

UNIVERZITET U BEOGRADU

ELEKTROTEHNIČKI FAKULTET

Aleksandra S. Pavlović

**DETEKCIJA NAMERNO IZAZVANIH  
PROMENA U SADRŽAJU SLIKE**

doktorska disertacija

Beograd, 2019.

UNIVERSITY OF BELGRADE  
SCHOOL OF ELECTRICAL ENGINEERING

Aleksandra S. Pavlović

**DETECTION OF INTENTIONALLY MADE  
CHANGES IN IMAGE CONTENT**

Doctoral Dissertation

Belgrade, 2019.

**Mentor:**

Dr Irini Reljin, red. prof, Univerzitet u Beogradu, Elektrotehnički fakultet

**Članovi komisije:**

Dr Irini Reljin, red. prof, Univerzitet u Beogradu, Elektrotehnički fakultet

Dr Milan Prokin, red. prof, Univerzitet u Beogradu, Elektrotehnički fakultet

Dr Andreja Samčović, red. prof, Univerzitet u Beogradu, Saobraćajni fakultet

Dr Dragana Šumarac-Pavlović, red. prof, Univerzitet u Beogradu, Elektrotehnički fakultet

Dr Ana Gavrovska, docent, Univerzitet u Beogradu, Elektrotehnički fakultet

**Datum odbrane:**

# DETEKCIJA NAMERNO IZAZVANIH PROMENA U SADRŽAJU SLIKE

## REZIME:

Digitalne slike i video signali predstavljaju najčešće prenošene sadržaje. Naime, sa razvojem savremenih digitalnih kamera i pametnih telefona, upotreba multimedijalnog sadržaja svakim danom postaje sve veća. Koriste se u svakodnevnom životu, za razmenu informacija, ali i kao potkrepljujući dokazi u različitim društvenim oblastima, kao što su: forenzička istraživanja, novinarstvo, dokazi na sudu i u policiji, i slično.

Sa razvojem softvera za izmenu digitalnih slika, postalo je veoma jednostavno izmeniti sadržaj postojeće slike: dodati ili ukloniti određeni sadržaj, ili čak od dve ili više slika napraviti novu sliku. Te promene se dešavaju bez značajnih degradacija u kvalitetu slike, i najčešće ne ostavljaju jasno vidljive tragove. Ukoliko slika nema u sebi ugrađen digitalni potpis ili vodeni žig, ne možemo biti sigurni u originalnost i verodostojnost iste. Zato je veoma važno razvijati metode koje će, bez postojanja dodatno ugrađenih informacija, moći da utvrde da li je slika original ili falsifikat.

Jedna od najčešćih metoda za falsifikovanje digitalnih slika jeste *copy-move forgery detection* (CMFD). Ona podrazumeva da se deo slike kopira i nalepi na neki drugi deo iste slike. Cilj takvih izmena je da se sakrije određeni sadržaj slike, ili da se duplira sadržaj slike. Tako kopirani i nalepljeni delovi se mogu naknadno skalirati, rotirati, višetruko nalepljavati, a izmenjena slika se naknadno može komprimovati.

U javno dostupnoj literaturi postoji mnogo algoritama koji su razvijeni za potrebe detekcije takvih vrsta promena. Međutim, postoje određeni nedostaci postojećih metoda: nisu primenljive na slike sa teksturama, imaju veliku kompleksnost izračunavanja i testirane su samo u uslovima JPEG kompresije, jako su osetljive ukoliko su kopirani i nalepljeni delovi većih dimenzija, ne mogu da detektuju promene ukoliko su nalepljeni delovi skalirani, imaju problem sa detekcijom ukoliko nalepljeni delovi pripadaju različitim blokovima, osetljive su na male kontraste u slici, daju mali procenat tačnosti detektovanja izmenjenih regiona i veliki procenat lažno detektovanih regiona.

Multifraktalna analiza se pokazala kao dobar alat za analizu postojećih slika, kao i segmentaciju određenih regiona, izdvajanje ivica, uglova slike i slično. Kako kopirani i nalepljeni delovi imaju sličnu strukturu, može se primeniti multifraktalna analiza, koja u osnovi analizira samosličnost. Multifraktalni spektar daje globalni opis slike (ili, opštije, fenomena koji se ispituje). Vrednost Hölder-ovog eksponenta zavisi od položaja u strukturi i opisuje lokalnu regularnost signala. Naime, različiti objekti na slici imaju različite spekture, različite pozicije maksimuma, minimuma, prve nule itd, što se pokazalo kao interesantan skup različitih parametara pomoću kojih se mogu detektovati namerne promene na slikama.

U ovoj disertaciji je opisana mogućnost korišćenja multifraktalnog spektra, kao i njegovih karakterističnih parametara, za segmentaciju i klasterovanje digitalnih slika. Predložena je nova metoda za detekciju CMFD promena na slikama, zasnovana na blokovskoj analizi, kao i na parametrima multifraktalnog spektra i nekim statističkim parametrima. Pre same detekcije, slika od interesa se deli na nepreklapajuće blokove kvadratnog oblika, čija dimenzija može varirati. Za svaki blok se računa karakteristični vektor. Za potrebe klasifikacije posmatranih blokova u izmenjene i neizmenjene, predložena je nova metaheuristika i semi-metrika, za analizu sličnosti između razmatranih blokova.

Eksperimentalni rezultati pokazuju da se predložena metoda može uspešno koristiti za detekciju izmenjenih regiona slike, sa velikim procentom ispravne detekcije falsifikovanih regiona i malim procentom lažne detekcije. Pri tome, kompleksnost računanja samog algoritma je manja u poređenju sa postojećim metodama.

**KLJUČNE REČI:** obrada slike, klasterovanje, forenzika slike, CMFD (*copy-move forgery detection*), multifraktalni spektar, Hölder-ov eksponent, metaheuristika, semi-metrika.

**NAUČNA OBLAST:** Telekomunikacije, obrada slike, forenzika slike

**UŽA NAUČNA OBLAST:** Forenzika slike

**UDK:**621.3

# DETECTION OF INTENTIONALLY MADE CHANGES IN IMAGE CONTENT

## ABSTRACT:

Digital images and video signals represent the most frequently transmitted contents. Namely, with the development of modern digital cameras and smartphones, the use of multimedia content increases every day. They are used in everyday life, for getting information and also as authenticated proofs or corroboratory evidence in different areas like: forensic studies, law enforcement, journalism and others.

With the development of digital imaging software, it became very easy to change the content of an existing image: add or remove a specific content, or even make a new image from two or more images. These changes occur without significant degradation in image quality, and most often do not leave clearly visible traces. If the image doesn't have a digital signature or a watermark embedded in it, we cannot be sure of the originality and authenticity of the image. It is therefore very important to develop methods that, without the existence of additional embedded information, will be able to determine if an image is original or forgery.

The most popular method in image forensics is *copy-move forgery detection* (CMFD), where content changes are deliberately made by copying a part of an image and pasting it to another location within the image. The aim of such changes is to hide the specific content of the image, or to duplicate the content of the image. Such deliberately made changes, e.g. copied parts, can be: translated, rotated, scaled, multiple copied, and so on, and the modified image can be compressed subsequently.

In the publicly available literature, there are many algorithms that have been developed for the purpose of detecting these types of changes. However, there are some lacks of existing methods: high sensitivity to texture features, high computational complexity and only tested with JPEG compression, high sensitive if copied and pasted parts are different size, unable to detect copy move with scaling, have a problem with

detection if the pasted parts belong to different blocks, high sensitive on the low contrast in the image, give a small percentage of the accuracy detection of the forgery regions and a large percentage of false detected regions.

Multifractal analysis has been proved to be a good tool for analyzing existing images, as well as segmentation of certain image regions, edges, angles and other. As copied and pasted parts have a similar structure, multifractal analysis can be applied, which basically analyzes self-similarity. The multifractal spectrum gives a global description of the image (or, more generally, the phenomenon being examined). The value of the Hölder exponent depends on the position in the structure and describes the local regularity of the signal. Namely, different objects in the image have different spectra, different positions of maximum, minimum, first zero, etc., which proved to be an interesting set of different parameters that can detect intentional changes in the images.

This dissertation describes the possibility of using the multifractal spectrum, as well as its characteristic parameters, for the analysis and segmentation of digital images. A new block-based method for detecting CMFD changes, based on the multifractal spectrum parameters, as well on some statistical parameters is proposed. Before the analysis, images are divided into non-overlapping blocks of fixed dimensions. For each block, the characteristic features are calculated. In order to classify observed blocks, new metaheuristic and semi-metric are proposed, for similarity analysis between blocks.

Experimental results show that the proposed method can be successfully used to detect forgery regions of the image, with a high percentage of correct detection of falsified regions and a small percentage of false detection. In addition, the algorithm's computational complexity is smaller compared to existing methods.

**KEYWORDS:** image processing, clustering, image forensics, CMFD (copy-move forgery detection), multifractal spectrum, Hölder exponent, metaheuristic method, semi-metric.

**SCIENTIFIC FIELD:** Telecommunications, Image processing, Image forensics

**SPECIFIC SCIENTIFIC FIELD:** Image forensics

**UDK:** 621.3

## SPISAK KORIŠĆENIH SKRAĆENICA

Skraćenica	Puni naziv
2NN	<i>2 Nearest Neighbors</i>
ACC	<i>Auto Color Correlogram</i>
AFMT	<i>Analytic Fourier Mellin Transform</i>
AHC	<i>Agglomerative Hierarchical Clustering</i>
ANN	<i>Approximate Nearest Neighbor</i>
APM	<i>Adaptive Patch Matching</i>
BBF	<i>Best Bin First</i>
BC	<i>Box-counting</i>
BM	<i>Blanket method</i>
BVNS	<i>Basic Variable Neighborhood Search</i>
CBF	<i>Counting Bloom Filters</i>

CDR	<i>Correct Detection Ratio</i>
CMFD	<i>Copy Move Forgery Detection</i>
DAFMT	<i>Discrete Analytical Fouirier-Mellin Transform</i>
DBCM	<i>Differential box-counting method</i>
DCT	<i>Discrete Cosine Transform</i>
DoG	<i>Difference of Gaussian</i>
DRHFs	<i>Discrete Radial Harmonic Fourier Moments</i>
DRPCET	<i>Discrete Radon Polar Complex Exponential Transform</i>
DWT	<i>Discrete Wavelet Transform</i>
DyWT	<i>Dyadic Wavelet Transform</i>
ELA	<i>Error Level Analysis</i>
FAST	<i>Features from Accelerated Segment Test</i>
fBm	<i>Fractional Brownian motion</i>
FFT	<i>Fast Fourier Transform</i>
FMT	<i>Fouirier-Mellin Transform</i>
FN	<i>False Negative</i>
FP	<i>False Positive</i>
FT	<i>Fourier Transform</i>
FWHT	<i>Fast Walsh-Hadamard Transform</i>
g2NN	<i>Generalized Two Nearest Neighbourhood</i>

HAC	<i>Hierarchical Agglomerative Clustering</i>
HSV	<i>H-hue, S-saturation, V-value</i>
IM	<i>Isarithm method</i>
IMF	<i>Inverse Multifractal Spectrum</i>
JPEG	<i>Joint Photograph Expert Group</i>
KAZE	<i>Japanska reč, u prevodu “vetar”</i>
LBCE	<i>Local Binary Coherency Error</i>
LBP	<i>Local Binary Pattern</i>
LFD	<i>Local Fractal Dimension</i>
LGWP	<i>Local Gabor Wavelets Patterns</i>
LLE	<i>Locally Linear Embedding</i>
LSH	<i>Locality-Sensitive Hashing</i>
MDFA	<i>Multifractal Detrended Fluctuation Analysis</i>
MLDD	<i>Multi Level Dense Descriptor</i>
ORB	<i>Oriented FAST and Rotated BRIEF</i>
PCA	<i>Principal Component Analysis</i>
PCET	<i>Polar Complex Exponential Transform</i>
PCT	<i>Polar Cosine Transform</i>
PHT	<i>Polar Harmonic Transform</i>
PST	<i>Polar Sine Transform</i>

QEMs	<i>Quaternion Exponent Moments</i>
QPECT	<i>Quaternion Polar Complex Exponential Transform</i>
RANSAC	<i>Random sample consensus</i>
Rg2NN	<i>Reversed-generalized 2 Nearest-Neighbor</i>
RGB	<i>Red, Green, Blue</i>
RHFs	<i>Radial Harmonic Fourier Moments</i>
RT	<i>Radon Transform</i>
SD	<i>Smooth Degree</i>
SI	<i>Swarm Intelligent</i>
SIFT	<i>Scale Invariant Feature Transform</i>
SPT	<i>Steerable Pyramid Transform</i>
SURF	<i>Speed Up Robust Features</i>
SVD	<i>Singular Value Decomposition</i>
SVM	<i>Support Vector Machine</i>
TPM	<i>Triangular Prism Method</i>
WTMM	<i>Wavelet Transform Modulus Maxima</i>
XCM	<i>‘Extended counting’ method</i>
YCbCr	<i>Komponentni kolor</i>

## SPISAK SLIKA

Broj	Naziv	Str.
Slika 2.1	Originalna slika (levo) i njena izmena (desno), primer 1 <i>copy move</i> izmene.	8
Slika 2.2	Originalna slika (levo) i njena izmena (desno), primer 2 <i>copy move</i> izmene.	8
Slika 2.3	Primer <i>image splicing</i> izmene.	8
Slika 2.4	Faze CMFD.	9
Slika 2.5	<i>Keypoint-based</i> metoda kod CMFD.	11
Slika 2.6	<i>Block-based</i> metoda kod CMFD.	13
Slika 3.1	Primeri prirodnih fraktala.	25
Slika 3.2	Primeri determinističkih monofraktala -1.	25
Slika 3.3	Primeri determinističkih monofraktala -2.	26
Slika 3.4	Računanje boks-dimenzije.	27
Slika 3.5	Metoda histograma za izračunavanje multifraktalnog spektra.	35
Slika 3.6	Kuća u naselju Baljevac, originalna slika (levo) i njena izmena (desno).	36
Slika 3.7	Slika kuće u naselju Brvenik, originalna slika (levo) i njena izmena (desno).	37

Slika 3.8	Multifraktalni spektri originalne i izmenjene slike (kuća u naselju Baljevac).	37
Slika 3.9	Multifraktalni spektri originalne i izmenjene slike (kuća u naselju Brvenik).	38
Slika 3.10	Podela na blokove (originalna slika).	40
Slika 3.11	Podela na blokove (izmenjena slika).	41
Slika 3.12	Multifraktalni spektri bloka B(1,1) originalne i izmenjene slike.	42
Slika 3.13	Multifraktalni spektri bloka B(1,2) originalne i izmenjene slike.	43
Slika 3.14	Multifraktalni spektri bloka B(2,1) originalne i izmenjene slike.	44
Slika 3.15	Multifraktalni spektri bloka B(2,2) originalne i izmenjene slike.	45
Slika 3.16	Originalna slika (levo) i njena izmena (desno), primer image splicing.	48
Slika 3.17	Multifraktalni spektri slika sa slike 3.16.	49
Slika 3.18	Primer detekcije naknadno dodatih elemenata na sliku primenom IMF.	50
Slika 3.19	Prva grupa testiranih slika (slike iz javno dostupne baze [IMA18]).	53
Slika 3.20	Druga grupa testiranih slika (slike generisane za eksperiment).	53
Slika 3.21	Analiza i segmentacija slike.	57
Slika 3.22	<i>Skyline</i> region je obeležen crvenom bojom.	58
Slika 3.23	Primeri slika sa <i>skyline</i> regionima.	59
Slika 3.24	Rezultati klasterovanja <i>grayscale</i> slike za različite kombinacije površina: a) prva kombinacija, b) druga kombinacija i c) treća kombinacija.	60
Slika 3.25	Rezultati klasterovanja slike za različite kombinacije površina (samo	62

	plavi kanal): a) prva kombinacija, b) druga kombinacija i c) treća kombinacija.	
Slika 3.26	Rezultati klasterovanja slike za različite kombinacije površina (zeleni kanal): a) prva kombinacija, b) druga kombinacija i c) treća kombinacija.	63
Slika 3.27	Rezultati klasterovanja slike za različite kombinacije površina (crveni kanal): a) prva kombinacija, b) druga kombinacija i c) treća kombinacija.	64
Slika 3.28	Rezultati klasterovanja slike za različite kombinacije površina (samo hue komponenta): a) prva kombinacija, b) druga kombinacija i c) treća kombinacija.	65
Slika 3.29	Ivice dela slike različitih luminansi se više ističu.	67
Slika 3.30	Primer svetle pozadine i tamnog objekta (levo) i slika generisana da simulira Mahov efekat (desno).	68
Slika 3.31	Multifraktalni spektri slika sa slike 3.30.	68
Slika 3.32	Primer tamne pozadine i svetlog objekta (levo) i slika generisana da simulira Mahov efekat (desno).	69
Slika 3.33	Multifraktalni spektri slika sa slike 3.32.	70
Slika 4.1.	Algoritam predložene metode zasnovane na multifraktalima.	72
Slika 4.2	Podela slike na nepreklapajuće blokove.	74
Slika 4.3.	Primer (a) originalne slike, (b) izmenjene slike i (c) njihovi multifraktalni spektri.	75
Slika 4.4.	Parametri multifraktalnog spektra korišćeni kao deskriptori blokova.	77
Slika 5.1	Primeri Copy-move falsifikovanja (prvih pet slika iz javno dostupnih baza): originalne slike (prvi red), odgovarajuće izmenjene slike (drugi red) i ground truth map (treći red).	84
Slika 5.2	Primeri Copy-move falsifikovanja (prvih pet slika iz javno dostupnih baza): originalne slike (prvi red), odgovarajuće izmenjene slike (drugi red) i ground truth map (treći red).	85

Slika 5.3	Primeri slika generisanih za potrebe istraživanja – originalne slike (prvi red) i odgovarajuće izmene (drugi red).	85
Slika 5.4	Prvih pet primera copy-move detekcije: originalne slike (prvi red), odgovarajuće izmenjene slike (drugi red), ground truth mape (treći red), rezultati detekcije falsifikata za blokove dimenzija 32x32 (četvrti red), rezultati detekcije falsifikata za blokove dimenzija 16x16 (peti red) i rezultati detekcije falsifikata za blokove dimenzija 8x8 (šesti red).	87
Slika 5.5	Drugih pet primera copy-move detekcije: originalne slike (prvi red), odgovarajuće izmenjene slike (drugi red), ground truth mape (treći red), rezultati detekcije falsifikata za blokove dimenzija 32x32 (četvrti red), rezultati detekcije falsifikata za blokove dimenzija 16x16 (peti red) i rezultati detekcije falsifikata za blokove dimenzija 8x8 (šesti red).	88
Slika 5.6	Primeri generisani za potrebe istraživanja: originalne slike (prvi red), odgovarajuće izmenjene slike (drugi red), rezultati detekcije falsifikata za blokove dimenzija 32x32 (treći red), rezultati detekcije falsifikata za blokove dimenzija 16x16 (četvrti red) i rezultati detekcije falsifikata za blokove dimenzija 8x8 (peti red).	94

## SPISAK TABELA

Broj	Naziv	Str.
Tabela 2.1	Primeri dodatnih “napada” na slike.	9
Tabela 3.1	Parametri multifraktalnog spektra originalne i izmenjene slike.	39
Tabela 3.2	Parametri multifraktalnog spektra blokova originalne slike.	46
Tabela 3.3	Parametri multifraktalnog spektra blokova izmenjene slike.	46
Tabela 3.4	Pearson-ov koeficijent korelacije za skup slika prikazan na Slici 3.19 [PAV17].	54
Tabela 3.5	Pearson-ov koeficijent korelacije za skup slika prikazan na Slici 3.20 [PAV17].	54
Tabela 3.6	Rezultati klasterovanja blokova za različite kombinacije površina (klasteri prikazani na slici 3.24).	61
Tabela 3.7	Rezultati klasterovanja blokova za različite kombinacije površina (klasteri prikazani na slici 3.25).	62
Tabela 3.8	Rezultati klasterovanja blokova za različite kombinacije površina (klasteri prikazani na slici 3.26).	63
Tabela 3.9	Rezultati klasterovanja blokova za različite kombinacije površina (klasteri prikazani na slici 3.27).	64
Tabela 3.10	Rezultati klasterovanja blokova za različite kombinacije površina (klasteri prikazani na slici 3.28).	66
Tabela 5.1	Performanse tačnosti u pojmovima preciznost i opoziv za blokove dimenzija 8x8, u procentima, za slike I, II, III, IV, V, VI, VII, VIII, IX i X.	89

Tabela 5.2	Performanse tačnosti u pojmovima preciznost i opoziv za blokove dimenzija 16x16, u procentima, za slike I, II, III, IV, V, VI, VII, VIII, IX i X.	90
Tabela 5.3	Performanse tačnosti algoritma u pojmovima CDR, u slučaju dimenzija blokova 16x16 i 32x32, za sliku II.	92
Tabela 5.4	Performanse tačnosti algoritma u pojmovima $F_C$ i $F_f$ , za blokove dimenzija 16x16, za slike II, V, VII i VIII.	92
Tabela 5.5	Performanse tačnosti algoritma u pojmovima $F_C$ i $F_f$ , za blokove dimenzija 32x32, za slike II, V, VII i VIII.	93
Tabela 5.6	Performanse predloženog algoritma za blokove dimenzija 32x32, za slike a), b), c), d) i e).	95
Tabela 5.7	Performanse predloženog algoritma za blokove dimenzija 16x16, za slike a), b), c), d) i e).	95
Tabela 5.8	Performanse predloženog algoritma za blokove dimenzija 8x8, za slike a), b), c), d) i e).	96
Tabela 5.9	Poređenje kompleksnosti računanja predložene metode sa drugim metodama.	96

# SADRŽAJ

	Strana
Spisak skraćenica	
Spisak slika	
Spisak tabela	
1. Uvod	1
1.1. Motivacija	1
1.2. Ciljevi istraživanja i polazne hipoteze	4
1.3. Organizacija disertacije	5
2. Detekcija promena “kopiraj i nalepi” ( <i>Copy move forgery detection</i> )	7
2.1 Pregled postojeće literature	15
2.1.1 Metode zasnovane na ključnim tačkama - ( <i>keypoint-based</i> ) metode	15
2.1.2 Metode zasnovane na podeli na blokove ( <i>block-based</i> metode)	18
3. Multifraktalna teorija	22
3.1 Principijelni koncept fraktalne teorije i samosličnih procesa	24
3.1.1 Skup frakタルnih dimenzija	26
3.1.2 Metoda zasnovana na boksevima ( <i>Box-counting method</i> )	27
3.2 Multifraktali	30

3.2.1	Fraktalna dimenzija $D_0$ i informaciona dimenzija $D_1$	30
3.2.2	Osobine funkcije $D_q$	31
3.2.3	Spektar fraktalnih dimenzija	32
3.2.4	Funkcija multifraktalnog spektra	33
3.2.5	Izračunavanje MF spektra	34
3.2.5.1	Metoda histograma	34
3.2.5.2	Podela na blokove	39
3.2.6	Inverzni multifraktalni spektar	47
3.3	Statistička analiza slika izmenjenih <i>copy-move</i> metodom	50
3.4	Segmentacija i klasterovanje slike na osnovu parametara multifraktalnog spektra	55
3.4.1	<i>Skyline</i> segmentacija slike korišćenjem boja i detaljnog klasterovanja	56
3.4.1.1	Segmentacija intenzitetske slike	60
3.4.1.2	Segmentacija slike zasnovana na R, G i B kanalu u RGB sistemu boja	61
3.4.1.3	Segmentacija slike korišćenjem samo H komponente u HSV sistemu boja	65
3.5	Mahov efekat	66
4.	Metodologija – nova metoda za detekciju CMFD promena	71
4.1	Nova metoda zasnovana na blokovima	71
5.	Rezultati simulacije i diskusija rezultata	83
5.1	Rezultati i diskusija slika iz javno dostupnih baza	83
5.2	Rezultati i diskusija za slike generisane za potrebe istraživanja	93
5.3	Kompleksnost računanja	96
9.	Zaključak	99
	Literatura	106
	Biografija autora	119



# 1. Uvod

## 1.1 Motivacija

Sa razvojem savremenih digitalnih kamera i pametnih telefona, upotreba multimedijalnog sadržaja svakim danom postaje sve veća. Korišćenjem Interneta i raznih društvenih mreža, razmena digitalnih fotografija je znatno uvećana. Digitalne fotografije predstavljaju većinu izvora informacija današnjice, i mogu se koristiti u različite svrhe, kao autentični ili potkrepljujući dokazi u područjima kao što su forenzička istraživanja, dokazi u policiji i na sudu, u novinarstvu, itd. Sa druge strane, razvojem softvera za izmenu digitalnih slika, postalo je veoma jednostavno izmeniti sadržaj postojeće slike, falsifikovati dokumente i preneti lažnu informaciju. Osoba ne mora biti ekspert kako bi korišćenjem softvera, kao što je *Adobe Photoshop*, uklonila ili dodala određeni sadržaj iz digitalne slike [PAV17a, PAV17b]. Te promene se dešavaju bez značajnih degradacija u kvalitetu slike, i najčešće ne ostavljaju jasno vidljive tragove. Ukoliko fotografija nema dodatno ugrađene informacije kao što su vodeni žig i digitalni potpis, ne možemo biti sigurni u autentičnost i originalnost digitalne slike. Drugim rečima, ne smemo verovati u ono što vidimo. Stoga je jasno koliki je značaj razvoja metoda za detekciju namerno izazvanih promena u sadržaju slike [PAV17a, PAV17b].

Metode za detekciju namerno izazvanih promena u sadržaju slike se mogu podeliti u dve kategorije: aktivne i pasivne, u zavisnosti od prisustva dodatne informacije [WAR16].

Aktivne metode podrazumevaju prisustvo dodatnih, naknadno ugrađenih informacija u sadržaju slike, kao što su vodeni žig ili digitalni potpis. Međutim, aktivne metode podrazumevaju da se dodatne informacije ugrađuju u sliku prilikom generisanja slike, ili naknadno od strane autorizovanog autora. Ukoliko je slika bez podataka o originalnosti (preuzeta sa *Internet-a*), aktivne metode je nemoguće koristiti. Sa druge strane, pasivne metode omogućavaju detekciju promena na slikama, bez prisustva dodatnih naknadno ugrađenih informacija u slici. Pasivne metode otkrivaju manipulacije nad slikama izdvajanjem prirodnih karakteristika slike, kao i karakteristika optičkih uređaja korišćenih za generisanje slike (karakteristike šuma). Ove metode se dalje mogu podeliti u dve kategorije: zavisne i nezavisne. Zavisne metode podrazumevaju da se deo slike kopira i nalepi na neki deo unutar iste slike (kopiraj i nalepi - *copy-move*) ili sa neke druge slike (spajanje slika - *image splicing*) [WAR16]. Druge vrste manipulacija nad slikama, kao što su kompresija, pododabiranje, “zamagljenje” i slično, spadaju u nezavisne metode. Što se tiče same detekcije uređaja kojim je generisana slika, ona se bazira na regularnostima optičkih senzora uređaja [WAR16].

Postoji nekoliko pasivnih metoda za detekciju namernih promena na slikama, a najviše korićena jeste tzv. CMFD (“detekcija promena kopiraj i nalepi” - *Copy Move Forgery Detection*) metoda. CMFD metoda podrazumeva da se deo slike kopira na neki drugi deo iste (*copy-move*) ili neke druge (*image splicing*) slike, kako bi se prikrila određena informacija, ili se prenela pogrešna informacija o sadržaju slike (duplirao sadržaj slike) [PAV17a, PAV17b]. Ovakve namerno izazvane promene, odnosno kopirani delovi, mogu se višestruko kopirati, rotirati, okretati, skalirati, filtrirati i slično [WAR16]. Ukoliko se delovi kopiraju u istu sliku, komponente šuma, paleta boja, dinamički opseg i druge važne osobine koje odgovaraju tim delovima, biće kompatibilne sa ostatkom slike, tako da će teško biti detektovane metodama koje tragaju za nekompatibilnostima u statističkim merenjima u raznim delovima slike.

Metode za detekciju namernih promena u sadržaju slike se mogu uglavnom opisati na sledeći način:

- Metode koje se zasnivaju na diskretnoj kosinusnoj transformaciji (*Discrete Cosine Transform* - DCT), ali nisu primenljive na slikama sa teksturama, imaju veliku kompleksnost izračunavanja i testirane su samo u uslovima JPEG (*Joint Photographic Experts Group*) kompresije [MAH18, ALA17, KAU15, HU16, SHI15, UST16, LIN16];
- Metode zasnovane na unapređenoj DCT, ali su jako osetljive ukoliko su kopirani i nalepljeni delovi većih dimenzija [MAH18];
- Metode koje se zasnivaju na Furijeovoj transformaciji (*Fourier Transform* – FT) [KUM13, SHI13], ali ne mogu da detektuju promene ukoliko su nalepljeni delovi skalirani;
- Metode zasnovane na diskretnoj talasnoj transformaciji (*Discrete Wavelet Transform* - DWT), ali imaju problem sa detekcijom ukoliko nalepljeni delovi pripadaju različitim blokovima [ALA17, HAY17, HU16];
- Metode zasnovane na dijadičnoj talasnoj transformaciji (*Dyadic Wavelet Transform* - DyWT), ali su testirane samo u uslovima JPEG kompresije i rotacije [WAR16];
- Metode koje se zasnivaju na relativno jednostavnom izračunavanju skalirajućih invarijantnih transformacionih karakteristika (*Scale Invariant Feature Transform* – SIFT), i ubrzanim robusnim karakteristikama (*Speed Up Robust Features* - SURF) [WAN18a, WAN18b, GAN18, GON16, ZHA17, WAR16], ali su osetljive na male kontraste u slici kao i na delove slike koji se ponavljaju;
- Metode koje se zasnivaju na DCT, principijalnoj analizi komponenata (*Principal Component Analysis* - PCA) i Zernike momentima [WAN17], ali imaju veliku kompleksnost izračunavanja.

Zbog navedenih nedostataka postojećih metoda, jasno je zašto je važan razvoj novih metoda za detekciju namernih promena na slikama.

Motivacija za izradu ove disertacije jeste razvoj nove metode za detekciju namernih promena na slikama koja će imati manju kompleksnost prilikom izračunavanja, i biti otpornija na regije sa teksturama, a takođe i omogućavati detekciju malih izmenjenih regija i davati veću preciznost prilikom detekcije regija koji su pretrpeli promene, kao i

manji procenat "lažne detekcije", tačnije detektovanja neizmenjenih delova slike kao izmenjenih.

## 1.2 Ciljevi istraživanja i polazne hipoteze

Cilj istraživanja jeste razvoj nove CMFD metode za detekciju namerno izazvanih promena u sadržaju slike upotrebom analize singulariteta slike. Naime, kopirani i nalepljeni delovi imaju sličnu strukturu, pa se može primeniti multifraktalna analiza, koja u osnovi analizira samosličnost. Metoda će biti testirana na primerima koji su generisani za potrebe analize, kao i na primerima iz javno dostupnih baza slika. Ovakva metoda je od značaja u digitalnoj forenzici i za primenu u automatskoj detekciji delova koji su kopirani u istu, kao i u drugu sliku, a takođe i u detekciji delova koji su skalirani, rotirani i višestruko kopirani.

Istraživanje se zasniva na sledećim osnovnim hipotezama:

1. Korišćenje multifraktala u detekciji namernih promena na slikama opravdava činjenica da se fraktalna dimenzija pokazala kao pogodan alat za karakterizaciju neregularnosti krive ili površine.
2. Izmena sadržaja slike utiče na osvetljenost i jasnoću originalne slike, stoga i na singularitete i multifraktalnost originalne slike.
3. Multifraktalni spektar predstavlja lokalne i globalne karakteristike slike.
4. Vrednosti takozvanog Hölder-ovog eksponenta daju informacije o lokalnoj regularnosti određenih tačaka – piksela.
5. Ukoliko se slika posmatra kao 2D signal, vrednosti Hölder-ovog eksponenta oko 2 predstavljaju „regularne“ piksele, dok pikseli čija je vrednost Hölder-ovog eksponenta različita od 2, predstavljaju tačke u kojima se „nešto dešava“.
6. Moguća je automatizacija detekcije namerno izazvanih promena, bez potrebe za prisustvom čoveka u bilo kojoj fazi detekcije.
7. Savremene metode detekcije se mogu primeniti na slike različitog formata i rezolucije.
8. Pozitivni rezultati će se dobiti korišćenjem odgovarajućih kodova u Matlabu i C#.

## 1.3 Organizacija disertacije

Disertacija je organizovana u šest poglavlja.

U uvodnom poglavlju je opisana inicijalna motivacija i objašnjeni su ciljevi istraživanja. Naime, opisani su razlozi zbog kojih je važno razvijati metode za detekciju namerno izazvanih promena u sadržaju slike, kao i nedostaci postojećih metoda. Polazne hipoteze su postavljene u skladu sa navedenim ciljevima.

Drugo poglavlje opisuje najčešći vid promena na slikama (CMFD). Dat je pregled postojećih metoda za detekciju CMFD promena na digitalnim slikama, kao i opis njihovih prednosti i nedostataka. Navedeni su i objašnjeni osnovni koraci u postojećim metodama, kao i algoritmi koji se koriste za izdvajanje i uparivanje karakteristika originalne i izmenjene slike, kao i pregled javno dostupne literature (povezani radovi).

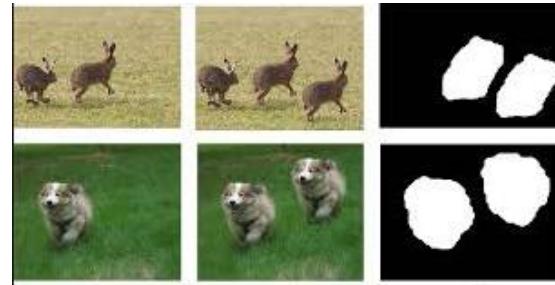
U trećem poglavlju je opisana multifraktalna teorija. Kako su kopirani i nalepljeni delovi sa iste slike, njihove karakteristike su slične, pa se stoga može koristiti multifraktalna analiza, koja u osnovi analizira samosličnost objekata. Objašnjen je način na koji se računa multifraktalni spektar, kao i razlozi zbog kojih je moguće koristiti parametre multifraktalnog spektra za detekciju namerno izazvanih promena na slikama. Naime, određenim izmenama na slikama, menjaju se i parametri spektra, pa se mogu koristiti za klasterovanje slika u izmenjene ili neizmenjene.

U četvrtom poglavlju je predstavljeno objašnjenje navedenog algoritma za detekciju promena na slikama, zasnovanog na parametrima multifraktalnog spektra i novoj semimetrici (rezulati su objavljeni i verifikovani u časopisu međunarodnog značaja). Opisana je sama metodologija i predstavljeni su detaljno koraci samog algoritma.

Rezultati primene predloženog algoritma na baze testiranih slika su dati u poglavlju 5. Algoritam je testiran na dve baze slika: bazi javno dostupnih slika [COM18, IMA18], kao i na bazi slika generisanih za potrebe istraživanja. Predstavljeni su i rezultati poređenja dobijenih rezultata sa rezultatima drugih autora, na osnovu određenih parametara

preciznosti detekcije promenjenih delova u sadržaju slike, kao i procentu „lažne detekcije“, i same kompleksnosti izračunavanja predloženih algoritama.

U šestom poglavlju je opisana diskusija dobijenih rezultata i data su zaključna razmatranja, doprinosi same disertacije kao i predlozi daljih istraživanja.



## 2. Detekcija promena “kopiraj i nalepi” (*Copy move forgery detection*)

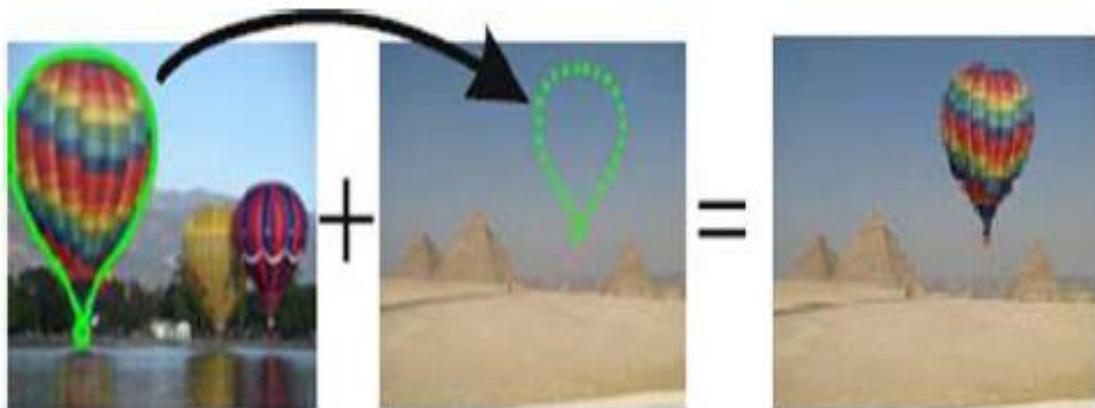
*Copy move forgery detection (CMFD)* metoda jeste jedna od najpoznatijih metoda za detekciju namerno izazvanih promena u sadržaju slike. Ona podrazumeva da se deo slike kopira i nalepi na neki drugi deo unutar iste slike (*copy move*) ili da se od dve ili više slike napravi jedna slika (*image splicing*). Cilj ovih promena na slikama jeste da se prekrije ili duplira određeni sadržaj slike, kako bi se prenela lažna informacija. Ovakve promene je teško detektovati jer su kopirani i nalepljeni delovi sa iste slike, tako da se parametri kao što su temperatura boja, osvetljenje, komponente šuma, itd. poklapaju kod originalne slike i izmenjenih delova. Delovi koji se najčešće kopiraju jesu trava, lišće, šuma, i razne teksture [FRID03]. Primeri *copy move* i *image splicing* metoda su dati na slikama 2.1, 2.2 i 2.3 [PAV17b].



Slika 2.1 Originalna slika (levo) i njena izmena (desno), primer 1 *copy move* izmene [IMA18, PAV17b].



Slika 2.2 Originalna slika (levo) i njena izmena (desno), primer 2 *copy-move* izmene [IMA18].



Slika 2.3 Primer *image splicing* izmene.

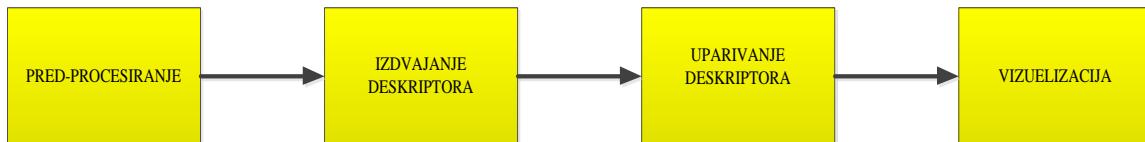
Na slici 2.1 možemo videti da je izmena nastala tako što je deo šume kopiran i nalepljen kako bi prekrio postojeći objekat na slici (zgrada) [PAV17b]. Slika 2.2 prikazuje primer kopiranja sadržaja (drvo) kako bi se duplirao sadržaj slike. Primer generisanja nove slike od dve postojeće (*image splicing*) prikazan je na slici 2.3.

*Copy-move* promene na slikama postaju još teže ukoliko se kombinuju sa geometrijskim transformacijama i post-procesirajućim operacijama, koje su prikazane u Tabeli 2.1 [WAR16].

Tabela 2.1 Primeri dodatnih “napada” na slike.

“Napadi”	Primeri	Opis
Post-procesiranje	JPEG kompresija, “zamagljenje” <sup>1</sup> , Gausov šum	Eliminiše vidljive tragove kopiranja i premeštanja, kao što su oštре ivice
Geometrijske transformacije	Rotacija, skaliranje, translacija	Omogućava sinhronizaciju i homogenizaciju između kopiranih delova i susedstva.

CMFD se obično sastoji od četiri faze: predprocesiranje, izdvajanje deskriptora, poklapanja deskriptora i vizuelizacije. Faze su prikazane na slici 2.4. Sledi detaljan opis svake od faza.



Slika 2.4 Faze CMFD.

Prva faza kod CMFD jeste faza pred-procesiranja, koja je opcionalna, i najčešće podrazumeva konverziju RGB (*Red, Green, Blue*) slike u *grayscale* (intenzitetsku) [YAN18, LEE15, SHI15, ALK16, ZHA13a, ZHA13b, CAO12, LI12a, LI12b, LYN13, MUH12, RYU13, WAN12]. Konverzija se vrši prema dobro poznatoj jednačini

---

<sup>1</sup> Najjednostavnije se postiže 2D NF filtriranjem dela slike

$$I = 0,228 \times R + 0,587 \times G + 0,114 \times B \quad (2.1)$$

gde I predstavlja *grayscale* komponentu, dok R, G i B predstavljaju crveni, zeleni i plavi kanal slike u boji, respektivno. Slika u boji se alternativno može konvertivati u YC<sub>b</sub>C<sub>r</sub> sistem boja, i dalja obrada se vrši nad luminentnom (Y) komponentom ili nad hrominentnim komponentama (C<sub>b</sub> i C<sub>r</sub>) [MAH18, ALA17, MUH14, UST16, HUS14, MUH13]. Konverzija iz RGB u *grayscale* ili YC<sub>b</sub>C<sub>r</sub> se vrši kako bi se smanjila dimenzionalnost podataka ili jasnije istakle vizuelne karakteristike slike. Takođe, povećava se brzina obrade i smanjuje se složenost pa time i samo vreme obrade. Pored konverzije u nove sisteme boja, najčešće se vrši podela slike u preklapajuće ili nepreklapajuće blokove, kako bi se smanjilo vreme uparivanja sličnih blokova.

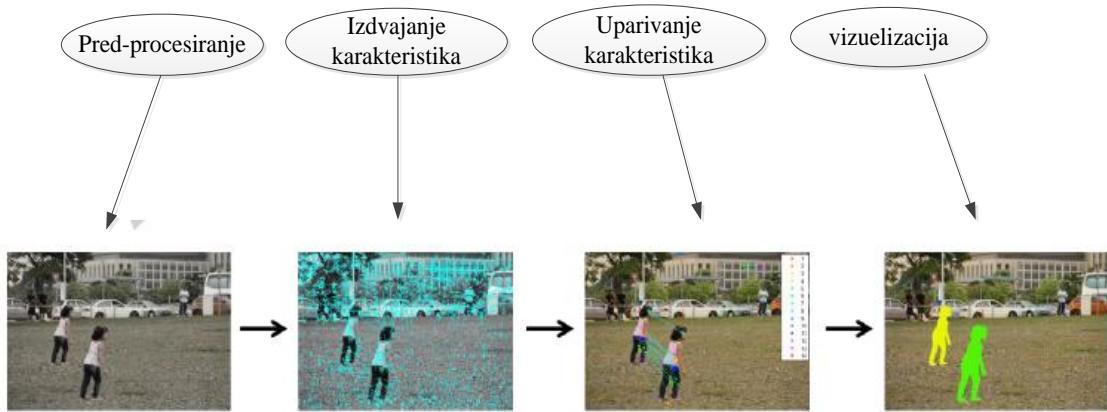
Posle faze pred-procesiranja, sledi faza izdvajanja deskriptora, gde se biraju relevantne informacije koje predstavljaju karakteristike od interesa za odgovarajuću sliku. Za izdvajanje deskriptora se najčešće koriste sledeće tehnike: diskretna kosinusna transformacija (*Discrete Cosine Transform* - DCT), diskretna talasna transformacija (*Discrete Wavelet Transform* - DWT), invarijante ključne tačke, transformacija u logaritamski polarni sistem, teksture i intenzitet [MAH18, ALA17, HAY17, KAU15, HU16, LIN16].

Nakon izdvajanja deskriptora, sledi faza uparivanja deskriptora, gde se na određeni način traži sličnost između jednog ili više deskriptora slike (najčešće su to karakteristični vektori). Tehnike uparivanja su uglavnom zasnovane na blokovima (*block-based*) ili na ključnim tačkama (*keypoint-based*), u zavisnosti od tipa izdvojenih deskriptora.

Poslednja faza jeste faza vizuelizacije, kako bi se prikazali i lokalizovali izmenjeni delovi na slici. Vizuelizacija kod *block-based* metoda se najčešće vrši tako što se izmenjeni blokovi prikazuju belom bojom, dok se ostatak slike prikazuje crnom bojom [WAR16]. Kod *keypoint-based* metoda, falsifikovani delovi se prikazuju linijskom transformacijom između odgovarajućih tačaka [AME11, CAO12, JAB13, LIN12, ZAO13].

CMFD metode mogu biti *keypoint-based* ili *block-based*.

*Keypoint-based* metode se zasnivaju na izdvajaju karakterističnih tačaka slike, gde se izdvajanje vrši samo u određenim regionima slike, bez podele slike na blokove (Slika 2.5) [WAR16]. Karakteristike ključnih tačaka predstavljaju lokalne karakteristike slike kao što su: ivice, uglovi, ili “grudvice” (*blobs*). Svaka karakteristika se predstavlja skupom deskriptora koji se izdvajaju u regionima u okolini ključne tačke. Zatim se vrši klasifikacija i uparivanje ključnih tačaka i deskriptora, kako bi se pronašli falsifikovani regioni slike [CHA16].



Slika 2.5 *Keypoint-based* metoda kod CMFD.

Za izdvajanje karakteristika kod *keypoint-based* metoda, najčešće se koriste sledeće tehnike: skalirajuća invarijantna transformacija karakteristika (*Scale Invariant Feature Transform* – SIFT), Harisov detektor uglova (*Harris Corner Detector*), ubrzane robusne karakteristike (*Speed Up Robust Features* - SURF) [WAN18a, WAN618, YAN18, CHA16, GON16, YAN17] i lokalna bidirekciona greška koherencije (*Local Bidirectional Coherency Error* - LBCE) [BI18a].

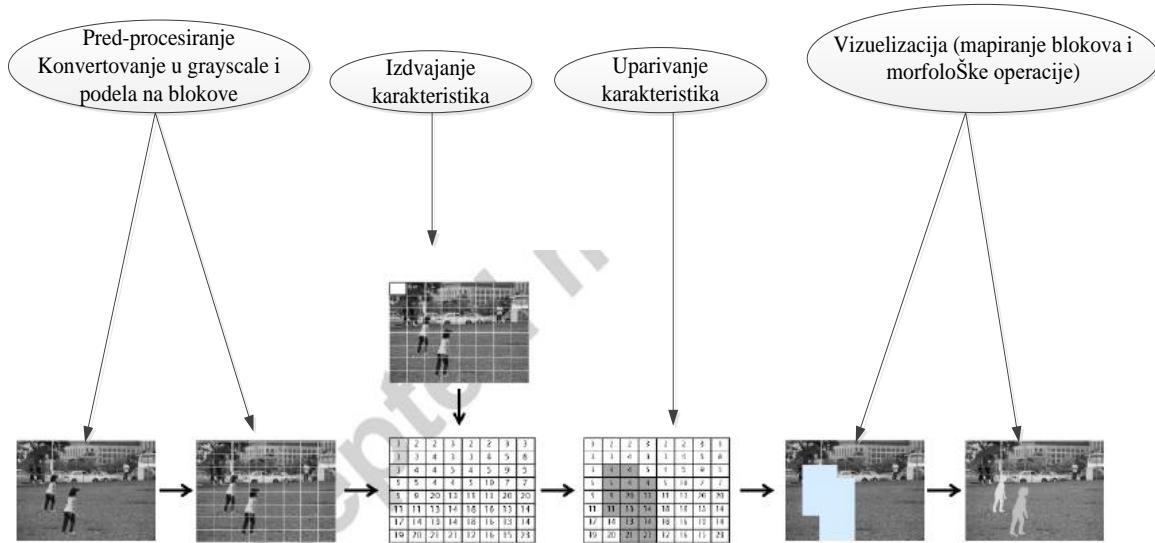
SIFT tehniku je prvo uveo *David Lowe*, za detekciju ključnih tačaka u različitim skalama, u cilju prepoznavanja objekata. Tehnika je otporna na procese rotacije i skaliranja [AME13, ANA14, HAS14, JAB13, LI15, MOH13, SHE13]. SIFT detektuje ključne tačke u različitim skalami koristeći Gausovu piramidu razlika (*Difference of Gaussian* - DoG) [WAR16]. DoG se koristi kako bi se svakoj ključnoj tački dodelili SIFT deskriptori koji su sastavljeni od gradijentnog orjentisanog histograma koji je otporan na rotacije i smanjila kompleksnost računanja.

*Harris Corner Detector* tehnika je uvedena odmah nakon SIFT tehnike, i izdvaja uglove i ivice iz određenih regiona na osnovu lokalne auto-korelace funkcije [CHE13, GUO13, KAK12, YU16, ZHA13b, ZHE14].

SURF tehnika se prvi put pojavila 2008. godine i uvedena je kako bi se prevazišli nedostaci SIFT tehnike i smanjio broj lažnih poklapanja. Kasnije su uvedena unapređenja i proširenja SURF tehnike [BO10, MIS13].

Što se tiče uparivanja karakteristika, kod *keypoint-based* metoda, najčešće se koriste tehnike najbližeg suseda: najbolji prvi bin (*Best Bin First*) [CHE13, JAB13, KAK13, MIS13, ZHA13a, ZHA13b], dva najbliža suseda (*Two Nearest Neighbourhood - 2NN*) [HAS14, JAB13, KAK13, MIS13, GUO13], generalizovana dva najbliža suseda (*Generalized Two Nearest Neighbourhood - g2NN*) [WAN18a, GAN18, ZHO17a, ZHO17b, YAN17, AME13, MOH13], kao i klasterovanje [ARD10]. Kod tehnika najbližeg suseda, računaju se rastojanja između ključnih tačaka, i ukoliko je rastojanje manje od određenog praga, smatra se da su tačke slične ili iste. Klasterovanje grupiše skupove objekata koji su slični, a tehnika koja se naročito koristi jeste hijerarhijsko aglomerativno klasterovanje (*Hierarchical Agglomerative Clustering - HAC*).

*Block-based* metode u fazi pred-procesiranja dele sliku na preklapajuće ili nepreklapajuće blokove kvadratnog oblika. Zatim se za svaki blok računaju karakteristični vektori sastavljeni od odgovarajućih deskriptora, u zavisnosti od primenjene metode. Karakteristični vektori se uparuju i traži se sličnost između blokova. Kada se odrede blokovi koji su slični, ti regioni se označavaju kao falsifikovani (Slika 2.6) [WAR16].



Slika 2.6 *Block-based metoda* kod CMFD.

Tehnike za izdvajanje karakterističnih vektora kod *block-based* metoda se mogu generalno podeliti na sledeći način: frekvencijska transformacija, invarijantni momenti, transformacija u logaritamski polarni sistem, teksture i intenzitet, smanjenje dimenzija i druge [WAR16].

Frekvencijska transformacija je najviše korišćena tehnika za izdvajanje karakterističnih vektora kod *block-based* metoda. Otporna je na šum i može da izdvoji komponente koje su translirane ili rotirane [CAO12, DEN12, HUA11, KET13, KUM13, LI12a, LI12b, MUH12, SHI13, BIN13, GUO13].

Radi unapređenja karakteristika frekvencijske transformacije, uvedene su tehnike, kao što su DCT, Furijeova transformacija (*Fourier Transform*), brza Valš-Hadamardova transformacija (*fast Walsh-Hadamard Transform - FWHT*), DWT, dijadična talasna transformacija (*Dyadic Wavelet Transform - DyWT*) i Vinerov filter talasića (*Wiener Filter Wavelet*) [MAH18, ALA17, HAY17, HU16].

Teksture postoje u prirodnim scenama, kao što su lišće, trava, drvo, oblaci, zemlja. Prema tome, mogu se koristiti kao karakteristike za lokalizaciju sličnosti u falsifikovanoj slici. U CMFD metodi, tekture i intenzitet se mere kroz oblik i informaciju o boji [ARD09, BRA11, DAV13, GAN14, HSU12, VLAN14, LYN13, SIN12, ULU13].

Invarijantni momenti su skup karakteristika koje su otporne na skaliranje i rotaciju, i mogu se koristiti za klasifikaciju i prepoznavanje objekata na slikama. Unapređenja kao što su centralni moment, Kravtočokov moment (*Krawtchouk's moment*), Zernikov moment (*Zernike moment*) [WAN17], i eksponencijalni moment su uvedena kako bi se prevazišli nedostaci regularnih momenata [IMA13, KAS13, ZHO13, RYU13].

Transformacija u logaritamski polarni sistem je tehnika za izdvajanje karakterističnih vektora blokova koja je otporna na rotaciju, skaliranje i translaciju [BAY09, LI12a, LI12b, ZHO13, WU10]. Transformacija se vrši tako što se tačke iz dvodimenzionalnog (2-D) Dekartovog koordinatnog sistema projektuju u logaritamsku polarnu ravan, pomoću nekih od sledećih transformacija: Furijeova Melinova transformacija (*Fourier Mellin Transform - FMT*), polarna harmonijska transformacija (*Polar Harmonic Transform - PHT*), polarna kosinusna transformacija (*Polar Cosine Transform - PCT*) i polarna sinusna transformacija (*Polar Sine Transform - PST*) [WAN17, WAR16].

Smanjenje dimenzija jeste tehnika koja se koristi za smanjenje dimenzionalnosti karakterističnih vektora, kao i za unapređenje kompleksnosti. Najčešće korišćene tehnike su dekompozicija jedinstvene vrednosti (*Singular Value Decomposition - SVD*), lokalno linearno ugrađivanje (*Locally Linear Embedding - LLE*) i principijelna analiza komponenata (*Principal Component Analysis - PCA*) [OOM16, HUA17, HU16, SHI15].

Tehnike uparivanja se koriste nakon izdvajanja karakterističnih vektora, kako bi se pronašli slični blokovi i odredila pozicija falsifikata. Ove tehnike se mogu podeliti u nekoliko kategorija: sortiranje, “pretresanje” (*hash*), korelacija, Euklidsko rastojanje i drugi [GAB18, WAN2918, ZHO17a, ZHO17b, JEN16, KAU15, LEE15, ALK16, YAN17].

Sortiranje je tehnika koja uređuje karakteristike po odgovarajućem poretku, i time unapređuje kompleksnost uparivanja [ARD09, ULU13, BRA11, CAO12, DAV13, GAN14]. U tehnike sortiranja spadaju leksikografska, KD drvo (*KD-Tree*), i radiks (*Radix*). *Hash* se koristi kao metoda koja osigurava da će bilo koja modifikacija biti oktrivena. U *Hash* tehnike spadaju brojanje blum filtera (*Counting Bloom Filters - CBF*) i lokalno osetljivo pretresanje (*Locality-Sensitive Hashing - LSH*) [BI18b, EMA16]. Korelacija je

statistički parametar dve ili više promenljivih koji određuje stepen povezanosti [WAR16]. Korelacioni koeficijenti se često koriste za određivanje duplicitarnih regiona nakon sortiranja [ZHO17a, ZHO17b, HAY17, MYN08, PEN11, SHA12, YHA08]. Euklidsko rastojanje jeste mera rastojanja dva vektora u Euklidskoj ravni. Koristi se za detekciju duplicitarnih regiona, nakon sortiranja [WAN2918, ZHO13, LI15, RYU10].

## 2.1 Pregled postojeće literature

U poslednjoj dekadi razvijeno je mnogo metoda za detekciju namerno izazvanih promena u sadržaju slike, a posebno onih koje se bave *copy-move* promenama, odnosno CMFD. Ove metode se mogu podeliti u dve kategorije: *keypoint-based* i *block-based*.

### 2.1.1 Metode zasnovane na ključnim tačkama - (*keypoint-based*) metode

U [WAN18b] je predstavljena metoda zasnovana na modelu invarijantnosti boja i kvaternionoj polarnoj kompleksnoj eksponencijalnoj transformaciji (*Quaternion Polar Complex Exponential Transform* - QPECT). Prvo se iz slike izdvajaju tačke od interesa koristeći novi detektor tačaka, koji je kombinacija SURF i modela invarijantnosti boja. Zatim se na osnovu izdvojenih tačaka od interesa izgrađuje skup Delanejevih (*Delaunay*) trouglova, za koje se računaju lokalne vizuelne karakteristike korišćenjem QPCET. Za uparivanje trouglova koriste se lokalne vizuelne karakteristike u kombinaciji sa drugim najbližim susedom (*2 nearest-neighbor* - Rg2NN) i BBF. Na kraju, duplicitarni regioni se detektuju koristeći nultu srednju normalizovanu unakrsnu korelacionu meru. Metoda zasnovana na dva karakteristična koraka je opisana u [WAN17]. U prvom koraku, u fazi predprocesiranja, digitalna slika se propušta kroz CMFD metodu koja kombinuje *Zernike Moments*, PCT i FMT, kako bi se otkrila klonirana područja. U drugom koraku, koriste se odabrane karakteristike koje naknadno otkrivaju područja koja *copy-move* metoda nije otkrila. Za pronalaženje najbližih suseda koristi se modifikovani algoritam spajanja putanja (*Patch-Match*). U [WAN18a], predložena je metoda koja prvo sliku od interesa deli na nepreklapajuće delove nepravilnog oblika, u različitim skalama. Zatim se na svaki deo primenjuje SIFT, za izdvajanje karakterističnih tačaka. Za detekciju sumnjivih regiona,

koristi se adaptivni algoritam za uparivanje putanja (*Adaptive Patch Matching*). Konačno, sumnjive tačke se spajaju linijama kako bi se vizuelizovali falsifikovani delovi. Metoda zasnovana na LBCE opisana je u [BI18a]. Naime, prvo se usvaja *hash* metoda koja je osetljiva na koherentnost, kako bi se ustanovila koherencija karakteristika u slici. Zatim se koristi LBCE kako bi se poboljšala koherencija između karakteristika preko brojnih iteracija. Kada varijacija LBCE slike nije veća od određenog praga, iterativni proces prestaje, i ukazuje da je poklapanje karakteristika stabilno. Na kraju, falsifikovanje se određuje primenom LBCE na svaku od karakteristika. U [YAN18], opisana je *keypoint-based* metoda zasnovana na unapređenom SIFT. Slika od interesa se prvo prevodi u *grayscale*. Zatim se koristi unapređeni SIFT algoritam za izdvajanje ključnih tačaka. Za uparivanje ključnih tačaka, koristi se AHC algoritam. Za slike koje su komprimovane sa visokim stepenom kompresije sa gubicima, predložena je *keypoint-based* metoda zasnovana na analizi nivoa grešaka (*Error Level Analysis - ELA*) [JER17]. Sa ELA, komprimovana slika se dekomprimuje sa poznatim nivoom greške, i računa se razlika između originalne i dekomprimovane slike, poznata kao nivoi grešaka. Komponente šuma se uklanjuju sa automatskim talasnim mekim pragom. Za detekciju falsifikovanih regiona, primenjuju se Dobiši (*Daubechies*) talasići sa semi-automatskim određivanjem praga. U [BEN16] je opisana *keypoint-based* metoda zasnovana na vodenom žigu. Naime, binarni vodeni žig se konstruiše iz same slike koja se razmatra, tako da svaka slika ima jedinstven vodeni žig, što omogućava detekciju falsifikovanja. Metoda se pokazala kao dobra u različitim uslovima falsifikovanja.

Metoda zasnovana na hijerarhijskom uparivanju karakteristika i višenivovskom opisivanju gustina (*Multi Level Dense Descriptor - MLDD*) opisana je u [BI16]. Pomoću MLDD se izdvajaju deskriptori koji se sastoje iz dva dela: deskriptor tekstura u boji (*Color Texture Descriptor*) i invarijantni deskriptor momenata (*Invariant Moment Descriptor*). Nakon računanja deskriptora, hijerarhijsko uparivanje karakteristika (*Hierarchical Feature Matching*) se koristi za uparivanje deskriptora i detekciju falsifikovanja. Pregled i analiza postojećih *keypoint-based* metoda su dati u [CHA16]. U [GAN16] predložena je *keypoint-based* metoda zasnovana na analitičkoj Furijeovoj-Melinovoj transformaciji (*Analytic Fourier Mellin Transform - AFMT*). Na sliku od interesa se primenju AFMT, u cilju

izdvajanja karakteristika. AFMT je pogodna jer je otporna na operacije rotacije i skaliranja. Za poređenje karakteristika i detekciju falsifikovanja, koristi se *Pirsonov* koeficijent korelacije između karakteristika. Metoda zasnovana na primeni SURF algoritma, predložena je i opisana u [GON16]. Slika od interesa se prvo prevodi u novi sistem boja, i računa se gradijent boja za svaki piksel. Zatim se primenjuje SURF algoritam, za izdvajanje karakterističnih tačaka. Za uparivanje tačaka i detekciju falsifikata koristi se metoda klasterovanja. U [HUA17] opisana je metoda koja uspešno vrši detekciju falsifikata pod jakim JPEG kompresijama. Metoda se zasniva na kombinaciji FFT, SVD i PCA, za izdvajanje karakterističnih vektora. Za poklapanje vektora koristi se kaskadno uparivanje. Metoda daje visoku preciznost detekcije, i karakteristični vektor se sastoji od samo jedne promenljive. Metoda zasnovana na statističkim momentima i dvodimenzionalnoj DCT predstavljena je u [KAU15]. Oko svakog piksela slike se formira centrirani prozor koji klizi, i računa se DCT kako bi se dobila matrica kvantizacionih koeficijenata. Za svaku matricu se određuje karakteristični vektor koji se sastoji od četiri parametra: srednje vrednosti, varijanse, momenta trećeg reda i momenta četvrtog reda. Vektori se porede na osnovu Euklidskog rastojanja između njih, i najbliži susedi se smatraju sličnim ili istim, odnosno na taj način se detektuje falsifikovanje.

U [LIN16] je opisana *keypoint-based* metoda zasnova na DCT, koja daje dobre rezultate pri velikim stepenima JPEG kompresije. Za računanje deskriptora autori koriste DCT. Kvantizacioni koeficijenti se porede na osnovu korelacionih koeficijenata, i na taj način se određuju falsifikovana područja. *Keypoint-based* metoda zasnovana na upravljačkoj piramidalnoj transformaciji (*Steerable Pyramid Transform - SPT*) i lokalnim binarnim oblicima (*Local Binary Pattern - LBP*) je detaljno opisana u [MUH14]. Slika se prvo iz RGB prevodi u YC<sub>b</sub>C<sub>r</sub> sistem boja. Zatim se primenjuje SPT na hrominentne kanale C<sub>b</sub> i C<sub>r</sub>, i izdvajaju se multi-skalirajući i multi-orientisani podopsezi. Tekstura u svakom podopsegu SPT se opisuje koristeći LBP histograme, koji generišu karakteristične vektore. Za klasifikaciju falsifikovanih i originalnih delova, autori koriste SVM. U [HU16], se predlaže aktivna metoda zasnovana na vodenom žigu i „*alpha mattes*<sup>2</sup>“. Za ugrađivanje

---

<sup>2</sup> *Vodeni žig koji se izdvaja iz postojeće slike*

vodenog žiga koriste se DWT, DCT i SVD. Za poređenje i detekciju falsifikata, koristi se razlika između dobijenih SVD vrednosti. Detaljan pregled *keypoint* metoda koje koriste SIFT i SURF algoritme za izdvajanje karakteristika je dat u [WAR16a, WAR16b]. U [CHA16] je prikazan detaljan pregled postojećih metoda za detekciju *copy-move* promena na slikama. *Keypoint-based* metoda zasnovana na KAZE (japanska reč, u prevodu vetar) i SIFT algoritmu je opisana u [YAN17]. Ključne tačke se opisuju hibridnim karakteristikama, koje se dobijaju primenom kombinacije KAZE i SIFT algoritama. Za detekciju uparivanja i falsifikovanja, autori koriste Euklidsko rastojanje između KAZE deskriptora, i porede ih prema algoritmu dva najbliža suseda (*2 Nearest Neighbors - 2NN*). U [ALK16] je opisana *keypoint-based* metoda zasnovana na diskretnoj analitičkoj Furijeovoj-Melinovoj transformaciji (*Discrete Analytical Fourier-Mellin Transform - DAFMT*). Slika se iz RGB prevodi u *grayscale*, a zatim se primenjuje DAFMT u cilju izdvajanja deskriptora. DAFTM deskriptori se leksikografski sortiraju i porede koristeći Spearmanov rank (*Spearman rank*) koeficijente korelacijske.

Metoda zasnovana na diskretnoj radon polarnoj eksponencijalnoj transformaciji (*Discrete Radon Polar Complex Exponential Transform - DRPCET*) je opisana u [ZHO17b]. Za izdvajanje deskriptora koristi se DRPCET algoritam, koji nastaje kombinacijom radon transformacije (*Radon transform - RT*) i PCET. Deskriptori se zatim leksikografski sortiraju, i porede pomoću koeficijenata korelacijske.

U [ZH016] je predstavljena *keypoint-based* metoda zasnovana na korišćenju karakteristika iz ubrzanog testa segmentacije (*Features from Accelerated Segment Test - FAST*) i orijentisanom ubrzanom testu segmentacije (*Oriented FAST and Rotated BRIEF - ORB*). Za izdvajanje ključnih tačaka koristi se FAST algoritam. Na izdvojene ključne tačke se primenjuje ORB, za izdvajanje deskriptora. Deskriptori se porede računanjem Hemingovog rastojanja između njih, i na taj način se detektuje falsifikovanje. Lažni falsifikati se uklanjaju primenom konsenzus slučajnog uzorka (*Random sample consensus – RANSAC*) algoritma.

### 2.1.2 Metode zasnovane na podeli na blokove (*block-based* metode)

U [MAH18] se predlaže metoda koja prvo RGB sliku prevodi u  $YC_bC_r$  sistem. Slika se zatim deli na blokove, i na svaki blok se primenjuje DWT, za izdvajanje karakteristika. Za smanjenje dimenzija karakterističnih vektora koristi se  $8 \times 8$  DCT. Zatim se računaju rastojanja između karakteristika blokova, i ukoliko su ta rastojanja manja od praga, blokovi se smatraju sličnim ili istim. *Block-based* metoda zasnovana na invarijantnim kvaternarnim eksponencijalnim momentima (*Quaternion Exponent Moments* - QEMs) je opisana u [WAN18a]. Slika od interesa se prvo propušta kroz niskopropusni Gausov filter. Zatim se deli na preklapajuće kružne blokove. Za svaki blok se izdvaja karakteristični vektor, korišćenjem deskriptora QEMs. Za uparivanje blokova i detekciju falsifikovanja koristi se Euklidsko rastojanje između vektora. U [HAY17] predložena je *block-based* metoda zasnovana na DWT i DCT. Slika se nakon predprocesiranja deli na preklapajuće blokove. Za izdvajanje karakteristika bloka, autori koriste DWT. Nakon primenjene DWT, naknadno se primenjuje DCT, u cilju smanjenja dimenzionalnosti karakterističnog vektora. Blokovi se zatim porede na osnovu korelacionih koeficijenata, i na taj način se pronalaze slični blokovi. *Block-based* metoda zasnovana na primeni LBP i DCT je opisana u [ALA17]. Slika od interesa se prvo prevodi iz RGB u  $YC_bC_r$  sistem boja, a zatim se deli na preklapajuće blokove. Za izdvajanje karakterističnih vektora, na blokove se prvo primenjuje LBP, a zatim DCT. Za uparivanje karakterističnih vektora i detekciju falsifikovanja, koristi se mašina za podržavanje vektora (*Support Vector Machine* - SVM).

U [OOM16] predložena je *block-based* metoda zasnovana na lokalnoj fraktalnoj dimenziji (*Local Fractal Dimension* - LFD). Slika se prvo deli na blokove fiksnih dimenzija, i za svaki blok se računa lokalna fraktalna dimenzija, kao karakteristika bloka. U cilju smanjenja kompleksnosti, karakteristike se organizuju prema B+ drvetu. Za uparivanje karakteristika i detekciju falsifikata, autori koriste SVD. Metoda zasnovana na fraktalnom kodovanju je opisana u [JEN16]. Slika od interesa se deli na preklapajuće blokove. Za svaki blok se računa karakteristični vektor koji se sastoji od četiri parametra: multifraktalne dimenzije, srednje vrednosti, varijanse i centralnog momenta. Karakteristični vektori se porede na osnovu Euklidskog rastojanja, i na taj način se određuju slični ili isti blokovi. U [EMA16] je opisana *block-based* metoda zasnovana na polarnoj eksponencijalnoj transformaciji (*Polar Complex Exponential Transform* – PCET) i aproksimativno najbližem

susedu (*Approximate Nearest Neighbor* – ANN). Slika od interesa se deli na preklapajuće blokove kružnog oblika. Za svaki blok se računa karakteristični vektor na osnovu primene PCET. Za uparivanje karakteristika i detekciju falsifikovanja koristi se ANN algoritam, na bazi LSH.

Metoda zasnovana na algoritmu histogramu gradijenata (*Histogram of Gradient* - HoG) je data u [LEE15]. Naime, slika od interesa se prevodi iz RGB u *grayscale*, i deli na preklapajuće blokove fiksnih dimenzija. Na svaki blok se primenjuje HoG, za izdvajanje deskriptora blokova. Za poređenje i uparivanje blokova, računa se Euklidsko rastojanje između deskriptora blokova, i ukoliko je ono manje od određenog praga, blokovi se smatraju sličnim. U [MAL16] opisana je *block-based* metoda zasnovana na automatskom koreogramu boja (*Auto Color Correlogram* - ACC). Slika se prvo filtrira niskopropusnim filtrom, a zatim deli na blokove. Na svaki blok se primenjuje *8Z Affine*<sup>3</sup> transformacija. Nakon toga, izdvajanje deskriptora za svaki blok se vrši pomoću ACC. Za poklapanje blokova i detekciju falsifikata, računa se Menhetn<sup>4</sup> rastojanje između deskriptora blokova. *Block-based* metoda zasnovana na PCA i DCT je predstavljena u [SHI15]. Slika od interesa se prevodi iz RGB u *grayscale*, i deli na preklapajuće blokove. Na svaki blok se primenjuje PCA i DCT, za generisanje deskriptora blokova. Između deskriptora se računa amplitudski offset, i ukoliko je veći od određenog praga, blokovi se smatraju sličnim.

U [UST16], opisana je *block-based* metoda sa automatskim određivanjem praga sličnosti. Slika se iz RGB prevodi u YC<sub>b</sub>C<sub>r</sub> sistem, a zatim deli na preklapajuće blokove. Na svaki blok se primenjuje DCT i cik-cak skeniranje, u cilju izdvajanja karakterističnog vektora. Vektori se porede elemenat-po elemenat, a prag sličnosti se automatski određuje, na osnovu karakteristika slike koja se testira. *Block-based* metoda zasnovana na inteligenciji roja (*Swarm Intelligent* - SI) i SIFT algoritmima je opisana u [ZHA17]. Slika se prevodi iz RGB u *grayscale*, a zatim deli na nepreklopajuće blokove. Za svaki blok se računa karakteristični vektor, koji se naziva stepen glatkoće (*smooth degree* - SD) i koji predstavlja količnik standardne devijacije bloka i maksimalne standardne devijacije.

---

<sup>3</sup> Podrazumeva rotaciju, skaliranje, refleksiju, rotaciju, i drugo

<sup>4</sup> Zbir horizontalnih i vertikalnih rastojanja između tačaka na mreži.

Detekcija falsifikovanja i uparivanje sličnih blokova se vrši primenom SI algoritma i SIFT algoritma.

U [CHO17] je opisana pasivna *block-based* metoda zasnovana na lokalnim Gaborovim talasnim oblicima (*Local Gabor Wavelets Patterns* - LGWP), koja u kombinaciji sa LBP daje dobre performanse u analizi slika sa teksturama, kao i delovima koji su rotirani. Metoda omogućava detekciju duplicitarnih regiona čak i u slučaju JPEG kompresije, kao i prilagođenja osvetljenja i zamagljenja. Metoda za detekciju *copy-move* promena, koja je fuzija radijalnih harmoničkih Furijeovih momenata (*Radial Harmonic Fourier Moments* - RHFM) i SIFT algoritma je opisana u [GAN18]. Prvo se primenjuje SIFT algoritam za izdvajanje karakterističnih vektora, za svaki blok, u fazi predprocesiranja. Za pronalaženje sličnih vektora i uklanjanje lažnih kandidata autori koriste 2NN test, adaptivno Euklidsko rastojanje i RANSAC.

U [ZHO17a] predložena je metoda zasnovana na diskretnim radijalnim harmoničkim Furijeovim momentima (*Discrete Radial Harmonic Fourier Moments* - DRHFM). Posle predprocesiranja, slika se deli u preklapajuće kružne blokove. Za izdvajanje karakteristika blokova koristi se DRHFM. Za pronalaženje sličnih oblika, koristi se 2NN test. Na kraju, za uklanjanje lažnih kandidata, autori koriste Euklidsko rastojanje i koreacione koeficijente.



### 3. Multifraktalna teorija

Mnogi autori su koristili koncept fraktala i multifraktala za opisivanje i segmentaciju slike. U [VEH92] predložene su neke, tada nove ideje za analizu slika korišćenjem multifraktala i tekstura. Dat je opis multifraktalne teorije kao i njene primene na opisivanje slike, i pokazano je da se multifraktalna analiza može primeniti direktno na diskretne signale. Zatim je predstavljen algoritam za klasifikaciju tekture, koji se zasniva na šemama učenja. Poslednji deo tog rada se odnosi na segmentaciju slike, i pokazano je da ovaj algoritam može uspešno da razdvoji ivice objekata kod slika koje su složenijeg sadržaja. Metoda za multifraktalnu analizu *grayscale* slika, sa posebnim osvrtom na medicinske slike, opisana je u [RELJ00]. Preko analize multifraktalnog spektra slike, može se doći do globalnih i lokalnih regularnosti slike. Uz pomoć različitih vrednosti fraktalne dimenzije, mogu se detektovati različiti delovi slike. Pokazano je da se multifraktali mogu uspešno koristiti za globalnu analizu slike, detekciju ivica, segmentaciju, klasifikaciju tekstura, itd.

U [SAL17] je detaljno opisana multifraktalna metodologija. Poseban osvrt je dat na četiri metode: moment metoda, histogram metoda, multifraktalna analiza fluktuacije detrendi (*Multifractal Detrended Fluctuation Analysis - MDFA*) i talasna transformacija modula maksimuma (*Wavelet Transform Modulus Maxima - WTMM*). Metoda momenta i

histogram metoda su pogodne za prostorno raspodeljene podatke, dok su MDFA i WTMM metode pogodne za jednodimenzionalne vremenske serije. Multifraktalnost se može uspešno koristiti za analizu lokalne i globalne kompleksnosti podataka.

Pregled metoda za izdvajanje frakタルih i multifrakタルih dimenzija, koje se mogu koristiti u analizi 1D, 2D i 3D medicinskih signala, dat je u [LOP09]. Analiza se zasniva na opisu sledećih metoda: prebrojavanju bokseva (*Box-counting* - BC), diferencijalna metoda prebrojavanja bokseva (*Differential box-counting method* - DBCM), “proširena metoda prebrojavanja” (“*Extended counting*” method - XCM), frakcioni Braunovski pokret (*Fractional Brownian motion methods* – *fBm*), metoda variograma (*Variogram method*), kvadratni spektar (*The power spectrum*), metoda merenja oblasti (*Area measurement method*), blanket metoda (*Blanket method* - BM), isaritmi metoda (*Isarithm method* - IM), kao i trouglasta prizma metoda (*Triangular prism method* - TPM). Za računanje multifrakタルnog spektra, opisane su sledeće metode: metode brojanja bokseva (*Box-counting methods*), multifrakタルni spektar velike devijacije (*large-deviation multifractal spectrum*), metoda talasića (*Wavelet methods*), WTMM metoda, i metoda lidera talasića (*wavelet leaders method*).

U [HAR14] predstavljena je karakterizacija tekstura pomoću multifrakタルa. Naime, predložene su dve različite metode za estimaciju multifrakタルnog spektra. Prva metoda se bazira na Ležandrovoj (*Legendre*) transformaciji, dok je druga metoda direktna metoda zasnovana na *box-counting* aplikaciji. Za obe metode, autori koriste multirezolucione talasne koeficijente. *Legendre* transformacija se koristi za estimaciju spektra, dok se *box-counting* metoda koristi za računanje *Hausdorf* dimenzija skupa sa istim stepenom singulariteta. Predložene metode se uglavnom koriste za klasifikaciju *Brodatz*<sup>5</sup> tekstura, u multifrakタルnoj analizi, za klasifikaciju različitih objekata, računanjem lokalnih singulariteta. Jedan od glavnih statističkih parametara samosličnosti jeste Hölder-ov eksponent ( $\alpha$ ), koji predstavlja zakon raspodele snage u okolini piksela. Raspodela Hölder-ovih eksponenta daje multifrakタルni spektar, koji se može koristiti kao karakteristični deskriptor za klasifikaciju, posebno histopatoloških slika. Metoda za analizu slika

---

<sup>5</sup> Slike karakterističnih tekstura

zasnovana na multifraktalima je opisana u [VEH94]. Svaka tačka slike se klasificuje na osnovu dva parametra, tipa singulariteta i njegove relativne visine, računanjem spektara različitih kapaciteta koji su izdvojeni iz nivoa sivog slike. U [IBR14] je predstavljen multifraktalni pristup za klasifikaciju uzoraka računanjem lokalnih singulariteta slike. Jedna od osnovnih mera samosličnosti koja se koristi u obradi slike jeste raspodela  $\alpha$  singulariteta u lokalnim okruženjima piksela. Raspodela tih singulariteta predstavlja multifraktalni spektar koji se može koristiti kao deskriptor za klasifikaciju. Eksperimentalni rezultati su pokazali da se multifraktalni spektar može uspešno korisiti za klasifikaciju histopataloških slika. Novi način za analizu karakteristika slike zasnovan na fraktalnoj dimenziji i multifraktalnom spektru je predstavljen u [LAM10]. Dat je kratak opis fraktalne teorije i karakteristična analiza digitalne slike. Opisan je algoritam za računanje fraktalne dimenzije i multifraktalnog spektra zasnovan na *box-counting* metodi. Program je napisan u programskom paketu Matlab. Pokazano je da se predloženi algoritam može uspešno koristiti za analizu karakterističnih površina slike.

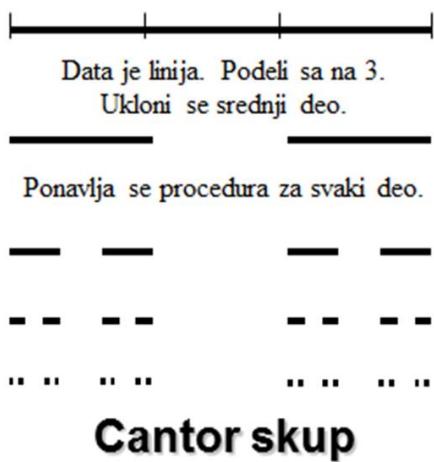
### 3.1 Principijelni koncept fraktalne teorije i samosličnih procesa

B. Mandelbrot je 1975. uveo pojam “*fractal*” za numeričko opisivanje objekata koji imaju strogo neregularnu formu kao što su površine, linije, i tela u prostoru. Ovi objekti mogu posedovati osobinu samosličnosti. Jedan od karakterističnih primera jeste izračunavanje dužine obale Velike Britanije. U zavisnosti od dimenzija mernih jedinica, dobija se različita dužina obale. Ukoliko se koriste manje merne jedinice, obala postaje sve duža. Morska obala pokazuje klasično frakтално svojstvo: uvećanjem dela obale prikazuje se uvek sličan oblik oblik, tako da je on (skoro) isti u različitim skalama posmatranja. Termin “*fractal*” potiče od latinske reči *fractus* što znači slomljen, prelomljen [OLE07]. U suprotnosti sa tradicionalnom Euklidskom dimenzijom, frakタルni objekti imaju beskonačnu dužinu. Kako fraktali imaju osobinu samosličnosti, oni su uglavnom uniformno raspoređeni u širokom opsegu, tako da postoji karakteristična sličnost fraktala u različitim skalamama posmatranja. U idealnom slučaju su frakタルni objekti nezavisni od skale u kojoj se posmatraju. Međutim, to važi samo za determinističke fraktele, odnosno za fraktele koji su

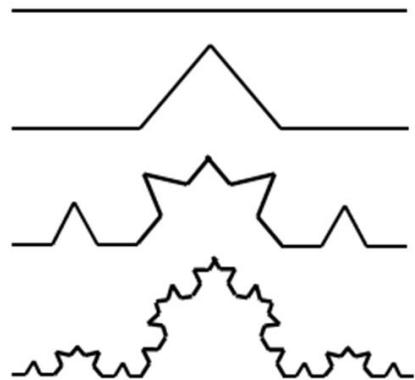
veštački generisani. Prirodni fraktali pokazuju samosličnost do određene granice. Nakon te granice, više nisu fraktali. To su tzv. prirodni ili slučajni fraktali [OLE07]. Na slici 3.1 možemo videti primere prirodnih fraktala. Iskazuju samosličnost u statističkom smislu, do određene granice skale, posle čega više nisu fraktali. Primeri prirodnih fraktala jesu građa drveta, nervni sistem čoveka, karfiol, itd. Striktno samoslični objekti (deterministički fraktali su Kantor set, *Von Koch*-ove krive, Sierpinski tepih, ...) imaju istu fraktalnu dimenziju u svim skalama [OLE07, RELJ15a, RELJ15b]. Oni su poznati i kao monofraktali. Primeri determinističkih monofraktala su dati na slikama 3.2 i 3.3.



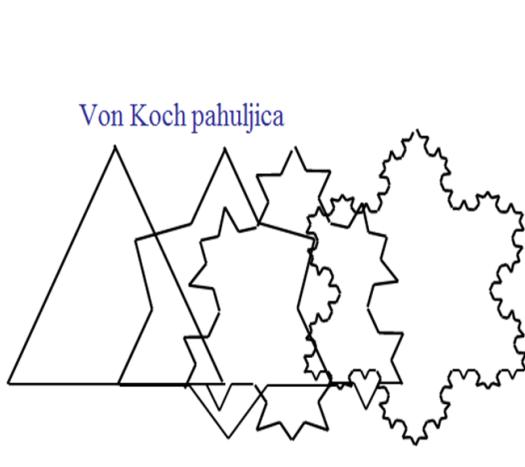
Slika 3.1 Primeri prirodnih fraktala [RELJ15a, RELJ15b].



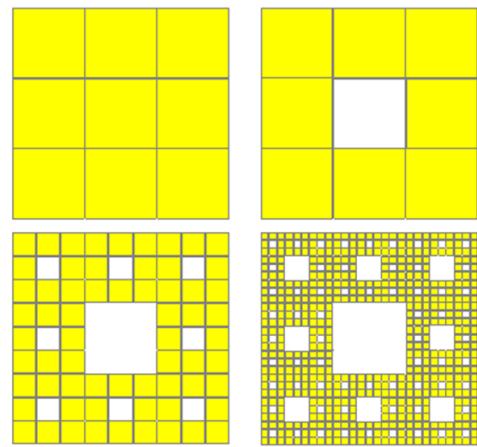
Von Koch kriva



Slika 3.2 Primeri determinističkih monofraktala -1 [RELJ15a, RELJ15b].



Sierpinskij tepih



Slika 3.3 Primeri determinističkih monofraktala -2 [RELJ15a, RELJ15b].

### 3.1.1 Skup frakタルnih dimenzija

Fraktali se opisuju parametrom koji se naziva frakタルna dimenzija. Prema algoritmu za određivanje Hausdorff dimenzije  $D_f$  skupa zauzetih površina zapreminom  $L^{D_f}$  u D-dimenzionalnom prostoru, ovaj skup se prekriva kockicama zapremine  $\varepsilon^{D_f}$  [GRA83]. Minimalan broj kockica (koje nisu prazne) koje prekrivaju skup je  $M(\varepsilon) = L^{D_f} (1/\varepsilon)^{D_f}$ . Iz ove jednačine se može izraziti frakタルna dimenzija kao [OLE07]

$$D_f = \lim_{\varepsilon \rightarrow 0} \left[ \frac{\ln M(\varepsilon)}{\ln(1/\varepsilon)} \right] \quad (3.1)$$

U praksi je prikladnije koristiti matematičku strukturu poznatu kao *Reney dimenzija*  $D_q$ , za estimaciju fraktalne dimenzije. Ona je povezana sa verovatnoćom  $p^i$  prisustva test tačaka u  $i$ -toj ćeliji sa eksponentom  $q$  [OLE07]

$$D_q = \lim_{l \rightarrow 0} \left( \frac{1}{1-q} \right) \frac{\ln \left[ \sum_{i=0}^{M(t)} p(\varepsilon)_i^q \right]}{\ln \varepsilon}, \quad q = 0, 1, 2, \dots \quad (3.2)$$

Ukoliko  $q \rightarrow 0$ , koristeći jednačinu (3.2) dobijamo

$$D_0 = \lim_{\varepsilon \rightarrow 0} \frac{\ln \left( \sum_{i=1}^{M(t)} 1 \right)}{\ln \varepsilon} = - \lim_{\varepsilon \rightarrow 0} \frac{\ln M(\varepsilon)}{\ln \varepsilon} = D_f \quad (3.3)$$

tj. *Reney dimenzija* se poklapa sa Hausdorff dimenzijom. Kako je  $D_q$  motona funkcija  $q$ , *Reney dimenzija* se smanjuje po kvadratnom zakonu. Na osnovu toga, zadovoljena je sledeća nejednakost:  $D_2 \leq D_0 = D$ . U skladu sa tim, najmanja donja granična vrednost Hausdorff dimenzije se može prikazati kao [OLE07]:

$$D_2 = \lim_{l \rightarrow 0} \frac{\left[ \sum_{i=1}^{M(t)} p(\varepsilon)_i^2 \right]}{\ln \varepsilon} \quad (3.4)$$

Kada se to uzme u obzir, verovatnoća  $p_i$  test tačke u prisustvu  $i$ -tog skupa se može predstaviti kao

$$p_i(\varepsilon) = \lim_{N \rightarrow \infty} \frac{N_i(\varepsilon)}{N} \quad (3.5)$$

gde je  $N$  ukupan broj test tačaka preko intervala  $I/L$ , dok je  $N_i$  broj tačaka u  $i$ -tom skupu [OLE07].

### 3.1.2 Metoda zasnovana na boksevima (*Box-counting method*)

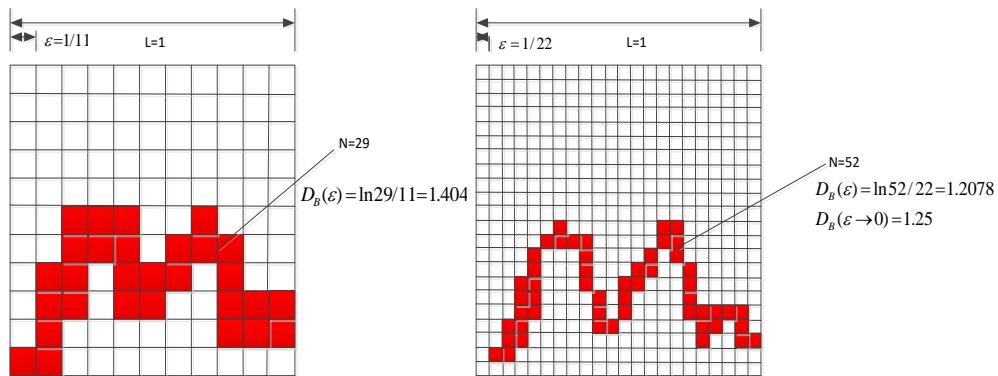
Fraktalna dimenzija koja je najjednostavnija za računanje jeste takozvana boks dimenzija fraktala. Fraktal se prekrije mrežom bokseva: kvadratima (za fraktalne linije), ili

kockama (za fraktalne površine), sa stranicama  $\varepsilon$ , i broje se boksevi koji nisu prazni,  $N(\varepsilon)$  [RElj15a, RELj15b, RELj02] (Slika 3.4).

Boks-dimenzija se računa kao

$$D_B = -\lim(\ln(N(\varepsilon)) / \ln \varepsilon) \quad (3.6)$$

pod uslovom da  $\varepsilon \rightarrow 0$ .



Slika 3.4 Računanje boks-dimenzije.

Korišćenjem manjih bokseva dobija se preciznija dimenzija.

## 3.2 Multifraktali

U svakodnevnom životu, realne pojave se ne mogu izraziti samo pomoću dva stanja: da-ne, 0-1, crno-belo, toplo-hladno i slično. Takve pojave traže detaljnije deskriptore kako bi se opisale vrednosti između donjih i gornjih granica. Kao što klasična geometrija nije bila u mogućnosti da opiše prirodne objekte (oblik i dužina morske obale), što je omogućila fraktalna geometrija, i kod fraktalne geometrije postoje ograničenja u opisivanju složenih pojava. Prirodni fraktali, za razliku od determinističkih fraktala, imaju različitu fraktalnu dimenziju pri različitim skalama. Mogu se uočiti podskupovi, unutar fraktala, koji imaju istu fraktalnu dimenziju. U tom slučaju govorimo o multifraktalima, odnosno, o traženju fraktala unutar fraktalne strukture [OLE07, RELj15a, RELj15b], i može se tražiti raspodela tih fraktalnih dimenzija. Kvantitativni opis multifraktalnih svojstava se može vršiti na razne načine. Razlikuju se od matematičkih fraktala:

- Nisu striktno samo-slični već u statističkom smislu,
- Postoji granica skale, sa gornje i donje strane, preko koje to nije više fraktal [OLE07, RELJ15a, RELJ15b].

Multifraktali su heterogeni fraktalni objekti. Kod njih nije dovoljno da se predstavi samo jedna veličina, kao u slučaju fraktala (fraktalna dimenzija), već je potrebno dati čitav spektar dimenzija. U opštem slučaju, broj tih dimenzija je beskonačan. Razlog tome leži u činjenici da ovi fraktali, zajedno sa čisto geometrijskim karakteristikama koje su definisane veličinom  $D_f$ , imaju određena statistička svojstva [OLE07, RELJ15a, RELJ15b].

Multifraktalni objekti se mogu opisati sa sledeći način:

Za fraktalni objekat se podrazumeva da obuhvata ograničenu površinu definisanu sa  $L$  u Euklidskom prostoru sa dimenzijom  $D$ . Fraktal se predstavlja skupom od  $N \gg 1$  tačaka koje su u ovoj oblasti raspoređene na određeni način, u fazi formiranja. Prepostavlja se da  $N \rightarrow \infty$ . Cela površina se deli na ćelije stranice  $l \ll L$  koje se prekrivaju  $\varepsilon^D$  jedinicama. Samo zauzete ćelije se razmatraju, u kojima je sadržana najmanje jedna od  $K$  tačaka koje pripadaju fraktalu. Recimo, indeks zauzetih ćelija  $i$  se menja od  $i = 1, 2, \dots, N(\varepsilon)$ , gde je  $N(\varepsilon)$  ukupan broj zauzetih ćelija [OLE07, RELJ15a, RELJ15b]. Prepostavljajući da je  $N_i(\varepsilon)$  broj tačaka u ćeliji sa indeksom  $i$ , dolazi se do zaključka da veličina

$$p_i(\varepsilon) = \lim_{K \rightarrow \infty} \frac{N_i(\varepsilon)}{K} \quad (3.7)$$

predstavlja verovatnoću da se tačka izabrana proizvoljno iz skupa nalazi u ćeliji  $i$ . U skladu sa normalizacijom verovatnoće, važi da je  $\sum_{i=1}^{N(\varepsilon)} p_i(\varepsilon) = 1$ . Generalizovana statistička suma  $Z(q, \varepsilon)$ , opisana eksponentom  $q$ , koji može imati sve vrednosti u intervalu  $-\infty < q < +\infty$  se definiše kao:

$$Z(q, \varepsilon) = \sum_{i=1}^{N(\varepsilon)} p_i^q(\varepsilon) \quad (3.8)$$

Definicija 1

Skup vrednosti

$$D_q = \frac{\tau(q)}{q-1} \quad (3.9)$$

gde

$$\tau(q) = \lim_{\varepsilon \rightarrow 0} \frac{\ln Z(q, \varepsilon)}{\ln \varepsilon} \quad (3.10)$$

se može nazvati spektar generalizovane *Reney* fraktalne dimenzije  $D_q$  koja opisuje raspodelu tačaka u površini [OLE07].

Ako je  $D_q = D_f = \text{const}$ , odnosno ako ne zavisi od  $q$ , dati skup tačaka predstavlja normalan regularan fraktal, koji se može definisati samo frakタルnom dimenzijom  $D_f$ . Nasuprot tome, ako se funkcija  $D_q$  menja sa  $q$ , skup tačaka koji se razmatra se posmatra kao multifraktal. Stoga, multifraktele možemo u opštem slučaju opisati kao neku nelinearnu funkciju  $\tau(q)$  koja definiše ponašanje statističke sume  $Z(q, \varepsilon)$  kada  $\varepsilon \rightarrow 0$  [OLE07]:

$$Z(q, \varepsilon) = \sum_{i=1}^{N(\varepsilon)} p_i^q(\varepsilon) \approx \varepsilon^{\tau(q)} \quad (3.11)$$

Ponašanje generalizovane statističke sume, u slučaju da je broj tačaka  $n_i(\varepsilon) = N/N(\varepsilon)$

jednak u svim zauzetim celijama  $p(\varepsilon) = 1/N(\varepsilon)$ , odnosno da je fraktal homogen postaje

$$Z(q, \varepsilon) = N^{1-q}(\varepsilon) \quad (3.12)$$

Jasno je da prema definiciji frakタルne dimenzije  $D_f$ , broj zauzetih celija za dovoljno malo  $\varepsilon$  postaje

$$N(\varepsilon) \approx \varepsilon^{-D_f} \quad (3.13)$$

Zamenjujući to u jednačinu (3.12) i upoređujući sa jednačinom (3.10) dobijamo da je u slučaju regularnog frakタルa funkcija  $\tau(q) = (q-1)D_f$  linearна. U tom slučaju su svi  $D_q=q$  i  $D_q$  u stvari ne zavisi od  $q$ . U tom slučaju fraktele za koje važi ova generalizovana vrednost  $D_q$  zovemo monofraktali [OLE07].

Ako raspodela tačaka duž celija nije ista, frakタルi postaju heterogeni, tj predstavljaju multifraktele. Za njihovo predstavljanje neophodno je poznavati čitav spektar

generalizovanih fraktalnih dimenzija  $D_q$ , broj koji je u opštem slučaju beskonačan. Stoga, za određivanje raspodele tačaka treba definisati i izvod funkcije  $\tau(q)$ , koji se računa direktno iz jednačine

$$\frac{d\tau(q)}{dq} = \lim_{\varepsilon \rightarrow 0} \frac{\sum_{i=1}^{N(\varepsilon)} p_i^q \ln p_i}{(\sum_{i=1}^{N(\varepsilon)} p_i^q) \ln \varepsilon} \quad (3.14)$$

Ukoliko ovaj izvod nije konstanta i ako se menja sa  $q$ , onda se radi o multifraktalu.

### 3.2.1 Fraktalna dimenzija $D_0$ i informaciona dimenzija $D_1$

Fizički smisao generalizovane fraktalne dimenzije  $D_q$  se može ispitati za različite vrednosti  $q$ . Za  $q=0$ , iz jednačine (3.12) sledi da je  $Z(0, \varepsilon) = N(\varepsilon)$ . Sa druge strane

$$Z(0, \varepsilon) \approx \varepsilon^{\tau(0)} = \varepsilon^{-D_0} \quad (3.15)$$

tako da dolazimo do  $N(\varepsilon) \approx \varepsilon^{-D_0}$ . To znači da  $D_0$  predstavlja uobičajeno Hausdorff dimenziju skupa, koja ne obezbeđuje informaciju o njenim statističkim osobinama i predstavlja grubu fraktalnu karakteristiku. U fizičkom smislu veličina  $D_1$  se može predstaviti kao [OLE07]

$$D_1 = \lim_{\varepsilon \rightarrow 0} \frac{\sum_{i=1}^{N(\varepsilon)} p_i \ln p_i}{\ln \varepsilon} \quad (3.16)$$

Brojilac ove jednačine predstavlja entropiju  $S(\varepsilon)$  fraktalnog skupa:  $S(\varepsilon) = -\sum_{i=1}^{N(\varepsilon)} p_i \ln p_i$ .

Kao rezultat, generalizovana fraktalna dimenzija  $D_1$  je povezana sa entropijom  $S(\varepsilon)$  [OLE07]

$$D_1 = -\lim_{\varepsilon \rightarrow 0} \frac{S(\varepsilon)}{\ln \varepsilon} \quad (3.17)$$

Na osnovu sličnog razmatranja, Šenon je generalizovao koncept entropije  $S$  za probleme prenosa informacija. Za te probleme entropija postaje veličina mere količine informacije koja je potrebna za opisivanje sistema u nekoj  $i$ -toj fazi. Vraćajući se na početni problem raspodele tačaka u fraktalnom skupu, moguće je zaključiti da [OLE07]

$$S(\varepsilon) \approx \varepsilon^{-D_1} \quad (3.18)$$

Gde  $D_1$  veličina karakteriše informaciju koja je potrebna za određivanje lokacije tačke u nekoj čeliji. Tada se generalizovana fraktalna dimezija često naziva informaciona dimenzija. Ona pokazuje kako se informacija uvećava kada veličina čelije  $\varepsilon$  teži nuli [OLE07].

### 3.2.2 Osobine funkcije $D_q$

Multifraktali se opisuju heterogenom raspodelom tačaka duž čelija. Naročito, ako su tačke koje čine multifraktal raspoređene uniformno preko svih  $N(\varepsilon)$  čelija, sa verovatnoćom  $p_i = 1/N(\varepsilon)$ , entropija će biti maksimalna i jednaka

$$S_{max}(\varepsilon) = -\sum_{i=1}^{N(\varepsilon)} p_i \ln p_i = \ln N(\varepsilon) \approx -D_0 \ln \varepsilon \quad (3.19)$$

Drugim rečima, biće veća od stvarne fraktalne energije izračunate za pravu heterogenu raspodelu tačaka  $S(\varepsilon) = -D_1 \ln \varepsilon$ . Prema tome, informaciona dimenzija multifraktala je uvek manja ili jednakoj njegovoj Hausdorff dimenziji  $D_0$ . Ova nejednačina se može generalizovati za proizvoljan eksponent  $q$  i može se dokazati da generalizovana fraktalna dimenzija  $D_1$  uvek monotono opada (ili bar ostaje konstantna) kako  $q$  raste [OLE07].

### 3.2.3 Spektar fraktalnih dimenzija

U cilju opisivanja multifraktala, predstavljen je skup generalizovanih fraktalnih dimenzija  $D_q$ , gde  $q$  uzima bilo koju vrednost u intervalu  $-\infty < q < +\infty$ . Međutim,  $D_q$  vrednosti nisu razlomljene vrednosti u konvencionalnom smislu, pa se iz tog razloga nazivaju generalizovane dimenzije [OLE07].

Za karakterizaciju multifraktalnog skupa se koristi funkcija multifraktalnog spektra  $f(\alpha)$  (spektar multifraktalnih singulariteta). Može se pokazati da su  $f(\alpha)$  vrednosti u stvari jednake Hausdorff dimenziji nekog homogenog fraktalnog podskupa od početnog skupa [OLE07].

Skup verovatnoća  $p_i$ , koji pokazuje relativnu zauzetost  $\varepsilon$  celija kojim se skup koji se razmatra može prekriti, može biti označen kao jedna od najvažnijih karakteristika multifraktala. Što je manja veličina celija, manja je vrednost koja je zauzeta. Za samosličan set zavisnost verovatnoće  $p_i$  od veličine celije ima stepenu karakteristiku [OLE07]

$$p_i(\varepsilon) \approx \varepsilon^{\alpha_i} \quad (3.20)$$

gde  $\alpha_i$  predstavlja neki eksponent (koji zavisi od celije  $i$ ). Za regularne fraktale su svi eksponenti  $\alpha_i$  isti i jednaki fraktalnoj dimenziji  $D_f$

$$p_i = \frac{1}{N(\varepsilon)} \approx \varepsilon^{D_f} \quad (3.21)$$

pa je tom slučaju je statistička suma data sa

$$Z(q, \varepsilon) = \sum_{i=1}^{N(\varepsilon)} p_i^q(\varepsilon) = N(\varepsilon) \varepsilon^{D_f(q-1)} \quad (3.22)$$

Prema tome,  $\tau(q) = D_f(q - 1)$  i sve generalizovane fraktalne dimenzije  $D_q = D_f$  se u ovom slučaju poklapaju i ne zavise od  $q$  [OLE07].

Međutim, za tako kompleksne objekte kao što su multifraktali, zbog njihove heterogenosti, verovatnoće zauzeća celija  $p_i$  u opštem slučaju su različite i eksponent  $\alpha_i$  za različite celije može imati različite vrednosti. U slučaju monofraktala, gde su svi  $\alpha_i$  jednaki (i jednaki fraktalnoj dimenziji  $D_f$ ), broj  $N(\varepsilon)$  očigledno zavisi od veličine celije  $\varepsilon$  u skladu sa kvadratnom funkcijom. Prema tome,  $N(\varepsilon) \approx \varepsilon^{-D_f}$ . Eksponent je u ovom slučaju definisan skupom dimenzija  $D_f$  [OLE07].

Za multifraktele se mogu javiti različite vrednosti  $\alpha_i$  sa verovatnoćama koje su različitih vrednosti (u zavisnosti od  $\alpha$ ) tako da su vrednosti  $f(\alpha)$  eksponent

$$n(\alpha) \approx \varepsilon^{-f(\alpha)} \quad (3.23)$$

Fizički smisao funkcije  $f(\alpha)$  se sastoji od činjenice da predstavlja Hausdorff dimenziju nekog homogenog fraktalnog podskupa od početnog skupa koji je okarakterisan istim verovatnoćama zauzetosti celija  $p_i \approx \varepsilon^\alpha$ . Kako je fraktalna dimenzija podskupa

očigledno uvek manja ili jednaka fraktalnoj dimenziji inicijalnog seta  $D_0$ , javlja se važna nejednakost  $f(\alpha) \leq D_0$  [OLE07].

Kao rezultat može se zaključiti da skup različitih vrednosti funkcije  $f(\alpha)$  (za različito  $\alpha$ ) predstavlja spektar frakタルnih dimenzija za homogeni podskup početnog skupa. Kako svaki podskup ima samo deo od ukupnog broja ćelija  $N(\varepsilon)$ , u koji se početni skup deli, uslov normalizacije verovatnoće  $\sum_{i=1}^{N(\varepsilon)} p_i(\varepsilon) = 1$  nije ispunjen kada se sabira u samo nekom podskupu. Suma ovih verovatnoća je manja od 1. Prema tome, verovatnoće  $p_i$  koje imaju istu vrednost  $\alpha_i$  su očigledno manje (ili su bar istog reda) od neke vrednosti  $\varepsilon^{f(\alpha_i)}$ , što je inverzno proporcionalno broju ćelija koje se koriste za prekrivanje tog podskupa (u slučaju monofrakta je  $p_i \approx 1/N(\varepsilon)$ ). Ovo rezultuje važnu nejednačinu za funkciju  $f(\alpha)$  i sledi da za sve vrednosti  $\alpha$  važi  $f(\alpha) \leq \alpha$ . Znak jednakosti važi, na primer, za slučaj potpuno homogenog frakta, gde je  $f(\alpha) = \alpha = D_f$  [OLE07].

### 3.2.4 Funkcija multifraktalnog spektra

Za računanje multifraktalnog spektra se traži raspodela ćelija koje imaju skalirajući indeks (Hölder -ov eksponent) unutar nekog opsega oko vrednosti  $\alpha$ , znači u opsegu  $\alpha + d\alpha$ . Time se opisuje globalno svojstvo pojave, pomoću tzv. funkcije  $f(\alpha)$ . Za striktne frakタルne objekte ili pojave (veštački generisane na osnovu nekog algoritma) sve tačke imaju istu vrednost eksponenta – to su monofrakta. Za prirodne frakta postoje raspodela vrednosti, odnosno funkcija  $f(\alpha)$ , koja je najčešće oblika parabole [RELJ15a, RELJ15b, RELJ00, RELJ02].

### 3.2.5 Izračunavanje MF spektra

Posmatra se struktura  $S$ . Ona se deli na nepreklapajuće bokseve  $S_i$  stranica  $\varepsilon$ , tako da je

$$S = \bigcup_i S_i \quad (3.24)$$

Svaki boks je opisan nekim iznosom mere  $\mu(S_i)$ . Može se definisati tzv. grubi Hölder-ov eksponent [RELJ15a, RELJ15b, RELJ00, RELJ02]:

$$\alpha_i = \frac{\ln(\mu(S_i))}{\ln \epsilon} \quad (3.25)$$

Njegova granična vrednost, kada  $\epsilon \rightarrow 0$  je

$$\alpha_i = \lim_{\epsilon \rightarrow 0} \alpha_i \quad (3.26)$$

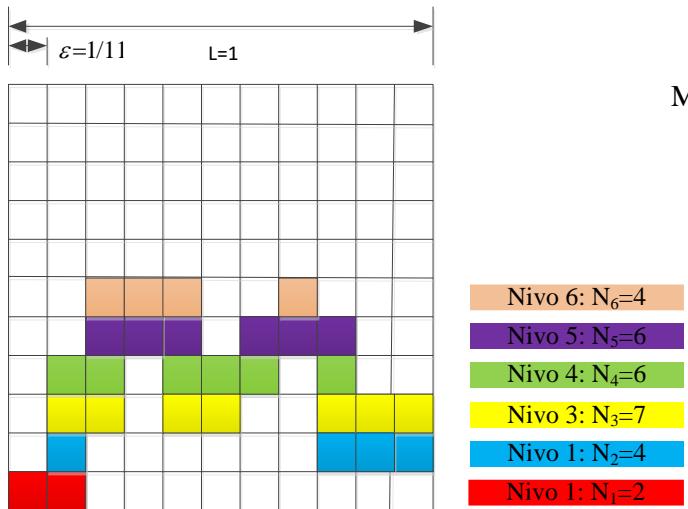
Parametar  $\alpha$  zavisi od položaja u strukturi i opisuje lokalnu regularnost. U celoj strukturi će postojati više bokseva sa istom vrednošću  $\alpha$ . Može se naći raspodela ove veličine u celoj strukturi, tj. MF spektar [RELJ15a, RELJ15b, RELJ00, RELJ02]

$$f_\epsilon(\alpha_i) = -\frac{\ln(N_\epsilon(\alpha_i))}{\ln \epsilon} \rightarrow f(\alpha) = \lim_{\epsilon \rightarrow 0} f_\epsilon(\alpha_i) \quad (3.27)$$

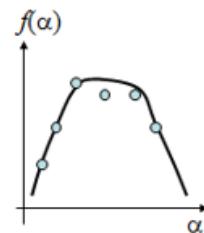
Obično se formira  $\alpha$ -prostor, pa se u njemu traži raspodela ovog parametra, tj. nije ista dimenzija boksa u originalnom prostoru ( $\epsilon$ ) i u  $\alpha$  prostoru (koristi se druga oznaka, npr.,  $\delta$ ) [RELJ15a, RELJ15b, RELJ00, RELJ02].

### 3.2.5.1 Metoda histograma

Metoda histograma je slična metodi *box-counting*-a, samo primenjenoj na raspodelu koeficijenata  $\alpha$ . Traži se broj bokseva koji pokrivaju određenu vrednost. Kao mera unutar posmatranih bokseva pri određivanju Hölder-ovih eksponenata mogu se koristiti različite vrednosti. To su najčešće maksimalna vrednost, minimalna vrednost, suma, najviše jednakih vrednosti, itd. Mere se normalizuju na sumu svih vrednosti veličine koja se posmatra [RELJ15a, RELJ15b, RELJ00, RELJ02].



Metod histograma:



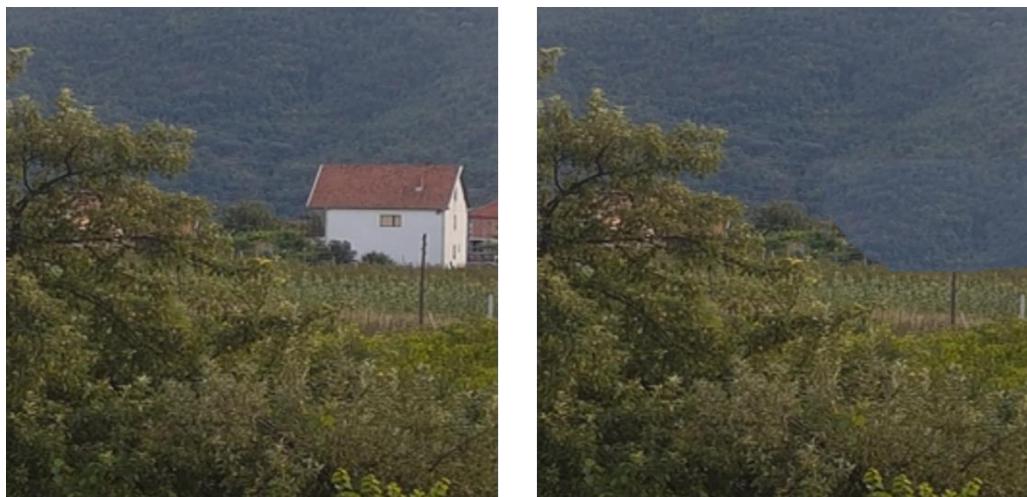
Traže se Hölder-ovi eksponenti za svaki nivo:  $\alpha_i, i = 1, 2, \dots, 6$   
a zatim raspodela ovih vrednosti, MF spektar,  $f(\alpha_i)$

Slika 3.5. Metoda histograma za izračunavanje multifraktalnog spektra [RELJ15a, RELJ15b].

Za isticanje lokalnih svojstava dimenzija bokseva treba da je što manja. Suprotan je zahtev pri analizi globalnog svojstva. U praksi, koristi se neki kompromis i/ili se primenjuje piramidalna analiza [RELJ00, RELJ02]. U MF postupku se kreiraju dve matrice: matrica Hölder-ovih eksponenata,  $\alpha$ , koji opisuju lokalnu regularnost slike (piksela) i matrica raspodele tih koeficijenata – spektar  $f(\alpha)$ , ili MF spektar slike. MF spektar daje globalni opis slike (ili, opštije, fenomena koji se ispituje). Parametar  $\alpha$  daje lokalnu informaciju o signalu. Spektar  $f(\alpha)$  opisuje globalno signal. Na osnovu para  $(\alpha, f(\alpha))$  može se opisati signal sa lokalnog i globalnog stanovišta. Male vrednosti  $\alpha$  označavaju signal koji se lokalno slabo menja. Male vrednosti  $f(\alpha)$  označavaju da je pojava koja ima lokalnu vrednost  $\alpha$  slabo verovatna (retko se pojavljuje), i obratno, za veliko  $f(\alpha)$  [RELJ15a, RELJ15b, RELJ00, RELJ02].

Vrednost Hölder-ovog eksponenta zavisi od položaja u strukturi i opisuje lokalnu regularnost signala. Naime, različiti objekti na slici imaju različite spekture, različite pozicije maksimuma, minimuma, prve nule itd, što se pokazalo kao interesantan skup različitih parametara pomoću kojih se mogu detektovati namerne promene na slikama. Na slikama

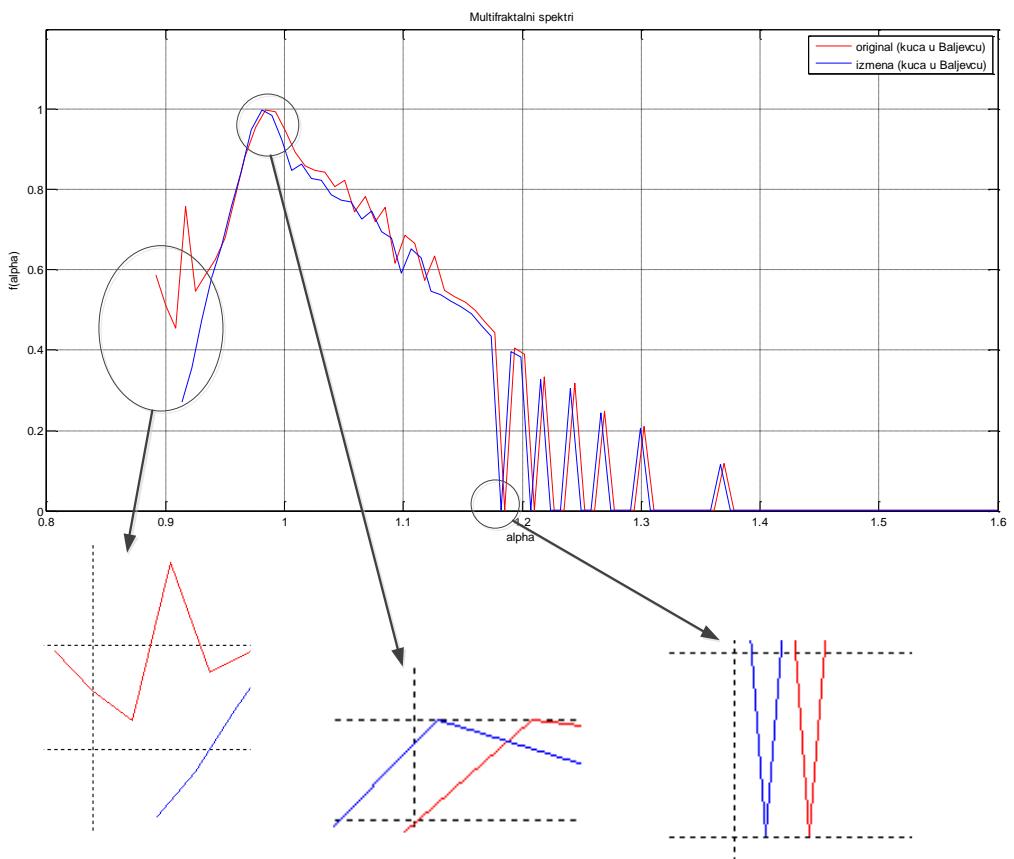
3.6 i 3.7 su dati primeri originalne slike (levo) i njene izmene (desno). Naime, slika 3.6 predstavlja sliku kuće u naselju Baljevac. Izmena na slici je nastala tako što je kopiran deo šume i nalepljen tako da se prekrije sadržaj slike (kuća). Slika 3.7 predstavlja sliku kuće u naselju Brvenik. Ovde je izmena nastala na drugačiji način (kuća je kopirana i nalepljena na drugi deo slike, kako bi se dobila lažna informacija o sadržaju slike – duplirao sadržaj slike). Slike 3.8 i 3.9 prikazuju multifraktalne spektre originalnih i izmenjenih slika sa Slika 3.6 i 3.7, respektivno. Sa slika 3.8 i 3.9 se može jasno uočiti da postoji razlika u vrednostima multifraktalnog spektra i Hölder-ovog eksponenta, za originalnu sliku i njenu izmenu (zaokruženi su u zumirani delovi u kojima se spektri razlikuju).



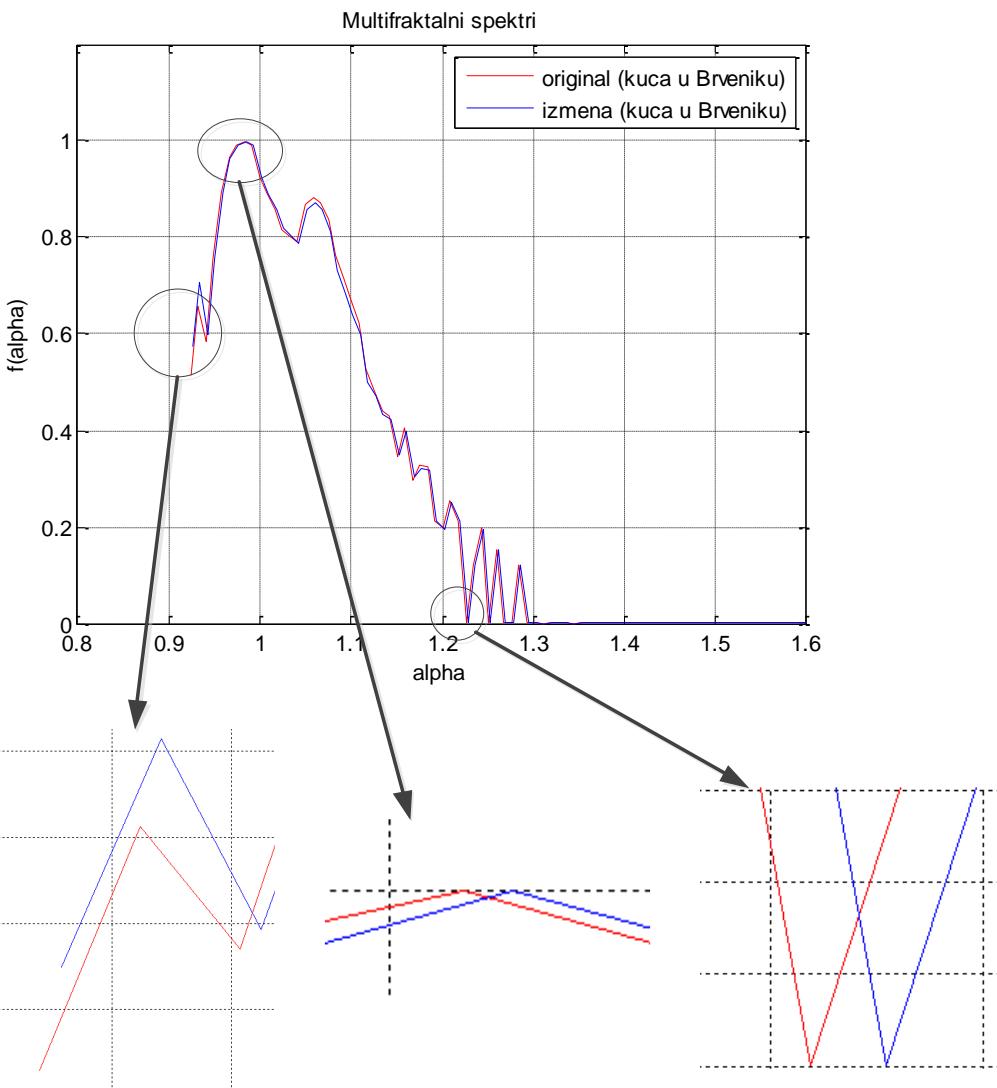
Slika 3.6 Kuća u naselju Baljevac, originalna slika (levo) i njena izmena (desno).



Slika 3.7 Kuća u naselju Brvenik, originalna slika (levo) i njena izmena (desno).



Slika 3.8 Multifraktalni spektri originalne i izmenjene slike (kuća u naselju Baljevac).



Slika 3.9 Multifraktalni spektri originalne i izmenjene slike (kuća u naselju Brvenik).

Parametri u kojima se spektri razlikuju jesu pozicija maksimuma multifraktalnog spektra ( $\alpha_0$ ), minimalne i maksimalne vrednosti Hölder-ovog eksponenta ( $\alpha_{\min}$  i  $\alpha_{\max}$ ), položaj prve nule multifraktalnog spektra ( $\alpha_1$ ), razlika između položaja prve nule i minimalne vrednosti Hölder-ovog eksponenta ( $\Delta = \alpha_1 - \alpha_{\min}$ ), kao i vrednosti površine ispod krive fraktalnog spektra, za određene intervale Hölder-ovog eksponenta, P1 u intervalu  $[\alpha_{\min}, \alpha_1]$ , P2 u intervalu  $[\alpha_0, \alpha_1]$ , P3 u intervalu  $[\alpha_2, \alpha_1]$ , P4 u intervalu  $[\alpha_1, \alpha_3]$ ,

gde se  $\alpha_2$  dobija kao  $\alpha_2 = \alpha_0 + 0,4 \cdot (\alpha_1 - \alpha_0)$ , a  $\alpha_3$  se dobija kao  $\alpha_3 = \alpha_1 + 0,2 \cdot (\alpha_{max} - \alpha_1)$ . U Tabeli 3.1 su prikazane opisane vrednosti, za originalnu sliku i njenu izmenu (Slika 3.7).

Tabela 3.1 Parametri multifraktalnog spektra originalne i izmenjene slike (kuća u naselju Brvenik).

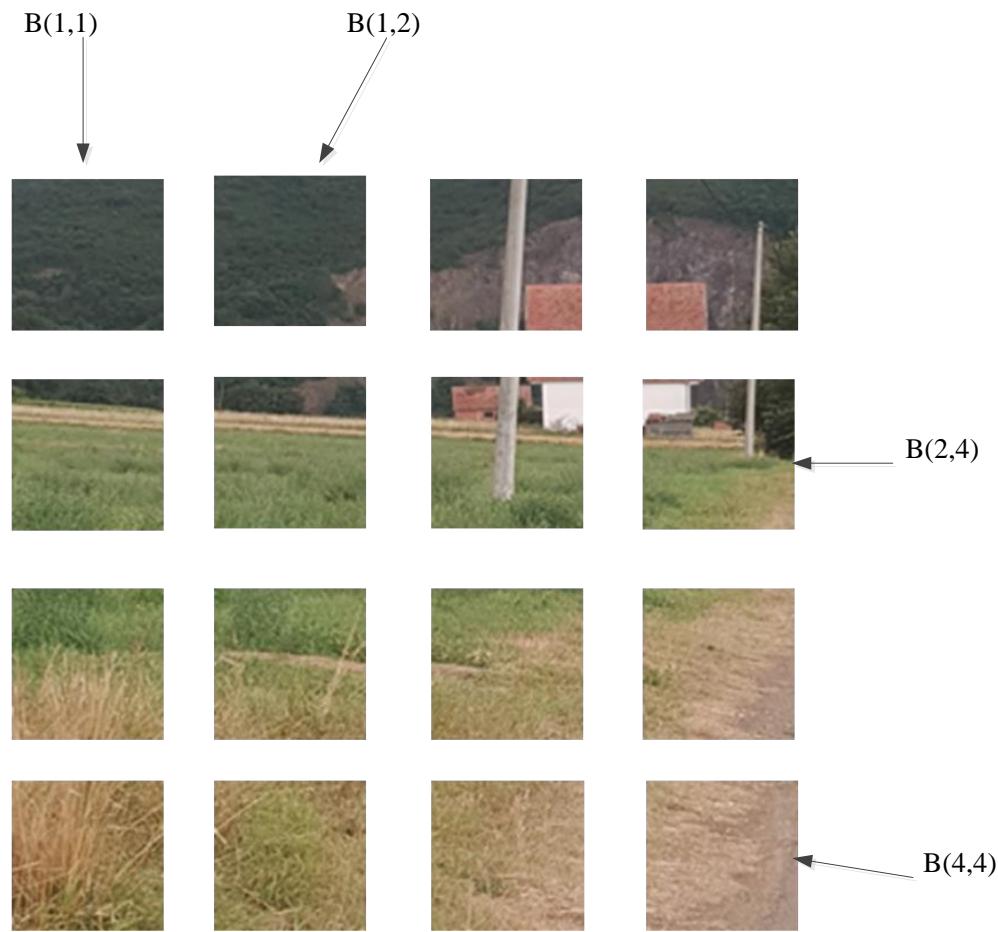
	$\alpha_{min}$	$\alpha_{max}$	$\alpha_0$	$\alpha_1$	$\Delta$	P1	P2	P3	P4
Original	0.924	1.7544	0.9827	1.226	0.302	0.1941	0.149	0.0607	0.005
izmena	0.9257	1.7562	0.9845	1.2277	0.302	0.1929	0.147	0.0591	0.0049

Iz Tabele 3.1 možemo zaključiti da se parametri multifraktalnog spektra originalne slike i njene izmene jasno razlikuju, pa se stoga mogu koristiti kao deskriptori slike i indikatori da je došlo do izmene u sadržaju slike.

### 3.2.5.2 Podela na blokove

U cilju detekcije namernih promena u sadržaju slike, slika od interesa se deli na preklapajuće ili nepreklapajuće blokove fiksnih dimenzija. Dimenzije blokova mogu da variraju, a najčešće korištene veličine blokova su 4x4, 8x8, 16x16, 32x32 i 64x64.

Obe slike se dele na nepreklapajuće blokove, dimenzija 64x64, radi ilustracije uticaja promena u sadržaju blokova na parametre multifraktalnog spektra koji su od interesa. Slika se skenira od gornjeg levog kraja, red po red, i blokovi se redom numerišu sa B(1,1), B(1,2),...,B(4,4), tj. sa  $B(i,j)$ , gde je  $i$  redni broj reda, a  $j$  redni broj kolone. Slike su rezolucije 256x256, tako da ukupno imamo 16 blokova po svakoj slici. Na slici 3.10 su prikazani blokovi originalne slike, dok slika 3.11 prikazuje blokove izmenjene slike (kuća u naselju Brvenik).

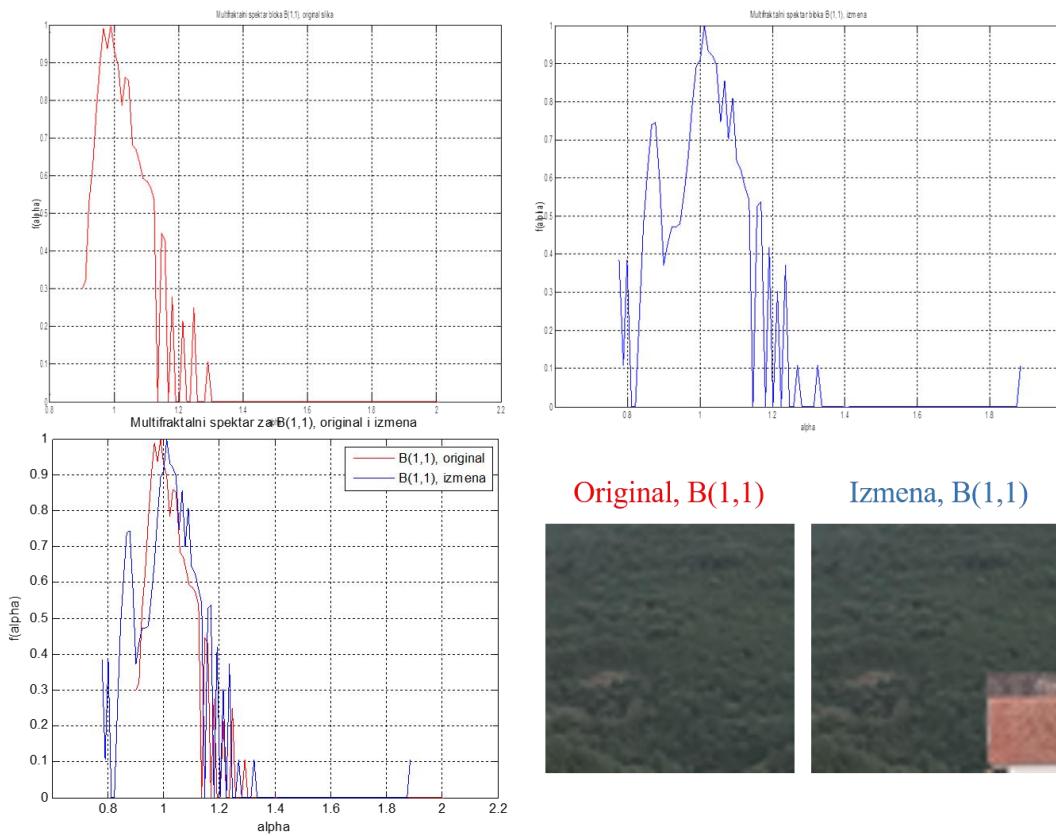


Slika 3.10 Podela na blokove (originalna slika) – kuća u naselju Brvenik.

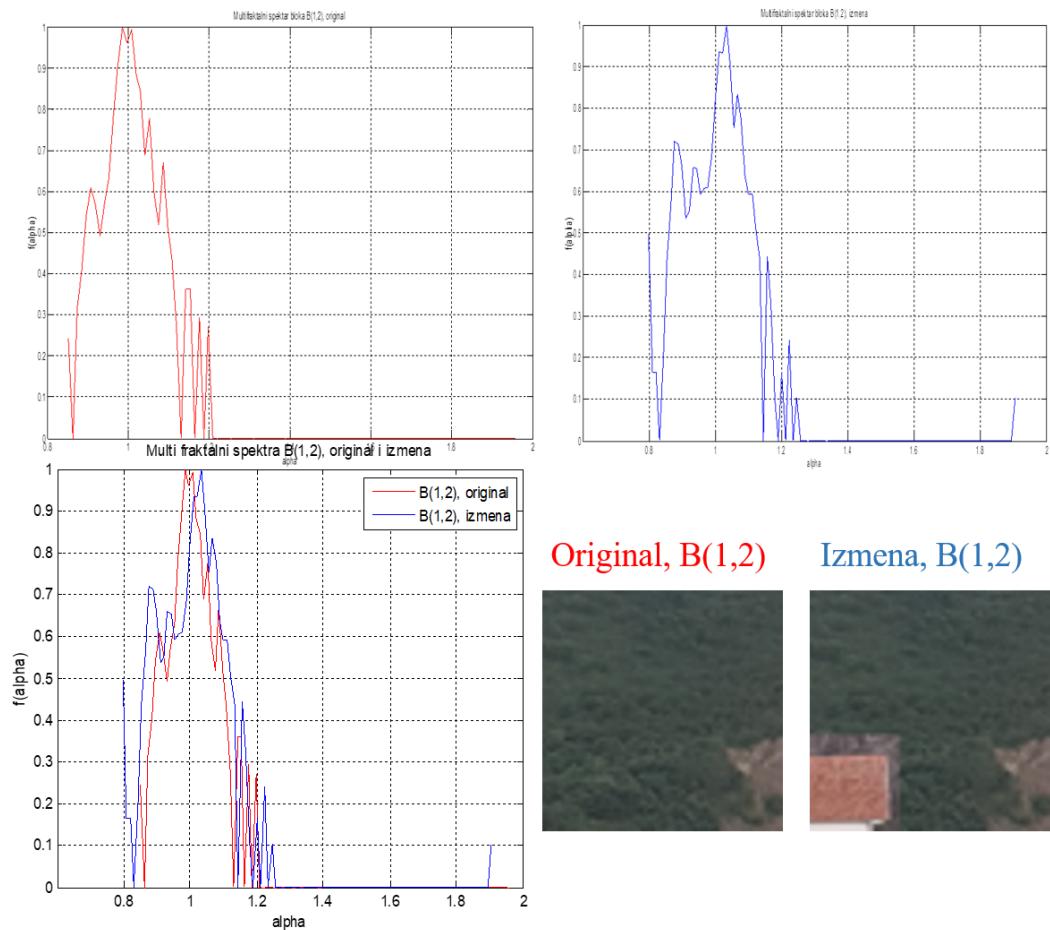


Slika 3.11 Podjela na blokove (izmenjena slika) – kuća u naselju Brvenik.

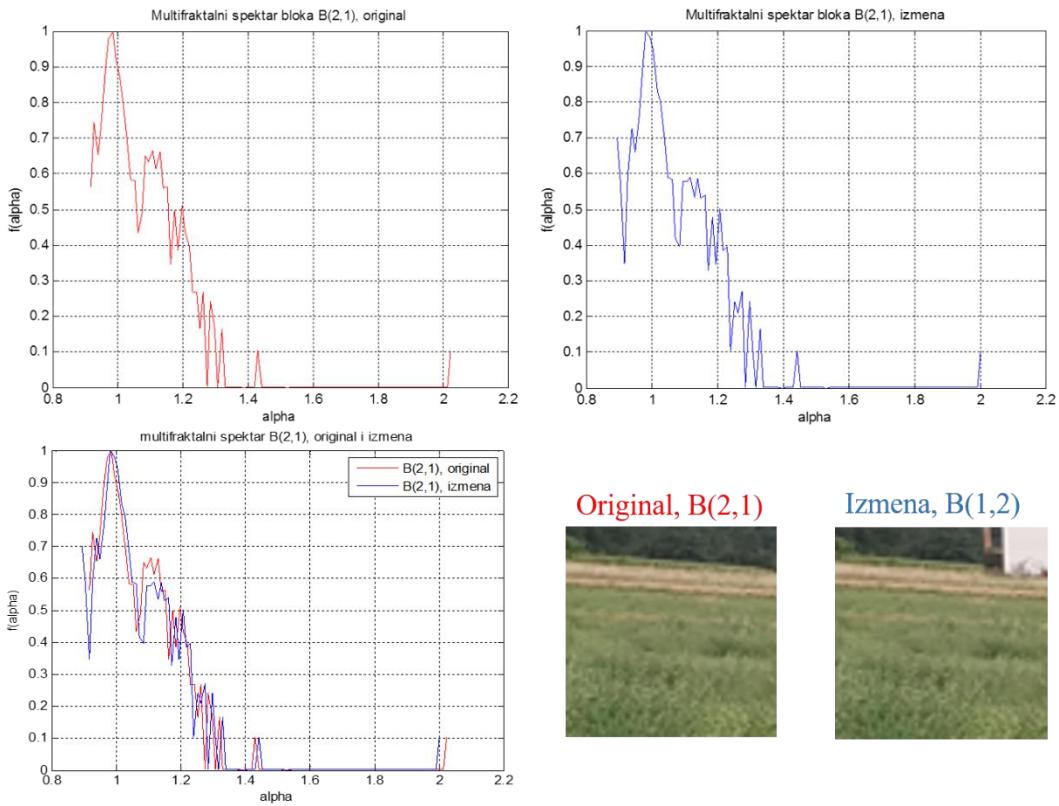
Sa slika 3.10 i 3.11 možemo videti da su izmenjeni sledeći blokovi: B(1,1), B(1,2), B(2,1) i B(2,2). Na slikama 3.12-3.15 su dati multifraktalni spektri neizmenjenih i izmenjenih blokova, odnosno blokova B(1,1), B(1,2), B(2,1) i B(2,2) originalne i izmenjene slike, respektivno.



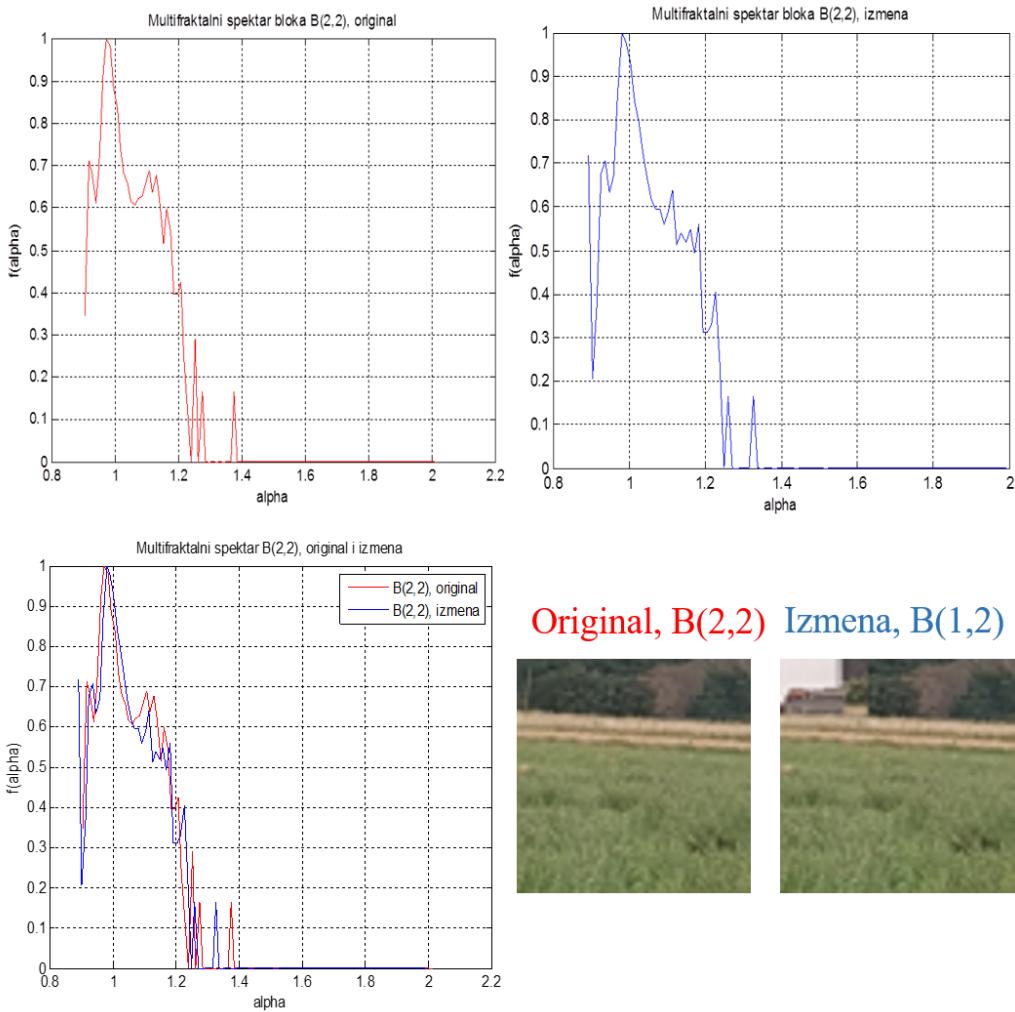
Slika 3.12 Multifraktalni spektri bloka B(1,1) originalne i izmenjene slike – kuća u naselju Brvenik.



Slika 3.13 Multifraktalni spektri bloka B(1,2) originalne i izmenjene slike – kuća u naselju Brvenik.



Slika 3.14 Multifraktalni spektri bloka B(2,1) originalne i izmenjene slike – kuća u naselju Brvenik.



Slika 3.15 Multifraktalni spektri bloka B(2,2) originalne i izmenjene slike – kuća u naselju Brvenik.

Sa slika 3.12-3.15 možemo videti da se multifraktalni spektri neizmenjenih i izmenjenih blokova prilično razlikuju, naročito u parametrima koji su opisani ranije i dati u Tabeli 3.1. Tabela 3.2 daje pregled svih parametara multifraktalnog spektra svih blokova originalne slike, dok su u Tabeli 3.3 predstavljeni isti parametri, samo za sve blokove izmenjene slike.

Tabela 3.2 Parametri multifraktalnog spektra blokova originalne slike – kuća u naselju Brvenik.

R.br.	alpha0	alpha min	alpha max	alpha1	alpha2	alpha3	P1	P2	P3	P4	Delta
1	0,9901	0,9006	2,0079	1,1355	1,0483	1,31	0,1674	0,1072	0,0573	0,0193	0,2349
2	0,9854	0,8512	1,9585	1,1309	1,0436	1,2964	0,1702	0,1023	0,05	0,0144	0,2797
3	1,0853	0,8616	1,9689	1,2195	1,139	1,3694	0,284	0,0908	0,0407	0,0075	0,3579
4	0,9803	0,8685	1,9758	1,2264	1,0788	1,3763	0,2539	0,1707	0,0758	0,0081	0,3579
5	0,9848	0,9177	2,025	1,2756	1,1011	1,4255	0,2103	0,1591	0,0809	0,0064	0,3579
6	0,9731	0,906	2,0133	1,2415	1,0805	1,3959	0,2094	0,1649	0,0797	0,007	0,3355
7	0,9933	0,9038	2,0112	1,2506	1,0962	1,4027	0,2137	0,1466	0,0668	0,000018755	0,3468
8	0,9849	0,9066	2,0139	1,2869	1,1057	1,4323	0,2337	0,1763	0,0869	0,0124	0,3803
9	0,9683	0,9236	2,0309	1,192	1,0578	1,3598	0,1765	0,1441	0,0604	0,002	0,2684
10	0,982	0,9148	2,0222	1,1945	1,067	1,36	0,177	0,1291	0,0494	0,0032	0,2797
11	1,0048	0,9265	2,0339	1,1614	1,0675	1,3359	0,1464	0,0854	0,0312	0,0052	0,2349
12	0,9825	0,9378	2,0451	1,1279	1,0407	1,3113	0,1128	0,0885	0,0369	0,0034	0,1901
13	0,9764	0,9317	2,039	1,1778	1,057	1,35	0,1555	0,1237	0,0526	0,0012	0,2461
14	0,9843	0,906	2,0133	1,152	1,0514	1,3243	0,1427	0,1051	0,0444	0,0042	0,246
15	0,9901	0,923	2,0303	1,1579	1,0572	1,3324	0,1479	0,1005	0,0392	0,0043	0,2349
16	1,0019	0,9236	2,0309	1,1473	1,0601	1,324	0,1355	0,0768	0,0277	0,000022344	0,2237

Tabela 3.3 Parametri multifraktalnog spektra blokova izmenjene slike – kuća u naselju Brvenik.

R.br.	alpha0	alpha min	alpha max	alpha1	alpha2	alpha3	P1	P2	P3	P4	Detla
1	1,0119	0,777	1,8843	1,1461	1,0656	1,2937	0,2188	0,1034	0,0532	0,0254	0,3691
2	1,0329	0,798	1,9053	1,1447	1,0776	1,2968	0,2097	0,0786	0,0396	0,0156	0,3467
3	1,0853	0,8616	1,9689	1,2196	1,139	1,3694	0,2843	0,0909	0,0408	0,0075	0,358
4	0,9803	0,8685	1,9758	1,2264	1,0788	1,3763	0,2543	0,1709	0,076	0,0081	0,3579
5	0,9837	0,8942	2,0015	1,2857	1,1045	1,4289	0,2203	0,1614	0,074	0,0057	0,3915
6	0,9807	0,8912	1,9986	1,2492	1,0881	1,399	0,2141	0,1598	0,0733	0,0037	0,358
7	0,9933	0,9038	2,0112	1,2506	1,0962	1,4027	0,2136	0,1466	0,0667	0,000018759	0,3468
8	0,9849	0,9066	2,0139	1,2869	1,1057	1,4323	0,2338	0,1764	0,0869	0,0124	0,3803
9	0,9683	0,9236	2,0309	1,192	1,0578	1,3598	0,1767	0,1443	0,0606	0,002	0,2684
10	0,982	0,9148	2,0222	1,1945	1,067	1,36	0,1771	0,1291	0,0494	0,0032	0,2797
11	0,9825	0,9265	2,0339	1,1614	1,0541	1,3359	0,1464	0,1076	0,0454	0,0052	0,2349
12	0,9825	0,9377	2,0451	1,1279	1,0406	1,3113	0,1128	0,0885	0,0369	0,0034	0,1902
13	0,9764	0,9317	2,039	1,1777	1,057	1,35	0,1554	0,1237	0,0526	0,0012	0,246
14	0,9843	0,906	2,0133	1,152	1,0514	1,3243	0,1427	0,1051	0,0444	0,0042	0,246

15	0,9789	0,923	2,0303	1,1579	1,0505	1,3324	0,1479	0,1116	0,0479	0,0043	0,2349
16	1,0019	0,9236	2,0309	1,1473	1,06	1,324	0,1356	0,0769	0,0277	0,00002237	0,2237

Napomena: žutom bojom su označeni izmenjeni blokovi, kao i parametri u kojima se blokovi, odnosno multifraktalni spektri blokova razlikuju. Što se tiče ostalih blokova koji su neizmenjeni, vrednosti parametara multifraktalnog spektra su iste, odnosno ostaju neizmenjene.

Iz Tabela 3.2 i 3.3 možemo zaključiti da se kod izmenjenih blokova itetako menjaju parametri multifraktalnog spektra. Stoga se oni mogu koristiti kao deskriptori blokova, u cilju detekcije promene na slikama. U narednom poglavljtu biće detaljno objašnjen novi model za detekciju CMFD promena, zasnovan prvenstveno na blokovskoj analizi i parametrima multifraktalnog spektra.

### 3.2.6 Inverzni multifraktalni spektar

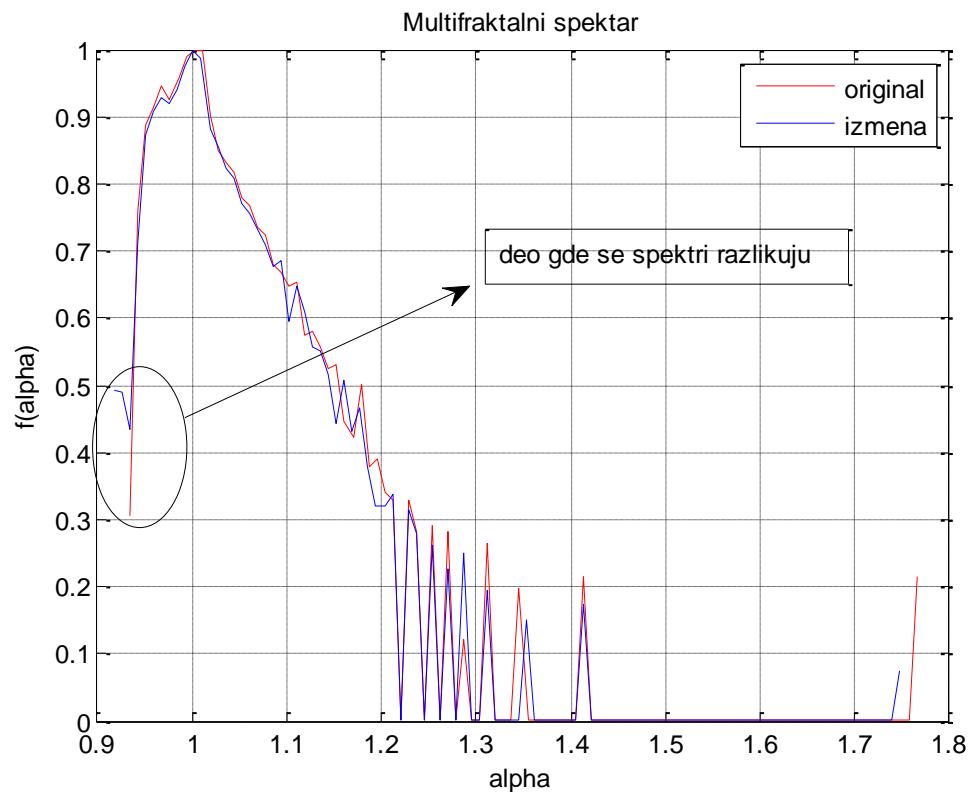
Na osnovu postupka za određivanje multifraktalnog spektra metodom histograma, moguće je izvesti postupak za izračunavanje inverznog multifraktalnog spektra (IMF). Ideja je prvo predložena u [RELJ00], za izdvajanje karakterističnih detalja slike. Ako svakom pikselu slike pridružimo odgovarajuće vrednosti  $\alpha$  i  $f(\alpha)$ , može se izračunati inverzni multifraktalni spektar. To znači da kada izračunamo MF spektar određenog signala, posmatrajući lokalno i globalno ponašanje vrednosti parametara  $\alpha$  i  $f(\alpha)$ , možemo izdvojiti neke karakteristične detalje, bez bilo kakve degradacije slike. Ova procedura je naročito od interesa u regionima u kojima MF spektar ima male vrednosti (globalno, retki slučajevi), i u regionima gde  $f(\alpha)$  ima velike vrednosti (globalno česti slučajevi). Preciznije, tačke koje imaju  $\alpha$  i  $f(\alpha)$  blizu 1 odgovaraju glatkim linijama, tj. to su tačke ivica, dok tačke koje ima vrednosti  $\alpha$  i  $f(\alpha)$  blizu 2, odgovaraju ravnim površinama.

Bilo koja klasična metoda za obradu slike (u prostornom ili vremenskom domenu) za izdvajanje regiona od interesa je uvek praćena manjim ili većim degradacijama slike [RELJ00]. MF i IFM analiza međutim, ne unose nikakve degradacije na slikama. IMF

analiza se može uspešno koristiti za izdvajanje izmenjenih delova slike, odnosno namerno dodatih delova slike. Naime, posmatrajući vrednosti multifraktalnog spektra slike i uočavanjem tzv. nepravilnosti spektra (pojavljivanje novih pikova, iskrivljene linije, pomeranje maksimuma i prve nule spektra), i računanjem IMF u tim intervalima vrednosti  $\alpha$ , može se doći do delova slike koji su izmenjeni. Na slici 3.16 je dat primer originalne slike (levo) i njene izmene (desno). Slika je izmenjena tako što je naknadno nalepljena kuća sa neke druge slike na dve lokacije na slici (*image splicing*). Slika 3.17 prikazuje multifraktalne spekture originalne slike i njene izmene.

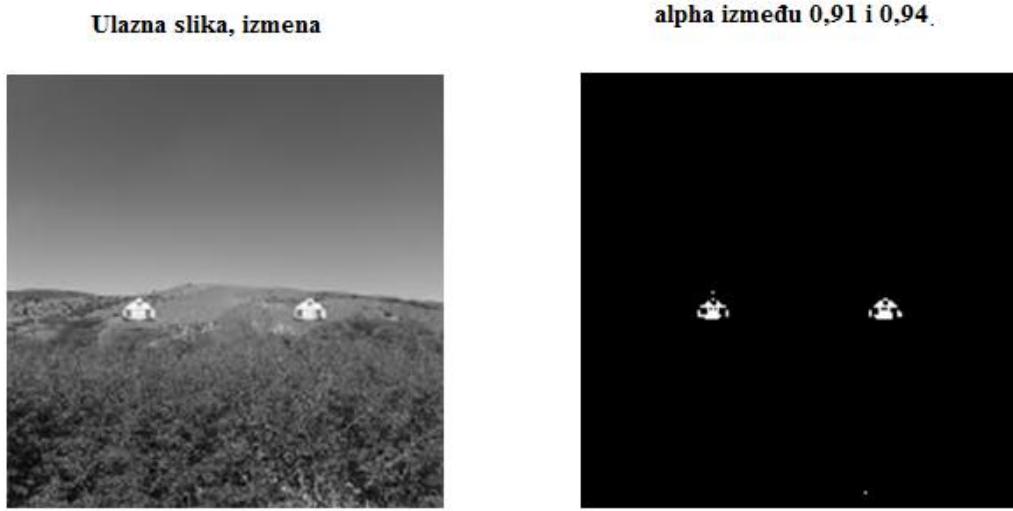


Slika 3.16 Originalna slika (levo) i njena izmena (desno), *primer image splicing*.



Slika 3.17 Multifraktalni spektri slika sa slike 3.16.

Posmatrajući spekture originalne slike i njene izmene, uočavamo delove gde je nastala promena u spektru. Kako su posebno interesantne male ili velike vrednosti MF spektra, uočavamo zaokruženi deo na slici 3.17, gde se vrednost spektra prilično uvećava (verovatno je nešto dodato na slici, neki detalj). Računajući IMF izmenjene slike, za posmatrani interval vrednosti  $\alpha$ , od 0,91 do 0,94, dobijamo sledeći grafički rezultat (Slika 3.18).



Slika 3.18 Primer detekcije naknadno dodatih elemenata na sliku primenom IMF.

Sa slike 3.18 možemo videti da je IMF analiza izmenjene slike, za određeni interval vrednosti  $\alpha$ , izdvojila objekte koji ne pripadaju originalnoj slici, i koji su naknadno dodati na originalnu sliku (objekti označeni belom bojom na slici 3.18 desno).

### 3.3 Statistička analiza slika izmenjenih copy-move metodom

U ovom poglavlju je predstavljeno istraživanje mogućnosti detektovanja slika iz iste grupe nad kojima je vršena *copy-move* promena. Takođe su prikazani i rezultati klasterovanja, kao i statističke analize takvih slika.

Korelacijom se meri jačina povezanosti između dve promenljive, dok korelaciona analiza pokazuje stepen zavisnosti između promenljivih. Intenzitet povezanosti između promenljivih, koje su u linearnom odnosu meri se na dva načina:

- apsolutnom merom intenziteta korelacije (kovarijansom) i
- relativnom merom intenziteta korelace veze, odnosno koeficijentom proste linearne korelacije (*Pearsonov* koeficijent) [PAV17].

U suštini, kovarijansa predstavlja zajedničku meru varijabilnosti promenljivih, pa se može predstaviti matematički kao zbir varijansi jedne i druge promenljive:

$$C_{xy} = SD_x^2 + SD_y^2 \quad (3.28)$$

odnosno

$$C_{xy} = \frac{\sum(x-\bar{x})^2}{n} + \frac{\sum(y-\bar{y})^2}{n} \quad (3.29)$$

Sređivanjem jednačine (3.29) dobijamo

$$C_{xy} = \frac{\sum xy}{n} - \bar{x}\bar{y} \quad (3.30)$$

gde:

- $x$  i  $y$  predstavljaju promenljive koje predstavljaju nizove podataka,
- $\bar{x}$  i  $\bar{y}$  predstavljaju srednje vrednosti, odnosno aritmetičke sredina nizova  $x$  i  $y$ , respektivno,
- $n$  je ukupna dužina niza,
- $C_{xy}$  označava kovarijansu,
- $SD_x$  i  $SD_y$  standardne devijacije nizova [PAV17].

Kako kovarijansa kao absolutna mera stepena povezanosti nije pogodna za procenu, umesto nje se računa relativna mera, tj. koeficijent proste linearne korelacije.

*Pearsonov* koeficijent, ili koeficijent proste linearne korelacije, predstavlja kovarijansu standardnih devijacija za dve promenljive. Računa se kao količnik kovarijanse i proizvoda standardnih devijacija jedne i druge promenljive [PAV17]:

$$r_{xy} = \frac{C_{xy}}{SD_x \cdot SD_y} = \frac{\text{kovarijansa}}{\text{proizvod standardnih devijacija } x \text{ i } y} \quad (3.31)$$

*Pearsonov* koeficijent korelacijske pokazuje stepen zavisnosti između promenljivih, kao i veličinu disperzije podataka oko regresione linije. Kod promenljivih koje nisu povezane disperzija oko regresione linije je velika, dok se povećanjem stepena povezanosti disperzija smanjuje. Ukoliko se dogodi da između promenljivih postoji apolutno

poklapanje, svi podaci pripadaju regresionoj liniji [PAV17].

Vrednosti koeficijenta korelacije se nalaze u intervalu od -1 do +1. Za promenljive koje nisu korelisane, koeficijent korelacije teži nuli. Promenljive su pozitivno korelisane ( $r>0$ ), u slučaju da kada vrednosti nezavisne promenljive  $x$  rastu da onda i vrednosti odgovarajuće zavisno promenljive  $y$  takođe rastu, i obrnuto, da kada vrednosti nezavisno promenljive  $x$  opadaju vrednosti odgovarajuće zavisno promenljive  $y$  takođe opadaju. Promenljive su negativno korelisane ( $r<0$ ), u slučaju da kada vrednosti nezavisno promenljive  $x$  rastu a vrednosti odgovarajuće zavisno promenljive  $y$  opadaju, i obrnuto, kada vrednosti nezavisno promenljive  $x$  opadaju a vrednosti odgovarajuće zavisno promenljive  $y$  rastu. Međuzavisnost među posmatranim nizovima je utoliko jača ukoliko je vrednost koeficijenta proste linearne korelacije bliža jedinici [PAV17].

Objekti se grupišu u klaster u zavisnosti od više atributa. Za svaki klaster može postojati poseban skup pravila po kome se objekti grupišu. Klase u koje će se objekti deliti nisu unapred zadate. Klasteri se otkrivaju na takav način da su objekti unutar istog klastera međusobno slični, a istovremeno različiti od objekata koji pripadaju drugim klasterima [PAV17].

Za klasterovanje podataka se može koristiti tzv. *K-means* algoritam. On podatke deli u  $K$  klastera, a broj klastera  $K$  se određuje na različite načine, u zavisnosti od kriterijuma donosioca odluke. Da bi se ispravno odredio pravi broj klastera u koje se podaci grupišu, algoritam se sprovodi više puta, a zatim se na osnovu mere kvaliteta klasterovanja odlučuje koji je broj klastera zadovoljavajući [PAV17].

Klasterovanje na osnovu *Pearsonovog* koeficijenta korelacije je korišćeno za analizu originalnih i izmenjenih slika. Opisan je primer klasterovanja na dve grupe slika. Prvu grupu predstavljaju slike iz javno dostupne baze [IMA18], dok drugi primer predstavlja primenu algoritma na slike generisane za potrebe testiranja od strane autora (slike 3.19 i 3.20, respektivno).



Slika 3.19 Prva grupa testiranih slika (slike iz javno dostupne baze [IMA18]).



Slika 3.20 Druga grupa testiranih slika (slike generisane za eksperiment).

Format svih testiranih slika je JPEG, a rezolucija može biti proizvoljna. Slika 3.19 predstavlja primer originalne slike i njene tri izmene: deo slike je kopiran i nalepljen na drugi deo iste slike (*copy-move*), i nakon toga rotiran kod izmena 1 i 2. Slika 3.20 predstavlja grupu slika, koja sadrži originalnu sliku i njene izmene. Naime, slika sa zida je kopirana i nalepljena na različite delove originalne slike [PAV17].

Nizovi  $x$  i  $y$  predstavljaju nivo sivog piksela originalne i izmenjenih slika (svaka slika je iz RGB sistema pretvorena u intenzitetsku sliku), dok je  $n$  ukupan broj piksela slika koje se analiziraju.

U cilju analize korelisanosti piksela izmenjenih i originalnih slika, odradene su statističke analize slika. Rezultati korelisanosti su prikazani u Tabelama 3.4 (za prvu grupu slika) i 3.5 (za drugu grupu slika).

Tabela 3.4 Pearsonov koeficijent korelacija za skup slika prikazan na Slici 3.19 [PAV17].

Pearsonov koeficijent	Original baza	Izmena 1	Izmena 2	Izmena 3
Original	1	0.941**	0.865**	0.950**
Izmena 1	0.941**	1	0.896**	0.911**
Izmena 2	0.865**	0.896**	1	0.834**
Izmena 3	0.950**	0.911**	0.834**	1

Tabela 3.5 Pearsonov koeficijent korelacija za skup slika prikazan na Slici 3.20 [PAV17].

Pearsonov koeficijent	Original	Izmena 1	Izmena 2	Izmena 3
Original	1	0.816**	0.820**	0.873**
Izmena 1	0.816**	1	0.658**	0.705**
Izmena 2	0.820**	0.658**	1	0.708**
Izmena 3	0.873**	0.705**	0.708**	1

Napomena: “\*\*” označavaju značajnu povezanost i pozitivnu korelisanost.

Iz Tabela 3.4 i 3.5 se može zaključiti da postoji jaka pozitivna korelisanost između piksela originalne slike i slike gde je vršena izmena, tako i između različitih izmena slika, u slučaju oba primera koja su analizirana. Jaka korelisanost je rezultat statistički slične promene, jer je isti deo nalepljen u svim izmenama slike, samo je postavljen pod različitim

uglovima [PAV17].

Vrednosti *Pearson*-ovog koeficijenta korelacije prikazane u Tabelama 3.4 i 3.5 ukazuju na statistički značajnu vezu između originalne slike i izmena, kao i između svake od izmena [PAV17].

### *K-means* klasterizacija

Nakon što je utvrđena jačina veze i nivo korelisanosti originalne slike i njenih izmena, primenom algoritma *K-means*, ustanovljeno je da je najbolje uzeti za  $K=2$ . Algoritam je primenjen na više različitih slika kod kojih su vršene iste izmene i pokazao je svoju uspešnost. Naime, klasifikacijom su dobijene dve grupe klastera. Prvom klasteru su pripadali izmenjeni pikseli dok su se u drugome našli originali. tj. pikseli nad kojima nije vršena nikakva promena. Kako su intenziteti piksela poređani u niz  $x$  redosledom kojim se nalaze u slici (red po red), može se precizno utvrditi na kojim pozicijama se nalaze pikseli koji su izmenjeni [PAV17].

## 3.4 Segmentacija i klasterovanje slike na osnovu parametara multifraktalnog spektra

Segmentacija slike, odnosno razumevanje sadržaja slike i izdvajanje karakteristika iz iste, jeste jedan od najvažnijih koraka u analizi slike. Posebno je važna za prepoznavanje objekata na slici. Predstavlja podelu slike na regije ili kategorije, koji odgovaraju različitim objektima sa slike ili delovima objekata sa slike, prema određenim kriterijumima. Osnova je za analizu slike i razumevanje karakteristika slike, kao i prepoznavanje objekata. Svaki piksel slike pripada jednoj od ovih brojnih kategorija. Dobrom segmentacijom se obično smatra da pikseli u istom regionu imaju slične vrednosti intenziteta i tako formiraju region, ili da susedni pikseli koji pripadaju različitim kategorijama imaju različite vrednosti. Cilj segmentacija jeste obično da regije predstavljaju značajne delove slike, kao što su uglovi, ivice, urbana područja, šume, itd. U drugim primerima segmentacije obično se pikseli izdvajaju tako da formiraju linije ili kružne segmente. Najčešće se segmentacija slike vrši da bi se slika podelila na delove koji

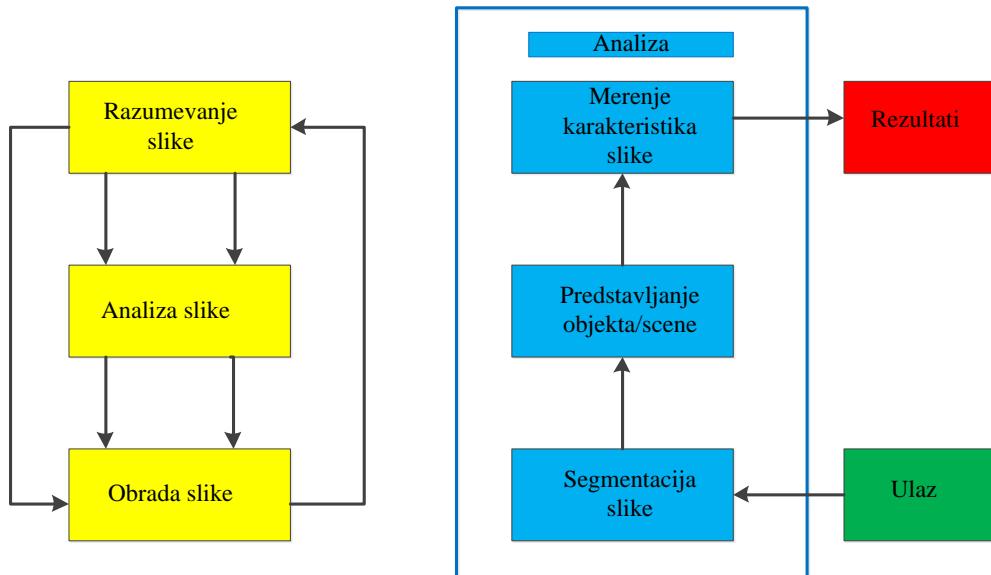
služe za dalju analizu [ZHA02, ZHA06]. U praksi nam obično nije važno da analiziramo sve delove slike, već samo određene delove koji imaju slične karakteristike.

U ovom poglavlju je opisana mogućnost korišćenja različitih parametara multifraktalnog spektra za klasterovanje različitih objekata na slici, odnosno segmentaciju slike, kao početni korak u detekciji *copy-move* promena na slikama. Klasterovanje je izvršeno prema sličnostima parametara multifraktalnog spektra [PAV18].

### **3.4.1 *Skyline* segmentacija slike korišćenjem boja i detaljnog klasterovanja**

Digitalne slike i video predstavljaju glavne medije za komunikaciju u današnje vreme. Komunikacija obuhvata fotografiju, pokretne slike, audio, animacije, grafiku, crteže, grafikone, pa čak i tekst. Slikovna i vizuelna predstava su korisne kako bi ljudi dobili većinu informacija o spoljašnjem svetu. U cilju boljeg razumevanja slika i dobijanja veće količine informacija iz njihovog razmatranja, razvijene su brojne tehnike. Razumevanje sadržaja slike i izdvajanje informacija iz njih predstavljaju važan deo u različitim aplikacijama i implementacijama. To znači da je prvi korak u suštini razumevanje sadržaja slike lokalizacija/segmentacija različitih delova slike [PAV18].

U suštini, segmentacija se najčešće izvodi koristeći činjenicu da određeni pikseli ili regioni imaju slične karakteristike. Samo su određeni delovi slike od interesa za analiziranje. Segmentacija slike predstavlja jednu od ključnih tačaka u obradi slike i kompjuterskoj viziji (*Computer Vision*). Odgovarajuća segmentacija je takođe važna za prepoznavanje oblika, objekata ili čak celokupnih slika. Unutar segmentacije, primenjuju se određeni kriterijumi kako bi se slika podelila u regije ili klastera. Rezultati primenjene segmentacije se zatim primenjuju u daljoj analizi slika od interesa i procesu prepoznavanja. Krajnji cilj segmentacije jeste postizanje relevantnih informacija za predstavljanje objekata i oblasti, i daljem opisu karakterističnih merenja [NGA11]. To je ilustrovano na slici 3.21.



Slika 3.21 Analiza i segmentacija slike.

Uspešno razumevanje semantičkog sadržaja slike/videa znači razumevanje osnovnih komponenti scene i njihove međusobne veze. Stoga, segmentacija se izvodi na lokalan način korišćenjem pristupa zasnovanim na blokovima. Jedan od najinteresantnijih delova scene može biti horizont ili *skyline* (linija između neba i šume, neba i mora, i slično). Odgovarajuća *skyline* segmentacija podrazumeva podelu slike na tri klastera: nebo, region oko neba i ostatak slike. Ovo nije jednostavan postupak zato što klasteri ne predstavljaju uniformne regije i sadrže detalje koji dovode do pogrešnog klasterovanja [LAZ14]. Cilj ovog poglavlja je da opiše postupak klasifikacije u tri klase za *skyline* segmentaciju slike, i da analizira uticaj sistema boja i detalja na rezultate klasterovanja [PAV18].

Segmentacija slike se može predstaviti kao klasterovanje, odnosno grupisanje piksela u značajne regije na slici, tj. u regije koje odgovaraju objektima ili delovima scene. U cilju segmentacije slike, slika se deli na skup preklapajućih ili nepreklapajućih regona (najčešće su to blokovi), gde unija tih regona predstavlja celokupan sadržaj slike [PAV18].

Postavljanje pravila za segmentaciju značajnih regona slike se može izraziti kao različit izbor parametara. Značajni regoni koji predstavljaju rezultat segmentacije obično

treba da budu uniformni i homogeni u pojmovima nekih karakteristika, susedni regioni treba da imaju značajno različite vrednosti u pojmovima ovih karakteristika, i granice svakog regiona treba da budu što jednostavnije. Tipična “jednostavna” granica se može naći u *skyline* slikama, gde *skyline* region predstavlja granicu između regiona neba i ostatka slike, koji sadrži šumu, zgrade, nebo, itd. *Skyline* region je predstavljen na slici 3.22 [PAV18].



Slika 3.22 *Skyline* region je obeležen crvenom bojom.

Inače, *skyline* segmentacija slike nije jednostavna, čak i ako postoji samo dva dominantna regiona, što je uzrokovano detaljima koji se nalaze u tim regionima [RELJ00, FAB11, CHI15, ARM17, CEL90]. Stoga je izvršena takva analiza, korišćenjem različitih karakteristika. Analizirano je ukupno 10 slika, na kojima *skyline* predstavlja liniju između neba i šume. Primeri *skyline* slika su dati na slici 3.23 [PAV18].



Slika 3.23. Primeri slika sa *skyline* regionima.

Treba imati na umu da se u regionu šume (čak i u regionu neba) mogu naći objekti koji mogu uticati na razlikovanje i rezultate klasterovanja. Drveće, kao i antenska oprema, se mogu naći u *skyline* regionu slike, kao što je prikazano na slici 3.23 (slika levo) [PAV18].

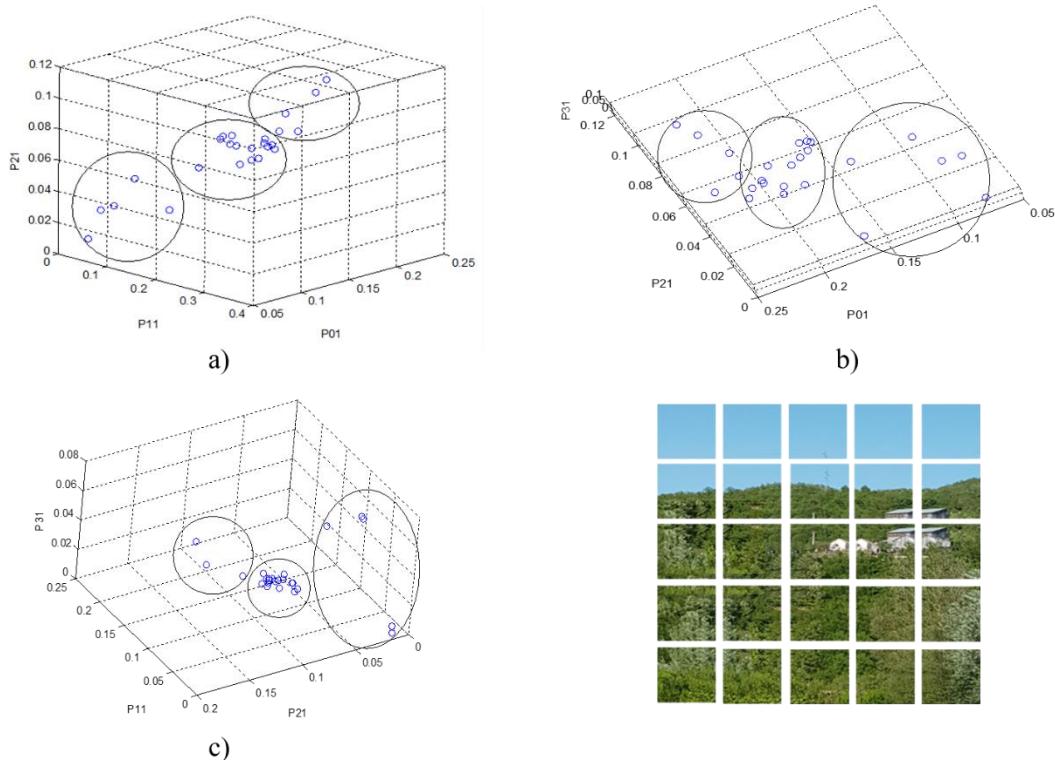
Analizirana je različita kolor reprezentacija slika, kao i njen uticaj na rezultate klasterovanja. Klasterovanje je izvršeno prema sličnostima parametara u raspodeli singulariteta slike. Za eksperimentalnu analizu su odabrane različite karakteristike, odnosno površine. U prvom koraku, slika od interesa se konvertuje iz RGB sistema boja u intenzitetsku, crveni (R), zeleni (G) i plavi kanal (B), kao i u *hue* (H) sliku korišćenjem HSV sistema boja (*H-hue*, *S-saturation*, *V-value*). Drugi korak jeste podela slike na preklapajuće blokove dimenzija 64x64. Veličina preklapanje je 16 piksela, i blokovi se preklapaju preko obe ose. Prema tome, slika se deli na 25 preklapajućih blokova. Slika se skenira red po red, i blokovi su numerisani sa 1, 2, 3,..., 25.

Za sliku na slici 3.23 (levo), drugi red (blokovi 6-10) pripadaju *skyline* regionu. Za ovaj eksperiment su izabrane četiri površine, prema odgovarajućoj raspodeli singulariteta slike [RELJ00]. Površine su označene sa P01, P11, P21 i P31 i računate su prema poziciji maksimuma i poziciji minimuma raspodele singulariteta blokova i ograničenjima raspodele singulariteta gledano iz pravca *x*-ose (pozicija prve nule i maksimalna i minimalna vrednost singulariteta slike). Za analizu slika, izabrane su tri različite kombinacije

površina: P01-P11-P21 (prva kombinacija), P01-P21-P31 (druga kombinacija) i P11-P21-P31 (treća kombinacija). Kombinacije površina su izabrane na slučajan način. Rezultati klasterovanja su prikazani za različite reprezentacije slika. Korišćeno je pet reprezentacija slika: *grayscale* reprezentacija, plavi, zeleni i crveni kanal, kao i reprezentacija zasnovana na *hue* komponenti HSV sistema boja [PAV18].

### 3.4.1.1 Segmentacija intenzitetske slike

U ovom delu analize slika se prvo konvertuje iz RGB sistema boja u *grayscale* domen. Rezultati klasterovanja korišćenjem *grayscale* slike za tri različite selekcije su prikazani na slici 3.24 (a), (b) i (c). Rezultati su predstavljeni za sliku 3.23 (levo). Sa slike 3.24 se mogu jasno uočiti tri izdvojena klastera, tj. blokovi mogu da se klasifikuju u tri različite klase, u zavisnosti od odabrane selekcije. Rezultati klasterovanja su dati u Tabeli 3.6 [PAV18].



Slika 3.24 Rezultati klasterovanja *grayscale* slike za različite kombinacije površina:  
a) prva kombinacija, b) druga kombinacija i c) treća kombinacija.

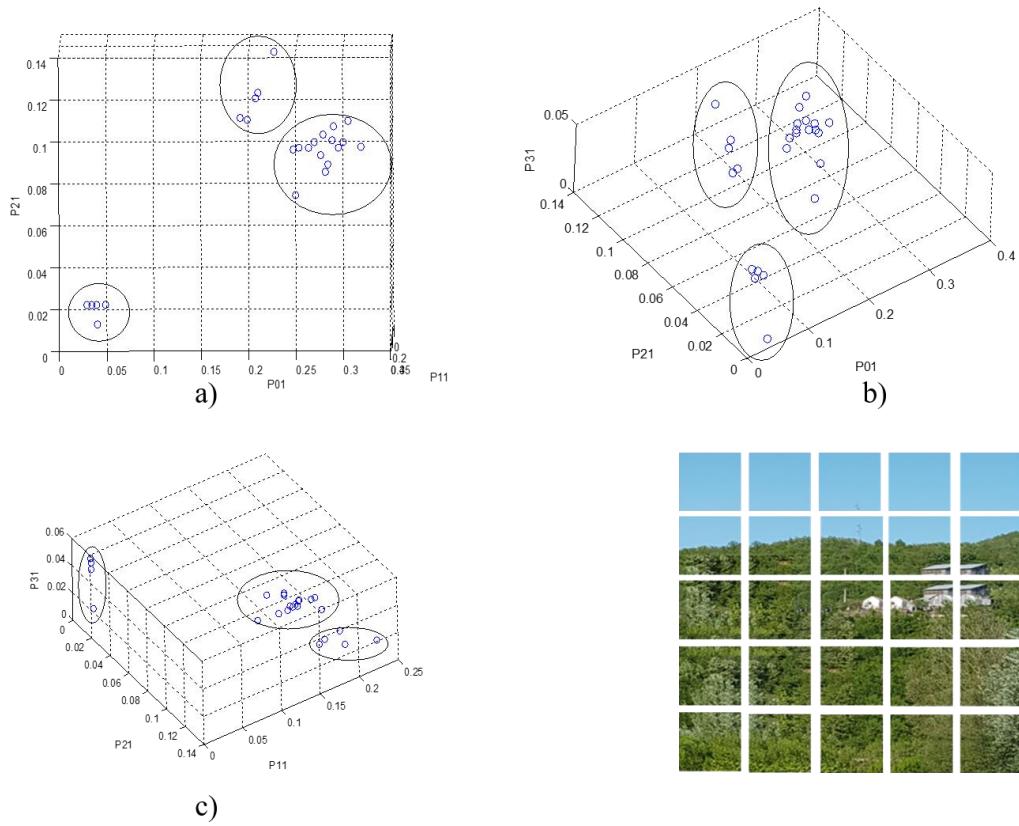
Tabela 3.6 Rezultati klasterovanja blokova za različite kombinacije površina (klasteri prikazani na slici 3.24).

Redni broj klastera	Prva kombinacija	Druga kombinacija	Treća kombinacija
1	1,2,3,4,5	1,2,3,4,5	1,2,3,4,5
2	6,7,8,9,10	6,7,8,9,10,14	6,7,9
3	Preostali blokovi	Preostali blokovi	Preostali blokovi

Iz Tabele 3.6 možemo videti da su blokovi podeljeni u tri različita klastera na sledeći način: prvi klaster obuhvata blokove 1,2,3,4 i 5, drugi klaster uključuje blokove 6,7,8,9 i 10, dok treći klaster obuhvata preostale blokove. Prema tome, klasteri jasno izdvajaju region neba, dok je segmentacija *skyline* regiona najuspešnija za prvu selekciju površina [PAV18].

#### 3.4.1.2 Segmentacija slike zasnovana na R, G i B kanalu u RGB sistemu boja

Testirane slike se uglavnom sastoje od regiona neba i šume. Stoga, analiza je izvršena korišćenjem R, G ili B kanala jer se regioni neba uglavnom razmatraju kao plavi regioni, dok se zelena boja koristi za predstavljanje šume. Prema tome, umesto konvertovanja slike u *grayscale*, izabrani su samo plavi ili samo zeleni kanal. Testiranje je izvršeno i za crveni kanal. Klasteri dobijeni korišćenjem samo plavog kanala su prikazani na slici 3.25(a), (b) i (c), za prvu, drugu i treću selekciju, respektivno. Tabela 3.7 prikazuje rezultate klasterovanja, tj. raspodelu blokova po klasterima, postignutu za sliku 3.23 (levo), ukoliko se izdvaja samo plavi kanal, a zatim računaju parametri multifraktalnog spektra [PAV18].



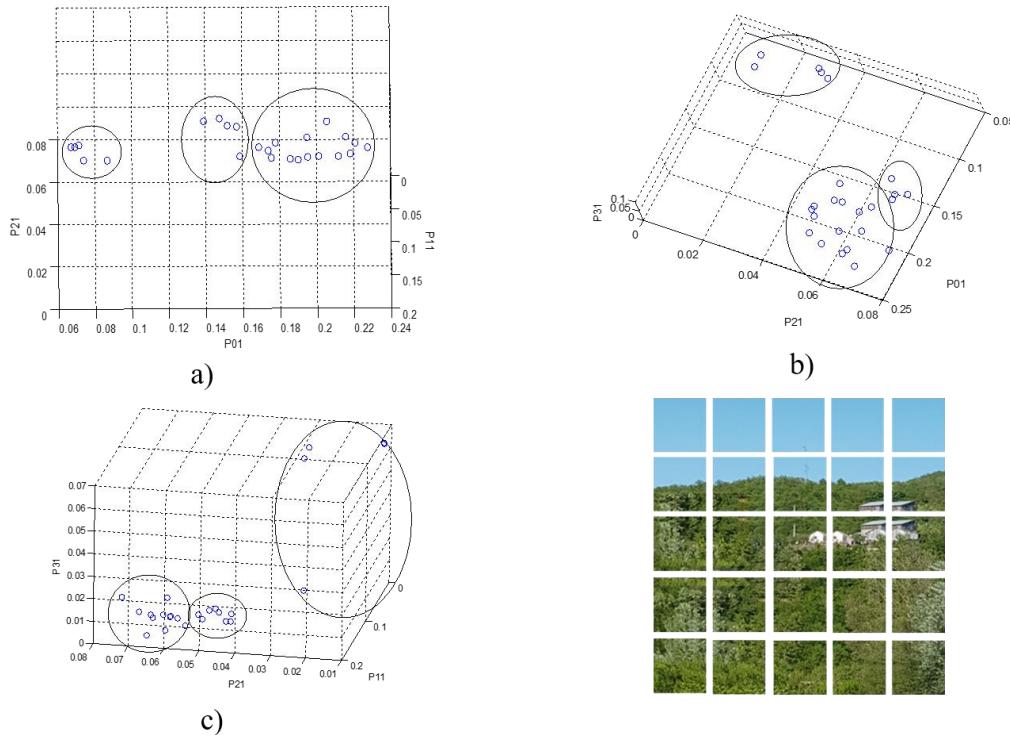
Slika 3.25 Rezultati klasterovanja slike za različite kombinacije površina (samo plavi kanal): a) prva kombinacija, b) druga kombinacija i c) treća kombinacija.

Tabela 3.7. Rezultati klasterovanja blokova za različite kombinacije površina (klasteri prikazani na slici 3.25).

Redni broj klastera	Prva kombinacija	Druga kombinacija	Treća kombinacija
1	1,2,3,4,5	1,2,3,4,5	1,2,3,4,5
2	6,7,8,9,10	6,7,8,9,10	6,7,9,10
3	Preostali blokovi	Preostali blokovi	Preostali blokovi

Iz Tabele 3.7 se može videti da se bolji rezultati klasterovanja dobijaju korišćenjem samo plavog kanala, u poređenju sa rezultatima dobijenim analizom *grayscale* slike.

Rezultati klasterovanja dobijeni korišćenjem samo zelenog kanala su dati na slici 3.26 (a), (b) i (c), za različite kombinacije površina, respektivno. U Tabeli 3.8 su prikazani rezultati raspodele blokova po klasterima (klasteri prikazani na slici 3.26) [PAV18].



Slika 3.26 Rezultati klasterovanja slike za različite kombinacije površina (zeleni kanal):  
a) prva kombinacija, b) druga kombinacija i c) treća kombinacija.

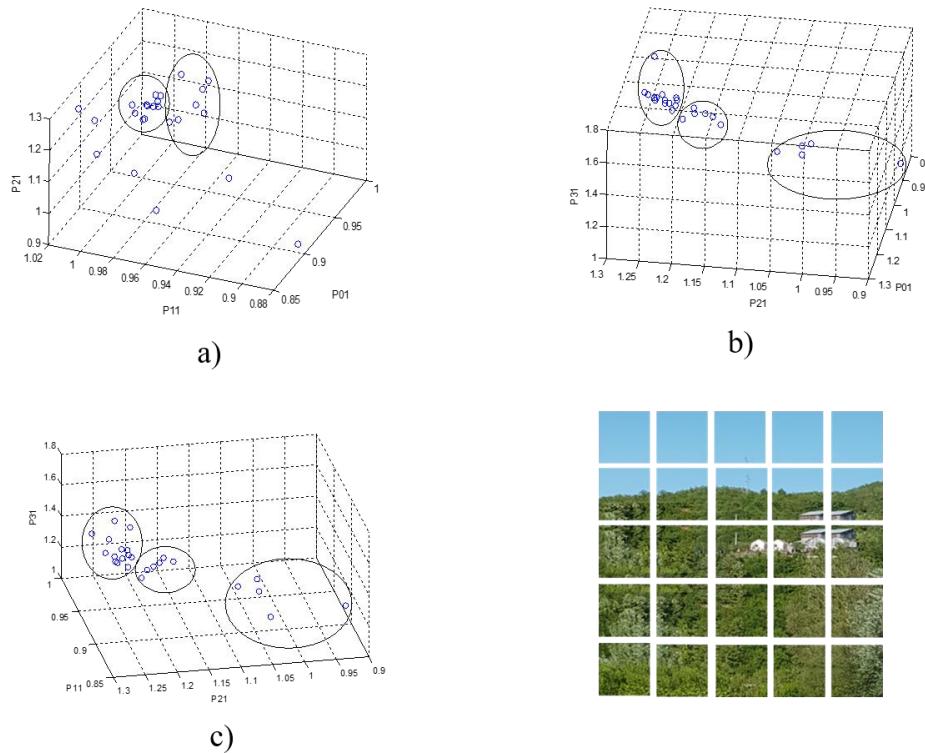
Tabela 3.8. Rezultati klasterovanja blokova za različite kombinacije površina (klasteri prikazani na slici 3.26).

Redni broj klastera	Prva kombinacija	Druga kombinacija	Treća kombinacija
1	1,2,3,4,5	1,2,3,4,5	1,2,3,4,5
2	6,7,8,9,10	6,7,8,9	6,7,9,8,10, 11,12,13
3	Preostali blokovi	Preostali blokovi	Preostali blokovi

Iz Tabele 3.8 možemo zaključiti da su rezultati dobijeni korišćenjem samo zelenog kanala lošiji u poređenju sa rezultatima postignutim analizom samo plavog kanala.

Rezultati klasterovanja dobijeni korišćenjem samo crvenog kanala su prikazani na

slici 3.27 (a), (b) i (c), za različite kombinacije površina, respektivno. Tabela 3.9 daje prikaz raspodele blokova po klasterima (klasteri prikazani na slici 3.27) [PAV18].



Slika 3.27 Rezultati klasterovanja slike za različite kombinacije površina (crveni kanal):

- a) prva kombinacija, b) druga kombinacija i c) treća kombinacija.

Tabela 3.9. Rezultati klasterovanja blokova za različite kombinacije površina (klasteri prikazani na slici 3.27).

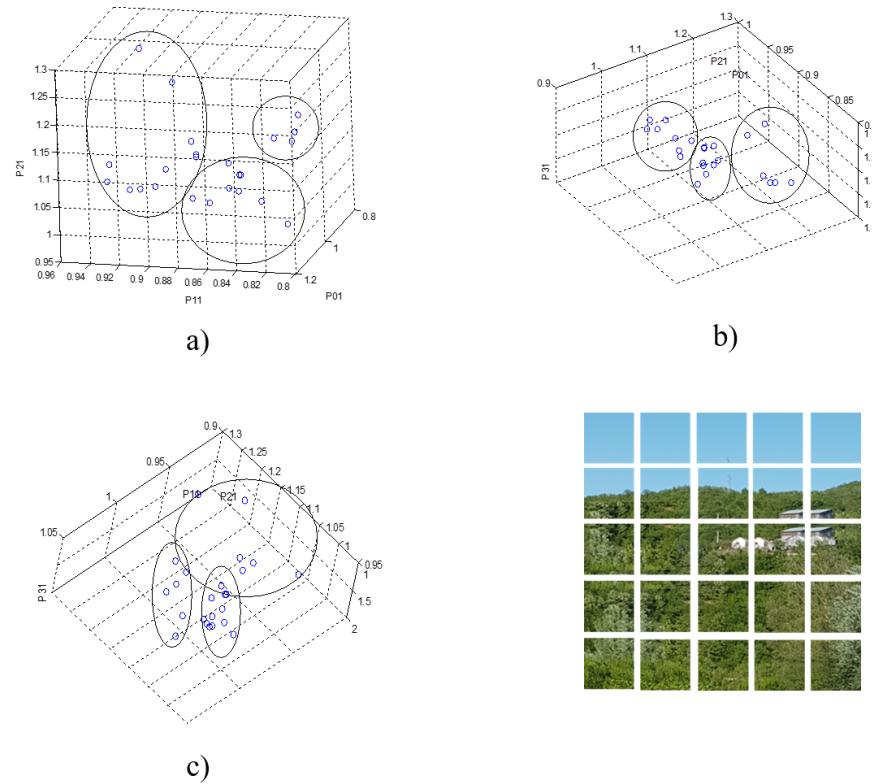
Redni broj klastera	Prva kombinacija	Druga kombinacija	Treća kombinacija
1	1,2,3,4,5,6,7	1,2,3,4,5	1,2,3,4,5
2	8,9,10,11,12,13	6,7,8,9,10,12	6,7,9,8,10,11
3	Preostali blokovi	Preostali blokovi	Preostali blokovi

Iz Tabele 3.9, možemo videti da se najlošiji rezultati klasterovanja dobijaju korišćenjem samo crvenog kanala. Prema tome, najbolji rezultati segmentacije se postižu korišćenjem samo plavog kanala slike, za slike koje su pretežno sastavljene od delova

neba, šume, mora i lično [PAV18].

### 3.4.1.3 Segmentacija slike korišćenjem samo *H* komponente u HSV sistemu boja

Za potrebe testiranja, segmentacija je takođe izvršena korišćenjem samo *hue* komponente posle konverzije slike iz RGB u HSV sistem boja. Primeri klasterovanja dobijeni korišćenjem samo H komponente su dati na slici 3.28 (a), (b) i (c), za različite kombinacije površina, respektivno. U Tabeli 3.10 je prikazana raspodela blokova po klasterima (klasteri sa slike 3.28).



Slika 3.28 Rezultati klasterovanja slike za različite kombinacije površina (samo *hue* komponenta): a) prva kombinacija, b) druga kombinacija i c) treća kombinacija.

Tabela 3.10. Rezultati klasterovanja blokova za različite kombinacije površina (klasteri prikazani na slici 3.28).

Redni broj klastera	Prva kombinacija	Druga kombinacija	Treća kominacija
1	1,2,3,4	1,2,3,4,5,6	1,2,3,4,5
2	5,6,7,8,9,10,11,12,13	7,8,9,10,11,12,13	6,7,9,8,10
3	Preostali blokovi	Preostali blokovi	Preostali blokovi

Iz Tabele 3.10 možemo videti da su rezultati klasterovanja postignuti korišćenjem samo *hue* komponente slični rezultatima dobijenim korišćenjem samo crvenog kanala. Prema tome, najbolji rezultati klasterovanja se postižu korišćenjem samo plavog kanala ili analizom *grayscale* slike [PAV18].

Analiza dobijenih rezultata je pokazala da se analiza singulariteta slike može uspešno primenjivati za klasterovanje i segmentaciju slike u različite objekte. Najbolji rezultati segmentacije se postižu korišćenjem samo plavog kanala slike.

### 3.5 Mahov efekat

Svetlost-EM zračenje čija je talasna dužina  $350\text{nm} \leq \lambda \leq 780\text{nm}$  pobuđuje vizuelni sistem čoveka. Svetlosni izvor jeste svako telo koje emituje svetlost. Primarni izvori svetlosti – proizvode sopstveno zračenje (Sunce, električne svetiljke, sveće...). Sekundarni izvori svetlosti – reflektuju ili čine difuznom svetlost koju emituje primarni izvor.

Radiometrijske veličine (ne uzimaju u obzir karakteristike posmatrača) su sledeće:

- Gustina fluksa zračenja;
- Iradijansa (ozračenost);
- Fluks zračenja.

Fotometrijske veličine (u većoj ili manjoj meri uzimaju uobzir karakteristike posmatrača):

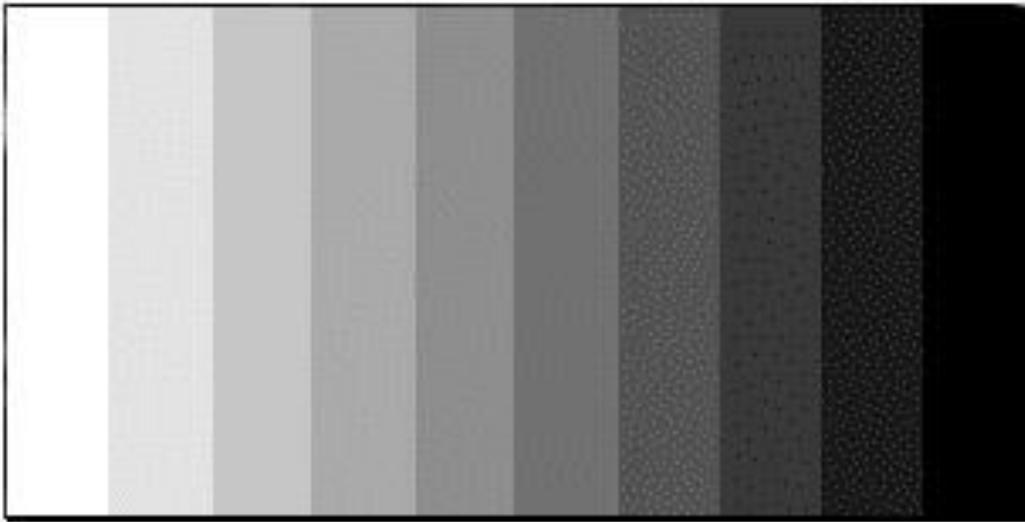
- Osvetljenost ;

- Svetlosni fluks (luminansa).

Luminansa jednog objekta nezavisna je od luminanse drugog objekta. Međutim, ovo subjektivno ne važi, pa se uvodi subjektivni osećaj luminanse – **SJAJNOST**. Eksperiment – smanjuje se razlika osvetljenosti jednog i drugog objekta; u jednom trenutku vizuelni sistem je više neće registrovati, pa važi *Weber-ov zakon*:

$$\frac{|\Delta l_{\min}|}{l} \approx 0,02 \quad (3.32)$$

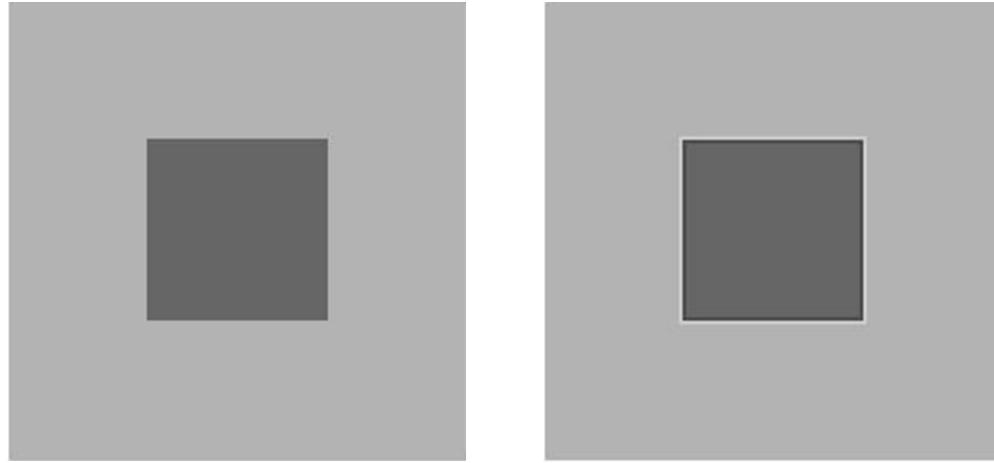
Prema Weberovom zakonu ljudski vid je osetljiv na kontrast, odnosno na relativni odnos, a ne na absolutni iznos luminanse (jednačina 3.32), pa se stoga ivice dela slike različitih luminansi više ističu (Slika 3.29).



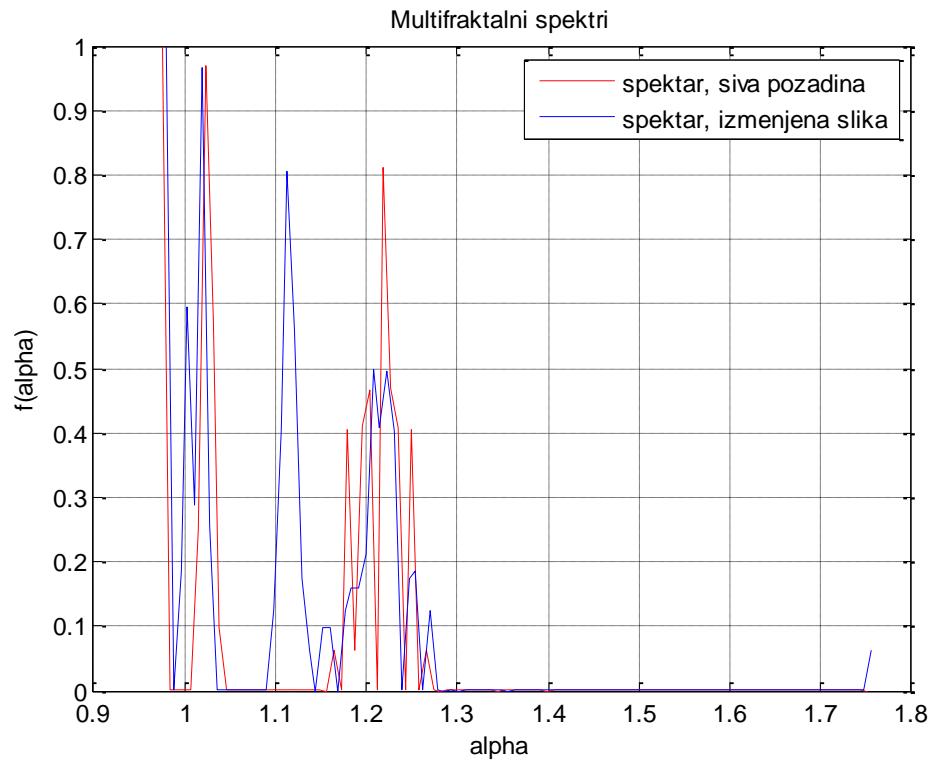
Slika 3.29 Ivice dela slike različitih luminansi se više ističu.

Na slici 3.30 (levo) je dat primer tamnog objekta (kvadrat) na svetloj pozadini. Kao posledica Mahovog efekta, odnosno nesavršenosti ljudskog vizuelnog sistema, imamo utisak da su ivični delovi objekta tamniji u odnosu na ostale, odnosno da je okolina objekta, neposredno uz ivicu, svetlijia od ostalog dela pozadine. Slika 3.30 (desno) predstavlja primer gde su namerno izmenjene vrednosti ivičnih piksela (unutrašnjost objekta je za nijansu tamnija, dok je spoljašnjost za nijansu svetlijia) – zaista različita

osveljenost.



Slika 3.30 Primer svetle pozadine i tamnog objekta (levo) i slika generisana da simulira Mahov efekat (desno).

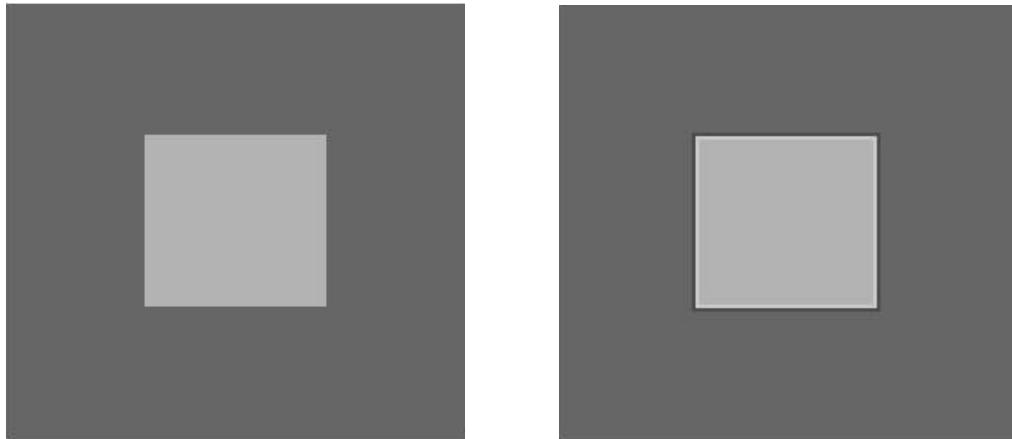


Slika 3.31 Multifraktalni spektri slika sa slike 3.30.

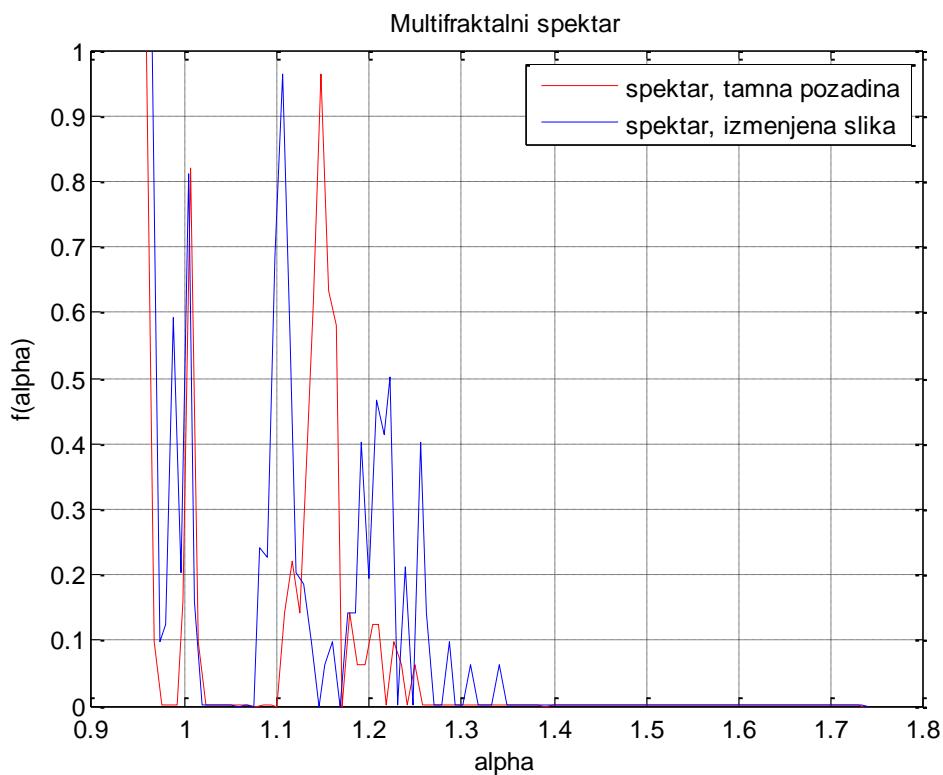
Na slici 3.31 su prikazani multifraktalni spektri slika sa slike 3.30. Iako vizuelno

slike levo i desno izgledaju isto (čini nam se da su to iste slike), njihovi multifraktalni spektri se itekako razlikuju. Stoga možemo zaključiti da su ovo dve različite slike, odnosno parametri multifraktalnog spektra se mogu koristiti za detekciju promena na slikama.

Na slici 3.32 (levo) je dat primer svetlog objekta (kvadrat) na tamnoj pozadini. Kao posledica Mahovog efekta, odnosno nesavršenosti ljudskog vizuelnog sistema, imamo utisak da su ivični delovi objekta svetlij u odnosu na ostale, odnosno da je okolina objekta, neposredno uz ivicu, tamnija od ostalog dela pozadine. Slika 3.32 (desno) predstavlja primer gde su namerno izmenjene vrednosti ivičnih piksela (unutrašnjost objekta je za nijansu svetlij, dok je spoljašnjost za nijansu tamnija) – zaista različita osveljenost. Na slici 3.33 su prikazani multifraktalni spektri slika sa slike 3.32.

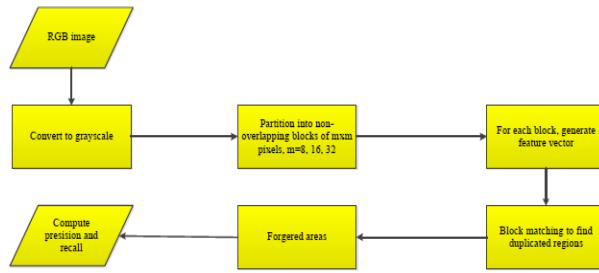


Slika 3.32 Primer tamne pozadine i svetlog objekta (levo) i slika generisana da simulira Mahov efekat (desno).



Slika 3.33 Multifraktalni spektri slike sa slike 3.32.

Iako vizuelno slike levo i desno izgledaju isto (čini nam se da su to iste slike), njihovi multifraktalni spektri se itekako razlikuju, kao i u prethodnom primeru.



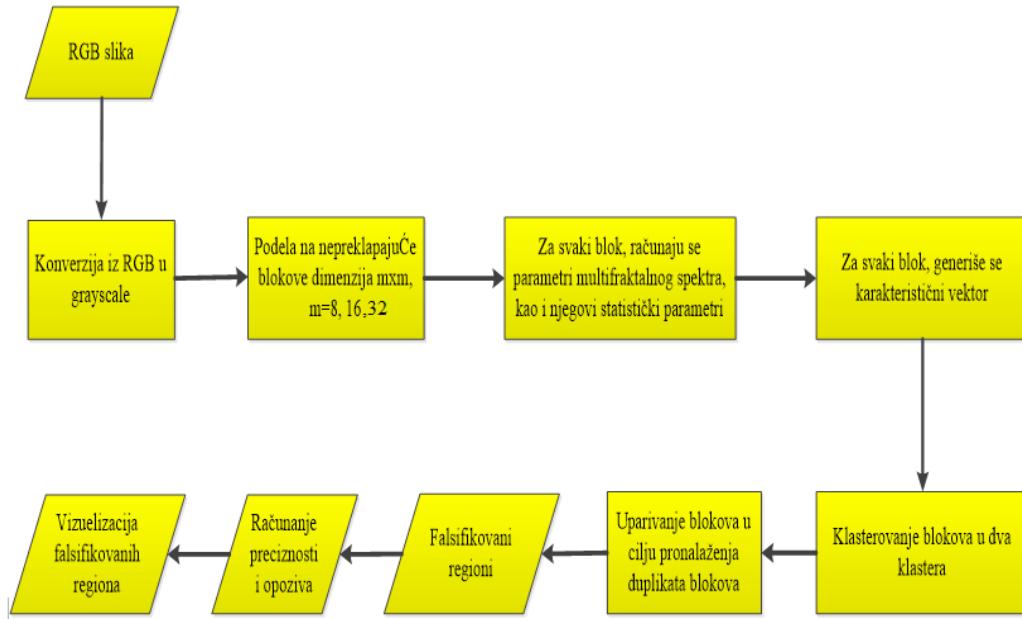
## 4. Metodologija – nova metoda za detekciju CMFD promena

CMFD promene na slikama jesu najčešće promene koje se u današnje vreme javljaju. Stoga je jasno koliko je važan razvoj novih metoda za detekciju takvih promena, a posebno je važno razvijati metode koje detektuju promene bez postojanja reference, u smislu neizmenjenih slika u analizi kopiranih segmenta, kako sa iste slike tako i sa druge slike (iz koje se delovi/cela slika ubacuju – kopiraju). U ovom poglavlju je dat detaljan opis novog algoritma za detekciju takvih promena, koji je zasnovan na multifraktalima i njihovim osobinama.

### 4.1 Nova metoda zasnovana na blokovima

Predložena metoda jeste tkz. *block-based* metoda, jer radi nad nepreklapajućim blokovima slike koja je od interesa. Metoda je zasnovana na multifraktalnim spektrima blokova i njegovim karakteristikama, kao nelinearnim parametrima, na srednjoj vrednosti i standardnoj devijaciji blokova, kao standardnim statističkim parametrima. Analizira se mogućnost ove metode za detekciju *copy-move* promena, a takođe se istražuje i uticaj veličine bloka na performanse detekcije regiona koji su falsifikovani, u terminima lažno pozitivni FP (*False Positive*) i lažno negativni FN (*False Negative*), kao i u pojmovima ispravan odnos detekcije (*correct detection ratio* (CDR) i *correct detection ratio*  $F_C$ ) i lažan odnos detekcije (*false detection ratio*  $F_f$ ). Veličina bloka varira od 32x32, 16x16 do 8x8

piksela. Metoda je sastavljena od 9 koraka i predstavljena je grafički na slici 4.1. Ceo program koji prati opisani algoritam sa slike 4.1 je napisan u programskim paketima Matlab i C# [PAV19].



Slika 4.1. Algoritam predložene metode zasnovane na multifraktalima.

Eksperimentalna analiza se vrši u devet koraka:

### Korak 1: Predprocesiranje slike

Prvi korak u predloženom algoritmu jeste konverzija ulazne RGB slike u intenzitetsku sliku. RGB slika u boji jeste matrica od  $M \times N \times 3$  niza piksela u boji, gde je boja svakog piksela predstavljena kombinacijom crvene, zelene i plave komponente boja, na određenoj prostornoj lokaciji. Intenzitetska slika jeste matrica podataka čije su vrednosti skalirane tako da predstavljaju intenzitete. Najčešće su to vrednosti u intervalu [0, 255], ukoliko koristimo 8-bitnu predstavu podataka. Konverzija se vrši jer su karakteristike koje pripadaju niskofrekvencijskim komponentama zgodnije za uparivanje od karakteristika koje pripadaju visokofrekvencijskim komponentama. Takođe, na ovaj način se smanjuje dimenzionalnost podataka koji se obrađuju, i uvećavaju se različitosti vizuelnih

karakteristika slike. Stoga se za smanjenje visokofrekvencijskih komponenti koristi niskopropusni Gausov filter. U ovoj implementaciji, veličina filtera je 5x5, dok je standardna devijacija 0,5 [PAV19].

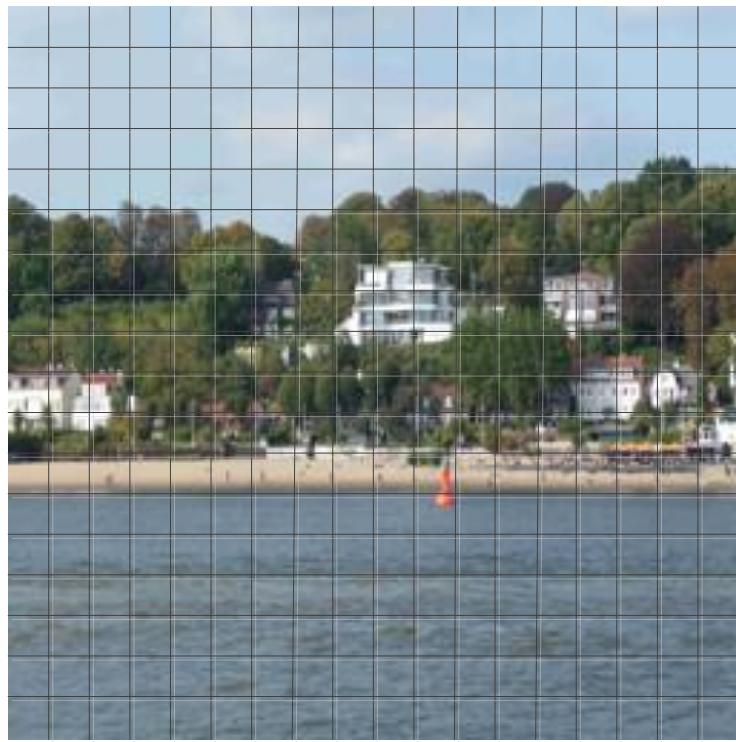
Dalje, R, G i B matrice komponenata slike u boji se konvertuju u intenzitetsku *grayscale* sliku prema dobro poznatoj jednačini (4.1):

$$X_{gray} = 0.299 \times R + 0.587 \times G + 0.114 \times B \quad (4.1)$$

gde su R, G i B crvena, zelena i plava komponenta slike u boji, respektivno [PAV19].

## **Korak 2: Podela slike na nepreklapajuće blokove**

Nakon konverzije RGB slike u intenzitetsku, intenzitetska slika se deli na nepreklapajuće blokove, oblika kvadrata, fiksnih dimenzija,  $m \times m$ , gde je  $m = 8, 16, 32$ . Slika se skenira red po red, počevši od gornjeg levog ugla slike. Podela na blokove se najčešće vrši u cilju smanjenja vremena i kompleksnosti računanja koji su potrebni za proces uparivanja karakteristika piksela, odnosno blokova. Za potrebe testiranja, sve slike su rezolucije 256x256, što ne utiče na uopštenost metode, ali omogućava bolju transparentnost metode. Metoda se može primeniti na slike proizvoljne rezolucije, recimo  $2^n \times 2^n$ . Obzirom na rezoluciju 256x256, svaka slika se deli na 64 bloka dimenzija 32x32, 256 blokova dimenzija 16x16, odnosno na 1024 blokova dimenzija 8x8. Na slici 4.2 je predstavljen grafički postupak podele slike na nepreklapajuće blokove [PAV19].

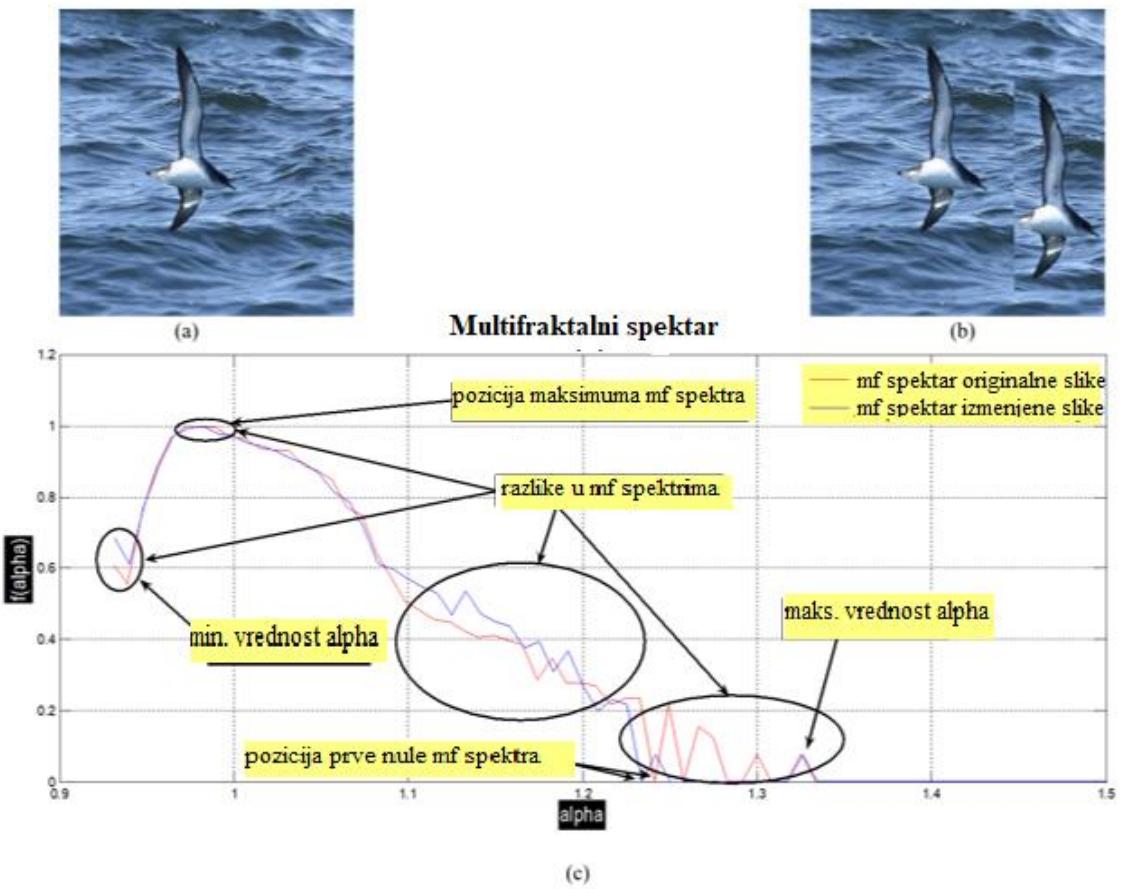


Slika 4.2 Podela slike na nepreklapajuće blokove.

### Korak 3: Računanje multifraktalnog spektra i statističkih parametara blokova

Kod računanja multifraktalnog spektra, kreiraju se dve matrice: matrica Hölder-ovih eksponenata  $\alpha$ , koja opisuje lokalnu regularnost slike (piksela) koja se analizira i matrica raspodele ovih koeficijenata – spektar  $f(\alpha)$  ili multifraktalni spektar slike. Multifraktalni spektar daje globalni opis slike (ili, uopštenije rečeno, fenomena koji se ispituje). Parametar  $\alpha$  daje lokalne informacije o signalima. Spektar  $f(\alpha)$  opisuje globalnost signala. Prema tome, signal se na lokalnom i globalnom nivou može opisati zasnovano na paru  $(\alpha, f(\alpha))$ . Male vrednosti  $\alpha$  označavaju da se signal lokalno slabo menja. Male vrednosti  $f(\alpha)$  označavaju fenomen sa lokalnim vrednostima  $\alpha$  koji se retko dešava, i obrnuto, za velike vrednosti  $f(\alpha)$  [PAV19].

Vrednosti Hölder-ovog eksponenta zavise od pozicije u strukturi i opisuju lokalnu regularnost slike. Naime, razliciti objekti na slici imaju razlicite spekture i pozicije maksimuma, sto se pokazalo kao interesantna metoda za detekciju promena na slikama. Slike 4.3(a) i 4.3(b) prikazuju jednostavni primer originalne slike i njene izmene, dok slika 4.3(c) prikazuje njihove multifraktalne spekture. Na slici 4.3(c) se moze jasno videti da postoje razlike u multifraktalnim spektrima i vrednostima Hölder-ovih eksponenata originalne slike i njene izmene [PAV19].



Slika 4.3. Primer (a) originalne slike, (b) izmenjene slike i (c) njihovi multifraktalni spektri.

Jednostavnim računanjem multifraktalnog spektra originalne slike i njene izmene i izdvajanjem njihovih karakterističnih osobina, mogu se jasno uočiti razlike u izračunatim spektrima, posebno u delovima koji su zaokruženi na slici 4.3(c). Analizom multifraktalnog spektra za veliki broj originalnih i izmenjenih slika, zaključili smo da su takve razlike

glavni indikatori da se desila promena u sadržaju slike. Prema tome, mogu se koristiti kao deskriptori blokova slike [PAV19].

U slučajevima kada se slika menja *copy-move* metodom, kopirani i nalepljeni delovi imaju ili sličnu strukturu, pa se stoga može primeniti multifraktalna analiza, koja u osnovi analizira samosličnost. Za svaki blok se računa multifraktalni spektar, i to metodom histograma, koja je detalno opisana u [RELJ00, RELJ15a, RELJ15b], kao i u jednačinama (3.24-3.27). Nakon računanjanja multifraktalnog spektra, izdvajaju se određeni parametri koji su od značaja za opisivanje blokova. Naime, parametri koji su od interesa su:  $\alpha_{\min}$  i  $\alpha_{\max}$  minimalna i maksimalna vrednost Hölder-ovog eksponenta, pozicija maksimuma multifraktalnog spektra  $\alpha_0$ , prva nula multifraktalnog spektra  $\alpha_1$ , kao i razlika između prve nule i pozicije maksimuma spektra. Pored multifraktalnog spektra, za svaki blok se računaju standardni statistički parametri, kao što su srednja vrednost i standardna devijacija (jednačine (4.2-4.7)) [PAV19].

#### **Korak 4: Izdvajanje karakteristika za svaki blok**

Sledeći korak u predloženom algoritmu jeste izdvajanje karakteristika svakog bloka slike od interesa. Svaki blok se opisuje tkz. karakterističnim vektorom koji se sastoji iz dva tipa deskriptora: multifraktalnih i nemultifraktalnih (statističkih deskriptora). Multifraktalni deskriptori jesu karakteristike multifraktalnog spektra opisane u prethodnom poglavlju, ali samo neke od gore navedenih, za koje se testiranjem većeg broja slika utvrdilo da daju najbolje informacije o sadržaju bloka:  $\alpha_0$  (pozicija maksimalne vrednosti multifraktalnog spektra),  $\alpha_{\min}$  i  $\alpha_{\max}$  (minimalna i maksimalna vrednost Hölder-ovog exponenta),  $\alpha_1$  (prva nula multifraktalnog spektra, odnosno minimalna vrednost multifraktalnog spektra  $f(\alpha)$ , razlika između  $\alpha_1$  i  $\alpha_{\min}$ ,  $\Delta = \alpha_1 - \alpha_{\min}$ , (Slika 4.4), dok su nemultifraktalni deskriptori statistički parametri blokova, srednja vrednost i standardna devijacija (jednačine 4.2 i 4.3 za blokove dimenzija 32x32, jednačine 4.4 i 4.5 za blokove dimenzija 16x16, odnosno jednačine 4.6 i 4.7 za blokove dimenzija 8x8) [PAV19].

$$\bar{x}_{32} = \frac{1}{1024} \sum_{i=1}^{1024} x_i \quad (4.2)$$

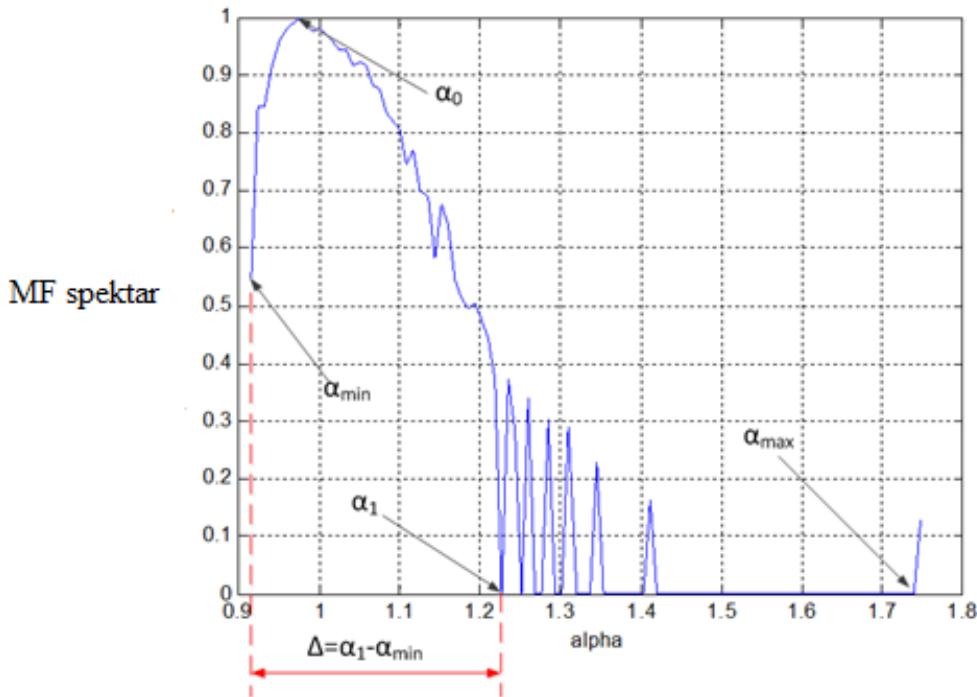
$$\sigma_{32}^2 = \frac{1}{1024} \sum_{i=1}^{1024} (x_i - \bar{x}_{32})^2 \quad (4.3)$$

$$\bar{x}_{16} = \frac{1}{256} \sum_{i=1}^{256} x_i \quad (4.4)$$

$$\sigma_{16}^2 = \frac{1}{256} \sum_{i=1}^{256} (x_i - \bar{x}_{16})^2 \quad (4.5)$$

$$\bar{x}_8 = \frac{1}{64} \sum_{i=1}^{64} x_i \quad (4.6)$$

$$\sigma_8^2 = \frac{1}{64} \sum_{i=1}^{64} (x_i - \bar{x}_8)^2 \quad (4.7)$$



Slika 4.4. Parametri multifraktalnog spektra korišćeni kao deskriptori blokova.

Iz gore navedenog, vidimo da se karakteristični vektor, odnosno vektor koji opisuje svaki blok, za svaki blok sastoji od sedam deskriptora:

$$f(\text{blok}) = \{\alpha_0, \alpha_{\min}, \alpha_{\max}, \alpha_1, \Delta, \bar{x}, \sigma^2\} \text{ [PAV19].}$$

## Korak 5: Klasterovanje blokova u dva klastera

Klasterovanje podrazumeva da se slični podaci (u odnosu na odgovarajuće deskriptore) grupišu zajedno u grupe koje nazivamo klasteri. Dok su elementi unutar klastera slični, klasteri se međusobno razlikuju. Klasterovanje je vid nenadgledanog učenja (engl. *unsupervised learning*) jer klasteri nisu određeni pre ispitivanja podataka. U našem slučaju, broj klastera je dva. Prvom klasteru pripadaju blokovi koji su neizmenjeni, dok drugi klaster obuhvata izmenjene blokove. Za podelu blokova u dva klastera, kao i za uparivanje karakterističnih vektora koristi se novi matematički model opisan u sledećem koraku [PAV19].

## Korak 6: Uparivanje blokova u cilju pronalaženja duplikata blokova

Za uparivanje blokova, tj. uparivanje i pronalaženje sličnih ili istih karakterističnih vektora blokova, predložena je nova semi-metrika,  $d: \mathbb{R}^n \times \mathbb{R}^n \rightarrow [0, +\infty)$ , koja može da poredi objekte (blokove)  $x_i, x_j \in \mathbb{R}^n$ :

$$d(x_i, x_j) = \begin{cases} 0 & , \text{if } i = j \\ \frac{\sum_{k=1}^n (x_i^k - x_j^k)^2}{|i-j|} & , \text{if } i \neq j \end{cases}, \quad i, j = 1, \dots, m \quad (4.8)$$

gde je  $x_i(x_i^1, x_i^2, \dots, x_i^n)$  karakteristični vektor koji opisuje  $i$ -ti blok sa atributima  $x_i^1, x_i^2, \dots, x_i^n$ ,  $i = 1, \dots, m$ , gde je  $m$  broj blokova, a  $n=7$  je broj deskriptora (atributa) za svaki blok, a  $i$  i  $j$  predstavljaju poziciju bloka u slici.

Neka je  $X \neq \emptyset$ . Funkcija  $d: X \times X \rightarrow [0, \infty)$  je semi-metrika na skupu  $X$  ukoliko za nju važe simetričnost, refleksivnost, i identitet koincidencije [NED16].

Za semi-metriku ne mora da važi jednačina trougla [NED16].

Lemma:  $d: \mathbb{R}^n \times \mathbb{R}^n \rightarrow [0, +\infty)$  definisano kao

$$d(x_i, x_j) = \begin{cases} 0 & , \text{if } i = j \\ \frac{\sum_{k=1}^n (x_i^k - x_j^k)^2}{|i-j|} & , \text{if } i \neq j \end{cases}, \quad i, j = 1, \dots, m, m \in \mathbb{N} \quad (4.9)$$

je ste semi-metrika.

Dokaz:

Dokazujemo da važi simetrija.

$\forall x_i, x_j \in \mathbb{R}^n$  if  $i = j$  dokaz je trivijalan  $d(x_i, x_j) = 0 = d(x_j, x_i)$

Ako je  $i \neq j$  onda važi  $d(x_i, x_j) = \frac{\sum_{k=1}^n (x_i^k - x_j^k)^2}{|i-j|} = \frac{\sum_{k=1}^n (x_j^k - x_i^k)^2}{|j-i|} = d(x_j, x_i)$

Refleksivnost:  $\forall x_i \in \mathbb{R}^n$  zato što je  $i = j$   $d(x_i, x_i) = 0$

Identitet koincidencije:  $\forall x_i, x_j \in \mathbb{R}^n$   $d(x_i, x_j) = 0 \Leftrightarrow i = j \Leftrightarrow x_i = x_j$ .

Lemma dokazana.

Takođe, koristi se interval  $[\min, \max]$ , gde je  $\min$  najmanja vrednost svih minimalnih vrednosti semi-metrike svih izmenjenih blokova i svih baza [COM18, IMA18] (računato prema formuli (4.8)), dok  $\max$  predstavlja najveću vrednost od svih maksimalnih vrednosti semi-metrike svih izmenjenih blokova iz svih baza (računato prema formuli (4.8)). Preciznije rečeno, to je  $X_1, X_2, \dots, X_p$  konačan broj skupova (u ovom slučaju *datasets* od slike) sa konačnim elementima  $x_i \in X_k, i = 1, 2, \dots, m_k$  i  $k = 1, 2, \dots, p, p, m_k \in \mathbb{N}$ , označeno sa  $\min = \min_{1 \leq k \leq p} d(x_i, x_j), x_i, x_j \in X_k$ , gde su  $x_i, x_j$  vektori izmenjenih blokova.

Kako bi se donela odluka, grupisanje klastera je korišćeno samo za blokove čija je semi-metrika  $d$  od jednog do drugog bloka u intervalu  $[\min, \max]$  [PAV19].

## Korak 7: Izdvajanje falsifikovanih regiona (blokova)

Metoda promenljivih okolina je metaheuristika. Predstavljena je devedesetih godina prošlog veka i zasniva se na tri osnovne činjenice:

1. Lokalni minimum u odnosu na jednu okolinu ne mora biti i lokalni minimum u odnosu na neku drugu okolinu;
2. Globalni minimum je lokalni minimum u odnosu na sve okoline;
3. Za većinu problema lokalni minimumi u odnosu na razne okoline su međusobno bliski [GLI17a].

Sve dok se ne zadovolji neki od kriterijuma zaustavljanja, vrši se sistematska pretraga okolina. Kriterijumi koji se najčešće koriste za zaustavljanje su: maksimalan broj iteracija između dva poboljšanja, minimalno poboljšanje u okviru unapred definisanog broja iteracija, maksimalno procesorsko vreme rada i drugi [GLI17a]. U principu, kriterijum zaustavljanja se bira na osnovu kompromisa između utrošenog vremena i kvaliteta koji se dobija. Osnovna metoda promenljivih okolina je najrasprostranjenija varijanta metode promenljivih.

Kod metode VNS osnovni koraci su sadržani u petlji u kojoj se menja indeks okoline  $k$ , određuje slučajno rešenje iz okoline, izvršava procedura lokalnog pretraživanja i proverava se kvalitet dobijenog lokalnog minimuma. Ovakvi koraci se ponavljaju sve dok ne bude zadovoljen neki od kriterijuma zaustavljanja [GLI17a]. U trenutku kada se bira okolina  $k$  početna rešenja se generišu na slučajan način kako bi se obezbedilo pretraživanje različitih regiona prilikom sledećeg razmrdavanja okoline  $k$ . Okoline se uglavnom razlikuju po broju transformacija (rastojanju) ili po vrsti transformacija (metrički) okolina jer se obezbeđuje više preduslova za dobijanje kvalitetnijih konačnih rešenja [GLI17a].

Osnovna metoda promenljivih okolina (BVNS) [MLA97, MLA18] primenjena na problem detektovanja izmenjenih blokova na slici implementirana je na sledeći način. Najpre su izračunata rastojanja (korišćenjem semi-metrike) između blokova primenom formule (jednačina (4.8)). U fazi predprocesiranja vrste matrice rastojanja (kao i

odgovarajući indeksi blokova) sortirane su u neopadajućem poretku [GLI17b, GLI17c]. Zatim se odredi interval  $[min, max]$  na osnovu procesa opisanog u koraku 5 i posmatraju se samo blokovi čije je rastojanje u ovom intervalu. Ovi podaci korišćeni su za efikasniju implementaciju operatora razmrdavanja. Naime, kako se svako rešenje karakteriše skupom centroida, operator razmrdavanja sastoji se u zameni odgovarajućeg broja centroida. Preciznije, razmrdavanje u okolini  $k$  podrazumeva da se centroidi zamene slučajno izabranim blokovima koji nisu centroidi, a udaljeni su najviše  $k$  mesta od centroida koga menjaju. U svakom koraku razmatra se zamena svih centroida, pri čemu do zamene neće doći ukoliko je slučajno izabrani blok najbliži tom centroidu (u stvari, to je sam taj centroid). Lokalno pretraživanje sastoji se u sistematskoj zameni jednog centroida blokom koji nije centroid. Ono polazi od rešenja dobijenog razmrdavanjem i izvršava se po principu najboljeg poboljšanja (*Best Improvement*) dok god ima poboljšanja [GLIS17a, PAV19].

Pseudokodom BVNS se može predstaviti na sledeći način:

- Inicijalizacija. Izabrati početno rešenje i definisati kriterijum zaustavljanja STOP=0
- Ponavljam
  - {
  - o
    - o Ponavljam
    - o {
      - Razmrdavanje () – Generisati slučajno rešenje u  $i$ -toj okolini od .
      - Lokalno pretraživanje () – označiti sa dobijeni lokalni minimum primenom neke od procedura loklanog pretraživanja koje polazi od.
      - Provera rešenja () – Ako je lokalni minimum bolji od trenutnog minimuma, preći u to rešenje tj..
    - Nastaviti do novog početnog rešenja u okolini

Inače preći u sledeću okolinu tj.

Ako je zadovoljen kriterijum zaustavljanja postaviti vrednost STOP = 1.

- o       } sve dok nije ili STOP = 1
- } sve dok nije STOP = 1

### Korak 8: Računanje preciznosti i opoziva

Performanse predloženih metoda se najčešće mere u pojmovima preciznosti (*precision*) i opoziva (*recall*), kao i u pojmovima ispravan odnos detekcije (*correct detection ratio* (CDR) i ( $F_c$ ) i lažni odnos detekcije (*false detection ratio*  $F_f$ ). Preciznost označava verovatnoću ispravnog detektovanja blokova koji su izmenjeni kao izmenjene, tj verovatnoću da su blokovi detektovani kao izmenjeni zaista izmenjeni. Opoziv označava verovatnoću (mogućnost) detektovanja izmenjenih blokova u slici. Stvarno pozitivni (*True positive* - TP) predstavlja broj izmenjenih blokova, koji su klasifikovani kao izmenjeni. Lažno pozitivni (*false positive* - FP) predstavlja broj originalnih (autentičnih) blokova koji su klasifikovani kao izmenjeni, dok lažno negativni (*false negative* - FN) predstavlja broj blokova koji su izmenjeni, ali su klasifikovani kao originalni (autentični):

$$\text{Preciznost} = \text{TP}/(\text{TP} + \text{FP}) \quad (4.10)$$

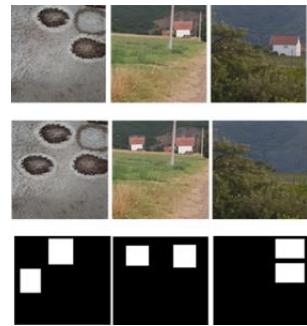
$$\text{Opoziv} = \text{TP}/(\text{TP} + \text{FN}) \quad (4.11)$$

Naime, preciznost se računa kao količnik broja izmenjenih blokova koji su klasifikovani kao izmenjeni i zbiru broja blokova izmenjenih blokova koji su klasifikovani kao izmenjeni i broja originalnih blokova koji su klasifikovani kao izmenjeni. Sa druge strane, opoziv se računa kao količnik broja izmenjenih blokova koji su klasifikovani kao izmenjeni i zbiru broja blokova izmenjenih blokova koji su klasifikovani kao izmenjeni i broja izmenjenih blokova koji su klasifikovani kao originalni [PAV19].

### Korak 9: Vizuelizacija falsifikovanih regiona

Poslednji korak u predloženom algoritmu jeste vizuelizacija falsifikovanih regiona, kako bi se prikazali i lokalizovali izmenjeni delovi na slici. Vizuelizacija je izvršena tako

što su izmenjeni blokovi prikazani belom bojom, dok je ostatak slike prikazan crnom bojom [PAV19].



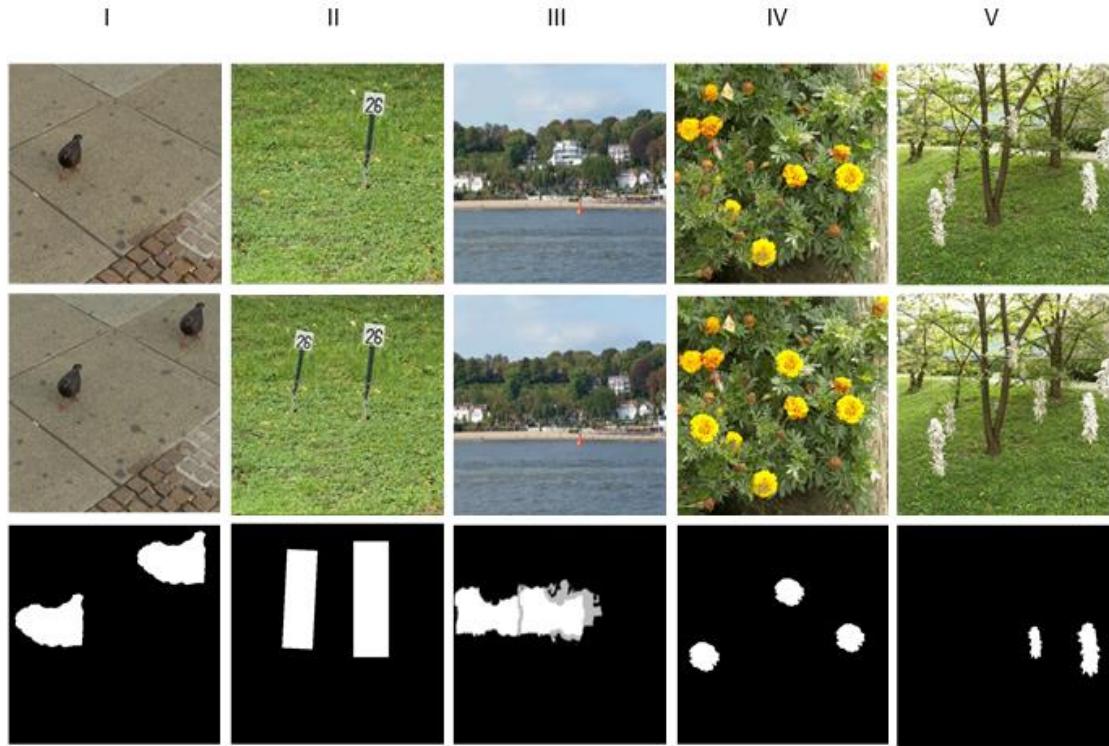
## 5. Rezultati simulacije i diskusija rezultata

U ovoj sekciji su predstavljeni eksperimentalni rezultati predloženog algoritma, kako bi se opisale performanse istog. Nova metoda je primenjena na bazi slika koja se sastoji iz dva dela: prvi deo predstavlju slike iz javno dostupnih baza slika [COM18, IMA18], koje su standardne baze koje većina autora koristi za testiranje performansi svojih metoda, dok drugi deo predstavlja slike koje su generisane za potrebe istraživanja.

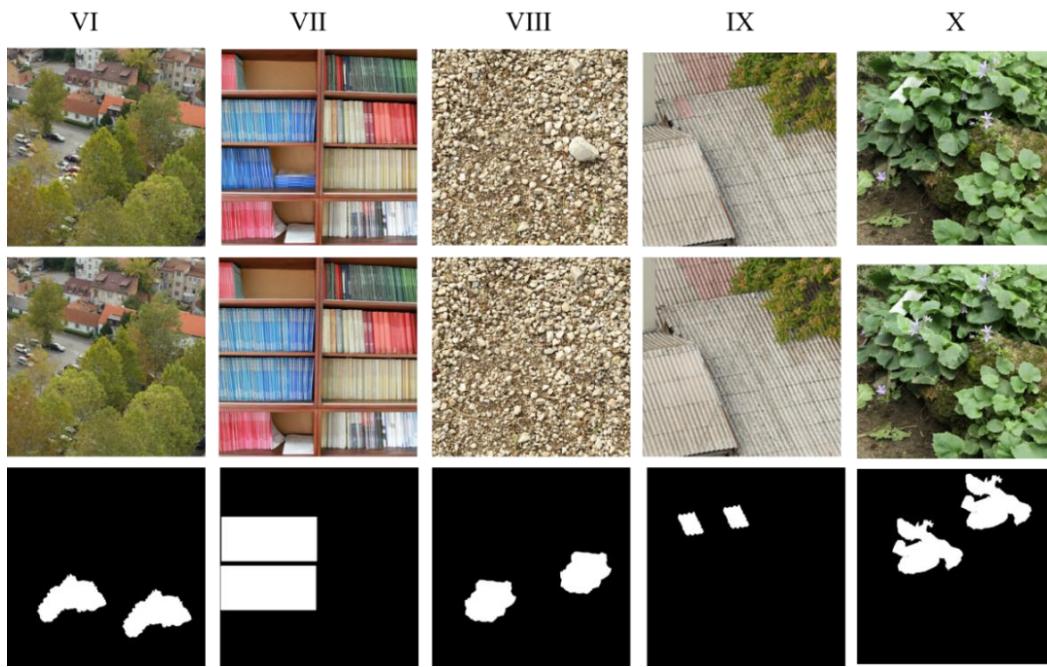
### 5.1 Rezultati i diskusija slika iz javno dostupnih baza

Korišćene su dve javno dostupne baze: CoMoFoD baza slika i *Image Manipulation Dataset* baza slika. CoMoFoD baza slika se sastoji od 200 slika: 100 originalnih i 100 izmenjenih, dok se *Image Manipulation Dataset* baza slika sastoji od 48 slika. Rezolucija svih testiranih slika jeste 256x256. Slike su izmenjene na taj način da je deo slike kopiran i nalepljen na neki drugi deo iste slike (*copy move*). Delovi slike koji se kopiraju se prenaljepljivanja mogu geometrijski transformisati, primenjujući rotaciju i skaliranje. Kopirani delovi takođe mogu biti različitih dimenzija (malih, srednjih ili velikih). U ovom poglavlju su predstavljeni rezultati za 15 izabranih slika, i to za 10 slika iz navedenih javno dostupnih baza koje su drugi autori koristili [ALK16, CHO17, LEE15, SON18] kao i za pet slika iz baze koja je generisana za potrebe istraživanja. Na svakoj od slika, jedan ili više regionala su

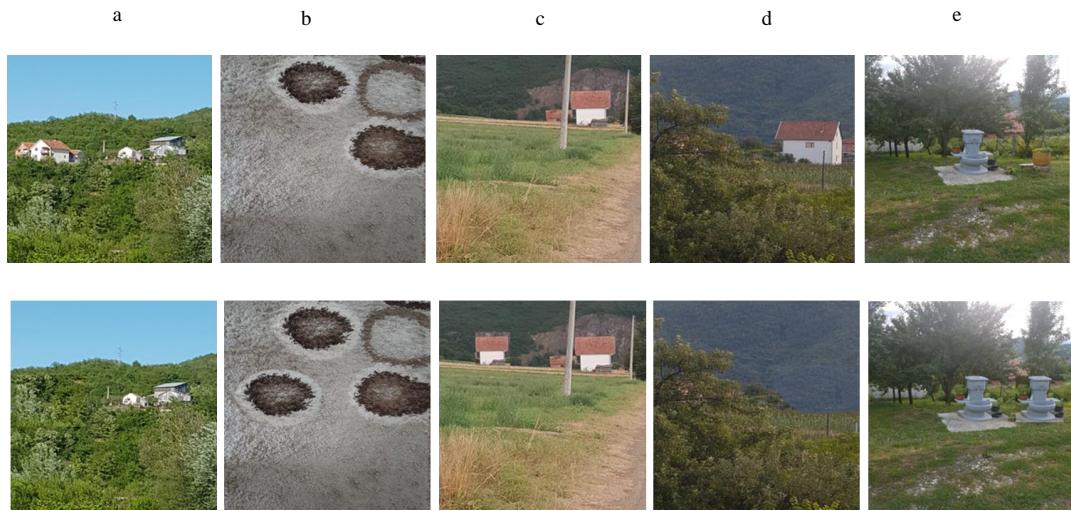
kopirani. Takođe, veličina kopiranih regiona varira od slike do slike. Originalne i izmenjene slike su prikazane na slikama 5.1, 5.2 i 5.3 [PAV19].



Slika 5.1 Primeri *Copy-move* falsifikovanja (prvih pet slika iz javno dostupnih baza): originalne slike (prvi red), odgovarajuće izmenjene slike (drugi red) i *ground truth map* (treći red) [PAV19].



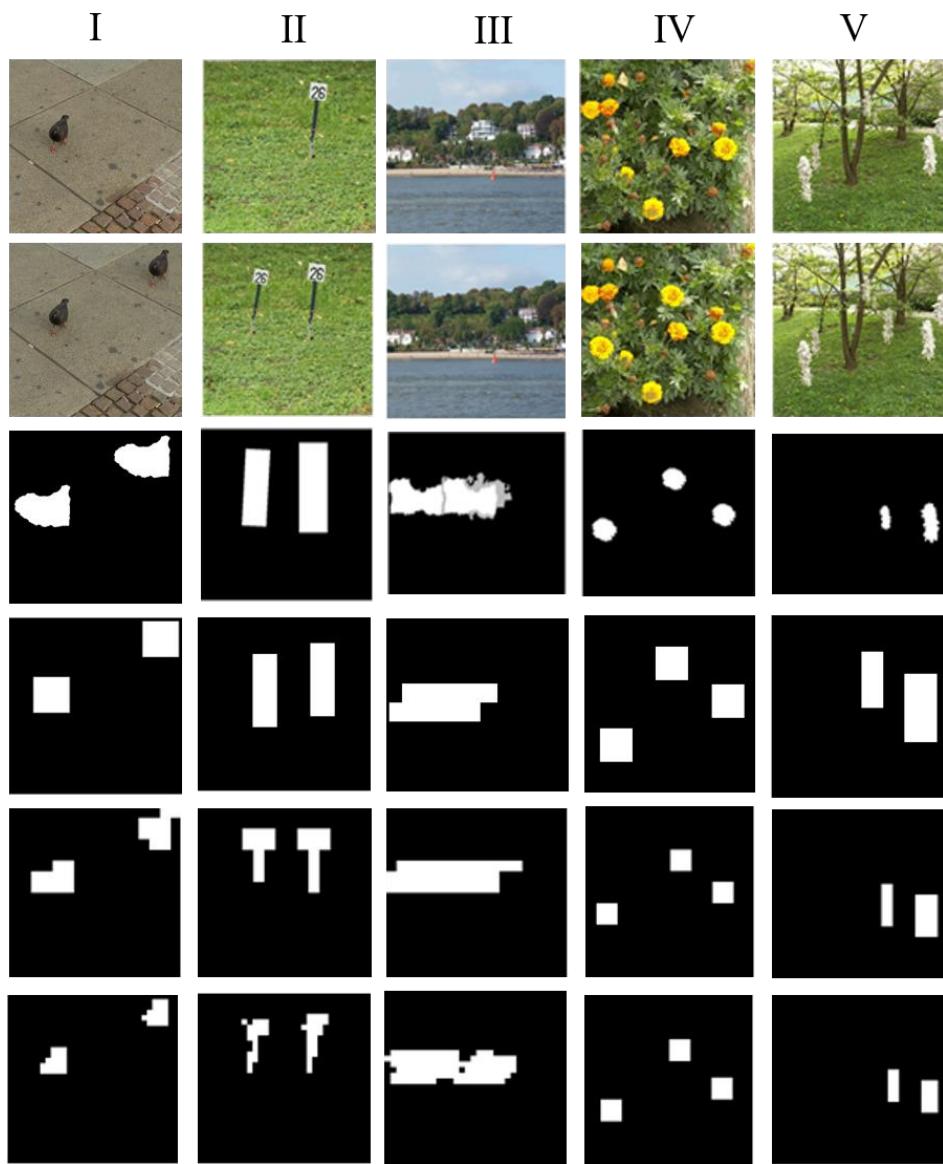
Slika 5.2 Primeri *Copy-move* falsifikovanja (prvih pet slika iz javno dostupnih baza): originalne slike (prvi red), odgovarajuće izmenjene slike (drugi red) i *ground truth map* (treći red) [PAV19].



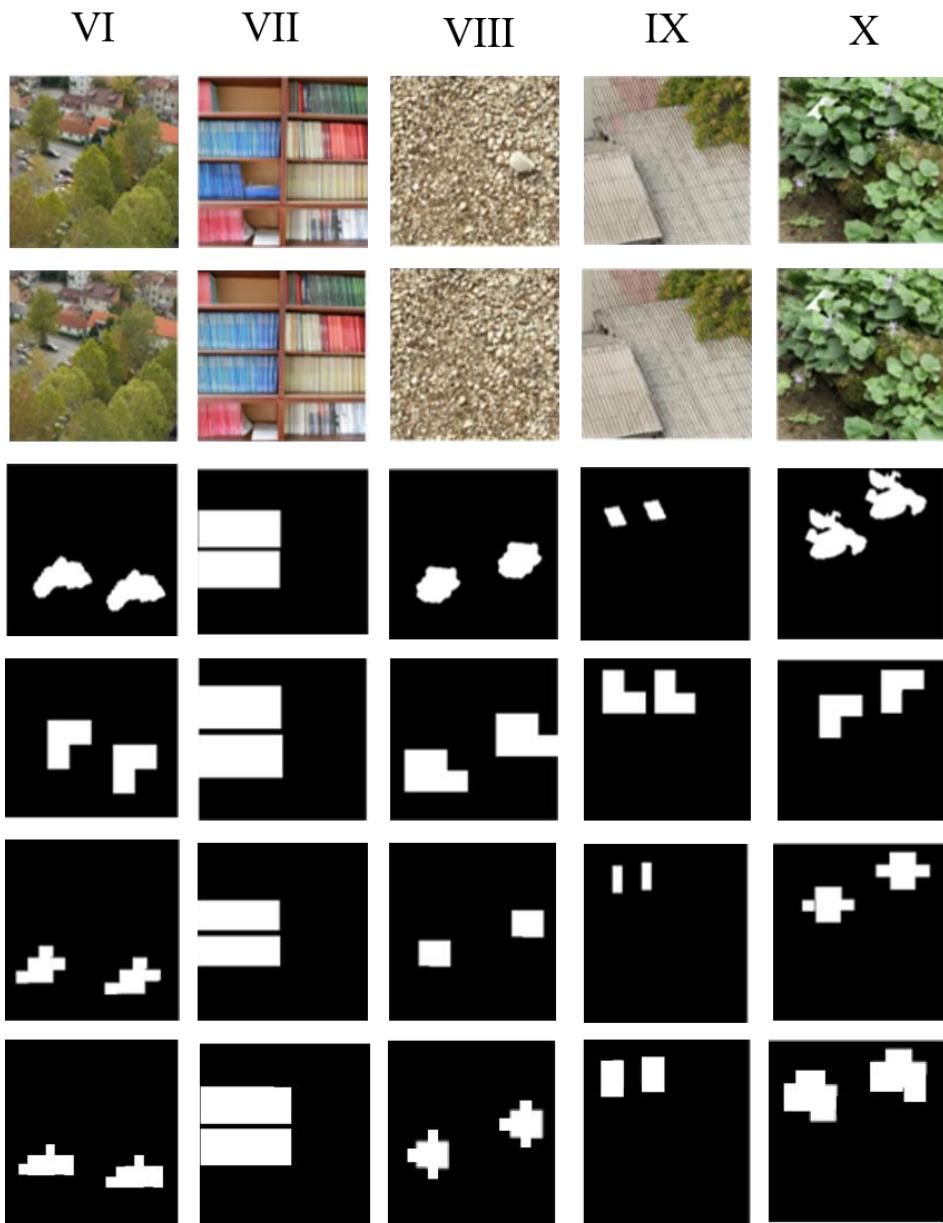
Slika 5.3 Primeri slika generisanih za potrebe istraživanja – originalne slike (prvi red) i odgovarajuće izmene (drugi red).

Ovaj algoritam je implementiran u cilju razvoja *block-based* metode za detekciju *copy-move* promena na slikama, za nepreklapajuće blokove fiksnih dimenzija, kao i proračuna performansi algoritma u pojmovima preciznosti detekcije, u zavisnosti od veličine bloka.

Slika 5.4 prikazuje rezultate detekcije izmenjenih regiona prvog seta testiranih slika (slike sa slike 5.1 (prvih pet slika iz javno dostupnih baza)), za različite veličine blokova (32x32, 16x16 i 8x8), dok slika 5.5 prikazuje rezultate detekcije izmenjenih regiona za drugi set testiranih slika (slike sa slike 5.2 (drugih pet slika iz javno dostupnih baza)), takođe za različite dimenzijske veličine blokova (32x32, 16x16 i 8x8) [PAV19].



Slika 5.4 Prvih pet primjera *copy-move* detekcije: originalne slike (prvi red), odgovarajuće izmenjene slike (drugi red), *ground truth mape* (treći red), rezultati detekcije falsifikata za blokove dimenzija 32x32 (četvrti red), rezultati detekcije falsifikata za blokove dimenzija 16x16 (peti red) i rezultati detekcije falsifikata za blokove dimenzija 8x8 (šesti red) [PAV19].



Slika 5.5 Drugih pet primera *copy-move* detekcije: originalne slike (prvi red), odgovarajuće izmenjene slike (drugi red), *ground truth mape* (treći red), rezultati detekcije falsifikata za blokove dimenzija 32x32 (četvrti red), rezultati detekcije falsifikata za blokove dimenzija 16x16 (peti red) i rezultati detekcije falsifikata za blokove dimenzija 8x8 (šesti red).

Performanse preciznosti predloženog algoritma za detekciju *copy-move* promena na slikama su izražene u pojmovima preciznost i opoziv, za slike generisane za potrebe istraživanja, kao i za slike iz javno dostupnih standardnih baza CoMoFoD i *Image*

*Manipulation Database.* Za svaku od slika je računat uticaj veličine nepreklapajućih blokova na performanse kao što su preciznost i opoziv. Opisani algoritam, koji predlaže novu semi-metriku za pronalaženje sličnih ili istih karakterističnih vektora blokova, je implementiran u proramskom jeziku C#. Uspeh predložene metode zasnovane na novoj semi-metrici, za slike iz javno dostupne baze, je prikazan u poređenju sa rezultatima koje su autori dobili u [ALK16], za blokove dimenzija 8x8, za slike iz CoMoFoD skupa slika (I, II, IV, V, VI, VII, VIII, IX i X). Uspešnost predložene metode je prikazana u Tabeli 5.1, u poređenju sa rezultatima dobijenim u [ALK16]. Tabela 5.2 prikazuje dobijene rezultate za isti skup slika, samo za blokove dimenzija 16x16 [PAV19].

Tabela 5.1.<sup>6</sup> Performanse tačnosti u pojmovima preciznost i opoziv za blokove dimezija 8x8, u procentima, za slike I, II, III, IV, V, VI, VII, VIII, IX i X.

Slika	Eksperimentalni rezultati			
	Rezultati iz [ALK16]		Rezultati postignuti predloženom metodom	
	Preciznost (%)	Opoziv (%)	Preciznost (%)	Opoziv (%)
I	87.62	99.48	91.67	100
II	100	97.53	95.83	97.87
III	Nije raspoloživo u [ALK16]	Nije raspoloživo u [ALK16]	100	98.33
IV	26.58	94.85	73.08	95
V	63.32	88.47	81.48	95.65
VI	59.25	98.68	86.95	99.56
VII	49.80	100	92.36	100
VIII	95.19	96.25	97.36	97.36
IX	62.53	97.30	89.32	96.35
X	41.49	93.37	95.48	96.65

Iz Tabele 5.1 može se zaključiti da su dobijeni rezultati značajno bolji u terminima preciznosti i opoziva, za slike označene sa I, IV, V, VI, VII, VIII and X, posebno u pojmu

---

<sup>6</sup> Napomena: numeracija u tabelama 5.1, 5.2, 5.3, .4 i 5.5 predstavlja redne brojeve slika sa slika 5.1 i 5.2.

preciznosti u slučaju slika IV, V, VI, VII, IX and X. Takođe, rezultati dobijeni za sliku II su relativno zadovoljavajući u pojmovima preciznosti, kao i rezultati dobijeni za sliku IX, u terminu opoziva.

Tabela 5.2. Performanse tačnosti u pojmovima preciznost i opoziv za blokove dimenzija 16x16, u procentima, za slike I, II, III, IV, V, VI, VII, VIII, IX I X.

Slika	Eksperimentalni rezultati	
	Preciznost (%)	Opoziv (%)
I	93.75	100
II	100	100
III	93.55	96.67
IV	76.74	97.06
V	84.61	91.67
VI	99.19	99.19
VII	99.16	100
VIII	100	99.59
IX	99.60	99.60
X	100	100

Rezultati predstavljeni u Tabeli 5.2 pokazuju visok procenat tačnosti detekcije izmenjenih regiona, u terminima preciznost i opoziv. U poređenju sa rezultatima prikazanim u Tabeli 5.1, možemo zaključiti da se bolja preciznost dobija korišćenjem blokova dimenzija 16x16, za isti skup testiranih slika [PAV19].

Razmatrajući rezultate postignute za sliku III (Tabele 5.1 i 5.2), možemo zaključiti da predložena metoda daje zadovoljavajuće rezultate, čak i kada je testirana slika komplikovanijeg sadržaja. U tom slučaju, bolje je koristiti blokove manjih dimenzija (veća preciznost se postigla korišćenjem blokova dimenzija 8x8 u poređenju sa blokovima dimenzija 16x16) [PAV19].

U cilju poređenja dobijenih rezultata sa rezultatima drugih autora, pored pojnova preciznost i opoziv, uvode se nove parametri koji opisuju preciznost predložene metode i

koji se definišu na sledeći način: *correct detection ratio* (CDR), korišćen od strane autora u [CHO17], i koji se definiše na sledeći način:

$$CDR = \frac{\text{The detected tampered region}}{\text{The tampered region}} \quad (5.1)$$

kao i *correct detection ratio*  $F_C$  i *false detection ratio*  $F_f$ , korišćeni od strane autora u [LEE15], i definisani na sledeći način:

$$F_C = \frac{|\mu \cap \mu^C + \omega \cap \omega^C|}{|\mu| + |\omega|} \quad (5.2)$$

$$F_f = \frac{|\mu^C - \mu| + |\omega^C - \omega|}{|\mu^C| + |\omega^C|} \quad (5.3)$$

gde:

- $\mu$  i  $\omega$  respektivno označavaju broj piksela originalnih regiona i broj piksela izmenjenih regiona u originalnoj slici,
- $\mu^C$  i  $\omega^C$  respektivno označavaju broj piksela originalnih i izmenjenih regiona koji prikazuju rezultate detekcije,
- $| |$  označava površinu (oblast) regiona,  $\cap$  označava presek dva regiona, i – označava razliku između dva regiona,
- $F_C$  označava performanse predloženog algoritma u terminu korektnog lociranja piksela *copy-move* izmenjenih regiona u izmenjenoj slici,
- $F_f$  procenat piksela koji su lažno pozitivni (t.j. pogrešno označeni kao izmenjeni).

Drugim rečima, ova dva parametra označavaju preciznost predloženog algoritma za detekciju *copy-move* regiona. Što je  $F_C$  bliže 1 i  $F_f$  bliže 0, metoda je preciznija [LEE15].

U Tabeli 5.3 su prikazani rezultati poređenja rezultata prikazanih u [CHO17] i rezultata dobijenih predloženom metodom, u pojmovima CDR, za sliku II u slučaju blokova dimenzija 16x16 i 32x32. Tabela 5.4 daje prikaz rezultata poređenja sa rezultatima

prikazanim u [LEE15], u pojmovima  $F_c$  i  $F_f$ , za slike II, V, VI I VII, za blokove dimenzija 16x16, dok Tabela 5.5 prikazuje iste rezultate ali za blokove dimezija 32x32 [PAV19].

Tabela 5.3. Performanse tačnosti algoritma u pojmovima CDR, u slučaju dimenzijskih blokova 16x16 i 32x32, za sliku II.

Slika	Veličina bloka	Eksperimentalni rezultati	
		Rezultati iz [CHO17]	Rezultati postignuti predloženom metodom
		CDR	CDR
II	16x16	0.991	1
II	32x32	0.974	0.8

Tabela 5.4. Performanse tačnosti algoritma u pojmovima  $F_c$  i  $F_f$ , za blokove dimenzija 16x16, za slike II, V, VII i VIII.

Slika	Eksperimentalni rezultati			
	Rezultati iz [LEE15]		Rezultati postignuti predloženom metodom	
	$F_c$	$F_f$	$F_c$	$F_f$
II	0.898	0.154	1	0
V	0.996	0.003	0.988	0.049
VI	0.976	0.012	0.988	0.004
VII	0.992	0.011	0.993	0.015

Tabela 5.5. Performanse tačnosti algoritma u pojmovima  $F_c$  i  $F_f$ , za blokove dimenzija 32x32, za slike II, V, VII i VIII.

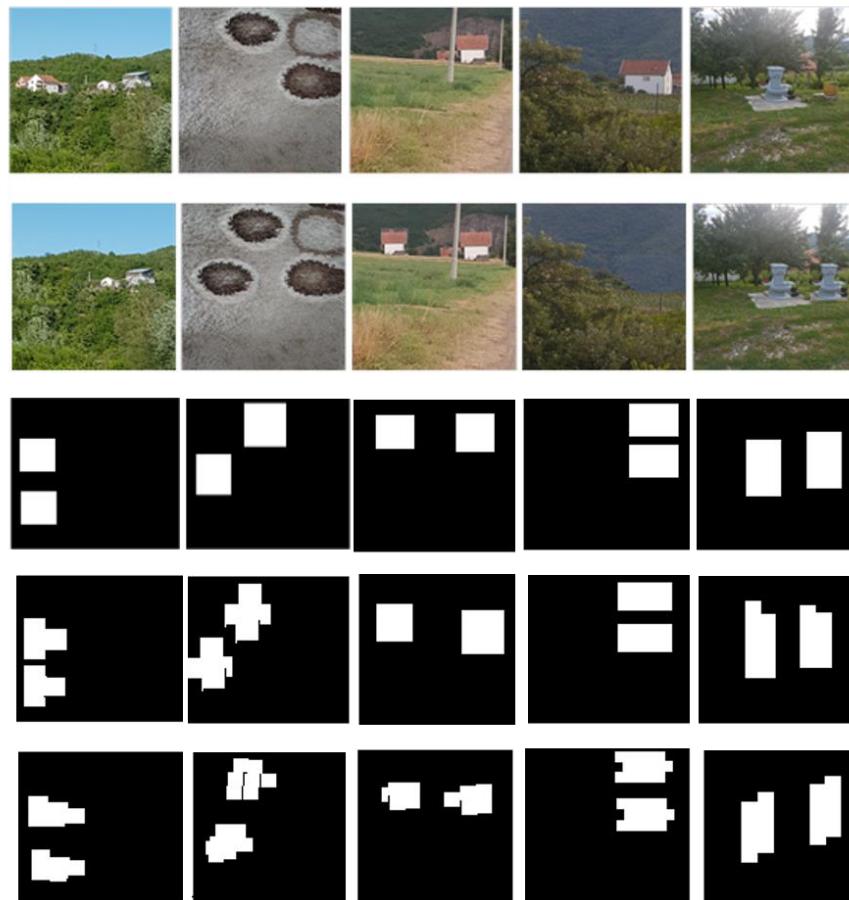
Slika	Eksperimentalni rezultati			
	Rezultati iz [LEE15]		Rezultati dobijeni predloženom metodom	
	$F_c$	$F_f$	$F_c$	$F_f$
II	0.922	0.107	0.953	0.625
V	0.976	0.015	100	0
VI	0.966	0.016	0.953	0
VII	0.958	0.06	100	0

Iz Tabele 5.3 možemo videti da su dobijeni rezultati bolji u terminima CDR u slučaju blokova dimenzija 16x16. Međutim, rezultati postignuti za blokove dimenzija 32x32 su neznatno lošiji u poređenju sa rezultatima postignutim u [CHO17]. Predloženi algoritam daje bolje rezultate za blokove dimenzija 16x16 u poređenju sa blokovima dimenzija 32x32 zato što su neki delovi izmenjenih regiona suviše mali i ne mogu se detektovati korišćenjem blokova većih dimenzija. Iz Tabele 5.4, možemo videti da predloženi algoritam daje značajno bolje rezultate u pojmovima  $F_c$  i  $F_f$  za slike II, VI I VII, za blokove dimenzija 16x16. Takođe, rezultati postignuti za sliku V su relativno zadovoljavajući, u pojmovima  $F_c$  i  $F_f$ . Iz Tabele 5.5 se može zaključiti da predloženi algoritam daje značajno bolje rezultate u terminima  $F_c$  i  $F_f$  za slike II, V i VII, za blokove dimenzija 32x32 [PAV19].

## 5.2 Rezultati i diskusija za slike generisane za potrebe istraživanja

Drugi deo testiranih slika predstavlja baza slika generisanih za potrebe istraživanja. Rezultati i diskusija dobijenih rezultata su prikazani za pet izabranih slika (slike sa slike 5.3

(a), (b), (c), (d) i (e)). Slika 5.6 prikazuje rezultate detekcije izmenjenih regionala trećeg seta testiranih slika (slike sa slike 5.3 (trećih pet slika- slike generisane za potrebe istraživanja)), za različite veličine blokova (32x32, 16x16 i 8x8).



Slika 5.6 Primeri generisani za potrebe istraživanja: originalne slike (prvi red), odgovarajuće izmenjene slike (drugi red), rezultati detekcije falsifikata za blokove dimenzija 32x32 (treći red), rezultati detekcije falsifikata za blokove dimenzija 16x16 (četvrti red) i rezultati detekcije falsifikata za blokove dimenzija 8x8 (peti red).

Uspešnost predložene metode je prikazana u Tabelama 5.6-5.8, za različite dimenzijske blokove (32x32, 16x16 i 8x8), respektivno.

Tabela 5.6. Perfomanse predloženog algoritma za blokove dimenzija 32x32, za slike a), b), c), d) i e).<sup>7</sup>

Slika	Eksperimentalni rezultati				
	Preciznost (%)	Opoziv (%)	CDR	$F_c$	$F_f$
a	87.32	94.56	0.854	0.945	0.015
b	92.43	100	0.895	0.955	0.02
c	89.35	95.42	0.915	0.953	0
d	91.05	89.32	0.923	100	0.45
e	90.35	95.46	0.945	0.892	0.3

Tabela 5.7. Perfomanse predloženog algoritma za blokove dimenzija 16x16, za slike a), b), c), d) i e).

Slika	Eksperimentalni rezultati				
	Preciznost (%)	Opoziv (%)	CDR	$F_c$	$F_f$
a	92.35	94.56	0.923	0.978	0
b	95.25	100	0.945	0.965	0.015
c	100	100	0.978	0.99	0
d	98.9	93.25	0.956	100	0.02
e	95.6	89.7	0.983	100	0.03

<sup>7</sup> Oznake a), b), c), d) i e) odgovaraju oznakama sa slike 5.3.

Tabela 5.8. Performanse predloženog algoritma za blokove dimenzija 8x8, za slike a), b), c), d) i e).

Slika	Eksperimentalni rezultati				
	Preciznost (%)	Opoziv (%)	CDR	$F_c$	$F_f$
a	85.75	90.56	0.91	0.972	0.01
b	93.25	100	0.887	0.954	0.02
c	97.8	100	0.921	100	0.32
d	89.79	89.32	0.932	0.942	0.027
e	93.4	88.05	0.94	0.94	0.045

Poredeći rezultate prikazane u Tabelama 5.6-5.8 možemo zaključiti da predloženi algoritam daje najbolje rezultate tačnosti za blokove dimenzija 16x16. Takođe, rezultati dobijeni za blokove drugih dimenzija su prilično zadovoljavajući.

### 5.3 Kompleksnost računanja

Kompleksnost računanja predloženih CMFD metoda jeste jedan od najvažnijih parametara koji utiču na performanse predloženih algoritama. Na kompleksnost računanja utiče ili broj deskriptora koji se koriste kao karakteristični vektori za svaki blok, ili sami broj blokova. Drugim rečima, kompleksnost računanja se može smanjiti ili smanjivanjem dimenzionalnosti karakterističnih vektora blokova, ili smanjenjem broja blokova (kompromis između veličine i broja blokova).

U predloženom algoritmu, za generisanje karakterističnog vektora za svaki blok, korišćen je multifraktalni spektar, kao i njegovi parametri, a takođe i standardni statistički parametri. Tako dobijeni karakteristični vektori imaju dimenzionalnost 7, odnosno sastoje se od 7 deskriptora. Tabela 5.9 prikazuje efikasnost predložene metode u poređenju sa postojećim metodama. U poređenju sa [ALK16, CHO17, GAN18, BI18a, YAN18,

MAH18, ALA17, HAY17, EMA16], dimenzionalnost karakterističnog vektora je manja, što ukazuje na manju kompleksnost računanja predložene metode.

Tabela 5.9. Poređenje kompleksnosti računanja predložene metode sa drugim metodama.

Tehnika	Algoritam za izdvajanje deskriptora	Dimenzionalnost karakterističnog vektora
[CHO17]	LGWP	256
[GAN18, BI18a, YAN18]	SIFT	128
[MAH18, ALA17, ALK16]	DCT	64
[MAH18, HAY17]	DWT, DCT	64
[HAY17]	Unapređenja DWT, DCT	10
[EMA16]	PCET	8
Predložena metoda	Multifraktalni spektar i statistički parametri	7

Cilj ovog istraživanja jeste da analizira uticaj različitih veličina blokova (8x8 piksela i 16x16 piksela) na performanse predloženog algoritma u terminima FP i FN. Poređenjem rezultata prikazanih u Tabelama 5.1-5.8, možemo zaključiti da veličina bloka utiče i na preciznost i na opoziv. Takođe, bolja tačnost se postiže za blokove dimenzija 16x16. To je posledica korišćenja blokova većih dimenzija koji daju više informacija za izračunavanje multifraktalnog spektra, i prema tome se postiže bolja predstava.

Analizom dobijenih rezultata, može se zaključiti da predložena metoda daje značajno bolje rezultate u terminima preciznost i opoziv, u poređenju sa rezultatima postignutim u [ALK16] (Tabela 5.1), za slike označene sa IV, V, VI, VII, IX I X. Takođe, rezultati postignuti za slike II i IX su relativno zadovoljavajući u terminima preciznost i opoziv. U slučaju slika kompleksnije strukture (slika koje sadrže nebo, šumu, more, pesak i zgrade), predložena metoda daje prilično dobre rezultate (Tabele 5.1 i 5.2). U tom slučaju, bolje je koristiti blokove manjih dimenzija (bolja preciznost se dobija korišćenjem blokova dimenzija 8x8 u poređenju sa blokovima dimenzija 16x16). U poređenju sa autorima koji

su analizirali isti skup slika [CHO17], predložena metoda daje bolje rezultate u pojmovima CDR, za sliku II i veličinu blokova  $16 \times 16$  (Tabela 5.3). U terminima  $F_C$  i  $F_f$ , za slike II, VI i VII, metoda daje značajno bolje rezultate, za blokove dimenzija  $16 \times 16$ . Rezultati dobijeni za sliku V su relativno zadovoljavajući, u poređenju sa rezultatima prikazanim u [LEE15] (Tabela 5.4). Iz Tabele 5.5, može se zaključiti da predložena metoda daje bolje rezultate u terminima  $F_C$  i  $F_f$ , za slike II, V I I VII, za blokove dimenzija  $32 \times 32$ . Takođe, rezultati postignuti za sliku II su relativno dobri.

Zasnovano na rezultatima iz Tabela 5.1 i 5.2, kao i na rezultatima iz Tabela 5.7 i 5.8 može se zaključiti da predložena metoda daje odlične rezultate za blokove dimenzija  $8 \times 8$  i  $16 \times 16$ , dok su rezultati za blokove većih dimenzija takođe zadovoljavajući. Treba naglasiti da većina tehnika za kompresiju koristi blokove dimenzija  $8 \times 8$  i  $16 \times 16$ , što je važno za slike sa velikim brojem detalja. Stoga, u cilju da se ne izgube promene izvršene malim regionima, najvažnije detekcije treba vršiti korišćenjem blokova dimenzija  $8 \times 8$  i  $16 \times 16$ . Rezultati detekcije dobijeni korišćenjem blokova dimenzija  $32 \times 32$  mogu biti veoma dobri, posebno za detekciju promena na slikama većih dimenzija. Korišćenjem blokova malih dimenzija (na primer,  $4 \times 4$ ) u algoritmima za detekciju, moguće je da velike promene ostanu nedetektovane. Sa druge strane, veliki blokovi, kao što su blokovi  $32 \times 32$  ili veći, mogu izbeći veoma male promene. Stoga, za detekciju CMFD promena, predlaže se korišćenje blokova dimenzija  $16 \times 16$ . Dodatne provere se mogu izvršiti korišćenjem većih blokova ukoliko su slike ekstremno visoke rezolucije.

Drugi aspekt koji je važan u razvoji CMFD metoda je kompleksnost računanja, koja je određena brojem deskriptora koji se koriste za svaki blok (dimenzionalnost karakterističnih vektora). U predloženom algoritmu, karakteristični vektor svakog bloka je 7-dimenzionalan. U poređenju sa drugim metodama (Tabela 5.9), dimenzije karakterističnih vektora su manje, što znači da predložena metoda ima manju kompleksnost računanja.

## **6. Zaključak**

U ovom poglavlju je dat pregled postignutih rezultata, kao i izvedenih zaključaka. Navedeni su doprinosi same disertacije. Date su smernice za buduća istraživanja u cilju daljeg unapređivanja detekcije namerno izazvanih promena u sadržaju slike.

U današnje vreme, visokotehnološka, čak i širokodostupna komercijalna tehnologija omogućava jednostavno kreiranje i promenu sadržaja slike, dodavanje i/ili uklanjanje nekih informacija unutar slike ili čak generisanje novih slika od dve ili više slika. Takve promene i generisanje slika od dve ili više slika se mogu raditi iz više razloga. Pored umetničkih i ličnih upotreba, mogu biti i sa ciljem kriminalne aktivnosti, u nameri da sakriju ili prenesu lažnu informaciju. Stoga je razvoj metoda za detekciju takvih vrsta promena postao veoma važan zahtev.

Jedna od najčešćih metoda falsifikovanja slika jeste tzv. „kopiraj i nalepi“ promena (CMFD), što je proizvelo da se najveći broj istraživanja u ovoj oblasti bavi upravo detekcijom ovakvih vrsta promena. U ovoj doktorskoj disertaciji, opisana je mogućnost detektovanja neoriginalnosti ispitivanih slika, kao i mogućnost klasterovanja slika u različite oblasti na osnovu Pearsonovog koeficijenta korelacije. Posebna pažnja je posvećena *skyline* segmentaciji slike, samim tim što takva segmentacija nije jednostavan

postupak, jer *skyline* regioni pored neba i šume sadrže i dodatne elemente. Od posebne važnosti jeste razvoj nove metode za detekciju CMFD promena, zasnovane na multifraktalnom spektru i njegovim parametrima, zatim statističkim parametrima za CMFD, na osnovu multifraktalnog spektra i njegovih parametara, zajedničkih statističkih parametara, novoj metaheuristici i semi-metrici.

Grupisanje (klasterovanje), kao sastavni deo predložene metaurističke metode je testirano eksperimentalno, na javno dostupnoj bazi slika, kao i na bazi slika generisanoj za potrebe istraživanja. Postignuti rezultati pokazuju visok stepen uspešnosti, prema vrednostima različitih parametara opisanim u disertaciji.

Kvalitet predložene metode je analiziran poređenjem sa rezultatima javno dostupnih metoda. Opisivanje kvaliteta je vršeno na osnovu uobičajenih mera: preciznost i opoziv (*precision* i *recall*). Na osnovu tih mera predložena metoda je davala bolje rezultate. Dodatna prednost predložene metode je da koristi karakteristični vektor manje dimenzije, u poređenju sa dimenzionalnostima vektora korišćenih kod pristupa drugih autora, što dovodi do manje kompleksnosti i veće brzine izračunavanja.

U budućem istraživanju, treba razmotriti korišćenje i drugih parametara multifraktalnog spektra, kao i razvijati nove metaheuristike i metode učenja. Takođe, treba ispitati performanse predložene metode pod različitim stepenima JPEG kompresije, kao i u detekciji drugih vrsta promena na slikama.

Na osnovu gore navedenog, osnovni doprinosi teze su sledeći:

**Doprinos 1 - Pregled i analiza standardnih tehniki za detekciju CMFD promena na digitalnim slikama. Pregled najčešće korišćenih parametara pri generisanju karakterističnih vektora blokova ili piksela, kao i tehnika međusobnog uparivanja blokova/piksela i klasterovanja u neizmenjene/izmenjene regije.**

Pregled postojeće literature i metoda za detekciju namerno izazvanih promena u sadržaju slike je dat u poglavljima 2.1.1 i 2.2.2. CMFD metode mogu biti *keypoint-based* ili *block-based*.

*Keypoint-based* metode se zasnivaju na izdvajanju karakterističnih tačaka slike, gde se izdvajanje vrši samo u određenim regionima slike, bez podele slike na blokove. Karakteristike ključnih tačaka predstavljaju lokalne karakteristike slike kao što su: ivice, uglovi, "grudvice" (*blobs*). Svaka karakteristika se predstavlja skupom deskriptora koji se izdvajaju u regionima u okolini ključne tačke. Za izdvajanje karakteristika kod *keypoint-based* metoda, najčešće se koriste sledeće tehnike: *Scale Invariant Feature Transform* (SIFT), *Harris Corner Detector*, *Speed Up Robust Features* (SURF) [WAN18a, WAN618, YAN18, CHA16, GON16, YAN17] i *Local Bidirectional Coherency Error* (LBCE) [BI18a].

Što se tiče uparivanja karakteristika, kod *keypoint-based* metoda, najčešće se koriste tehnike najbližeg suseda: *Best Bin First* [CHE13, JAB13, KAK13, MIS13, ZHA13a, ZHA13b], 2NN [HAS14, JAB13, KAK13, MIS13, GUO13] i g2NN [WAN18a, GAN18, ZHO17a, ZHO17b, YAN17, AME13, MOH13], kao i klasterovanje [ARD10].

*Block-based* metode u fazi pred-procesiranja dele sliku na preklapajuće ili nepreklapajuće blokove kvadratnog oblika. Zatim se za svaki blok računaju karakteristični vektori sastavljeni od odgovarajućih deskriptora, u zavisnosti od primenjene metode. Karakteristični vektori se uparuju i traži se sličnost između blokova. Tehnike za izdvajanje karakterističnih vektora kod *block-based* metoda se mogu generalno podeliti na sledeći način: frekvencijska transformacija, invarijantni momenti, transformacija u logaritamski polarni sistem, teksture i intenzitet, smanjenje dimenzija i druge [WAR16], kao i unapređenja frekvencijske transformacije: *Discrete Cosine Transform* (DCT), *Fourier Transform*, *Fast Walsh-Hadamard Transform* (FWHT), *Discrete Wavelet Transform* (DWT), *Dyadic Wavelet Transform* (DyWT) i *Wiener Filter Wavelet* [MAH18, ALA17, HAY17, HU16].

Tehnike uparivanja se koriste nakon izdvajanja karakterističnih vektora, kako bi se pronašli slični blokovi i odredila pozicija falsifikata. Ove tehnike se mogu podeliti u

nekoliko kategorija: sortiranje, “pretresanje” (*hash*), korelacija, Euklidsko rastojanje i drugi [GAB18, WAN2918, ZHO17a, ZHO17b, JEN16, KAU15, LEE15, ALK16, YAN17].

**Doprinos 2 – Pregled i analiza parametara multifraktalnog spektra, kao i mogućnost primene parametara multifraktalnog spektra u skyline segmentaciji slika.**

Pregled multifraktalne teorije i detaljan opis parametara multifraktalnog spektra koji se mogu koristiti uspešno u *skyline* segmentaciji slika je dat u poglavljima 3.2 i 3.4.1. *Skyline* segmentacija slike nije jednostavna, čak i ako postoje samo dva dominantna regiona, što je uzrokovano detaljima koji se nalaze u tim regionima [RELJ00, FAB11, CHI15, ARM17, CEL90]. Testirana je mogućnost *skyline* segmentacije slike u različitim sistemima boja: *grayscale* slika, samo plavi, zeleni i crveni kanal, kao i samo H komponenta u HSV sistemu boja, i pokazano je da se analiza singulariteta slike može uspešno primenjivati za klasterovanje i segmentaciju slike u različite objekte. Najbolji rezultati segmentacije se postižu korišćenjem samo plavog kanala slike, ili analizom *grayscale* (intenzitetske) slike. To je posledica činjenice da su testirane slike uglavnom sastavljene od plavih regiona, i da je plava boja dominantna u generisanju intenzitetske slike.

**Doprinos 3 – Pokazano je da se inverzni multifraktalni spektar (što ranije nije primenjivano u te svrhe) može uspešno koristiti u detekciji objekata koji su naknadno dodati na postojeću sliku (primer detekcije image splicing promena na slikama).**

Inverzni multifraktalni spektar je opisan u poglavljju 3.2.6. Ako svakom pikselu slike pridružimo odgovarajuće vrednosti  $\alpha$  i  $f(\alpha)$ , kreiraju se matrice  $\alpha$  vrednosti i  $f(\alpha)$ , koje opisuju lokalne i globalne karakteristike slike, respektivno. Iz ovih matrica, izborom posebnih vrednosti  $\alpha$  i/ili  $f(\alpha)$  mogu se u polaznoj slici izdvojiti regioni karakterisani tim vrednostima  $\alpha$  i/ili  $f(\alpha)$ , a bez degradacije slike. Ova procedura je od naročitog interesa za izdvajanje regiona u kojima MF spektar,  $f(\alpha)$ , ima male vrednosti (globalno retki slučajevi),

i u regionima gde  $f(\alpha)$  ima velike vrednosti (globalno česti slučajevi) [RELJ00]. IMF analiza se može uspešno koristiti za izdvajanje izmenjenih delova slike, odnosno namerno dodatih delova slike. Posmatranjem matrice  $\alpha$ , na osnovu nepravilnosti spektra: pojavljivanje novih pikova, iskrivljene linije, pomeranje maksimuma i prve nule spektra, i računanjem IMF u tim intervalima vrednosti  $\alpha$ , mogu se detektovati delovi slike koji su izmenjeni.

*Doprinos 4 – Od posebne važnosti u ovoj disertaciji jeste razvoj nove metode za detekciju CMFD promena na slikama, zasnovanoj na multifraktalnom spektru i njegovim parametrima, kao i statističkim parametrima dobijenim iz multifraktalnog spektra i njegovih parametara.*

Nova blokovska metoda za detekciju CMFD promena na slikama je detaljno opisana u poglavlju 4. Kopirani i nalepljeni delovi su sa iste slike, tako da su njihove karakteristike slične. Kako multifraktalna teorija u osnovi analizira samosličnost, može se koristiti u detekciji takve vrste promena. Metoda je zasnovana na određenim parametrima multifraktalnog spektra, do kojih se došlo analizom velikog broja testiranih slika. Naime, prilikom promene sadržaja digitalne slike, menja se i multifraktalni spektar. Pokazano je da su neki od postojećih parametara značajniji u odnosu na druge koji karakterišu spektre, pa su stoga odabrani kao delovi karakterističnih vektora koji opisuju blokove izmenjenih slika.

*Doprinos 5 – Razvijena je nova semi-metrika, na bazi metaheuristike, koja je primenjivana za uparivanje blokova i pronalaženje istih ili sličnih karakterističnih vektora blokova.*

U postojećoj literaturi autori su uglavnom koristili iste ili slične tehnike uparivanja blokova, kao što su: sortiranje, “pretresanje” (hash), korelacija, Euklidsko rastojanje i slično. U ovoj disertaciji je razvijena nova semi-metrika, koja se pokazala jako uspešnom u

pronalaženju i uparivanju sličnih blokova slike, tj. sličnih karakterističnih vektora. Semi-metrika je opisana detaljno u poglavlju 4.1. Najpre su izračunata rastojanja (korišćenjem semi-metrike) između blokova. U fazi predprocesiranja vrste matrice rastojanja (kao i odgovarajući indeksi blokova) sortirane su u neopadajućem poretku [GLI17b, GLI17c]. Zatim se određuje interval [min, max] na osnovu procesa opisanog u koraku 5 i posmatraju se samo blokovi čije je rastojanje u ovom intervalu. Ovi podaci korišćeni su za efikasniju implementaciju operatora razmrdavanja. Naime, kako se svako rešenje karakteriše skupom centroida, operator razmrdavanja sastoji se u zameni odgovarajućeg broja centroida. Preciznije, razmrdavanje u okolini  $k$  podrazumeva da se centroidi zamene slučajno izabranim blokovima koji nisu centroidi, a udaljeni su najviše  $k$  mesta od centroida koga menjaju. U svakom koraku razmatra se zamena svih centroida, pri čemu do zamene neće doći ukoliko je slučajno izabrani blok najbliži tom centroidu (u stvari, to je sam taj centroid). Lokalno pretraživanje sastoji se u sistematskoj zameni jednog centroida blokom koji nije centroid. Ono polazi od rešenja dobijenog razmrdavanjem i izvršava se po principu najboljeg poboljšanja (*Best Improvement*) dok god ima poboljšanja [GLIS17, PAV19].

**Doprinos 6 – Pokazano je da ova metoda daje bolje performanse u detekciji izmenjenih regionala slike, kao i manji procenat “lažne detekcije”, odnosno detekcije neizmenjenih regionala kao izmenjenih, u poređenju sa metodama u postojećoj literaturi.**

Predložena metoda zasnovana na multifraktalima i semi-metrici je testirana eksperimentalno na dve baze slika: slike iz javno dostupnih baza, kao i slike generisane za potrebe istraživanja. Analizom i diskusijom dobijenih rezultata pokazano je da metoda dalje bolje performanse u terminima preciznost i opoziv, kao i u terminima koje koriste drugi autori za testiranje svojih algoritama, za blokove dimenzija 8x8, 16x16 i 32x32 (poglavlje 5).

**Doprinos 7 –** Pokazano je da veličina izbor veličine bloka utiče na performanse predloženog algoritma, i pokazano je da se najbolja tačnost dobija korišćenjem blokova dimenzija 16x16.

U poglavlju 5 je analiziran uticaj veličine bloka na performanse predloženog algoritma. Analizom dobijenih rezultata može se zaključiti da predložena metoda daje odlične rezultate za veličinu blokova 8x8 i 16x16, dok su rezultati postignuti za blokove većih dimenzija takođe zadovoljavajući. Treba naglasiti da većina tehnika za kompresiju slika koristi blokove od 8x8 i 16x16 piksela, što je važno za slike sa velikim brojem detalja. Stoga, u cilju da se ne izgube promene izvršene u malim regionima slike, većina tehnika za detekciju promena na slikama treba da se zasniva na blokovima 8x8 i 16x16. Ukoliko su slike velike rezolucije, rezultati detekcije mogu biti odlični i korišćenjem blokova većih dimenzija, na primer 32x32, dok je pri korišćenju blokova manjih dimezija (4x4) moguće da promene većih dimenzija ostaju nedetektovane. Sa druge strane, velikim blokovima, kao što su blokovi dimenzija 32x32, moguće je da se ne detektuju veoma male promene. Prema tome, za CMFD se preporučuje korišćenje blokova dimezija 16x16. Korišćenje blokova dimenzija 16x16 daje bolje performanse u poređenju sa korišćenjem blokova dimenzija 8x8 jer blokovi dimenzija 16x16 daju više informacija za računanje multifraktalnog spektra.

**Doprinos 8 –** Predložena metoda ima manju kompleksnost računanja u odnosu na metode predložene u postojećoj literaturi.

Kompleksnost izračunavanja CMFD algoritama jeste jedan od parametara koji određuju računarsku zahtevnost metode. Na kompleksnost računanja utiče ili broj deskriptora koji se koriste kao karakteristični vektori za svaki blok, ili broj blokova. Drugim rečima, kompleksnost računanja se može smanjiti ili smanjivanjem dimenzionalnosti karakterističnih vektora blokova, ili smanjenjem broja blokova (kompromis između veličine i broja blokova).

U predloženom algoritmu, za generisanje karakterističnog vektora za svaki blok, korišćen je multifraktalni spektar, kao i njegovi parametri, a takođe i standardni statistički parametri. Tako dobijeni karakteristični vektori opisani su sa sedam deskriptora, dakle, imaju dimenzionalnost 7, što je značajno manje od dimenzionalnosti karakterističnih vektora drugih metoda (LGWP – 256 deskriptora, SIFT – 128 deskriptora, DWT i DCT – 64 deskriptora, unapređena DWT i DCT – 10 deskriptora, PCET – 8 deskriptora). Time je pokazano da je kompleksnost i vreme računanja predložene metode manja u poređenju sa postojećim metodama.

# Literatura

- [ALA17] Alahmadi, A., Hussain, M., Aboalsamh, H., Muhammad, G., Bebis, G., & Mathkour, H. (2017) Passive detection of image forgery using DCT and local binary pattern. *Signal, Image and Video Processing*, 11(1):81-88. <https://doi.org/10.1007/s11760-016-08990>
- [ALK16] Alkawaz, M. H., Sulong, G., Saba, T., & Rehman, A. (2016) Detection of copy-move image forgery based on discrete cosine transform. *Neural Computing and Applications*: 1-10. <https://doi.org/10.1007/s00521-016-2663-3>
- [AME11] Amerini, I., Ballan, L., Caldelli, R., Del Bimbo, A., & Serra, G. (2011). A sift-based forensic method for copy–move attack detection and transformation recovery. *IEEE Transactions on Information Forensics and Security*, 6(3), 1099-1110.
- [AME13] Amerini, I., Ballan, L., Caldelli, R., Del Bimbo, A., Del Tongo, L., & Serra, G. (2013). Copy-move forgery detection and localization by means of robust clustering with J-Linkage. *Signal Processing: Image Communication*, 28(6), 659-669.
- [ANA14] Anand, V., Hashmi, M. F., & Keskar, A. G. (2014, April). A copy move forgery detection to overcome sustained attacks using dyadic wavelet transform and SIFT methods. In *Asian Conference on Intelligent Information and Database Systems* (pp. 530-542). Springer, Cham.

- [ARD09] Ardizzone, E., & Mazzola, G. (2009, September). Detection of duplicated regions in tampered digital images by bit-plane analysis. In *International Conference on Image Analysis and Processing* (pp. 893-901). Springer, Berlin, Heidelberg.
- [ARD10] Ardizzone, E., Bruno, A., & Mazzola, G. (2010, September). Detecting multiple copies in tampered images. In *2010 IEEE International Conference on Image Processing* (pp. 2117-2120). IEEE.
- [ARM17] A. Armagan, M. Hirzer, P.M. Roth, and V. Lepetit, "Accurate Camera Registration in Urban Environments Using High-Level Feature Matching," In *Proceedings of the British Machine Vision Conference*, pp.1-12, 2017.
- [BAY09] Bayram, S., Sencar, H. T., & Memon, N. (2009, April). An efficient and robust method for detecting copy-move forgery. In *2009 IEEE International Conference on Acoustics, Speech and Signal Processing* (pp. 1053-1056). IEEE.
- [BEN16] Benhouma, O., Hermassi, H., El-Latif, A. A. A., & Belghith, S. (2016). Chaotic watermark for blind forgery detection in images. *Multimedia Tools and Applications*, 75(14), 8695-8718.
- [BI16] Bi, X., Pun, C. M., & Yuan, X. C. (2016). Multi-level dense descriptor and hierarchical feature matching for copy-move forgery detection. *Information Sciences*, 345, 226-242. <https://doi.org/10.1016/j.ins.2016.01.061>
- [BI18a] Bi, X., & Pun, C. M. (2018) Fast copy-move forgery detection using local bidirectional coherency error refinement. *Pattern Recognition*, 81: 161-175. <https://doi.org/10.1016/j.patcog.2018.03.028>
- [BI18b] Bi, X., Pun, C. M., & Yuan, X. C. (2018) Multi-scale feature extraction and adaptive matching for copy move forgery detection. *Multimedia Tools and Applications*, 77(1): 363-385. <https://doi.org/10.1007/s11042-016-4276-3>
- [BIN13] Bin, Y. A. N. G., Xingming, S. U. N., Xianyi, C., Zhang, J., & Xu, L. I. (2013). An Efficient Forensic Method for Copy-move Forgery Detection Based on DWT-FWHT. *Radioengineering*, 22(4).

- [BO10] Bo, X., Junwen, W., Guangjie, L., & Yuwei, D. (2010, November). Image copy-move forgery detection based on SURF. In *Multimedia information networking and security (MINES), 2010 International conference on* (pp. 889-892). IEEE.
- [BRA11] Bravo-Solorio, S., & Nandi, A. K. (2011, May). Exposing duplicated regions affected by reflection, rotation and scaling. In *2011 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 1880-1883). IEEE.
- [CAO12] Cao, Y., Gao, T., Fan, L., & Yang, Q. (2012). A robust detection algorithm for copy-move forgery in digital images. *Forensic science international*, 214(1-3), 33-43.
- [CEL90] M. Celenk, "A color clustering technique for image segmentation," *Computer Vision, Graphics, and image processing*, 52(2), pp.145-170,1990.
- [CHA16] Chauhan, D., Kasat, D., Jain, S., & Thakare, V. (2016). Survey on keypoint based copy-move forgery detection methods on image. *Procedia Computer Science*, 85, 206-212.
- [CHE13] Chen, L., Lu, W., Ni, J., Sun, W., & Huang, J. (2013). Region duplication detection based on Harris corner points and step sector statistics. *Journal of Visual Communication and Image Representation*, 24(3), 244-254.
- [CHI15] D.Y. Chino, L.P. Avalhais, J.F. Rodrigues, and A.J Traina (2015), "Bowfire: detection of fire in still images by integrating pixel color and texture analysis," In *Conference on Graphics, Patterns and Images (SIBGRAPI)*, pp. 95-102, .
- [CHO17] Chou, C. L., & Lee, J. C. (2017) Copy-Move Forgery Detection Based on Local Gabor Wavelets Patterns. In *International Conference on Security with Intelligent Computing and Big-data Services* (pp. 47-56). [https://doi.org/10.1007/978-3-319-76451-1\\_5](https://doi.org/10.1007/978-3-319-76451-1_5)
- [COM18] CoMoFoD database, available at: <http://www.vcl.fer.hr/comofod>
- [DAV13] Davarzani, R., Yaghmaie, K., Mozaffari, S., & Tapak, M. (2013). Copy-move forgery detection using multiresolution local binary patterns. *Forensic science international*, 231(1-3), 61-72.
- [DEN12] Deng, Y., Wu, Y., & Zhou, L. (2012). Detection of copy-rotate-move forgery using Dual Tree Complex Wavelet Transform. *Advanced Science Letters*, 16(1), 32-38.

- [EMA16] Emam, M., Han, Q., & Niu, X. (2016) PCET based copy-move forgery detection in images under geometric transforms. *Multimedia Tools and Applications*, 75(18): 11513-11527. <https://doi.org/10.1007/s11042-015-2872-2>
- [FAB11] A. Fabijanska, "Variance filter for edge detection and edge-based image segmentation," *MEMSTECH*, pp. 151-154, 2011.
- [FRID03] Fridrich, A. J., Soukal, B. D., & Lukáš, A. J. (2003). Detection of copy-move forgery in digital images. In *Proceedings of Digital Forensic Research Workshop*.
- [GAN14] Gan, Y., & Zhong, J. (2014). Image copy-move tamper blind detection algorithm based on integrated feature vectors. *Journal of Chemical and Pharmaceutical Research*, 6(6), 1584-1590.
- [GAN16] Gan, Y., & Zhong, J. (2016). Application of AFMT method for composite forgery detection. *Nonlinear Dynamics*, 84(1), 341-353. <https://doi.org/10.1007/s11071-015-2524-0>
- [GAN18] Gan, Y., Chung, J., Young, J., Hu, Z., & Zhao, J. (2018) A Duplicated Forgery Detection Fusion Algorithm using SIFT and Radial-Harmonic Fourier Moments. *International Journal of Performability Engineering*, 14(1), 111. <https://doi.org/10.23940/ijpe.18.01.p12.111120>
- [GLI17a] Glišović Nataša, „Optimizacija problema upravljanja odnosima koristi i troškova pri raspoređivanju projekata primenom metaheurističkih algoritama“, doktorska disertacija, Matematički fakultet, Univerzitet u Beogradu, 2017.
- [GLI17b] Glisovic, N., Davidovic, T., Bojovic, N. and Knezevic, N., Statistical and Mathematical Methods for Solving the Problem of Clustering of Station Data When Data Is Incomplete, Conference: *XXXV Symposium on New Technologies in Postal and Telecommunication Vehicles, PostTel 2017*, Faculty of Transport and Traffic Engineering, Belgrade, December 2017.
- [GLI17c] Glisovic, N. and Davidovic, T. and Raskovic, M., Clustering when missing data by using the variable neighborhood search, (in serbian). In Proc. SYM-OP-IS 2017, pages 158-163, Zlatibor, Serbia, 2017.

- [GON16] Gong, J., & Guo, J. (2016). Image copy-move forgery detection using SURF in opponent color space. *Transactions of Tianjin University*, 22(2), 151-157. <https://doi.org/10.1007/s12209-016-2705-z>
- [GRA83] Grassberger, P., & Procaccia, I. (1983). Characterization of strange attractors. *Physical review letters*, 50(5), 346.
- [GUO13] Guo, J. M., Liu, Y. F., & Wu, Z. J. (2013). Duplication forgery detection using improved DAISY descriptor. *Expert Systems with Applications*, 40(2), 707-714.
- [HAR14] Harrar, K., & Khider, M. (2014). Texture analysis using multifractal spectrum. *International Journal of Modeling and Optimization*, 4(4), 336.
- [HAS14] Hashmi, M. F., Anand, V., & Keskar, A. G. (2014). Copy-move image forgery detection using an efficient and robust method combining un-decimated wavelet transform and scale invariant feature transform. *Aasri Procedia*, 9, 84-91.
- [HAY17] Hayat, K., & Qazi, T. (2017) Forgery detection in digital images via discrete wavelet and discrete cosine transforms. *Computers & Electrical Engineering*, 62: 448-458. <https://doi.org/10.1016/j.compeleceng.2017.03.013>
- [HSU12] Hsu, H. C., & Wang, M. S. (2012, August). Detection of copy-move forgery image using Gabor descriptor. In *Anti-counterfeiting, Security, and Identification* (pp. 1-4). IEEE.
- [HU16] Hu, W. C., Chen, W. H., Huang, D. Y., & Yang, C. Y. (2016). Effective image forgery detection of tampered foreground or background image based on image watermarking and alpha mattes. *Multimedia Tools and Applications*, 75(6), 3495-3516.
- [HUA11] Huang, Y., Lu, W., Sun, W., & Long, D. (2011). Improved DCT-based detection of copy-move forgery in images. *Forensic science international*, 206(1-3), 178-184.
- [HUA17] Huang, D. Y., Huang, C. N., Hu, W. C., & Chou, C. H. (2017). Robustness of copy-move forgery detection under high JPEG compression artifacts. *Multimedia Tools and Applications*, 76(1), 1509-1530.
- [HUS14] Hussain, M., Saleh, S. Q., Aboalsamh, H., Muhammad, G., & Bebis, G. (2014, June). Comparison between WLD and LBP descriptors for non-intrusive image forgery

detection. In *Innovations in Intelligent Systems and Applications (INISTA) Proceedings, 2014 IEEE International Symposium on* (pp. 197-204). IEEE.

[IBR14] Ibrahim, M., & Mukundan, R. (2014). Multi-fractal techniques for emphysema classification in lung tissue images. In *International Conference on Environment, Chemistry and Biology* (Vol. 78, pp. 115-119).

[IMA13] İmamoğlu, M. B., Ulutaş, G., & Ulutaş, M. (2013, November). Detection of copy-move forgery using krawtchouk moment. In *2013 8th International Conference on Electrical and Electronics Engineering (ELECO)* (pp. 311-314). IEEE.

[IMA18] Image Manipulation Dataset, available at:  
<https://www5.cs.fau.de/research/data/image-manipulation/>

[JAB13] Jaberi, M., Bebis, G., Hussain, M., & Muhammad, G. (2013, July). Improving the detection and localization of duplicated regions in copy-move image forgery. In *Digital Signal Processing (DSP), 2013 18th International Conference on* (pp. 1-6). IEEE.

[JEN16] Jenadeleh, M., & Ebrahimi Moghaddam, M. (2016) Blind detection of region duplication forgery using fractal coding and feature matching. *Journal of forensic sciences*, 61(3): 623-636. <https://doi.org/10.1111/1556-4029.13108>

[JER17] Jeronymo, D. C., Borges, Y. C. C., & dos Santos Coelho, L. (2017). Image forgery detection by semi-automatic wavelet soft-thresholding with error level analysis. *Expert Systems with Applications*, 85, 348-356.

[KAK12] Kakar, P., & Sudha, N. (2012). Exposing postprocessed copy–paste forgeries through transform-invariant features. *IEEE Transactions on Information Forensics and Security*, 7(3), 1018-1028.

[KAS13] Kashyap, A., & Joshi, S. D. (2013, December). Detection of copy-move forgery using wavelet decomposition. In *2013 International Conference on Signal Processing and Communication (ICSC)* (pp. 396-400). IEEE.

[KAU15] Kaushik, R., Bajaj, R. K., & Mathew, J. (2015) On image forgery detection using two dimensional discrete cosine transform and statistical moments. *Procedia Computer Science*, 70: 130-136. <https://doi.org/10.1016/j.procs.2015.10.058>

- [KET13] Ketenci, S., & Ulutas, G. (2013, July). Copy-move forgery detection in images via 2D-Fourier transform. In *2013 36th International Conference on Telecommunications and Signal Processing (TSP)* (pp. 813-816). IEEE.
- [KUM13] Kumar, S., Desai, J., & Mukherjee, S. (2013, December). A fast DCT based method for copy move forgery detection. In *2013 IEEE Second International Conference on Image Information Processing (ICIIP-2013)* (pp. 649-654). IEEE.
- [LAM10] Lam, A. D., & Li, Q. (2010, May). Fractal analysis and multifractal spectra for the images. In *2010 International Symposium on Computer, Communication, Control and Automation (3CA)* (Vol. 2, pp. 530-533). IEEE.
- [LAZ14] D. Lazarevic, M. Misic, B. Cirkovic, "Recent image segmentation techniques", *National Conference FQ2014*, pp.26.1-11, 2014.
- [LEE15] Lee, J. C., Chang, C. P., & Chen, W. K. (2015) Detection of copy–move image forgery using histogram of orientated gradients. *Information Sciences*, 321: 250-262. <https://doi.org/10.1016/j.ins.2015.03.009>
- [LI12a] Li, L., Li, S., & Wang, J. (2012, October). Copy-move forgery detection based on PHT. In *Information and Communication Technologies (WICT), 2012 World Congress on* (pp. 1061-1065). IEEE.
- [LI12b] Li, X. H., Zhao, Y. Q., Liao, M., Shih, F. Y., & Shi, Y. Q. (2012). Passive detection of copy-paste forgery between JPEG images. *Journal of Central South University*, 19(10), 2839-2851.
- [LIN16] Lin, C. S., & Tsay, J. J. (2016) Passive forgery detection using discrete cosine transform coefficient analysis in JPEG compressed images. *Journal of Electronic Imaging*, 25(3): 033010. <https://doi.org/10.1117/1.JEI.25.3.033010>
- [LOP09] Lopes, R., & Betrouni, N. (2009). Fractal and multifractal analysis: a review. *Medical image analysis*, 13(4), 634-649.
- [LYN13] Lynch, G., Shih, F. Y., & Liao, H. Y. M. (2013). An efficient expanding block algorithm for image copy-move forgery detection. *Information Sciences*, 239, 253-265.
- [MAH18] Mahmood, T., Mehmood, Z., Shah, M., & Saba, T. (2018) A robust technique for copy-move forgery detection and localization in digital images via stationary wavelet

- and discrete cosine transform. *Journal of Visual Communication and Image Representation*, 53: 202-214. <https://doi.org/10.1016/j.jvcir.2018.03.015>
- [MAL16] Malviya, A. V., & Ladha, S. A. (2016) Pixel based image forensic technique for copy-move forgery detection using auto color correlogram. *Procedia Computer Science*, 79: 383-390. <https://doi.org/10.1016/j.procs.2016.03.050>
- [MIS13] Mishra, P., Mishra, N., Sharma, S., & Patel, R. (2013). Region duplication forgery detection technique based on SURF and HAC. *The Scientific World Journal*, 2013.
- [MLA18] Mladenović, Nenad, Kenneth Sørensen, and Marcone Souza, eds. "Special issue on ‘Advances in Variable Neighborhood Search’." *International Transactions in Operational Research* 25.1 (2018): 427-427.
- [MLA97] Mladenović, Nenad, and Pierre Hansen. "Variable neighborhood search." *Computers & operations research* 24.11 (1997): 1097-1100.
- [MOH13] Mohamadian, Z., & Pouyan, A. A. (2013, April). Detection of duplication forgery in digital images in uniform and non-uniform regions. In *Computer Modelling and Simulation (UKSim), 2013 UKSim 15th International Conference on* (pp. 455-460). IEEE.
- [MUH12] Muhammad, G., Hussain, M., & Bebis, G. (2012). Passive copy move image forgery detection using undecimated dyadic wavelet transform. *Digital Investigation*, 9(1), 49-57.
- [MUH13] Muhammad, G., Al-Hammadi, M. H., Hussain, M., Mirza, A. M., & Bebis, G. (2013, July). Copy move image forgery detection method using steerable pyramid transform and texture descriptor. In *EUROCON, 2013 IEEE* (pp. 1586-1592). IEEE.
- [MUH14] Muhammad, G., Al-Hammadi, M. H., Hussain, M., & Bebis, G. (2014). Image forgery detection using steerable pyramid transform and local binary pattern. *Machine Vision and Applications*, 25(4), 985-995.
- [MYN08] Myna, A. N., Venkateshmurthy, M. G., & Patil, C. G. (2007, December). Detection of region duplication forgery in digital images using wavelets and log-polar mapping. In *International Conference on Computational Intelligence and Multimedia Applications (ICCIMA 2007)* (Vol. 3, pp. 371-377). IEEE.

- [NED16] Nedović Ljubo, „Neki tipovi rastojanja i fazi mera sa primenom u obradi slika“, doktorska disertacija, Fakultet tehničkih nauka, Univerzitet u Novom sadu, 2016.
- [NGA11] K.N. Ngan, H. Li, *Video Segmentation and Its Applications*, Springer, 2011.
- [OLE07] Oleg I. Sheluhin, Sergey M. Smolskiy, Andrey V. Osin, “*Self-similar processes in telecommunications*”, John Wiley & Sons, Ltd, 2007.
- [OOM16] Oommen, R. S., Jayamohan, M., & Sruthy, S. (2016) Using Fractal Dimension and Singular Values for Image Forgery Detection and Localization. *Procedia Technology*, 24: 1452-1459. <https://doi.org/10.1016/j.protcy.2016.05.176>
- [PAV17a] Pavlović, A. Gavrovska, I. Reljin, “Multifractal spectrum of the images obtained by copy move method“, IcETRAN, 5-8. juna, Kladovo, Srbija, 2017.
- [PAV18] Aleksandra Pavlović, Ana Gavrovska, Nataša Milosavljević, „The image segmentation based on the image singularities analysis“, 14<sup>th</sup> *Symposium on Neural Networks and Applications* (NEUREL), Belgrade, Serbia, November 20-21, 2018.
- [PAV19] Aleksandra Pavlović, Nataša Glišović, Ana Gavrovska, Irini Reljin, „Copy-move forgery detection based on multifractals“, *Multimedia Tools and Applications*, 2019, doi: 10.1007/s11042-019-7277-1.
- [PAV7b] Aleksandra Pavlović, Irini Reljin, “Statistička analiza slika izmenjenih copy-move metodom”, XXXV *Ssimpozijum o novim tehnologijama u poštanskom I telekomunikacionom saobraćaju – Postel 2017*, Beograd, 5. i 6. decembar 2017.
- [PEN11] Peng, F., Nie, Y. Y., & Long, M. (2011). A complete passive blind image copy-move forensics scheme based on compound statistics features. *Forensic science international*, 212(1-3), e21-e25.
- [RELJ00] Reljin, I., Reljin, B., Pavlovic, I., & Rakočevic, I. (2000). Multifractal analysis of gray-scale images. In *2000 10th Mediterranean Electrotechnical Conference. Information Technology and Electrotechnology for the Mediterranean Countries. Proceedings. MeleCon 2000 (Cat. No. 00CH37099)*(Vol. 2, pp. 490-493). IEEE.
- [RELJ02] Irini Reljin, Branimir Reljin, “Fractal geometry and multifractals in analyzing and processing medical data and Images”, *Archive of Oncology*, pp. 283-293, 2002.

- [RELJ15a] Reljin Irini, "Metrika i statistika za vremenske nizove", slajdovi sa predavanja iz predmeta „*Odabranogoglavlja iz Multimedijalnih signala*“, ETF, 2015.
- [RELJ15b] Reljin Irini, „Multifraktali“, „, slajdovi sa predavanja iz predmeta „*Odabranogoglavlja iz Multimedijalnih signala*“, ETF, 2015.
- [RYU10] Ryu, S. J., Lee, M. J., & Lee, H. K. (2010, June). Detection of copy-rotate-move forgery using Zernike moments. In *International workshop on information hiding* (pp. 51-65). Springer, Berlin, Heidelberg.
- [RYU13] Ryu, S. J., Kirchner, M., Lee, M. J., & Lee, H. K. (2013). Rotation invariant localization of duplicated image regions based on Zernike moments. *IEEE Transactions on Information Forensics and Security*, 8(8), 1355-1370.
- [SAL17] Salat, H., Murcio, R., & Arcaute, E. (2017). Multifractal methodology. *Physica A: Statistical Mechanics and its Applications*, 473, 467-487.
- [SHA12] Shao, H., Yu, T., Xu, M., & Cui, W. (2012). Image region duplication detection based on circular window expansion and phase correlation. *Forensic science international*, 222(1-3), 71-82.
- [SHE13] Shen, X. J., Zhu, Y., Lv, Y. D., & Chen, H. P. (2013). Image copy-move forgery detection based on sift and gray level. In *Applied Mechanics and Materials* (Vol. 263, pp. 3021-3024). Trans Tech Publications.
- [SHI13] Shin, Y. D. (2013). Fast Detection of Copy-Move Forgery Image using DCT. *Journal of Korea Multimedia Society*, 16(4), 411-417.
- [SHI15] Shih, F. Y., & Jackson, J. K. (2015) Copy-Cover Image Forgery Detection in Parallel Processing. *International Journal of Pattern Recognition and Artificial Intelligence*, 29(08), 1554004. <https://doi.org/10.1142/S021800141554004X>
- [SIN12] Singh, J., & Raman, B. (2012). A high performance copy-move image forgery detection scheme on GPU. In *Proceedings of the International Conference on Soft Computing for Problem Solving (SocProS 2011) December 20-22, 2011* (pp. 239-246). Springer, India.

- [SON18] Soni, B., Das, P. K., & Thounaojam, D. M. (2018). Dual System for Copy-move Forgery Detection using Block-based LBP-HF and FWHT Features. *Engineering Letters*, 26(1). <https://doi.org/10.1109/TIFS.2010.2051666>
- [ULU13] Ulutas, G., & Ulutas, M. (2013, November). Image forgery detection using color coherence vector. In *2013 International Conference on Electronics, Computer and Computation (ICECCO)* (pp. 107-110). IEEE.
- [UST16] Ustubioglu, B., Ulutas, G., Ulutas, M., & Nabiiev, V. V. (2016) A new copy move forgery detection technique with automatic threshold determination. *AEU-International Journal of Electronics and Communications*, 70(8): 1076-1087. <https://doi.org/10.1016/j.aeue.2016.05.005>
- [VEH92] Véhel, J. L., Mignot, P., & Berroir, J. P. (1992, June). Multifractals, texture, and image analysis. In *Proceedings 1992 IEEE Computer Society Conference on Computer Vision and Pattern Recognition* (pp. 661-664). IEEE.
- [VEH94] Vehel, J. L., & Mignot, P. (1994). Multifractal segmentation of images. *Fractals*, 2(03), 371-377.
- [WAN12] Wang, T., Tang, J., Zhao, W., Xu, Q., & Luo, B. (2012, September). Blind detection of copy-move forgery based on multi-scale autoconvolution invariants. In *Chinese Conference on Pattern Recognition* (pp. 438-446). Springer, Berlin, Heidelberg.
- [WAN17] Wang, X. Y., Li, S., Liu, Y. N., Niu, Y., Yang, H. Y., & Zhou, Z. L. (2017). A new keypoint-based copy-move forgery detection for small smooth regions. *Multimedia Tools and Applications*, 76(22), 23353-23382.
- [WAN18a] Wang, X. Y., Jiao, L. X., Wang, X. B., Yang, H. Y., & Niu, P. P. (2018). A new keypoint-based copy-move forgery detection for color image. *Applied Intelligence*, 1-23.
- [WAN18b] Wang, X. Y., Liu, Y. N., Xu, H., Wang, P., & Yang, H. Y. (2018) Robust copy-move forgery detection using quaternion exponent moments. *Pattern Analysis and Applications*, 21(2): 451-467. <https://doi.org/10.1007/s10044-016-0588-1>

- [WAR16a] Warbhe, A. D., Dharaskar, R. V., & Thakare, V. M. (2016). A survey on keypoint based copy-paste forgery detection techniques. *Procedia Computer Science*, 78, 61-67.
- [WAR16b] Warif, N. B. A., Wahab, A. W. A., Idris, M. Y. I., Ramli, R., Salleh, R., Shamshirband, S., & Choo, K. K. R. (2016). Copy-move forgery detection: survey, challenges and future directions. *Journal of Network and Computer Applications*, 75, 259-278.
- [WU10] Wu, Q., Wang, S., & Zhang, X. (2010, November). Detection of image region-duplication with rotation and scaling tolerance. In *International Conference on Computational Collective Intelligence* (pp. 100-108). Springer, Berlin, Heidelberg.
- [YAN17] Yang, F., Li, J., Lu, W., & Weng, J. (2017). Copy-move forgery detection based on hybrid features. *Engineering Applications of Artificial Intelligence*, 59, 73-83.
- [YAN18] Yang, B., Sun, X., Guo, H., Xia, Z., & Chen, X. (2018) A copy-move forgery detection method based on CMFD-SIFT. *Multimedia Tools and Applications*, 77(1): 837-855. <https://doi.org/10.1007/s11042-016-4289-y>
- [YAN19] Yan, Y., Ren, W., & Cao, X. (2019). Recolored Image Detection via a Deep Discriminative Model. *IEEE Transactions on Information Forensics and Security*, 14(1), 5-17. <https://doi.org/10.1109/TIFS.2018.2834155>
- [YU16] Yu, L., Han, Q., & Niu, X. (2016). Feature point-based copy-move forgery detection: covering the non-textured areas. *Multimedia Tools and Applications*, 75(2), 1159-1176.
- [ZHA02] Y.J. Zhang, "Image engineering and related publications," *International Journal of Image and Graphics*, 2 (3), pp. 441-452, 2002.
- [ZHA06] Y.J. Zhang, *Advances in Image and Video Segmentation*, Tsinghua University, Beijing, China, IMR Press.2006.
- [ZHA13a] Zhao, J., & Guo, J. (2013). Passive forensics for copy-move image forgery using a method based on DCT and SVD. *Forensic science international*, 233(1-3), 158-166.

- [ZHA13b] Zhao, J., & Zhao, W. (2013). Passive forensics for region duplication image forgery based on harris feature points and local binary patterns. *Mathematical Problems in Engineering*, 2013.
- [ZHA17] Zhao, F., Shi, W., Qin, B., & Liang, B. (2017). Image forgery detection using segmentation and swarm intelligent algorithm. *Wuhan University Journal of Natural Sciences*, 22(2), 141-148. <https://doi.org/10.1007/s11859-017-1227-4>
- [ZHE14] Zheng, J., & Chang, L. (2014). Detection technology of tampering image based on Harris corner points. *J. Comput. Inf. Syst.*, 10, 1481-1488.
- [ZHO13] Zhong, L., & Xu, W. (2013, May). A robust image copy-move forgery detection based on mixed moments. In *2013 IEEE 4th International Conference on Software Engineering and Service Science* (pp. 381-384). IEEE.
- [ZHO16] Zhong, J., & Gan, Y. (2016) Detection of copy–move forgery using discrete analytical Fourier–Mellin transform. *Nonlinear Dynamics*, 84(1): 189-202. <https://doi.org/10.1007/s11071-015-2374-9>
- [ZHO17a] Zhong, J., Gan, Y., Young, J., Huang, L., & Lin, P. (2017) A new block-based method for copy move forgery detection under image geometric transforms. *Multimedia Tools and Applications*, 76(13): 14887-14903. <https://doi.org/10.1007/s11042-016-4201-9>
- [ZHO17b] Zhong, J., Gan, Y., Young, J., & Lin, P. (2017) Copy Move Forgery Image Detection via Discrete Radon and Polar Complex Exponential Transform-Based Moment Invariant Features. *International Journal of Pattern Recognition and Artificial Intelligence*, 31(02): 1754005. <https://doi.org/10.1142/S0218001417540052>

# Biografija autora

## Osnovni podaci

Aleksandra S. Pavlović rođena je 04.03.1985. godine u Kraljevu. Završila je 2004. godine Gimnaziju u Raškoj, prirodno-matematički smer, kao nosilac diplome „Vuk Karadžić“. Diplomirala je 2008. godine na Elektrotehničkom fakultetu Univerziteta u Beogradu na odseku Telekomunikacije i informacione tehnologije, smer Sistemsko inženjerstvo, sa prosečnom ocenom 8.73. Nakon toga je upisala master studije na istom fakultetu, smer Sistemsko inženjerstvo i radiokomunikacije, koje je završila 2010. godine sa prosečnom ocenom 9.33. Upisala je 2010. godine doktorske studije na Elektrotehničkom fakultetu Univerziteta u Beogradu, odsek Telekomunikacije.

## Radno iskustvo:

Angažovana je kao asistent u nastavi na Državnom univerzitetu u Novom Pazaru od 2009. godine u oblasti Audio i video tehnologija. Do sada je bila angažovana na nekoliko predmeta (Osnovi računarske tehnike, Osnovi elektrotehnike 1, Osnovi elektrotehnike 2,

Elektronika, Teorija informacija, Digitalna obrada signala, Digitalna obrada slike, Osnovi televizije, Osnovi audio tehnologija, Elektroakustika, Telekomunikacije, Digitalne komunikacije, Aplikativni softver, Osnovi informatike, Primena računara 1, Digitalna elektronika). Na redovnim godišnjim ocenjivanjima od strane studenata, dobijala je odlične ocene. Od 2018. godine angažovana je na Visokoj školi elektrotehnike i računarstva u Beogradu, kao asistent u nastavi, za užu naučnu oblast Informatika i računarska tehnika.

## **Projekti**

Angažovana na realizaciji i programu istraživanja na projektima:

- “Integralni i optimizirani proces testiranja i održavanja softvera”, pod oznakom TR 13018,
- “Optimizacija performansi energetski-efikasnih računarskih i komunikacionih sistema“, pod oznakom TR 32023,
- *Professional Development of Vocation Education Teachers with European Practices* (Pro-VET, 2018-2021).

## **Dodatna usavršavanja i angažovanja:**

Usavršavala se kroz kurseve za oblasti i projekte na kojima je radila (TR 13018 i TR 32023), kao i na brojnim seminarima koji su održavani na Državnom univerzitetu u Novom Pazaru, u okviru međunarodnog projekta “Tempus”, kao i seminara kompanije FLIR, za obuku za korišćenje termovizijske kamere. Pohađala je i zavšila MUMIA (*Multilingual and multifaceted interactive information access*) trening školu u okviru projekta COST Action IC1002, u oblasti pretraživanja multimedijalnog sadržaja (*Building Next Generation Search Systems*), Olimpijada, Halkidiki, Grčka, septembra 2012. godine. Govori engleski, nemački i ruski jezik.

## **Objavljeni radovi**

Autor je i koautor preko trideset naučnih radova izlaganih i objavljenih na domaćim i međunarodnim konferencijama, kao i u domaćim i međunarodnim časopisima (bez i sa impakt faktorom), kao i nekoliko tehničkih rešenja.

Прилог 1.

### Изјава о ауторству

Потписани-а АЛЕКСАНДРА ГАВЛОВИЋ  
број уписа 5006/10

Изјављујем

да је докторска дисертација под насловом

ДЕСТЕКУЈА НАМЕРНО ИЗАЗВАНИХ  
ПРОМЕНА У САДРЖАЈУ СЛИКЕ

- резултат сопственог истраживачког рада,
- да предложена дисертација у целини ни у деловима није била предложена за добијање било које дипломе према студијским програмима других високошколских установа,
- да су резултати коректно наведени и
- да нисам кршио/ла ауторска права и користио интелектуалну својину других лица.

Потпис докторанда

у Београду, 25.02.2017

А.Гавловић

Прилог 2.

**Изјава о истоветности штампане и електронске  
верзије докторског рада**

Име и презиме аутора АЛЕКСАНДРА ПАВЛОВИЋ

Број уписа 5006/10

Студијски програм ТЕЛЕКОМУНИКАЦИЈЕ

Наслов рада ДЕТЕКЦИЈА НОМЕРНО ИЗАЗВАНИХ ПРОМСНА У СЛЯРСТВУ СЛИКЕ

Ментор проф. др Ирина Ребин

Потписани АЛЕКСАНДРА ПАВЛОВИЋ

изјављујем да је штампана верзија мог докторског рада истоветна електронској верзији коју сам предао/ла за објављивање на порталу Дигиталног репозиторијума Универзитета у Београду.

Дозвољавам да се објаве моји лични подаци везани за добијање академског звања доктора наука, као што су име и презиме, година и место рођења и датум одбране рада.

Ови лични подаци могу се објавити на мрежним страницама дигиталне библиотеке, у електронском каталогу и у публикацијама Универзитета у Београду.

Потпис докторанда

У Београду, 25.02.2019

А.Павловић

Прилог 3.

### Изјава о коришћењу

Овлашћујем Универзитетску библиотеку „Светозар Марковић“ да у Дигитални репозиторијум Универзитета у Београду унесе моју докторску дисертацију под насловом:

ДЕТЕКЦИЈА НАЧЕРНО КЗАЗВАНИХ ПРОМЕНА  
У САДРЖАЈУ СЛИКЕ

која је моје ауторско дело.

Дисертацију са свим прилозима предао/ла сам у електронском формату погодном за трајно архивирање.

Моју докторску дисертацију похађену у Дигитални репозиторијум Универзитета у Београду могу да користе сви који поштују одредбе садржане у одабраном типу лиценце Креативне заједнице (Creative Commons) за коју сам се одлучио/ла.

1. Ауторство
2. Ауторство - некомерцијално
3. Ауторство – некомерцијално – без прераде
4. Ауторство – некомерцијално – делити под истим условима
5. Ауторство – без прераде
6. Ауторство – делити под истим условима

(Молимо да заокружите само једну од шест понуђених лиценци, кратак опис лиценци дат је на полеђини листа).

Потпис докторанда

У Београду, 25.02.2019.

А. Ј. Ђаблочић