Filmometrija kratkog filma "Let's Recycle", Swachh Bharat misije

Selec, Hrvoje

Master's thesis / Diplomski rad

2021

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University North / Sveučilište Sjever**

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:122:822257

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

University North Digital Repository

Sveučilište Sjever

Diplomski rad br. 27/ARZO/2021

Filmometrija kratkog filma „Let's Recycle“, Swachh Bharat misije

Hrvoje Selec, 1509/336D

Koprivnica, srpanj 2021. godine

Sveučilište Sjever

Odjel za Ambalažu, recikliranje i zaštitu okoliša

Diplomski rad br. 27/ARZO/2021

Filmometrija kratkog filma „Let's Recycle“, Swachh Bharat misije

Student

Hrvoje Selec, 1509/336D

Mentorica

izv.prof.dr.sc. Lovorka Gotal Dmitrović

Koprivnica, srpanj 2021. godine

Sveučilište Sjever
Sveučilišni centar Koprivnica
Trg dr. Žarka Dolinara 1, HR–48000 Koprivnica

Prijava diplomskog rada

Definiranje teme diplomskog rada i povjerenstva

ODJEL: Odjel za ambalažu, recikliranje i zaštitu okoliša

STUDIJ: diplomski sveučilišni studij Ambalaža, recikliranje i zaštita okoliša

PRISTUPNIK: Hrvoje Selec | MATIČNI BROJ: 1509/336D

DATUM: | KOLEGIJ: Razvoj modela složenih sustava u zaštiti okoliša

NASLOV RADA: Filmometrija kratkog filma "Let's Recycle", Swachh Bharat misije

NASLOV RADA NA ENGL. JEZIKU: Cinemetrics of the short film "Let's Recycle", Swachh Bharat Mission

MENTOR: izv. prof. dr. sc. Lovorka Gotal Dmitrović | ZVANJE: izvanredna profesorica

ČLANOVI POVJERENSTVA:

1. izv. prof. dr. sc. Krunoslav Hajdek - predsjednik povjerenstva
2. izv. prof. dr. sc. Bojan Šarkanj
3. izv. prof. dr. sc. Lovorka Gotal Dmitrović
4. prof. dr. sc. Mario Tomiša - rezervni član
5.

Zadatak diplomskog rada

BROJ: 27/ARZO/2021

OPIS:

U diplomskom radu u teoretskom dijelu opisati važnost filma kao medija, osnove filmometrije, što je, čemu služi i njenu važnost za shvaćanje razvoja filma. Nabrojati glavne metode filmometrije te ukratko opisati njen razvoj.
U eksperimentalnom dijelu razviti konceptualne modela: uzrok-posljedica dijagram (Ishikawa dijagram), dijagram uzročnih petlji i dijagram ciklusa aktivnosti. Navesti glavne karakteristike odabranog filma. Prikazati distribuciju dužine kadrova kroz odabrani film te objasniti zašto je ona takva. Objasniti RGB aditivni model boja te korištenjem aplikacija, izrezati kadrove na pravilni vremenski razmak (dt) i odrediti distribuciju medijana i standardne devijacije za boje:
- crvena (eng. red; heksadecimalna trojka: #FF0000, RGB: 255-0-0)
- zelena (eng. green; heksadecimalna trojka: #00FF00, RGB: 0-255-0) i
- plava (eng. blue; heksidecimalna trojka: #0000FF, RGB: 0-0-255).

Prikazati dobivene rezultate, te objasniti razloge ovakvih distribucija kod kratkog igranog filma vezanog uz zaštitu okolaša.
Donijeti zaključak.

ZADATAK URUČEN: | POTPIS MENTORA:

Predgovor

Prije svega želim zahvaliti svojoj mentorici izv.prof.dr.sc. Lovorki Gotal Dmitrović na podršci i savjetima od samih početaka kada se tema filmometrije tek nazirala nakon edukacije u sklopu Škole medijske kulture „Dr. Ante Peterlić“ održane 2018. godine u Varaždinu. Njena upornost i smirenost uvijek me vraćala u fokus koji ponekad kod mene nije bio prisutan. Veliko hvala na „čvrstim“ živcima i na vjeri u mene koju Ste imali sve ovo vrijeme.

Ovim se putem zahvaljujem članovima Povjerenstva, kao i nastavnicima te kolegama sa Sveučilišta Sjever na podršci tijekom studiranja.

I na kraju, hvala mojoj obitelji i prijateljima, a posebno hvala mojoj baki kojoj ujedno i posvećujem ovaj rad.

Sažetak

Film, kao medij, može prenijeti poruku posredovanjem slike i zvuka. Budući da se film sastoji od niza slika, on je vizualan te je nužno povezan s osjetilom vida, odnosno vizualno je percipiran. Filmometrija, kao način statističke analize kvantitativnih podataka, opisuje strukturu i sadržaj filmova te se traži ponavljajući uzorak (autora, perioda i sl.) koji daje aspekt stila. Parametrizacijom i vizualizacijom filmskih podataka određuju se karakteristike filmova, poput uređivačke strukture, boje, govora ili pokreta, obrađuju se, analiziraju i transformiraju u grafičke prikaze. U ovom radu parametrizacijom dužine kadrova i RGB boja u kratkometražnom filmu „Let's Recycle“ određene su točke tranzicije.

Ključne riječi: *statistika RGB boja, statistika dužine kadrova, točke tranzicije u filmu*

Abstract

Film, as a medium, can convey a message by mediating image and sound. Since the film consists of a series of images, it is visual and is necessarily connected with the sense of sight, i.e. it is visually perceived. Cinemetrics, as a way of statistical analysis of quantitative data, describes the structure and content of the films and repetitive pattern (authors, periods, etc.) which gives the style aspect needs to be found. Parameterization and visualization of film data determine the characteristics of films, such as editorial structure, color, speech or movement, they are processed, analyzed and transformed into graphic representations. In this paper, the transition points are determined by parameterizing the lengths of frames and RGB colors in the short film "Let's Recycle".

Key words: *RGB color statistic, frame length statistic, transition points in the film*

Sadržaj

1. Uvod 5

2. Film 7

2.1. Povijest filma 7

2.2. Kadar 9

2.3. Filmski planovi 10

2.4. Boje u filmu 11

2.5. Filmska industrija 12

2.6. Film kao sustav 14

3. Eksperimentalni dio 17

3.1. Konceptualni modeli 17

3.1.1. Dijagram uzročnih petlji za količinu snimljenih filmova 17

3.1.2. Dijagram ciklusa aktivnosti nastanka filma 18

3.1.3. Dijagram uzrok-posljedica (Ishikawa dijagram) nastanaka filma 19

3.2. Statistika duljine kadrova 21

3.3. Statistika RGB boja 25

3.1.1. Crvena boja 26

3.1.2. Zelena boja 32

3.1.3. Plava boja 38

3.1.4. RGB boje 43

4. Zaključak 44

5. Literatura 46

Popis korištenih kratica

DVD	Digital Versatile Disk
VHS	Video Home System
PAL	Phase Alternating Line
NTSC	National Television System Committee
FX	Special Effects
RGB	Red, Green, Blue

1. Uvod

Sagledavajući filmsku teoriju Ante Peterlića, postoje određeni načini na koje se kroz posredovanje formalnih elemenata oblikovanja, zvukova i tehničkih procesa stvara značenje kod procesa snimanja, odnosno stvaranja filma. Kao rezultat se tako dobiva filmsko djelo, a ono prenosi različita značenja do kojih je gledatelj u mogućnosti doći do određenog mišljenja [1].

Arnheim u svojoj knjizi „Film kao umjetnost“ tvrdi kako je film medij koji ne treba uvijek biti umjetnički, ali s druge strane tvrdi kako nije niti obična mehanička reprodukcija same stvarnosti. Njegov zaključak jest da je film nužno „montaža pojedinačnih sličica“ [2].

Pojam filmometrije *(engl. Cinemetrics)* uveo je 2005. g. Yuri Tsivian, profesor sa Sveučilišta u Chicagu, Odjel za kino i medijske studije, kao istoimene internetske stranice. Međutim, „otac“ statističke analize stilova filma je Barry Salt. On je ručnim mjerenjima dokazao da postoji uzorak koji se ponavlja, ovisno o vremenu nastanka filma, ali i sazrijevanjem pojedinog autora. Film kao medij, već desetljećima nije samo umjetnost, već sadrži jaku tehničku komponentu, a preko filma kao medija jaku društvenu odgovornost. Filmom se prenose informacije te se njime može upravljati javnim mišljenjem.

U svom eseju, Barry Salt, „Statistička analiza stilskih filmova“ (1974), a kasnije u knjizi Filmski stil i tehnologija (1992), Salt opisuje individualni stil redatelja sustavno prikupljajući podatke o formalnim parametrima njihovih filmova. Salt tada predstavlja količinu i učestalost ovih formalnih parametara u stupčastim grafikonima, postocima i prosječnim duljinama okidanja. Kad uspoređuje i suprotstavlja formu filmova različitih redatelja, prelazi u područje stilske analize. Stil u ovom smislu označava skup mjerljivih obrazaca koji značajno odstupaju od kontekstualnih normi. Kao samo jedan primjer, Barry Salt izračunao je da je prosječna duljina filma u 1940-ima oko 9-10 sekundi. Film iz 1940-ih s prosječnom duljinom snimanja od 30 sekundi stoga značajno odstupa od norme i stoga je značajan pokazatelj stila.

Saltova osnovna ideja koja stoji iza njegove analize stilova jest da se filmovi zamjetno razlikuju jedna od drugoga te da bi se varijable korištene u njegovom proučavanju trebale temeljiti na konceptima koje filmaši koriste. Smatra da je najjednostavnije dobiti prosječnu duljinu snimke, odnosno duljina filma podijeljena s brojem snimkama u njemu. Navodi kako je montažni rez u nijemim filmovima brži nego kod ozvučenih filmova. Osim duljine drugu varijablu koju proučava je točka gledišta. Osim toga prati vrste planova. Navedene varijable koje je proučavao su pokazale karakteristične razlike među filmovima iz ranijeg doba kinematografije.

U idealnom slučaju, analizu bi trebalo provesti bilježenjem cjelovitih karakteristika svakog kadra (skaliranje, trajanje pokreta, duljina kadra i dr.) i to uzastopno kroz cijeli film. Smatra kako bi to omogućilo najcjelovitiju analizu svih mogućih međusobnih odnosa između varijabli. Nakon rada na 35 mm filmskoj vrpci, Salt se okrenuo radu s DVD-ima i VHS kasetama. Ubacuje ih u nelinearni sustav za uređivanje i bilježi pokrete kamere na zaslonu programskog alata. Napominje kako je važno kod analitičkog pristupa potrebno uzeti u obzir radi li se o vrpcama ili DVD-ima. Primjerice važno je upotrebljavati snimku napravljenu za televizijski sustav PAL jer ta snimka je snimana brzinom od 24 sličice u sekundi kako je i snimljen izvorni film, no prenosi se na potrošački medij brzinom od 25 sličica u sekundi. To znači da se vrijeme rada uređaja sa sustavom PAL skraćuje za 4% od izvornog vremena. Za NTSC snimke nije potrebno primjenjivati isto. Salt je prvenstveno koristio DVD kopije za analizu uzorka, a provjeru je radio VHS kopijom istog filma [3].

2. Film

Film je medij pohrane kronofotografski analiziranog pokreta koji je raščlanjen na 24 ili 25 statičnih fotograma (slika, sličica) u sekundi. Sinteza se pokreta odvija u postupku projiciranja filma s istom učestalošću kojom je i snimljen. Filmska je tehnologija u osnovi definirana samim izumom i ne zahtijeva bitne razvojne promjene.

2.1. Povijest filma

William Dickson i Thomas Edison su 1893. godine predstavili kinetoskop. Kineskop je mogao u istom trenutku gledati samo jedan gledatelj. Riječ je o kutiji u kojoj se pokretao film, a gledalo ga se virenjem kroz rupicu. Filmovi su u stvari bili samo prizori iz svakodnevnice, trajali su manje od minute, a snimani su na filmsku vrpcu. Krajevi su im bili spojeni, a sam gledatelj je tako promatrao prizor koji se vrtio u petlji.

Na otkriću filma radili su mnogi fotografi i izumitelji. Braća Max i Emil Skladanowsky izumili su „Bioskop“ koji je predstavljao kameru i projektor, a tako su nastale filmove prikazali na velikom platnu u Berlinu. Ipak, mjesec dana kasnije, braća Lumière javno su demonstrirali svoj „Kinematograf“. Prvo filmsko prikazivanje na svijetu održalo se u Grand Cafeu u Parizu 22. ožujka 1895. godine. Naslov prikazivanog filma bio je „Odlazak radnika iz Lumière tvornice“. Jasnoća i tehnika snimljenog crno-bijelog filma koji je trajao svega pedesetak sekundi bio je revolucija. Njihovi su snimatelji krenuli snimati po cijelom svijetu, a ujedno su prikazivali Lumièreove filmove i filmski aparat te snimali prizore iz dalekih krajeva. Tim snimkama počinje povijest filma u mnogim zemljama. Poznati snimatelj braće Lumière, Alexandre Promio je 1898. godine snimio nekoliko jednominutnih filmova u Puli i Šibeniku. Jedan od poznatijih filmova „Pozdrav s jarbola“ prikazuje šibensku luku.

Kako su se ljudi brzo naviknuli na ideju filma, započela je izrada nijemih filmova. U početku je film imao statičnu kameru kojom se dokumentiralo što se dešava ispred nje. Glumci su unaprijed znali u kojim se okvirima smiju kretati i unutar tih okvira su ostali tijekom cijelog filma. U filmu „Rađanje jedne nacije“ nastalom 1915. godine po prvi se puta uvodi montaža.

Prvi zvučni film pod naslovom „Pjevač jazza“ službeno je prikazan 1927. godine u Sjedinjenim Američkim Državama. U filmu su samo dijelovi koji su se odnosili na glazbene točke bili sinkronizirani, a ostali igrani dijelovi bili su proicirani kao i prijašnji filmovi. Prvi hrvatski igrani film pod nazivom „Brcko u Zagrebu“ snimljen je 1917. godine.

Stilska podjela filma je također važna. 60-tih godina prošlog stoljeća za vrijeme realizma redatelj nije imao pretjerani utjecaj na ono što se snimalo pa film nije imao određeni stil već se sastojao od puno dugih kadrova. Istaknuti redatelji tog razdoblja bili su Ford, Hawks, Lang, Kurosawa i Hitchcock.

Pred kraj realizma istaknuti je bio talijanski neorealizam čiji su istaknuti redatelji bili Rosselini i de Sica. Autori su tako svojim filmovima prenosili živote ljudi, porodica i određenih regija, a glavno su obilježje tog razdoblja bili „naturščići". Riječ je o ljudima koji glumili u filmu kako bi što realnije bila prikazana svakodnevnica.

U modernizmu pak dlazi do određene intervencije umjetnika u samom snimanju te se tada počinje koristiti vožnja kamere no dolazi i do skokova u priči. Prvi je tako nastao film „Građanin Kane", a danas se smatra jednim od najvažnijih filmskih ostvarenja. Nosioci modernizma su Bergam, Antonioni i Kubrick. Na vrhuncu modernizma ističe se struja francuskog novog vala, a najistaknutiji je Goddardov film „Do posljednjeg daha".Obilježje modernizma je filmski jezik, a po prvi puta nema naglaska na sadržaju.

Sadašnje razdoblje je razdoblje postmodernizma i ono traje od 70-tih naovamo. Karakteristika postmodernizma je da više nema važnosti ni u sadržaju, a ni u filmskom jeziku. Najznačajniji predstavnicu ovog razdoblja su braća Coen, Lynch i Tarantino. Kuda ide postmodernizam na neki način dočarava film „Kill Bill", koji je ustvari „film u filmu", a pun je citata s mnoštvo referenci, izokrenutih žanrova, gdje se koristi iskustvo prijašnjih filmova.

Od prvih filmu se nastojalo nadodati boju. Na početku su filmske vrpce ble ručno kolorirane, da bi Pathé 1905. godine u Francuskoj pokrenuo tehniku toniranja uz pomoću šablona i maski. Kasnije je pokrenuta proizvodnja pretkoloriranih pozitivskih filmskih vrpci (Agfa i Kodak).

Američki inženjer njemačkog podrijetla Herbert T. Kalmus pokrenuo je 1915. godine u Bostonu istraživanje dvobojnoga filma. To je postupak kombinacije kolor-filtriranja i obojenoga tiska koji se radio na filmskoj vrpci. Kamerom tako prolaze dvije vrpce koje su eksponirane kroz isti objektiv ali kroz crveni i zeleni filter. Taj postupak je kratko korišten jer slika nije bila zadovoljavajuće kvalitete, a boja je kao postupak u filmu neko vrijeme je praktički zaboravljena.

Nakon Kalmusovih daljnjih istraživanja nastaje nova technicolor-metoda s trima negativima u kameri gdje je svaki od njih je bio osjetljiv na drugu boju. Kod razvijanja, osvijetljeni tamni dijelovi slike se ističu te izgledaju poput reljefa.

Reljefi se poslije koriste kao klišeji za određenu boju te se tiskaju na film jedan za drugim te jedan preko drugoga. „Technicolor“ je i danas na neki način najopstojniji kolor-proces ako se gleda trajnost i zasićenost boja. Godine 1939. javlja se „agfacolor“, u to vrijeme uz „tehnicolor“ najcjenjeniji postupak [4].

2.2. Kadar

Kadar kao temeljna jedinica filma višeznačna je odrednica u području fotografije, filmske i elektroničke fotografije u tehnici i praksi, pa tako i u teoriji fotografije, filma i videa. Uz kadar u tehničkom smislu vežu se mnogi tehnički termini poput okvir, okvir kadra, proporcije i omjer, snimka i slično.

Kadar nije samo tehnički određen već je i temeljna jedinica filmskog izraza, sa svim značajkama koje to nosi i za snimatelja, redatelja, montažera, ali i za glumce te ostale sudionike kreiranja kadra, a ujedno je i bitna vizualna odrednica pokretnih slika u sadržajnom i stvaralačkom smislu. Koncipiranjem, snimanjem i montažom kadrova u tehničkom i kreativnom smislu oblikuje se filmsko vrijeme i prostor.

Kompozicija filmskog kadra zbog same prirode medija pokretnih slika svakako je složenija od primjerice kompozicija slika fotografske tehnike i to ne samo zbog mogućnosti mijenjanja vidnog kuta i točke promatranja tijekom snimanja već i zbog vremenske komponente, odnosno trajanja kadra.

Predstavlja temeljnu jedinicu filma, a sastavljen je od manjih jedinica to jest fotograma, odnosno elektroničkih slika/poluslika koje predstavljaju neprekinuti i kontinuirani slikovni vremensko-prostorni niz nekog prizora. Početkom ili prekidom tog niza počinje ili prestaje određeni kadar, bilo da se radi o postupku snimanja ili pak montaže. Kadar se može definirati kao najmanja dinamička jedinica filma, a fotogram kao najmanja statička jedinica filma.

Za gledatelja kadar nema neki izraženi okvir, već rub slike koji graniči s prostorom izvan projekcije. Okvir bi bio granica slike koja je materijalizirana okvirom televizijskog ekrana ili crnim okvirom koji je u pojedinim kinematografima određen bijelim projekcijskim zaslonom. Taj okvir omogućava oštro iscrtani rub slike. Rijetko koji gledatelj će primijetiti neoštrinu na rubu slike, tako da je sam rub svjetlosno prilično neodređen, odnosno nema oštre svjetlosne granice, a ostatak ekrana nije previše zatamnjen [5].

2.3. Filmski planovi

Filmski planovi mogu biti definirani kao omjer veličine ljudske figure u vidnom polju objektiva odnosno širine kadra. Oni značavaju parametar kadra, to jest omjer vizualne prisutnosti primarnog predmeta u izrezu kadra. Kod statičnog kadra je riječ o jednom planu, dok u kadrovima gdje se nalazi kamera ili subjekti te se kreću, tada može biti više planova.

Planovi se dijele na opće (široke) i bliže (uske). Općim se planovima prikazuje prvenstveno prostor to jest geografija prizora i kod njih se prizor događa. Dijele se na:

- **Daleki total** – gdje se ljudska figura ne razlikuje se od drugih subjekata ili objekata u samom kadru,
- **Srednji total ili polutotal** – gdje se ljudska figura razlikuje od drugih subjekata ili objekata u kadru, ali se još se uvijek ne raspoznaje. Koristi se za velike scene,
- **Total** – gdje je ljudska figura još uvijek smještena u prostor i prepoznaje se. Po veličini odgovara prostoru u kazalištu, a i ljudi većinu svog vremena svijet promatraju u "totalima",
- **Američki plan** – gdje sam prostor ne dominira nad ljudskom figurom odnosno gdje su prostor i ljudski element izjednačeni. Koji se koriste u različitim situacijama u kojima se ne želi potencirati subjektivni svijet,
- **Srednji plan -** polubliži, bliži i krupni plan, su planovi gdje u središte dolazi lice. Kod gledatelja stvara osjećaj kako glumac doživljava subjektivne osjećaje,
- **Polubliži plan,**
- **Bliži plan,**
- **Krupni plan,**
- **Detalj** – gdje je određen element izložen iz prostora te je time naglašena njegova uloga u samoj radnji.

Bitni sastojci prizora po dubini unutar kadra također se nazivaju planom. Važno je da se razlikuju prednji plan i stražnji plan odnosno pozadina kadra te dio prizora iza prednjega plana. Kod snimanja navedenih općih planova koriste se širokokutni i normalni objektivi, a rjeđe uskokutni objektivi koji služe za postizanje „zbijenosti" nekog prostora.

2.4. Boje u filmu

Boja u filmu se koristiti kao određeni dodatak estetici filma. Boje prisutne u filmu daleko su od onog što se smatra realističnim bojama, a uključuju asocijacije i objašnjenja na nekoliko razina. Određena boja ima utjecaj na gledatelja ostavljajući mu ugodan ili neugodan osjećaj što stvara fizičku asocijaciju. Psihološka asocijacija pak bojom može potaknuti psihološko stanje samog gledatelja, dok estetska asocijacija boje može biti selektivno odabrana u skladu s učinkom koji se proizvodi ovisno o ravnoteži, proporciji i kompoziciji boje unutar filma [6].

Boja se u filmu može koristiti za manipulaciju kojom se ističe vizualni doživljaj, ali se može koristiti i ekspresivno, zavisi koja se boja koristi te kakva joj je raspoređenost u kadru, a kako bi se njome naglasila dramatičnost. Ona može predstavljati značajan element kod naracije koji se postiže kombiniranjem i kontroliranjem boje u sceni, u ugođaju scene ali i u kostimografiji, a navedeno dovodi do različitih mogućnosti u interpretaciji. Boju na filmu možemo proizvesti na razne načine poput primjerice raznim filterima, osvjetljenjem ili pak korištenjem raznih filmskih traka, ali i laboratorijskom obradom [7].

Boja se ne koristi samo zbog estetike već njima može utjecati na gledateljeve emocije i to na svjesnoj i nesvjesnoj razini. Boja može imati različita značenja i biti korištena na različite načine, što znači da se boja u filmu ne može koristiti na specifično dobar ili loš način, ako ju se opravdano koristi. Važno je znati kako koristiti boju da bi se probudile emocije kod gledatelja, što snimateljima daje mogućnost igre i istraživanja [8].

Postoji simbolika boja, a te osnove simbolike počivaju na subjektivnim tumačenjima koja su opće prihvaćena i priznata. Najčešće ta tumačenja potječu psihofizike doživljaja boja. One mogu mijenjati, ali i objašnjavati autorovo izražavanje prema publici. Tko autor može promijeniti dramaturgiju filma objašnjavanjem ili sugeriranjem nekog duševnog stanja. U filmu boju ne koristimo kao likovno tumačenje već za dramsko ili psihološko [9].

2.5. Filmska industrija

Film možemo promatrati kao proizvod. Proizvođači ulažu novac u stvaranje kako bi u tom procesu ostvarili povrat ulaganja, a dobri su filmovi zapravo arhitektonski zamišljeni. Kako se filmovi stvaraju, odnosno produciraju, na prvi pogled može biti poprilično strano od načina na koji funkcionira klasična industrija.

Filmovi često imaju složeni životni ciklus zbog same distribucije putem raznih kanala, od kina do televizije, od DVD-a do platformi gdje ih gledatelj može vidjeti na zahtjev, ali i na raznim tržištima, vremenskim zonama, formatima, na raznim jezicima itd. Promjenom dionika kroz razne kanale i regulative postoje brojne mogućnosti u podjeli rizika i dobiti kroz promidžbu koja uključuje razne igračke, zatim časopise i knjige, ali i glazbu te ostalu opremu suvremenog marketinga.

Da bi film rezultirao početnim ulaganjima kroz koncept, snimanje, postprodukciju, marketing i distribuciju, u ovoj se industriji zapošljava paleta visoko specijaliziranih tvrtki i pojedinaca, od jedinstvenih timova za specijalne efekte (FX) do primjerice specijaliziranih stolara pa sve do usluga ugostiteljskih djelatnosti. Stoga je već u 30-ima u Sjedinjenim Američkim Državama filmska industrija bila visoko koncentrirana i konkurentna, a njihovo je gospodarstvo tako u praksi implementiralo paušalne obrte te na razne prekvalificiralo radnu snagu za svoje potrebe. Danas njihova filmska produkcija i dalje radi kroz navedenu praksu.

Svaki film usmjeren na zaradu fokusira se na određenu publiku i udovoljava njenim očekivanjima. Producenti u ranim fazama posvećuju veliku pažnju projektu kroz pomna proučavanja uz traženje povratnih informacija od brojnih i različitih suradnika kako bi formulirali „finalni projekt“ prije samog ulaganja resursa u snimanje.

Producentski posao obuhvaća traženje prikladne glumačke ekipe, angažiranost financijera, distribucijske partnere te opsežna istraživanja potencijala i rizika, intelektualna vlasništva i zakonske regulative. Do snimanja dolazi tek kad pretprodukcija postigne jasan i zajednički prikaz vizije projekta koji obuhvaća ciljanu publiku i čimbenike uspjeha te kad su pravilno identificirani potencijalni rizici kako bi ih pravovremeno vrednovali i ublažili.

Nakon navedenih procesa samo snimanje se odvija brzim tempom kroz sinergiju brojnih specijaliziranih suradnika kako bi se izbjegla nepotrebna kašnjenja koja bi dovela do eventualnih financijskih gubitaka. Zbog toga se scene snimaju bez reda, a neki poznatiji, skuplji glumci na sceni će se pojaviti tek nekoliko dana te su zbog toga setovi paralelno pripremljeni.

Cijeli se postupak snimanja mora optimizirati kako bi se obveze snimale na vrijeme i time pod kontrolom držao trošak upravljanja procesom. Dakako zbog neočekivanih promjena na samom snimanju redatelji i producenti su primorani brzoj prilagodbi.

Uz to nije zanemarivo aktivno uključivanje publike tijekom postprodukcije testirajući tako film na manjim fokus skupinama. Tako postprodukcija postaje presudan korak kako bi film bio prilagođen publici u samoj montaži podešavanjem tempa, tona, osjećaja i utjecaja filma, a kako bi se savršeno uklopila glazba, specijalni efekti te ostala brojna izražajna sredstva u svrhu dobivanja cjeline.

Redatelji često snimaju dodatnih nekoliko snimaka scene kako bi se zaštitili od potencijalnih rizika te time istražili alternative i prikupili dopunski materijal za kasniju fazu montaže. Ako je tako sagledan film kao proizvod, važno je do savršenstva dovesti cijeli projekt, od sveopćeg frontalnog istraživanja u fazi pretprodukcije, pa sve do postprodukcije i distribucije, kombinirajući procesno orijentirani način razmišljanja sa slučajnošću i pažljivim promatranjem eventualnih uskih grla koje pokušavaju izbjeći brojni specijalizirani talenti svojim naporima.

Složene projektne sustave često vodi dvojac: voditelj projekta i inženjer sustava dijeleći faktički projekt na dvije različite domene koje se preklapaju – inženjerstvo i upravljanje. Drugim riječima, obojica su inženjeri, a njihove su u vještinama ponašanja i fokusu jer jedan vodi proces dok drugi stvara.

Gledajući film kao složeni proizvod važna je produkcija. Produkciju se u samom procesu dijeli na producenta koji je pokretačka snaga projekta te ima veliko iskustvo u mnogim aspektima stvaranja filma kroz različite pozicije na filmskim ili televizijskim projektima. Zatim producent je odgovoran za sve financijske aspekte filma kroz osiguravanje investitora i sastavljanje financiranja za samu proizvodnju te producent sustava koji je odgovoran za financijske i ugovorne aspekte cijelog ciklusa stvaranja filma.

Izrada filmova se od početka fokusira na pitanje troškova, a ti problemi se ulijevaju u sve procese filmske produkcije, to znači da se troškovi stjecanja određuju relativno u odnosu na troškove i prihode. Upravljanje životnim ciklusom filmova kontinuiran je proces od primjerice tizera koji postupno uvode film na komercijalno tržište distribucije još za vrijeme snimanja, do pažljivo osmišljenih priča o poznatim glumcima te nakon objavljivanja filma same reklame i komercijalna eksploatacija.

Nakon prikazivanja filmski životni ciklus se nastavlja kroz prikazivanje na televizijama te na razne druge načine. Njegov životni ciklus zapravo nikad ne staje, iako neki filmovi padnu u zaborav dok mnogi postaju „klasik“ [10].

2.6. Film kao sustav

Svaki složen inženjerski sustav, prema Magee, C. L., de Weck, O. L. (2002) [11], ima određene glavne karakteristike, a one su:

- Tehnička složenost (složen protok informacija, energije, mase, vrijednosti) i humanističko-društvena složenost (značajan utjecaj organizacijskog čimbenika),
- stvarnost (postoji u fizičkom svijetu),
- izgrađenost od strane ljudi (umjetno napravljen, a ne prirodan),
- otvorenost koja ima jasno definirane granice (razmjena tvari, energije i informacija preko granica sustava),
- dinamičnost u vremenu (sustav ili njegov podsustav je vremenski promjenjiv),
- hibridnost (miješana kontinuirana stanja sustava),
- mješovit sustav kontrole (djelomična ljudska kontrola s autonomnim elementima) i
- dizajniranost za ljudske potrebe.

Znanost o složenosti se bavi sa prirodom nastajanja, učenjem, prilagodbom i inovacijama sustava. Složenost se promatra kroz pogled broja komponenti sustava ili broja njihovih kombinacija, a kako bi se izučavani problem mogao u cijelosti razumjeti i donijeti što bolja odluka. Kod početka istraživanja složenosti, Kolmogorov je definirao stupanj složenosti kao „količinu informacija koje su potrebne za opisivanje sustava“ [12].

Složene, tehničke sustave prvi su klasificirali V. Hubka i W. E. Eder, 1988. godine. Oni su unutar svoje klasifikacije uvrstili funkciju, grane gospodarstva, korištenje proizvoda, vrste operanda, važne fizikalne principe, način proizvodnje, materijale i drugo. Ipak, Hubka klasificira složene tehničke sustave (ΣTS) koji su fokusirani na tehnički sustav, bez utjecaja organizacijskog čimbenika, a definira ih kao interakciju tehničkog procesa (TP) koji pretvara ulaz (ΣOd_1) u izlaz (ΣOd_2). Okoliš ($\sum Env$) i humanističko-društvena komponenta (ΣHu) nisu integrirani u tehnički sustav i tehnički proces, pa tako opisuje pristup koji nije u skladu sa zahtjevima inženjerskih sustava. [13].

Prema B. Edmonds, 1999. „Zašto je sustav složen i u kojoj mjeri“ postavlja jedno je od osnovnih i važnih pitanja u području složenih sustava. Ističe kako ne postoji suglasnost o najboljem načinu mjerenja složenosti [14].

S. Lloyd, 2001. je opisao više od četrdeset različitih definicija složenih sustava te ih grupirao prema pitanjima na koje one pokušavaju odgovoriti (teškoća u opisu ili u stvaranju sustava i stupanj organizacije) [15].

Prema Y. Bar-Yam, 2004. dobre mjere složenosti sustava moraju mjeriti uređenost sustava, a ne njihovu slučajnost *(eng. Randomness)* što bi značilo da entropija sustava mora poprimati vrijednosti za jednostavne sustave, gdje postoji malo dominantnih stanja. Profil složenosti, prema navedenom autoru tako mjeri složenost kao količinu informacija potrebnih za opis sustava kroz funkciju skale na kojoj je sustav promatran [16].

C.L. Magee i O.L. de Weck, 2002, su definirali složene i inženjerske sustave, kao [11]:

- Složen sustav je sustav s brojnim komponentama s međusobnim vezama, interakcijama i međusobnim zavisnostima koje je teško opisati, s njima upravljati, predvidjeti i razumjeti, te ih dizajnirati ili promijeniti.

- Inženjerski sustav je sustav koji su dizajnirali ljudi, a koji ima svrhu i velikih je razmjera ujedno složen od tehničke i humanističko-socijalne komponente, uključujući i upravljanje njime.

Klasifikacija sustava s obzirom na atribute inženjerskih sustava i vrste procesa u njima, temelji se na teoriji sustava. Metode istraživanja u području složenih sustava prema B. Edmonds, 1999. [17], mogu se razvrstati na metode kojima se mjeri složenosti sustava i metode modeliranja složenih sustava i samo upravljanje njime.

U radu C.L. Magee i O.L. de Weck, 2002., prikazuju razliku između inženjerskih i ostalih sustava i njihovu podjelu to jest klasifikaciju. Glavna razlika inženjerskih složenih sustava prema ostalim složenim sustavima je u humanističko-društvenoj komponenti, koja je sastavnica inženjerskih sustava, uz tehničku složenost. Autori navode i nekoliko važnih pitanja te daju odgovore kada je neki složen sustav inženjerski. Pitanja se odnose na [11]:

- područja postojanja, odnosno je li složen sustav samo misaoni ili postoji i u realnom svijetu? **Svi inženjerski sustavi su stvarni, odnosno, imaju stvarne/realne aspekte**.

- podrijetlo, to jest je li složen sustav nastao bez ljudske intervencije ili je njegovo postojanje rezultat namjernog ili slučajnog procesa koji ima humanističku komponentu pri izgradnji i provedbi? **Svi inženjerski sustavi su umjetni i izgrađeni od strane ljudi/društva.**

- granice sustava to jest postoji li razmjena tvari, energije i informacija preko granica sustava? **Svi inženjerski sustavi su otvoreni.**

- ovisnost o vremenu to jest je li sustav vremenski promjenjiv ili ima i vremenski promjenjiv podsustav ili je dio većeg sustava koji je promjenjiv te mijenja svojstva i stanje s vremenom? **Svi inženjerski sustavi su dinamični u vremenu**.

- stanja sustava to jest je li sustav ima kontinuirana stanja ili je sustav diskretan ili hibridan? **Svi inženjerski sustavi su hibridni**.
- uključenost humanističko-društvene komponente odnosno kakav je sustav kontrole rada sustava. Autonomni sustavi ne trebaju operatora ili smjernice za vođenje operacije, dok mješoviti sustavi imaju elemente minimalne ili djelomične ljudske kontrole i autonomnih elemenata. **Svi inženjerski sustavi su mješoviti.**
- ispunjenje ljudskih potreba, jer svrha inženjerstva je ispuniti potrebe ljudi, te su **svi inženjerski sustavi dizajnirani kako bi ispunjavali ljudske potrebe** koje su definirane kao potreba za komunikacijom, sigurnosti, dugovječnosti i zdravljem, skloništem, hranom/vodom, transportom, zabavom, estetskim užitkom, obrazovanjem, socijalnim, emocionalnim, duhovnim životom i znatiželjom. Značajan broj inženjerskih složenih sustava ispunjava višestruke potrebe ljudi.

Kako navedeni autorimi ističu, svi inženjerski složeni sustavi su stvarni, otvoreni, umjetni, dinamični, hibridni (kontinuirano i diskretno upravljanje sustavom), sadrže i tehničku i humanističko-društvenu složenost te imaju mješovitu kontrolu (imaju i autonomne i ljudski kontrolirane elemente ili podsustave).

Film ima sve karakteristike inženjerskog odnosno složenog sustava jer ima tehničku složenost, stvaran je, otvoren, umjetan jer je napravljen od strane ljudi, dinamičan jer može poprimati razna stanja, hibridan jer neki dijelovi nastaju kontinuirano, dok drugi nastaju diskretno i ima mješovitu kontrolu kao podlogu za upravljanje njime. Nastajanjem filma upravlja hijerarhijski složena struktura ljudi, a njegov rad ispunjava višestruku ljudsku potrebu za komunikacijom, obrazovanjem, socijalnim, emocionalnim, duhovnim životom i znatiželjom, ali i zabavom te estetskim užitkom.

3. Eksperimentalni dio

3.1. Konceptualni modeli

Konceptualni modeli su slike kojima se opisuje dio stvarnog svijeta, odnosno objektnog sustava. Konceptualno modeliranje započinje određivanjem specifikacije strukture podataka objektnog sustava kojima se nsatoji približiti struktura samom korisniku. Stvaranje konceptualnog modela se tako radi se temeljem predodžbe o strukturi i logici funkcioniranja sustava koji se modelira.

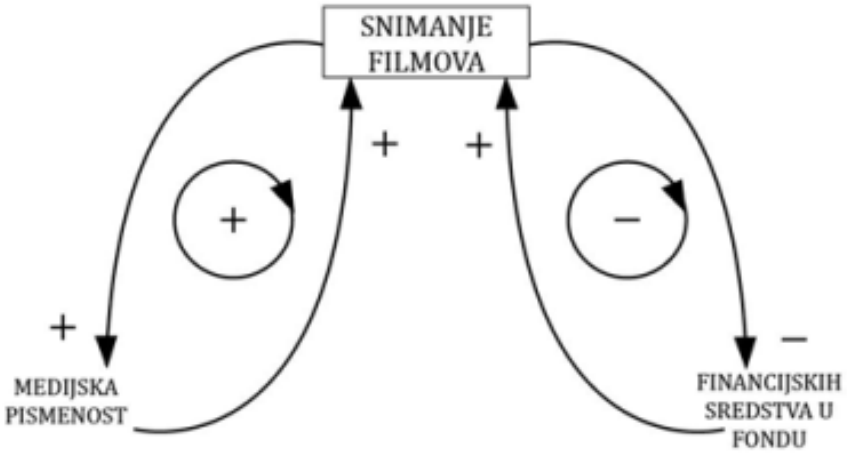
3.1.1. Dijagram uzročnih petlji za količinu snimljenih filmova

Dijagram uzročnih petlji prikazuje uzročno-posljedičnu vezu između elemenata sustava s povratnom vezom. Strelicom se označava smjer veze između uzroka i posljedice.

Ako je strelica označena „+“ tada se uzrok i posljedica mijenjaju u istom smjeru, odnosno radi se o pozitivnoj petlji, a kada je oznaka „-“ uzrok i posljedica se mijenjaju u suprotnom smjeru, pa se radi o negativnoj petlji.

Pozitivnom petljom, nastaje stalni rast ili stalno smanjenje veličine tih elemenata, a time i nestabilno napuštanje ravnotežnog stanja sustava. Negativna povratna veza (polukružna strelica u sredini petlje sa znakom „-“) označava vezu u kojoj elementi petlje uzrokuju promjenu stanja vlastitog djelovanja, a sustav ide prema ravnotežnom stanju.

Ako u petlji ima negativnih veza, tip petlje ovisi o parnosti ukupnog broja negativnih veza. Petlja s parnim brojem negativnih veza je pozitivna povratna petlja, a s neparnim brojem negativnih veza je negativna petlja [18].



Slika 3.1.1. Dijagram uzročnih petlji za količinu snimljenih filmova

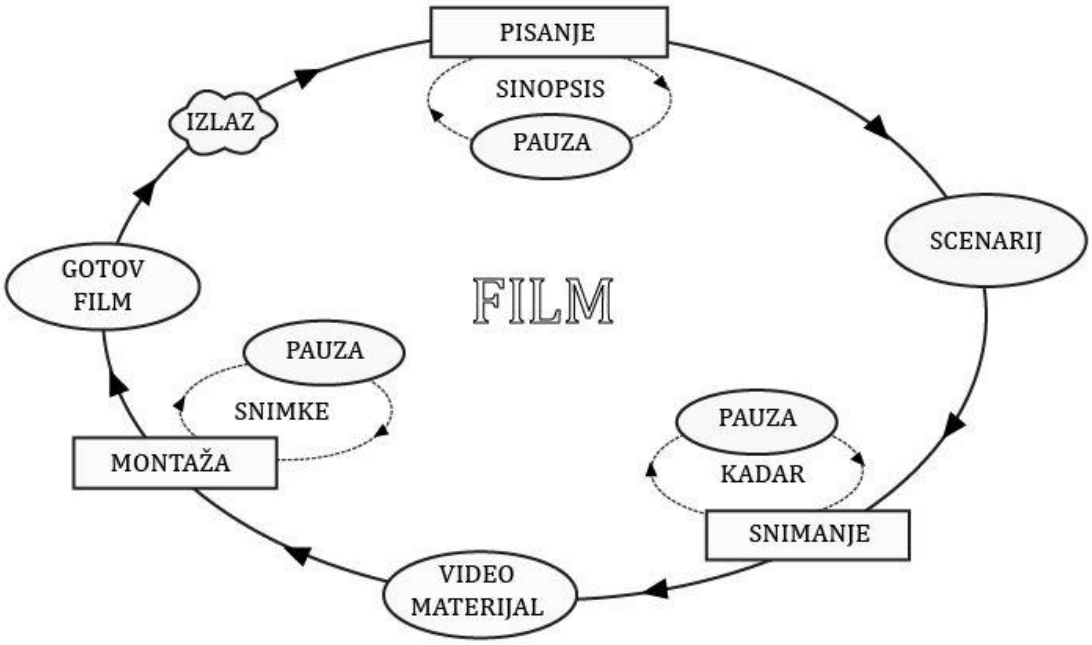
Prema dijagramu uzročnih petlji (Slika 3.1.1.) definirana je negativna petlja između broja snimljenih filmova i financijskih sredstava u fondu te pozitivna petlja između količine filmova i medijske pismenosti.

3.1.2. Dijagram ciklusa aktivnosti nastanka filma

Dijagram ciklusa aktivnosti (DCA) opisuje cilj u ciklusima aktivnosti resursa i entiteta. Takav je model prikladan za probleme koji prikazuju redove čekanja. Prikazuje životni ciklus objekata koji postoje u samom sustavu. On opisuje aktivna i pasivna stanja resursa ili entiteta u sustavu. Većinom šravokutnik predstavlja aktivno stanje resursa ili entiteta, a krug predstavlja pasivno stanje. Luk se koristi za povezivanje aktivnosti i reda.

Aktivnost predstavlja interakciju između resursa i entiteta, a za što obično treba duže vrijeme. Token predstavlja stanje čekanja i aktivnosti. Svi su ciklusi aktivnosti zatvoreni u sebe. Nakon izvođenja jednog događaja prelazi se na događaj koji je sljedeći na redu, a vrijeme simulacije se pomiče na vrijeme izvođenja tog novog događaja.

Prilikom izvođenja novog događaja, događa se i promjena stanja sustava te se mijenjaju atributi jednog ili više entiteta [18]. Dijagram ciklusa aktivnosti koji opisuje nastanak filma prikazan je na slici 3.1.2.



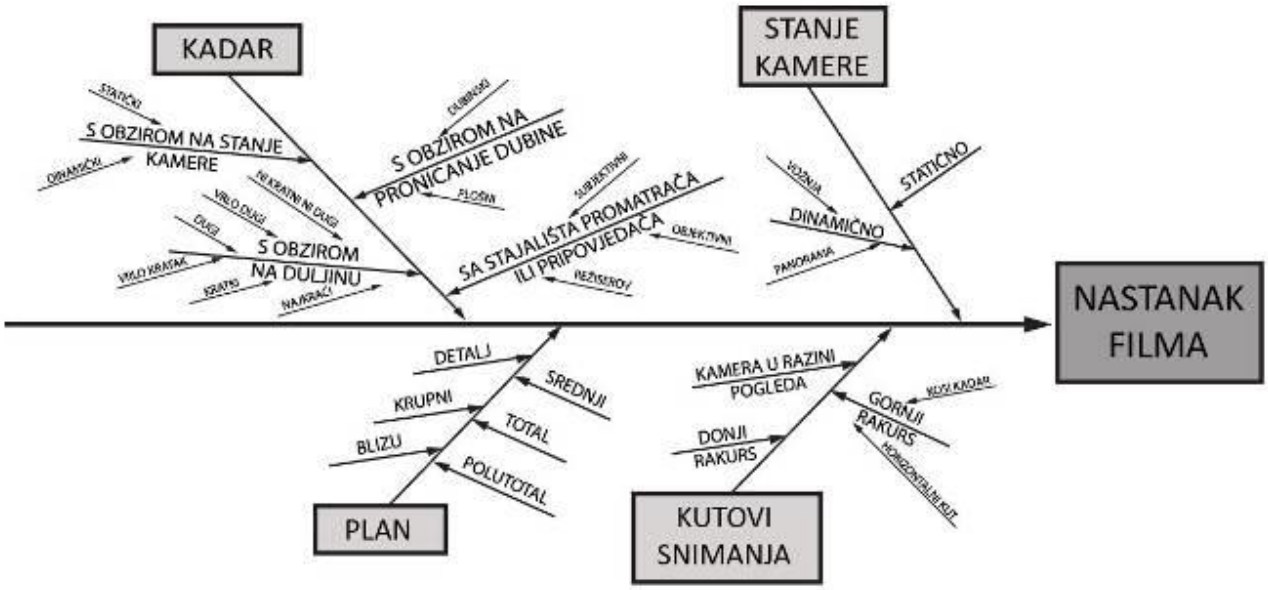
Slika 3.1.2. Dijagram ciklusa aktivnosti nastanka filma

Prema Slici 3.1.2. prvi korak nastanka filma je pisanje što je aktivno stanje, a sinopsis je entitet. Nakon pisanja dobiva se scenarij. Slijedi aktivno stanje snimanja, a entitet je kadar. Dobiven video materijal šalje se na montažu. Montaža je aktivno stanje,a snimke su entitet i nakon toga je gotov film.

3.1.3. Dijagram uzrok-posljedica (Ishikawa dijagram) nastanka filma

Dijagram uzrok-posljedica pomaže u identifikaciji, sortiranju i prikazivanju mogućih uzroka specifičnih problema ili karakteristika kvaliteta. Grafički se tako ilustrira odnos između danog izlaza i svih faktora koji utječu na izlaz.

Dizajniranje dijagrama uzrok-posljedica pomaže kod rješavanja problema to jest poboljšanja kada treba prepoznati moguće uzroke i utvrditi razloge za specifičnu posljedicu ili problem te analizirati postojeće probleme prilikom provođenja korektivnih akcija. Prilikom primjene ovog dijagrama dizajnira se grafički prikaz uzroka organiziranih tako da se pokaže njihov odnos sa specifičnom posljedicom. Dijagram ima uzrok-stranu i posljedica-stranu [18].



Slika 3.1.3. Ishikawa dijagram nastanka filma

Model uzrok-posljedica posljedice nastanka filma (Slika 3.1.3.) ima četiri uzroka:

- kadar,
- stanje kamere,
- plan i
- kutove snimanja.

Kadar ima četiri poduzroka:

- stanje kamere (statički i dinamički),
- pronicanje dubine (dubinski i plošni),
- duljina (najkraći, kratki, vrlo kratki, ni kratki ni dugi, dugi i vrlo dugi) te
- vrsta promatrača (režiserov, subjektivni i objektivni).

Stanje kamere ima dva poduzroka:

- statično stanje i
- dinamično stanje (vožnja i panorama).

Plan ima šest poduzroka kojima se mijenja:

- blizu,
- krupni,
- detalj,
- srednji,
- total i
- polutotal.

Kut snimanja ima tri poduzroka:

- razina pogleda,
- donji rakurs i
- gornji rakurs (kosi kadar i horizontalni kut).

3.2. Statistika duljine kadrova

Statistika dužine kadrova rađena je za kratkometražni igrani film pod nazivom „Let's Recycle“, Swachh Bharat misije. Film je 2016. godine dobio nagradu „MTV Junkyard Film Festivala“ za najbolji kratki film te je pobijedio na „Suchitwa Mission Think Clean“ festivalu. Duljina kadrova prikazana je u tablici 3.2.1.

Tablica 3.2.1. Duljina kadrova

t (min)	Δt (min)
0.01	
0.03	0.02
0.05	0.02
0.10	**0.05**
0.16	**0.06**
0.18	0.02
0.20	0.02
0.22	0.02
0.26	0.04
0.28	0.02
0.30	0.02
0.31	0.01
0.36	0.05
0.38	0.02
0.40	0.02
0.42	0.02
0.44	0.02
0.45	0.01
0.46	0.01
0.47	0.01
0.49	0.02
0.50	0.01
0.52	0.02
0.53	0.01
0.54	0.01
0.57	0.03
0.59	0.02
1.01	0.02
1.03	0.02
1.04	0.01
1.07	0.03
1.10	0.03
1.13	0.03
1.15	0.02
1.20	0.05
1.24	0.04
1.34	0.02
1.35	0.01
1.39	0.04
nastavak na idućoj stranici	

nastavak s prethodne stranice	
1.41	0.02
1.43	0.02
1.48	0.05
1.5	0.02
1.52	0.02
1.59	0.07

Mjerenje je izvršeno ručno, od strane 5 osoba, a svaka osoba mjerila je 3 puta. U tablicu su unesene vrijednosti moda izmjerenih duljina trajanja kadrova (Δt). U tablici 3.2.2. prikazana je deskriptivna (opisna) statistika za vrijednosti Δt.

Tablica 3.2.2. Deskriptivna statistika za vrijednost Δx

aritmetička sredina	0.026222222
standardna devijacija	0.016554166
3σ	0.049662497
3σ+ar.sr.	0.07588472
medijan	0.02
mod	0.02
max	0.08
min	0.01
raspon	0.07
varijanca	0.00027404
koeficijent varijacije	63.13029316

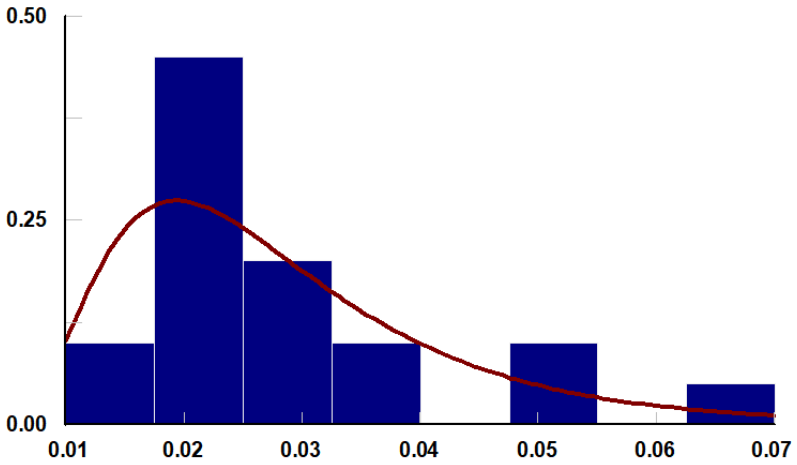
U tablici 3.2.2. vidljivo je da postoji desna ekstremna vrijednost. Primijenjena je metoda „Six sigma“. Six sigma je skup alata i tehnika kojima se proces poboljšava. Pojam potječe iz terminologije koja je povezana sa statističkim modeliranjem proizvodnje procesa [19]. Metodom je uklonjena eksteremna vrijednost.

Korištenjem aplikacije Stat::Fit određena je teorijska distribucija vjerojatnosti koja najbolje opisuje dobivene podatke, a to je inverzna Gaussova distribucija (0, 0.108, 0.0285) (*Slika 3.2.1.)* čija je dobrota podudaranja ispitana Kolmogorov-Smirnov i Anderson-Darling testovima. *(tablica 3.2.3. i slika 3.2.1.)*

Tablica 3.2.3. Dobrota podudaranja ispitana Kolmogorov-Smirnov i Anderson-Darling testovima

	minimum	0
	α	0.107605
	β	0.0285
Kolmogorov-Smirnov test	broj podataka	20
	KS stat.	0.23
	α	0.05
	KS stat. (20, 0.05)	0.294
	p vrijednost	0.205
	rezultat	ne odbija se
Anderson-Darling	broj podataka	20
	AD stat.	0.918
	α	0.05
	AD stat. (0.05)	2.49
	p vrijednost	0.403
	rezultat	ne odbija se

Korištenjem Stat::Fit aplikacije za statistiku kadrova kroz film ponaša prema Inverznoj Gaussovoj distribuciji vjerojatnosti.



Slika 3.2.1.Statistika kadrova ponaša se prema Inverznoj Gaussovoj distribuciji vjerojatnosti

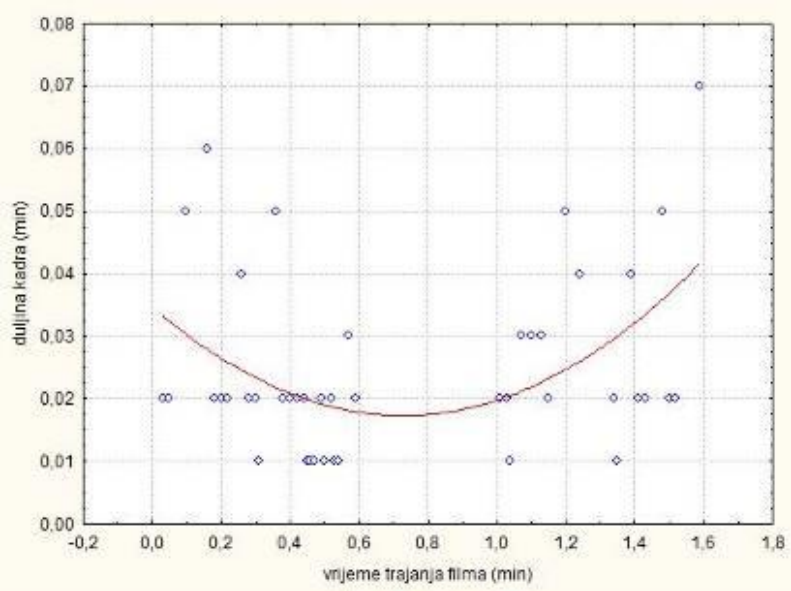
Inverzna Gaussova distribucija je kontinuirana distribucija s granicom na lijevoj strani. Parametri koji ju opisuju su: minimalna vrijednost (min), parametar oblika (α) koji je uvijek veći od 0 i parametar (β). Funkcija (1) koja opisuje inverznu Gaussovu distribuciju je:

$$f(x) = \left(\frac{\alpha}{2\pi(x-min)^3}\right)^{1/2} \exp\left[-\frac{\alpha(x-min-\beta)^2}{2\beta^2(x-\min)}\right] \quad (1)$$

Inverzna Gaussova distribucija ima nekoliko svojstava analognih Gaussovoj distribuciji. Opisuje raspodjelu vremena kojem je Brownovo gibanje s pozitivnim zanosom potrebno da dosegne fiksnu pozitivnu razinu [20].

Korištenjem aplikacije Statistica ispitana je funkcija dužine kadra u ovisnosti od vremena trajanja filma. Funkcija koja je dobivena je kvadratna jednadžba (2):

$$y = 0.0327x^2 - 0.0477x + 0.0346 \tag{2}$$



Slika 3.2.2. Graf statistike duljine kadrova

Ova kvadratna jednadžba (2) nema nul točke. Tjeme grafa funkcije je ujedno i ekstrem kvadratne funkcije *(Slika 3.2.2.):*

$$y = 0.0327x^2 - 0.0477x + 0.0346 \tag{3}$$

$$dy = 2 \cdot 0.0327x dx - 0.0477\, dx \tag{4}$$

$$dy = 0.0654x dx - 0.0477\, dx \tag{5}$$

$$dy = (0.0654x - 0.0477)\, dx \tag{6}$$

$$y' = dy/dx = 0.0654x - 0.0477 \tag{7}$$

Ekstrem funkcije postoji za dy/dx = 0, to jest za:

$$0.0654x - 0.0477 = 0 \tag{8}$$

$$0.0654x = 0.0477 \tag{9}$$

$$x = 0.7294 \tag{10}$$

Ova vrijednost je koordinata tjemena na grafu *(slika 3.2.2.).*

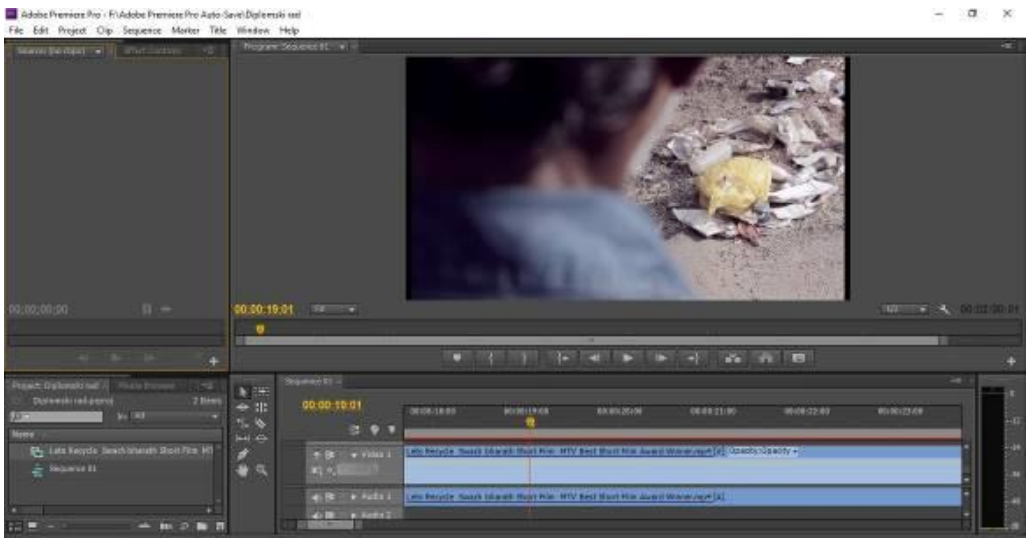
3.3. Statistika RGB boja

Kroz primjer kratkometražnog igranog filma „Let's Recycle“ provedena je statistika RGB boja. Film traje dvije minute, a u programskom alatu Adobe Premiere PRO CS6 korištenom u eksperimentalnu svrhu izvučena je po jedna fotografija svake 2 s filma. Redoslijed fotografija od početka do kraja filma prikazan je na slici 3.3.1.



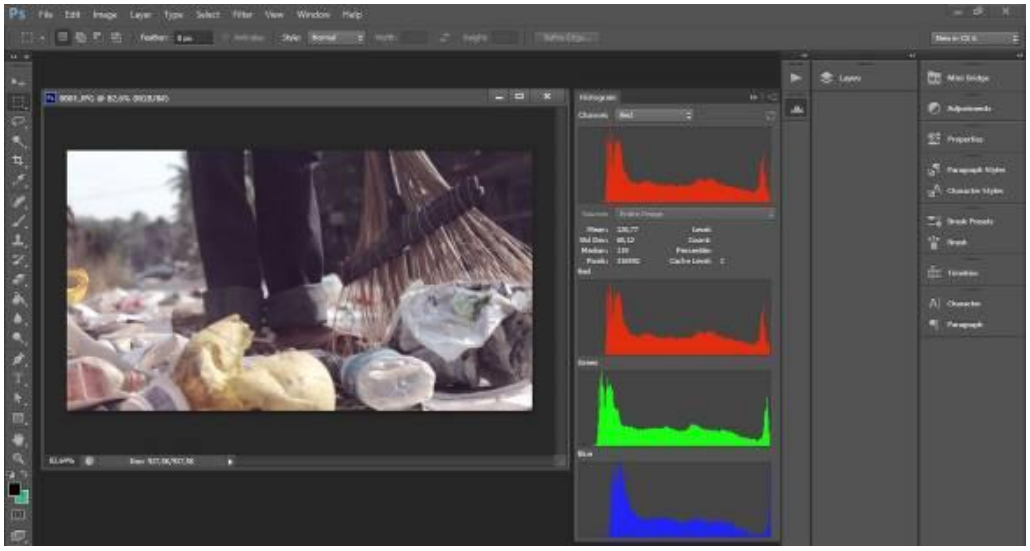
Slika 3.3.1. Fotografije iz filma korištene za statistiku boja

Adobe Premiere PRO CS6 prikazan je na slici 3.3.2.



Slika 3.3.2. Korištenje programskog alata Adobe Premiere CS6

Za dobivanja rezultata korištenja RGB boja fotografije iz filma analizirane su u programskom alatu Adobe Photoshop CS6 (Slika 3.3.3.). Korištenjem opcije histograma očitavane su vrijednosti aritmetička sredina, medijan i standardna devijacija svake boje (crvena, zelena, plava).



Slika 3.3.3. Korištenje programskog alata Adoe Photoshop CS6

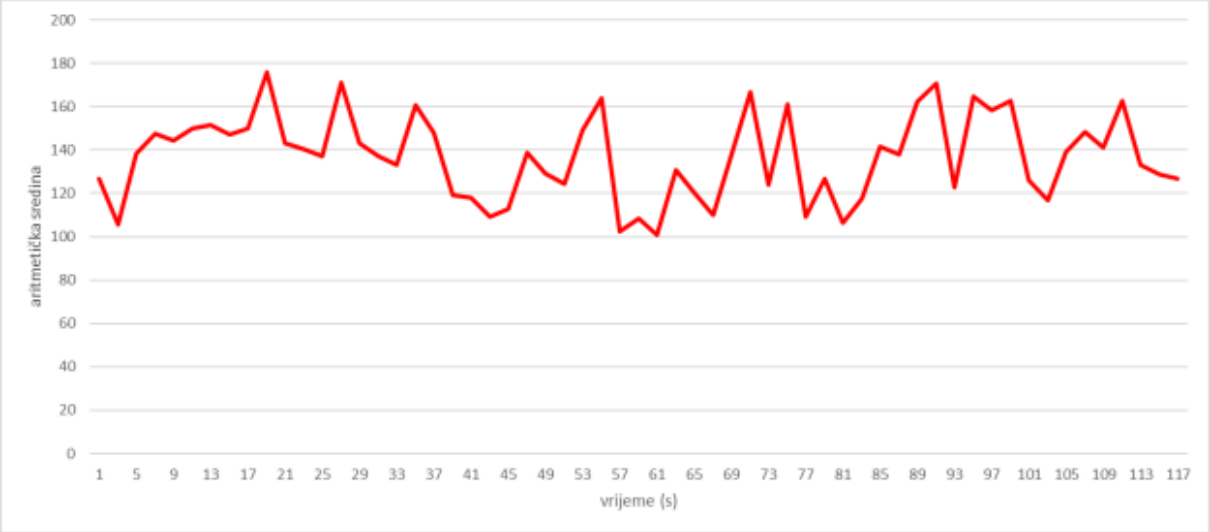
3.3.1. Crvena boja

Crvena boja na ljude utječe fizički ili na „niži red“ njihove psihološke aktivnosti. Pozitivno prenosi fizičku hrabrost, energiju, osnove preživljavanja, snagu toplinu, muževnost i uzbuđenje. Negativna strana crvene je što stvara napetost i agresivnost. Utječe na brzinu pulsa i time stvara dojam bržeg prolaženja vremena [19]. U Tablici 3.3.1. te na slici 3.3.1. i 3.3.2. prikazani su prikupljeni podaci za crvenu boju.

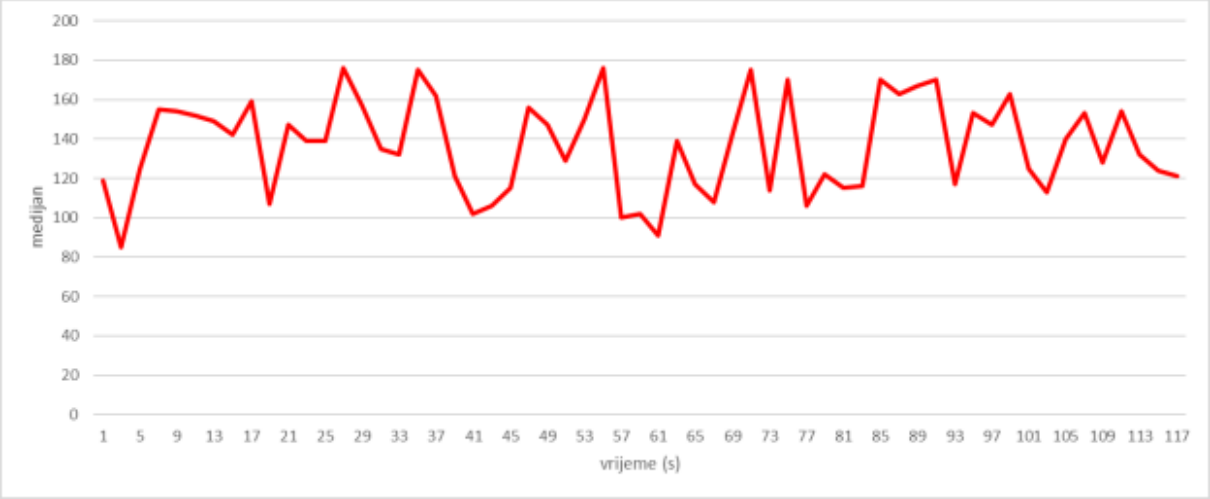
Tablica 3.3.1. Prikupljeni podaci za crvenu boju kadrova

aritmetička sredina	standardna devijacija	medijan
126.77	68.12	119
105.58	58.90	85
138.33	69.63	125
147.47	57.28	155
144.41	61.50	154
149.83	51.60	152
151.53	54.13	149
147.17	56.24	142
149.78	54.02	159
176.00	71.05	107
143.13	61.13	147
140.5	65.44	139
137.21	67.45	139
171.10	28.55	176
143.28	64.27	157
137.05	72.67	135
133.06	67.23	132
160.64	71.52	175
148.06	60.48	162
nastavak na idućoj stranici		

nastavak s prethodne stranice		
119.35	71.57	121
117.83	63.30	102
109.09	38.18	106
112.85	69.08	115
138.8	48.24	156
129.04	59.73	147
124.2	68.89	129
149.29	44.38	150
164.07	44.73	176
102.44	42.83	100
108.26	48.91	102
100.80	45.19	91
130.64	53.01	139
120.45	55.41	117
109.82	49.86	108
137.54	54.67	143
166.72	49.71	175
124.01	36.82	114
161.01	53.79	170
109.25	62.75	106
126.73	78.72	122
106.28	51.7	115
117.59	64.11	116
141.38	56.94	170
137.86	55.64	163
162.45	67.58	167
170.89	67.12	170
122.86	66.34	117
164.80	73.82	153
158.43	74.31	147
162.54	43.99	163
125.92	67.54	125
116.78	60.21	113
139.33	51.94	140
148.53	48.06	153
141.15	77.97	128
162.59	78.1	154
133.26	56.7	132
128.67	56.72	124
126.72	56.78	121

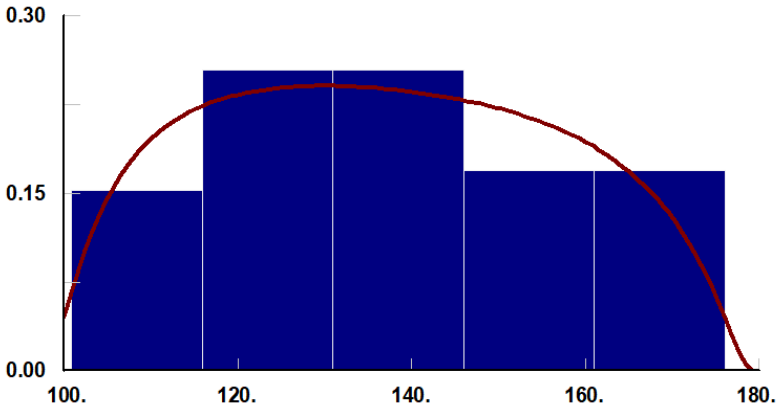


Slika 3.3.1.1. Prikupljeni podaci aritmetičke sredine crvene boje kadrova



Slika 3.3.1.2. Prikupljeni podaci medijana crvene boje kadrova

Korištenjem Stat::Fit aplikacije za aritmetičku sredinu boje u svakom od izuzetih kadrova vidljivo je da se aritmetička sredina crvene boje kroz film ponaša prema Johnson SB distribuciji vjerojatnosti (97.7, 81.5, 0.0841, 0.808) (Slika 3.3.1.3.). Johnson SB distribucija vjerojatnosti opisana je parametrima minimuma x vrijednosti (min), rasponom x iznad minimuma (λ), parametrom iskrivljenosti (γ) i parametrom oblika (δ) > 0.



Slika 3.3.1.3. Aritmetička sredina crvene boje ponaša se prema Johnson SB distribuciji vjerojatnosti

Johnson SB distribucija je kontinuirana distribucija koja ima i gornje i donje konačne granice. Distribucija Johnson SB zajedno sa Log normalnom i Johnson SU distribucijom, transformacije su normalne distribucije i mogu se koristiti za opisivanje najprirodnijih unimodalnih skupova podataka. Johnson SB distribucija vjerojatnosti opisana je funkcijom:

$$f(x) = \frac{\delta}{\sqrt{2\pi}y(1-y)\lambda} exp\left(-\frac{1}{2}\left(\gamma + \delta\, ln\left(\frac{y}{1-y}\right)\right)^2\right) \tag{11}$$

gdje je

$$y = \frac{x-min}{\lambda} \tag{12}$$

U tablici 3.3.2. prikazana je dobrota podudaranja vrijednosti aritmetičke sredine s Johnson SB distribucijom vjerojatnosti ispitanim Kolmogorov-Smirnov i Anderson-Darling testovima.

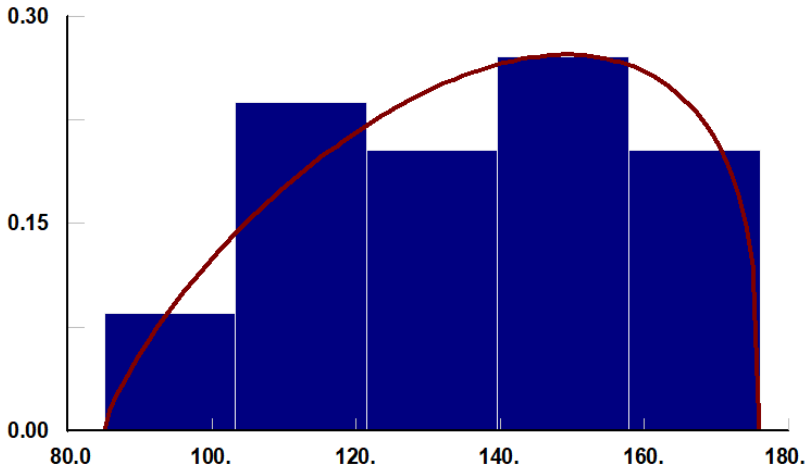
Tablica 3.3.2. Dobrota podudaranja vrijednosti aritmetičke sredine sa Johnson SB distribucijom vjerojatnosti ispitanim Kolmogorov-Smirnov i Anderson-Darling testovima

	minimum	97.7306
	λ	81.4755
	γ	0.0841401
	δ	0.808263
Kolmogorov-Smirnov test	broj podataka	59
	KS stat.	0.0718
	α	0.05
	KS stat. (59, 0.05)	0.174
	p vrijednost	0.9
	rezultat	ne odbija se

nastavak na idućoj stranici

nastavak s prethodne stranice		
Anderson-Darling	broj podataka	59
	AD stat.	0.247
	α	0.05
	AD stat. (0.05)	2.49
	p vrijednost	0.972
	rezultat	ne odbija se

Korištenjem Stat::Fit aplikacije za medijan boje u svakom od izuzetih kadrova dobiveno je da se medijan crvene boje kroz film ponaša prema Beta distribuciji vjerojatnosti (85, 176, 1.77, 1.32) (Slika 3.3.1.4.). Karakteristika Beta distribucije su minimum (min), maksimum (max), parametar donjeg oblika (p), parametar gornjeg oblika (q) i Beta matematičke funkcije B (p,q).



Slika 3.3.1.4. Medijan crvene boje ponaša se prema Beta distribuciji vjerojatnosti

U tablici 3.3.3. prikazana je dobrota podudaranja vrijednosti medijana s Beta distribucijom vjerojatnosti (85, 176, 1.77, 1.32) ispitanim Kolmogorov-Smirnov i Anderson-Darling testovima. Beta distribucijom je kontinuirana distribucija s granicom na lijevoj strani. Funkcija koja ju opisuje je:

$$f(x) = \frac{1}{B(p,q)} \frac{(x-min)^{p-1}(max-x)^{q-1}}{(max-min)^{p+q-1}} \tag{12}$$

Beta distribucija je kontinuirana distribucija koja ima i gornje i donje konačne granice. Budući da se mnoge stvarne situacije mogu ograničiti na ovaj način, Beta distribucija može se empirijski koristiti za procjenu stvarne raspodjele i za mali skup podataka. Kada su vrijednosti p i q > 1 uzrokuju da je Beta distribucija konačna na toj granici.

Tablica 3.3.3. Dobrota podudaranja (fitanja) vrijednosti medijana sa Beta distribucijom vjerojatnosti ispitanim Kolmogorov-Smirnov i Anderson-Darling testovima

	minimum	85
	maksimum	176
	p	1.76806
	q	1.31985
Kolmogorov-Smirnov test	broj podataka	59
	KS stat.	0.0776
	α	0.05
	KS stat. (59, 0.05)	0.174
	p vrijednost	0.842
	rezultat	ne odbija se
Anderson-Darling	broj podataka	56
	AD stat.	0.339
	α	0.05
	AD stat. (0.05)	2.49
	p vrijednost	0.906
	rezultat	ne odbija se

Deskriptivna statistika aritmetičke sredine crvene boje kadrova prikazana je u tablici 3.3.4.

Tablica 3.3.4. Deskriptivna statistika aritmetičke sredine crvene boje kadrova

aritmetička sredina	136.9681
standardna devijacija	19.54931
max	176
min	100.8
medijan	137.86
mod	nema
varijanca	382.1757
koeficijent varijacije	14.27289

U tablici 3.3.4. prikazana je deskriptivna (opisna) statistika aritmetičke sredine crvene boje po vremenu trajanja filma. Aritmetička sredina iznosi 136.97, a medijan aritmetičke sredine crvene boje 137.86. Vidljivo je relativno dobro preklapanje, kao i mali koeficijent varijacije od 14,27%.

Vrijednosti kod koji se uočava veće odstupanje od aritmetičke sredine, primjenjujući metodu 4σ, uočljiv je pik u 19 s filma. U tom trenutku dolazi do točke prijeloma, odnosno do vrhunca zapleta filma. Naročito je to dobro vidljivo na slici 3.3.13. gdje su vidljivi grafički prikazi sve tri boje RGB spektra.

Kvaliteta Four Sigma - Ova razina performansi daje proizvod bez nedostataka u 99,349% slučajeva. U granice 4σ spada 73% vrijednosti kod Gaussove distribucije.

Deskriptivna statistika medijana crvene boje kadrova prikazana je u tablici 3.3.5

Tablica 3.3.5. Deskriptivna statistika medijana crvene boje kadrova

aritmetička sredina	136.7627
standardna devijacija	23.84674
max	176
min	85
medijan	139
mod	147
varijanca	568.6669
koeficijent varijacije	17.43658

Napetost radnje se održava ubacivanje crvene boje. Primjenjujući metodu 2σ na vrijednosti aritmetičkih sredina boje kadrova te medijana boje kadrova uočljivi su kadrovi u kojima i aritmetička sredina ali i medijan izlaze iz zone granice određene metodom 2σ. To se događa u 27 s, 35 s, 55 s, 71 s, 75 s, 89 s, 91 s i 99 s (vidljivo je kao pikovi na grafu na slici 4.3.1.3. i 4.3.1.4.). Crvena u ovo slučaju prenosi osjećaj opasnosti i tragičnosti.

3.3.2. Zelena boja

Zelena boja utječe na ljudsku ravnotežu uma, tijela i emocija. To se postiže harmonijom kroz osjećaj ravnoteže, osvježenja, univerzalne ljubavlji, mira i obnove [19].

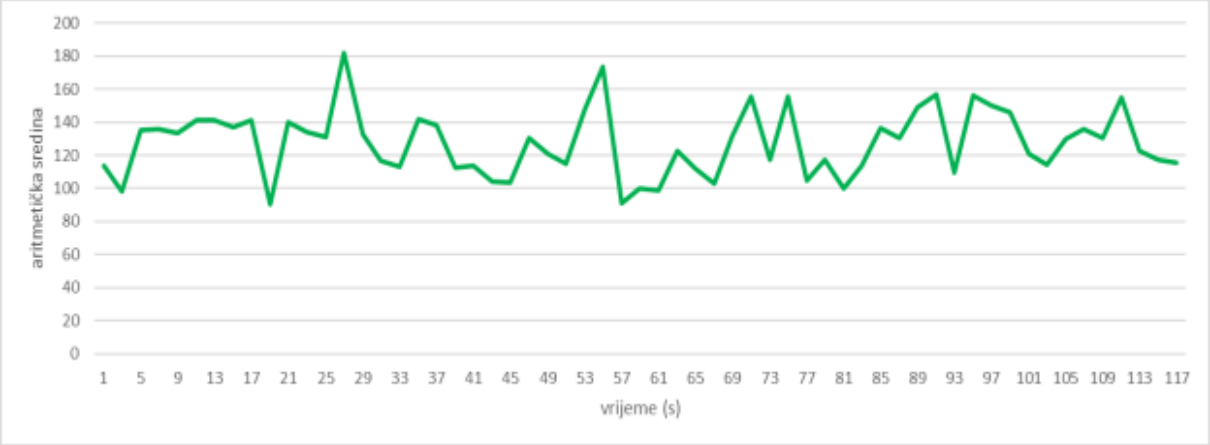
Zelena boja ne traži neko podešavanje u percepciji kada ju čovjek vidi te se time postiže ravnoteža jer se nalazi u sredini spektra. Zelena boja može negativno ukazati na zastoj te ako je koristimo krivo s drugim bojama može ostaviti djam dosade.

U Tablici 3.3.6. i na slikama 3.3.5. i 3.3.6. prikazani su prikupljeni podaci za zelenu boju u kadrovima.

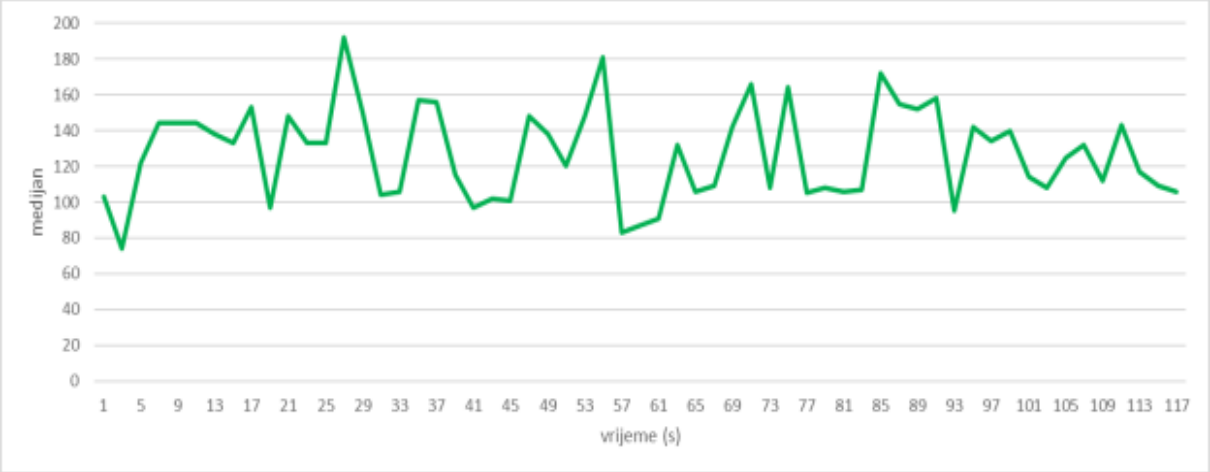
Tablica 3.3.6. Prikupljeni podaci za zelenu boju kadrova

aritmetička sredina	standardna devijacija	medijan
113.94	69.94	103
98.1	63.97	74
135.3	75.18	122
135.6	58.7	144
133.64	62.11	144
141.07	54.43	144
141.18	57.16	138
137.24	59.25	133
140.95	54.75	153
90.59	70.8	97
140.11	63.45	148
134.19	67.71	133
130.79	69.51	133
nastavak na idućoj stranici		

nastavak s prethodne stranice		
182.05	32.55	192
133.05	66.7	150
116.46	76.05	104
113.13	68.69	106
141.98	75.33	157
138.45	64.19	156
112.73	74.15	115
113.87	64.45	97
104.03	39.82	102
103.77	70.37	101
130.43	49.47	148
120.82	60.75	138
114.96	73.07	120
147.55	46.6	148
173.48	38.61	181
90.81	44.01	83
100.23	48.18	87
98.74	50.99	91
122.55	52.19	132
111.65	58.38	106
102.90	51.48	109
131.83	52.27	142
155.50	52.82	166
117.21	36.17	108
155.40	55.33	164
104.93	63.03	105
117.56	80.34	108
99.79	53.00	106
113.91	68.12	107
136.68	58.27	172
130.44	56.35	155
149.11	73.17	152
156.94	70.44	158
109.43	66.59	95
155.99	79.07	142
149.89	78.65	134
145.83	46.69	140
120.65	63.72	114
114.56	59.13	108
129.78	53.26	125
135.60	49.18	132
130.27	82.91	112
155.21	81.93	143
122.41	57.19	117
117.54	57.11	109
115.22	56.99	106

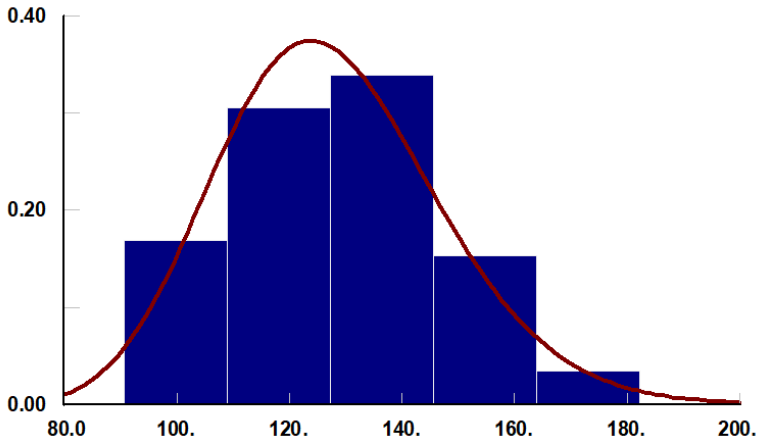


Slika 3.3.1.5. Prikupljeni podaci aritmetičke sredine zelene boje kadrova



Slika 3.3.1.6. Prikupljeni podaci medijana zelene boje kadrova

Korištenjem Stat::Fit aplikacije za aritmetičku sredinu boje u svakom od izuzetih kadrova vidljivo je da se aritmetička sredina zelene boje kroz film ponaša prema Gamma distribuciji vjerojatnosti (18.5, 30.4, 3.58) *(Slika 3.3.1.7.).* Gamma distribucija vjerojatnosti opisana je parametrima minimuma x vrijednosti (min), parametrom oblika (α) i parametrom ljestvice (β).



Slika 3.3.1.7. Aritmetička sredina zelene boje ponaša se prema Gamma distribuciji vjerojatnosti

Gamma raspodjela je kontinuirana raspodjela ograničena na donjoj strani. U slučaju kada je $\alpha > 1$ Gamma distribucija vjerojatnosti je 0 u min x i doseže vrijednost koja ovisi i o α i β te se nakon toga smanjuje monotono. Funkcija koja je opisuje je:

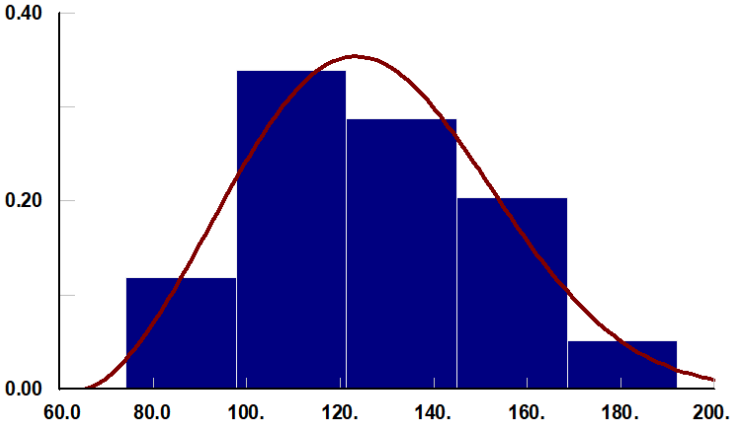
$$f(x) = \frac{(x-min)^{\alpha-1}}{\beta^{\alpha}\Gamma(\alpha)} exp\left(-\frac{[x-min]}{\beta}\right) \quad (13)$$

U tablici 3.3.7. prikazana je dobrota podudaranja vrijednosti aritmetičke sredine s Gamma distribucijom vjerojatnosti ispitanim Kolmogorov-Smirnov i Anderson-Darling testovima.

Tablica 3.3.7. Dobrota podudaranja vrijednosti aritmetičke sredine sa Gamma distribucijom vjerojatnosti ispitanim Kolmogorov-Smirnov i Anderson-Darling testovima

	minimum	18.5045
	α	30.4093
	β	3.5827
Kolmogorov-Smirnov test	broj podataka	59
	KS stat.	0.0958
	α	0.05
	KS stat. (59, 0.05)	0.174
	p vrijednost	0.616
	rezultat	ne odbija se
Anderson-Darling	broj podataka	59
	AD stat.	0.359
	α	0.05
	AD stat. (0.05)	2.49
	p vrijednost	0.888
	rezultat	ne odbija se

Korištenjem Stat::Fit aplikacije za medijan boje u svakom od izuzetih kadrova vidljivo je da se medijan zelene boje kroz film ponaša prema vrijednosti medijana s Weibullovom distribucijom vjerojatnosti (65.3, 2.61, 69.8) *(Slika 3.3.1.8.).* Weibullovom distribucijom je kontinuirana distribucija s granicom na lijevoj strani.



Slika 3.3.1.8. Medijan zelene boje ponaša se prema Weibullovoj distribuciji vjerojatnosti

U tablici 3.3.8. prikazana je dobrota podudaranja vrijednosti medijana s Weibullovom distribucijom vjerojatnosti (65.3, 2.61, 69.8) ispitanim Kolmogorov-Smirnov i Anderson-Darling testovima. Za $\alpha > 1$ Weibullova raspodjela n x iznosi 0.

Tablica 3.3.8. Dobrota podudaranja vrijednosti medijana sa Weibullovom distribucijom vjerojatnosti ispitanim Kolmogorov-Smirnov i Anderson-Darling testovima

	minimum	65.3154
	α	2.61229
	β	69.7953
Kolmogorov-Smirnov test	broj podataka	59
	KS stat.	0.118
	α	0.05
	KS stat. (59, 0.05)	0.174
	p vrijednost	0.355
	rezultat	ne odbija se
Anderson-Darling	broj podataka	59
	AD stat.	0.614
	α	0.05
	AD stat. (0.05)	2.49
	p vrijednost	0.635
	rezultat	ne odbija se

Weibullova distribucija vjerojatnosti doseže vrijednost koja ovisi i o α i o β, a nakon toga se smanjuje monotono. Jedinstvena je po tome jer ima negativnu iskrivljenost kada je α > 3.6 (rep s desne strane. Funkcija koja ju opisuje je:

$$f(x) = \frac{\alpha}{\beta}\left(\frac{x-min}{\beta}\right)^{\alpha-1} exp\left(-\left(\frac{[x-min]}{\beta}\right)^{\alpha}\right) \quad (14)$$

Deskriptivna statistika aritmetičke sredine i medijana zelene boje kadrova prikazana je u tablicama 3.3.9. i 3.3.10.

Tablica 3.3.9. Deskriptivna statistika aritmetičke sredine zelene boje kadrova

aritmetčka sredina	127.4241
standardna devijacija	19.96952
max	182.05
min	90.59
medijan	130.27
mod	135.6
varijanca	398.7818
koeficijent varijacije	15.6717

Tablica 3.3.10. Deskriptivna statistika moda zelene boje kadrova

aritmetička sredina	127.2712
standardna devijacija	25.88025
max	192
min	74
medijan	132
mod	106
varijanca	669.7873
koeficijent varijacije	20.33473

Relativno je dobro podudaranje aritmetičke sredine i medijana za vrijednosti aritmetičke sredine zelene boje kadrova i medijana zelene boje kadrova. Koeficijenti varijacije su mali odnosno nema velikih odstupanja od aritmetičke sredine niti aritmetičke sredine zelene boje kadrova, a niti medijana zelene boje kadrova. Zanimljivo je da se kod zelene boje kadrova pojavljuje dominantna vrijednost i kod aritmetičke sredine, a i kod medijana.

Jako naglašeni pik zelene boje, prema metodi 4σ, i kod aritmetičke sredine i kod medijana, uočljiv je u 27 s i 55 s filma. Zelena boja u ovom slučaju utječe na samu ravnotežu i harmoniju u filmu. Ravnoteža se postiže jer se zelena boja nalazi na sredini spektra.

Pokazuju se emocije glavnog lika koji želi riješiti problem otpada pa ga na neki način iskoristi, oporabi. Djevojčici daje igračku koju je izradio od otpada koji je ona ranije bacila te tu ujedno utječe na nju, mijenja njenu svijest razmišljanja.

Primjenjujući metodu 2σ uočljivi su blaži pikovi, naglašene zelene boje pod kraj filma, odnosno pod kraj raspleta radnje, u 71 s, 75 s i 91 s.

3.3.3. Plava boja

Plava boja utječe na „viši red“ psihološke aktivnosti te time utječe na um čovjeka. Pozitivno utječe na čovjekovu inteligenciju i njegovu sposobnost komunikacije. Daje svojevrsno povjerenje, smirenostii utječe na obaveze, logike i osviještenosti [19]. Negativna strana plave boje je što daje dojam hladnoće, a samim time i manjak emocija, rezerviranost i neljubaznost.

Plava potiče psihološku reakciju, a jake nijanse plave potiću misao. Mekše plave nijanse smiruju um i pomažu kod koncentraciji.

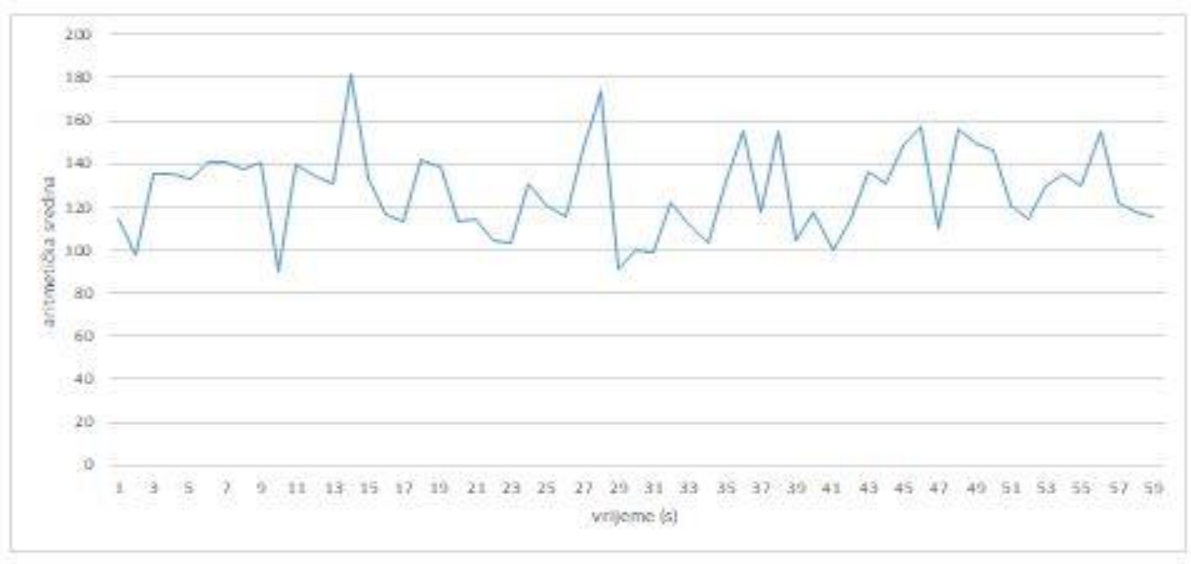
Plava boja ističe jasnu komunikaciju no iako se može shvatiti kao hladna i neprijateljska. Prema istraživanjima plava je najomiljenija boja kod ljudi.

U Tablici 3.3.11. i na slikama 3.3.1.9. i 3.3.1.10. prikazani su prikupljeni podaci za plavu boju po kadrovima filma.

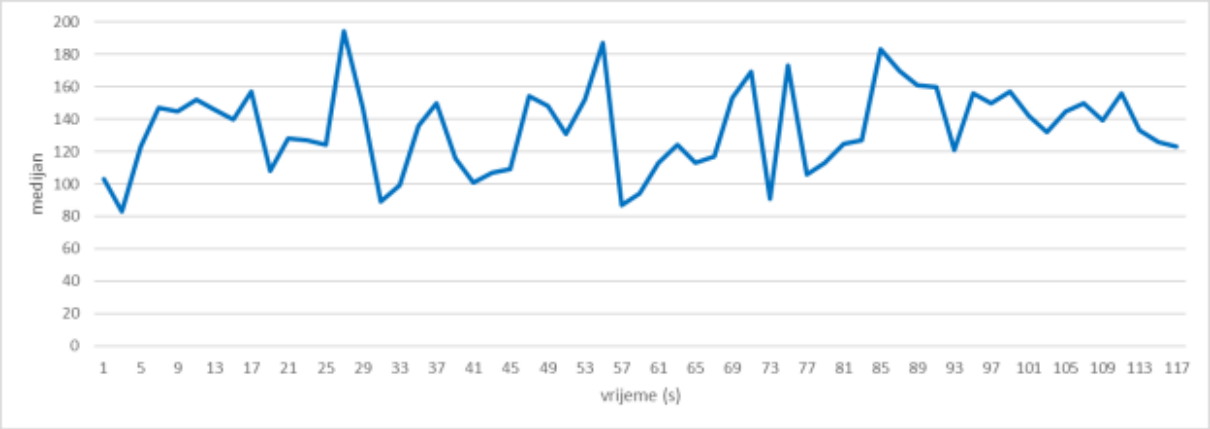
Tablica 3.3.11. Prikupljeni podaci plave boje kadrova

aritmetička sredina	standardna devijacija	medijan
117.67	63.41	103
108.15	60.73	83
144.39	71.32	123
141.67	53.34	147
140.58	55.76	145
150.24	52.99	152
149.33	55.48	146
145.69	56.92	140
149.82	48.69	157
102.43	65.03	108
128.73	61.21	128
133.3	65.89	127
129.83	66.9	124
182.44	36.68	194
136.00	64.32	147
105.65	64.60	89
108.41	56.90	99
133.24	67.54	136
137.94	61.66	150
nastavak na idućoj stranici		

nastavak s prethodne stranice		
115.93	68.93	116
119.80	62.45	101
111.19	40.39	107
111.17	65.87	109
137.19	47.56	154
131.33	59.35	148
126.83	73.41	131
153.45	47.20	152
182.74	35.47	187
95.68	40.44	87
108.55	42.86	94
112.63	58.07	113
124.31	46.66	124
118.98	58.49	113
116.61	52.85	117
142.00	49.18	153
159.02	51.91	169
110.24	42.54	91
163.60	54.29	173
109.83	66.63	106
123.10	79.22	113
118.49	53.71	125
133.21	68.60	127
125.04	59.45	183
145.39	55.82	170
159.51	68.67	161
165.89	65.44	160
129.30	63.42	121
170.94	71.31	156
166.58	70.30	150
165.45	49.43	157
147.15	55.43	142
145.31	52.19	132
152.3	58.12	145
156.59	54.30	150
151.51	76.56	139
168.96	75.07	156
140.32	52.65	133
135.80	52.60	126
133.79	52.44	123

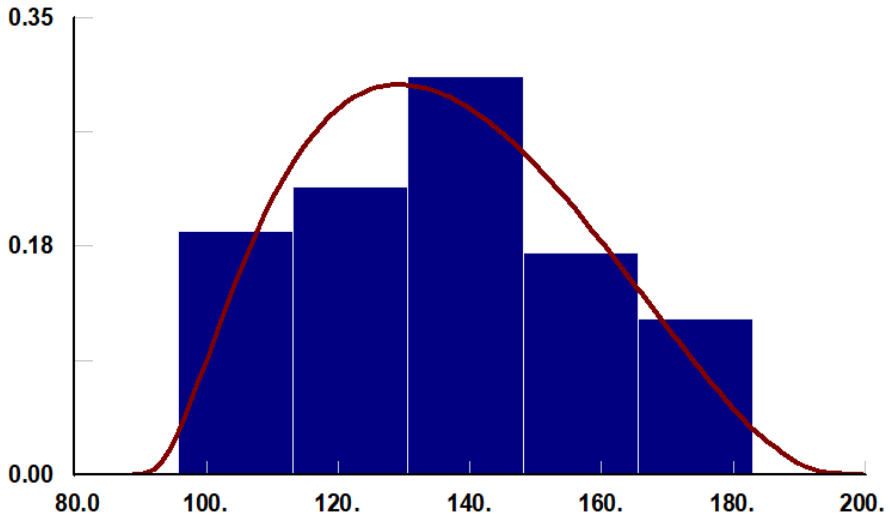


Slika 3.3.1.9. Prikupljeni podaci za aritmetičku sredinu plave boje kadrova



Slika 3.3.1.10. Prikupljeni podaci za medijana plave boje kadrova

Korištenjem Stat::Fit aplikacije za aritmetičku sredinu boje u svakom od izuzetih kadrova vidljivo je da se aritmetička sredina plave boje kroz film ponaša prema Johnson SB distribuciji vjerojatnosti (88.8, 111, 0.391, 1.14) *(Slika 3.3.1.11.).* Johnson SB distribucija vjerojatnosti opisana je u poglavlju 3.3.1. Crvena boja.



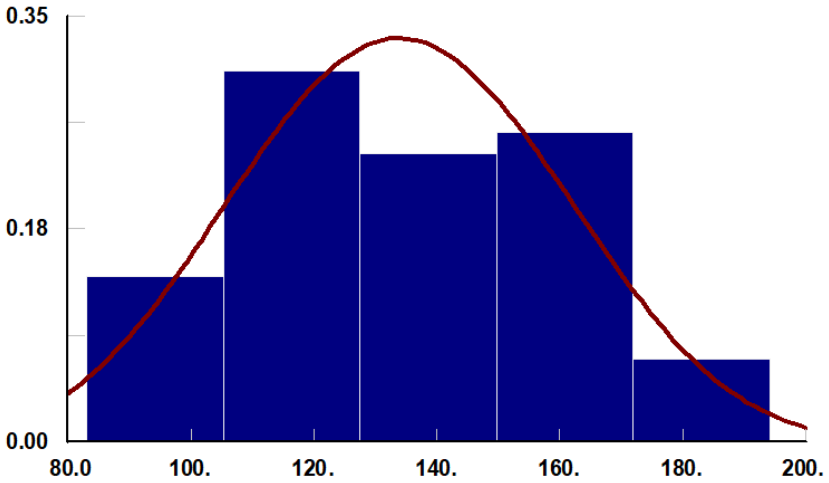
Slika 3.3.1.11. Aritmetička sredina plave boje ponaša se prema ponaša prema Johnson SB distribuciji vjerojatnosti

U tablici 3.3.12. prikazana je dobrota podudaranja vrijednosti aritmetičke sredine s Johnson SB distribucijom vjerojatnosti ispitanim Kolmogorov-Smirnov i Anderson-Darling testovima.

Tablica 3.3.12. Dobrota podudaranja vrijednosti aritmetičke sredine sa Johnson SB distribucijom vjerojatnosti ispitanim Kolmogorov-Smirnov i Anderson-Darling testovima

	minimum	88.8225
	λ	110.858
	γ	0.390787
	δ	1.13715
Kolmogorov-Smirnov test	broj podataka	59
	KS stat.	0.0491
	α	0.05
	KS stat. (59, 0.05)	0.174
	p vrijednost	0.998
	rezultat	ne odbija se
Anderson-Darling	broj podataka	59
	AD stat.	0.16
	α	0.05
	AD stat. (0.05)	2.49
	p vrijednost	0.998
	rezultat	ne odbija se

Korištenjem Stat::Fit aplikacije za medijan boje u svakom od izuzetih kadrova vidljivo je da se medijan plave boje kroz film ponaša prema Johnson SB distribuciji vjerojatnosti (4.8, 262, 0.0627, 2.45) *(Slika 3.3.1.12.).* Johnson SB distribucija vjerojatnosti opisana je u poglavlju 3.3.1. Crvena boja.



Slika 3.3.1.12. Medijan plave boje ponaša se prema ponaša prema Johnson SB distribuciji vjerojatnosti

U tablici 3.3.13. prikazana je dobrota podudaranja vrijednosti medijana s Johnson SB distribucijom vjerojatnosti ispitanim Kolmogorov-Smirnov i Anderson-Darling testovima.

Tablica 3.3.13. Dobrota podudaranja vrijednosti medijana sa Johnson SB distribucijom vjerojatnosti ispitanim Kolmogorov-Smirnov i Anderson-Darling testovima

	minimum	4.80093
	λ	261.534
	γ	0.0626684
	δ	2.44785
Kolmogorov-Smirnov test	broj podataka	59
	KS stat.	0.0852
	α	0.05
	KS stat. (59, 0.05)	0.174
	p vrijednost	0.753
	rezultat	ne odbija se
Anderson-Darling	broj podataka	59
	AD stat.	0.255
	α	0.05
	AD stat. (0.05)	2.49
	p vrijednost	0.968
	rezultat	ne odbija se

Deskriptivna statistika aritmetičke sredine i medijana plave boje kadrova prikazana je u tablicama 3.3.14. i 3.3.15.

Tablica 3.3.14. Deskriptivna statistika aritmetičke sredine plave boje kadrova

aritmetička sredina	136.1224
standardna devijacija	20.89679
max	182.74
min	95.68
medijan	135.8
mod	nema
varijanca	436.6757

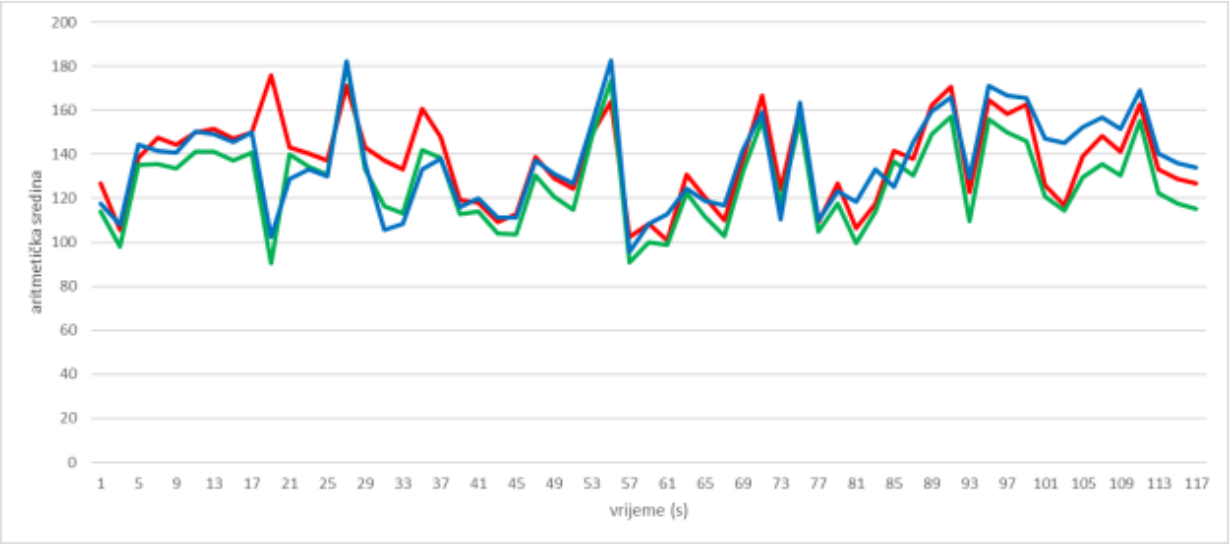
Tablica 3.3.15. Deskriptivna statistika medijana plave boje kadrova

aritmetička sredina	134.102
standardna devijacija	25.8382
max	194
min	83
medijan	133
mod	150
varijanca	667.61

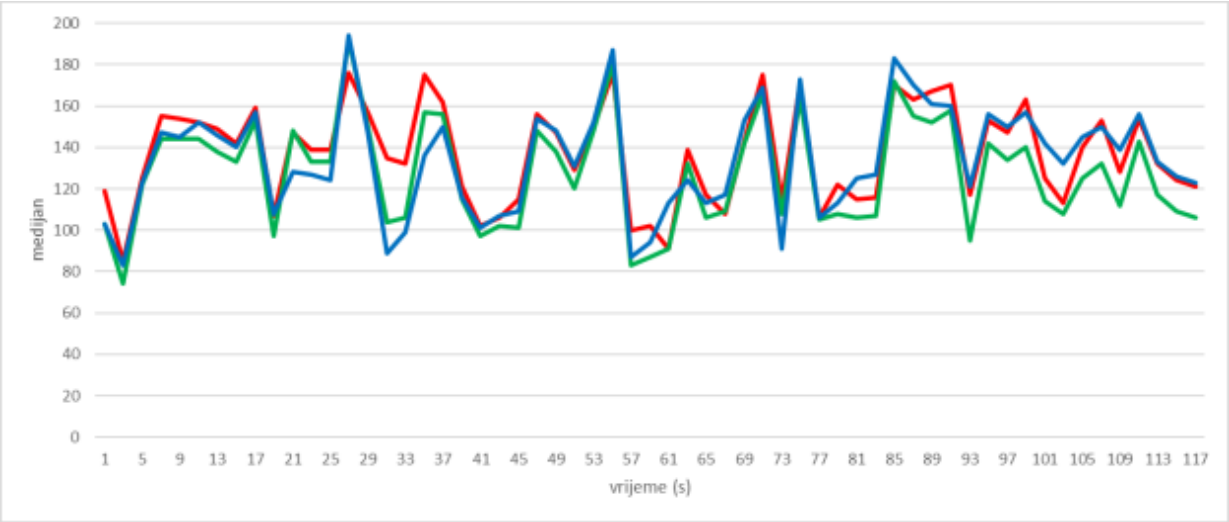
Primjenjujući metodu 4σ naglašeni su plavom bojom kadrovi u 27 s i 55 s filma. Tu možemo vidjeti kako se upravo plavom bojom ističe sposobnost komunikacije, povjerenje, javlja se smirenost i osviještenost. Osim tih „glavnih“ pikova, manji su u 71 s, 75 s, 89 s i 91 s filma.

3.3.4. RGB boje

Na slikama 3.3.1.13. i 3.3.1.14. prikazane su zajedno prikupljeni podaci za sve tri boje RGB spektra.



Slika 3.3.1.13. Prikupljeni podaci aritmetičke sredine boja



Slika 3.3.1.14. Prikupljeni podaci medijana boja

Statistikom boja uočene su točke tranzicije, odnosno prijelaza iz jedne faze u drugu. Na taj način i statistikom boja jasne su granice zapleta, vrhunca i raspleta radnje u filmu. Te točke su točke u kojima se sve tri boje jako ističu.

Crvena je istaknuta radi naglašavanja napetosti, plava radi naglašavanja misaonog procesa i smirenosti, a zelena uspostavlja ravnotežu u čovjekovom umu, tijelu i emocijama.

Točke tranzicije su u trenutku 27 sek. i 55 sek. filma. Može se statistički zaključiti da je do 27 sekunde zaplet, od 27 do 55 sekunde vrhunac, a nakon 55 sekunde rasplet filmske radnje.

4. Zaključak

Film kao umjetničko djelo autori stvaraju da bi prenijeli određena značenja do kojih je sam gledatelj u mogućnosti doći do namjeravanog mišljenja. Duljina kadra je pomno tehnički oblikovana raznovrsnim planovima.

Boja u filmu dodatak je estetici filma, a uključuje asocijacije i objašnjenja na nekoliko razina. Tako boja može utjecati na gledatelje ostavljajući mu ugodan ili neugodan osjećaj.

One mogu biti i selektivno odabrane u skladu s učinkom koji mogu proizvesti ovisno o ravnoteži, proporciji i kompoziciji unutar kadra. Boja se može koristiti za vizualni doživljaj koji manipulira s namjerom, a kako bi se naglasila dramatičnost.

Postiže se značajan element kod naracije kombiniranjem i kontroliranjem boje u sceni. Proizvodi se na razne načine poput korištenja raznih filtera, osvjetljenjem ili korištenjem raznih filmskih traka, ali i laboratorijskom obradom.

Ako film promatramo kao proizvod najvažnija komponenta je njegov životni ciklus zbog same distribucije putem raznih kanala. Da bi film bio uspješan potrebno je pomno planirati parametre ulaganja kroz koncept, pretprodukciju, snimanje, postprodukciju, marketing i distribuciju.

Nakon prikazivanja filmski životni ciklus se nastavlja kroz prikazivanje na televizijama te na razne druge načine. Njegov životni ciklus zapravo nikad ne staje, iako neki filmovi padnu u zaborav dok mnogi postaju „klasik“.

Film ima sve karakteristike složenog, inženjerskog sustava: ima tehničku složenost, stvaran je, otvoren, umjetan (nastao je radom ljudi), dinamičan (može poprimati različita stanja), hibridan (neki dijelovi nastaju kontinuirano, a neki diskretno), i ima mješovitu kontrolu kao podlogu za upravljanje njime. Nastajanjem filma upravlja hijerarhijski složena struktura zaposlenika, a njegov rad ispunjava višestruku ljudsku potrebu: komunikacijom, zabavom, estetskim užitkom, obrazovanjem, socijalnim, emocionalnim, duhovnim životom i znatiželjom (humanističko-društvena složenost).

Otkrivanje, integriranje i analiza ogromnih količina heterogenih podataka, koje se često nazivaju „velikim podacima“, ključna je točka u istraživanju složenih tehničkih sustava. Razvoj informacijskih tehnologija s posebnim naglaskom na istraživačkim metodama prikupljanja i analize podataka te njihovom pohranjivanju i pristupu podacima, značajno su poboljšali metode i njihova izvješća.

Relacijska baza podataka omogućuje korištenje ograničenja i uloga na vrstama podataka koje se može unijeti, što se može koristiti za osiguravanje kvalitete podataka sjajnim multimedijskim pristupom koji se odnosi na odgovarajuću zastupljenost podataka ili sustava na različitim razinama. Stoga su baze podataka ključne za analizu i pripremu meta podataka, kao i modeliranje kako bi se uspostavili konceptualni modeli.

Statistički softverski alati podržavaju mnoge funkcije modeliranja, pružajući dodatnu prednost podrške robusnim proračunima, analizi podataka, osiguranju kvalitete, vizualizaciji i podešavanju podataka. Velike količine podataka često zahtijevaju posebnu pozornost tijekom njihove analize i pročišćavanja, posebno u slučaju značajnog broja nepostojećih podataka.

Velike količine podataka zahtijevaju dubinsku analizu, kao i post hoc analizu, jer velika količina podataka može sadržavati skriveno znanje koje doseže samo dubinskim kopanjem podataka, potrebnim za otkrivanje obrazaca ponašanja promatranih entiteta i medijskog sustava kao cjeline.

Prema statistici kadra i analizi statistike boje može se zaključiti da je prelomni trenutak filma, odnosno vrhunac radnje filma bio u 19 sekundi.

Statistikom boja uočene su točke tranzicije, odnosno prijelaza iz jedne faze u drugu. Na taj način i statistikom boja jasne su granice zapleta, vrhunca i raspleta radnje u filmu.

Tranzicijske točke su točke u kojima se sve tri boje jako ističu. Crvena je istaknuta radi naglašavanja napetosti i agresivnosti, plava radi naglašavanja komunikaciju, povjerenje, obavezu, misaoni proces i smirenost, a zelena uspostavlja obnovu i ravnotežu u čovjekovom umu, tijelu i emocijama.

Točke tranzicije su u trenutku 27 sekunde i 55 sekunde filma. Može se statistički zaključiti da je do 27 sekunde zaplet, od 27 do 55 sekunde vrhunac, a nakon 55 sekunde rasplet radnje filma.

Film kao medij, već desetljećima nije samo umjetnost, već sadrži jaku tehničku komponentu, a preko filma kao medija jaku društvenu odgovornost. Filmom se prenose informacije te se njime može upravljati javnim mišljenjem.

Kroz propagandni film „Let's Recycle" Swachh Bharat misije možemo vidjeti kako upravo filmometrijom, odnosno samim bojama kao i brzinom izmjene kadrova možemo utjecati na publiku. Njihov je glavni cilj bio kroz navedeni film vizualnim elementima nesvjesno skrenuti pozornost upravo na zaštitu okoliša i recikliranje što je primarni cilj njihove misije te određenim bojama utjecati i senzibilizirati samu javnost kako bi prikazali problematiku vezanu uz plastičnu ambalažu kojom se onečišćuje okoliš.

5. Literatura

1 Peterlić, A. (2001.): *Osnove teorije filma*, Hrvatska sveučilišna naklada, Zagreb

2 Arnheim, R. (1957.): *Film as art*, University pf California Press, Berkeley, Los Angeles, London

3 http://www.cinemetrics.lv/salt.php, dostupno 15.05.2021.

4 Mikić, K. (2006.): *Sažeti pregled povijesti svjetskog snimateljstva*, ZAPIS – Bilten, HFS

5 Midžić, E. (2004.): *O slici pokretnih slika / Kadar i stanje kamere*, Areagrafika. Zagreb

6 Mikić, K. (2008.): *Svjetlo i boja u filmu*, ZAPIS – Bilten, HFS

7 Hollander, A. (1989.): *Moving Pictures*, Albert A. Knopf inc., New York

8 Šurina, M. (2019.): *Utjecaj boje u filmu na promatrača*, diplomski rad, UAOS, Osijek

9 Mitry, J. (1965.): *Estetika i osihologija filma*, II. Los formes Editions Universitaires, Pariz

10 Luzeaux, D., Morlaye, T., Wippler, J. (2014.): *If We Engineerd Systems Like We Produce Movies*, Proceedings of the Fifth Int. Conf. on Complex Systems Design & Management

11 Magee, C. L., de Weck O. L.: *An Attempt at Complex System Classification*, ESD Internal
Symposium, MIT 2002, http://esd.mit.edu/WPS/ESD Internal Symposium Docs/ESD-WP-2003-01.02-ESD Internal Symposium.pdf, downloaded: 29.10.2013.

12 Kolmogorov, A. N., (1983.): Combinatorial Foundations of Information Theory and the Calculus of Probability, Russian Mathematical Surveys, 38, pp 29-40

13 Hubka, V., Eder, W. E. (1988.): *Theory of Technical Systems*, Springer-Verlag, Berlin

14 Edmonds, B. (1999.): *What is Complexity?: The philosophy of Complexity per se with application to some examples in evolution*, F. Heylighen & D. Aerts (eds.): The Evolution of Complexity, Kluwer, Dordrecht, 1-18. (http://bruce.edmonds.name/evolcomp)

15 Lloyd, S. (2001.): *Measures of Complexity: A nonexhaustive list*, IEEE Control Syst. Mag., 21,7-8

16 Bar-Yam, Y. (2004.): *Multiscale complexity/entropy*, Advances in Complex Systems, 7, 47-63

17 Gotal Dmitrović, L., Dušak, V., Milković, M. (2017.): *Modeliranje informacijskih sustava za zaštitu površinskih voda*, Sveučilište Sjever, Varaždin

18 Johnsn, N. L., Kotz, S., Balahrishnan, N. (1994.): *Continuous Univariate Distributions*, Volume 1", John Wiley & Sons

19 Banks, J., Carson II, J. S. (1984.): *Discrete-Event System Simulation*, Prentice-Hall

20 Wright, A., Murphy, D. (2009.): *The Colour Affects System of Colour Psychology*, Colour Affects, London, UK

Popis slika

Slika 3.1.1. Dijagram uzročnih petlji za količinu snimljenih filmova

Slika 3.1.2. Dijagram ciklusa aktivnosti nastanka filma

Slika 3.1.3. Ishikawa dijagram nastanka filma

Slika 3.2.1. Statistika kadrova ponaša se prema Inverznoj Gaussovoj distribuciji vjerojatnosti

Slika 3.2.2. Graf statistike kadrova

Slika 3.3.1. Fotografije iz filma korištene za statistiku boja

Slika 3.3.2. Korištenje programskog alata Adobe Premiere CS6

Slika 3.3.3. Korištenje programskog alata Adobe Photoshop CS6

Slika 3.3.1.1. Aritmetička sredina srvene boje ponaša se prema Johnson SB distribuciji vjerojatnosti

Slika 3.3.1.2. Medijan crvene boje ponaša se prema Beta distribuciji vjerojatnosti

Slika 3.3.1.3. Graf aritmetičke sredine crvene boje kadrova

Slika 3.3.1.4. Graf medijana crvene boje kadrova

Slika 3.3.1.5. Aritmetička sredina zelene boje ponaša se prema Gamma distribuciji vjerojatnosti

Slika 3.3.1.6. Medijan zelene boje ponaša se prema Weibullovoj distribuciji vjerojatnosti

Slika 3.3.1.7. Graf aritmetičke sredine zelene boje kadrova

Slika 3.3.1.8. Graf medijana zelene boje kadrova

Slika 3.3.1.9. Aritmetička sredina plave boje ponaša se prema ponaša prema Johnson SB distribuciji vjerojatnosti

Slika 3.3.1.10. Medijan plave boje ponaša se prema ponaša prema Johnson SB distribuciji vjerojatnosti

Slika 3.3.1.11. Graf aritmetičke sredine plave boje kadrova

Slika 3.3.1.12. Graf medijana plave boje kadrova

Slika 3.3.1.13. Graf aritmetičke sredine boja

Slika 3.3.1.14. Graf medijana boja

Popis tablica

Tablica 3.2.1. Trajanje kadrova

Tablica 3.2.2. Deskriptivna statistika za vrijednost Δx

Tablica 3.2.3. Dobrota podudaranja (fitanja) ispitana Kolmogorov-Smirnov i Anderson-Darling testovima

Tablica 3.3.1. Deskriptivna statistika crvene boje kadrova

Tablica 3.3.2. Dobrota podudaranja (fitanja) vrijednosti aritmetičke sredine sa Johnson SB distribucijom vjerojatnosti ispitanim Kolmogorov-Smirnov i Anderson-Darling testovima

Tablica 3.3.3. Dobrota podudaranja (fitanja) vrijednosti medijana sa Beta distribucijom vjerojatnosti ispitanim Kolmogorov-Smirnov i Anderson-Darling testovima

Tablica 3.3.4. Deskriptivna statistika aritmetičke sredine crvene boje kadrova

Tablica 3.3.5. Deskriptivna statistika medijana crvene boje kadrova

Tablica 3.3.6. Deskriptivna statistika zelene boje kadrova

Tablica 3.3.7. Dobrota podudaranja (fitanja) vrijednosti aritmetičke sredine sa Gamma distribucijom vjerojatnosti ispitanim Kolmogorov-Smirnov i Anderson-Darling testovima

Tablica 3.3.8. Dobrota podudaranja (fitanja) vrijednosti medijana sa Weibullovom distribucijom vjerojatnosti ispitanim Kolmogorov-Smirnov i Anderson-Darling testovima

Tablica 3.3.9. Deskriptivna statistika aritmetičke sredine zelene boje kadrova

Tablica 3.3.10. Deskriptivna statistika moda zelene boje kadrova

Tablica 3.3.11. Deskriptivna statistika plave boje kadrova

Tablica 3.3.12. Dobrota podudaranja (fitanja) vrijednosti aritmetičke sredine sa Johnson SB distribucijom vjerojatnosti ispitanim Kolmogorov-Smirnov i Anderson-Darling testovima

Tablica 3.3.13. Dobrota podudaranja (fitanja) vrijednosti medijana sa Johnson SB distribucijom vjerojatnosti ispitanim Kolmogorov-Smirnov i Anderson-Darling testovima

Tablica 3.3.14. Deskriptivna statistika aritmetičke sredine plave boje kadrova

Tablica 3.3.15. Deskriptivna statistika medijana plave boje kadrova

Prilog

Film „Let's Recycle“ se nalazni na poveznici: https://www.mojoplex.in/watch/Premiers-Short-Films/Lets-Recycle-Swach-bharath-Short-Film-MTV-Best-Short-Film-Award-Winner/AV000116

91 matches from 9 sources, of which 8 are online sources.

PlagLevel: **7.6%**/9.8%

- [0] (54 matches, **6.3%**/7.6%) from repozitorij.foi.unizg.hr/islandora/object/foi:530/datastream/PDF/download
- [1] (9 matches, **0.6%**/0.9%) from a PlagScan document of your organisation... Luka Meglic.docx" dated 2021-08-24
- [2] (7 matches, **0.7%**/0.8%) from zir.nsk.hr/en/islandora/object/unin:1507/datastream/PDF/view
- [3] (7 matches, **0.1%**/0.4%) from www.hfs.hr/nakladnistvo_zapis_detail.aspx?sif_clanci=1598
- [4] (2 matches, **0.3%**/0.3%) from repozitorij.unios.hr/islandora/object/aukos:147/datastream/PDF/view
- [5] (5 matches, **0.1%**/0.3%) from core.ac.uk/download/pdf/197856375.pdf
  (+ 1 documents with identical matches)
- [7] (1 matches, **0.1%**) from bs.wikipedia.org/wiki/Šest_sigma
  (+ 1 documents with identical matches)

Settings

Sensitivity: *Low*
Bibliography: *Bibliography excluded*
Citation detection: *No detection*
Whitelist: --

Analyzed document

==========1/55==========

Diplomski rad br. 27/ARZO/2021
Filmometrija kratkog filma „Let's Recycle“, Swachh Bharat misije
Hrvoje Selec, 1509/336D
Koprivnica, srpanj 2021. godine
==========2/55==========

==========3/55==========

Odjel za Ambalažu, recikliranje i zaštitu okoliša
Diplomski rad br. 27/ARZO/2021
Filmometrija kratkog filma „Let's Recycle“, Swachh Bharat misije

Student

Hrvoje Selec, 1509/336D

Mentorica

izv.prof.dr.sc. Lovorka Gotal Dmitrović

Sveučilište
Sjever

SVEUČILIŠTE
SJEVER

IZJAVA O AUTORSTVU
I
SUGLASNOST ZA JAVNU OBJAVU

Završni/diplomski rad isključivo je autorsko djelo studenta koji je isti izradio te student odgovara za istinitost, izvornost i ispravnost teksta rada. U radu se ne smiju koristiti dijelovi tuđih radova (knjiga, članaka, doktorskih disertacija, magistarskih radova, izvora s interneta, i drugih izvora) bez navođenja izvora i autora navedenih radova. Svi dijelovi tuđih radova moraju biti pravilno navedeni i citirani. Dijelovi tuđih radova koji nisu pravilno citirani, smatraju se plagijatom, odnosno nezakonitim prisvajanjem tuđeg znanstvenog ili stručnoga rada. Sukladno navedenom studenti su dužni potpisati izjavu o autorstvu rada.

Ja, HRVOJE SELEC *(ime i prezime)* pod punom moralnom, materijalnom i kaznenom odgovornošću, izjavljujem da sam isključivi autor/ica završnog/diplomskog (*obrisati nepotrebno*) rada pod naslovom FILMOMETRIJA KRATKOG FILMA "LETS RECYCLE", SWACHH BHARAT MISIJE *(upisati naslov)* te da u navedenom radu nisu na nedozvoljeni način (bez pravilnog citiranja) korišteni dijelovi tuđih radova.

Student/ica:
(upisati ime i prezime)

(vlastoručni potpis)

Sukladno Zakonu o znanstvenoj djelatnost i visokom obrazovanju završne/diplomske radove sveučilišta su dužna trajno objaviti na javnoj internetskoj bazi sveučilišne knjižnice u sastavu sveučilišta te kopirati u javnu internetsku bazu završnih/diplomskih radova Nacionalne i sveučilišne knjižnice. Završni radovi istovrsnih umjetničkih studija koji se realiziraju kroz umjetnička ostvarenja objavljuju se na odgovarajući način.

Ja, HRVOJE SELEC *(ime i prezime)* neopozivo izjavljujem da sam suglasan/na s javnom objavom završnog/diplomskog (*obrisati nepotrebno*) rada pod naslovom FILMOMETRIJA KRATKOG FILMA "LETS RECYCLE", SWACHH BHARAT MISIJE *(upisati naslov)* čiji sam autor/ica.

Student/ica:
(upisati ime i prezime)

(vlastoručni potpis)