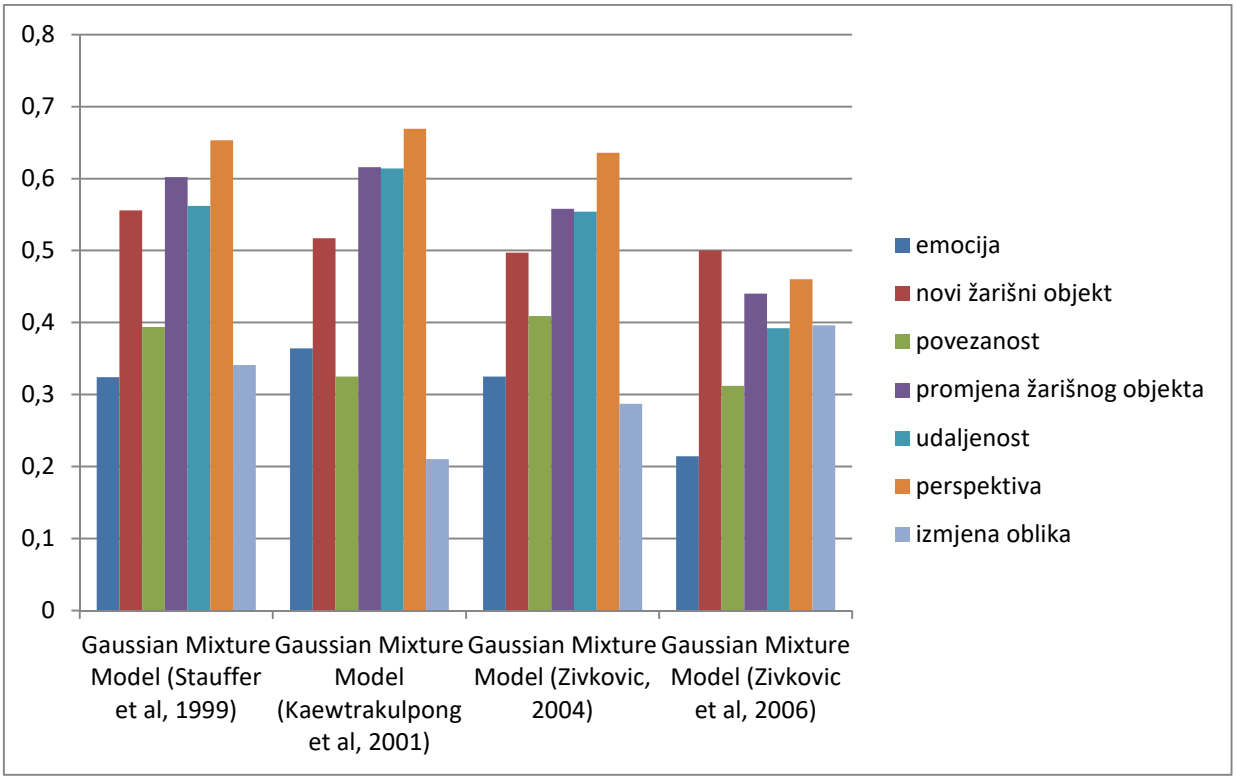

Slika 39 - Graf korelacija po algoritmima za algoritme bazirane na Gausovoj distribuciji (višestruke)

U kategoriji drugog tipa metoda zasnovanih na neodređenoj (eng. *Fuzzy*) logici autor navodi:

a) *Tip-2 Fuzzy GMM-UM* (El Baf et al, 2008a)
b) *Tip-2 Fuzzy GMM-UV* (El Baf et al, 2008a)
c) *Tip-2 Fuzzy GMM-UM with MRF* (Zhao et al, 2012)
d) *Tip-2 Fuzzy GMM-UV with MRF* (Zhao et al, 2012)

Kratica GMM označava eng. *Gaussians Model Mixture*, dok UM označava eng. *Uncertain Mean Vector*. Kratica UV označava eng. *Uncertain Variance Vector*, a kratica MRF dolazi od eng. *Markov Random Field*.

Tablica 13 - Spearmanove korelacije za algoritme bazirane na neodređenoj (eng. Fuzzy) logici drugog tipa

DIMENZIJA	KORELACIJA							
	Tip-2 Fuzzy GMM-UM	*Tip-2 Fuzzy GMM-UV*	*Tip-2 Fuzzy GMM-UM with MRF*	*Tip-2 Fuzzy GMM-UV with MRF*				
emocija	0,287	0,313	0,292	0,214				
novi žarišni objekt	0,264	0,514	0,304	0,500				
povezanost	-0,079	0,425	0,045	0,312				
promjena žarišnog objekta	0,289	0,561	0,325	0,440				
udaljenost	0,227	0,540	0,281	0,392				
perspektiva	0,265	0,622	0,322	0,460				
izmjena oblika	0,079	0,332	0,160	0,396				

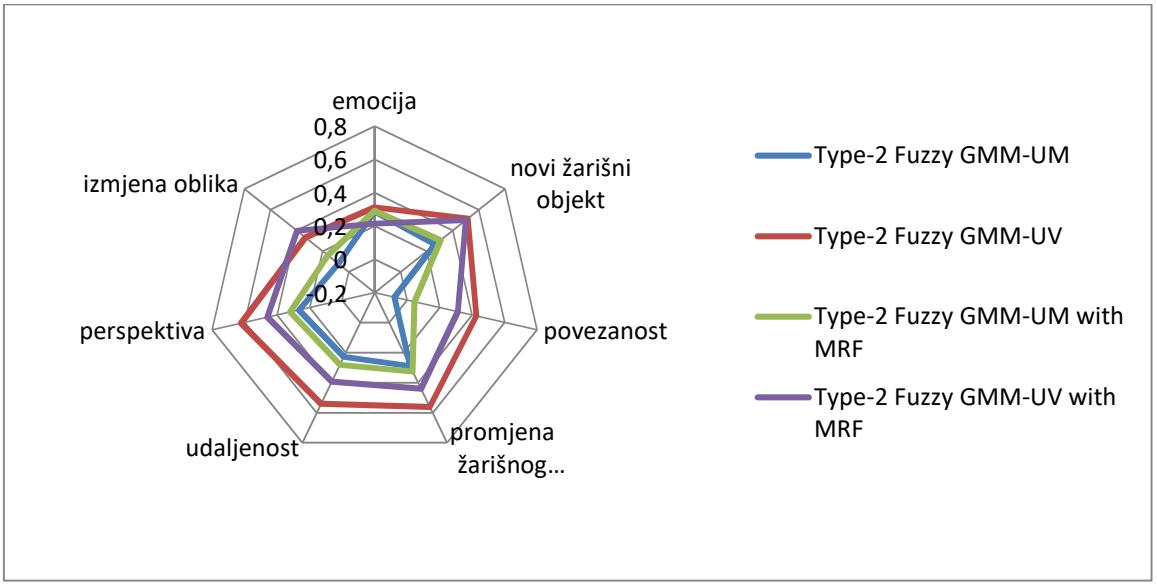

Slika 40 - Graf korelacija po dimenzijama za algoritme bazirane na neodređenoj (eng. Fuzzy) logici drugog tipa

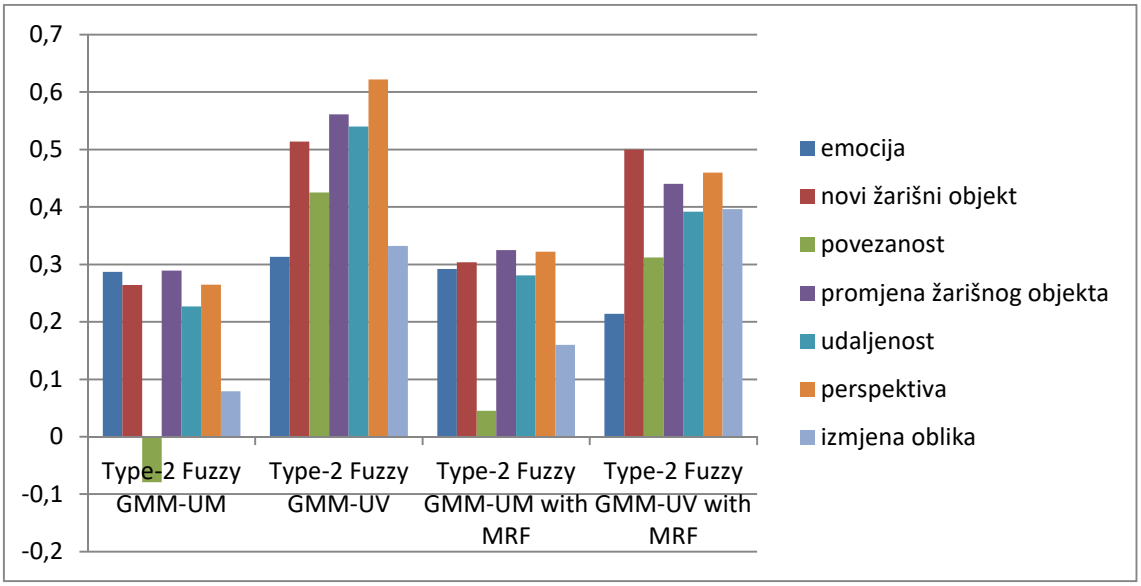

Slika 41 - Graf korelacija po algoritmima za algoritme bazirane na neodređenoj (eng. Fuzzy) logici drugog tipa

U kategoriji metoda zasnovanih na više značajki (eng. *Multiple features based methods*) autor navodi nekoliko metoda:

a) *Texture* BGS
b) *Texture-Based Foreground Detection with* MRF
c) *Multi-Layer BGS* (Yao et al, 2007)
d) MultiCue BGS
e) SuBSENSE
f) LOBSTER

Tablica 14 - Spearmanove korelacije za algoritme bazirane na više značajki

DIMENZIJA	KORELACIJA							
	Texture BGS		*Multi-Layer BGS*		*SuBSENSE*	*LOBSTER*		
emocija	0,198	-	0,386	-	0,380	0,289		
novi žarišni objekt	0,296	-	0,495	-	0,335	0,534		
povezanost	0,355	-	0,452	-	0,039	0,386		
promjena žarišnog objekta	0,312	-	0,593	-	0,471	0,469		
udaljenost	0,279	-	0,616	-	0,449	0,473		
perspektiva	0,334	-	0,699	-	0,511	0,512		
izmjena oblika	0,163	-	0,262	-	0,011	0,387		

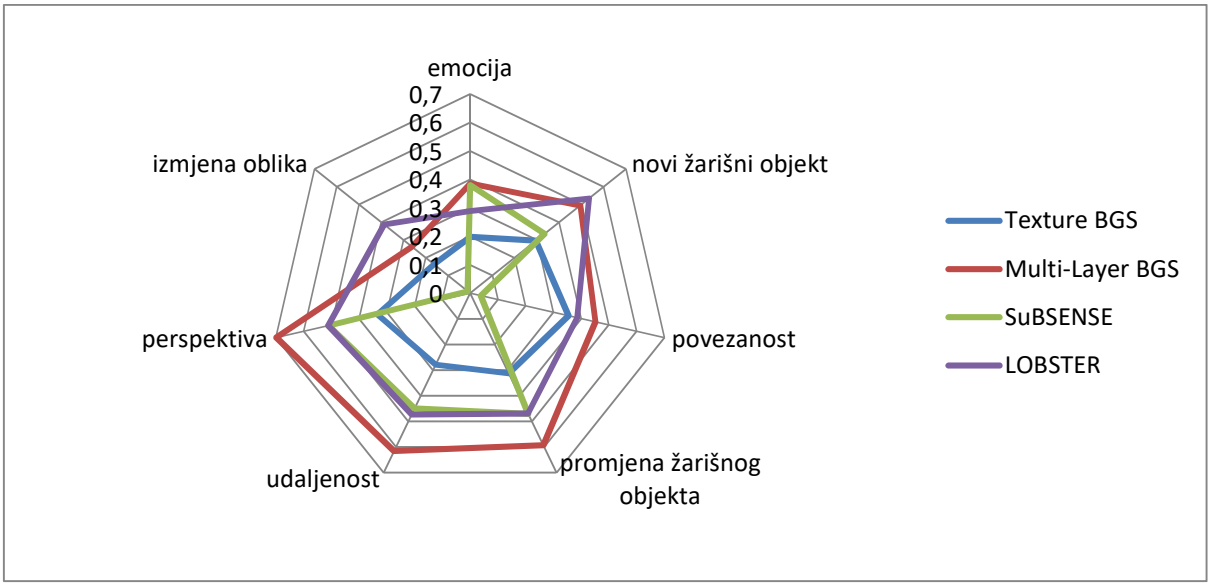

Slika 42 - Graf korelacija po dimenzijama za algoritme bazirane na više značajki

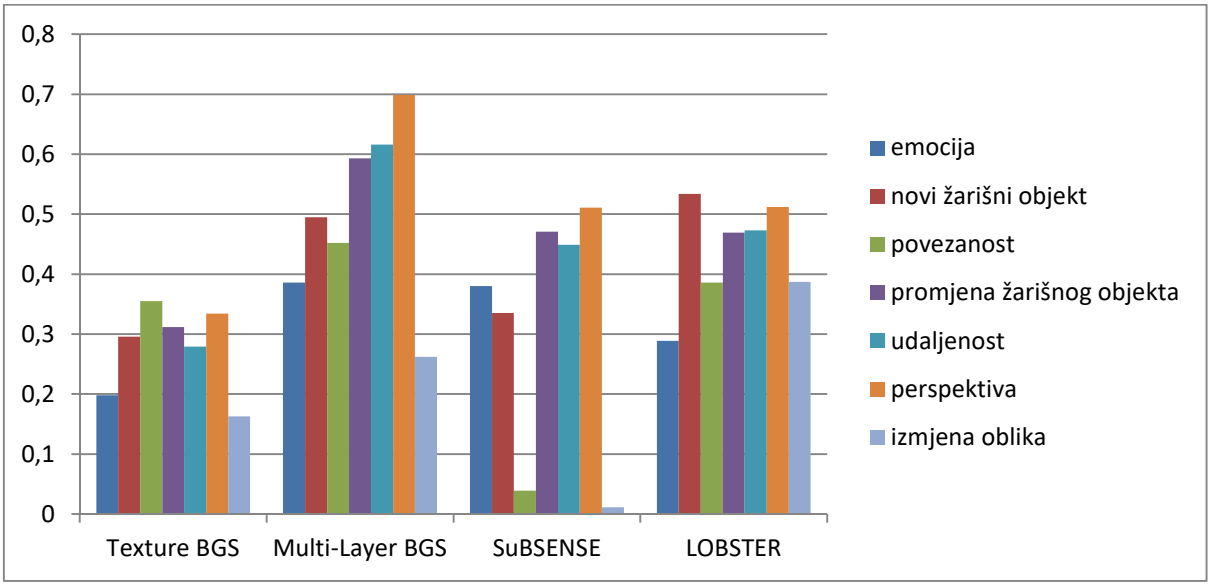

Slika 43 - Graf korelacija po algoritmima za algoritme bazirane na više značajki

U kategoriji neparametrijskih metoda autor navodi:

a) *Pixel-Based Adaptive Segmenter* (Hofmann et al, 2012)
b) *GMG* (Godbehere et al, 2012)
c) *VuMeter* (Goyat et al, 2006)
d) *KDE* (Elgammal et al, 2000)
e) *IMBS* (Bloisi et al, 2012)

Tablica 15 - Spearmanove korelacije za algoritme bazirane na neparametrijskim metodama

DIMENZIJA	KORELACIJA							
		GMG	*VuMeter*	*KDE*	*IMBS*			
emocija	-	0,204	0,254	0,131	0,069			
novi žarišni objekt	-	0,352	0,524	0,185	0,069			
povezanost	-	0,372	0,308	0,161	0,078			
promjena žarišnog objekta	-	0,431	0,507	0,248	0,061			
udaljenost	-	0,425	0,412	0,306	0,095			
perspektiva	-	0,521	0,543	0,32	0,125			
izmjena oblika	-	0,227	0,404	0,025	-0,096			

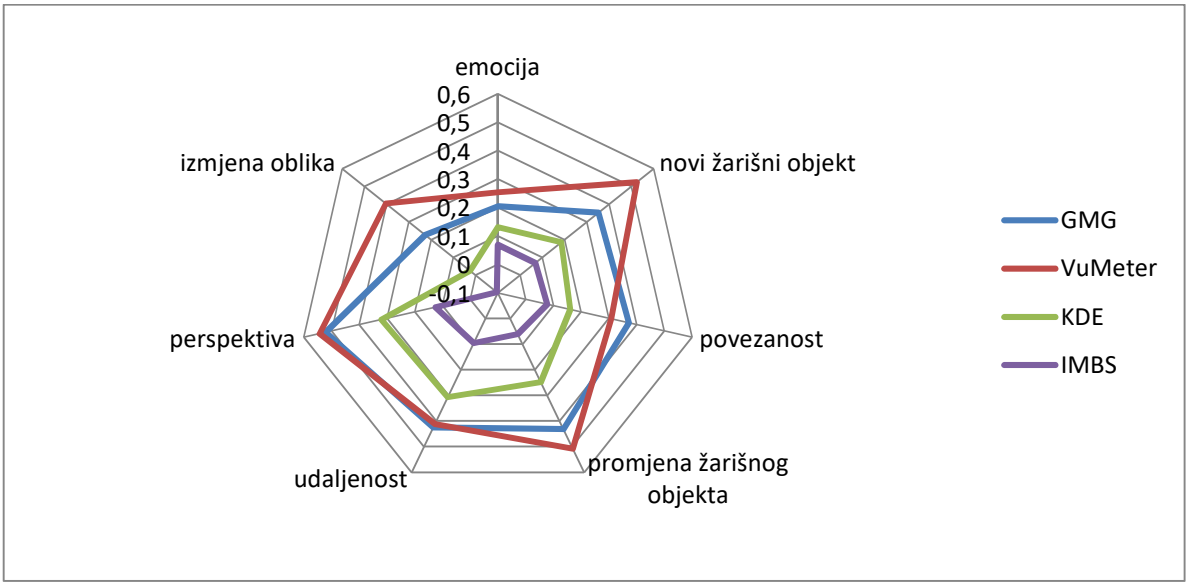

Slika 44 - Graf korelacija po dimenzijama za algoritme bazirane na neparametrijskim metodama

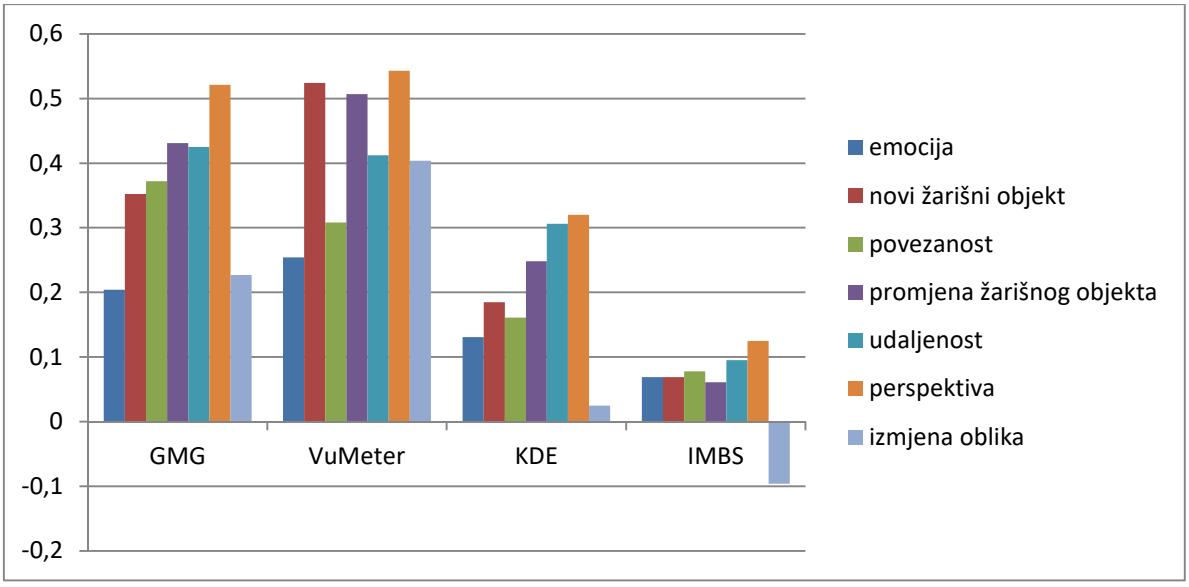

Slika 45 - Graf korelacija po algoritmima za algoritme bazirane na neparametrijskim metodama

U kategoriji metoda temeljenih na podprostoru (eng. *Subspace-based methods*) autor navodi samo jednu:

a) *Eigenbackground* / *SL-PCA* (Oliver et al, 2000)

Tablica 16 - Spearmanove korelacije za algoritam baziran na podprostoru

DIMENZIJA	**KORELACIJA**							
	Eigenbackground							
emocija	0,061							
novi žarišni objekt	0,231							
povezanost	0,232							
promjena žarišnog objekta	0,258							
udaljenost	0,269							
perspektiva	0,305							
izmjena oblika	0,117							

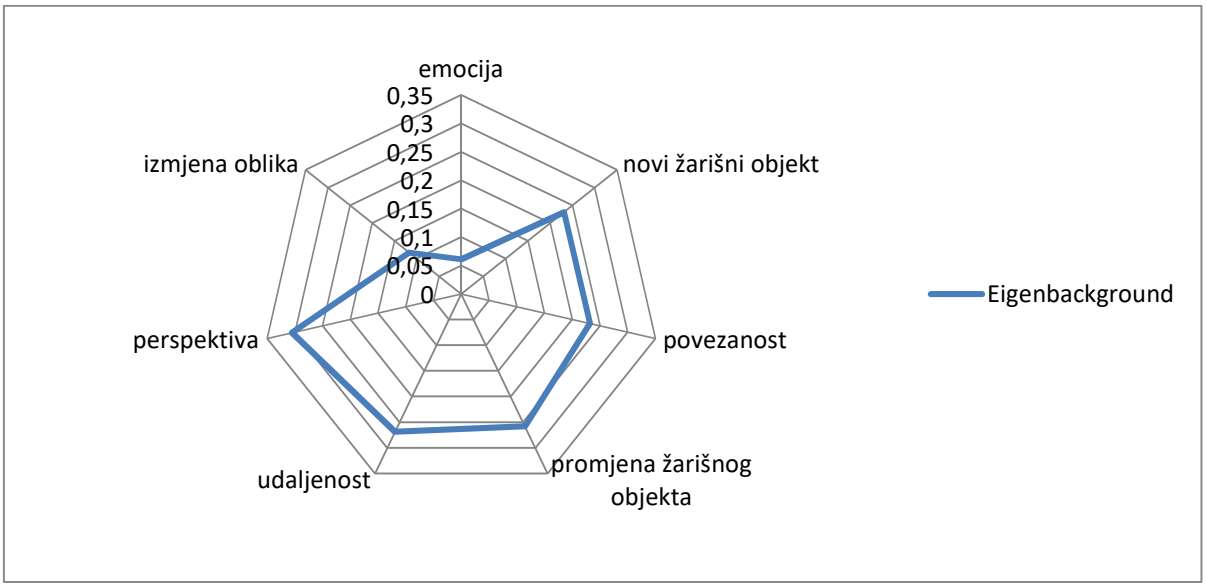

Slika 46 - Graf korelacija po dimenzijama za algoritam baziran na podprostoru

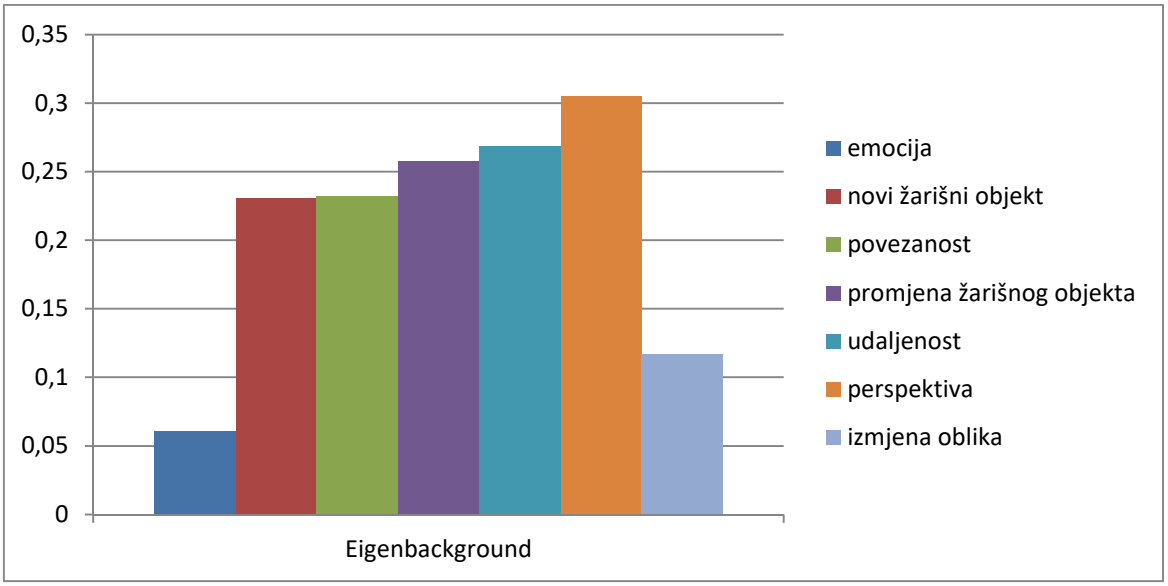

Slika 47 - Graf korelacija po algoritmima za algoritam baziran na podprostoru

U kategoriji neuronskih i *neuro-fuzzy* metoda (eng. *Neural and neuro-fuzzy methods*) autor navodi:

a) *Adaptive* SOM (Maddalena et al, 2008)
b) *Fuzzy Adaptive* SOM (Maddalena et al, 2010)

Na žalost niti jedan algoritam nije bilo moguće koristiti.

Kako se radi o korelacijama, izbor algoritma možemo svesti na usporedbu vrijednosti korelacija između pojedinih dimenzija gustoće informacija i vrijednosti dobivene svakim algoritmom. Za algoritam kod kojeg je zbroj korelacija najveći možemo reći da je najsličniji LC4MP modelu. Drugim riječima tražimo:

$$maximum \sum_{i=1}^{7} corr_i$$

pri čemu imamo sedam dimenzija gustoće informacija, označene varijablom *i*. Tablica 17 prikazuje rezultate pri čemu je podebljavanjem u zadnjem stupcu označena maksimalna vrijednost.

Tablica 17 – Rezultati za pojedine algoritme

	emocija	novi žarišni objekt	poveza nost	promje na žarišno g objekta	udaljen ost	perspek tiva	izmjena oblika	
statička razlika slika	0,035	0,252	0,211	0,254	0,26	0,29	0,124	1,426
razlika slika	0,287	0,434	0,381	0,496	0,519	0,585	0,231	2,933
ponderirano kretanje srednje vrijednosti	0,333	0,476	0,385	0,545	0,564	0,63	0,234	3,167
ponderirano kretanje varijance	0,323	0,47	0,383	0,543	0,561	0,628	0,225	3,133
prilagodljivo „učenje“ pozadine	0,321	0,496	0,39	0,569	0,555	0,639	0,295	3,265
prilagodljivo selektivno „učenje“ pozadine	0,132	0,39	0,298	0,367	0,365	0,399	0,278	2,229
vremenska srednja vrijednost	0,371	0,493	0,39	0,583	0,603	0,667	0,231	3,338
adaptivni medijan	0,22	0,463	0,371	0,416	0,391	0,433	0,411	2,705
vremenski medijan	0,317	0,524	0,41	0,577	0,576	0,636	0,342	3,382
Sigma-Delta	0,306	0,495	0,405	0,577	0,556	0,648	0,302	3,289
Fuzzy Sugeno Integral	0,394	0,522	0,356	0,538	0,561	0,604	0,274	3,249
Fuzzy Choquet Integral	0,393	0,517	0,359	0,534	0,561	0,605	0,277	3,246
Gauss Average	0,252	0,489	0,385	0,473	0,45	0,507	0,421	2,977
Gaussian Mixture Model (Stauffer et al, 1999)	0,324	0,556	0,394	0,602	0,562	0,653	0,341	3,432
Gaussian Mixture Model (Kaewtrakulpong et al, 2001)	0,364	0,517	0,325	0,616	0,614	0,669	0,21	3,315
Gaussian Mixture Model (Zivkovic, 2004)	0,325	0,497	0,409	0,558	0,554	0,636	0,287	3,266
Gaussian Mixture Model (Zivkovic et al, 2006)	0,214	0,5	0,312	0,44	0,392	0,46	0,396	2,714
Tip-2 Fuzzy GMM-UM	0,287	0,264	-0,079	0,289	0,227	0,265	0,079	1,332
Tip-2 Fuzzy GMM-UV	0,313	0,514	0,425	0,561	0,54	0,622	0,332	3,307
Tip-2 Fuzzy GMM-UM with MRF	0,292	0,304	0,045	0,325	0,281	0,322	0,16	1,729
Tip-2 Fuzzy GMM-UV with MRF	0,214	0,5	0,312	0,44	0,392	0,46	0,396	2,714
Texture BGS	0,198	0,296	0,355	0,312	0,279	0,334	0,163	1,937
Multi-Layer BGS	0,386	0,495	0,452	0,593	0,616	0,699	0,262	**3,503**

SuBSENSE	0,38	0,335	0,039	0,471	0,449	0,511	0,011	2,196
LOBSTER	0,289	0,534	0,386	0,469	0,473	0,512	0,387	3,05
GMG	0,204	0,352	0,372	0,431	0,425	0,521	0,227	2,532
VuMeter	0,254	0,524	0,308	0,507	0,412	0,543	0,404	2,952
KDE	0,131	0,185	0,161	0,248	0,306	0,32	0,025	1,376
IMBS	0,069	0,069	0,078	0,061	0,095	0,125	-0,096	0,401
Eigenbackground	0,061	0,231	0,232	0,258	0,269	0,305	0,117	1,473

Očigledno je najveći zbroj korelacija (3,503) između vrijednosti dobivenih *Multi-Layer* algoritmom za uklanjanje pozadine i sedam varijabli Lang i suradnika, tako da će se taj algoritam koristiti u nastavku disertacije. Umjesto engleskog naziva algoritma koristit će se pripadajući hrvatski naziv – višeslojni algoritam. Vrijednost *p* za svih sedam vrijednosti je manja od 0,01 odnosno rezultati korelacija su statistički značajni na razini od 1%. Tablica dobivena obradom u programskom paketu SPSS nalazi se u prilogu pod 10.7.

Analizom samih dimenzija gustoće informacija predložene u sklopu LC4MP modela intuitivno možemo zaključiti da algoritmi za uklanjanje pozadine vjerojatno nemaju veze sa nekim od dimenzija. Slika 48 sa grafičkim prikazom korelacija svih algoritama sa svim dimenzijama jasno na to ukazuje. Prikazane korelacije dimenzija emocija, povezanosti i izmjene oblika vjerojatno su rezultat osjetljivosti BGS algoritama na izmjenu kadra, što bi se moglo i dokazati metodom parcijalne korelacije koja uklanja utjecaj jedne od varijabli i prikazuje korelacije ostalih varijabli.

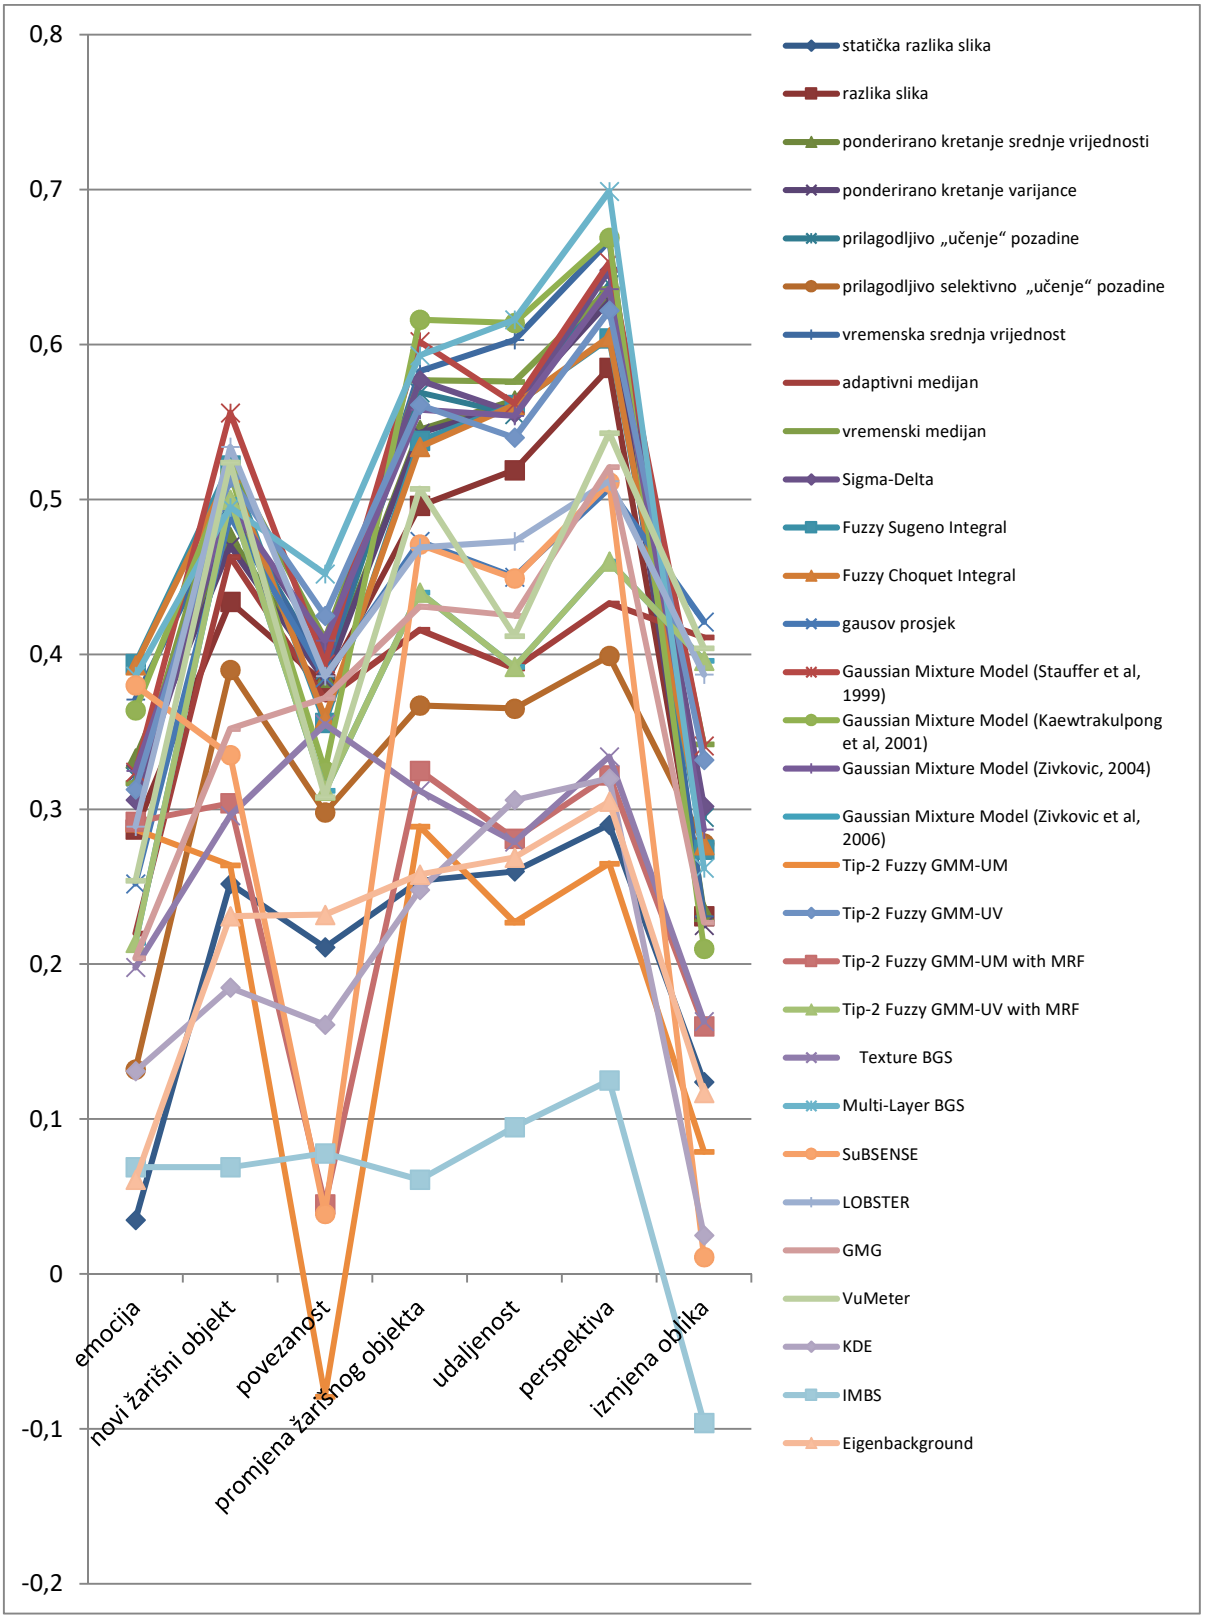

Slika 48 – Graf korelacija po dimenzijama za sve algoritme

5.1.2. Analiza utjecaja varijable „Složenost strukture“

S obzirom da se mjerenje vrijednosti I^2 zbiva samo kod izmjene kadra, vjerojatno postoji korelacija između varijabli „Složenost strukture“ i „Gustoća informacija“. Varijabla „Složenost strukture“ ima velik utjecaj i na vrijednosti koje dobivamo mjerenjem predloženim modelom, jer pri izmjeni kadra jednostavni algoritmi registriraju velik broj točaka (eng. *pixel*) kao prednji plan, odnosno tijelo koje se kreće. Složeniji algoritmi su možda manje osjetljiviji na izmjenu kadra, mada niti jedan od njih nije na to imun prije svega zato jer je određeni dio njih razvijan uz pretpostavku da će obrađivati video isječke dobivene snimanjem nepokretnom kamerom.

Da bi isključili utjecaj varijable „Složenost strukture“, može se koristiti višestruka hijerarhijska regresijska analiza (Tabachnick et al, 2013) ili parcijalna korelacija. Prva pretpostavka za korištenje višestruke regresijske analize je veći uzorak, a Green je predložio jednostavno pravilo za izračun najmanjeg uzorka i to $N \geq 50+8m$, pri čemu je m broj nezavisnih varijabli. S obzirom na podatke i broj varijabli, ovi uvjeti su svakako zadovoljeni. Nadalje višestruka regresijska analiza, kao i parcijalna korelacija zahtijevaju linearnu povezanosti i određene postavke normalnosti. Testiranje normalnosti je obavljeno korištenjem programskog paketa SPSS i rezultati nisu bili zadovoljavajući. U prilogu je tablica analize podataka provedena u programskom paketu SPSS i to metodom Kolmogorov Smirnov, kao i histogrami podataka po pojedinim dimenzijama da bi se utvrdilo zadovoljavaju li podatci kriterij normalnosti koji je nužan za korištenje višestruke regresije. Iz tog razloga u nastavku se koristila neparametrijska metoda parcijalne korelacije koja je implementirana u programskom paketu R Studio. Tom metodom računamo korelaciju između dvije varijable uz isključivanje utjecaja treće za koju smatramo da nam utječe na rezultat (Kim, 2015).

Rezultati su dani u tablici ispod za svaku od navedenih sedam varijabli koje je koristila Lang u svom modelu, a s obzirom na p-vrijednosti korelacije za samo dvije varijable su statistički značajne i to povezanost i perspektiva. U zadnjem stupcu su vrijednosti iz prethodne tablice u kojoj se vide vrijednosti Spearmanove korelacije između pojedinih sedam varijabli i vrijednosti dobivenih predloženim modelom zasnovanom na prethodno izabranom višeslojnom algoritmu.

Tablica 18 – Vrijednosti parcijalnih korelacija uz isključivanje utjecaja varijable Složenost strukture

Varijabla	Spearmanova korelacija (r) **bez utjecaja Složenosti strukture**	p-vrijednost	Spearmanova korelacija (r)
emocija	-0,013	0,873	0,386
novi žarišni objekt	0,059	0,495	0,386
povezanost	**0,325**	**0,000**	0,452
promjena žarišnog objekta	-0,156	0,068	0,593
udaljenost	0,110	0,203	0,616
perspektiva	**0,213**	**0,012**	0,699
izmjena oblika	0,062	0,474	0,262

Ne ulazeći dublje u analizu možemo konstatirati da varijabla „Složenost strukture“ koju koristi A. Lang i kojom se mjeri učestalost izmjene kadra ima značajan utjecaj na navedenih sedam varijabli i izračunate vrijednosti BGSVAI koja je zasnovana na višeslojnom algoritmu. Isključivanjem utjecaja varijable „Složenost strukture“ korelacije između pojedinih dimenzija i BGSVAI su blizu nule što je i očekivano jer nije realno očekivati da neke od varijabli poput varijable „Emocija“ možemo mjeriti predloženim modelom baziranim na algoritmu za uklanjanje pozadine.

5.2.Hipoteza 1

Kao što je prethodno navedeno prva hipoteza glasi:

H1 - Vizualna aktivnost u dinamičnim slikama mjerljiva je uporabom algoritama za uklanjanje pozadine: očekuje se statistički značajna povezanost vizualne aktivnosti mjerene algoritmima za uklanjanje pozadine i postojećeg Indeksa vizualne aktivnosti.

Za testiranje povezanosti vizualne aktivnosti mjerene odabranim višeslojnim algoritmom (eng. *Multilayer BGS*) i Indeksa vizualne aktivnosti (VAI, eng. *Visual Activity Index*) izračunat je Spearmanov koeficijent korelacije.

Tablica 19 su navedene VAI i BGSVAI vrijednosti za svih 135 analiziranih video isječaka.

Tablica 19 - VAI i BGS VAI vrijednosti za video isječke

BROJ ISJEČKA	VAI	BGS VAI
1	0,1843	0,60326397

BROJ ISJEČKA	VAI	BGS VAI
69	0,00533	0,01173386

2	0,12041	0,3990822
3	0,06126	0,41137529
4	0,04309	0,13160294
5	0,049915	0,26480622
6	0,11658	0,40001051
7	0,03418	0,1469605
8	0,010005	0,12639906
9	0,01427	0,13571138
10	0,10932	0,42275159
11	0,018	0,10442482
12	0,15626	0,31105023
13	0,009405	0,08150544
14	0,03304	0,15911899
15	0,0008	0,03448338
16	0,011545	0,03972614
17	0,00357	0,05111002
18	0,01536	0,01723632
19	0,04326	0,24988217
20	0,03816	0,1324817
21	0,004815	0,13561004
22	0,00803	0,09533506
23	0,0035	0,12457096
24	0,03697	0,3783267
25	0,01189	0,04088168
26	0,025835	0,09984219
27	0,05455	0,0743592
28	0,170975	0,36595267
29	0,00316	0,04892285
30	0,01571	0,08717212
31	0,02118	0,06868482
32	0,016595	0,05203014
33	0,002775	0,02566959
34	0,005205	0,02198452
35	0,004465	0,08191215
36	0,02192	0,08673326
37	0,057155	0,3227927
38	0,01448	0,15546177
39	0,14776	0,57168151
40	0,13915	0,44027923
41	0,25601	0,6995528
42	0,08562	0,23015779
43	0,044165	0,25325182
44	0,04696	0,13483636
45	0,0243	0,1142757
46	0,04925	0,17927012
47	0,05126	0,2508076
48	0,03017	0,22259005
49	0,06539	0,28683751
70	0,00345	0,0220515
71	0,0426	0,1134856
72	0,043945	0,31143901
73	0,04825	0,32835832
74	0,00254	0,04867712
75	0,004395	0,13939096
76	0,07905	0,22805641
77	0,01994	0,13654748
78	0,04876	0,14041115
79	0,11744	0,36299544
80	0,047755	0,07537032
81	0,00102	0,08382052
82	0,00072	0,0332519
83	0,03868	0,23269532
84	0,01036	0,0815249
85	0,00161	0,00881087
86	0,00589	0,07103355
87	0,00348	0,03297732
88	0,042945	0,21416396
89	0,07185	0,25120923
90	0,16114	0,32288204
91	0,00432	0,11196286
92	0,05044	0,34064245
93	0,00918	0,10413749
94	0,001675	0,03905706
95	0,01152	0,04801723
96	0,00581	0,10755044
97	0,021825	0,18987177
98	0,00261	0,08466777
99	0,086305	0,19728506
100	0,00613	0,14682676
101	0,04701	0,09580253
102	0,00752	3,8564E-05
103	0,01778	0,05532905
104	0,05245	0,06285566
105	0,118845	0,4860961
106	0,116765	0,42627494
107	0,103925	0,42021672
108	0,216195	0,68010456
109	0,03691	0,31157539
110	0,095945	0,24958913
111	0,1217	0,35313443
112	0,09188	0,23243281
113	0,16787	0,39839457
114	0,21652	0,31132405
115	0,03166	0,08621504
116	0,00146	0,07304516
117	0,08456	0,24402279

50	0,01264	0,05087723
51	0,126885	0,26640473
52	0,0013	0,01934076
53	0,037465	0,09194814
54	0,017165	0,09893947
55	0,065215	0,38247422
56	0,04905	0,35998981
57	0,043605	0,17201826
58	0,038865	0,1609644
59	0,07965	0,34375457
60	0,059055	0,13918248
61	0,02051	0,07892265
62	0,092195	0,34038744
63	0,041565	0,20447692
64	0,060365	0,25793817
65	0,00833	0,0892645
66	0,006505	0,07419131
67	0,04225	0,16325777
68	0,01255	0,20278646

118	0,015335	0,13956247
119	0,017125	0,20794751
120	0,27316	0,28736194
121	0,10978	0,22898057
122	0,15752	0,52413691
123	0,046765	0,19160366
124	0,09011	0,5136913
125	0,08359	0,27946459
126	0,01047	0,12017227
127	0,00271	0,06108505
128	0,153925	0,11477655
129	0,00555	0,01929948
130	0,02062	0,22357939
131	0,0301	0,13716869
132	0,05029	0,29327766
133	0,02076	0,08335148
134	0,03736	0,06511931
135	0,01643	0,08617332

Spearmanov koficijent korelacije:

$$r_s = 0,823,$$

dok je Pearsonov koeficijen korelacije:

$$r = 0,793.$$

U oba slučaja $p<0,01$, odnosno vrijednosti korelacija su statistički značajne. U prilogu se nalaze izlazni rezultati korelacija dobivenih u programskom paketu SPSS. Radi se o **snažnoj pozitivnoj korelaciji** jer je vrijednost koeficijenta korelacije između 0,7 i 1 (Horvat et al, 2012).

Slika 49 je grafički prikazana povezanost VAI i BGSVAI vrijednosti za video isječke na raspršenom grafu.

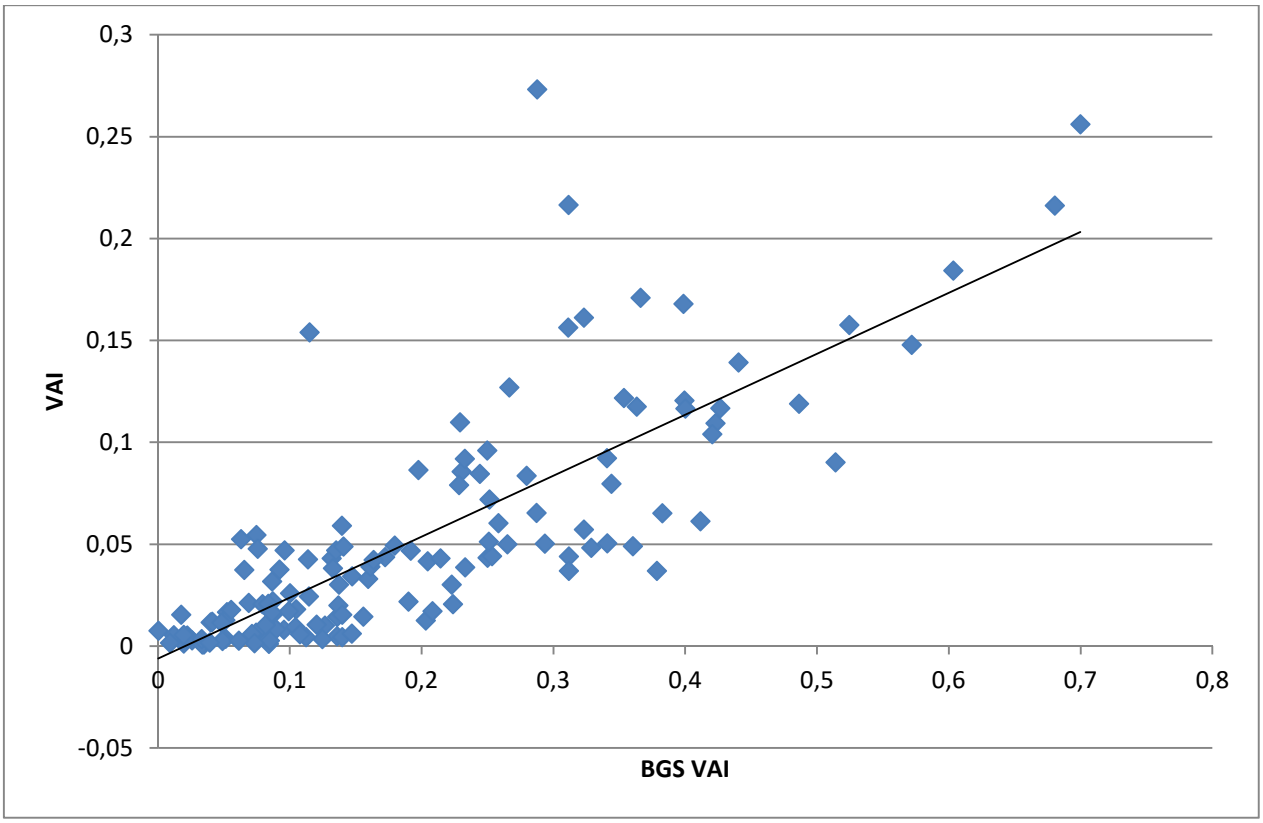

Slika 49 – Grafički prikaz povezanost VAI i BGS VAI vrijednosti za video isječke

Na osnovu dobivene vrijednosti korelacije možemo prihvatiti hipotezu H1:

H1 - Vizualna aktivnost u dinamičnim slikama mjerljiva je uporabom algoritama za uklanjanje pozadine: očekuje se statistički značajna povezanost vizualne aktivnosti mjerene algoritmima za uklanjanje pozadine (BGS VAI, *Background Subtraction Visual Activity Index*) i Indeksa vizualne aktivnosti (VAI, eng. *Visual Activity Index*).

5.3.Hipoteza 2

Druga hipoteza glasi:

H2 - Metoda mjerenja vizualne aktivnosti algoritmom za uklanjanje pozadine, kod uvođenja različitih razina šuma u video sadržaje, robusnija je u odnosu na postojeću metodu koja koristi Indeks vizualne aktivnosti: očekuje se postojanje statistički značajne razlike rezultata mjerenja vizualne aktivnosti temeljenog na algoritmima za uklanjanje pozadine i postojećeg Indeksa vizualne aktivnosti, kod uvođenja različitih razina šuma u video sadržaje.

Šum je degradacija kvalitete slike koja nastaje iz više razloga. Može nastati na samom senzoru koji pretvara elektromagnetsko zračenje vidljivog spektra u napon, ali i pri prijenosu i obradi signala. Mjera VAI je medijan razlike vrijednosti pojedinačnih točaka i osjetljiv je na šum, a s druge strane imamo predloženi Indeks vizualne aktivnosti BGSVAI koji se bazira na algoritmima za uklanjanje pozadine. Navedeni algoritmi najčešće imaju implementiran dio koji ima za cilj smanjiti utjecaj nekih vrsta šuma, što bi moglo činiti predloženi Indeks kvalitetnijom mjerom vizualne aktivnosti.

Jedna od karakteristika šuma je da je najčešće nepredvidiv i samim tim se opisuje stohastičkim modelima. Postoji više modela koji služe za opisivanje šuma, a Sonka i suradnici navode više kategorija šuma koji se pojavljuju na području računalnog vida, odnosno u video sadržajima:

a) bijeli šum
b) Gaussov šum
c) aditivni šum
d) multiplikativni šum
e) kvantizacijski šum
f) šum u impulsima (Sonka et al, 1993).

Od navedenih Gaussov šum je jedna od češće korištenih aproksimacija šuma, a slučajna varijabla normalno distribuirana ima gustoću vjerojatnosti definirana izrazom:

$$p(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{\frac{-(x-\mu)^2}{2\sigma^2}}$$

pri čemu je μ srednja vrijednost, a σ standardna devijacija slučajne varijable (Sonka et al, 1993).

Za unos šuma u video isječke korišten je programski paket MatLAB R2012b tvrtke Mathworks, pri čemu je video isječcima dodan šum distribuiran po spomenutoj Gausovoj krivulji. U programskom paketu MATLAB za to se koristi funkcija *imnoise* []. Navedena funkcija ima sljedeću sintaksu:

J = imnoise(I,'gaussian',M,V)

u slučaju da se želi slici dodati šum distribuiran po Gausovoj krivulji. Varijabla J predstavlja sliku sa dodanim šumom, dok varijabla I predstavlja sliku kojoj treba dodati šum. Varijabla M je srednja vrijednost šuma, dok je varijabla V varijanca šuma koji se dodaje. Treba napomenuti

da su sve vrijednosti pretvorene u brojeve s pomičnim zarezom zbog manje vjerojatnosti gubitka informacija kod obrade slika. Slika 50 prikazuje prvu sliku jednog video isječka koji se koristio u radu, ali bez dodanog šuma. Slika 55 je zadnja u nizu od pet slika iza slike bez šuma, na kojima se vidi sve veća razina šuma. Tablica 20 prikazuje različite vrijednosti varijance šuma koji je dodan slici, a na slikama ispod su i vidljive te razlike.

Tablica 20 – Slike i vrijednosti dodanog šuma

SLIKA	Srednja vrijednost dodanog šuma	Varijanca dodanog šuma
Slika 50	0	0
Slika 51	0	0,0001
Slika 52	0	0,001
Slika 53	0	0,01
Slika 54	0	0,1
Slika 55	0	1

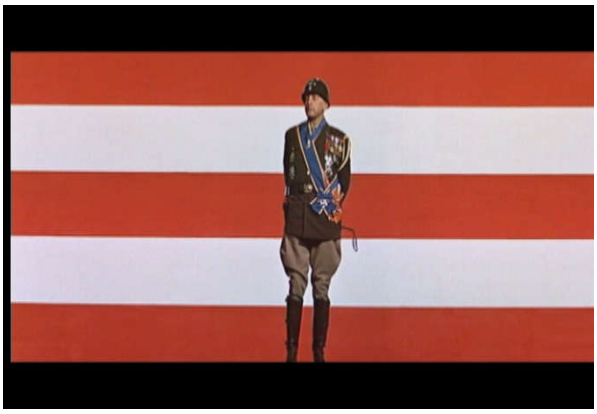

Slika 50 – Varijanca 0

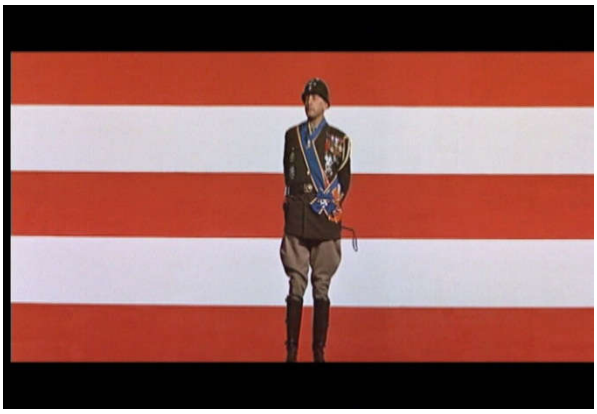

Slika 51 – Varijanca 0,0001

Slika 52 – Varijanca 0,001

Slika 53 – Varijanca 0,01

Slika 54 – Varijanca 0,1

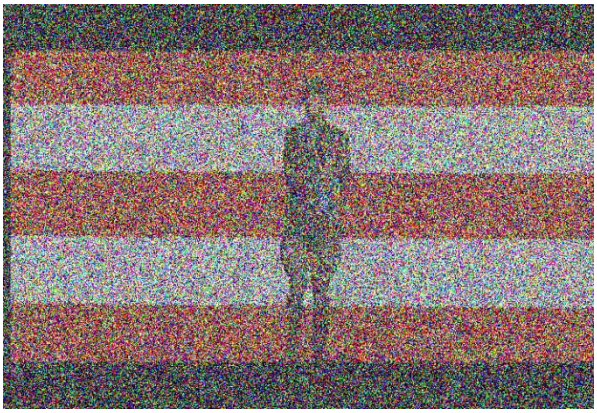

Slika 55 – Varijanca 1

Da bi se utvrdilo utjecaj šuma na vrijednosti VAI i BGSVAI, slučajnim izborom je izabran jedan od video isječaka koji su korišteni u radu Lang te su mu dodavane različite razine šuma na način da se mijenjala varijanca Gausove distribucije šuma u funkciji *imnoise*. Tablica 21 prikazuje te vrijednosti, a na slikama Slika 56 i Slika 57 se grafički vidi rast vrijednosti VAI i BGSVAI kako raste varijanca šuma dodanog svim slikama video isječka.

Tablica 21 – Vrijednosti VAI I BGS VAI za različite varijance distribucije šuma

Varijanca dodanog šuma	0	0,0001	0,001	0,01
VAI	0,010005	0,011140	0,023455	0,192135
BGSVAI	0,126399	0,131926	0,185899	0,722737

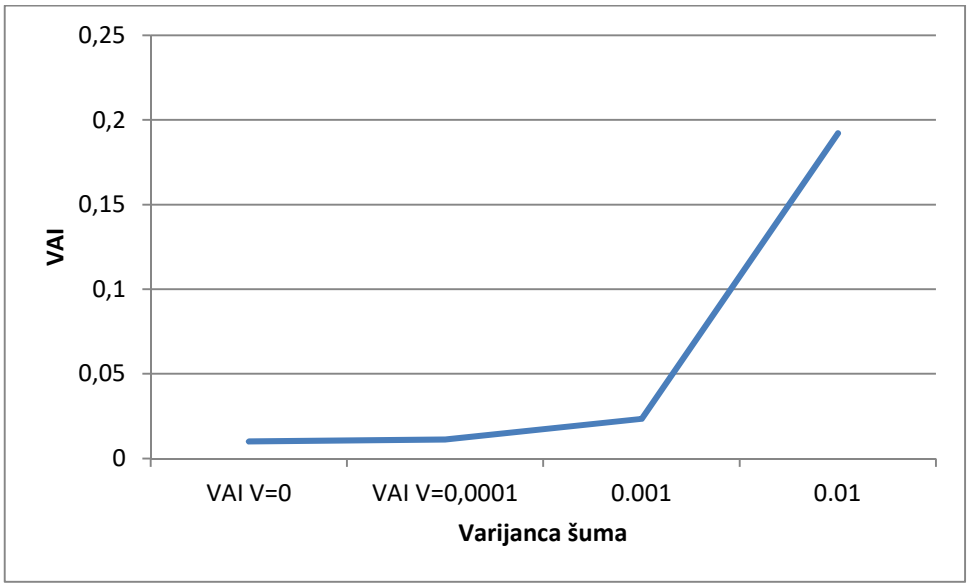

Slika 56 – VAI vrijednosti za različite varijance šuma za jedan video isječak

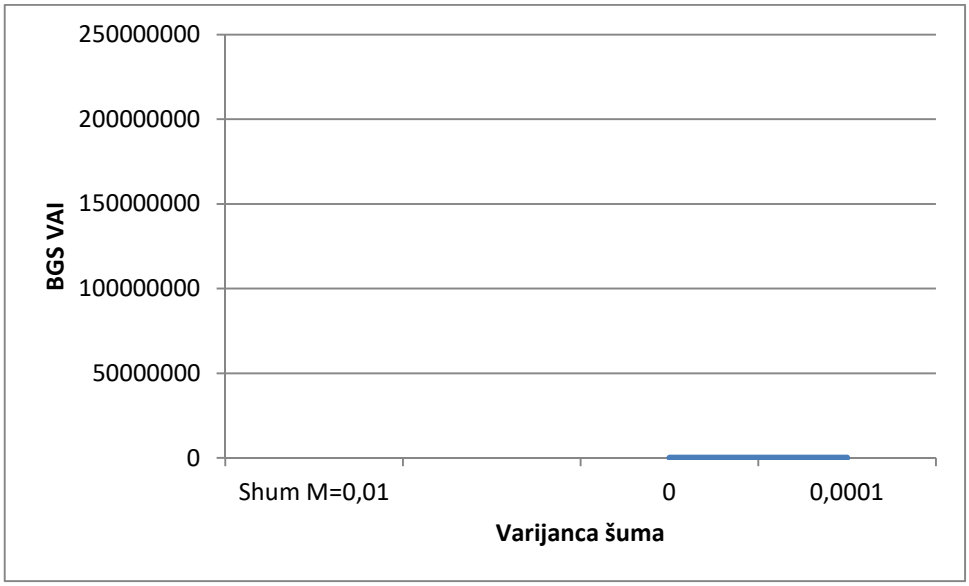

Slika 57 – BGS VAI vrijednosti za različite varijance šuma za jedan video isječak

Dobivene vrijednosti ukazivale su na to da treba krenuti s najmanjom vrijednošću varijance, te nakon dodavanja relativno male količine šuma analizirati značajnost utjecaja na mjere VAI I BGSVAI. Od 135 video isječaka od Lang koji su korišteni u radu izabrano je 30 video isječaka, te je tim isječcima dodan šum na opisan način. Pri tom se koristio MatLAB programski kod koji se nalazi u prilogu disertacije. Dobivene vrijednosti su u tablici Tablica 22, pri čemu su parovi video isječaka u kojima je došlo do rasta VAI ili BGSVAI ukošeni, dok su parovi u kojima je došlo do pada VAI ili BGS VAI vrijednosti podebljani.

Tablica 22 – Vrijednosti VAI I BGS VAI uz različite varijance šuma

Broj video isječka	VAI (V=0)	VAI (V=0,0001)	BGS VAI (V=0)	BGS VAI (V=0,0001)
8	*0,010005*	*0,01114*	*0,12639906*	*0,131925963*
9	*0,01427*	*0,01502*	*0,135711377*	*0,13622549*
12	*0,15626*	*0,15765*	**0,311050235**	**0,292797692**
17	*0,00357*	*0,00379*	*0,05111002*	*0,053478238*
21	*0,004815*	*0,006145*	*0,135610043*	*0,139439539*
24	**0,03697**	**0,036805**	**0,378326696**	**0,358923384**
25	*0,01189*	*0,015095*	*0,040881677*	*0,04099519*
28	*0,170975*	*0,17181*	*0,365952672*	*0,373714908*
33	*0,002775*	*0,00466*	*0,025669591*	*0,026237902*
43	*0,044165*	*0,044485*	*0,253251822*	*0,254523764*
51	*0,126885*	*0,12889*	**0,266404731**	**0,266217611**
59	*0,038865*	*0,03975*	*0,160964404*	*0,163049247*
61	*0,059055*	*0,06061*	*0,13918248*	*0,139722911*
74	*0,043945*	*0,044805*	**0,311439009**	**0,29891542**
77	*0,004395*	*0,005745*	*0,139390964*	*0,139855469*
82	*0,047755*	*0,049775*	*0,075370316*	*0,079136779*
86	*0,03868*	*0,03931*	**0,232695317**	**0,21463928**

91	*0,042945*	*0,04373*	**0,214163958**	**0,206843369**
93	*0,16114*	*0,162185*	**0,322882035**	**0,322085977**
100	*0,021825*	*0,02261*	**0,189871771**	**0,176147983**
107	*0,01778*	*0,01837*	*0,055329048*	*0,058991029*
113	*0,03691*	*0,03784*	**0,311575393**	**0,298592587**
118	*0,16787*	*0,168465*	**0,398394571**	**0,397028598**
123	*0,08456*	*0,0846*	**0,244022792**	**0,235339074**
126	*0,017125*	*0,017855*	**0,207947506**	**0,205282002**
127	*0,27316*	*0,27368*	**0,287361936**	**0,281852875**
134	*0,01047*	*0,01127*	*0,120172267*	*0,128029776*
137	*0,00555*	*0,01128*	**0,019299482**	**0,019185001**
138	*0,02062*	*0,02094*	**0,223579389**	**0,210500102**
143	*0,019685*	*0,021875*	**0,086173319**	**0,079379998**

Iz tablice se vidi da dodavanjem šuma VAI vrijednost za video isječke raste osim za samo jedan slučaj, ali kod BGSVAI vrijednosti podatci su značajno drugačiji. Za 14 od 30 video isječaka BGSVAI vrijednost je porasla, dok je kod 16 od 30 video isječaka BGSVAI vrijednost smanjena što ukazuje da je BGSVAI robusniji za manje količine šuma. U tablici Tablica 22 su u zadnja dva stupca podebljane vrijednosti za slučajeve kada je vrijednost BGSVAI manja za video isječke kojima je dodan šum. Na slikama broj Slika 58 – Vrijednosti VAI i Slika 59 – Vrijednosti BGS VAI je to vidljivo i na grafičkom prikazu ako se usredotočimo na vrhove stupaca. Očigledno je da su na slici Slika 58 crveni stupci neznatno viši od plavih pri čemu oni prikazuju vrijednost VAI za video isječke kojima je dodan šum srednje vrijednosti M=0 i varijance V=0,0001. Na slici broj Slika 59 za neke video isječke viši su crveni stupci, a za neke plavi.

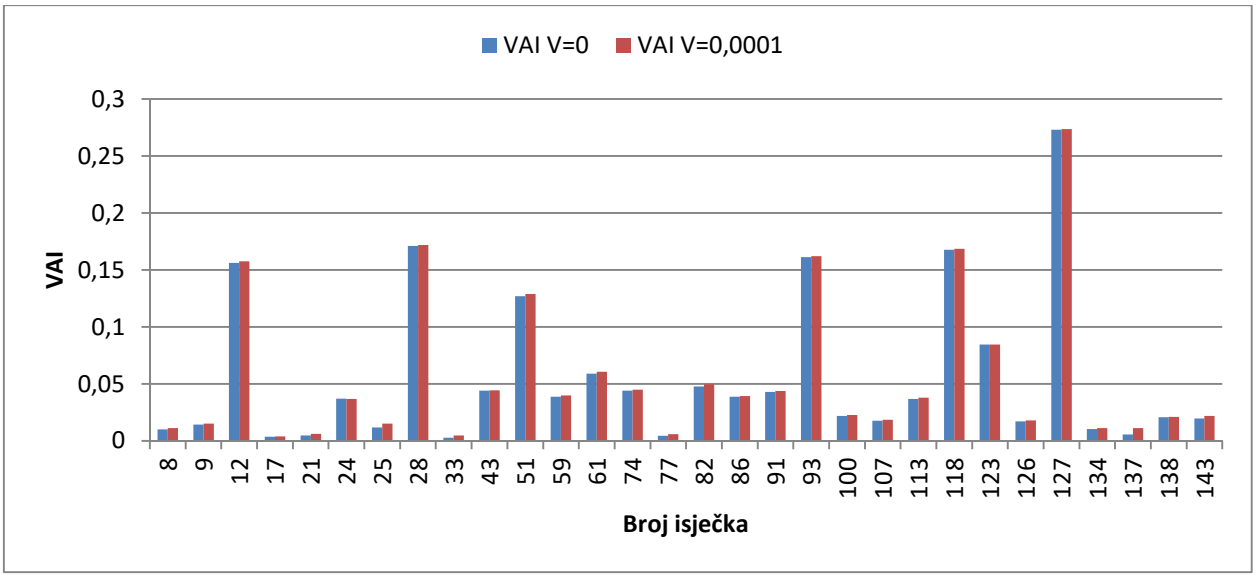

Slika 58 – Vrijednosti VAI za izabrane video isječke

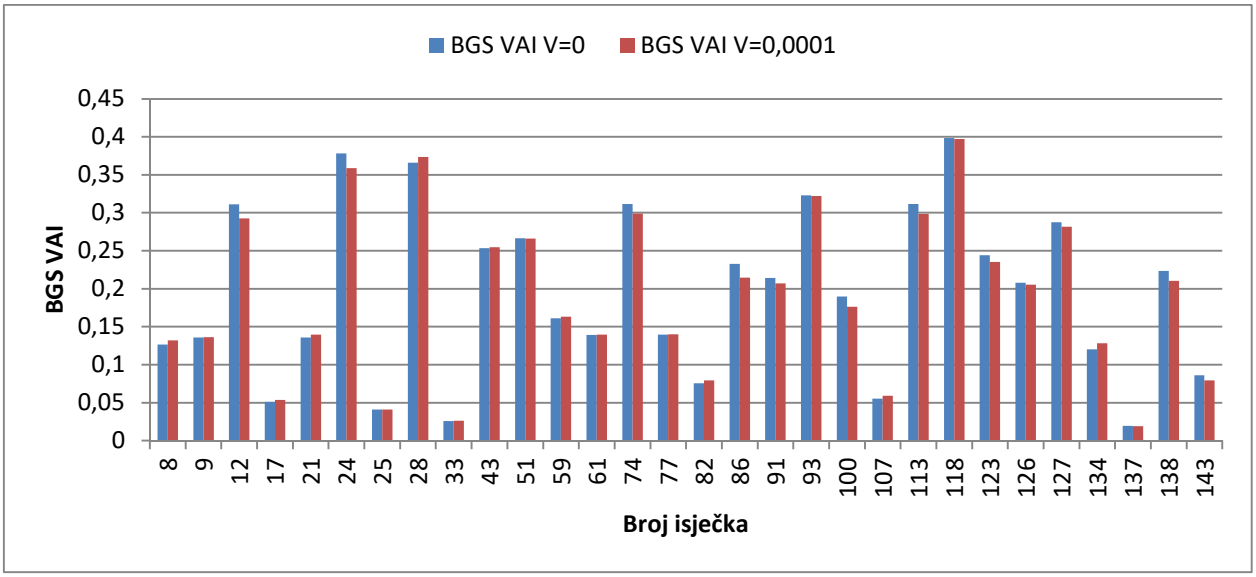

Slika 59 – Vrijednosti BGS VAI za izabrane video isječke

Dobivene vrijednosti ukazuju da bi postavljena hipoteza mogla biti točna što se treba dokazati statističkim testom. Izabran je Wilcoxonov test ranga koji je namijenjen za ponovljena mjerenja, a test je proveden korištenjem programskog paketa SPSS. Pitanje koje se postavlja je da li unošenje šuma ima utjecaj na mjere VAI i BGSVAI. Testiranje je obavljeno na način da su uspoređene vrijednosti VAI za 30 video isječaka prije i poslije dodavanja šuma, a isti postupak je izveden i za vrijednosti BGSVAI.

Wilcoxonov test ranga otkrio je da povećanje vrijednosti VAI nakon unošenja šuma u video isječke nije slučajno, a dobivene vrijednosti su $z=-4,741$ i $p<0,0005$. Medijan rezultata se unošenjem šuma povećao i to sa $Md=0,03694$ na $Md=0,03732$.

Što se tiče utjecaja šuma na vrijednosti BGSVAI Wilcoxonovim testom ranga nije se moglo dokazati statistički značajno povećanje vrijednosti, $z=-1,471$, $p=0,141$. Medijan rezultata se unošenjem šuma smanjio i to sa $Md=0,1989$ na $Md=0,1907$.

Iz dobivenih vrijednosti moguće je izračunati i veličinu utjecaja šuma na vrijednosti VAI i BGSVAI, pa tako veličina utjecaja šuma na VAI iznosi 0,61, dok veličina utjecaja šuma na BGS VAI iznosi 0,19 (Pallant, 2011). Po kriteriju Cohen-a utjecaj šuma na VAI je velik, dok je utjecaj šuma na BGS VAI mali (Cohen, 1988). (Cjelovit izlaz koji daje programski paket SPSS je u prilogu disertacije pod 10.9.)

Na osnovu dobivenih rezultata možemo zaključiti da se hipoteza H2 može prihvatiti:

H2 - Mjerenja vizualne aktivnosti algoritmima za uklanjanje pozadine kod uvođenja različitih razina šuma u video sadržaje, robusnije je u odnosu na Indeks vizualne aktivnosti.

5.4.Hipoteza 3

Treća hipoteza glasi:

H3 - Mjerenje vizualne aktivnosti algoritmima za uklanjanje pozadine ukazuje na rast vizualne aktivnost u dinamičnim slikama u zadnjih nekoliko desetljeća.

Za dokazivanje treće hipoteze potrebno je izračunati vrijednost BGSVAI za video isječke koji na neki način predstavljaju cjelokupnu svjetsku produkciju pokretnih slika što uključuje različite žanrove filmova i televizijskog programa i to u nekom dužem periodu. S obzirom da se radi o vrlo zahtjevnom zadatku koji je praktički nemoguće realizirati, za potrebe disertacije uzeti su filmovi koji su na neki način predstavljali kinematografiju određenog perioda, a osim njih analizirani su i glazbeni video spotovi u periodu od posljednjih nekoliko desetljeća.

5.4.1. Analiza filmske produkcije

S obzirom da je u zadnjih nekoliko desetljeća američka filmska industrija prilično produktivna, a i filmovi producirani u Sjedinjenim Američkim Državama su najdostupniji, u disertaciji su filmovi producirani u Sjedinjenim Američkim Državama uzeti kao predstavnici trendova. Osim američke filmske industrije prilično je produktivna i indijska, ali zbog izrazito slabe dostupnosti indijskih filmova u digitalnom obliku na ovim prostorima u disertaciji oni nisu uzeti u razmatranje. Treba spomenuti i činjenicu da posljednjih godina Sjedinjene Američke Države ne produciraju najveći broj filmova u svijetu nego je to Indija. Slika 60 prikazuje kartu svijeta na kojoj se vide pojedine države pri čemu je različitim nijansama naznačen broj produciranih filmova u 2003. godini. Što je nijansa tamnija u državi je produciran veći broj filmova u apsolutnom iznosu.

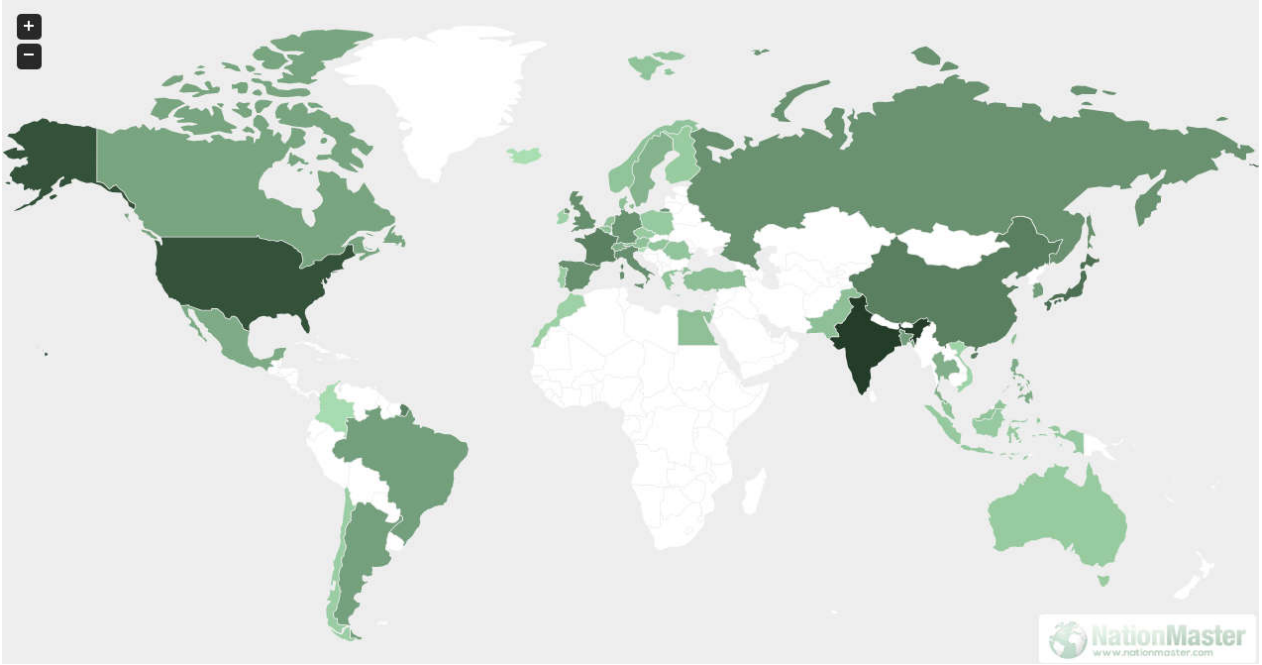

Slika 60 – Produkcija filmova na globalnoj razini u 2003. godini (Nationmaster, 2017)

Navedene godine najveći broj filmova produciran je u Indiji i to 946, dok su Sjedinjene Američke Države bile druge po produkciji sa 611 filmova, a Japan treći sa 310 filmova (Nationmaster, 2017). Slika 61 također prikazuje kartu svijeta i različitim nijansama su naznačeni brojevi produciranih filmova, ali u ovom slučaju je riječ o 2013. godini. U tih deset godina situacija se nije značajnije izmijenila, jedino što je na drugo mjesto po broju filmova došla Nigerija sa 997 filmova, a i dalje je prva bila Indija sa 1255 filmova. Sjedinjene Američke Države pale su na treće mjesto sa 819 produciranih filmova u 2013. godini (Nationmaster, 2017a).

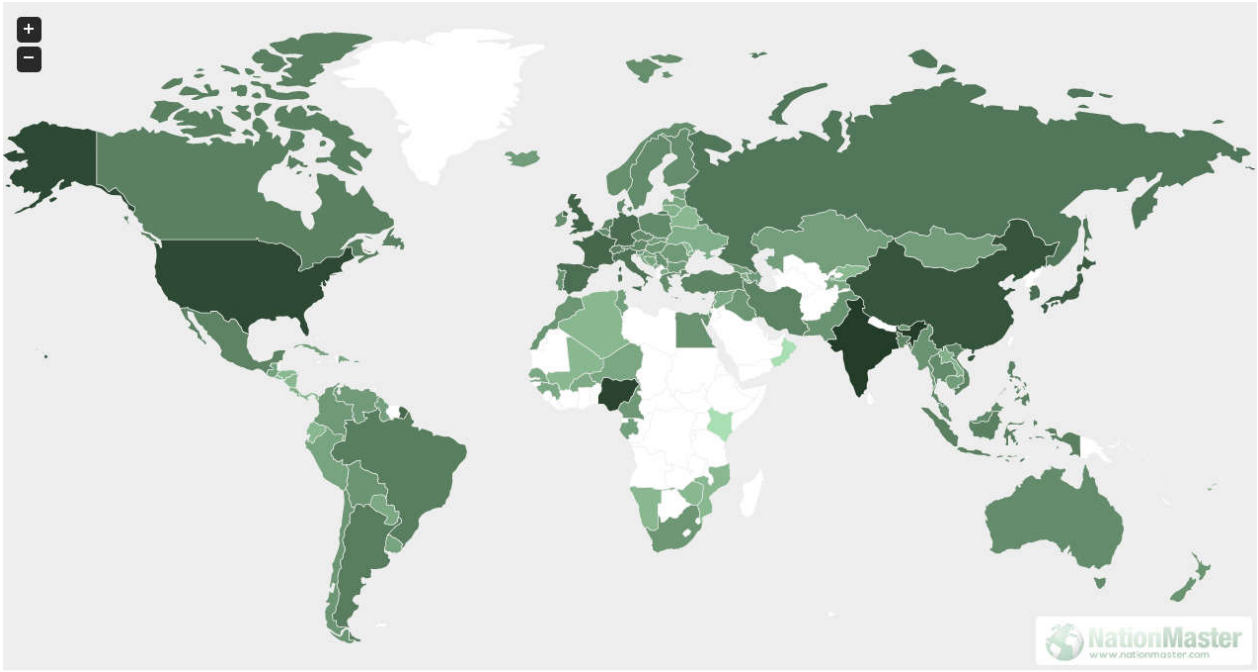

Slika 61 - Produkcija filmova na globalnoj razini u 2013. godini (Nationmaster, 2017a)

Izbor filmova američke filmske industrije za analizu je nekako logičan izbor i zbog potencijalno velikog utjecaja američke filmske industrije na filmsku industriju drugih država. Već spomenutu indijsku filmsku industriju često se kritizira zbog plagiranja i kopiranja američke filmske industrije, a indijski režiseri se brane izjavama da američki filmovi njima služe kao inspiracija (Sunder, 2011).

Nakon izbora američke filmske industrije iz prethodno navedenih razloga, potrebno je definirati kriterij izbora filmova koji će se analizirati izabranim BGSVAI algoritmom. Slučajan izbor filmova po godinama nije na žalost dolazio u obzir iz više razloga, a ključni razlog je što bi pristup svim filmovima američke filmske industrije produciranih u zadnjih pedesetak godina bio izuzetno skup. Iz tog razloga uzorak koji će biti analiziran je prigodan, a radi se o filmovima koji su dobili nagradu za najbolji film (eng. *Academy Award for Best Picture*) u pojedinoj godini od Akademije filmskih umjetnosti i znanosti (eng. *Academy of Motion Picture Arts and Sciences*). Tablica 23 navedeni su obrađeni filmovi. U prvom stupcu je godina produkcije, u drugom je naslov filma, a u trećem su režiseri istih. U tablici 25 su navedene tehničke karakteristike filmova koji su bili dobavljivi, uključujući i algoritam sažimanja, a na slici 62 je grafički prikazano trajanje filmova na način da je na vodoravnoj osi prikazan period od 1965. godine do 2014. godine.

Tablica 23 – Popis obrađenih filmova

GODINA	NAZIV FILMA	REŽISER
1965.	The Sound of Music	Robert Wise
1966.	A Man for All Seasons	Fred Zinnemann
1967.	In the Heat of the Night	Walter Mirisch
1968.	Oliver!	John Woolf
1969.	Midnight Cowboy	Jerome Hellman
1970.	Patton	Frank McCarthy
1971.	The French Connection	Philip D'Antoni
1972.	The Godfather	Albert S. Ruddy
1973.	The Sting	Tony Bill, Michael Phillips and Julia Phillips
1974.	The Godfather Part II [O]	Francis Ford Coppola, Gray Frederickson and Fred Roos
1975.	One Flew Over the Cuckoo's Nest	Michael Douglas and Saul Zaentz
1976.	Rocky	Irwin Winkler and Robert Chartoff
1977.	Annie Hall	Charles H. Joffe
1978.	The Deer Hunter	Barry Spikings, Michael Deeley, Michael Cimino and John Peverall
1979.	Kramer vs. Kramer	Stanley R. Jaffe
1980.	Ordinary People	Ronald L. Schwary
1981.	Chariots of Fire	David Puttnam
1982.	Gandhi	Richard Attenborough
1983.	Terms of Endearment	James L. Brooks
1984.	Amadeus	Saul Zaentz
1985.	Out of Africa	Sydney Pollack
1986.	Platoon	Arnold Kopelson
1987.	The Last Emperor [O]	Jeremy Thomas
1988.	Rain Man	Mark Johnson
1989.	Driving Miss Daisy	Richard D. Zanuck and Lili Fini Zanuck
1990.	Dances with Wolves	Jim Wilson and Kevin Costner
1991.	The Silence of the Lambs	Edward Saxon, Kenneth Utt and Ron Bozman
1992.	Unforgiven	Clint Eastwood
1993.	Schindler's List / The Fugitive	Steven Spielberg, Gerald R. Molen and Branko Lustig / Andrew Davis
1994.	Forrest Gump	Wendy Finerman, Steve Tisch and Steve Starkey
1995.	Braveheart	Mel Gibson, Alan Ladd Jr. and Bruce Davey
1996.	The English Patient	Saul Zaentz
1997.	Titanic	James Cameron and Jon Landau
1998.	Shakespeare in Love	David Parfitt, Donna Gigliotti, Harvey Weinstein, Edward Zwick and Marc Norman
1999.	American Beauty	Bruce Cohen and Dan Jinks
2000.	Gladiator	Douglas Wick, David Franzoni and Branko Lustig
2001.	A Beautiful Mind	Brian Grazer and Ron Howard
2002.	Chicago	Martin Richards
2003.	The Lord of the Rings: The Return of the King	Barrie M. Osborne, Peter Jackson and Fran Walsh

2004.	Million Dollar Baby	Clint Eastwood, Albert S. Ruddy and Tom Rosenberg
2005.	Crash	Paul Haggis and Cathy Schulman
2006.	The Departed	Graham King
2007.	No Country for Old Men	Scott Rudin, Joel Coen and Ethan Coen
2008.	Slumdog Millionaire [O]	Christian Colson
2009.	The Hurt Locker	Kathryn Bigelow, Mark Boal, Nicolas Chartier and Greg Shapiro
2010.	The King's Speech	Iain Canning, Emile Sherman and Gareth Unwin
2011.	The Artist / War Horse	Thomas Langmann / Steven Spielberg
2012.	Argo	Grant Heslov, Ben Affleck and George Clooney
2013.	12 Years a Slave	Brad Pitt, Dede Gardner, Jeremy Kleiner, Steve McQueen and Anthony Katagas
2014.	Birdman or (The Unexpected Virtue of Ignorance)	Alejandro G. Iñárritu, John Lesher and James W. Skotchdopole

Tablica 24 – Karakteristike obrađenih filmova

GODINA	TRAJANJE	UKUPAN BROJ SLIKA	BROJ SLIKA U SEKUNDI	ŠIRINA	VISINA	ALGORITAM SAŽIMANJA
1965.	2:54:42	251316	23.976	1920	898	H.264/MPEG-4 AVC
1966.	1:55:36	173400	25	720	416	MPEG-1/2
1967.	1:50:04	158338	23.976	1280	706	H.264/MPEG-4 AVC
1968.	2:33:41	223609	24.25	720	386	H.264/MPEG-4 AVC
1969.	1:53:21	163061	23.976	1280	706	H.264/MPEG-4 AVC
1970.	2:51:57	247360	23.976	1280	610	H.264/MPEG-4 AVC
1971.	1:39:34	149350	25	720	576	MPEG-1/2
1972.	2:57:09	254841	23.976	1280	738	H.264/MPEG-4 AVC
1973.	2:09:16	185958	23.976	1920	1058	H.264/MPEG-4 AVC
1974.	3:22:06	290733	23.976	1280	738	H.264/MPEG-4 AVC
1975.	2:13:42	192335	23.976	1920	1090	H.264/MPEG-4 AVC
1976.	1:59:36	172052	23.976	1920	1058	H.264/MPEG-4 AVC
1977.	1:33:23	134338	23.976	1920	1058	H.264/MPEG-4 AVC
1978.	3:03:32	264024	23.976	1920	816	H.264/MPEG-4 AVC
1979.	1:44:48	150761	23.976	1920	1058	H.264/MPEG-4 AVC
1980.	2:04:12	178669	23.976	1280	706	H.264/MPEG-4 AVC
1981.	2:03:33	177734	23.976	1280	706	H.264/MPEG-4 AVC
1982.	3:11:14	275101	23.976	1920	834	H.264/MPEG-4 AVC
1983.	2:11:55	189770	23.976	1920	1090	H.264/MPEG-4 AVC
1984.	3:00:27	259588	23.976	1920	802	H.264/MPEG-4 AVC
1985.	2:40:55	231488	23.976	1920	1058	H.264/MPEG-4 AVC
1986.	1:59:49	172363	23.976	1920	1058	H.264/MPEG-4 AVC
1987.	2:42:42	234288	24	1920	962	H.264/MPEG-4 AVC
1988.	2:13:52	192575	23.976	1920	1058	H.264/MPEG-4 AVC
1989.	1:39:24	142993	23.976	1280	738	H.264/MPEG-4 AVC
1990.	3:56:38	340411	23.976	1920	834	H.264/MPEG-4 AVC
1991.	1:58:31	170493	23.976	1280	704	H.264/MPEG-4 AVC
1992.	2:10:40	187972	23.976	1920	834	H.264/MPEG-4 AVC

1993.	3:15:12	280807	23.976	1920	1058	H.264/MPEG-4 AVC
1994.	2:22:09	204491	23.976	1920	834	H.264/MPEG-4 AVC
1995.	2:57:43	255656	23.976	1920	834	H.264/MPEG-4 AVC
1996.	2:41:48	232759	23.976	1920	1058	H.264/MPEG-4 AVC
1997.	3:06:49	280225	25	1920	866	H.264/MPEG-4 AVC
1998.	2:03:36	177806	23.976	1280	578	H.264/MPEG-4 AVC
1999.	2:01:39	175001	23.976	1920	834	H.264/MPEG-4 AVC
2000.	2:50:57	245922	23.976	1920	834	H.264/MPEG-4 AVC
2001.	2:15:19	194661	23.976	1920	1058	H.264/MPEG-4 AVC
2002.	1:53:16	163104	24	1920	1058	H.264/MPEG-4 AVC
2003.	3:21:02	289534	23.976	1920	802	H.264/MPEG-4 AVC
2004.	2:12:31	190633	23.976	1920	802	H.264/MPEG-4 AVC
2005.	1:55:00	165434	23.976	720	320	MPEG-4
2006.	2:31:19	217678	23.976	1920	802	H.264/MPEG-4 AVC
2007.	2:02:10	175744	23.976	1920	834	H.264/MPEG-4 AVC
2008.	1:55:14	172850	25	1920	802	H.264/MPEG-4 AVC
2009.	2:10:39	187948	23.976	1920	1090	H.264/MPEG-4 AVC
2010. ?	1:58:29	170616	24	720	384	MPEG-4
2011.	1:40:28	144527	23.976	1420	1090	H.264/MPEG-4 AVC
2012.	2:00:22	173155	23.976	1920	802	H.264/MPEG-4 AVC
2013.	2:14:10	193007	23.976	1920	802	H.264/MPEG-4 AVC
2014.	1:59:17	171596	23.976	1920	1058	H.264/MPEG-4 AVC

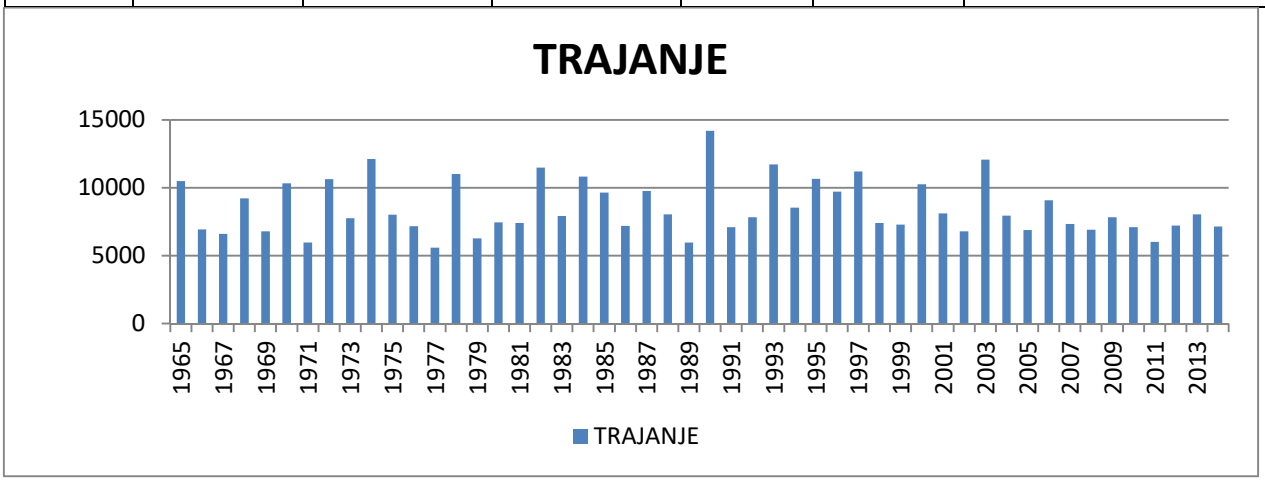

Slika 62 – Grafički prikaz trajanja obrađenih filmova u sekundama

S obzirom da se radi o pedeset filmova koji u prosjeku imaju oko dvjesto tisuća pojedinačnih slika (eng. *frame*) svaki, ukupno je obrađeno nešto preko 10 milijuna pojedinačnih slika. Algoritam je testiran na nekoliko računala te su vremena obrade po pojedinoj slici iznosila između 2 i 5 sekundi. Na novijim bržim računalima sa procesorom i5 tvrtke Intel to vrijeme je iznosilo 2 sekunde što bi ukupno za obradu svih 50 filmova iznosilo nešto preko 7 mjeseci. Iz tog razloga obrada filmova je distribuirana na 11 istih, ali slabijih računala s procesorom tvrtke AMD i to modelom *Athlon 64 X2 Dual Core 5000+* radnog takta 2,6 GHz. Da bi se izbjeglo konfiguriranje svakog računala, koristio se program *VMware Player* koji omogućuje korištenje

virtualnog računala na koji se može instalirati operativni sustav i potrebni programi. Na taj način konfiguracija okruženja je napravljena samo jednom te je datoteka sa slikom kompletnog tvrdog diska kopirana na ostala računala. Na jednom korištenom računalu obrada svih filmova trajala bi nešto manje od godinu dana, a s obzirom da je korišteno 11 računala istovremeno, obrada je trajala nešto više od mjesec dana. Vrijeme obrade po jednoj slici je iznosilo oko 3 sekunde. Za vrijeme obrade bilo je potrebno nadgledati računala i nakon završene obrade jednog filma pokretati obradu sljedećeg. Trajanje obrade pojedinačnog filma iznosilo je između 5 i 9 dana, ovisno o razlučivosti i trajanju samog filma. Tablica 25 prikazuje dobivene rezultate.

Tablica 25 – BGS VAI vrijednosti za obrađene filmove

GODINA	TRAJANJE	UKUPAN BROJ SLIKA	UKUPAN BROJ TOČAKA (eng. *pixel*)	BROJ TOČAKA (eng. *pixel*) POKRETNIH OBJEKATA	BGS VAI
1965.	2:54:42	251316	420736512000	46113627161	0,1096
1966.	1:55:36	173400	50692088160	6123280496	0,1208
1967.	1:50:04	158338	141061939200	21935125657	0,1555
1968.	2:33:41	223609	146080972800	21599568357	0,1479
1969.	1:53:21	163061	145272238080	26402562302	0,1817
1970.	2:51:57	247360	184911032320	20104773268	0,1087
1971.	1:39:34	149350	133169633280	37727277333	0,2833
1972.	2:57:09	254841	234860544000	35557793635	0,1514
1973.	2:09:16	185958	371360870400	77533776694	0,2088
1974.	3:22:06	290733	267944140800	30435057309	0,1136
1975.	2:13:42	192335	177259622400	19231568479	0,1085
1976.	1:59:36	172052	151496499200	27831804087	0,1837
1977.	1:33:23	134338	123766272000	12379220975	0,1000
1978.	3:03:32	264024	413623480320	81134272462	0,1962
1979.	1:44:48	150761	43430112000	4844632614	0,1116
1980.	2:04:12	178669	158732124160	12913258459	0,0814
1981.	2:03:33	177734	158347683840	26932991958	0,1701
1982.	3:11:14	275101	431021905920	57667065817	0,1338
1983.	2:11:55	189770	174900326400	23055787992	0,1318
1984.	3:00:27	259588	396683097600	56290577768	0,1419
1985.	2:40:55	231488	462259200000	77410350363	0,1675
1986.	1:59:49	172363	344204390400	80121615089	0,2328
1987.	2:42:42	234288	427379817760	77636379836	0,1817
1988.	2:13:52	192575	384553728000	56396392529	0,1467
1989.	1:39:24	142993	131802624000	13372878993	0,1015
1990.	3:56:38	340411	533341255680	89308497686	0,1675
1991.	1:58:31	170493	150155284480	26422966212	0,1760
1992.	2:10:40	187972	294518292480	37356168579	0,1268
1993.	3:15:12	280807	171238448640	28482571790	0,1663
1994.	2:22:09	204491	320394240000	60202772773	0,1879
1995.	2:57:43	255656	400544501760	118387183026	0,2956
1996.	2:41:48	232759	464805120000	71149284308	0,1531
1997.	3:06:49	280246	449828459520	126615057278	0,2815
1998.	2:03:36	177819	124729359360	30291631894	0,2429
1999.	2:01:39	175001	274882552320	29935635677	0,1089
2000.	2:50:57	245922	385287782400	85457711798	0,2218
2001.	2:15:19	194661	388699084800	62355130686	0,1604
2002.	1:53:16	163098	324421493760	84037769773	0,2590
2003.	3:21:16	289534	581749248000	103646142579	0,1782
2004.	2:12:31	190586	292130220800	52804198256	0,1808
2005.	1:55:00	165455	36214790400	8584587659	0,2370
2006.	2:31:19	217678	334353408000	64630653282	0,1933

2007.	2:02:10	175744	275355740160	36513382171	0,1326
2008.	1:55:14	172850	265497600000	56530580769	0,2129
2009.	2:10:39	187948	389768371200	80888685147	0,2075
2010.	1:58:29	170628	47175229440	5890310688	0,1249
2011.	1:40:28	144530	324069888000	50379667509	0,1555
2012.	2:00:22	173159	265972224000	76304560763	0,2869
2013.	2:14:10	193007	296460288000	38713888012	0,1306
2014.	1:59:17	171596	342650880000	76478143938	0,2232

Slika 63 prikazuje dobivene BGSVAI vrijednosti, a na vodoravnoj osi su navedene godine u kojima su filmovi nagrađeni za najbolji film (eng. *Academy Award for Best Picture*). Na grafikonu su uočljive dvije anomalije, a to su značajno manje vrijednosti BGSVAI za dva filma i to iz 1993. i 2011. godine. Radi se o filmovima "*Schindler's List*" i "*The Artist*" koji su snimljeni u crno-bijeloj tehnici što očigledno ima utjecaj na rezultat. Navedeni filmovi su zamijenjeni jednim od kandidata za najbolje filmove tih godina koji su izabrani slučajnim izborom, a snimljeni su u boji. Radi se o filmovima "*The Fugitive*" režisera Andrewa Davisa i "*War Horse*" režisera Stevena Spielberga.

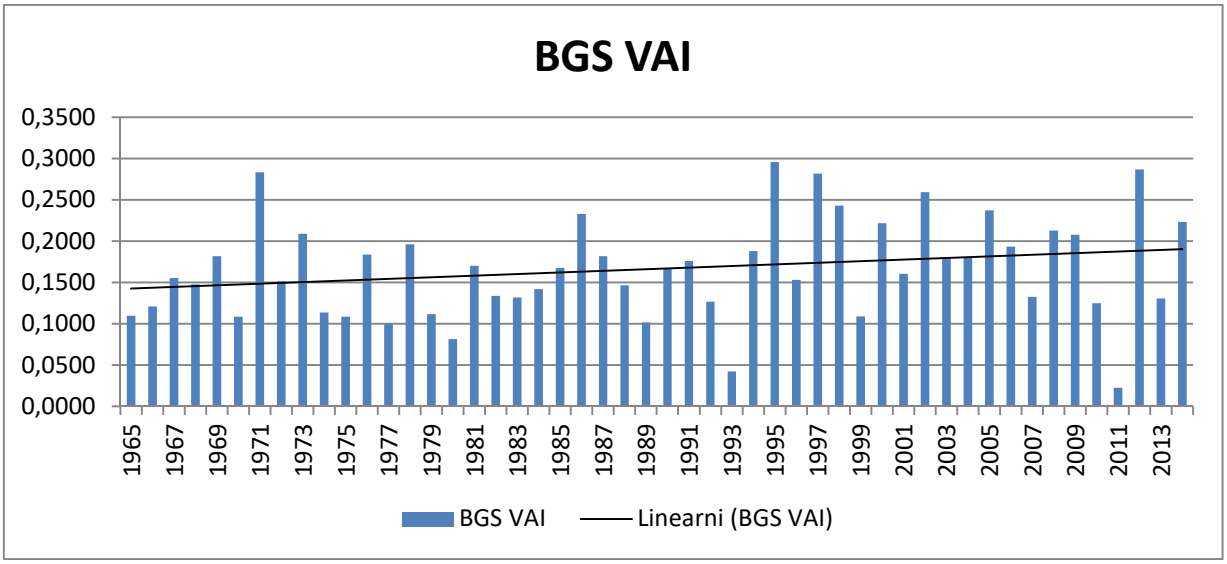

Slika 63 – BGS VAI vrijednosti za filmove

Slika 64 prikazuje BGS VAI vrijednosti nakon što su filmovi "*Schindler's List*" i "*The Artist*" zamijenjeni. Navedena anomalija vezana uz korištenje crno-bijele tehnike snimanja više nije vidljiva.

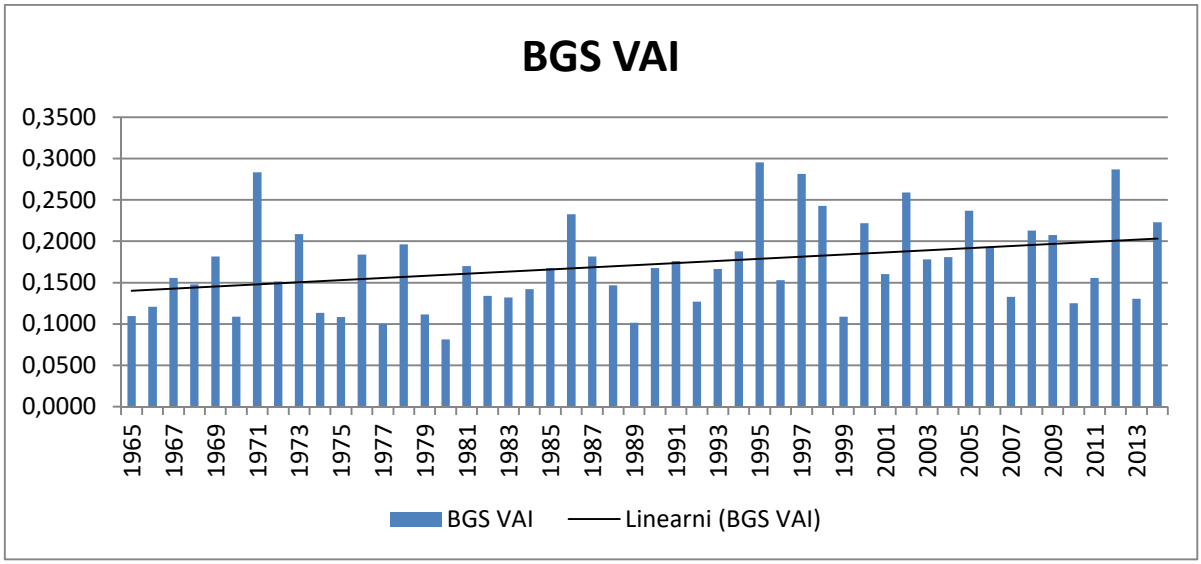

Slika 64 – BGS VAI vrijednosti nakon zamjene filmova "The Artist" i "Schindler's List"

Na osnovu dobivenih rezultata postavljamo hipoteze:

H3.0a – Nema promjene vrijednosti BGS VAI u analiziranim filmovima u promatranom periodu

H3.Aa – Vrijednosti BGS VAI rastu, odnosno padaju u analiziranim filmovima u promatranom periodu

Kako bi testirali postavljenu hipotezu koristio se Mann-Kendalov test za trendove (Mann, 1945)(Kendal, 1975). Spomenuti test se rjeđe koristi i nije implementiran u programskom paketu SPSS, a radi se o neparametrijskom testu za procjenu trenda varijable. Koristi se kao zamjena za parametrijsku linearnu regresijsku analizu (Gilbert, 1987). Hirsch i suradnici navode da se navedeni test koristi za otkrivanje značajnih odstupanja trenda varijable, kao i kvantifikaciju istih (Hirsch et al, 1982). Testiranje je provedeno korištenjem programskog paketa R Studio verzije 1.0.153. Učitani podatci su prikazani grafički na slici 65. Na okomitoj osi su BGSVAI vrijednosti, ali prikazane kao rangovi između 1 i 50, ovisno o redoslijedu.

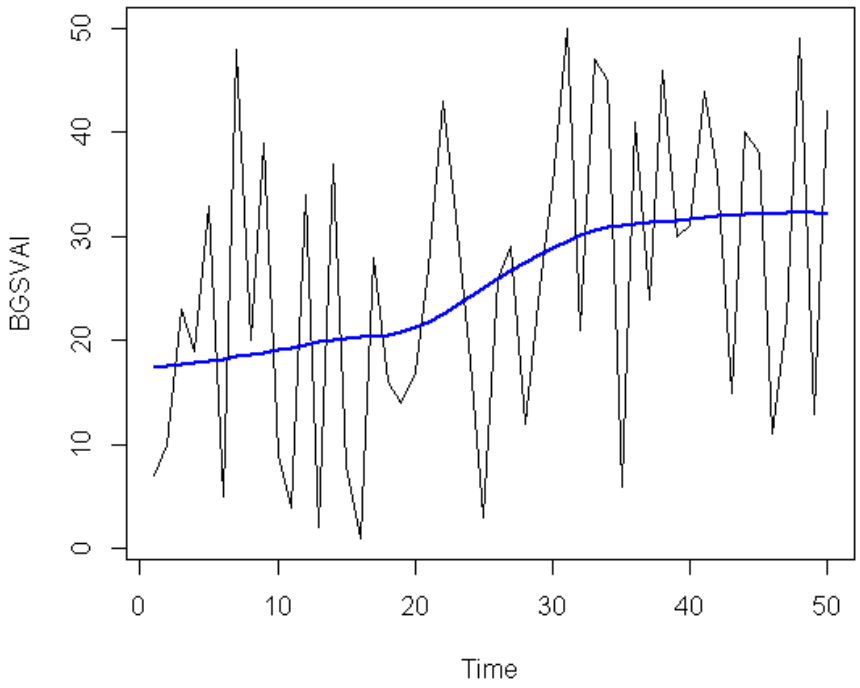

Slika 65 – Grafički prikazani BGSVAI podatci testirani Mann-Kendalovim testom za trendove

Prije provođenja testa preporučljivo je istražiti postoji li povezanost među podatcima u smislu periodičnog ponavljanja. Jedna od metoda koja se može koristiti je i vizualna inspekcija grafova dobivenih funkcijama *acf()* i *pacf()* u programu R Studio, koja izračunava autokorelaciju i djelomičnu autokorelaciju vremenskih nizova. Na slici 66 se vide rezultati navedenih funkcija te se vidi da korelacija i autokorelacija nizova nije značajna, jer je većina okomitih crta u granicama vodoravnih plavih iscrtkanih pravaca što ukazuje na izostanak navedenih pojava.

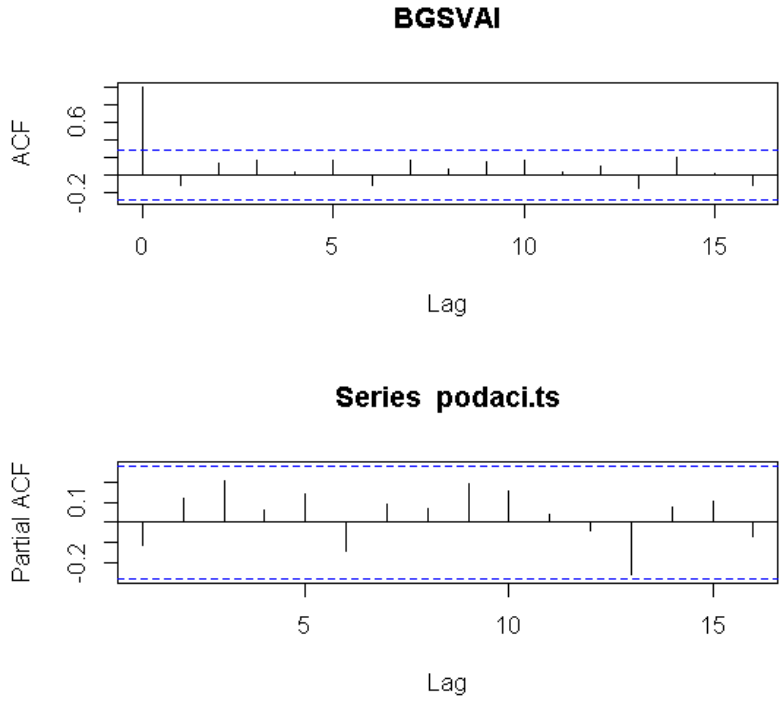

Slika 66 – Testiranje periodičnog ponavljanja u programu R Studio

Dobiveni rezultat testa je u nastavku:

$$Score = 293 \text{ , } \mathrm{Var}(Score) = 14291.67$$

$$\text{denominator} = 1225$$

$$\text{tau} = 0.239, \text{ 2-sided } p_{value} = 0.014584$$

Na osnovu dobivenih rezultata moramo odbaciti nul-hipotezu i prihvatiti alternativnu na razini značajnosti od 5%, a s obzirom da je S>0 trend je rastući. Možemo zaključiti:

H3.Aa – Vrijednosti BGSVAI rastu u analiziranim filmovima u promatranom periodu

5.4.2. Analiza glazbenih video spotova

Kod dokazivanja treće hipoteze koriste se i glazbeni video spotovi koji su dobili nagradu *MTV Best Music Video*. S obzirom da se spomenuta nagrada dodjeljuje od 1984. godine na raspolaganje je tridesetak video spotova koji su bili nagrađeni navedenom godišnjom nagradom. Pri izboru glazbenih video spotova za analizu izabran je prigodan uzorak iz sličnih razloga kao i kod filmova, a to je u ovom slučaju dostupnost materijala i globalni utjecaj

američke glazbene produkcije. Osim nagrade *MTV Best Music Video* postoji i nagrada *Video of the Year* koja se dodjeljuje tek od 2016. godine u sklopu manifestacije *American Music Award*. Ona nije zanimljiva zbog malog broja dodijeljenih nagrada. Osim nje u Sjedinjenim Američkim Državama se svake godine dodjeljuje nagrada *Grammy Award for Best Music Video* i to od 1984. godine, kao i spomenuta nagrada *MTV Best Music Video*. Ipak, zbog izmjena u kategorijama 1988. i 1989. godine kada je ta nagrada podijeljena na dvije kategorije (*Best Concept Music Video* i *Best Performance Music Video*) korišteni su glazbeni video spotovi koji su dobili nagradu *MTV Best Music Video*. Tablica 26 osim godina, izvođača i naziva pjesama koje su tih godina dobile spomenutu nagradu, daje i podatke o video isječcima koji su korišteni u analizi. Popis sa poveznicama na servis www.youtube.com sa kojeg su glazbeni video spotovi preuzeti nalazi se u prilogu disertacije.

Tablica 26 – Popis dobitnika nagrade MTV Best Music Video od 1984. do 2013. godine

Godina	Izvođač	Naziv pjesme	Visina	Širina	Broj točaka (piksela)	Broj slika/s
1984	The Cars	"You Might Think"	162	352	57024	29.960
1985	Don Henley	"The Boys of Summer"	264	352	92928	29.971
1986	Dire Straits	"Money for Nothing"	360	480	172800	25.000
1987	Peter Gabriel	"Sledgehammer"	360	480	172800	25.000
1988	INXS	"Need You Tonight/Mediate"	360	480	172800	25.000
1989	Neil Young	"This Note's for You"	360	480	172800	29.971
1990	Sinéad O'Connor	"Nothing Compares 2 U"	360	480	172800	25.000
1991	R.E.M.	"Losing My Religion"	360	480	172800	25.000
1992	Van Halen	"Right Now"	360	640	230400	29.917
1993	Pearl Jam	"Jeremy"	360	480	172800	29.971
1994	Aerosmith	"Cryin'"	360	480	172800	23.976
1995	TLC	"Waterfalls"	360	640	230400	29.971
1996	The Smashing Pumpkins	"Tonight, Tonight"	360	480	172800	25.000
1997	Jamiroquai	"Virtual Insanity"	360	640	230400	29.971
1998	Madonna	"Ray of Light"	360	480	172800	25.000
1999	Lauryn Hill	"Doo Wop (That Thing)"	360	640	230400	29.971
2000	Eminem	"The Real Slim Shady"	360	480	172800	24.000
2001	Christina Aguilera, Lil' Kim, Mýa and Pink	"Lady Marmalade"	360	480	172800	23.976

2002	Eminem	“Without Me”	360	480	172800	23.976
2003	Missy Elliott	“Work It”	314	640	200960	23.976
2004	OutKast	“Hey Ya!”	360	480	172800	29.971
2005	Green Day	“Boulevard of Broken Dreams”	360	480	172800	23.976
2006	Panic! at the Disco	“I Write Sins Not Tragedies”	360	480	172800	23.976
2007	Rihanna (featuring Jay-Z)	„Umbrella“	360	640	230400	23.976
2008	Britney Spears	“Piece of Me”	358	640	229120	23.976
2009	Beyoncé	“Single Ladies (Put a Ring on It)”	360	640	230400	29.971
2010	Lady Gaga	“Bad Romance”	360	840	230400	23.976
2011	Katy Perry	“Firework”	360	640	230400	23.976
2012	Rihanna (featuring Calvin Harris)	„We Found Love“	360	640	230400	25.000
2013	Justin Timberlake	“Mirrors”	360	640	230400	23.976

Za razliku od prethodno obrađenih filmova trajanje obrade glazbenih video spotova je znatno kraće. Prvi razlog je što glazbeni video spotovi traju po nekoliko minuta, a razlučivost dostupnih je znatno niža od razlučivosti filmova. U prethodnoj tablici je vidljivo da velika većina analiziranih glazbenih video spotova ima razlučivost 480 točaka (eng. *pixel*) po vodoravnoj osi i 360 točaka po okomitoj osi. Kao i kod obrade filmova koristio se program *VMware Player* koji omogućuje korištenje virtualnog računala na koje se može instalirati operativni sustav i potrebni programi. Tablica 27 odnosno njen zadnji stupac prikazuje BGSVAI vrijednosti.

Tablica 27 – Podatci za glazbene video spotove

GODINA	Visina	Širina	Broj točaka po slici	Broj točaka pokretnih objekata	Ukupan broj točaka	BGSVAI
1984.	162	352	57024	72494034	312548544	0,231945
1985	264	352	92928	44042026	786542592	0,055994
1986	360	480	172800	293377172	1295654400	0,226432
1987	360	480	172800	252359316	1196294400	0,210951
1988	360	480	172800	34968052	689472000	0,050717
1989	360	480	172800	316057126	1350432000	0,234041
1990	360	480	172800	99994694	1360108800	0,07352
1991	360	480	172800	395507343	1222560000	0,323508
1992	360	640	230400	379074779	1780070400	0,212955
1993	360	480	172800	562672114	1724198400	0,326338
1994	360	480	172800	490205818	1374969600	0,356521
1995	360	640	230400	913513071	2171059200	0,420768
1996	360	480	172800	303170135	1118707200	0,271
1997	360	640	230400	133134028	1633305600	0,081512
1998	360	480	172800	700872811	1317427200	0,532001
1999	360	640	230400	366689671	1632153600	0,224666
2000	360	480	172800	469900451	1108512000	0,423902
2001	360	480	172800	538161267	1133913600	0,474605
2002	360	480	172800	556174802	1239494400	0,448711
2003	314	640	200960	628780797	1278708480	0,491731
2004	360	480	172800	457817577	1567468800	0,292074
2005	360	480	172800	436884349	1191456000	0,366681
2006	360	480	172800	325263929	768268800	0,423373
2007	360	640	230400	486471900	1397145600	0,34819
2008	358	640	229120	551710144	1054639360	0,523127
2009	360	640	230400	182427187	1371801600	0,132984
2010	360	840	230400	276892417	1699200000	0,162955
2011	360	640	230400	447656833	1290470400	0,346894
2012	360	640	230400	527334058	1586073600	0,332478
2013	360	640	230400	469933334	2763648000	0,170041

Slika 67 prikazuje vrijednosti BGS VAI za glazbene video spotove od 1984. do 2013. godine, a prikazana je i crta trenda.

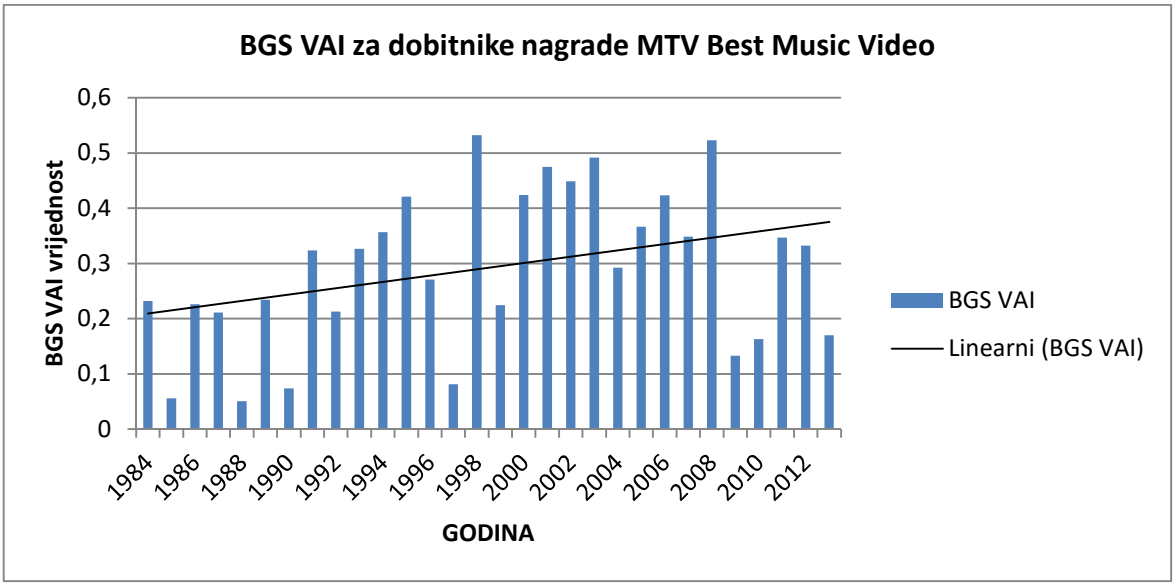

Slika 67 – BGS VAI vrijednosti za glazbene video spotove

Na osnovu dobivenih rezultata postavljamo hipoteze:

H3.0b – Nema promjene vrijednosti BGSVAI u analiziranim glazbenim video spotovima u promatranom periodu

H3.Ab – Vrijednost BGSVAI raste, odnosno pada u analiziranim glazbenim video spotovima u promatranom periodu

Radi testiranja postavljene hipoteze, kao i prethodno s filmovima, koristio se Mann-Kendalov test za trendove (Mann, 1945)(Kendal, 1975). Kao što je već navedeno radi se o neparametrijskom testu za procjenu trenda varijable. Koristi se kao zamjena za parametrijsku linearnu regresijsku analizu (Gilbert, 1987). Hirsch i suradnici navode da se navedeni test koristi za otkrivanje značajnih odstupanja trenda varijable, kao i kvantifikaciju istih (Hirsch et al, 1982). Testiranje je provedeno korištenjem programskog paketa R Studio verzije 1.0.153. Učitani podatci su prikazani grafički na slici Slika 68. Na okomitoj osi su BGSVAI vrijednosti, ali prikazane kao rangovi između 1 i 30, ovisno o redoslijedu.

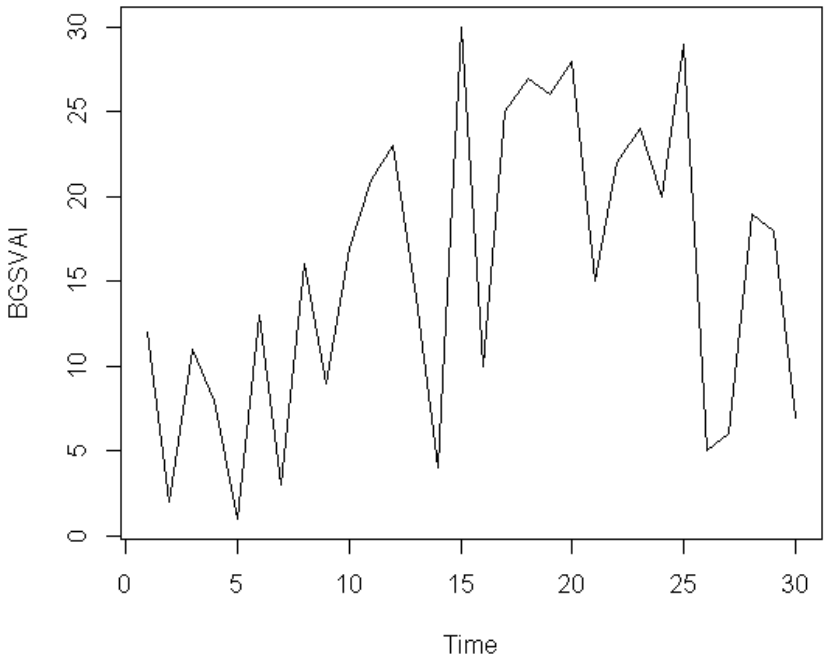

Slika 68 - Grafički prikazani BGSVAI podatci testirani Mann-Kendalovim testom za trendove

Prije provođenja testa kao i kod analize filmova istraženo je postoji li povezanost među podatcima u smislu periodičnog ponavljanja. Koristila se vizualna inspekcija uz pomoć funkcija *acf()* i *pacf()* u programu R Studio, koja izračunava autokorelaciju i djelomičnu autokorelaciju vremenskih nizova. Slika 69 prikazuje rezultate navedenih funkcija, na kojima se vidi da korelacija i autokorelacija nizova nije značajna, jer je većina okomitih crta u granicama vodoravnih plavih iscrtkanih pravaca što ukazuje na izostanaka navedenih pojava.

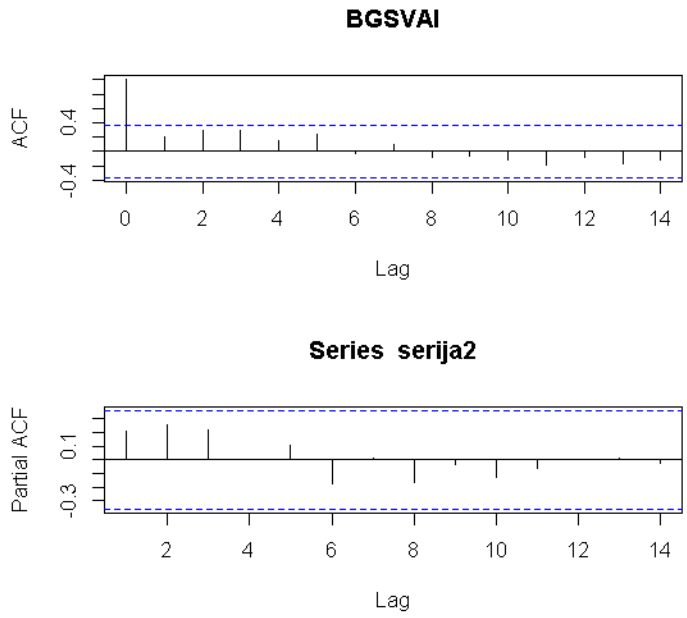

Slika 69 - Testiranje periodičnog ponavljanja u programu R Studio

Dobiveni rezultat testa je u nastavku:

$$Score = 111 \text{ , } \mathrm{Var}(Score) = 3141.667$$

$$\text{denominator} = 435$$

$$\text{tau} = 0.255, \text{ 2-sided } p_{value} = 0.049703$$

Na osnovu dobivenih rezultata moramo odbaciti nul-hipotezu i prihvatiti alternativnu na razini značajnosti od 5%, a s obzirom da je S>0, trend je rastući. Možemo zaključiti:

H3.Ab – Vrijednost BGS VAI raste u analiziranim glazbenim video spotovima u promatranom periodu

Iz navedenog se može zaključiti da se i hipoteza H3 prihvaća:

H3 - Mjerenje vizualne aktivnosti algoritmima za uklanjanje pozadine ukazuje na rast vizualne aktivnost u dinamičnim slikama u zadnjih nekoliko desetljeća.

6. REZULTATI I RASPRAVA

Rasprava rezultata dobivenih prethodno opisanim statističkim testovima bit će provedena redoslijedom postavljenih hipoteza:

H1 - Vizualna aktivnost u dinamičnim slikama mjerljiva je uporabom algoritama za uklanjanje pozadine: očekuje se statistički značajna povezanost vizualne aktivnosti mjerene algoritmima za uklanjanje pozadine i Indeksa vizualne aktivnosti.

H2 – Metoda mjerenje vizualne aktivnosti algoritmima za uklanjanje pozadine kod uvođenja različitih razina šuma u video sadržaje, robusnija je u odnosu na Indeks vizualne aktivnosti: očekuje se postojanje statistički značajne razlike rezultata mjerenja vizualne aktivnosti temeljenog na algoritmima za uklanjanje pozadine i Indeksa vizualne aktivnosti, kod uvođenja različitih razina šuma u video sadržaje.

H3 - Mjerenje vizualne aktivnosti algoritmima za uklanjanje pozadine ukazuje na rast vizualne aktivnost u dinamičnim slikama u zadnjih nekoliko desetljeća.

Prije svega potrebno je razjasniti sam pojam vizualne aktivnosti kojem različiti autori dodjeljuju različita značenja. Analizom literature uočena su dva dijametralno suprotna značenja pojma, jedno se odnosi na vizualnu aktivnost subjekta, dok se drugo odnosi na vizualnu aktivnost objekta, pri čemu se najčešće radi o mediju. Daljom analizom literature vezane uz vizualnu aktivnost objekta, odnosno medija i načina mjerenja iste utvrđeno je da postoji nekoliko metoda mjerenja vizualne aktivnosti i to:

a) Mjerenje dužine kadrova
b) Vizualni otisak prsta
c) Filmski oblaci
d) Indeks vizualne aktivnosti

Analizom sveobuhvatnosti i utjecaja na znastvenu zajednicu navedenih metoda jest očigledno da je Indeks vizualne aktivnosti, bez obzira što je predložen prije manje od jednog desetljeća, najsveobuhvatnija mjera s velikim utjecajem. Upravo zbog toga je Indeks vizualne aktivnosti iskorišten za usporedbu s predloženom mjerom vizualne aktivnosti koja se temelji na algoritmima za uklanjanje pozadine.

Korištenje algoritama za uklanjanje pozadine s ciljem mjerenja vizualne aktivnosti koje je predloženo i obrađeno u disertaciji ne spominje se u dosadašnjoj literaturi. Predloženi model

temelji se na višeslojnom algoritmu za uklanjanje pozadine (*Multi-Layer BGS*). S obzirom da postoji veći broj algoritama za uklanjanje pozadine, bilo je potrebno odabrati jedan od njih, pri čemu je odabir utemeljen na kvantitativnim pokazateljima. U tu svrhi je korišten Model ograničenog kapaciteta obrade motiviranih posredovanih poruka (LC4MP) autorice A. Lang u okviru kojega se definira pojam gustoće informacija kao učestalost novouvedenih informacija u video sadržaj pri svakoj izmjeni kadra. U LC4MP modelu „Gustoća informacija" je definirana pomoću sedam dimenzija, a za izbor algoritma analizirana je korelacija između vrijednosti dobivenih predloženom metodom (BGSVAI) i sedam dimenzija „Gustoće informacija". Dimenzije su: promjena žarišnog objekta, novi žarišni objekt, povezanost, udaljenost, perspektiva, emocija i izmjena oblika. LC4MP model je odgovarajući izbor jer definira trenutke nastanka informacijskog preopterećenja, pri čemu na iste ukazuje i kvantitativno. Na taj način su se podatci i video isječci korišteni u radovima A. Lang mogli koristiti i za izbor algoritma za uklanjanje pozadine, na način da se tražio najveći zbroj korelacija vrijednosti dobivenih predloženom metodom i pojedinih dimenzija gustoće informacija. Nakon analize tridesetak algoritama najveću vrijednost zbroja korelacija imao je već spomenuti višeslojni algoritam za uklanjanje pozadine i to 3,503. Očekivano, korelacije između nekih dimenzija i vrijednosti izračunatih predloženim modelom BGSVAI su bile znatnije, dok su druge bile neznatne. Dimenzije perspektiva (0,699), udaljenost (0,616) i promjena žarišnog objekta (0,539) imaju vrijednosti korelacije veće od 0,5 dok dimenzije novi žarišni objekt (0,495), emocija (0,386), povezanost (0,452) i izmjena oblika (0,262) imaju vrijednosti korelacije manje od 0,5. Razlika korelacija po dimenzijama je očekivana iz razloga što su neke od dimenzija gustoće informacija više ili manje povezane s brojem točaka koje tvore objekte u prednjem planu, odnosno pozadini.

Osim „Gustoće informacija" u LC4MP modelu definiran je i pojam koji se naziva „Složenost strukture" i to kao prosječan broj izmjena kadra u sekundi. Ne ulazeći dublje u analizu LC4MP modela, a poznavajući način funkcioniranja algoritama za uklanjanje pozadine može se pretpostaviti da složenost strukture ima velik utjecaj na vrijednosti dobivene predloženom metodom BGSVAI. Razlog tome je što će većina algoritama za uklanjanje pozadine izmjenu kadra u početku registrirati kao pojavu velikog broja novih pokretnih objekata u kadru i samim time će rast složenosti strukture utjecati i na rast vrijednosti dobivenih predloženom metodom BGSVAI. Korištenjem parcijalne korelacije izračunata je korelacija između pojedinih dimenzija, odnosno vrijednosti gustoće informacija i vrijednosti dobivenih predloženom metodom BGSVAI bez utjecaja „Složenosti strukture", te su dobivene vrijednosti bile relativno male, a u nekim slučajevima i negativne. Dvije dimenzije, odnosno varijable za

koje je korelacija ostala donekle značajna su povezanost (r=0,325) i perspektiva (r=0,213). Isključivanjem utjecaja varijable „Složenost strukture“ korelacije između pojedinih dimenzija i BGSVAI znatno se smanjuju što je i očekivano jer nije realno očekivati da neke od varijabli poput varijable „Emocija“ možemo mjeriti predloženom metodom BGSVAI koja se zasniva na algoritmu za uklanjanje pozadine.

Kao što je prethodno navedeno, Indeks vizualne aktivnosti (Cutting, 2011) najsveobuhvatnija je mjera te je stoga korišten za usporedbu s predloženom mjerom BGSVAI (eng. *Background Subtraction Visual Activity Index*). Za testiranje korelacije predložene metode BGSVAI i Indeksa vizualne aktivnosti (eng. *Visual Activity Index*) izračunat je Spearmanov koeficijent korelacije te on iznosi $r_s = 0,823$.

Radi se o snažnoj pozitivnoj korelaciji što je bilo i očekivano, a bez obzira na različite pristupe mjerenja vizualne aktivnosti, Indeks vizualne aktivnosti i predložena metoda BGSVAI mjere razlike u intenzitetu pojedinih točaka (eng. *pixel*) susjednih slika (eng. *frame*) u video isječku. Poopćeno, što je veći broj točaka različite boje, veća je i vrijednost vizualne aktivnosti.

Indeks vizualne aktivnosti (VAI, eng. *Visual Activity Index*) u nekim situacijama može se pokazati manjkavim u usporedbi s mogućim najboljim rješenjem za kvantifikaciju vizualne aktivnosti u video isječcima. Prije svega postavljeni model u potpunosti isključuje gledatelja, odnosno primatelja medijskog sadržaja. U nekim situacijama je moguće da vrijednost VAI prilično visoka, a primatelj medijskog sadržaja tu aktivnost praktički uopće ne primjećuje. Primjer za to bi bio snimak drveta na kojem se lišće pomiče na vjetru. Na tragu toga se nazire i druga primjedba, a to je osjetljivost na šum u video sadržaju koji može utjecati na konačnu vrijednost VAI, a opet je moguće da uopće ne bude registrirana od primatelja sadržaja. Različita otpornost na šum Indeksa vizualne aktivnosti i predložene metode BGSVAI analizirana je u okviru druge hipoteze.

Kao što je navedeno u prethodnom poglavlju za Indeks vizualne aktivnosti se ne može reći da je otporan na šum te se u drugoj hipotezi navodi da je očekivano postojanje statistički značajne razlike rezultata mjerenja vizualne aktivnosti temeljenog na algoritmima za uklanjanje pozadine (BGSVAI) i Indeksu vizualne aktivnosti, kod uvođenja različitih razina šuma u video sadržaje. Za razliku od Indeksa vizualne aktivnosti, dio algoritama za uklanjanje pozadine imaju implementiran dio koji na različite načine umanjuje utjecaj šuma. Kompleksniji algoritmi za uklanjanje pozadine su osmišljeni s ciljem da budu otporni na različite vrste šuma koji se pojavljuju na području računalnog vida.

S ciljem analize utjecaja šuma na Indeks vizualne aktivnosti i predloženu mjeru BGSVAI dodane su različite razine Gaussovog šuma testnom video isječku, koje su se razlikovale u varijanci te su izmjereni VAI i BGSVAI. Vrijednosti su prikazane grafički te je izabrana vrijednost varijance Gaussovog šuma (V=0,0001) koja će biti dodana uzorku od 30 video isječaka izabranih slučajnim odabirom. Nakon dodavanja Gaussovog šuma izmjerene su vrijednosti VAI i BGSVAI za svih 30 video isječaka te su uspoređene sa vrijednostima dobivenim prije dodavanja šuma. Dodavanjem šuma VAI vrijednost za video isječke raste u 29 od 30 video isječaka, ali kod BGSVAI vrijednosti podatci su značajno drugačiji. Za 14 od 30 video isječaka BGSVAI vrijednost je povećana, dok je kod 16 od 30 video isječaka BGSVAI vrijednost smanjena što ukazuje da je BGSVAI robusniji kod manjih količina šuma. Dalja istraživanja bi se mogla provesti sa većim količinama šuma.

Wilcoxonov test ranga otkrio je da povećanje vrijednosti VAI nakon unošenja šuma u video isječke nije slučajno, a dobivene vrijednosti su $z=-4,741$ i $p<0,0005$. Medijan rezultata se unošenjem šuma povećao i to sa $Md=0,03694$ na $Md=0,03732$. Što se tiče utjecaja šuma na vrijednosti BGSVAI, Wilcoxonovim testom ranga nije se moglo dokazati statistički značajno povećanje vrijednosti, $z=-1,471$, $p=0,141$. Medijan rezultata se unošenjem šuma smanjio i to sa $Md=0,1989$ na $Md=0,1907$.

Navedeno testiranje obavljeno je samo sa BGSVAI metodom koja se bazira na višeslojnom algoritmu za uklanjanje pozadine, s konstantnom vrijednošću varijance Gaussovog šuma i samo sa Gussovim šumom. U daljim istraživanjima mogu se koristiti i ostali algoritmi za uklanjanje pozadine, a mogu se mijenjati i vrijednosti varijance. Nadalje, osim Gaussovog šuma mogu se primijeniti i drugi modeli šuma.

Rast vizualne aktivnosti u proteklih nekoliko desetljeća uočen je korištenjem različitih mjera za tu namjenu, pa je za testiranje treće hipoteze iskorištena predložena metoda BGSVAI. Ključni problem bio je izbor uzorka, ali je zbog ograničenih sredstava i pristupa filmovima odlučeno ići na prigodan uzorak koji bi predstavljao trendove u filmskoj produkciji. Isključivo zbog dostupnosti odabrani su filmovi producirani u Sjedinjenim Američkim Državama i to oni koji su u posljednjih pedesetak godina dobili nagradu za najbolji film (eng. *Academy Award for Best Picture*) u pojedinoj godini od Akademije filmskih umjetnosti i znanosti (eng. *Academy of Motion Picture Arts and Sciences*).

Za navedene filmove nagrađene između 1965. i 2014. godine izračunate su vrijednosti BGSVAI, te se za testiranje hipoteze koristio Mann-Kendalov test za trendove. Prihvaćena je

alternativna hipoteza da vrijednosti BGSVAI rastu u analiziranim filmovima u promatranom periodu. Na rast trenda ukazuje vrijednost S=293 jer je veća od nule, a vrijednost p=0.014584.

Osim filmova analizirani su i video spotovi koji su dobili nagradu *MTV Best Music Video*.između 1984. i 2013. godine. Opet se radi o prigodnom uzorku koji predstavlja trendove u produkciji video spotova. Izračunate su vrijednosti BGSVAI te se za testiranje hipoteze opet koristio Mann-Kendalov test za trendove. Prihvaćena je alternativna hipoteza da vrijednosti BGSVAI rastu u analiziranim video spotovima u promatranom periodu. Na rast trenda ukazuje vrijednost S=111 jer je veća od nule, a vrijednost p=0.049703. Dalja analiza bi se mogla provesti sa različitim kategorijama filmova, kao što opisuje Cutting u radu u kojem uvodi Indeks vizualne aktivnosti, pri čemu analizira pet kategorija filma: akcijske, avanturističke, drame, animirane i komedije (Cutting, 2011).

7. ZAKLJUČAK

Izrada ove disertacije potaknuta je spoznajom autora da se znanstvenici s područja društevnih i humanističkih znanosti u svojim radovima često koriste kvalitativnim mjerama za opisivanje različitih razina vizualne aktivnosti u video sadržajima. Neki od radova autora ukazuju da visoke razine vizualne aktivnosti mogu negativno utjecati na kognitivne sposobnosti, ali pri tome postoji nedostatak kvantitativnih pokazatelja vrijednosti vizualne aktivnosti. Sadržaj ove disertacije nastao je u nastojanju da se doprinese istraživanju područja utjecaja video sadržaja na primatelja poruke koja sadrži dinamične slike.

Promišljanjem o načinu mjerenja vizualne aktivnosti video sadržaja u razmatranje su uzeti algoritami za uklanjanje pozadine koji pripadaju algoritmima računalnog vida. Radi se o algoritmima koji se razvijaju već desetljećima, te ih je dostupno nekoliko desetaka. Osnovna ideja kvantificiranja vizualne aktivnosti na ekranu jest da se radi o omjeru površina pokretnih objekata i ukupne površine koja se promatra, drugim riječima radi se o izlaznim vrijednostima obrade video sadržaja spomenutih algoritama za uklanjanje pozadine. Problem odabira algoritma kojim se vizualna aktivnost najbolje kvantificira riješen je usporedbom rezultata korištenja predložene metode kvantificiranja i vrijednosti „gustoće informacija“ koja je opisana u Modelu ograničenog kapaciteta obrade motiviranih posredovanih poruka.

Nakon odabira algoritma za uklanjanje pozadine, predloženi model uspoređen je s Indeksom vizualne aktivnosti koji je deifinirao Cutting i za koji se može reći da je dosadašnja jedina prihvaćena metoda mjerenja vizualne aktivnosti video sadržaja. Korelacija izračunata za vrijednosti dobivene mjerenjem predloženom metodom i postojećeg Indeksa vizualne aktivnosti, pokazala se značajno visoka, što je potvrdilo da je vizualna aktivnost u dinamičnim slikama mjerljiva uporabom predložene metode koja uključuje korištenje algoritama za uklanjanje pozadine.

Algoritmi za uklanjanje pozadine najčešće imaju implementiran dio koji ima za cilj smanjiti utjecaj nekih vrsta šuma, što bi moglo činiti predloženi mjeru otpornijom na šum u video sadržaju. Testiranje te hipoteze provedeno je uspoređivanjem utjecaja različitih razina Gaussovog šuma na navedene dvije mjere vizualne aktivnosti, Indeks vizualne aktivnosti prema Cuttingu i predloženu mjeru zasnovanu na algoritmima za uklanjanje pozadine, te je dokazano da postoji statistički značajna razlika u tom utjecaju. Predložena mjera, odnosno model mjerenja, otporniji je na šum u video sadržaju.

Konačno je predloženi model mjerenja vizualne aktivnosti korišten za dokazivanje značajnosti promjene vizualne aktivnosti u video sadržajima u posljednjih nekoliko desetljeća. Za potrebe disertacije obrađeno je 50 filmova koji su nagrađeni nagradom *Academy Award for Best Picture* u posljednjih pedesetak godina, kao i 30 video spotova koji su nagrađeni nagradom *MTV Best Music Video* u posljednjih tridesetak godina. U oba prigodna uzorka uočen je statistički značajan rast vrijednosti BGSVAI u proteklom periodu koji je bio obuhvaćen istraživanjem.

8. PREGLED NAJVAŽNIJIH DOPRINOSA

S obzirom na slojevitost disertacije koja se očituje u nužnosti završetka prethodne faze da bi se moglo prijeći u sljedeću, doprinosi su složeni u skladu s tim slijedom. Rad je podijeljen u dva dijela, a to su Teorijska razmatranja i Istraživački dio. U prvom dijelu je analizirana dostupna literatura te je izložena sama ideja o novoj metodi mjerenja gustoće informacija koja je zasnovana na algoritmima za uklanjanje pozadine. Pri tome se kao kriterij pri odabiru algoritma koristio Model ograničenog kapaciteta obrade motiviranih posredovanih poruka (LC4MP) Annie Lang. Prema tome doprinos prvog dijela je sljedeći.

1. Korištenjem „gustoće informacija“ definirane Modelom ograničenog kapaciteta obrade motiviranih posredovanih poruka (LC4MP) Annie Lang kao kriterija pri odabiru algoritma za uklanjanje pozadine, u predloženoj metodi mjerenja vizualne aktivnosti (BGSVAI) uvodi se potencijalna mogućnost daljeg razvoja i automatizacije LC4MP modela.

Doprinosi drugog dijela koji uključuje niz statističkih testova i analiza pod nazivom „Istraživački dio“ nabrojani su u nastavku.

2. Predložena metoda mjerenja vizualne aktivnosti u dinamičnim slikama kao alternativa postojećoj metodi, Indeksu vizualne aktivnosti, omogućit će znanstvenicima na području humanističkih i društvenih znanosti da kvantificiraju vizualnu aktivnost koju su do sada u radovima opisivali kvalitativno.
3. Predložena metoda mjerenja vizualne aktivnosti u dinamičnim slikama omogućit će mjerenje vizualne aktivnosti s manjim utjecajem šuma na krajnji rezultat. Ta dokazana prednost u usporedbi s postojećom metodom, Indeksom vizualne aktivnosti, ostvarena je korištenjem algoritama za uklanjanje pozadine koji su razvijani s ciljem da u što je moguće većoj mjeri uklone utjecaj šuma.
4. Ukazivanje na porast vizualne aktivnosti mjerene predloženom metodom i za period unazad nekoliko desetljeća, doprinos je poticanju rasprave o toj pojavi. Radovi koji ukazuju na negativan utjecaj viših razina vizualne aktivnosti dostupni su posljednjih nekoliko godina, ali još se nije pokrenula šira javna rasprava o tom pitanju.

9. LITERATURA

1. Williams, F., The Communications Revolution, Beverly Hills, California, Sjedinjene Američke Države, 1982.
2. Malović, S., Masovno komuniciranje, Golden marketing-Tehnička knjiga, Zagreb, 2014.
3. Mikelić, N., (2003), Metode i pravila oblikovanja multimedijske poruke i njen utjecaj na zapamćivanje i razumijevanje sadržaja, Magistarski rad, Filozofski fakultet Zagreb, 2003.
4. Wittenmark, B., Haglund, H., Johansson, M., (1998), Dynamic pictures and interactive learning, IEEE Control Systems (Volume: 18, Issue: 3, June 1998), p. 26 – 32
5. Bilen, H., Fernando, B., Gavves, E., Vedaldi, A., (2017), Action Recognition with Dynamic Image Networks, Computer Vision and Pattern Recognition (cs.CV), 2017.
6. Fergusson, R., Heilmann, C., (2013), Beginning JavaScript with DOM Scripting and Ajax: Second Editon, Apress; 2nd ed. edition (June 26, 2013)
7. Mcquail, D. (2000.): McQuail's Mass Communication Theory. 4. izdanje. London/Thousand Oaks, Ca./New Delhi.
8. Sigman, A., (2010): The Impact Of Screen Media On Children: A Eurovision For Parliament,
9. Junichi Furusho, Masakazu Suzuki, Izumi Tazaki, Hiroyuki Satoh, Katuhiko Yamaguchi, Yoji Iikura, Komei Kumagai, Tetuji Kubagawa, Tsunekatsu Hara (2002) A comparison survey of seizures and other symptoms of Pokemon phenomenon, Pediatric Neurology, Volume 27, Issue 5, November 2002, Pages 350–355
10. Lillard, A. S., & Peterson, J. (2011). The immediate impact of different types of television on young children's executive function. Pediatrics, 128, 644–649. http://dx.doi.org/ 10.1542/peds.2010-1919.
11. Watt, J. H., & Krull, R. (1974). An information theory measure for television programming. Communication Research, 1, 44–68.
12. Watt, J. H., & Welch, A. J. (1983). Effects of static and dynamic complexity on children's attention and recall of televised instruction. In J. Bryant & D. R. Anderson (Eds.), Chil dren's understanding of television: Research on attention and comprehension (pp. 69–102). New York: Academic Press.

13. Cooper, N., Uller, C., Pettifer, J., & Stolc, F. (2009). Conditioning attentional skills: Examining the effects of the pace of television editing on children's attention. Acta Paediatrica, 98, 1651–1655.
14. Lang, A., Bolls, P., Potter, R. F., & Kawahara, K. (1999). The effects of production pacing and arousing content on the information processing of television messages. Journal of Broadcasting & Electronic Media, 43, 451–475.
15. Anderson, D. R., Levin, S., & Lorch, E. (1977). The effects of TV program pacing on the behavior of preschool children. Educational Technology Research and Development, 25, 159–166.
16. Huston, A. C., Wright, J. C., Wartella, E., Rice, M. L., Watkins, B. A., Campbell, T., et al. (1981). Communicating more than content: Formal features of children's television programs. Journal of Communication, 31, 32–48.
17. D. Bordwell, (2002). Intensified continuity - Visual style in contemporary American film. Film Quarterly, 55(3), 16-28.
18. Palmer, M. Katie, Movie Trailers Are Getting Insanely Fast. Trust Us, We Counted the Cuts, http://www.wired.com/2013/06/online-trailerscuts/ (pristup: 12.10.2014.)
19. Cutting, J.E. DeLong and K.L. Brunik (2011) Visual activity in Hollywood film: 1935 to 2005 and beyond. Psychology of Aesthetics, Creativity, and the Arts 5, pp. 115-125.
20. Salt, B. (2006). Moving into pictures. London: Starword
21. Jahne, B., Haussecker, H.(2000), Computer Vision and Applications - A Guide for Students and Practitioners, Academic Press, 2000
22. Jain, Ramesh, Nagel, H. -H. (1979). On the Analysis of Accumulative Difference Pictures from Image Sequences of Real World Scenes. IEEE Trans. Pattern Anal. Mach. Intell. 1, 2 (February 1979), 206-214. DOI=10.1109/TPAMI.1979.4766907
23. Lang ,A., Park, B. ,. Sanders-Jackson,A.N. ,. Wilson, B.D. & Wang, Z. (2007) Cognition and Emotion in TV Message Processing: How Valence, Arousing Content, Structural Complexity, and Information Density Affect the Availability of Cognitive Resources, Media Psychology, 10:3, 317-338, DOI: 10.1080/15213260701532880
24. Hanjalic, A. (2002), Shot-boundary detection: unraveled and resolved?, Circuits and Systems for Video Technology, IEEE Transactions on , vol.12, no.2, pp.90,105, Feb 2002, doi: 10.1109/76.988656
25. Boreczky, John S., Rowe, Lawrence A. (1996), Comparison of video shot boundary detection techniques, Journal of Electronic Imaging 5(2), 122–128 (April 1996)

26. Christakis, D.A., Ramirez, J. S. B. Ramirez J. M. (2012), Overstimulation of newborn mice leads to behavioral differences and deficits in cognitive performance, Scientific Reports 2 (2012): 546. PMC. Web. 5 Oct. 2016.
27. Peruško, Z., „Uvod u medije“, Naklada Jesenski i Turk, Hrvatsko sociološko društvo, Zagreb, 2011.
28. Webster, Definition of medium for English Language Learners, https://www.merriam-webster.com/dictionary/medium (posjećeno: 10.10.2016.)
29. Narodne novine, Zakon o medijima, Zagreb, 7. listopada 2003.
30. Narodne novine, Zakon o audiovizualnim djelatnostima, 13. srpnja 2007.
31. Shannon, C.E., „A Mathematical Theory of Communication“, The Bell System Technical Journal, Vol. 27, pp. 379–423, 623–656, July, October, 1948.
32. Fiske, J., „INTRODUCTION TO COMMUNICATION STUDIES“, Routledge, London, 1990.
33. Sutcliffe, A., (2008), „Multimedia User Interface Design“, The Human-Computer Interaction Handbook – Fundamentals, Evolving Technology and Emerging Applications – Second edition, editors: Andrew Sears, Julie A. Jacko, HUMAN FACTORS AND ERGONOMICS, Lawrence Erlbaum Associates, Taylor & Francis Group, New York, 2008.
34. Bernsem, N.O., „Foundations of multimodal representations: a taxonomy of representational modalities“, Interacting with Computers, vol 6 no 4 (1994) 347-371
35. L.A. Jones-Jordan, G.L. Mitchell, S.A. Cotter, R.N. Kleinstein, R.E. Manny, D.O. Mutti, J.D. Twelker, J.R. Sims, K. Zadnik, Visual activity before and after the onset of juvenile myopia, Invest Ophthalmol Vis Sci, 2011 Mar 29;52(3):1841-1850
36. Fulton, J.F., OBSERVATIONS UPON THE VASCULARITY OP THE HUMAN OCCIPITAL LOBE DURING VISUAL ACTIVITY, Brain, A Journal of Neurology, 310-320, 1928. DOI: http://dx.doi.org/10.1093/brain/51.3.31
37. Land, M. F.; Lee, D. N., Where do we look when we steer, Nature, Vol 369(6483), Jun 1994, 742-744. http://dx.doi.org/10.1038/369742a0
38. Kaminski, T., Kruszewski, M., Niezgoda, M., APPLICATION OF EYETRACKING RESEARCH TECHNIQUES INTO ROAD SAFETY STUDIES – THEORETICAL CONSIDERATIONS, Journal of KONES Powertrain and Transport, Vol. 19, No. 4 2012
39. Findlay, J., Active vision: Visual activity in everyday life, Current Biology 1998, 8:R640–R642

40. Grobelny , J., Michalski, R., Weron, R., Is Human Visual Activity in Simple Human-Computer Interaction Search Tasks a Lévy Flight?, PhyCS 2015 - 2nd International Conference on Physiological Computing Systems, Proceedings 2015, p. 67-71, 2nd International Conference on Physiological Computing Systems, PhyCS 2015; ESEOAngers, Loire Valley; France; 11 February 2015 through 13 February 2015;
41. Gibson, J. J., The visual perception of objective motion and subjective movement. Psychological Review, 61, p.304–314., 1954.
42. Stelmach, B.L., ; Tam, W.J., Hearty, P.J., Static and dynamic spatial resolution in image coding: an investigation of eye movements, Proc. SPIE 1453, Human Vision, Visual Processing, and Digital Display II, 147 (June 1, 1991); doi:10.1117/12.44351
43. Goldstein, R.B., Woods, R.L., Peli, E., Where people look when watching movies: Do all viewers look at the same place?, Comput Biol Med. 2007 July ; 37(7): p.957–964.
44. Turković, H., Filmski leksikon, Leksikografski zavod Miroslav Krleža, 2008. http://film.lzmk.hr/clanak.aspx?id=761 (posjećeno: 14.12.2016.)
45. Salt, B., Statistical Style Analysis of Motion Pictures, Film Quarterly, Vol. 28, No. 1 (Autumn, 1974), pp. 13-22
46. Baxter, M., (2014), Notes on Cinemetric Data Analysis, http://www.cinemetrics.lv/dev/Cinemetrics_Book_Baxter.pdf (posjećeno: 5.8.2016.)
47. Brunick, K.L., Cutting, J.E., DeLong, J.E., Low-level features of film: what they are and why we would be lost without them, Psychocinematics – exploring cognition at the movies, Editor: Shimamura, A.P., Oxford University Press, 2013.
48. Cutting, J.E., Candan, A., (2015a), Shot Durations, Shot Classes, and the Increased Pace of Popular Movies, Projections, Volume 9, Issue 2, Winter 2015: 40–62, doi: 10:3167/proj.2015.090204
49. Cutting, J.E., Brunick, K.L., DeLong, J.E., Iricinschi, C., Candan, A., Quicker, faster, darker: Changes in Hollywood film over 75 years, i-Perception, 2, 569–576.
50. Tsivian, Y., "Cinemetrics, Part of the Humanities' Cyberinfrastructure." Digital Tools in Media Studies. Eds. Bernd Freisleben, Manfred Grauer, and Michael Ross. Bielfeld: Transcript Verlag, 2009. 93-100.
51. DeLong, J.E. Brunick, K.L., Cutting, J.E.(2012), Film through the Human Visual System: Finding Patterns and Limits, Editors: Kaufman, J.C., Simonton, D.K., The Social Science of Cinema 1st Edition, Oxford University Press, 2013.

52. Schaefer R.F., Martinez, T.J., B.A. and M.A., Trends in Network News Editing Strategies From 1969 Through 2005, Journal of Broadcasting & Electronic Media, 53:3, 347-364, 2009.
53. Redfern, N. (2012). The lognormal distribution is not an appropriate parametric model for shot length distributions of Hollywood films. Literary and Linguistic Computing, doi:10.1093/llc/fqs066
54. Baxter, M., On the distributional regularity of shot lengths in film, Digital Scholarship in the Humanities Apr 2015, 30 (1) 119-128; DOI: 10.1093/llc/fqt041
55. Brodbeck, F., CINEMETRICS - Frederic Brodbeck's bachelor graduation project at the Royal Academy of Arts (KABK), Den Haag, http://cinemetrics.fredericbrodbeck.de/ (pristup: 4.12.2016.)
56. Lim, K.K., Kang, H., He, J., Chromatography: A Quantified Visualization of Movies, http://cseweb.ucsd.edu/~kyl063/chromatography/paper.pdf (pristup: 4.12.2016.)
57. Burghardt, M., Wolff, C., Digital Humanities in Bewegung: Ansätze für die computergestützte Filmanalyse, Digital Humanities im deutschsprachigen Raum (DHd) 2016, Konferenzabstracts, Universität Leipzig, 7. bis 12. März 2016
58. Grijalva, M., Film Clouds, https://classes.soe.ucsc.edu/cmps161/Winter14/projects/mngrijal/proj/writeup.pdf (pristup: 4.12.2016.)
59. Li, E., Barendse, J., Brodbeck, F., Tanner, A., From A to Z: Developing a Visual Vocabulary for Information Security Threat Visualisation, Graphical Models for Security, Third International Workshop, GraMSec 2016, Lisbon, Portugal, June 27, 2016, Revised Selected Papers, pp 102-118, Springer, 2016. DOI: 10.1007/978-3-319-46263-9_7
60. Bruce, C.J., Goldberg, M.E., Primate Frontal Eye Fields. I. Single Neurons Discharging Before Saccades, JOURNALOF NEUROPHYSIOLOGY, Vol. 53. No. 3, March 1985.
61. Bértolo H1, Paiva T, Pessoa L, Mestre T, Marques R, Santos R., Visual dream content, graphical representation and EEG alpha activity in congenitally blind subjects, Cognitive Brain Research, Volume 15, Issue 3, February 2003, Pages 277–284
62. Barry Salt (2016): The exact remake: a statistical style analysis of six Hollywood films, New Review of Film and Television Studies, DOI: 10.1080/17400309.2016.1198635
63. Potter, M. C. (1976). Short-term conceptual memory for pictures. Journal of Experimental Psychology:Human Learning and Memory, 2, 509 –522

64. Turković, H.,(2008a) Filmski leksikon, Leksikografski zavod Miroslav Krleža, 2008. http://film.lzmk.hr/clanak.aspx?id=1641 (posjećeno: 14.12.2016.)
65. Cutting, J.E., Brunick, K.L., Candan, A.,(2012) Perceiving event dynamics and parsing Hollywood films, Joumal of Experimental Psychology: Human Perception and Performance, 2012, Vol. 38, No. 6, 1476-1490, doi: 10.1037/a0027737
66. Cutting, J., Iricinshi, C., (2015), Re-Presentation s of Space in Hollywood Movies: An Event-Indexing Analysis, Cognitive Science 39 (2015) 434–456, DOI: 10.1111/cogs.12151
67. Turković, H.,(2008b) Filmski leksikon, Leksikografski zavod Miroslav Krleža, 2008. http://film.lzmk.hr/clanak.aspx?id=1121 (posjećeno: 14.12.2016.)
68. Turković, H.,(2008c) Filmski leksikon, Leksikografski zavod Miroslav Krleža, 2008. http://film.lzmk.hr/clanak.aspx?id=1118 (posjećeno: 14.12.2016.)
69. Geiger, S., & Reeves, B. (1993). The Effects of Scene Changes and Semantic Relatedness on Attention to Television. Communication Research, 20(2), 155–175. http://doi.org/10.1177/009365093020002001
70. Carroll, J. M., & Bever, T. G. (1976). Segmentation in Cinema Perception. Science, 191(4231), 1053–1055
71. Reeves, B., Thorson, E., Rothschild, M. L., McDonald, D., Hirsch, J., & Goldstein, R. (1985). Attention to television: intrastimulus effects of movement and scene changes on alpha variation over time. International Journal of Neuroscience, 27(3-4), 241–55
72. Rothschild, M., Thorson, E., Reeves, B., Hirsch, J.E., Goldstein, R.J., (1986), EEG Activity And The Processing Of Television Commercials, Communication Research, Vol 13, Issue 2, 1986
73. Anderson, D.R., Levin, S.R., Lorch, E.P., (1977), The Effects of TV Program Pacing on the Behavior of Preschool Children, AV Communication Review, Vol. 25, No. 2 (Summer, 1977), pp. 159-166
74. Lynn, R., (1966), Attention, Arousal and the Orientation Reaction, Pergamon Press Ltd., Headington Hill Hall, London, 1966.
75. Lang, A., (1990), Involuntary Attention and Physiological Arousal Evoked by Structural Features and Emotional Content in TV Commercials, Communication Research, v17 n3 p275-99 Jun 1990
76. Smith, T. J. (2005). An Attentional Theory of Continuity Editing. University of Edinburgh.

77. Chandler, J.J., Pronin, E., (2012), Fast Thought Speed Induces Risk Taking, Psychological Science, 23(4) 370–374
78. Pronin E., Wegner D.M., Manic thinking: independent effects of thought speed and thought content on mood., Psychol Sci. 2006 Sep;17(9):807-13.
79. Candan, A., Cutting, J.E., DeLong, J.E., (2016), RSVP at the movies: dynamic images are remembered better than static images when resources are limited, Visual Cognition, DOI: 10.1080/13506285.2016.1159636
80. Webster, Definition of information, https://www.merriam-webster.com/dictionary/information (posjećeno: 07. siječnja, 2017.)
81. Floridi, L., (2005), Is Semantic Information Meaningful Data?, Philosophy and Phenomenological Research, Vol. LXX, No. 2, March 2005
82. Audi, R., (1999), The Cambridge Dictionary of Philosophy 2nd Edition, Cambridge University Press; 2 edition (September 28, 1999)
83. Shanon, C.E. (1948), A Mathematical Theory of Communication, The Bell System Technical Journal, Vol XXVII, No.2, July, 1948.
84. Shanon, C.E. (1993), Collected Papers, Editors: Sloane, N.J.A., Wyner, A.D., Wiley-IEEE Press, 1993.
85. Weaver, W., (1949), "The Mathematics of Communication", Scientific American, 181(1): 11–15.
86. Whitaker, J.C., (2005), The Electrical Engineering Handbook Second edition, Taylor & Francis Group, Boca Raton, FL, SAD
87. Topfer, F.,Pillewitzer, W. (1964), Das Auswahlgesetz, ein Mittel zur kartographischen Generalisierung. Kartographische Nachrichten 14, 117-121 (1964).
88. Frank, A.U., Timpf, S., (1994), Multiple representations for cartographic objects in a multi-scale tree—An intelligent graphical zoom, Computers & Graphics, Volume 18, Issue 6, November–December 1994, Pages 823-829, DOI:10.1016/0097-8493(94)90008-6
89. Jahnke, M., Krisp, J.M., Kumke, H., (2011), How Many 3D City Models Are There? – A Typological Try, The Cartographic Journal Vol. 48 No. 2 pp. 124–130 International Cartographic Conference, Paris 2011-Special Issue May 2011.
90. Perrin, D.G., (1969), A Theory of Multiple-Image Communication, AV Communication Review, Vol. 17, No. 4 (Winter, 1969), pp. 368-382, Springer

91. Chang T-W, Kinshuk, Chen, N-S, Yu P-T (2012) The effects of presentation method and information dens ity on visual search ability and working memory load, Computers & Education 58 (2012) 721–731,
92. Gabillon, Y., Lepreux, S., Olieira, K.M., (2013), Towards Ergonomic User Interface Composition: A Study about Information Density Criterion, Human-Computer Interaction, Part I, HCII 2013, LNCS 8004, pp. 211–220, 2013., Springer-Verlag Berlin Heidelberg 2013
93. Ziefle, M., (2010), Information prese ntation in small screen devices: The trade-off between visual density and menu foresight, Applied Ergonomics 41 (2010) 719-730, Elsevier, doi:10.1016/j.apergo.2010.03.001
94. Schenkel, A., J. Zhang, Y. Zhang. (1993). Long-range correlations in human writings. Fractals, 1(1):47–55.
95. Kokol, P, Kokol, M., Kokol, P., (2006) THE INFORMATION DENSITY OF LITERARY WORKS THROUGH HISTORY, Cybernetics and Systems: An International Journal, 37:4, 361-371, DOI: 10.1080/01969720600626378
96. Hammouda, K., (2000), An Ecological Perspective of Visual Information Density in Interface Design, Department of Systems Design Engineering, University of Waterloo, Ontario, Canada, http://pami.uwaterloo.ca/pub/hammouda/sde744-paper.pdf (pristup: 22.12.2016.)
97. Chu, J., Li, M., (2012), A Culture-based Study on Information Density of Mobile E-commerce Websites, 2012 Fifth International Symposium on Computational Intelligence and Design, 28-29. Octobar 2012, Volume 2, Hanzhou, China, 2012. DOI: 10.1109/ISCID.2012.218
98. Fox, J.R., Park, B., Lang, A., (2007), When Available Resources Become Negative Resources: The Effects of Cognitive Overload on Memory Sensitivity and Criterion Bias, Communication Research, 2007 34: 277, DOI: 10.1177/0093650207300429
99. Rogers, E. M., & Agarwala-Rogers, R. (1975) . Organ izational communication. In G. J. Hanneman & W. J. McEwen (Ed s.), Communication and behaviour (pp. 218-236). Reading, MA:Addison Wesley.
100. Jones, Q. (2003), Applying Cyber-Archaeology, K. Kuutti, EH. Karsten, G. Fitzpatrick, P. Dourish and K. Schmidt (eds.), ECSCW 2003: Proceeding of the Eighth European Conference on Computer Supported Cooperative Work, 14-18 September 2003, Helsinki, Finland, pp. 42-56. 2003 Kluwer Academic Publishers.

101. Feather, J. P. (1998). The information society: A study of continuity and change (2nd ed.). London: Library Association Publishing.
102. Eppler, M.J., Mengis, J., (2004), The Concept of Information Overload: A Review of Literature from Organization Science, Accounting, Marketing, MIS, and Related Disciplines, The Information Society, 20: 325–344, 2004., DOI: 10.1080/01972240490507974
103. Chewning, E.G., Harrell, A.M., (1990), THE EFFECT OF INFOFlMATION LOAD ON DECISION MAKERS' CUE UTILIZATION LEVELS AND DECISION QUALITY IN A FINANCIAL DISTRESS DECISION TASK, Accounting, Organizations and Sociely, Vol. 15, No. 6, pp. 527-542, 1990.
104. Malhorta, N.K., Jain, A.K., Lagakos, S.W., (1982), The information Overload Controversy: An Alternative Viewpoint, Journal of Marketing, Vol. 46 (Spring 1982)
105. Galbraith, J.R., (1974), Organization design: An information processing view, Interfaces, Vol. 4, No. 3, May 1974
106. Schick, A.G., Gordon, L.A., Haka, S. (1990), INFORMATION OVERLOAD: A TEMPORAL APPROACH, Accounting Organizations and Society. Vol. 15, No. 3, pp. 199-220, 1990
107. Owen, R.S., (1992), Clarifying the Simple Assumption of the Information Load Paradigm, Advances in Consumer Research Volume 19, eds. John F. Sherry, Jr. and Brian Sternthal, Provo, UT : Association for Consumer Research, Pages: 770-776. (adresa: http://acrwebsite.org/volumes/7387/volumes/v19/NA-19 , posjećeno: 22.12.2016.)
108. Muller, T. E. 1984. Buyer response to variations in product information load. *Psychological Review* 63:81–97.
109. Wilson, T. D. (2001). Information overload: Implications for healthcare services. Health Informatics Journal, 7(2), 112–117. DOI:10.1177/146045820100700210
110. Nelson, M. R. (1994). We have the information you want, but getting it will cost you! Held hostage by information overload. Crossroads, 1 (1), 11–15. http://dx.doi.org/10.1145/197177.197183
111. Schick, A. G., Gordon, L. A., & Haka, S. (1990). Information overload: A temporal approach. Accounting, Organizations and Society, 15(3), 199–220. http://dx.doi.org/10.1016/0361-3682(90)90005-F

112. Schneider, S. C. (1987). Information overload: Causes and consequences. Human Systems Management, 7(2), 143–153.
113. Bawden, D., Robinson, L. (2009). The dark side of information: overload, anxiety and other paradoxes and pathologies. Journal of Information Science, 35(2), pp. 180-191. doi: 10.1177/0165551508095781,
114. Stvilia, B., Twidale, M. B., Smith, L. C., & Gasser, L. (2005). Assessing information quality of a community-based encyclopedia. In F. Naumann, M. Gertz, & S. Mednick (Eds.), Proceedings ofthe International Conference on Information Quality-ICIQ 2005 (pp. 442–454). Cambridge, MA: MTIQ.
115. Ackoff, R. L. (1967). Management misinformation systems. Management Science,
14(4), B147–B156
116. Kirsh, D. (2000). A few thoughts on cognitive overload. Intellectica, 1 (30), 19–51.
117. Speier, C., Valacich, J. S., & Vessey, I. (1999). The influence oftask interruption on individual decision making: An information overload perspective. Decision Sciences, 30(2), 337–360
118. Tushman, M. L., & Nadler, D. A. (1978). Information processing as an integrating concept in organizational design. Academy of Management Review, 3(3), 613–624
119. Campbell, D. J. (1988). Task complexity: A review and analysis. The Academy ofManagement Review, 13(1), 40–52
120. Cooper, G. (1998). Research into cognitive load theory and instructional design at UNSW, (adresa: http://webmedia.unmc.edu/leis/birk/CooperCogLoad.pdf, posjećeno: 22.12.2016.)
121. Jackson, T.W., Farzaneh, P. (2012), Theory-based model of factors affecting information overload, International Journal of Information Management, Volume 32, Issue 6, December 2012, Pages 523–532, DOI: 10.1016/j.ijinfomgt.2012.04.006
122. Wurman, R.A., (2001), Information Anxiety 2, New Riders Publishers, New York, 2001
123. Ho, J., Tang, R., (2001), Towards an Optimal Resolution to Information Overload: An Infomediary Approach, GROUP '01 Proceedings of the 2001 International ACM SIGGROUP Conference on Supporting Group Work, p. 91-96, Boulder, Colorado, USA — September 30 - October 03, 2001

124. Tushman, M. L., and Nadler, D. A. 1978. Information processing as an integrating concept in organizational design. Academy of Management Review 3:613–625

125. Malović, S., Maletić, F., Vilović, G., Kurtić, N., „Masovno komuniciranje“, Golder marketing – Tehnička knjiga, Sveučilište Sjever, Zagreb, 2014.

126. Jahne, B., Haussecker, H.(2000), Computer Vision and Applications - A Guide for Students and Practitioners, Academic Press, 2000

127. Sweller, J. (1988), Cognitive Load During Problem Solving: Effects on Learning, Cognitive Science, Volume 12, Issue 2, April 1988., Pages 257–285

128. Sweller, J. (1994), COGNITIVE LOAD THEORY, LEARNING DIFFICULTY,
AND INSTRUCTIONAL DESIGN, Learning and Instruction, Vol.4, pp.293-312, 1994. Elsevier Science Ltd.

129. Jacoby J, Speller DE, Kohn CA. (1974a), Brand choice behavior as a function of information load. Journal of Marketing Research 1974(11:1):63–9. February.

130. Jacoby J, Speller DE, Kohn CA. (1974b), Brand choice behavior as a function of information load: replication and extension. Journal of Consumer Research 1974(1):33–42. June.

131. Jacoby J. (1977), Information load and decision quality: some contested issues. Journal of Marketing Research 1977(14:4):569–73. November

132. Wilkie, W.L., (1974), Analysis of Effects of Information Load, Journal of Marketing Research, 11 (November), p.462-466

133. Summers, J.O., (1974), "Less Information is Better?", Journal of Marketing Research, 11 (November), p.467-468.

134. Russo, J.E., (1974), More Information Is Better: A Re-evaluation of Jacoby, Speller and Kohn," Journal of Consumer Research, 1 (December), 68-72.

135. Green, P. E., Carmone F. J., Wachspress, D. P. (1977), On the Analysis of Qualitative Data in Marketing Research, Journal of Marketing Research, 14 (February), p.52-59.

136. Malhorta, N.K., Jain, A.K., Lagakos, S.W., (1982), The Information Overload Controversy: An Alternative Viewpoint, Journal of Marketing, Vol. 46, No. 2 (Spring, 1982), pp. 27-37

137. Keller, K. L., & Staelin, R. (1987). Effects of quality and quantity of information on decision effectiveness. Journal of Consumer Research, 14, 200–213.

138. Keller, K.L., Stealin, R. (1989) Assessing Biases in Measuring Decision Effectiveness and Information Overload, Journal of Consumer Research, Vol. 15, No. 4 (Mar., 1989), pp. 504-508

139. Chen, Y-C., Shang R-A., Kao, C-Y., (2009), The effects of information overload on consumers' subjective state towards buying decision in the internet shopping environment, Electronic Commerce Research and Applications 8 (2009) p.48–58.

140. Nielsen, J. (2003), "Information Pollution". Nielsen Norman Group. (https://www.nngroup.com/articles/information-pollution/) PRISTUP: 31. svibnja 2017.

141. Cameron, G.T., Curtin, P.A., (1995), Tracing Sources of Information Pollution: A Survey and Experimental Test of Print Media's Labeling Policy for Feature Advertising, Journalism & Mass Communication Quarterly, Vol 72, Issue 1, pp. 178 – 189

142. Nielsen, J., (2004), IM, Not IP (Information Pollution), Queue, Volume 1, issue 8

143. O'Connell, N., (2008),"Interruption overload", Strategic Direction, Vol. 24 Iss 10 pp. 3 – 5

144. Iqbal, S.T., Bailey, B.P. (2004), Using Eye Gaze Patterns to Identify User Tasks, Presented at the The Grace Hopper Celebration of Woman in Computing, Oct. 6 – 9 2004., Chicago, Illinois, SAD,

145. Adamczyk, P.D., Bailey, B.P. (2004), "If not now, when?: the effects of interruption at different moments within task execution," in Proceedings of the SIGCHI Conference on Human Factors in Computing Systems, 2004, pp. 271–278.

146. Bailey, B.P., Konstan, J.A. (2006), "On the need for attention-aware systems: Measuring effects of interruption on task performance, error rate, and affective state," Computers in Human Behavior, vol. 22, no. 4, pp. 685 – 708, 2006

147. Czerwinski, M., Cutrell, E.,Horvitz, E., (2000), "Instant messaging: Effects of relevance and timing," in People and computers XIV: Proceedings of HCI, vol. 2. British Computer Society, 2000, pp. 71–76

148. Kreifeldt. J.G., McCarthy, M.E., (1981), "Interruption as a test of the usercomputer interface," in JPL Proceeding of the 17 th Annual Conference on Manual Control, 1981, pp. 655–667

149. Okoshi, T., Ramos, J., Nozaki, H., Nakazawa, J., Dey A.K., Tokuda, H., (2015), Attelia: Reducing User's Cognitive Load due to Interruptive Notifications on Smart

Phones, IEEE International Conference on Pervasive Computing and Communications (PerCom), St. Louis, Missouri, Sjedinjene Američke Države, 23-27. ožujak 2015.

150. Britton, B. K., & Tesser, A. (1982). Effects of prior knowledge on use of cognitive capacity in three complex cognitive tasks. Journal of Verbal Learning and Verbal Behavior, 21, 421-436

151. Britton, B. K., Westbrook, R. D., & Holgredge, T. S. (1978). Reading and cognitive capacity usage: Effects of text difficulty. Journal of Experimental Psychology: Human Learning and Memory, 4, 582-591

152. Reeves, B., & Thorson, E. (1986). Watching television: Experiments on the viewing process. Communication Research, 13, 343-361.

153. Reeves, B., Thorson, E., Rothschild, M., McDonald, D., Hirsch, J., & Goldstein, R. (1985). Attention to television: Intra-stimulus effects of movement and scene changes on alpha variation over time. International Journal of Neuroscience, 25, 241-255

154. Basil, M.D., (1994), Secondary Reaction-Time Measures, MEASURING PSYCHOLOGICAL RESPONSES TO MEDIA MESSAGES, Edited by Annie Lang, RoutledgeTaylor &. Francis Group, 1994.

155. Lang, A. (2000), The Limited Capacity Model of Mediated Message Processing, Journal of Communication, Volume 50, Issue 1, March 2000, p. 46-70

156. Lang, A., Basil, M.D., (1998), Attention, Resource Allocation and Communication Research: What Do Secondary Task Reaction Times Measure Anyway?, Annals of the International Communication Association, 21:1, 443-458,

157. Lang, A., Bradley, S.D., Park, B., Shin, M., Chung, Y., (2006), Parsing the Resource Pie: Using STRTs to Measure Attention to Mediated Messages, Media Psychology, Volume 8, 2006 - Issue 4, Taylor & Francis

158. Kahneman, D. (1973). Attention and Effort. Prentice Hall

159. Berlyne, D. E., & Ditkofsky, J. (1976). Effects of novelty and oddity on visual selective attention, British Journal of Psychology, 67(2), 175–180

160. Reeves, B., Lang, A., Kim, E., & Tatar, D. (1999). The effects of screen size and message content on attention and arousal. Media Psychology, 1, 49–67

161. Franconeri, S. L., & Simons, D. J. (2003). Moving and looming stimuli capture visual attention, Perception and Psychophysics, 65, 999–1010

162. Anderson, R. C., & Pichert, J. W. (1978). Recall of previously unrecallable information following a shift in perspective. Journal of Verbal Learning and Verbal Behavior, 17, 1–12.

163. Kraft, R. N. (1987). The influence of camera angle on comprehension and retention of pictorial events. Memory & Cognition, 15(4), 291–307.

164. Andrew, J. D. (1976). The major film theories: An introduction. New York: Oxford University Press.

165. Eisenstein, S., & Leyda, J. N. (1949). Film form: Essays in film theory. London: Dobson

166. Lang, A., Bolls, P., Potter, R. F., & Kawahara, K. (1999). The effects of production pacing and arousing content on the information processing of television messages. Journal of Broadcasting & Electronic Media, 43(4), 451–475.

167. Lang, A., Dhillon, K., & Dong, Q. W. (1995). The effects of emotional arousal and valence on television viewers cognitive capacity and memory. Journal of Broadcasting & Electronic Media, 39(3), 313–327.

168. Lang, A., Newhagen, J., & Reeves, B. (1996). Negative video as structure: Emotion, attention, capacity, and memory. Journal of Broadcasting & Electronic Media, 40(4), 460–477

169. Lang, P. J., Bradley, M. M., & Cuthbert, B. N. (1990). Emotion, attention, and the startle reflex. Psychological Review, 97, 377–395.

170. McKenna, F. P., & Sharma, D. (1995). Intrusive cognitions: An investigation of the emotional Stroop task. Journal of Experimental Psychology: Learning, Memory, and Cognition, 21, 1595–1607.

171. Fox, J., Lang, A., Chung, Y., Lee, S., & Potter, D. (2004). Picture this: Effects of graphics on the processing of television news. Jounal of Broadcasting and Electronic Media, 48(4), 646–674.

172. Lang, A., Kurita, S., Gao, Y., Rubenking, B. (2013) Measuring Television Message Complexity as Available Processing Resources: Dimensions of Information and Cognitive Load, Media Psychology, 16:2, 129-153,

173. Lang, A., Sanders-Jackson, A., Wang, Z., Rubenking, B. (2012), Motivated message processing: How motivational activation influences resource allocation, encoding, and storage of TV messages, Motivation and Emotion, September 2013, Volume 37, Issue 3, pp 508–517

174. Huang, T. (1996). Vandoni, Carlo, E, ed. Computer Vision : Evolution And Promise, 19th CERN School of Computing. Geneva: CERN. pp. 21–25. ISBN 978-9290830955.

175. Shapiro, L.G., Stockman, G.C., (2001), Computer vision, Pearson, 2001, ISBN-13: 978-0130307965

176. Ballard, D.H., Brown, C.M., (1982), Computer vision, Prentice-Hall, Inc. Englewood Cliffs, New Yersey, 1982.

177. Sarkar, M., (2016), Bioinspired Optical Imaging, Biologically Inspired Computer Vision - Fundamentals and Applications, Editors: Cristóbal, G., Perrinet, L., Keil, M.S., Wiley-VCH Verlag GmbH & Co, Weinheim, Njemačka, 2016.

178. Bajcsy, R., (2014), Rationale for Computational Vision, Computer Vision - A Reference Guide, Editor: Katsushi Ikeuchi, Springer Reference, 2014.

179. Fischler, M.A., Firschein, O., (1987), Introduction; Readings in Computer Vision:
Issues, Problems, Principles, and Paradigms Editors: Fischler, M.A., Firschein, O., Morgan Kaufmann Publishers, Inc., Los Altos, USA, 1987.

180. Rockwood, A., McAndless, J. (1999), Through the Looking Glass: The Synthesis of Computer Graphics and Computer Vision, Visions and Views, Philips Research, 1999.

181. Sonka, M., Hlavac, V., Boyle, R., (1993), Image Processing, Analysis and Machine Vision, Springer-Science+Business Media, Bv.,

182. Barrow, H.G., Tenenbaum, J.M., (1981), Computational vision, Proceedings of the IEEE (Volume: 69, Issue: 5, May 1981), p. 572 – 595

183. Hornberg, A. (2017), Preface First Edition, Handbook of Machine and Computer Vision - The Guide for Developers and Users, Second, Revised and Updated Edition, Editor: 183. Hornberg, A. Wiley-VCH, Verlag GmbH & Co. KGaA, Weinheim, Njemačka

184. Steger, C., (2017), Machine Vision Algorithms, Handbook of Machine and Computer Vision - The Guide for Developers and Users, Second, Revised and Updated Edition, Editor: 183. Hornberg, A. Wiley-VCH, Verlag GmbH & Co. KGaA, Weinheim, Njemačka, p. 505-698

185. Wright, W.D., (2007), Professor Wright's Paper from the Golden Jubilee Book: The Historical and Experimental Background to the 1931 CIE System of Colorimetry,

Colorimetry: Understanding the CIE System, Editor: János Schanda, John Wiley & Sons, Inc., 2007.

186. Jones, L.A. (1943), The Historical Background and Evolution of the Colorimetry Report, Journal of the Optical Society of America Vol. 33, Issue 10, pp. 534-543 (1943)

187. BrainHQ, (2017), https://www.brainhq.com/brain-resources/brain-facts-myths/how-vision-works (pristup: 11.11.2017.)

188. Loomis, J. (1998), Pixel Neighbors, http://www.johnloomis.org/ece563/notes/BinaryImages/neighbors/Neighbors.html (pristup: 18.03.2017.)

189. Jimenez-Fernandez, V.M., Vazquez-Leal, H., Filobello-Nino, U.A., Jimenez-Fernandez, M., Morales-Mendoza, L.J., Gonzalez-Lee, M., (2016), Exploring the use of two-dimensional piecewise-linear functions as an alternative model for representing and processing grayscale-images, Journal of Applied Research and Technology 2016;14:311-8 - DOI: 10.1016/j.jart.2016.09.001

190. Hotz, L., Neumann, B., Terzic, K., (2008), High-Level Expectations for Low-Level Image Processing, . In: Dengel A.R., Berns K., Breuel T.M., Bomarius F., Roth-Berghofer T.R. (eds) KI 2008: Advances in Artificial Intelligence. KI 2008. Lecture Notes in Computer Science, vol 5243. Springer, Berlin, Heidelberg

191. Marr, D. (1982), Vision - A Computational Investigation into the Human Representation and Processing of Visual Information, MIT Press, 2010.

192. Papert, S., (1966), The Summer Vision Project, Artifical Inteligence Group, MIT, 1966.

193. Ritter, G.X., Wilson, J.N., (2001), Handbook of Computer Vision Algorithms in Image Algebra, CRC Press, September 21, 2000.

194. Tanenbaum, J.M., Barrow, H.G., Bolles, R.C., Fischler, M.A., Wolf, H.C., (1979), Map-guided interpretation of remotely-sensed imagery, Conference on Pattern Recognition and Image Processing; August 6-8, 1979; Chicago, IL, USA, 1979

195. Perkins, W.A., (1978), A Model-Based Vision System for Industrial Parts, IEEE Transactions on Computers (Volume: C-27, Issue: 2, Feb. 1978), IEEE, p.126-143

196. Ballard, D.H., Sklansky, J., (1976), A Ladder-Structured Decision Tree for Recognizing Tumors in Chest Radiographs, IEEE Transactions on Computers (Volume: C-25, Issue: 5, May 1976), IEEE, p.503-513

197. Vijipriya, J., Ashok, J., Suppiah, S.,(2016), A Review on Significance of Sub Fields in Artificial Intelligence, International Journal Of Latest Trends In Engineering And Technology, (IJLTET), 6(3), 2016.

198. Arens, M., Ottlik, A., Nagel, H.H., (2004) Using Behavioral Knowledge for Situated Prediction of Movements. In Proc. 27th German Conference on Artificial Intelligence (KI-2004), volume LNAI 3238, pages 141–155. Springer, September 2004.

199. Martimet, J., Elsayad, I., (2012), Mid-Level Image Descriptors, Intelligent Multimedia Databases and Information Retrieval: Advancing Applications and Technologies, Editors: Yan, L., Ma, Zongmin, Information Science Reference, IGI Global, Pennsylvania, USA

200. Smeulders, A.W.M., Worring, M., Santini, S., Gupta, A., Jain, R., (2000), Content-Based Image Retrieval at the End of the Early Years, IEEE Transactions on Pattern Analysis and Machine Intelligence, Volume 22 Issue 12, December 2000, Page 1349-1380, IEEE Computer Society Washington, DC, USA

201. Luo, J., & Savakis, A. (2001). Indoor versus outdoor classification of consumer photographs using low-level and semantic features. In Proceedings of International Conference ion Image Processing, vol. 2, (pp. 745–748). ICIP'01. IEEE Computer Society

202. Shaikh, S.H., Saeed, K., Chaki, N., (2014), Moving Object Detection Using Background Subtraction, Springer, 2014.

203. Bouwmans, T. (2012), Background subtraction for visual surveillance: a fuzzy approach, in: Handbook on Soft Computing for Video Surveillance, Taylor and Francis Group, 2012

204. Benezeth, Y., Jodoin, P.M., Laurent, B.E.H., Rosenberger, C., (2010), Comparative study of background subtraction algorithms, Journal of Electronic Imaging 19(3), 033003 (Jul–Sep 2010)

205. Paragios, N., Deriche, R., (2000), Geodesic active contours and level sets for the detection and tracking of moving objects, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 22 (3), pp. 266–280, 2000.

206. Fejes, S., Davis, L.S., (1999), Detection of independent motion using directional motion estimation, Computer Vision and Image Understanding (CVIU), Vol. 74 (2), pp. 101–120, 1999.

207. Piccardi, M., (2004), Background subtraction techniques: A review, IEEE Int. Confon Systems, Man and Cybernetics (SMC), Vol. 4, pp. 3199–3104, 2004.

208. Sobral, A., (2013), BGSLibrary: an OpenCV C++ background subtraction library, in: IX Workshop de Viso Computacional (WVC'2013). Rio de Janeiro, Brazil, 2013.

209. McFarlane, N.J. B., Schofield, C.P. (1995) Segmentation and tracking of piglets in images, Mach. Vis. Appl. 8 (3) (1995) 187–193.

210. Calderara, S., Melli, R., Prati, A., Cucchiara, R. (2006) Reliable back ground suppression for complex scenes, in: ACM International Workshop on Video Surveillance and Sensor Networks, 2006.

211. Zhang, H., Xu, D. (2006) Fusing color and texture features for back ground model, in: International Conference on Fuzzy Systems and Knowledge Discovery, 2006.

212. El Baf, F., Bouwmans, T., Vachon, B. (2008), Fuzzy integral for moving object detection, in: IEEE International Conference on Fuzzy Systems (FUZZ-IEEE), 2008, pp. 1729–1736.

213. Sigari, M., Mozayani, N., Pourreza, H. (2008), Fuzzy running average and fuzzy background subtraction: concepts and application, Int. J. Comput. Sci. Network Security 8 (2) (2008) 138–143.

214. Wren, C., Azarbayejani, A., Darrell, T., Pentland, A. (1997), Pfinder: real-time tracking of the human body, IEEE Trans. Pattern Anal. Mach. Intell. 19 (7) (1997) 780–785

215. Benezeth, Y., Jodoin, P.-M., Emile, B., Laurent, H., Rosenberger, C. (2008) Review and evaluation of commonly-implemented background subtraction algorithms. In: IEEE International Conference on Pattern Recognition (ICPR), 2008, pp. 1–4.

216. Yao, J., Odobez, J. M., (2007) Multi-layer background subtraction based on color and texture, in: IEEE Computer Vision and Pattern Recognition Conference (CVPR), 2007

217. Hofmann, M., Tiefenbacher, P., Rigoll, G. (2012), Background segmentation with feedback: The pixel-based adaptive segmenter, in: IEEE Computer Society Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), 2012, pp. 38–43.

218. Godbehere, A.B., Matsukawa, A., Goldberg, K. (2012), Visual tracking of human visitors under variable-lighting conditions for a responsive audio art installation, in: American Control Conference (ACC), 2012.

219. Goyat, Y., Chateau, T., Malaterre, L., Trassoudaine, L. (2006) Vehicle trajectories evaluation by static video sensors, in: IEEE International Conference on Intelligent Transportation Systems, 2006.

220. Oliver, N.M., Rosario, B., Pentland, A.P., (2000) A Bayesian computer vision system for modeling human interactions, IEEE Trans. Pattern Anal. Mach. Intell. 22 (8) (2000) 831–843

221. Maddalena, L., Petrosino, A. (2008) A self-organizing approach to background subtraction for visual surveillance applications, IEEE Trans. Image Process. 17 (7) (2008) 1168–1177.

222. Maddalena, L., Petrosino, A. (2010) A fuzzy spatial coherence-based approach to background/foreground separation for moving object detection, Neural Comput. Appl. 19 (2) (2010) 179–186

223. El Baf, F., Bouwmans, T., Vachon, B. (2008a) Type-2 fuzzy mixture of Gaussians model: Application to background modeling, in: International Symposium on Advances in Visual Computing (ISVC), 2008.

224. Zhao, Z., Bouwmans, T., Zhang, X., Fang, Y. (2012) A fuzzy background modeling approach for motion detection in dynamic backgrounds, in: International Conference Communications in Computer and Information Science, vol. 346, 2012, pp. 177–185

225. Stauffer, C., Grimson, W.E.L., (1999) Adaptative background mixture models for a realtime tracking, in: IEEE International Conference on Computer Vision and Pattern Recognition (CVPR), 1999.

226. Kaewtrakulpong, P., Bowden, R. (2001) An improved adaptive background mixture model for realtime tracking with shadow detection, European Workshop on Advanced Video Based Surveillance Systems (AVSS), 2001.

227. Zivkovic, Z., (2004) Improved adaptive Gausian mixture model for background subtraction, International Conference Pattern Recognition, UK, August, 2004,

228. Zivkovic, Z., Heijden, F.V. D., (2006) Efficient adaptive density estimation per image pixel for the task of background subtraction, Pattern Recog. Lett. 27 (7) (2006) 773–780

229. Bouwmans, T., El Baf, F., Vachon, B. (2008) Background modeling using mixture of Gaussians for foreground detection - a survey, Recent Patents Comput. Sci. 1 (3) (2008) 219–237

230. Heikkila, M., Pietikainen, M., (2006), A Texture-Based Method for Modeling the Background and Detecting Moving Objects, IEEE Transactions On Pattern Analysis And Machine Intelligence, Vol. 28, No. 4, April 2006.

231. St-Charles, P-L, Bilodeau, G-A, Bergevin, R., (2014), Flexible Background Subtraction With Self-Balanced Local Sensitivity, The IEEE Conference on Computer Vision and Pattern Recognition (CVPR) Workshops, 2014, pp. 408-413

232. St-Charles, P-L, Bilodeau, G-A, (2014a), Improving background subtraction using local binary similarity patterns, Applications of Computer Vision (WACV), 2014 IEEE Winter Conference on Applications of Computer Vision, 24-26 March 2014, Steamboat Springs, CO, USA

233. Kertesz, C., Oy, V., (2011), Texture-Based Foreground Detection, International Journal of Signal Processing, Image Processing and Pattern Recognition Vol. 4, No. 4, December, 2011

234. Noh, S.J., Jeon, M., (2012), A New Framework for Background Subtraction Using Multiple Cues, Asian Conference on Computer Vision 2012, pp 493-506, Part of the Lecture Notes in Computer Science book series (LNCS, volume 7726)

235. Bloisi, D., Iocchi, L., (2012), Independent Multimodal Background Subtraction, In: Proc. of the 3rd Int. Conf. on Computational Modeling of Objects Presented in Images: Fundamentals, Methods and Applications, pp. 39–44 (2012).

236. Lacassagne, L., Manzanera, A., (2009), Motion Detection: Fast And Robust Algorithms For Embedded Systems, 16th IEEE International Conference on Image Processing (ICIP), 7-10 Nov. 2009., Cairo, Egypt

237. Elgammal, A.M., Harwood, D., Davis, L.S. (2000), Non-parametric Model for Background Subtraction, Proceedings of the 6th European Conference on Computer Vision-Part II, Pages 751-767, June 26 - July 01, 2000., London, UK

238. Vacavant, A. (2013) http://isit.u-clermont1.fr/~anvacava/index.html , accessed at 30/03/2013

239. Bloisi, D. D. (2013) http://www.dis.uniroma1.it/~bloisi/software/imbs.html , accessed at 30/03/2013

240. Parks, D. (2013) http://dparks.wikidot.com/source-code , accessed at 30/03/2013

241. Yao, J. and Odobez, J.M. (2013) http://www.idiap.ch/~odobez/humandetection/related-publications.html accessed at 30/03/2013

242. Bender, L. (2013) http://scene.sourceforge.net/ , accessed at 30/03/2013.
243. Hofmann, M. (2013) https://sites.google.com/site/pbassegmenter/home, accessed at 30/03/2013.
244. Bouwmans, T., (2013) https://sites.google.com/site/thierrybouwmans/ , accessed at 30/03/2013.
245. Zivkovic, Z. (2013) http://www.zoranz.net , accessed at 30/03/2013.
246. Laugraud, B. (2013) http://www.montefiore.ulg.ac.be/~blaugraud/index.php , accessed at 30/03/2013.
247. Tabachnick, B.G., Fidell, L.S., (2013) Using Multivariate Statistics, 6th edition, Pearson Education, Inc., SAD
248. Kim, S., (2015), ppcor: An R Package for a Fast Calculation to Semi-partial Correlation Coefficients. Communications for Statistical Applications and Methods, 22(6), 665-674.
249. Pallant, J. (2011), SPSS SURVIVAL MANUAL A step by step guide to data analysis using SPSS 4th edition, Allen & Unwin, Australia
250. Cohen, J., (1988), Statistical Power Analysis for the Behavioral Sciences (2nd ed.), New Jersey: Lawrence Erlbaum Associates, ISBN 0-8058-0283-5
251. Horvat, J., Mijoč, J., (2012), Osnove statistike, Naklada Ljevak d.o.o., Zagreb, Hrvatska, 2012.
252. Nationmaster (2017), "Countries Compared by Media > Films produced. International Statistics at NationMaster.com", Internet Movie Database 2003. Aggregates compiled by NationMaster. Retrieved from http://www.nationmaster.com/country-info/stats/Media/Films-produced
253. Nationmaster (2017a), "All countries compared for Media > Cinema > Number of national feature films produced", UNESCO Institute for Statistics. Source tables. Aggregates compiled by NationMaster. Retrieved from http://www.nationmaster.com/country-info/stats/Media/Cinema/Number-of-national-feature-films-produced
254. Sunder, M., (2011), Bollywood/Hollywood, Theoretical Inquiries in Law, Volume 12, Number 1 January 2011 Article 10,
255. Mann, H.B., (1945), „Nonparametric tests against trend“, Econometrica, Vol. 13, No. 3 (Jul., 1945), pp. 245-259
256. Kendall, M.G. (1975) Rank Correlation Methods, 4th edition, Charles Griffin, London

257. Hirsch, R.M., Slack, J.R., Smith, R.A. (1982), „Techniques of trend analysis for monthly water quality dana“ , Water Resources Research 18(1):107-121

258. Gilbert, R.O. (1987), Statistical Methods for Environmental Pollution Monitoring, Wiley, New York, SAD

10. PRILOZI

10.1. Programski kod u Microsoft Visual C++ 2010 Express

Demo.cpp

```
/*
This file is part of BGSLibrary.

BGSLibrary is free software: you can redistribute it and/or modify
it under the terms of the GNU General Public License as published by
the Free Software Foundation, either version 3 of the License, or
(at your option) any later version.

BGSLibrary is distributed in the hope that it will be useful,
but WITHOUT ANY WARRANTY; without even the implied warranty of
MERCHANTABILITY or FITNESS FOR A PARTICULAR PURPOSE.  See the
GNU General Public License for more details.

You should have received a copy of the GNU General Public License
along with BGSLibrary.  If not, see <http://www.gnu.org/licenses/>.
*/
#include <iostream>
#include <fstream>
#include <opencv2/opencv.hpp>
//#include <cv.h>
//#include <highgui.h>

#include "package_bgs/FrameDifferenceBGS.h"
#include "package_bgs/StaticFrameDifferenceBGS.h"
#include "package_bgs/WeightedMovingMeanBGS.h"
#include "package_bgs/WeightedMovingVarianceBGS.h"
#include "package_bgs/MixtureOfGaussianV1BGS.h"
#include "package_bgs/MixtureOfGaussianV2BGS.h"
#include "package_bgs/AdaptiveBackgroundLearning.h"
#include "package_bgs/AdaptiveSelectiveBackgroundLearning.h"

#if CV_MAJOR_VERSION >= 2 && CV_MINOR_VERSION >= 4 &&
CV_SUBMINOR_VERSION >= 3
#include "package_bgs/GMG.h"
#endif

#include "package_bgs/dp/DPAdaptiveMedianBGS.h"
#include "package_bgs/dp/DPGrimsonGMMBGS.h"
#include "package_bgs/dp/DPZivkovicAGMMBGS.h"
#include "package_bgs/dp/DPMeanBGS.h"
#include "package_bgs/dp/DPWrenGABGS.h"
#include "package_bgs/dp/DPPratiMediodBGS.h"
#include "package_bgs/dp/DPEigenbackgroundBGS.h"
```

```
#include "package_bgs/dp/DPTextureBGS.h"

#include "package_bgs/tb/T2FGMM_UM.h"
#include "package_bgs/tb/T2FGMM_UV.h"
#include "package_bgs/tb/T2FMRF_UM.h"
#include "package_bgs/tb/T2FMRF_UV.h"
#include "package_bgs/tb/FuzzySugenoIntegral.h"
#include "package_bgs/tb/FuzzyChoquetIntegral.h"

#include "package_bgs/lb/LBSimpleGaussian.h"
#include "package_bgs/lb/LBFuzzyGaussian.h"
#include "package_bgs/lb/LBMixtureOfGaussians.h"
#include "package_bgs/lb/LBAdaptiveSOM.h"
#include "package_bgs/lb/LBFuzzyAdaptiveSOM.h"

#include "package_bgs/ck/LbpMrf.h"
#include "package_bgs/jmo/MultiLayerBGS.h"
// The PBAS algorithm was removed from BGSLibrary because it is
// based on patented algorithm ViBE
// http://www2.ulg.ac.be/telecom/research/vibe/
//#include "package_bgs/pt/PixelBasedAdaptiveSegmenter.h"
#include "package_bgs/av/VuMeter.h"
#include "package_bgs/ae/KDE.h"
#include "package_bgs/db/IndependentMultimodalBGS.h"
#include "package_bgs/sjn/SJN_MultiCueBGS.h"
#include "package_bgs/bl/SigmaDeltaBGS.h"

#include "package_bgs/pl/SuBSENSE.h"
#include "package_bgs/pl/LOBSTER.h"

int main(int argc, char **argv)
{
 //std::cout << "Using OpenCV " << CV_MAJOR_VERSION << "." <<
CV_MINOR_VERSION << "." << CV_SUBMINOR_VERSION << std::endl;

 //Varijable
 int sirina = 0;
 int visina = 0;
 unsigned long int svetocke = 0;
 unsigned long int svebijeletocke = 0;
 int bijeletocke = 0;
 int frame_broj = 0;

 CvCapture *capture = 0;
 int resize_factor = 100;

 if(argc > 1)
 {
  //std::cout << "Otvaram: " << argv[1] << std::endl;
        std::cout << argv[1] <<" ";
```

```
  capture = cvCaptureFromAVI(argv[1]);
 }
 else
 {
  capture = cvCaptureFromCAM(0);
  resize_factor = 50; // set size = 50% of original image
 }

 if(!capture)
 {
  std::cerr << "Cannot initialize video!" << std::endl;
  return -1;
 }

 IplImage *frame_aux = cvQueryFrame(capture);
 IplImage *frame = cvCreateImage(cvSize((int)((frame_aux->width*resize_factor)/100) ,
(int)((frame_aux->height*resize_factor)/100)), frame_aux->depth, frame_aux->nChannels);
 cvResize(frame_aux, frame);
 sirina = (int)((frame_aux->width*resize_factor)/100);
 visina = (int)((frame_aux->height*resize_factor)/100);
 /* Background Subtraction Methods */
 IBGS *bgs;

 /*** Default Package ***/
 //bgs = new FrameDifferenceBGS;
 //bgs = new StaticFrameDifferenceBGS;
 //bgs = new WeightedMovingMeanBGS;
 //bgs = new WeightedMovingVarianceBGS;
 //bgs = new MixtureOfGaussianV1BGS;
 //bgs = new MixtureOfGaussianV2BGS;
 //bgs = new AdaptiveBackgroundLearning;
 //bgs = new AdaptiveSelectiveBackgroundLearning;
 //Ovaj ispod je bio odkomentiran 24.11.2015. kad sam pripremao clanak za Maroko
 //bgs = new GMG;

 /*** DP Package (thanks to Donovan Parks) ***/
 //bgs = new DPAdaptiveMedianBGS;//OK
 //bgs = new DPGrimsonGMMBGS;//OK
 //bgs = new DPZivkovicAGMMBGS;//OK
 //bgs = new DPMeanBGS;//OK
 //bgs = new DPWrenGABGS;//OK
 //Ovaj sljedeci je za Izrael koristen u svinju 2015 !!!!!!!!!!!!!!!!!!!!!!!
 //bgs = new DPPratiMediodBGS;
 //bgs = new DPEigenbackgroundBGS;//OK
 //bgs = new DPTextureBGS;//OK

 /*** TB Package (thanks to Thierry Bouwmans, Fida EL BAF and Zhenjie Zhao) ***/
 //bgs = new T2FGMM_UM;
 //bgs = new T2FGMM_UV;
 //bgs = new T2FMRF_UM;
```

```
  //bgs = new T2FMRF_UV;
  //bgs = new FuzzySugenoIntegral;
  //bgs = new FuzzyChoquetIntegral;

  /*** JMO Package (thanks to Jean-Marc Odobez) ***/
  //bgs = new MultiLayerBGS;

  /*** PT Package (thanks to Martin Hofmann, Philipp Tiefenbacher and Gerhard Rigoll) PRESKOCENO!!!!!!!!!!!!!***/
  //bgs = new PixelBasedAdaptiveSegmenter;

  /*** LB Package (thanks to Laurence Bender) ***/
  //bgs = new LBSimpleGaussian;
  bgs = new LBFuzzyGaussian;
  //bgs = new LBMixtureOfGaussians;
  //bgs = new LBAdaptiveSOM;
  //bgs = new LBFuzzyAdaptiveSOM;

  /*** LBP-MRF Package (thanks to Csaba Kertész) ***/
  //bgs = new LbpMrf;

  /*** AV Package (thanks to Lionel Robinault and Antoine Vacavant) ***/
  //bgs = new VuMeter;

  /*** EG Package (thanks to Ahmed Elgammal) ***/
  //bgs = new KDE;

  /*** DB Package (thanks to Domenico Daniele Bloisi) ***/
  //bgs = new IndependentMultimodalBGS;

  /*** SJN Package (thanks to SeungJong Noh) ***/
  //bgs = new SJN_MultiCueBGS;

  /*** BL Package (thanks to Benjamin Laugraud) ***/
  //bgs = new SigmaDeltaBGS;

  /*** PL Package (thanks to Pierre-Luc) ***/
  //bgs = new SuBSENSEBGS();
  //bgs = new LOBSTERBGS();

  int key = 0;
  while(key != 'q')
  {
    frame_aux = cvQueryFrame(capture);
    if(!frame_aux) break;

    cvResize(frame_aux, frame);

    cv::Mat img_input(frame);
    //cv::imshow("input", img_input);
```

```
    cv::Mat img_mask;
    cv::Mat img_bkgmodel;
    bgs->process(img_input, img_mask, img_bkgmodel); // by default, it shows automatically
the foreground mask image
    //cv::imshow("output", img_mask);
            bijeletocke = countNonZero(img_mask);
            svebijeletocke = svebijeletocke + bijeletocke;
            svetocke = svetocke + (visina * sirina);
            frame_broj=frame_broj + 1;

    //if(!img_mask.empty())
    //  cv::imshow("Foreground", img_mask);
    //  do something

    key = cvWaitKey(33);
  }

  delete bgs;

  cvDestroyAllWindows();
  cvReleaseCapture(&capture);
/*
  std::cout << "Visina: " << visina << std::endl;
  std::cout << "Sirina: " << sirina << std::endl;
  std::cout << "Razlucivost: " << sirina*visina << std::endl;
  std::cout << "Bijele: " << bijeletocke << std::endl;
  std::cout << "Sve bijele: " << svebijeletocke << std::endl;
  std::cout << "Sve tocke: " << svetocke << std::endl;
  std::cout << "Broj frameova: " << frame_broj << std::endl;
  return 0;*/
  ofstream file_;
  file_.open("izlazsve.txt",ios::app);
  file_ << visina << " " << sirina << " " << sirina*visina << " " << bijeletocke << " " <<
svebijeletocke << " " << svetocke << " " << frame_broj <<"\n";
  file_.close();
  /*
  std::cout << visina;
  std::cout << " ";
  std::cout << sirina;
  std::cout << " ";
  std::cout << sirina*visina;
  std::cout << " ";
  std::cout << bijeletocke;
  std::cout << " ";
  std::cout << svebijeletocke;
  std::cout << " ";
  std::cout << svetocke;
  std::cout << " ";
  std::cout << frame_broj << std::endl;*/
```

```
 return 0;


}
```

10.2. Programski kod u programu MATLAB za mjerenje vrijednosti VAI (prilagođeno od Cutting)

processCorrAndLum.m

```
close all;
clear all;

[filename pathname] = uigetfile('*.avi', 'Select a film');
startDir = pwd;
cd(pathname);
vr = VideoReader([pathname filename]);
startTime = tic;

%data to eventually output: 1 is VAI, 2 is Lum
data = zeros(2, vr.NumberOfFrames);
disp('variables initalized');

arrayCounter = 1;

%prime the program with frames
img1 = rgb2gray(read(vr, arrayCounter));
[width, height, colors] = size(img1);
arrayCounter = arrayCounter + 1;
%gamma correct and store luminance
imgam = imadjust(img1, [0.0 1.0], [0.0 1.0], .45);  %gamma correx
data(2, 1) = median(single(reshape(imgam, width*height, 1, 1)));

img2 = rgb2gray(read(vr, arrayCounter));
%gamma correct and store luminance
imgam = imadjust(img2, [0.0 1.0], [0.0 1.0], .45);  %gamma correx
data(2, 2) = median(single(reshape(imgam, width*height, 1, 1)));

%backup, so that the next step is seamless
img2 = img1;
img3 = img2;

%No VAI until 3rd Frame
data(1,1) = NaN;
data(1,2) = NaN;

tic;
```

```
h = waitbar(0,'Processing');

disp('starting processing');
for i = 3:vr.NumberOfFrames
   arrayCounter = arrayCounter + 1;
   img1 = img2;
   img2 = img3;
   img3 = rgb2gray(read(vr, arrayCounter));

   %store
   data(1, arrayCounter) = corr2(img1, img3);

   %gamma correct and store luminance
   imgam = imadjust(img3, [0.0 1.0], [0.0 1.0], .45);  %gamma correx
   data(2, arrayCounter) = median(single(reshape(imgam, width*height, 1, 1)));

   if mod(arrayCounter, 100) == 0
      timeElapsed = toc;
      fps = 100/timeElapsed;
      clc;
      disp(['Speed = ' num2str(fps) ' FPS']);
      disp(['Estimated Completion in: '  ...
         num2str(ceil( (vr.NumberOfFrames - arrayCounter) / fps  / 60 ) ) ' minutes' ]);
      h = waitbar(arrayCounter/vr.NumberOfFrames, h);
      tic;
   end
end

close(h);

%write data to file
csvwrite([filename(1:end-4) '_VAI_and_LUM.csv'], data');

%compute stats from raw data
vai = 1-nanmedian(data(1,:));
avgLum = nanmean(data(2,:));

clc;
disp(['VAI = ' num2str(vai) '          Mean Lum (Gamma) = ' num2str(avgLum)] );
disp(['Processing complete in ' num2str( round(toc(startTime) /60 ) ) ' minutes']);
cd(startDir);
```

10.3. Programski kod u MATLAB-u za dodavanje šuma u video isječke

```
% Demo macro to extract frames and get frame means from an avi movie
% and save individual frames to separate image files.
% Then rebuilds a new movie by recalling the saved images from disk.
% Also computes the mean gray value of the color channels
% And detects the difference between a frame and the previous frame.
clc;    % Clear the command window.
close all;  % Close all figures (except those of imtool.)
imtool close all;  % Close all imtool figures.
clear;  % Erase all existing variables.
workspace;  % Make sure the workspace panel is showing.
fontSize = 14;

% Change the current folder to the folder of this m-file.
% (The line of code below is from Brett Shoelson of The Mathworks.)
if(~isdeployed)
    cd(fileparts(which(mfilename)));
end

% Open the rhino.avi demo movie that ships with MATLAB.
[filename pathname] = uigetfile('*.avi', 'Select a film');
folder = fullfile(matlabroot, '\toolbox\images\imdemos');
movieFullFileName = fullfile(pathname,filename);
% Check to see that it exists.
if ~exist(movieFullFileName, 'file')
    strErrorMessage = sprintf('File not found:\n%s\nYou can choose a new
one, or cancel', movieFullFileName);
    response = questdlg(strErrorMessage, 'File not found', 'OK - choose a
new movie.', 'Cancel', 'OK - choose a new movie.');
    if strcmpi(response, 'OK - choose a new movie.')
        [baseFileName, folderName, FilterIndex] = uigetfile('*.avi');
        if ~isequal(baseFileName, 0)
            movieFullFileName = fullfile(folderName, baseFileName);
        else
            return;
        end
    else
        return;
    end
end

try
    videoObject = VideoReader(movieFullFileName)
    % Determine how many frames there are.
    numberOfFrames = videoObject.NumberOfFrames;
    vidHeight = videoObject.Height;
    vidWidth = videoObject.Width;

    numberOfFramesWritten = 0;
    % Prepare a figure to show the images in the upper half of the screen.
    figure;
    %   screenSize = get(0, 'ScreenSize');
    % Enlarge figure to full screen.
    set(gcf, 'units','normalized','outerposition',[0 0 1 1]);

    % Ask user if they want to write the individual frames out to disk.
    promptMessage = sprintf('Do you want to save the individual frames out
to individual disk files?');
```

```
    button = questdlg(promptMessage, 'Save individual frames?', 'Yes',
'No', 'Yes');
    if strcmp(button, 'Yes')
        writeToDisk = true;

        % Extract out the various parts of the filename.
        [folder, baseFileName, extentions] = fileparts(movieFullFileName);
        % Make up a special new output subfolder for all the separate
        % movie frames that we're going to extract and save to disk.
        % (Don't worry - windows can handle forward slashes in the folder
name.)
        folder = pwd;   % Make it a subfolder of the folder where this m-
file lives.
        outputFolder = sprintf('%s/Movie Frames from %s', folder,
baseFileName);
        % Create the folder if it doesn't exist already.
        if ~exist(outputFolder, 'dir')
            mkdir(outputFolder);
        end
    else
        writeToDisk = false;
    end

    % Loop through the movie, writing all frames out.
    % Each frame will be in a separate file with unique name.

    for frame = 1 : numberOfFrames
        % Extract the frame from the movie structure.
        thisFrame = read(videoObject, frame);
        thisFrame = imnoise(thisFrame,'gaussian',0,0.01);
        % Display it
        hImage = subplot(2, 2, 1);
        image(thisFrame);
        caption = sprintf('Frame %4d of %d.', frame, numberOfFrames);
        title(caption, 'FontSize', fontSize);
        drawnow; % Force it to refresh the window.

        % Write the image array to the output file, if requested.
        if writeToDisk
            % Construct an output image file name.
            outputBaseFileName = sprintf('Frame %4.4d.png', frame);
            outputFullFileName = fullfile(outputFolder,
outputBaseFileName);
            % Write it out to disk.
            imwrite(thisFrame, outputFullFileName, 'png');
        end


        % Update user with the progress.  Display in the command window.
        if writeToDisk
            progressIndication = sprintf('Wrote frame %4d of %d.', frame,
numberOfFrames);
        else
            progressIndication = sprintf('Processed frame %4d of %d.',
frame, numberOfFrames);
        end
        disp(progressIndication);
        % Increment frame count (should eventually = numberOfFrames
        % unless an error happens).
        numberOfFramesWritten = numberOfFramesWritten + 1;
```

```
    end

    % Alert user that we're done.
    if writeToDisk
        finishedMessage = sprintf('Done!  It wrote %d frames to
folder\n"%s"', numberOfFramesWritten, outputFolder);
    else
        finishedMessage = sprintf('Done!  It processed %d frames of\n"%s"',
numberOfFramesWritten, movieFullFileName);
    end
    disp(finishedMessage); % Write to command window.
    uiwait(msgbox(finishedMessage)); % Also pop up a message box.

    % Exit if they didn't write any individual frames out to disk.
    if ~writeToDisk
        return;
    end

    % Ask user if they want to read the individual frames from the disk,
    % that they just wrote out, back into a movie and display it.
    promptMessage = sprintf('Do you want to recall the individual
frames\nback from disk into a movie?\n(This will take several seconds.)');
    button = questdlg(promptMessage, 'Recall Movie?', 'Yes', 'No', 'Yes');
    if strcmp(button, 'No')
        return;
    end

    % Create a VideoWriter object to write the video out to a new,
different file.
    writerObj = VideoWriter('NewRhinos.avi');
    open(writerObj);

    % Read the frames back in from disk, and convert them to a movie.
    % Preallocate recalledMovie, which will be an array of structures.
    % First get a cell array with all the frames.
    allTheFrames = cell(numberOfFrames,1);
    allTheFrames(:) = {zeros(vidHeight, vidWidth, 3, 'uint8')};
    % Next get a cell array with all the colormaps.
    allTheColorMaps = cell(numberOfFrames,1);
    allTheColorMaps(:) = {zeros(256, 3)};
    % Now combine these to make the array of structures.
    recalledMovie = struct('cdata', allTheFrames, 'colormap',
allTheColorMaps)
    for frame = 1 : numberOfFrames
        % Construct an output image file name.
        outputBaseFileName = sprintf('Frame %4.4d.png', frame);
        outputFullFileName = fullfile(outputFolder, outputBaseFileName);
        % Read the image in from disk.
        thisFrame = imread(outputFullFileName);
        % Convert the image into a "movie frame" structure.
        recalledMovie(frame) = im2frame(thisFrame);
        % Write this frame out to a new video file.
        writeVideo(writerObj, thisFrame);
    end
    close(writerObj);
    % Get rid of old image and plot.
    delete(hImage);
    % delete(hPlot);
    % Create new axes for our movie.
    % subplot(1, 3, 2);
    % axis off;  % Turn off axes numbers.
```

```
    % title('Movie recalled from disk', 'FontSize', fontSize);
    % Play the movie in the axes.
    % movie(recalledMovie);
    % Note: if you want to display graphics or text in the overlay
    % as the movie plays back then you need to do it like I did at first
    % (at the top of this file where you extract and imshow a frame at a
time.)
    msgbox('Gotovo!');

catch ME
    % Some error happened if you get here.
    strErrorMessage = sprintf('Error extracting movie frames
from:\n\n%s\n\nError: %s\n\n)', movieFullFileName, ME.message);
    uiwait(msgbox(strErrorMessage));
end
```

10.4. Popis video isječaka Annie Lang korištenih u radu

Visina	Sirina	Broj frameova	Naziv datoteke	Length (Sec)	Emotion (1-Neg/ 2-Pos/ 3-Both)	Arousing (1-None/ 2-Some/ 3-A lot)	Emotion Change	New	Unrelated	Object Change	Closer	Perspective Change	Form Change	Average Info/sec	Average Camera/s
480	720	1799	60-FearFactor-1	60	1	3	0	6	4	33	15	31	0	1,483333	0,583333
480	720	899	30-Ad_Gundam08MSTeam2001	30	1	3	5	13	0	25	10	24	0	2,566667	0,833333
480	720	902	30-Ad_DinosaurPlanet2003-1	30	1	3	12	20	2	20	10	21	5	3	0,766667
480	720	1798	60-Alien-1	60	1	3	12	4	0	31	6	31	0	1,4	0,516667
480	720	487	60-Blade2-3	60	1	3	9	2	0	30	4	30	0	1,25	0,5
480	720	1798	60-G_Saviour-3	60	1	3	13	10	0	29	11	30	2	1,583333	0,5
480	720	1810	60-Animatrix-3	60	1	3	12	3	1	13	8	15	0	0,866667	0,25
480	720	899	30-StarTrek2_WrathOfKahn-3	30	1	3	5	2	0	7	1	7	0	0,733333	0,233333
480	720	899	30-ScorpionKing-2	30	1	3	2	4	1	6	4	8	0	0,833333	0,266667
480	720	1800	60-ForensicDetectives-1	60	1	3	3	0	0	3	8	12	0	0,433333	0,2
480	720	1798	60-Spider-Man-2	60	1	3	5	1	0	6	1	9	0	0,366667	0,15
480	720	901	30-ArmyAnts-1	30	1	3	0	0	0	1	1	5	0	0,233333	0,2
480	720	923	30-CSI-3	30	1	3	0	2	0	4	2	4	0	0,4	0,133333
480	720	899	30-X-Files-2	30	1	3	0	0	0	0	2	3	0	0,166667	0,1
480	720	1798	60-Jin_Roh-2	60	1	3	0	1	0	5	2	7	0	0,25	0,133333
480	720	899	30-MightyAphrodite-2	30	1	3	0	0	0	0	0	0	0	0	0
480	720	910	30-Patton-4	30	1	3	0	0	0	0	1	1	0	0,066667	0,033333
480	720	918	Paradise_30-7	30	1	3	0	1	0	3	2	3	0	0,3	0,1
480	720	899	30-IncredibleHumanBody-4	30	1	1	0	3	0	3	0	3	0	0,3	0,133333
480	720	901	30-Animatrix-1	30	1	2	9	1	0	7	5	13	0	1,166667	0,433333
480	720	899	30-BuffyTheVampireSlayer-3	30	1	2	4	2	0	14	3	14	0	1,233333	0,466667
480	720	1798	60-PearlHarbor-2	60	1	2	13	3	0	19	5	19	0	0,983333	0,316667
480	720	1805	60-BetterMan-1	60	1	2	12	6	1	19	10	19	2	1,15	0,366667
480	720	919	30-AlienAbduction-1	30	1	2	3	2	1	8	1	11	4	1	0,366667
480	720	899	30-Jin_Roh-1	30	1	2	0	4	0	7	3	7	0	0,7	0,233333
480	720	899	30-SpaceCowboys-4	30	1	2	4	0	0	6	2	7	0	0,633333	0,233333
480	720	1798	60-MoulinRouge-2	60	1	2	2	1	0	14	0	14	0	0,516667	0,233333

480	720	899	30-PowerRangerNinjaStorm-1	30	1	2	5	1	1	5	2	5	0	0,633333	0,166667
480	720	899	30-Lilo&Stitch-1	30	1	2	2	3	0	5	1	6	0	0,566667	0,2
480	720	1798	60-JohnQ_Bonus-2	60	1	2	0	10	0	11	2	9	6	0,633333	0,183333
480	720	1798	60-Sept11-1	60	1	2	0	0	0	1	1	2	0	0,066667	0,033333
480	720	899	30-RealStoryOfToraToraTora-1	30	1	1	0	1	1	2	1	2	2	0,3	0,066667
480	720	911	30-GiantRobo-2	30	1	2	3	0	0	0	1	3	0	0,233333	0,1
480	720	903	30-CowboyBebop-1	30	1	1	0	0	0	0	0	0	0	0	0
480	720	899	Fchri	30	1	2	1	0	1	1	1	1	0	0,166667	0,033333
480	720	1806	60-AnnieGetYourGun-6	60	1	2	0	0	0	0	0	0	0	0	0
480	720	919	MTV_30-3	30	2	3	2	5	0	15	7	30	0	1,966667	1
480	720	900	30-TheKid-4	30	2	3	5	1	0	16	7	16	0	1,5	0,533333
480	720	899	30-MusicVideo-1	30	2	3	6	4	2	24	9	35	0	0	1,166667
480	720	1799	60-ChipNDale-1	60	2	3	5	2	0	10	8	27	0	0,866667	0,45
480	720	899	30-TV_Show-1	30	2	3	7	4	0	12	8	14	0	1,5	0,466667
480	720	899	30-MajorLeague-5	30	2	3	1	5	2	12	5	14	0	1,3	0,466667
480	720	899	30-ChipNDale-1	30	2	3	1	1	0	5	4	8	0	0,633333	0,266667
480	720	1144	60-TradingSpaces-1	60	2	3	1	6	0	15	6	14	0	0,7	0,25
480	720	1798	60-HeavyMetal-2	60	2	3	3	2	0	15	8	15	0	0,716667	0,266667
480	720	1798	60-HeavyMetal-3	60	2	3	0	4	1	10	4	14	0	0,55	0,233333
480	720	1798	60-TradingSpaces-2	60	2	3	4	2	1	7	6	11	0	0,516667	0,183333
480	720	917	Majestic_30-2	30	2	3	1	1	0	6	4	7	0	0,633333	0,233333
480	720	1799	60-WillyWonka-1	60	2	3	1	1	0	4	3	6	0	0,25	0,1
480	720	899	30-SpaceCowboys-5	30	2	3	1	1	0	3	0	3	0	0,266667	0,1
480	720	899	30-MTV_MovieAward2004-6	30	2	3	1	0	0	2	1	3	0	0,233333	0,1
480	720	899	30-tango-1	30	2	3	0	0	0	0	0	0	0	0	0
480	720	899	30-grinch-1	30	2	3	0	0	0	1	0	2	0	0,1	0,066667
480	720	901	30-Sayonara-1	30	2	3	1	0	0	0	1	2	0	0,133333	0,066667
480	720	899	30-Ad_Head&Shoulder-2004April	30	2	2	0	1	6	8	8	15	0	1,266667	0,5
480	720	896	30-Ad_Wendys&LooneyTunes2003-1	30	2	2	0	10	7	14	3	11	3	1,6	0,5
480	720	899	30-Barney-1	30	2	2	0	1	0	7	3	10	0	0,7	0,333333
480	720	899	30-PearlHarborBonus-2	30	2	2	0	11	0	11	2	10	4	1,266667	0,366667
480	720	1798	60-Wiggles-2	60	2	2	9	6	1	24	8	21	8	1,283333	0,416667
480	720	899	30-BeautyandTheBeast-1	30	2	2	1	2	0	4	3	6	0	0,533333	0,233333

480	720	899	30-TopGun-3	30	2	2	0	0	0	7	1	7	0	0,5	0,233333
480	720	1799	60-EmerilLive-1	60	2	2	1	8	2	14	4	14	0	0,716667	0,233333
480	720	899	30-CNN-TigerWoods	30	2	2	3	1	0	3	0	3	1	0,366667	0,1
480	720	1809	60-UnknownComedy-2	60	2	1	0	3	1	4	3	9	0	0,333333	0,2
480	720	899	30-KingOfTheHill-2	30	2	2	3	2	0	6	2	6	0	0,633333	0,2
480	720	899	30-IncredibleHumanBody-1	30	2	1	0	0	0	1	1	2	2	0,2	0,066667
480	720	1798	60-ThomasAndTheMagicRailroad-3	60	2	2	1	0	1	2	1	4	0	0,15	0,066667
480	720	1802	60-Nova_Pearl	60	2	1	0	2	2	6	2	6	2	0,333333	0,1
480	720	902	30-Connections-2	30	2	1	0	0	0	0	0	0	0	0	0
480	720	1805	60-DareDevilBonus-2	60	2	1	0	0	0	0	0	0	0	0	0
480	720	899	30-ThereGoesAGarbageTruck-1	30	2	2	0	0	0	0	0	0	0	0	0
480	720	899	30-Spartacus_2004-1	30	1	3	25	14	5	25	16	33	9	4,233333	1,1
480	720	1779	60-Ad_SilentMobious-2001	60	1	3	12	15	0	42	9	44	4	2,1	0,75
480	720	911	30-BetterMan-2	30	2	2	2	0	0	4	4	7	0	0,566667	0,233333
480	720	897	30-PearlHarborBonus-1	30	1	3	5	15	0	15	2	15	2	1,8	0,5
480	720	1786	60-PhoneBooth-1	60	1	3	6	18	2	25	5	16	4	1,266667	0,5
480	720	1793	60-PearlHarbor-5	60	1	3	3	9	0	13	9	15	0	0,816667	0,25
480	720	1798	60-ScorpionKing-1	60	1	3	1	13	2	15	4	10	6	0,85	0,25
480	720	1787	60-PowerRangerNinjaStorm-1	60	1	3	0	1	1	9	6	16	0	0,55	0,266667
480	720	899	30-PersonalVelocity-3	30	1	3	2	1	0	4	2	4	0	0,433333	0,133333
480	720	1790	60-Yu_Gi_Oh-1	60	1	3	3	1	0	12	5	11	0	0,533333	0,216667
480	720	1792	60-Alien-2	60	1	3	2	2	8	3	8	0	0	0,383333	0,133333
480	720	901	30-CNN_CA_fire-1	30	1	3	0	0	0	1	2	4	0	0,233333	0,133333
480	720	1797	60-ChildrenOfDune-1	60	1	3	2	2	0	8	4	7	0	0,383333	0,133333
480	720	1798	60-StarTrek_Generations-2	60	1	3	2	0	0	1	1	2	0	0,1	0,033333
480	720	1802	60-tango-1	60	1	3	0	1	0	2	0	2	0	0,083333	0,033333
480	720	1802	60-Patton-2	60	1	3	2	3	0	6	1	6	0	0,3	0,1
480	720	891	30-PowerRangerNinjaStorm-2	30	1	2	6	1	0	11	1	12	0	1,033333	0,4
480	720	917	30-CSI-2	30	1	2	12	2	0	12	2	13	0	1,366667	0,433333
480	720	890	30-TopGun-2	30	1	2	6	6	0	13	5	10	0	1,333333	0,433333
480	720	1793	60-JohnQ-4	60	1	2	2	2	0	20	3	20	0	0,783333	0,333333
480	720	905	30-BlackHawkDown-1	30	1	3	2	5	1	15	5	15	0	1,433333	0,5
480	720	1793	60-DareDevil-2	60	1	2	6	2	0	23	6	23	0	1	0,383333
480	720	905	30-SpaceCowboys-1	30	1	1	0	3	0	7	4	3	0	0,566667	0,233333
480	720	1798	60-ChildrenOfDune-3	60	1	2	2	1	0	15	7	15	0	0,666667	0,25

480	720	1798	60-StarTrek_Nemesis-2	60	1	2	1	5	1	13	8	10	0	0,633333	0,216667
480	720	902	30-KobeBryant-1	30	1	2	0	5	2	5	2	5	3	0,733333	0,166667
480	720	1789	60-Robotech-1	60	1	2	4	1	0	8	2	11	0	0,433333	0,183333
480	720	894	30-Spider-Man-1	30	1	2	2	2	0	5	1	6	0	0,533333	0,2
480	720	1797	60-CNN_CA_fire-1	60	1	2	0	2	0	3	2	3	0	0,166667	0,05
480	720	1797	60-Law&Order_CI-2	60	1	2	2	0	0	5	2	6	0	0,25	0,1
480	720	897	30-CowboyBebop-2	30	1	1	0	0	0	0	0	0	0	0	0
480	720	911	30-Gattaga-2	30	1	2	0	0	0	0	0	0	0	0	0
480	720	1810	60-Connections-1	60	1	2	0	1	0	1	0	1	0	0,05	0,016667
480	720	921	MTV_30-5	30	2	3	10	5	2	23	17	31	1	2,966667	1,033333
480	720	899	30-NBC-Olympic2004-Swimming-3	30	2	3	8	6	2	10	14	25	6	2,366667	0,833333
480	720	899	30-sports-2	30	2	3	6	4	2	24	9	35	0	2,933333	1,133333
480	720	899	30-TV_Show-2	30	2	3	8	9	2	13	8	14	0	1,8	0,466667
480	720	906	30-MTV_interview-1	30	2	3	3	3	0	10	6	14	0	1,2	0,466667
480	720	1799	60-ChipNDale-2	60	2	3	0	1	0	15	11	31	0	0,966667	0,516667
480	720	1795	ThatThing_60-2	60	2	3	4	5	0	20	11	23	0	1,05	0,383333
480	720	1798	60-SesameStreet-1	60	2	3	3	2	0	12	12	22	0	0,85	0,35
480	720	897	ThatThing_30-1	30	2	3	2	3	0	7	2	7	0	0,7	0,233333
480	720	1810	60-MajorLeague-1	60	2	3	6	4	2	24	9	35	0	0,816667	0,233333
480	720	1793	60-HeavyMetal-1	60	2	3	0	3	0	9	5	12	0	0,483333	0,2
480	720	898	30-Animatrix-6	30	2	1	2	2	0	2	1	2	1	0,333333	0,1
480	720	914	30_chickenrun-4	30	2	3	8	3	0	14	8	14	0	1,566667	0,466667
480	720	899	30-MTV_MovieAward2004-7	30	2	2	15	2	0	15	8	15	0	1,833333	0,5
480	720	898	30-BuffyTheVampireSlayer-2	30	2	2	3	1	0	4	1	4	0	0,433333	0,133333
480	720	902	30-MTV_Cribs-1	30	2	1	0	5	0	20	3	13	5	1,533333	0,733333
480	720	900	30-AChristmasStory-2	30	2	3	1	2	0	2	2	2	0	0,3	0,066667
480	720	910	MTV_30-9	30	2	1	1	0	10	4	9	8	9	1,366667	7
480	720	891	30-PearlHarbor-1	30	2	1	0	2	0	11	5	11	0	0,966667	0,366667
480	720	1774	60-VictoriaSecretShow2003-1	60	2	2	0	6	1	13	9	26	2	0,95	0,433333
480	720	892	30-Barney-3	30	2	2	2	2	1	8	3	8	0	0,8	0,266667
480	720	906	30-BlackHawkDown-4	30	1	2	3	3	0	9	4	9	0	0,933333	0,3
480	720	899	30-Babe_pig-3	30	2	2	1	2	0	4	2	4	1	0,466667	0,333333
480	720	1799	60-ArnoldPalmer-2004Masters	60	2	1	5	1	0	6	4	8	0	0,4	0,116667
480	720	898	30-Bounce-1	30	1	2	1	1	0	2	2	2	0	0,266667	0,066667
480	720	898	30-Whales-1	30	2	1	0	0	0	5	1	6	0	0,4	0,2

480	720	897	30-HereComesTheMonsterTruck-1	30	2	1	0	2	0	2	1	2	0	0,233333	0,066667
480	720	887	30-Ad_FindingNemo_VideoGame2001	30	2	2	2	10	0	18	3	18	5	1,866667	0,7
480	720	896	30-FatherChristmas-1	30	2	1	0	2	0	3	1	3	0	0,3	0,1
480	720	1812	60-AnnieGetYourGun-1	60	2	1	0	0	0	0	0	0	0	0	0
480	720	898	30-StarTrek_Generations-1	30	2	1	0	0	0	0	0	0	0	0	0

10.5. Histogrami korištenih podataka po pojedinim dimenzijama

Tests of Normality

	Kolmogorov-Smirnov[a]			Shapiro-Wilk		
	Statistic	df	Sig.	Statistic	df	Sig.
camus	,169	135	,000	,869	135	,000
emocija	,251	135	,000	,675	135	,000
novi_zarisni_objekt	,238	135	,000	,696	135	,000
povezanost	,377	135	,000	,416	135	,000
promjena_ zarisnog_objekta	,143	135	,000	,894	135	,000
udaljenost	,175	135	,000	,812	135	,000
perspektiva	,159	135	,000	,853	135	,000
izmjena_objekta	,455	135	,000	,442	135	,000

a. Lilliefors Significance Correction

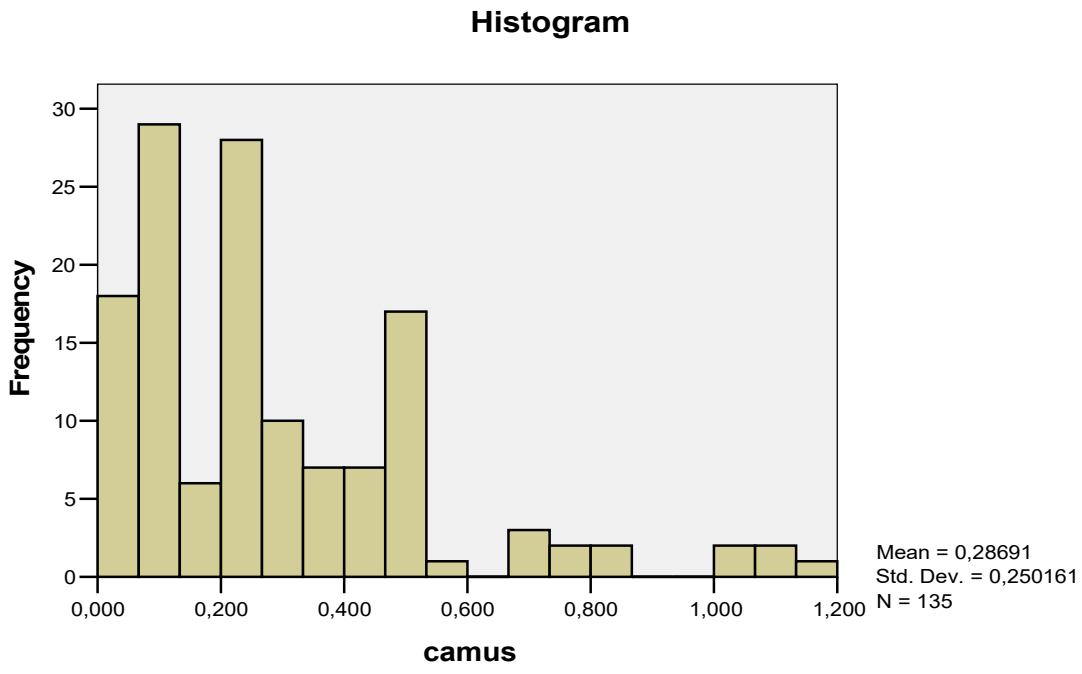

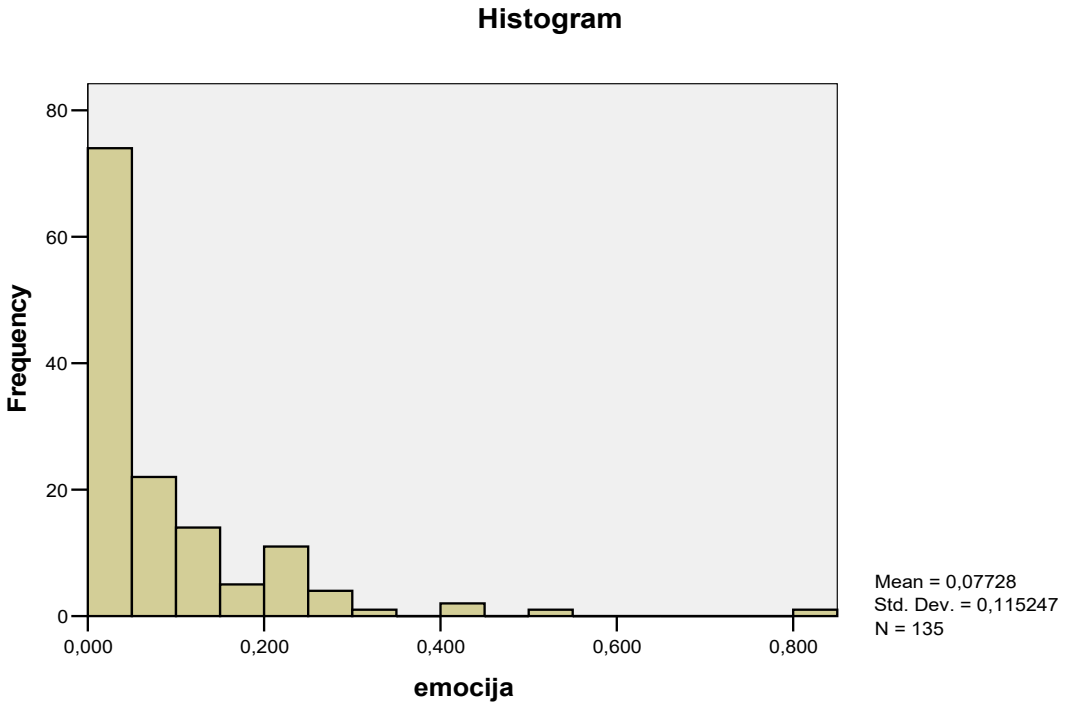
Histogram
Frequency
80
60
40
20
0
0,000
0,200
0,400
0,600
0,800
emocija
Mean = 0,07728
Std. Dev. = 0,115247
N = 135

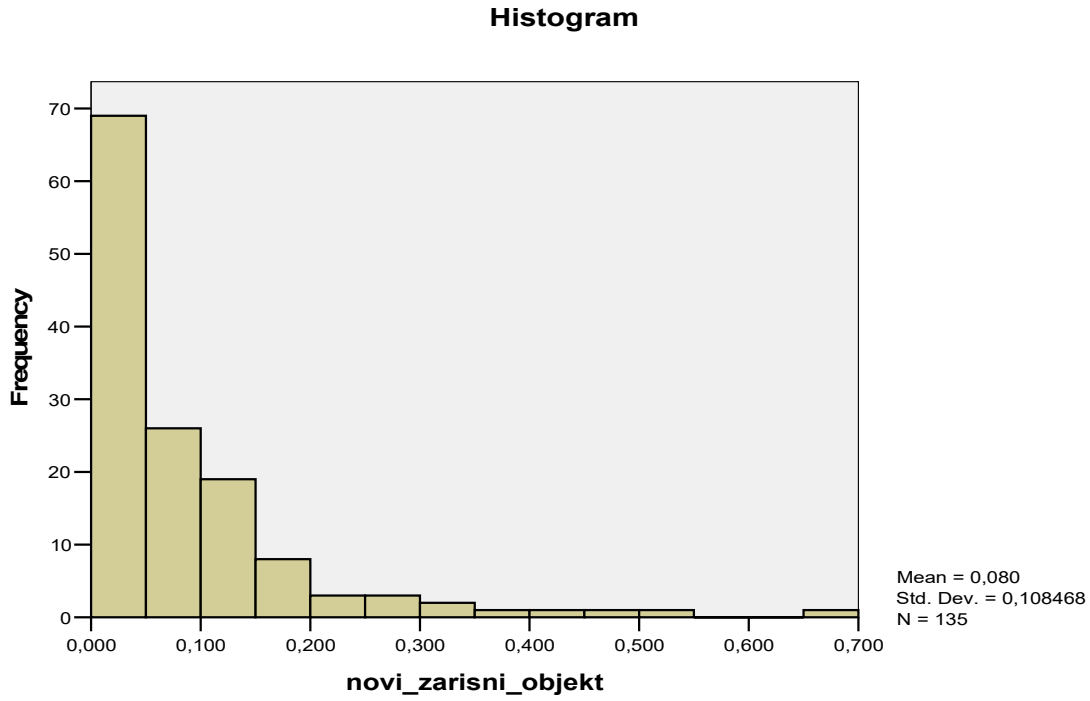
Histogram
Frequency
70
60
50
40
30
20
10
0
0,000
0,100
0,200
0,300
0,400
0,500
0,600
0,700
novi_zarisni_objekt
Mean = 0,080
Std. Dev. = 0,108468
N = 135

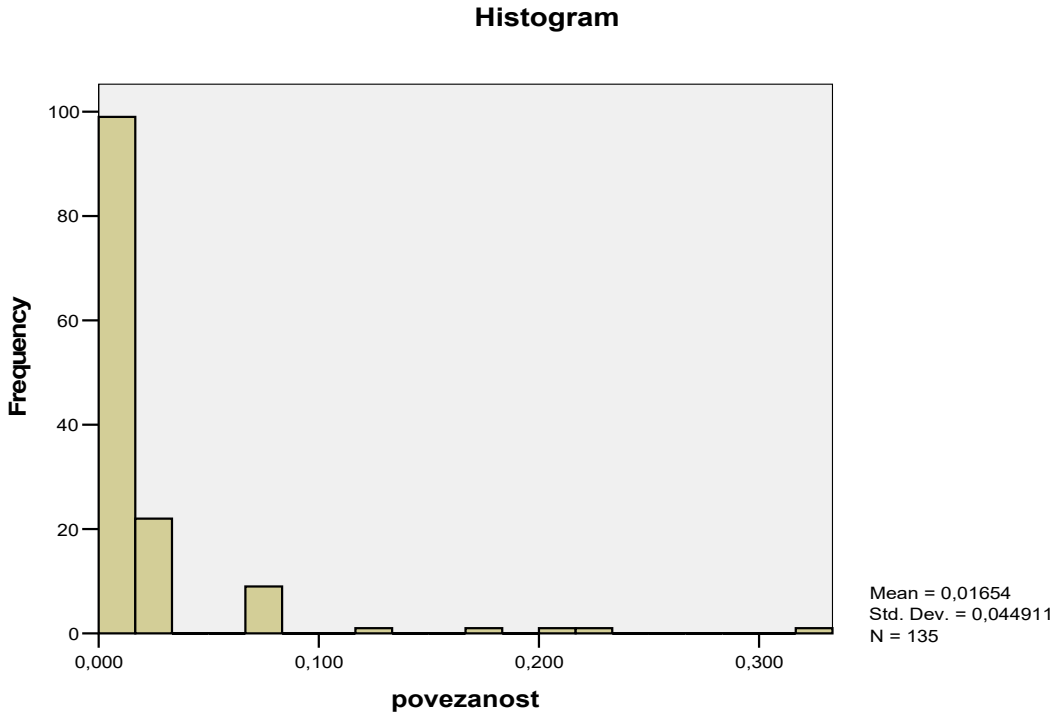
Histogram
Frequency
100
80
60
40
20
0
0,000
0,100
0,200
0,300
povezanost
Mean = 0,01654
Std. Dev. = 0,044911
N = 135

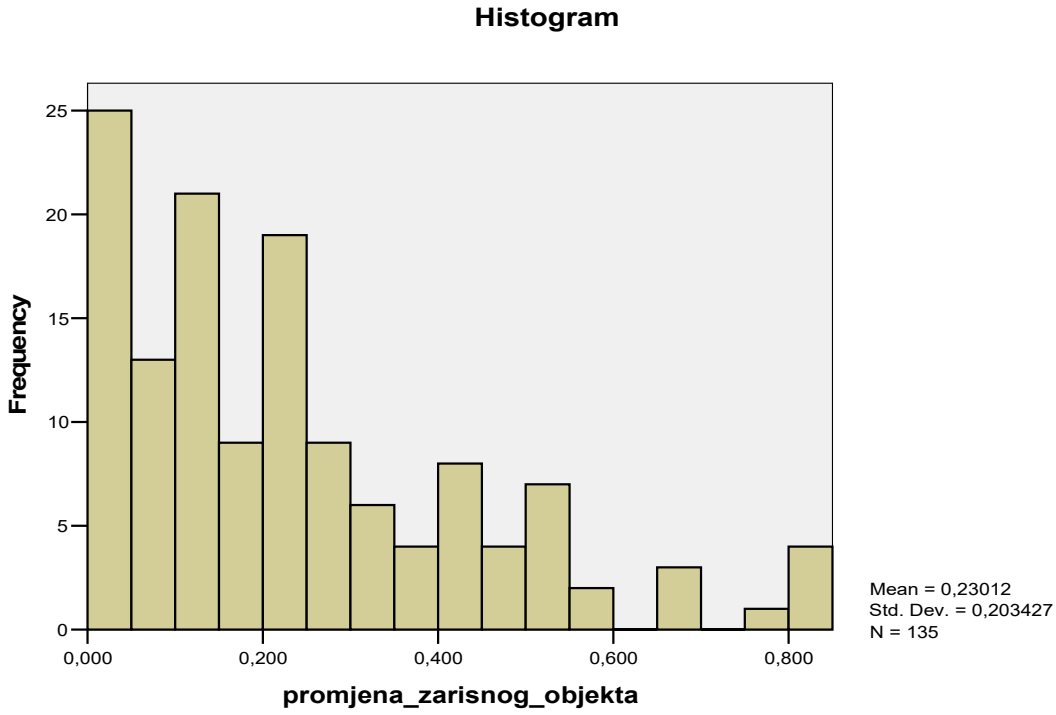
Histogram
Frequency
25
20
15
10
5
0
0,000
0,200
0,400
0,600
0,800
promjena_zarisnog_objekta
Mean = 0,23012
Std. Dev. = 0,203427
N = 135

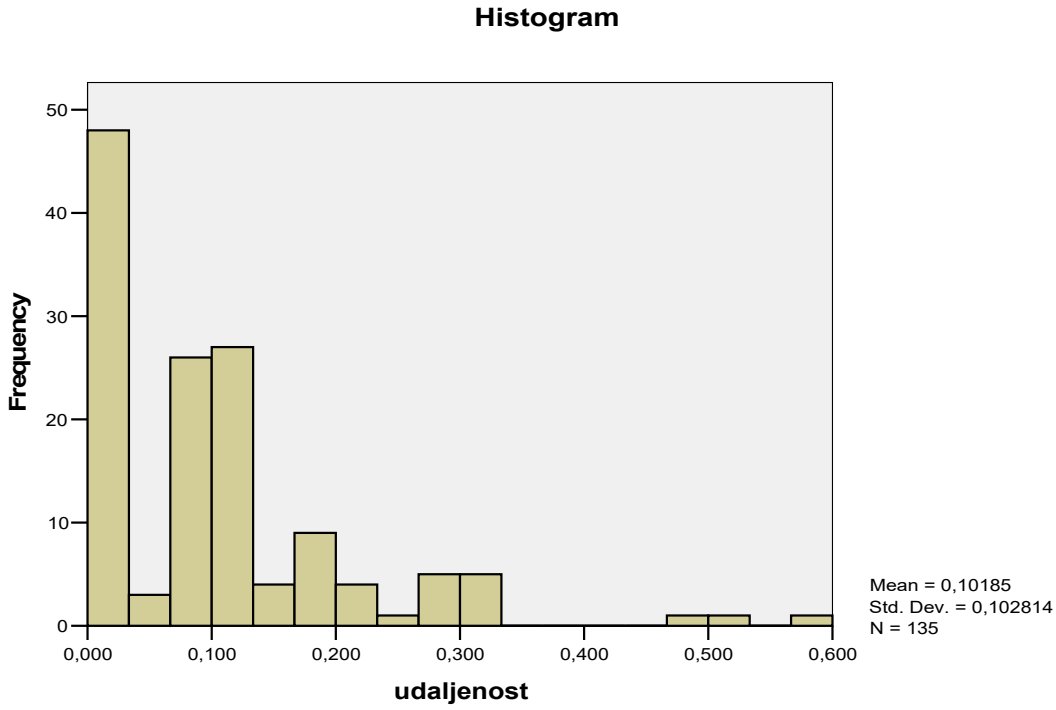
Histogram
Frequency
udaljenost
Mean = 0,10185
Std. Dev. = 0,102814
N = 135

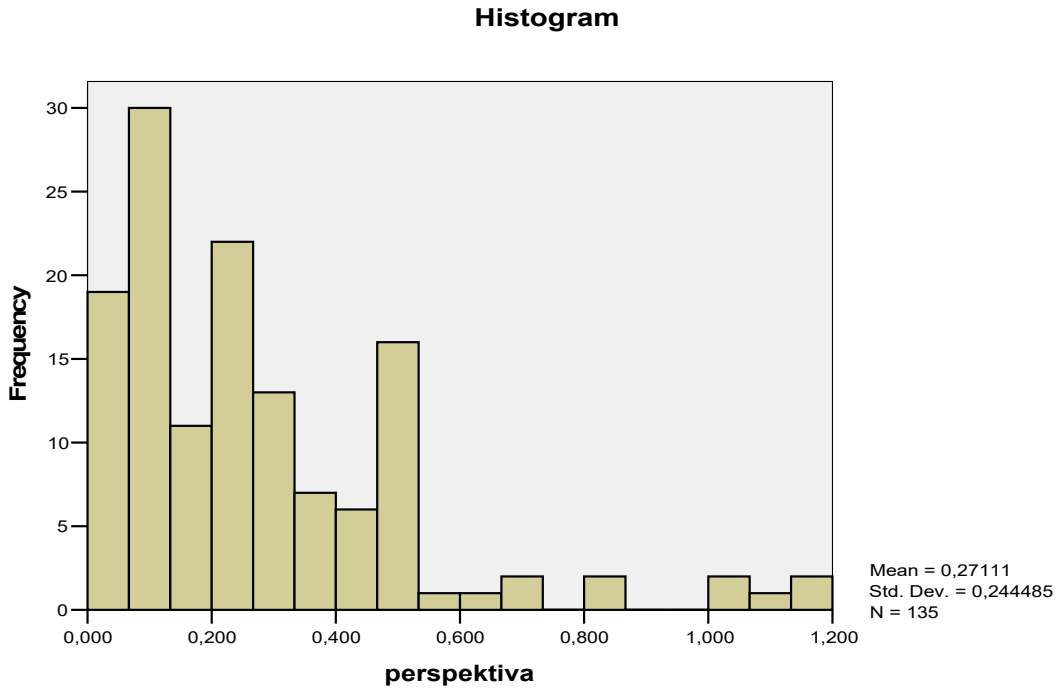
Histogram
Frequency
perspektiva
Mean = 0,27111
Std. Dev. = 0,244485
N = 135

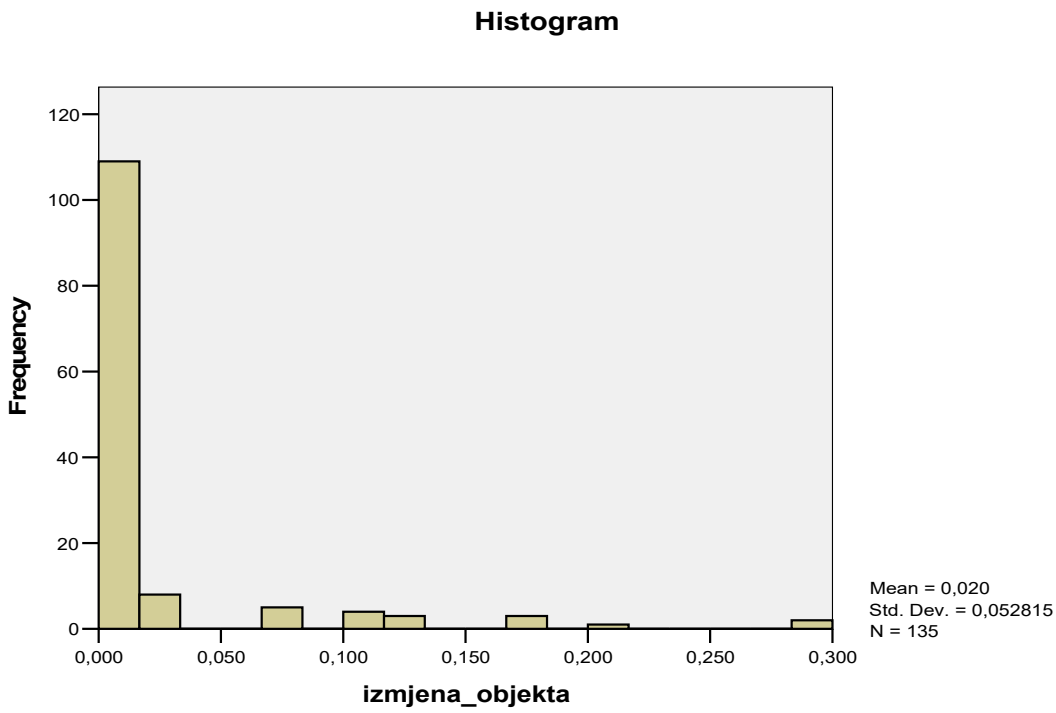
Histogram
Frequency
120
100
80
60
40
20
0
0,000
0,050
0,100
0,150
0,200
0,250
0,300
izmjena_objekta
Mean = 0,020
Std. Dev. = 0,052815
N = 135

10.6. Postavke za algoritme uklanjanja pozadine koji su korišteni u radu

KATEGORIJA	ALGORITAM	POSTAVKE
Osnovne metode	Static Frame Difference	<opencv_storage> <enableThreshold>1</enableThreshold> <threshold>15</threshold> <showOutput>0</showOutput> </opencv_storage>
	Frame Difference	<opencv_storage> <enableThreshold>1</enableThreshold> <threshold>15</threshold> <showOutput>1</showOutput> </opencv_storage>
	Weighted Moving Mean	<opencv_storage> <enableWeight>1</enableWeight> <enableThreshold>1</enableThreshold> <threshold>15</threshold> <showOutput>1</showOutput> <showBackground>0</showBackground> </opencv_storage>
	Weighted Moving Variance	<opencv_storage> <enableWeight>1</enableWeight> <enableThreshold>1</enableThreshold> <threshold>15</threshold> <showOutput>1</showOutput> </opencv_storage>
	Adaptive Background Learning	<opencv_storage> <alpha>5.0000000000000003e-002</alpha> <limit>-1</limit> <enableThreshold>1</enableThreshold> <threshold>15</threshold> <showForeground>1</showForeground> <showBackground>1</showBackground> </opencv_storage>
	Adaptive Selective Background Learning	<opencv_storage> <learningFrames>90</learningFrames> <alphaLearn>5.0000000000000003e-002</alphaLearn> <alphaDetection>5.0000000000000003e-002</alphaDetection> <threshold>25</threshold> <showOutput>1</showOutput> </opencv_storage>
	Temporal Mean	<opencv_storage> <threshold>2700</threshold>

		<alpha>9.9999999747524271e-007</alpha> <learningFrames>30</learningFrames> <showOutput>1</showOutput> </opencv_storage>
	Adaptive Median	<opencv_storage> <threshold>40</threshold> <samplingRate>7</samplingRate> <learningFrames>30</learningFrames> <showOutput>1</showOutput> </opencv_storage>
	Temporal Median	<opencv_storage> <threshold>30</threshold> <samplingRate>5</samplingRate> <historySize>16</historySize> <weight>5</weight> <showOutput>1</showOutput> </opencv_storage>
	Sigma-Delta	<opencv_storage> <ampFactor>1</ampFactor> <minVar>15</minVar> <maxVar>255</maxVar> <showOutput>1</showOutput> </opencv_storage>
Algoritmi bazirani na neodređenoj (eng. Fuzzy) logici	Fuzzy Sugeno Integral	<opencv_storage> <showOutput>1</showOutput> <framesToLearn>10</framesToLearn> <alphaLearn>1.0000000000000001e-001</alphaLearn> <alphaUpdate>1.0000000000000000e-002</alphaUpdate> <colorSpace>1</colorSpace> <option>2</option> <smooth>1</smooth> <threshold>6.7000000000000004e-001</threshold> </opencv_storage>
	Fuzzy Choquet Integral	<opencv_storage> <showOutput>1</showOutput> <framesToLearn>10</framesToLearn> <alphaLearn>1.0000000000000001e-001</alphaLearn> <alphaUpdate>1.0000000000000000e-002</alphaUpdate> <colorSpace>1</colorSpace> <option>2</option> <smooth>1</smooth> <threshold>6.7000000000000004e-001</threshold> </opencv_storage>
	Fuzzy Gaussian	<opencv_storage> <sensitivity>72</sensitivity> <bgThreshold>162</bgThreshold>

		<learningRate>49</learningRate> <noiseVariance>195</noiseVariance> <showOutput>1</showOutput> </opencv_storage>
Single gaussian based methods	Gaussian Average of Wren	<opencv_storage> <threshold>1.2250000000000000e+001</threshold> <alpha>4.9999998882412910e-003</alpha> <learningFrames>30</learningFrames> <showOutput>1</showOutput> </opencv_storage>
	Simple Gaussian	<opencv_storage> <threshold>1.2250000000000000e+001</threshold> <alpha>4.9999998882412910e-003</alpha> <learningFrames>30</learningFrames> <showOutput>1</showOutput> </opencv_storage>
Multiple gaussians based methods	Gaussian Mixture Model of Stauffer and Grimson	<opencv_storage> <threshold>9.</threshold> <alpha>1.0000000000000000e-002</alpha> <gaussians>3</gaussians> <showOutput>1</showOutput> </opencv_storage>
	Gaussian Mixture Model of KadewTraKuPong and Bowden	<opencv_storage> <alpha>5.0000000000000003e-002</alpha> <enableThreshold>1</enableThreshold> <threshold>15</threshold> <showOutput>1</showOutput> </opencv_storage>
	Gaussian Mixture Model of Zivkovic	<opencv_storage> <alpha>5.0000000000000003e-002</alpha> <enableThreshold>1</enableThreshold> <threshold>15</threshold> <showOutput>1</showOutput> </opencv_storage>
	Gaussian Mixture Model of Zivkovic	<opencv_storage> <threshold>25.</threshold> <alpha>1.0000000474974513e-003</alpha> <gaussians>3</gaussians> <showOutput>1</showOutput> </opencv_storage>
	Gaussian Mixture Model of Laurence Bender	<opencv_storage> <sensitivity>81</sensitivity> <bgThreshold>83</bgThreshold> <learningRate>59</learningRate> <noiseVariance>206</noiseVariance> <showOutput>1</showOutput>

		</opencv_storage>
Type-2 Fuzzy based methods	Type-2 Fuzzy GMM-UM of	<opencv_storage> <threshold>9.</threshold> <alpha>1.0000000000000000e-002</alpha> <km>1.5000000000000000e+000</km> <kv>6.0000002384185791e-001</kv> <gaussians>3</gaussians> <showOutput>1</showOutput> </opencv_storage>
	Type-2 Fuzzy GMM-UV of Baf et al	<opencv_storage> <threshold>9.</threshold> <alpha>1.0000000000000000e-002</alpha> <km>1.5000000000000000e+000</km> <kv>6.0000002384185791e-001</kv> <gaussians>3</gaussians> <showOutput>1</showOutput> </opencv_storage>
	Type-2 Fuzzy GMM-UM with MRF	<opencv_storage> <threshold>9.</threshold> <alpha>1.0000000000000000e-002</alpha> <km>2.</km> <kv>8.9999997615814209e-001</kv> <gaussians>3</gaussians> <showOutput>1</showOutput> </opencv_storage>
	Type-2 Fuzzy GMM-UV with MRF	<opencv_storage> <threshold>9.</threshold> <alpha>1.0000000000000000e-002</alpha> <km>2.</km> <kv>8.9999997615814209e-001</kv> <gaussians>3</gaussians> <showOutput>1</showOutput> </opencv_storage>
Multiple features based methods	Texture BGS	<opencv_storage> <showOutput>1</showOutput> </opencv_storage>
	Texture-Based Foreground Detection with MRF	<opencv_storage> <showOutput>1</showOutput> </opencv_storage>
	Multi-Layer BGS	<opencv_storage> <preloadModel>"./models/MultiLayerBGSModel.yml"</preloadModel> <saveModel>0</saveModel> <detectAfter>0</detectAfter> <disableDetectMode>1</disableDetectMode>

		<disableLearningInDetecMode>0</disableLearningInDetecMode> <loadDefaultParams>1</loadDefaultParams> <max_mode_num>5</max_mode_num> <weight_updating_constant>5.</weight_updating_constant> <texture_weight>5.0000000000000000e-001</texture_weight> <bg_mode_percent>6.0000002384185791e-001</bg_mode_percent> <pattern_neig_half_size>4</pattern_neig_half_size> <pattern_neig_gaus_sigma>3.</pattern_neig_gaus_sigma> <bg_prob_threshold>2.0000000298023224e-001</bg_prob_threshold> <bg_prob_updating_threshold>2.0000000298023224e-001</bg_prob_updating_threshold> <robust_LBP_constant>3</robust_LBP_constant> <min_noised_angle>1.7453293502330780e-001</min_noised_angle> <shadow_rate>6.0000002384185791e-001</shadow_rate> <highlight_rate>1.2000000476837158e+000</highlight_rate> <bilater_filter_sigma_s>3.</bilater_filter_sigma_s> <bilater_filter_sigma_r>1.0000000149011612e-001</bilater_filter_sigma_r> <frame_duration>1.0000000149011612e-001</frame_duration> <learn_mode_learn_rate_per_second>5.0000000000000000e-001</learn_mode_learn_rate_per_second> <learn_weight_learn_rate_per_second>5.0000000000000000e-001</learn_weight_learn_rate_per_second> <learn_init_mode_weight>5.0000000745058060e-002</learn_init_mode_weight> <detect_mode_learn_rate_per_second>9.9999997764825821e-003</detect_mode_learn_rate_per_second> <detect_weight_learn_rate_per_second>9.9999997764825821e-003</detect_weight_learn_rate_per_second> <detect_init_mode_weight>1.0000000474974513e-003</detect_init_mode_weight> <showOutput>1</showOutput> </opencv_storage>
	MultiCue BGS	<opencv_storage> <showOutput>1</showOutput> </opencv_storage>
	SuBSENSE	<opencv_storage> <fRelLBSPThreshold>3.3300000429153442e-001</fRelLBSPThreshold>

		<nDescDistThresholdOffset>3</nDescDistThresholdOffset> <nMinColorDistThreshold>30</nMinColorDistThreshold> <nBGSamples>50</nBGSamples> <nRequiredBGSamples>2</nRequiredBGSamples> <nSamplesForMovingAvgs>100</nSamplesForMovingAvgs> <showOutput>1</showOutput> </opencv_storage>
	LOBSTER	<opencv_storage> <fRelLBSPThreshold>3.6500000953674316e-001</fRelLBSPThreshold> <nLBSPThresholdOffset>0</nLBSPThresholdOffset> <nDescDistThreshold>4</nDescDistThreshold> <nColorDistThreshold>30</nColorDistThreshold> <nBGSamples>35</nBGSamples> <nRequiredBGSamples>2</nRequiredBGSamples> <showOutput>1</showOutput> </opencv_storage>
Non-parametric methods	Pixel-Based Adaptive Segmenter (PBAS)	<opencv_storage> <showOutput>1</showOutput> </opencv_storage>
	GMG	<opencv_storage> <initializationFrames>20</initializationFrames> <decisionThreshold>6.9999999999999996e-001</decisionThreshold> <showOutput>1</showOutput> </opencv_storage>
	VuMeter	<opencv_storage> <enableFilter>1</enableFilter> <binSize>8</binSize> <alpha>9.9500000000000000e-001</alpha> <threshold>2.9999999999999999e-002</threshold> <showOutput>1</showOutput> </opencv_storage>
	KDE	<opencv_storage> <framesToLearn>10</framesToLearn> <SequenceLength>50</SequenceLength> <TimeWindowSize>100</TimeWindowSize> <SDEstimationFlag>1</SDEstimationFlag> <lUseColorRatiosFlag>1</lUseColorRatiosFlag> <th>9.9999999999999995e-008</th> <alpha>2.9999999999999999e-001</alpha> <showOutput>1</showOutput> </opencv_storage>
	IMBS	<opencv_storage>

		<showOutput>1</showOutput> </opencv_storage>
Subspace-based methods	Eigenbackground / SL-PCA	<opencv_storage> <threshold>225</threshold> <historySize>20</historySize> <embeddedDim>10</embeddedDim> <showOutput>1</showOutput> </opencv_storage>
Neural and neuro-fuzzy methods	Adaptive SOM	<opencv_storage> <sensitivity>75</sensitivity> <trainingSensitivity>245</trainingSensitivity> <learningRate>62</learningRate> <trainingLearningRate>255</trainingLearningRate> <trainingSteps>55</trainingSteps> <showOutput>1</showOutput> </opencv_storage>
	Fuzzy Adaptive SOM	<opencv_storage> <sensitivity>90</sensitivity> <trainingSensitivity>240</trainingSensitivity> <learningRate>38</learningRate> <trainingLearningRate>255</trainingLearningRate> <trainingSteps>81</trainingSteps> <showOutput>1</showOutput> </opencv_storage>

10.7. Izlazni rezultati Spearmanove korelacije iz SPSS-a između BGSVAI vrijednosti i pojedinih dimenzija Gustoće informacija

Correlations

			BGSVAI	LANG1	LANG2	LANG3	LANG4	LANG5	LANG6	LANG7
Spearman's rho	BGSVAI	Correlation Coefficient	1,000	,386**	,495**	,452**	,593**	,616**	,699**	,262**
		Sig. (2-tailed)	.	,000	,000	,000	,000	,000	,000	,002
		N	135	135	135	135	135	135	135	135
	LANG1	Correlation Coefficient	,386**	1,000	,412**	,129	,603**	,511**	,612**	,112
		Sig. (2-tailed)	,000	.	,000	,135	,000	,000	,000	,197
		N	135	135	135	135	135	135	135	135
	LANG2	Correlation Coefficient	,495**	,412**	1,000	,353**	,769**	,594**	,653**	,435**
		Sig. (2-tailed)	,000	,000	.	,000	,000	,000	,000	,000
		N	135	135	135	135	135	135	135	135
	LANG3	Correlation Coefficient	,452**	,129	,353**	1,000	,290**	,387**	,296**	,374**
		Sig. (2-tailed)	,000	,135	,000	.	,001	,000	,000	,000
		N	135	135	135	135	135	135	135	135
	LANG4	Correlation Coefficient	,593**	,603**	,769**	,290**	1,000	,758**	,937**	,287**
		Sig. (2-tailed)	,000	,000	,000	,001	.	,000	,000	,001
		N	135	135	135	135	135	135	135	135
	LANG5	Correlation Coefficient	,616**	,511**	,594**	,387**	,758**	1,000	,821**	,161
		Sig. (2-tailed)	,000	,000	,000	,000	,000	.	,000	,062
		N	135	135	135	135	135	135	135	135
	LANG6	Correlation Coefficient	,699**	,612**	,653**	,296**	,937**	,821**	1,000	,237**
		Sig. (2-tailed)	,000	,000	,000	,000	,000	,000	.	,006
		N	135	135	135	135	135	135	135	135
	LANG7	Correlation Coefficient	,262**	,112	,435**	,374**	,287**	,161	,237**	1,000
		Sig. (2-tailed)	,002	,197	,000	,000	,001	,062	,006	.
		N	135	135	135	135	135	135	135	135

**. Correlation is significant at the 0.01 level (2-tailed).

10.8. Izlazni rezultati Spearmanove korelacije varijabli VAI i BGSVAI u SPSS-u uz 1. hipotezu

Correlations

		VAI	BGSVAI
VAI	Pearson Correlation	1	,793**
	Sig. (2-tailed)		,000
	N	135	135
BGSVAI	Pearson Correlation	,793**	1
	Sig. (2-tailed)	,000	
	N	135	135

**. Correlation is significant at the 0.01 level

Correlations

			VAI	BGSVAI
Spearman's rho	VAI	Correlation Coefficient	1,000	,823**
		Sig. (2-tailed)	.	,000
		N	135	135
	BGSVAI	Correlation Coefficient	,823**	1,000
		Sig. (2-tailed)	,000	.
		N	135	135

**. Correlation is significant at the 0.01 level (2-tailed).

10.9. Izlazni rezultati Wilckoxonovog testa u SPSS-u uz 2. hipotezu

NPar Tests

Descriptive Statistics

	N	Percentiles		
		25th	50th (Median)	75th
VAI_bez	30	,01153500	,03694000	,06543125
VAI_sa	30	,01408500	,03732250	,06660750

Wilcoxon Signed Ranks Test

Ranks

		N	Mean Rank	Sum of Ranks
VAI_sa - VAI_bez	Negative Ranks	1[a]	2,00	2,00
	Positive Ranks	29[b]	15,97	463,00
	Ties	0[c]		
	Total	30		

a. VAI_sa < VAI_bez

b. VAI_sa > VAI_bez

c. VAI_sa = VAI_bez

Test Statistics[b]

	VAI_sa - VAI_bez
Z	-4,741[a]
Asymp. Sig. (2-tailed)	,000

a. Based on negative ranks.

b. Wilcoxon Signed Ranks Test

NPar Tests

Descriptive Statistics

	N	Percentiles		
		25th	50th (Median)	75th
BGSVAI_bez	30	,11167253	,19890964	,29328401
BGSVAI_sa	30	,11586733	,19071499	,28458908

Wilcoxon Signed Ranks Test

Ranks

		N	Mean Rank	Sum of Ranks
BGSVAI_sa - BGSVAI_bez	Negative Ranks	16[a]	19,00	304,00
	Positive Ranks	14[b]	11,50	161,00
	Ties	0[c]		
	Total	30		

a. BGSVAI_sa < BGSVAI_bez

b. BGSVAI_sa > BGSVAI_bez

c. BGSVAI_sa = BGSVAI_bez

Test Statistics[b]

	BGSVAI_sa - BGSVAI_bez
Z	-1,471[a]
Asymp. Sig. (2-tailed)	,141

a. Based on positive ranks.

b. Wilcoxon Signed Ranks Test

10.10. Adrese korištenih glazbenih video spotova na servisu www.youtube.com

YEAR	VIDEO OF THE YEAR WINNER	SONG	HYPERLINK
1984	The Cars	"You Might Think"	http://www.youtube.com/watch?v=3dOx510kyOs
1985	Don Henley	"The Boys of Summer"	http://www.youtube.com/watch?v=qh4nVj8g4hg
1986	Dire Straits	"Money for Nothing"	http://www.youtube.com/watch?v=wTP2RUD_cL0
1987	Peter Gabriel	"Sledgehammer"	http://www.youtube.com/watch?v=NR6pyJy–MQ
1988	INXS	"Need You Tonight/Mediate"	http://www.youtube.com/watch?v=Mq9mlMnQAVM
1989	Neil Young	"This Note's for You"	http://www.youtube.com/watch?v=KSSvzCNBvIQ
1990	Sinéad O'Connor	"Nothing Compares 2 U"	http://www.youtube.com/watch?v=iUiTQvT0W_0
1991	R.E.M.	"Losing My Religion"	http://www.youtube.com/watch?v=xwtdhWltSIg
1992	Van Halen	"Right Now"	http://www.youtube.com/watch?v=YCcLNmOpN3A
1993	Pearl Jam	"Jeremy"	http://www.youtube.com/watch?v=MS91knuzoOA
1994	Aerosmith	"Cryin'"	http://www.youtube.com/watch?v=qfNmyxV2Ncw
1995	TLC	"Waterfalls"	http://www.youtube.com/watch?v=8WEtxJ4-sh4
1996	The Smashing Pumpkins	"Tonight, Tonight"	http://www.youtube.com/watch?v=NOG3eus4ZSo
1997	Jamiroquai	"Virtual Insanity"	http://www.youtube.com/watch?v=MEyXHTQ_xV8
1998	Madonna	"Ray of Light"	http://www.youtube.com/watch?v=fLkNJYG4b2Q
1999	Lauryn Hill	"Doo Wop (That Thing)"	http://www.youtube.com/watch?v=T6QKqFPRZSA
2000	Eminem	"The Real Slim Shady"	http://www.youtube.com/watch?v=FhdHQ1wGSas
2001	Christina Aguilera, Lil' Kim, Mýa and Pink	"Lady Marmalade"	http://www.youtube.com/watch?v=RQa7SvVCdZk

2002	Eminem	“Without Me”	http://www.youtube.com/watch?v=YVkUvmDQ3HY
2003	Missy Elliott	“Work It”	http://www.youtube.com/watch?v=VsrK3dhbpKw
2004	OutKast	“Hey Ya!”	http://www.youtube.com/watch?v=PWgvGjAhvIw
2005	Green Day	“Boulevard of Broken Dreams”	http://www.youtube.com/watch?v=Soa3gO7tL-c
2006	Panic! at the Disco	“I Write Sins Not Tragedies”	http://www.youtube.com/watch?v=vc6vs-l5dkc
2007	Rihanna (featuring Jay-Z)	„Umbrella“	http://www.youtube.com/watch?v=CvBfHwUxHIk
2008	Britney Spears	“Piece of Me”	http://www.youtube.com/watch?v=KmN_NtMkBbg
2009	Beyoncé	“Single Ladies (Put a Ring on It)”	http://www.youtube.com/watch?v=4m1EFMoRFvY
2010	Lady Gaga	“Bad Romance”	http://www.youtube.com/watch?v=qrO4YZeyl0I
2011	Katy Perry	“Firework”	http://www.youtube.com/watch?v=QGJuMBdaqIw
2012	Rihanna (featuring Calvin Harris)	„We Found Love“	http://www.youtube.com/watch?v=tg00YEETFzg
2013	Justin Timberlake	“Mirrors”	http://www.youtube.com/watch?v=uuZE_IRwLNI

11. Popis objavljenih radova i životopis

Đokić, Kristian; Idlbek, Robert; Jeleč Raguž, Mirjana. Measuring visual activity in a video content based on computer vision temporal median algorithm // The 4th Palestinian International Conference on Computer and Information Technology / Hashem Tamimi (ur.). Hebron : Palestine Polytechnic University, 2015. (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).

Đokić, Kristian. Measurement of Visual Activity in a Video Content Based on Computer Vision Methods of Background Subtraction // Infusing Research and Knowledge in South-East Europe / M. Ntika, E. Kalyva, A. Karamanos, T. Lagkas, P. Patsala, A. Prodromidou, Z. Tatsioka (ur.). Thessaloniki : SEERC Research Centre of the University of Sheffield, 2015. 383-391 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).

Đokić, Kristian; Idlbek, Robert; Marinac, Antun. New Approach of Visual Activity Measuring with Background Subtraction Algorithms // Computer Graphics, Imaging & Visualisation - New Techniques and Trends / Banissi, Ebad ; Sarfraz, Muhammad ; Fakir, Muhammad (ur.). Beni Mellal : Sultan Moulay Sliman University, Beni Mellal, Morocco, 2016. 25-25 (predavanje,međunarodna recenzija, objavljeni rad, znanstveni).

Đokić, Kristian; Idlbek, Robert; Mandušić, Dubravka. Model of information density measuring in e-learning videos // 6th Cyprus International Conference on Educational Research (CYICER-2017). Kyrenia, 2017. 45-45 (predavanje,međunarodna recenzija, objavljeni rad, znanstveni).

Đokić, Kristian; Vesna, Vulić; Measurement of information density in educational material production // Second International Conference on Current Issues of Languages, Dialects and Linguistics, Ahwaz, Iran, 1.-2. February, 2018. (predavanje,međunarodna recenzija, objavljeni rad, znanstveni).

Đokić, Kristian; Blažičević, Marija. Korištenje Moodle dodatka GPS format u nastavi Tjelesne i zdravstvene kulture // . 2015. (predavanje,domaća recenzija,ppt prezentacija,stručni).

Jeleč Raguž, Mirjana; Đokić, Kristian; Radišić, Bojan; Križanec, Elizabeta. Innovativeness of Enterprises According to its Size and Economic Activity: Croatian Case Study // Proceedings of the 65th the IIER International Conference, Moscow, Russia / Suresh, P. (ur.). Bhubaneswar, India : R. K Printers, 2016. 8-13 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).

Đokić, Kristian. Does information density of television programs increase over time?. // Media & Mass Communication. 3 (2014) ; 79-91 (članak, znanstveni)

Potnik Galić, Katarina; Đokić, Kristian; Radišić, Bojan.Primjena Excela u financijskim izračunima. // Računovodstvo revizija i financije. 04.2009. (2009) ; 175-180 (članak, stručni).

Đokić, Kristian.Sustav Moodle. // Časopis za informatiku u poslovanju - infoTrend. 156 (2007) ; 54-56 (članak, stručni).

Đokić, Kristian; Radman-Funarić, Mirjana; Potnik Galić, Katarina. The Relationship between the Cryptocurrency Value (Bitcoin) and Interest for it in the Region // Proceedings of the ENTRENOVA - ENTerprise REsearch InNOVAtion Conference / Maja Baćović, Marin Milković,

Mirjana Pejić Bach, Sanja Peković (ur.).Kotor : IRENET, 2015. 391-398 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).

Blažičević, Marija; Đokić, Kristian. Model primjene geocachinga u nastavi tjelesne i zdravstvene kulture u sustavu visokog obrazovanja // Tehnološki razvoj u funkciji održivog turizma i sporta / dr.sc. Nevenka Breslauer, prof.v.š. (ur.). Čakovec, 2014. 183-189 (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).

Andrlić, Berislav; Budić, Hrvoje; Đokić, Kristian. Research of e-marketing information system in hospitality // Proceedings of International conference "Scientific research and experimental development". Paris : World Academy of Science, Engineering and Technology, 2011. (predavanje,međunarodna recenzija,objavljeni rad,znanstveni).

Đokić, Kristian; Šulc, Domagoj. Održavanje sigurnosti bežičnih mreža // Zbornik radova sa znanstveno stručnog skupa Organizacija i tehnologija održavanja : OTO 2014 / Lacković, Zlatko (ur.). 2014. (predavanje,domaća recenzija,objavljeni rad,stručni).

Đokić, Kristian; Popović, Aleksandar; Đurović, Petra. Pregled Internet servisa za pohranu i prikaz podataka izmjerenih u realnom vremenu // Zbornik radova sa znanstveno stručnog skupa Organizacija i tehnologija održavanja : OTO 2013. (predavanje,domaća recenzija,objavljeni rad,znanstveni).

Đokić, Kristian. Utjecaj jednosmjernog komunikacijskog kanala između obrazovne ustanove i roditelja/staratelja baziranog na SMS porukama na poznavanje ocjena i termina testiranja od strane roditelja/staratelja // Zbornik radova savjetovanja „MIPRO Proceedings". Opatija : MIPRO, 2012. 1699-1704 (poster,međunarodna recenzija,objavljeni rad,stručni).

Đokić, Kristian; Delvechio, Manuel; Adžić, Stjepan. Korištenje GSM mobilnih mreža u strategiji održavanja po stanju sustava // ORGANIZACIJA I TEHNOLOGIJA ODRŽAVANJA 2012 / Lacković, Zlatko (ur.). Županja : Društvo održavatelja Osijek, 2012. 101-106 (predavanje,domaća recenzija,objavljeni rad,stručni).

Đokić, Kristian; Radišić, Bojan; Pišmiš, Vjekoslav. Korištenje SMS usluge mobilne telefonije za distribuciju informacija u odgojno-obrazovnim ustanovama ruralnog područja // Zbornik radova 3nd International Conference "Vallis Aurea" focus on: Regional Development - Proceedings / Katalinić, Branko (ur.). 2012. (poster,međunarodna recenzija,objavljeni rad,stručni).

Đokić, Kristian; Lacković, Krešimir; Miletić, Damir. Implementacija SMS usluge u CRM sustave // Zbornik radova sa znanstveno stručnog skupa Organizacija i tehnologija održavanja : OTO 2010 / Lacković, Zlatko (ur.). Kutina : Društvo održavatelja Osijek, Poljoprivredni fakultet u Osijeku, Petrokemija d.d. Kutina, 2010. 79-91 (predavanje,domaća recenzija,objavljeni rad,znanstveni).

Đokić, Kristian; Radišić, Bojan; Grgić, Ivan. Bežično povezivanje udaljenih lokalnih mreža // 2nd International Conference "Vallis Aurea" focus on: Regional Development - Proceedings / Katalinić, Branko (ur.). Požega : Veleučilište u Požegi, DAAM International Vienna, 2010. 311-315 (predavanje,međunarodna recenzija,objavljeni rad,stručni).

Đokić, Kristian; Radišić, Bojan. Održavanje sigurnosti informacijskih sustava s osvrtom na aktualne prijetnje // Organizacija i tehnologija održavanja OTO 2009.. 2009. 43-50 (predavanje,domaća recenzija,objavljeni rad,stručni).

Đokić, Kristian. Smjernice za razvoj sustava nadzora i kontrole vinograda i procesa proizvodnje vina pod općom javnom licencom // Zbornik radova 1st International Conference "Vallis Aurea“. Požega : Veleučilište u Požegi, 2008. (poster,međunarodna recenzija,objavljeni rad,stručni).

Đokić, Kristian. Sustav za distribuciju ocjena učenika i najava pismenih provjera znanja putem SMS poruka – e- imenik // Zbornik radova savjetovanja „ Računala u obrazovanju“ – MIPRO 2004.. Opatija : MIPRO, 2004. 203-206 (predavanje,međunarodna recenzija,objavljeni rad,stručni).

OSOBNE INFORMACIJE

Đokić Kristian

34000 Požega (Hrvatska)

+38534311466

kdjokic@vup.hr

Skype kristian.djokic.work

Spol Muško | Datum rođenja 1 srpnja 71 | Državljanstvo hrvatsko

RADNO ISKUSTVO

travnja 12 – danas

Viši predavač

Veleučilište u Požegi, Požega (Hrvatska)

-stručni Upravni studij - kolegiji Informatika I i Informatika II

-stručni studij Prehrambena tehnologija - kolegij Osnove informatike

-stručni studij Vinogradar-vinar-voćar - kolegij Primjena računala

-specijalistički studij Trgovinsko poslovanje - kolegiji Elektronička trgovina i Informacijski sustavi potpore odlučivanju

listopada 08 – ožujka 12

Predavač

Veleučilište u Požegi, Požega (Hrvatska)

-stručni Upravni studij - kolegiji Informatika I i Informatika II

-stručni studij Prehrambena tehnologija - kolegij Osnove informatike

-stručni studij Vinogradar-vinar-voćar - kolegij Primjena računala

-specijalistički studij Trgovinsko poslovanje - kolegiji Elektronička trgovina i Informacijski sustavi potpore odlučivanju

rujna 01 – rujna 08

Nastavnik informatike

Osnovna škola Antuna Kanižlića, Požega (Hrvatska)

Predmeti Izborna informatika i Tehnička kultura

rujna 99 – kolovoza 01

Nastavnik informatike

Obrtnička škola, Požega (Hrvatska)

Premet Informatika

OBRAZOVANJE I OSPOSOBLJAVANJE

12 – danas

Doktor znanosti (u tijeku!)

Filozofski fakultet, Zagreb (Hrvatska)

PDS informacijskih i komunikacijskih znanosti

99 – 11

Magistar znanosti

Fakultet organizacije i informatike, Varaždin (Hrvatska)

Poslijediplomski studij Informacijski sustavi

95 – 99 **Diplomirani inženjer prometnih znanosti**

Fakultet prometnih znanosti, Zagreb (Hrvatska)

Telekomunikacijski i poštanski promet

91 – 95 **Inženjer elektrotehnike**

Viša tehnička škola, Zagreb (Hrvatska)

Industrijska elektronika

1986 – 1990 **Prirodoslovno-matematički tehničar**

CUO Zvonko Brkić, Požega (Hrvatska)

OSOBNE VJEŠTINE

Materinski jezik: hrvatski

Ostali jezici

	RAZUMIJEVANJE		GOVOR		PISANJE
	Slušanje	Čitanje	Govorna interakcija	Govorna produkcija	
engleski	B2	B2	B2	B2	B2

Stupnjevi: A1/A2: Početnik - B1/B2: Samostalni korisnik - C1/C2 Iskusni korisnik
Zajednički europski referentni okvir za jezike

Komunikacijske vještine: 2000. Pedagoško-psihološka naobrazba, Pedagoški fakultet, Osijek

Računalne vještine:
2005. Osnovni ECDL program, FINA Slavonski Brod
2006. Napredni ECDL program, ECDL testni centar Linum-Baranja, Osijek
2007. Predavač i ispitivač osnovnog ECDL programa, KING ICT d.o.o., Zagreb
2007. Predavač i ispitivač naprednog ECDL programa, KING ICT d.o.o., Zagreb
2007. CISCO akademija (CCNA), Tehničko veleučilište, Varaždin

Vozačka dozvola: A, A1, B