

CONTRIBUȚII LA COMPRESIA IMAGINILOR MEDICALE DIGITALE

Teză destinată obținerii
titlului științific de doctor inginer
la
Universitatea Politehnica Timișoara
în domeniul CALCULATOARE ȘI TEHNOLOGIA
INFORMAȚIEI
de către

Ildikó-Angelica Szöke

Conducător științific: prof.univ.dr.ing. Vasile STOICU-TIVADAR

Referenți științifici: prof.univ.dr.ing. Vasile Gheorghiuță GĂITAN
prof. univ. dr. Viorel NEGRU
prof. univ. dr. ing. Stefan HOLBAN

Ziua susținerii tezei: 7 iulie 2017

Seriile Teze de doctorat ale UPT sunt:

- | | |
|---|--|
| 1. Automatică | 9. Inginerie Mecanică |
| 2. Chimie | 10. Știința Calculatoarelor |
| 3. Energetică | 11. Știința și Ingineria Materialelor |
| 4. Ingineria Chimică | 12. Ingineria sistemelor |
| 5. Inginerie Civilă | 13. Inginerie energetică |
| 6. Inginerie Electrică | 14. Calculatoare și tehnologia informației |
| 7. Inginerie Electronică și Telecomunicații | 15. Ingineria materialelor |
| 8. Inginerie Industrială | 16. Inginerie și Management |

Universitatea Politehnica Timișoara a inițiat seriile de mai sus în scopul diseminării expertizei, cunoștințelor și rezultatelor cercetărilor întreprinse în cadrul Școlii doctorale a universității. Seriile conțin, potrivit H.B.Ex.S Nr. 14 / 14.07.2006, tezele de doctorat susținute în universitate începând cu 1 octombrie 2006.

Copyright © Editura Politehnica – Timișoara, 2013

Această publicație este supusă prevederilor legii dreptului de autor. Multiplicarea acestei publicații, în mod integral sau în parte, traducerea, tipărirea, reutilizarea ilustrațiilor, expunerea, radiodifuzarea, reproducerea pe microfilme sau în orice altă formă este permisă numai cu respectarea prevederilor Legii române a dreptului de autor în vigoare și permisiunea pentru utilizare obținută în scris din partea Universității Politehnica Timișoara. Toate încălcările acestor drepturi vor fi penalizate potrivit Legii române a drepturilor de autor.

România, 300159 Timișoara, Bd. Republicii 9,
Tel./fax 0256 403823
e-mail: editura@edipol.upt.ro

Cuvânt înainte

În ultimii ani capacitatea de stocare și transmitere a informației a crescut considerabil. În același timp, dezvoltarea și cererea de date sau obiecte multimedia este într-o continuă ascensiune. Evoluțiile recente în tehnologia informației au revoluționat numeroase domenii de cercetare. Medicina, este doar unul dintre domeniile în care dezvoltările tehnologice au făcut progrese importante. Volumul datelor care descriu aspecte cu impact direct sau indirect în practica medicală a crescut exponențial în ultima decadă. În contextul acestei dezvoltări o contribuție importantă o are imagistica medicală. Diversificarea echipamentelor de investigații medicale a contribuit semnificativ la creșterea cantității de date medicale prin generarea unor cantități mari de imagini de cele mai diverse tipuri. Faptul că acestea, conform legislațiilor în vigoare, trebuie să fie arhivate o perioadă de timp îndelungată de ordinul lunilor și anilor, a ridicat problema rezolvării creșterii spațiului de stocare. Faptul că imaginile medicale arhivate trebuie corelate cu diagnosticul aferent, a complicat și mai mult problema. Din aceste considerente s-a investit și se investește un efort considerabil în domeniul stocării imaginilor medicale. Au apărut platforme specializate pentru arhivarea imaginilor medicale corelate cu diagnosticul aferent, care însă sunt destinate marilor unități medicale, nefiind posibilă utilizarea lor în marea majoritate a centrelor de imagistică medicală care utilizează o arhivare obișnuită a datelor medicale de tip imagine. Indiferent de platforma utilizată sau a reținerii imaginilor medicale obișnuit în baze de date clasice apare problema utilizării unor formate de imagine clasice de tip JPEG, TIFF, BMP etc. Acestea ocupă un spațiu considerabil.

Din acest considerent, în prezenta teză de doctorat se propune un nou format de imagine, care se pretează pentru reprezentarea imaginilor în general și în particular a imaginilor medicale. Acest format de imagine poate micșora până de 4 ori dimensiunea imaginii în condițiile păstrării unei acuratețe ridicate a imaginii în cauză.

Timișoara, iulie 2017

Ildikó-Angelica Szöke

Această teză de doctorat nu ar fi fost realizată fără suportul necondiționat al domnilor profesori Dr. Ing. Vasile Stoicu-Tivadar și Dr. Ing. Ștefan Holban. Îmi mulțumesc domnului profesor Dr. Ing. Vasile Stoicu-Tivadar pentru suportul profesionist, acordat în calitate de conducător științific. Sunt de asemenea recunoscătoare domnului profesor Dr. Ing. Ștefan Holban pentru răbdarea și suportul științific și moral pe care domnul profesor mi l-a oferit când a fost necesar.

Mulțumesc familiei pentru susținere, înțelegere și răbdarea de care au dat dovadă.

Szöke, Ildikó-Angelica

Contribuții la compresia imaginilor medicale digitale

Teze de doctorat ale UPT, Seria X, Nr. YY, Editura Politehnica, 2016, XX pagini, XX figuri, XX tabele.

Cuvinte cheie: algoritmul Local Binary Pattern, indice de similaritate metrică (SSIM), Local Binary Compressed (LBC)

Rezumat,

Teza de doctorat propune un nou algoritm, derivat din algoritmul Local Binary Patter, de compresie a diferitelor tipuri de imagini medicale și care a fost numit Local Binary Compressed. Teza propune, de altfel, și un instrument în sine care analizează indicele de similaritate (SSIM) dintre imaginile obținute folosind diferiți algoritmi de compresie. Rezultatele obținute, făcute pe diferite tipuri de imagini medicale, demonstrează o îmbunătățire semnificativă față de arhivarea clasică și relevă utilitatea metodei ca alternativă la maniera actuală de a arhiva și stoca imagini

CUPRINS		Pag
Notaiii, abrevieri, acronime		1
Lista de figuri		4
Lista de tabele		8
1	Introducere	
1.1	Motivație	9
1.2	Obiective	10
1.3	Publicații	11
1.4	Structura tezei de doctorat	12
2	Formate de imagini utilizate în imagistica medicală	
2.1	Tehnici imagistice medicale	14
2.2	Structura unei imagini digitale	15
2.3	Caracteristicile comune ale fișierelor de imagine	16
2.4	Compresia imaginilor	17
2.5	Standarde utilizate în imagistica medicală	24
2.6	Concluzii	30
3	Operatorul Local Binary Pattern	
3.1	Operatorul de baza LBP	32
3.2	Tipuri de vecinătăți și metode de interpolare	34
3.3	Pattern-uri uniforme	37
3.4	Invariantul Rotation asociat LBP-ului	39
3.5	Variații ale operatorului de baza LBP	40
3.6	Concluzii	41
4	Compresia imaginilor statice utilizând operatorul Local Binary Pattern. Formatul LBC	
4.1	Compresia imaginilor utilizat operatorul Local Binary Pattern. Principiul metodei propuse	43
4.1.1	Compresia imaginilor	44
4.1.2	Restaurarea imaginii comprimate	44
4.2	Metrici de similaritate	47
4.3	Concluzii	51
5	Rezultate experimentale	
5.1	Corelația dintre indexul de compresie și dimensiunea imaginii	52
5.2	Determinarea valorii constantei Gaussiene și Uniforme pentru obținerea celui mai bun indice de similaritate SSIM	57
5.3	Concluzii	64

6	Compresia imaginilor digitale medicale statice. Rezultate experimentale	
6.1	6.1 Determinarea exactă a constantei Gaussiene și Uniforme care determină mărimea intervalului de dispersie în jurul valorii LBP	66
6.2	6.2 Stabilirea influenței pe care o prezintă cele mai utilizate formate de imagini medicale (BMP, JPG, PNG) asupra procesului de compresie	70
6.2.1	6.2.1 Stabilirea influenței pe care o prezintă formatul de tip BMP asupra procesului de compresie	71
6.2.2	6.2.2 Stabilirea influenței pe care o prezintă formatul de tip JPG asupra procesului de compresie	73
6.2.3	6.2.3 Stabilirea influenței pe care o prezintă formatul de tip PNG asupra procesului de compresie	74
6.2.4	6.2.4 Eficiența algoritmului de compresie	75
6.3	6.3 Concluzii	77
7	Concluzii și Contribuții personale	
7.1	7.1 Concluzii	78
7.2	7.2 Contribuții personale	81
	Anexa	
	A1	82
	A2	89
	Bibliografie	100

Notații, abrevieri, acronime

ACR-NEMA	- standard imagistic apărut în 1985. Dezvoltat de ACR (American College of Radiology) și NEMA (National Electrical Manufacturers Association)
BMP	- Bit Map Image – format imagistic
CCD	- Charge-Coupled Device (senzorii de imagine folosiți în imagistică)
CR, DX	- Digital Roentgenografie
CT	- Tomografia computerizată
DIB	- Device-Independent Bitmap – format imagistic
DICOM	- Digital Imaging and COmmunications in Medicine
DNG	- Digital NeGative – format imagistic
(GDP)	- Gross Domestic Product
GIF	- Graphic Interchange Format – format imagistic
JPEG	- Joint Photographic Expert Group (J.P.E.G.) – format imagistic
LBC	- Local Binary Pattern Compressed – format imagistic
LBP	- Local Binary Pattern
LZV	- Lempel–Ziv–Welch (LZW) lossless data compression algorithm
MG	- Mamografie
MR	- Rezonanța magnetică
NM	- Medicina Nucleară
PET-CT	- Tomografia cu emisie de pozitroni
(PT)	
PNG	- Portable Network Graphic – format imagistic
RAW	- Raw image format (formatul brut de imagine) – format imagistic
RGB	- roșu (Red), verde (Green) și albastru (Blue)
RMN	- Rezonanța Magnetică Nucleară
SC	- imaginile scanate
SSIM	- Structural Similarity Index Metric
TIFF	- Tagged Image File Format – format imagistic
US	- Ultrasonografia
XA	- Angiografie digitală
X-ray	- Radiologie

Lista de figuri

- Figura 1.1 - Date generate în imagistica medicală
- Figura 2.1 - Exemple de imagini medicale rezultate din analize imagistice
- Figura 2.2 - Structura fișierului imagine
- Figura 2.3 - Fluxul procesului de compresie al unei imagini
- Figura 2.4 - Imagine de tip JPEG
- Figura 2.5 - Imagine de tip GIF dimensiune 257.74KB
- Figura 2.6 - Imagine de tip PNG dimensiune 564.69 KB
- Figura 2.7 - Imagine de tip TIFF dimensiune 921.75 KB
- Figura 2.8 - Imagine de tip BMP dimensiune 921.73 KB
- Figura 2.9 - Analyze 7.5. Facilități de procesare a imaginilor (transformări spațiale, modificări a intensității, segmentări de volum, prelucrări matematice etc.)
- Figura 2.10 - Nifti. Facilități de procesare a imaginilor (transformări spațiale, modificări a intensității, segmentări de volum, prelucrări matematice etc.)
- Figura 2.11 - Minc. Facilități de procesare a imaginilor (transformări spațiale, modificări a intensității, segmentări de volum, prelucrări matematice etc.)
- Figura 2.12 - Viewer Dicom
- Figura 3.1 - Operatorul de bază LBP
- Figura 3.2 - Imaginea inițială și histograma aferentă
- Figura 3.3 - Vecinătăți circulare
- Figura 3.5 - Coordonatele reale și întregi
- Figura 3.6 - Interpolare liniară
- Figura 3.7 - Interpolare biliniară
- Figura 3.8 - Cele 9 pattern-uri uniforme corespunzătoare unui pixel cu 8 vecinătăți
- Figura 3.9 - Pattern-uri uniforme pentru o vecinătate 3x3
- Figura 3.10 - Diferite tipuri de micro-texturi determinate de LBP
- Figura 3.11 - Rotația unei vecinătăți circulare 3x3
- Figura 4.1 - Algoritmul de compresie / decompresie

- Figura 4.2 - Procesul de comprimare / decomprimare a unei imagini
- Figura 4.3 - Diagrama sistemului SSIM
- Figura 5.1 - Imagini ecografice
- Figura 5.2 - Blocuri color
- Figura 5.3 - Imagini fotografice - clădiri
- Figura 5.4 - Imagini fotografice - fluturi
- Figura 5.5 - Graficul indicelui de compresie pentru imagini ecografice
- Figura 5.6 - Graficul indicelui de compresie pentru imagini de tip blocuri colorate
- Figura 5.7 - Graficul indicelui de compresie pentru imagini de tip clădiri
- Figura 5.8 - Graficul indicelui de compresie pentru imagini de tip fluturi
- Figura 5.9 - Graficul indicelui de compresie funcție de dimensiunea imaginii
- Figura 5.10 - Graficul valorii SSIM pentru imaginea Bo - 1.BMP pentru cazul unei reconstrucții a acesteia utilizând o distribuție Gaussiană, respectiv uniformă
- Figura 5.11 - Graficul valorii SSIM pentru imaginea 15_red_15_green_50_blue.jpg pentru cazul unei reconstrucții a acesteia utilizând o distribuție Gaussiană, respectiv uniformă
- Figura 5.12 - Graficul valorii SSIM pentru imaginea image 101_0141.jpg pentru cazul unei reconstrucții a acesteia utilizând o distribuție Gaussiană, respectiv uniformă.
- Figura 5.13 - Graficul valorii SSIM pentru imaginea 4.jpg pentru cazul unei reconstrucții a acesteia utilizând o distribuție Gaussiană, respectiv uniformă
- Figura 5.14 - Graficul valorii SSIM pentru setul de imagini ecografice pentru cazul unei reconstrucții a acesteia, utilizând o distribuție Uniformă (a), respectiv Gaussiană (b)
- Figura 5.15 - Graficul valorii SSIM pentru setul de imagini de tip clădiri, pentru cazul unei reconstrucții a acesteia, utilizând o distribuție Uniformă (a), respectiv Gaussiană (b)
- Figura 5.16 - Graficul valorii SSIM pentru tot setul de imagini (ecografii, blocuri colorate, clădiri, fluturi), pentru cazul unei reconstrucții a acesteia, utilizând o distribuție Uniformă (a), respectiv Gaussiană (b)

- Figura 6.1 - Caracteristicile de tip dimensiune (bytes) a imaginilor care sunt prezente în baza de date de imagini ecografice
- Figura 6.2 - Valorile medii, minime respectiv maxime pentru indicele de compresie care se poate obține pentru imaginile ecografice care sunt prezente în baza de date
- Figura 6.3a - Valoarea medie, minimă respectiv maximă a indicelui de similaritate pentru cazul utilizării unei distribuții gaussiene care este folosită pentru calculul intervalului de dispersie a valorilor LBP
- Figura 6.3b - Valoarea medie, minimă respectiv maximă a indicelui de similaritate pentru cazul utilizării unei distribuții uniforme care este folosită pentru calculul intervalului de dispersie a valorilor LBP
- Figura 6.4 - Variația indicelui de similaritate pentru cazul utilizării unei distribuții gaussiene, respectiv uniforme care este folosită pentru calculul intervalului de dispersie a valorilor LBP
- Figura 6.5 - Imagini radiologice reprezentative pentru setul de imagini de tip BMP, JPG, PNG
- Figura 6.6 - Rezultate statistice pentru imagini medicale statice de tip BMP
- Figura 6.7 - Rezultate statistice pentru imagini medicale statice de tip JPG
- Figura 6.8 - Rezultate statistice pentru imagini medicale statice de tip PNG
- Figura 6.9 - Dimensiunea imaginilor (KO) pentru formatele BMP, JPG, PNG originale și dimensiunea imaginilor comprimate (formatul LBC)
- Figura 6.10 - Raportul între dimensiunea imaginilor în formatele BMP, JPG, PNG originale și dimensiunea imaginilor comprimate (formatul LBC)
- Figura 6.11 - Graficele relației dintre: (a) formatul imaginii și factorul de compresie (b) formatul imaginii și indicele de similaritate
- Figura A1.1 - Prima pagina din aplicația LBP Image Compression
- Figura A1.2 - (a) Imaginea originală; (b) Imaginea grayscale transformată
- Figura A1.2 - (a) Imaginea de tip dispersie; (b) Imaginea valoare medie
- Figura A1.3 - Imagine obținută prin utilizare unei legi de distribuție de tip Gaussian în care s-a utilizat un interval de dispersie de 1%

- Figura A1.4 - Imagine obținută prin utilizare unei legi de distribuție de tip Uniformă în care s-a utilizat un interval de dispersie de 1%
- Figura A1.5 - Determinarea indicilor de performanță pentru o imagine în formatul LBC
- Figura A1.6 - Instanțierea procesului determinării valorii procentuale de stabilire a intervalului de dispersie a pixelilor
- Figura A1.7 - Computation progress bar
- Figura A1.8 - Exemplu de fișier .csv
- Figura A2.1 - Imagine originală grayscale – tip schiță în creion
- Figura A2.2 - Imagine grayscale - restaurată cu un procent de 5 %, distribuție uniformă
- Figura A2.3 - Imagine grayscale - restaurată cu un procent de 5 %, distribuție Gaussiană
- Figura A2.4 - Imagine originală grayscale – tip ecografie medicală
- Figura A2.5 - Imagine grayscale - restaurată cu un procent de 2%, distribuție uniformă
- Figura A2.6 - Imagine grayscale - restaurată cu un procent de 2%, distribuție Gaussiană
- Figura A2.7 - Imagine originală grayscale – tip portret
- Figura A2.8a - Imagine grayscale - restaurată cu un procent de 10%, distribuție uniformă (SSIM = 0.86019)
- Figura A2.8b - Imagine grayscale - restaurată cu un procent de 2%, distribuție uniformă (SSIM = 0.91346)
- Figura A2.9 - Detaliu Imagine grayscale - restaurată cu un procent de
 - (a) 10% distribuție uniformă (SSIM = 0.86019)
 - (b) 2%, distribuție uniformă (SSIM = 0.91346)
- Figura A2.10a - Imagine grayscale - restaurată cu un procent de 10%, distribuție Gaussiană (SSIM = 0.60194)
- Figura A2.10b - Imagine grayscale - restaurată cu un procent de 2%, distribuție Gaussiană (SSIM = 0.92502)
- Figura A2.11 - Detaliu Imagine grayscale - restaurată cu un procent de
 - (a) 10% distribuție Gaussiană (SSIM = 0.60194)
 - (b) 2%, distribuție Gaussiană (SSIM = 0.92502)

Lista de tabele

- Tabel 2.1 - Avantaje, dezavantaje și utilizări ale principalelor formate de imagine
- Tabel 4.1 - Semnificația variabilelor din formula de calcul a valorii pixelilor în jurul valorii medii
- Tabel 6.1 - Relația dintre formatul imaginii, factorul de compresie și indicele de similaritate
- Tabelul A2.1 - Corelația existentă între natura imaginii / dimensiunea intervalului de dispersie, definită procentual și indicele de similaritate SSIM. Se utilizează o lege de distribuție uniformă.
- Tabelul A2.2 - Corelația existentă între natura imaginii / dimensiunea intervalului de dispersie, definită procentual și indicele de similaritate SSIM. Se utilizează o lege de distribuție Gaussiană.
- Tabelul A2.3 - Indici de compresie obținuți prin utilizarea formatului de imagine LBC

1. INTRODUCERE

1.1. Motivație

Evoluția în domeniul calculatoarelor și a tehnologiei informației din ultimul deceniu a atras după sine un salt major în imagistică în general și în imagistica medicală, în special. Ca urmare a acestei dezvoltări au apărut noi tehnici de investigație medicală care nu ar fi putut exista în absența unor echipamente de calcul puternice și performante. Amintim dintre acestea Rezonanța Magnetică Nucleară (RMN) și Tomografia computerizată (CT). Aceasta a făcut ca domeniul medical să se dezvolte rapid. Acest domeniu a trecut de la o creștere de 8.75% în 2015, la o creștere de 9.1% în 2016, aspect menționat în raportul "2016 Global Medical Trend Rates" publicat de Aon Hewit Insurance and Risk Management [2]. O contribuție importantă la această dezvoltare a avut-o și se estimează că o va avea, imagistica medicală.

Numărul mare de echipamente de investigație medicală de tip imagistic a avut drept consecință creșterea cantității de date care este necesară să fie salvată pe intervale lungi de timp. Acest aspect, se datorează faptului că multitudinea de echipamente medicale de investigații imagistică, generează o multitudine de imagini care au cele mai diverse formate de imagini și dimensiuni. Formatele în cauză sunt în general cele impuse de constructorul echipamentelor în cauză care le consideră adecvate pentru tipul de investigație.

Investițiile în acest domeniu sunt considerabile [1]. De exemplu, USA a cheltuit aproximativ 17% din Produs Intern Brut în 2015 (în acel an Produsul intern brut al SUA - a fost de 18036.65 miliarde de dolari americani). Similar statele Uniunii Europene investesc în domeniul medical peste 10% din PIB. Ca urmare a acestui context, în 2012 cantitatea de informație medicală digitală care a fost de 500 pentabytes, se preconizează că va atinge 25,000 pentabytes in 2020 [1].

În cadrul acestei informații medicale, imagistica medicală are cea mai mare pondere. In 2015 se arată în [3] - Big Data Analytics for Healthcare, că în medie în cadrul unui spital s-au generat 2-3 pentabyte (665 terabytes) de date digitale pentru pacienții internați în spital. Din această cantitate de date, 80% reprezentau imaginile medicale de tip CT, respectiv X-rays. În fiecare an creșterea cantității de date imagistice de natură medicală este de 20% - 30%. Este de menționat faptul că această situație s-a datorat celor aproximativ 30 miliarde de internări în spitale din 2015, care au generat peste 650 miliarde de imagini care au trebuit arhivate. In figura 1.1 se prezintă principalele surse [3] de echipamente medicale care generează mari cantități de date de tip imagine.

Acesta este contextul în care s-a dezvoltat cercetarea prezentată în această teză de doctorat, care se axează pe reducerea cantității de date de tip imagine medicală prin propunerea unui nou tip de format de imagine.




Figura 1.1
 Date generate în imagistica medicală

Sursa
<http://medcitynews.com/2013/03/the-body-in-bytes-medical-images-as-a-source-of-healthcare-big-data-infographic/>

1.2. Obiective

Această teză de doctorat propune o nou format de reprezentare a imaginilor digitale, în cazul general și în special a imaginilor de factură medicală, rezultate în urma unei investigații imagistice. Metoda are la bază conceptul de Local Binary Pattern (LBP) introdus de către Ojala T și Pietikäinen M. [4, 5], operator care permite descrierea texturii unei imagini prin intermediul unui vector de numere întregi, de dimensiune variabilă, care în varianta de bază are dimensiunea de 256 valori. Formatul de imagine propus l-am numit **Local Binary Pattern Compressed (LBC)**.

Cercetarea care a condus în final la un format imagine nou a avut ca și obiective următoarele:

- Analiza caracteristicilor formatelor de imagine utilizate în prezent. În cadrul acestei analize s-a urmărit definirea caracteristicilor care sunt comune formatelor de imagine existente în prezent. Analiza s-a extins și asupra modului în care acestea sunt utilizate de imagistica medicală din momentul de față. De asemenea, s-a avut în vedere o analiză a modului în care se rezolvă, în prezent, stocarea imaginilor medicale corelată cu diagnosticul aferent acestora.
- Efectuarea unei sinteze asupra conceptului de Local Binary Pattern văzut ca un descriptor al texturii imaginii, care poate îngloba informații structurale ce definesc în mod univoc o imagine. Aceasta sinteză a avut ca finalitate determinarea variantei de LBP care se pretează la construirea unui nou format de imagine.

- Găsirea unei modalități de construire a unui format de imagine robust, care să conducă la un factor de compresie mai bun al imaginii în contextul păstrării, cât mai fidel, a conținutului acesteia.
- Efectuarea de studii privind calitatea formatului de imagine propus în cazul general al unor imagini cu formate de imagine diferite, cu dimensiuni diferite și cu conținut diferit. Rezultatul acestui studiu s-a dorit a avea ca finalitate definirea unor criterii de calibrare a formatului în funcție de contextul în care se utilizează.
- Efectuarea unui studiu privind oportunitatea utilizării formatului de imagine propus pentru imaginile rezultate în urma unor investigații medicale imagistice.

Obiectivele enumerate mai sus au fost atinse în cadrul cercetării efectuate și sunt prezentate în această teză.

1.3. Publicații

În cadrul prezentei cercetări au fost prezentate și publicate o serie de lucrări care urmăresc și reflectă diversele etape de cercetare care au fost parcurse. Aceste lucrări sunt:

- 1) Ildikó-Angelica SZÖKE, Vasile STOICU-TIVADAR, Diana LUNGEANU. Sleep fragmentation. A study on how daily activities affect our sleeping, *Intelligent Engineering Systems (INES)*, 2015 IEEE 19th International Conference on 3 – 5 Sept 2015; Pages: 259-263, DOI: 10.1109/INES.2015.7329718
Indexată ISI
- 2) Radu Andrei ȘTEFAN, Ildikó-Angelica SZÖKE, Ștefan HOLBAN. Hierarchical clustering techniques and classification applied in Content Based Image Retrieval (CBIR), *Applied Computational Intelligence and Informatics (SACI)*, 2015 IEEE 10th Jubilee International Symposium on 21-23 May 2015; Pages: 147-52, DOI: 10.1109/SACI.2015.7208188
Indexată IEEE
- 3) Ildikó-Angelica SZÖKE, Diana LUNGEANU, Ștefan HOLBAN. Image compression techniques using Local Binary Pattern, *Applied Machine Intelligence and Informatics (SAMI)*, 2015 IEEE 13th International Symposium on 22-24 January 2015; Pages 139-143, DOI: 10.1109/SAMI.2015.7061863
Indexată ISI
- 4) Ildikó-Angelica SZÖKE, Vasile STOICU-TIVADAR, Diana LUNGEANU. A comparative study of using the LBC format for compressing medical images. *IEEE 15th International Symposium on Applied Machine Intelligence and Informatics (SAMI 2017)*, January 26-28 2017 in Herľany, Slovakia
Indexată IEEE

1.4. Structura tezei de doctorat

Teza este structurată într-un număr de 7 capitole la care se adaugă o anexă. Problematika tratată este următoarea:

În capitolul 1, intitulat **Introducere**, se prezintă contextul care a condus la demararea cercetării prezentate în teză. De asemenea sunt enunțate obiectivele cercetării și articolele care au confirmat și care au rezultat din cercetarea întreprinsă.

În capitolul 2, intitulat **Formate de imagini utilizate in imagistica medicală**, se face o sinteză a principalelor formate de imagini utilizate în imagistică. Fiecare tip de imagine analizată din punctul de vedere a modului în care se cuantifică o imagine achiziționată de un echipament imagistic.

Se arată care este acuratețea reprezentării imagistice și dimensiunile medii pentru formatul de imagine utilizat. Sinteza este urmată de o analiză a platformelor utilizate în imagistica medicală, accentul fiind pus pe cea mai utilizată platformă denumită DICOM.

În capitolul 3, intitulat **Operatorul Local Binary Pattern** este analizat operatorul LBP. În cadrul acestei analize este prezentată varianta de bază a acestei metode precum și variantele care s-au dezvoltat de-a lungul timpului. Analiza a avut ca și finalitate determinarea variantei de LBP care poate fi utilizată la definirea formatului de imagine propus în teză.

În capitolul 4, intitulat **Compresia imaginilor statice utilizând operatorul Local Binary Pattern. Formatul LBC**, se prezintă formatul de imagine propus de autoarea tezei. Propunerea pleacă de la o imagine achiziționată de un echipament imagistic (indiferent de natura acestuia – aparat foto, scanner sau un echipament de imagistică medicală) care este reținută într-un format care prezintă două componente. Prima componentă este o imagine de valori medii, iar cea de a doua o imagine de tip „dispersie”. Imaginea de tip „dispersie” este obținută utilizându-se operatorul LBP în varianta de clasică în care este luată în considerare o regiune de 3x3 pixeli. Cele două imagini sunt reținute într-un format pe care l-am numit LBC (**L**ocal **B**inary **P**attern **C**ompressed). Formatul care conține cele două imagini are o dimensiune de 4 ori mai mică decât imaginea originală din care provine. Cele două imagini din cadrul formatului sunt utilizate pentru reconstrucția imaginii originale în momentul în care se dorește vizualizarea ei. Pentru a determina calitatea formatului LBC s-a utilizat un indice de similaritate metrică SSIM (acronimul de la Structural Similarity Index Metric).

Tehnica propusă prezintă două aspecte. Un prim aspect este cel al faptului că aplicarea ei conduce la obținerea unui format de imagine diferit de cele existente în prezent. Cel de al doilea este legat de faptul că are atașat un mecanism de compresie, respectiv decompresie a matricei de pixeli care definește imaginea originală. Combinarea celor două componente în contextul utilizării a două imagini complementare de reprezentare a unei imagini, conduce la un format eficient, mai ales pentru imagini de dimensiuni mari.

În capitolul 5, intitulat **Rezultate Experimentale**, se efectuează un studiu care are drept scop determinarea setărilor utilizate de formatul LBC. Aceste setări se referă la determinarea intervalelor de dispersie utilizate, la refacerea imaginii

originale în cursul procesului de vizualizare a formatului LBC. Determinarea acestui interval s-a efectuat corelat cu determinarea legii de distribuție optime care se utilizează pentru generarea imaginii din momentul vizualizării acesteia. S-au avut în vedere două legi de distribuție: uniformă și respectiv Gaussiană. Experimentele în care s-au luat în considerare atât imagini grayscale cât și color s-au efectuat luând în considerare toate formatele de imagini care sunt generate de echipamentele de achiziție a imaginilor. Pentru determinarea calității formatului LBC obținut în contextul acestui studiu, s-a utilizat o metrica de similaritate definită de SSIM. De asemenea s-a determinat influența pe care o are dimensiunea imaginii asupra setărilor utilizate în momentul în care o imagine LBC este utilizată ca format de reprezentare.

În capitolul 6, intitulat **Compresia imaginilor digitale medicale statice. Rezultate experimentale**, s-a efectuat un studiu privind eficiența utilizării formatului LBC pentru reprezentarea imaginilor de factură medicală generate de diverse echipamente de investigație imagistică. Aceste imagini prezintă caracteristici care le deosebesc de imaginile obișnuite (de tip fotografic) prin caracteristicile de dimensiune, rezoluție și nu în ultimul rând de conținut. În contextul acestui studiu, s-au utilizat setările formatului LBC determinate în capitolul 5. Studiul s-a efectuat pentru imagini de tip ecografie și radiografie care s-au preluat din baze de date medicale de referință în domeniu. În urma studiului efectuat s-au confirmat setările formatului LBC pentru reprezentarea imaginilor medicale. De asemenea, s-a arătat utilitatea acestui format pentru imagini medicale de mari dimensiuni.

În capitolul 7, intitulat **Concluzii și Contribuții personale** sunt prezentate aspectele care rezultă din utilizarea formatului LBC atât din punct de vedere teoretic cât și practic. Aceste concluzii se referă atât la utilizarea formatului propus pentru reprezentarea imaginilor de factură generală, cât și a celor de natură medicală. În cadrul acestor aspecte sunt subliniate contribuțiile aduse în cadrul cercetării de definire a unui tip de format de imagine.

2. FORMATE DE IMAGINI UTILIZATE ÎN IMAGISTICA MEDICALĂ

În prezentul capitol se face o trecere în revistă a principalelor formate de imagini utilizate în prezent, fiind scoase în evidență cele care sunt utilizate de imagistica medicală. Sunt astfel analizate și prezentate tehnicile medicale care generează imagini, precum și echipamentele care sunt implicate în acest proces. Se arată faptul că dezvoltarea tehnicii medicale în domeniul explorărilor neinvazive a cunoscut o dezvoltare deosebită în ultimul deceniu, când s-a trecut de la explorări de tip radiografic la explorări în care sunt utilizate tehnici de rezonanță magnetică nucleară. Au apărut, ca urmare a acestei dezvoltări, o mare varietate de tipuri de formate de imagini, atât 2D cât și 3D. Ca rezultat al acestei diversități de tipuri de imagine a apărut necesitatea de a corela imaginea obținută cu diagnosticul aferent acesteia și de a stoca pe termen lung aceste informații pentru a putea urmări istoricul unei afecțiuni pe care o are o persoană. Acest aspect a condus la cantități mari de informație medicală de tip imagine, care conform legislației existente este necesară de a fi arhivată pe intervale de ordinul anilor. Din aceste considerente, în ultimul deceniu s-au dezvoltat tehnici de imagistică medicală specifice. Pentru a putea propune, în această direcție, o modalitate nouă de reducere a spațiului de stocare a imaginilor medicale, a devenit necesară trecerea în revistă a structurii unei imagini în cazul general, urmată de prezentarea celor mai importante tipuri de formate de imagini utilizate în prezent, atât în domeniul imagisticii cât și în cel al imagisticii medicale. Se prezintă, de asemenea, principala tehnică utilizată în prezent pentru stocarea imaginilor și corelarea acestora cu un diagnostic.

2.1. Tehnici imagistice medicale

O imagine medicală este reprezentarea structurii interne sau a funcției unei regiuni anatomice sub forma unei matrice formată din elemente de imagine numiți pixeli sau voxeli. Este o reprezentare discretă care rezultă dintr-un proces de eșantionare / reconstrucție a hărților valorilor numerice. Numărul de pixeli folosit pentru a descrie câmpul de vedere al unei anumite modalități de achiziție este o expresie a detaliilor cu care anatomia sau funcția anatomică poate fi descrisă. Valoarea numerică a pixelilor exprimată depinde de modalitatea de formare a imaginii, protocolul de achiziție, de reconstrucție, și în cele din urmă, post-procesare.

În prezent există o mare varietate de tehnici imagistice medicale care se utilizează în funcție de natura investigației medicale. Ceea ce merită remarcat este faptul că tehnicile utilizate au urmărit îndeaproape evoluția tehnologică din domeniul imagisticii.

Prima metodă de investigare imagistică, care a fost utilizată a folosit razele X. Ulterior aceasta a fost înlocuită, în mare parte de tehnologia ecografică, bazată pe ultrasunete. Trebuie de specificat faptul că această înlocuire apare mai ales ca o definire mai exactă a cazurilor în care rezultatele sunt mai bune, utilizând o metodă sau alta.

O dată cu dezvoltarea tehnologiei informației, au apărut noi metode de generare a imaginilor medicale. Astfel a apărut tomograful computerizat care utilizând raze X direcționate și poate crea imagini 3D din interiorul corpului uman.

Ulterior a apărut Rezonanța Magnetică Nucleară (RMN) care se bazează pe faptul că corpul uman are peste 70% apă, făcând astfel posibilă excitarea protonilor de hidrogen sub influența unui câmp magnetic și în consecință recepționarea semnalului de modificare a stării acestora. Semnalul furnizat de aceștia depinde de natura țesutului dând astfel posibilitatea interpretării de către un calculator și reproducerea cu mare exactitate a tuturor țesuturilor din corpul uman.

Exemple din cele mai cunoscute tipuri de imagini medicale sunt prezentate în figura 2.1:




Figura 2.1 Exemple de imagini medicale rezultate din analize imagistice de tip:
a) radiografie; b) ecografie;
c) computer tomograf; d) rezonanță magnetică nucleară;

- Radiografiile utilizează un sistem de iradiere cu raze X. Tehnica este utilizată pentru obținerea unor imagini digitale sau analogice atunci când se investighează sistemul osos uman.
- Ecografiile utilizează ecouri de ultrasunete emise de un transducer. Acestea se utilizează atunci când se investighează țesuturi moi ale unor organe interne din corpul uman. În acest caz, se pot obține atât imagini analogice cât și digitale.
- Imaginile create de computerul tomograf utilizează raze X de mică energie, direcționate spre zona țintă. Utilizând un număr mare de fascicule de acest tip, circular în jurul zonei investigate se poate crea o imagine 3D axială a zonei investigate. Imaginile în acest caz sunt digitale.
- Rezonanța magnetică nucleară utilizează câmpuri electromagnetice care excită protonii de hidrogen din zona investigată. Aceștia emit un semnal atunci când trec din starea de excitare în starea normală, semnal care este utilizat pentru crearea unei imagini digitale a zonei investigate.

2.2. Structura unei imagini digitale

O imagine digitală reprezintă orice imagine provenită de la un scanner, de la o cameră foto digitală sau dintr-un calculator. Imaginile stocate într-un calculator sunt "digitizate", adică au fost supuse unui proces ce transformă o imagine din lumea reală în date numerice (valori digitale). Această organizare a unei imagini digitale poate fi descrisă ca fiind o matrice de pixeli. Un pixel (PICTure ELEment) reprezintă cel mai mic element al unei imagini digitale și are trei atribute ce pot fi exprimate numeric/digital: culoare, opacitate și poziția în matrice (dată de cele două coordonate plane). Informațiile sunt stocate în calculator în format binar, de 0 și 1.

Calculatoarele sunt folosite pentru stocarea și manipularea numerelor, deci odată ce imaginea a fost digitizată aceasta poate fi folosită pentru a examina, arhiva, modifica, afișa, transmite sau imprimă imaginea într-o varietate de modalități.

Rezoluția unei imagini este exprimată în funcție de numărul de pixeli. Cu toate acestea, imaginile fiind Bi-dimensionale, se obișnuiește că rezoluția se exprimă ca $X \times Y$. De exemplu, 640X480 înseamnă 640 de coloane x 480 de rânduri sau înălțime x lățime.

Culoarea fiecărui pixel este reprezentată folosind următoarele metode:

- Dacă imaginea este monocromă, culoarea fiecărui pixel este exprimată printr-un bit, 1 sau 0.
- Pentru o imagine true color, culoarea fiecărui pixel este exprimată în valori de intensitate pentru fiecare dintre culorile fundamentale (RGB). De obicei, fiecare componentă a unei culori este reprezentată pe un octet. Rezultă 256 de nivele pentru fiecare dintre componente. În acest caz, sunt necesari câte 3 octeți pentru fiecare pixel, deci rezultă posibilitatea utilizării a 16 777 216 combinații de culoare.
- Pentru o imagine bazată pe o paletă de culori, valoarea fiecărui pixel este interpretată ca fiind un index într-un tabel cu valori RGB (paleta de culori sau colormap). Numărul de biți necesari pentru stocarea culorii unui pixel depinde de numărul de culori din paletă. Dimensiunile obișnuite ale paletelor de culori sunt 16 (4 biți / pixel) și 256 (8 biți / pixel).

Imaginile digitale color (RGB) sunt alcătuite din trei canale: roșu (Red), verde (Green) și albastru (Blue). Fiecare canal este reprezentat pe 8 biți. De aici rezultă faptul că, o imagine color este de fapt o combinație de 3 imagini pe câte 8 biți, câte una pentru fiecare canal. Acesta este standardul actual în fotografia digitală.

Fotografiile alb-negru au apărut la mijlocul secolului al 19-lea. Această denumire de alb-negru este imprecisă deoarece fotografiile conțin de fapt numeroase tonuri de gri. O imagine grayscale conține informații despre intensitatea luminii, nu și despre culoare [1]. O imagine color (RGB) poate fi transformată într-o imagine în tonuri de gri prin intermediul unor algoritmi ce utilizează ponderi diferite ale canalelor de culoare. Procesul ce stă la baza acestor algoritmi este alcătuit din trei pași:

- Obținerea valorilor de roșu, verde și albastru ale unui pixel;
- Prelucrarea matematică a valorilor pentru obținerea unei singure valori de gri;
- Înlocuirea valorilor inițiale de roșu, verde și albastru cu valoarea gri obținută.

2.3. Caracteristicile comune ale fișierelor de imagine

Scopul reținerii imaginilor în fișiere este acela de a putea reda imaginile stocate pentru vizualizări sau prelucrări ulterioare. Pentru realizarea acestui deziderat, este necesar ca un fișier imagine să prezinte o structură standard care să permită așa cum am specificat refacerea (vizualizarea) sa.

Structura unui fișier imagine este formată din următoarele componente:

- Dimensiune imagine (înălțime / lățime);
- Numărul de biți prin care se cuantifică un pixel (1, 4, 8, 16, 24 sau 64 biți);

- Tipul imaginii (specifică dacă valorile pixelilor sunt valori RGB sau index într-o paletă de culori);
- Paleta de culori utilizată (dacă este cazul);
- Matricea cu valorile pixelilor

Diferențele care apar între diferitele formate de fișiere se datorează variantelor care apar în structura prezentată anterior.

Arhitectura unui fișier imagine tipic, este prezentată în figura 2.2. Fișierul prezintă un antet în care sunt incluse informații despre imaginea conținută, după care urmează paleta de culori, dacă valorile pixelilor din imagine reprezintă indecșii din paleta de culori. Matricea cu valorile pixelilor apare după paleta de culori. În marea majoritate a situațiilor pixelii imaginii sunt stocați linie cu linie.

Matricea de pixeli ocupă cea mai mare parte a fișierului imagine.




Figura 2.2 Structura fișierului imagine

De la un format de fișier imagine la altul pot apărea variații în modul de stocare a informațiilor, de genul:

- Informațiile din antet au o ordine diferită;
- Paleta de culori poate fi absentă;
- Tabloul de pixeli poate fi stocat fie linie cu linie fie coloană cu coloană;
- În cazul în care pixelii sunt de tip RGB, ordinea Roșu, Verde, Albastru poate fi diferită;
- Valorile pixelilor pot fi stocate ca plane de biți sau în format împachetat.
 - Dacă imaginea este stocată pe plane de biți, biții pentru fiecare pixel sunt separați conform poziției bitului – cei mai puțin semnificativi biți ai tuturor pixelilor sunt stocați pe o linie, apoi se trece la biții următoarei poziții de bit, și așa mai departe;
 - În formatul împachetat, toți biții care aparțin unui pixel sunt stocați unul după altul.
- Matricea de pixeli poate fi comprimată.

2.4. Compresia imaginilor

Termenul de *compresie a imaginilor* se referă la procesul de reducere a cantității de date necesară pentru a reprezenta imaginea la o calitate subiectivă acceptabilă. Acest lucru poate fi obținut prin eliminarea unor redundanțe prezente într-o imagine [2]. În informatică și teoria informației, compresia datelor reprezintă

procesul de codificare a informațiilor folosind un număr mai mic de biți decât reprezentarea lor necodificată. Un avantaj al compresiei este faptul că reduce consumul de resurse importante, precum spațiul de pe hard disk sau lățimea benzii de transmisie.

Implementarea compresiei unei imagini presupune stocarea imaginii într-un flux de biți pe cât de compact posibil și decodificarea imaginii cât mai exact posibil. Elementele necesare sunt un codificator și un decodificator. Codificatorul primește imaginea și o transformă într-o serie de date binare care apoi este transmisă la intrarea decodicatorului. Decodicatorul reface imaginea decodificată cât mai precis posibil [3]. Fluxul de compresie descris este ilustrat în Figura 2.3.




Figura 2.3 Fluxul procesului de compresie al unei imagini

Cele mai importante proprietăți ale unui algoritm de compresie sunt rata de compresie și calitatea reconstrucției. Raportul de compresie reprezintă raportul dintre numărul de biți necesar reprezentării datelor înainte și după compresie.

Cele mai cunoscute tehnici de compresie a imaginilor sunt *compresia fără pierderi* și *compresia cu pierderi*. Prima tehnică nu produce nici pierdere în calitatea imaginii și este utilizată în cazurile în care acuratețea imaginii este foarte importantă, ca de exemplu desenele tehnice. În cazul unei *compresii cu pierderi*, versiunea originală diferă de cea reconstituită iar pentru determinarea eficienței algoritmului utilizat sunt necesare metode suplimentare de estimare a diferențelor dintre cele două versiuni. În continuare [8, 18] sunt prezentate câteva formate cunoscute de imagini.

JPEG

A fost propus în 1992 de către **Joint Photographic Expert Group** (J.P.E.G.). Formatul poate fi utilizat pentru reprezentarea imaginilor grayscale și color, și a fost destinat comprimării imaginilor alb-negru sau color. La construirea acestui format se ia în considerare faptul că ochiul uman este mai sensibil la variațiile de intensitate al culorilor (luminanță) și mai puțin sensibil la variațiile de culoare din imagine (crominanță). Tehnica presupune decuparea imaginii inițiale în blocuri de dimensiune (8 x 8) pixeli sau (16 x 16) pixeli și aplicarea unei transformate Discrete Cosine Transform (DCT) pentru culoare, la nivelul fiecărui bloc. Rezultatul, care este definit de o singură valoare numerică împreună cu intensitatea culorii respective care nu este alterată, reprezintă valoarea care va defini în final formatul JPEG. Formatul JPEG poate fi utilizat în două variante:

- fără pierdere de informație caz în care raportul între imagine brută și cea de tip JPEG este de 2 la 1
- cu pierdere de informație caz în care raportul între imaginea brută și cea de tip JPEG variază în intervalul [2 , 60]. Evident că în acest caz indicele de similaritate SSIM între imaginea inițială și cea în format JPEG variază mult fiind prezent în intervalul [0.5 – 0.7].

Ceea ce merită de specificat se referă la faptul că în cazul în care o imagine în acest format este urmată de o salvare după fiecare vizualizare, are loc o degradare a calității imaginii care devine perceptibilă. Calitatea în acest caz se corelează cu factorul de compresie ales de utilizator, apărând cu atât mai repede cu cât rata de compresie este mai mare. Un exemplu este prezentat în figura 2.4



Figura 2.4

a) Imaginea inițială de tip JPEG
dimensiune 76.58KB



b) Imagine alterată după două salvări
repetate (dimensiune 35.58 KB)

GIF

Formatul **Graphic Interchange Format** (GIF) a apărut înaintea formatului de tip JPEG. Formatul utilizează o paletă de 256 culori, codificarea acestora fiind deci pe 8 biți. Compresia în acest caz a imaginii brute apare prin aceea că se determină zone care au aceiași culoare, care sunt reprezentate printr-o singura valoare numerică. Ca urmare, formatul este cu atât mai eficient cu cât sunt prezente în imagini zone cu aceiași culoare. De asemenea merită de remarcat faptul că formatul nu gestionează luminanța culorii. Pentru o zonă cu aceiași culoare în care luminanța variază, se ia în calcul o valoare medie a acesteia în formatul GIF aferent zonei în cauză, aspect care conduce la o alterare a imaginii. Din acest considerent, formatul este recomandat pentru definirea obiectelor grafice în care apar zone cu aceiași culoare și cu aceiași luminanță. Acesta este cazul obiectelor grafice de tip butoane

bare de defilare etc. care apar în aplicațiile Windows. Pe de altă parte însă atunci când se obține de la un echipament imagistic o imagine în care o culoare se reprezintă pe 24 de biți (avem 16 milioane de culori), utilizarea acestui format conduce la o alterare a imaginii pentru care indicele de similaritate SSIM poate fi mai mic de 0.8. Un exemplu este prezentat în figura 2.5.



Figura 2.5
Imagine de tip GIF
dimensiune 257.74KB

PNG

Formatul **P**rotatable **N**etwork **G**raphic (PNG) reprezintă o extensie a formatului de tip GIF, prin aceea că în plus față de acesta gestionează și variația luminanței. Se utilizează același principiu ca în cazul gestiunii culorii din formatul GIF, fiind determinate zone cu aceeași luminanță care se definesc printr-o singură valoare (gestionarea acestora se face pe 256 de nivele indiferent de gestionarea culorii care se poate face pe 8 biți (PNG-8) sau pe 24 biți (PNG-24). În ambele cazuri dimensiunea imaginii crește semnificativ față de o imagine definită de formatul GIF. Indicele de similaritate variază în acest caz funcție de natura și complexitatea coloristică a imaginii, fiind aproximativ de 0.7. Un exemplu este dat în figura 2.6.



Figura 2.6
Imagine de tip PNG
dimensiune 564.69 KB

TIFF

Formatul **Tagged Image File Format** (TIFF) a fost dezvoltat în 1986, fiind destinat reprezentării imaginilor brute care prezintă o varietate mare de culori și luminanță. Reprezentarea culorilor se face pe 24 biți în cazul obișnuit și pe 64 biți în cazul în care se cere o acuratețe mare de reprezentare a imaginii. Este un format fără pierdere de informație, aspect care face ca dimensiunea unei imagini de acest tip să prezinte dimensiuni mari. Pe de altă parte formatul permite salvări repetate, fără alterarea calității imaginii. În prezent este utilizat în industria tipografică și în imagistica medicală în contextul unor platforme specializate de tip Nifti [53] respectiv Minc [54] (destinate gestiunii imaginilor medicale obținute în tomografia craniană). Un exemplu este prezentat în figura 2.7.



Figura 2.7
Imagine de tip TIFF
dimensiune 921.75 KB

BMP / DIB

Formatul **Bit Map Image** (BMP) este utilizat de sistemul de operare Windows. BMP stochează o imagine ca pe o hartă de biți independentă de echipamentul imagistic care a creat imaginea brută. Heder-ul formatului BMP este structurat într-o :

- paletă de culori care specifică tipul imaginii. Acesta poate fi pe 1 bit în cazul imaginilor grayscale, 4 biți în cazul descrierii imaginii prin 16 culori, 8 biți dacă imaginea utilizează un număr de 256 culori sau 24 de biți pentru imaginile de tip true color (16.7 milioane de culori)
- numărul de planuri utilizate pentru reprezentarea imaginii (1 pentru imagini monocrome, respectiv 2 sau 3 pentru cele color)
- o hartă care definește imaginea brută care prezintă structura definită anterior.

DIB este acronimul de la (**Device-Independent Bitmap**). Reprezintă o variantă a formatului BMP cu excepția faptului că heder-urile sunt diferite. Un exemplu este prezentat în figura 2.8.



Figura 2.8
Imagine de tip BMP
dimensiune 921.73 KB

RAW

Formatul de imagine de tip Raw Image Format (RAW) reprezintă datele primare care se obțin de la senzorul echipamentului imagistic. Practic imaginea este definită de harta de pixeli care rezultă în urma unei achiziții de imagine, fiind din acest punct de vedere echivalentul negativului unei imagini fotografice clasice. Din aceste considerente, acest format reprezintă „*formatul brut de imagine*”. Formatul RAW prezintă un header care conține informații referitoare la setările echipamentului imagistic (timp de expunere, contrast, balans alb / negru, etc.) urmat de o hartă de pixeli care conțin doar o singură valoare de tip RGB. Aceste setări vor fi utilizate ulterior ca date inițiale pentru definirea formatului în care imaginea va fi reprezentată (JPEG, BMP etc.). Dimensiunile formatului RAW sunt mari în contextul în care rezoluția imaginii este maximă.

Formatul RAW prezintă două dezavantaje care fac improprie folosirea sa ca imagine care poate fi stocată:

- pentru a putea fi imprimat sau vizualizat este necesară o prelucrare inițială obligatorie
- formatul este dependent de tipul de echipament imagistic care l-a generat. Producătorul se asigură astfel acesta să nu poată fi prelucrat de aplicațiile unor firme.

DNG

Formatul de imagine DNG (**D**igital **NeG**ative) a fost lansat de Adobe în 2004 în intenția de a pune la dispoziția fotografiilor un format universal de fișier RAW. Fișierele de tip DNG prezintă aceleași avantaje și dezavantaje ca cele de tip RAW.

Tabel 2.1 Avantaje, dezavantaje și utilizări ale principalelor formate de imagine [18]

	AVANTAJE	DEZAVANTAJE	UTILIZARE
JPEG	Raport Calitate / Dimensiune imagine foarte bun Codificare pe 8, 16 și 24 biți (16.7 milioane de culori).	Format cu pierderi, datorită algoritmului de compresie Nu permite gestionarea transparenței	Format acceptat de toate aparatele foto digitale In varianta JPEG2 este utilizat de platforma Dicom
GIF	Raport Calitate / Dimensiune imagine bun, dacă complexitatea coloristică a imaginii este mică Poate gestiona transparența. Permite efectuarea de animații.	Codificare doar pe 8 biți. Comprimarea imaginii este dependentă de complexitatea coloristică a imaginii brute	Este un format universal de reprezentare a obiectelor grafice din aplicațiile Web

PNG	<p>Raport Calitate / Dimensiune imagine bun, dacă complexitatea coloristică a imaginii este mică</p> <p>Poate gestiona transparenta mai bine decât formatul GIF.</p>	<p>Imaginile sunt comprimate mai puțin decât formatul JPEG.</p> <p>Nu permite efectuarea de animații</p>	<p>Este un format universal de reprezentare a obiectelor grafice din aplicațiile Web</p> <p>Este un format curent utilizat pentru reprezentările grafice fiind prezent în majoritatea platformelor (Excel, Mathtype etc.) care prezintă componente de editare grafică.</p>
TIFF	<p>Datorită codificării pe 24 biți sau 64 biți calitatea imaginii este foarte bună .</p> <p>Poate gestiona transparenta</p>	<p>Datorită faptului că Imaginile au dimensiuni foarte mari utilizarea sa este restricționată numai pentru cazul reprezentărilor imaginilor cu multe detalii</p> <p>Formatul</p>	<p>Este utilizat în industria tipografică.</p> <p>Reprezintă modalitatea de reprezentare a imaginilor în contextul unor platforme imagistice medicale de tip Nifti, Minc.</p>
BMP / DIB	<p>Format universal prezent în toate versiunile sistemului de operare Windows</p> <p>Calitate imagine bună</p>	<p>Raport Calitate / Dimensiune imagine dependent de modul de reprezentare a culorilor</p> <p>1 bit (alb negru), 4 biți (grayscale), 8 biți (256 culori) 24 biți (16.7 milioane culori)</p>	<p>Este un format universal utilizat de sistemul de operare Windows</p>

Metodele actuale de compresie nu sunt finale. Aspecte interesante, cum ar fi obținerea de modele exacte de imagini, reprezentări optime ale acestor modele și procesarea rapidă a reprezentărilor respective, sunt marile provocări cu care ne confruntăm.

2.5. Standarde utilizate în imagistica medicală

Formatul de fișiere imagine reprezintă modul standard pentru a stoca informația care descrie o imagine, în cadrul unei fișier de date de tip imagine. Un set de date de imagini medicale, constă de obicei dintr-unul sau mai multe imagini, reprezentând:

- proiecția unui volum anatomic pe un plan de imagine (proiecție sau imagine plană),
- o serie de imagini reprezentând secțiuni printr-un volum anatomic (tehnici imagistice tomografice),
- un set de date care definesc un volum (imagistică tridimensională) sau
- achiziționarea multiplă a aceleiași imagini tomografice sau de volum de-a lungul unui interval de timp pentru definirea unei imagini dinamice (imagistica 4D, a patra axă este timpul).

Formatul de fișier descrie modul în care sunt organizate datele de imagine în interiorul fișierului de imagine și modul în care matricea de pixeli care definește imaginea ar trebui să fie interpretată de către un software specializat pentru încărcare și vizualizare corectă. O imagine medicală este reprezentarea structurii interne sau a funcției unei regiuni anatomice sub forma unei matrice de pixeli. Este, din acest considerent, o reprezentare discretă, care rezultă dintr-un proces de eșantionare a unei zone anatomice. Numărul de pixeli folosit pentru a descrie respectiva zonă anatomică, depinde de acuratețea cerută pentru analiza imaginii în contextul actului medical. Precizia de reprezentare care se regăsește direct în calitatea imaginii, depinde de protocolul de achiziție, de reconstrucție și în cele din urmă de post-procesarea imaginii respective [8].

Interpretarea fotometrică

Interpretarea fotometrică specifică modul în care valorile pixelilor care definesc imaginea medicală, se interpretează pentru afișarea corectă a imaginii ca o imagine alb-negru sau color. Astfel:

- Imaginile radiologice clinice, cum ar fi tomografia computerizată cu raze X (CT) ca și imaginile obținute prin rezonanța magnetică (MR) au o scară de interpretare de tip grayscale.
- Imaginile obținute de medicina nucleară, cum ar fi cele generate de tomografia cu emisie de pozitroni (PET) ca și tomografia cu emisie de fotoni (SPECT), sunt de obicei afișate pe o hartă de culoare sau paletă de culori adiacentă. În acest caz, fiecare pixel al imaginii este asociat cu o culoare dintr-o hartă de culoare predefinită specificată de utilizator. Culoarea care se obține, definește modul în care imaginea este reprezentată pe un display imagistic. Ceea ce se obține prin acest mod de reprezentare, în care paleta de culori este definită de utilizator, face posibilă obținerea unor informații de detaliu. Cu alte cuvinte, imaginea se colorează de către utilizator în funcție de modul în care se efectuează interpretarea imagistică. Această culoare este temporară, fiind o informație asociată și nu pre-stocată. Acest aspect, impune ca la nivelul unui pixel, din imaginea inițială, să îi fie atașat încă o valoare, care specifică că aceasta este de tip pseudo-culoare.
- Pentru imaginile medicale color se folosește modelul de culoare roșu-verde-albastru (pe scurt, RGB). În acest caz, imaginea este definită de 3 matrice de pixeli, fiecare reprezentând o culoare RGB de o anumită intensitate. În acest caz, pixelul de culoare apare ca o combinație a celor trei culori primare. Culoarea este, de exemplu, utilizată pentru a codifica direcția fluxului sanguin (și viteza) în ecografiile Doppler, pentru a afișa informațiile funcționale simultan cu cele anatomice ca în PET / CT sau PET / MRI.

Metadate

Metadatele sunt informații care descriu imaginea. Această informație este prezentă în mod obișnuit la începutul fișierului ca un antet și conține dimensiunile matricei imaginii, dacă imaginea este color sau grayscale, cât și informații care facilitează interpretarea fotometrică. Grație metadatelor, o aplicație software este capabilă să recunoască și să deschidă corect o imagine într-un format de fișier acceptat. În cazul imaginilor medicale, metadatele au un rol mai mare, datorită naturii speciale pe care o prezintă imaginile. Astfel, acestea au informații legate de

modul în care s-a achiziționat imaginea și de caracteristicile echipamentului medical care a generat imaginea în cauză. O metadată poate conține inclusiv diagnostice care s-au dat prin analiza imaginii respective. De exemplu, o imagine obținută prin rezonanță magnetică va avea parametri referitori la secvența de puls utilizată, informații de sincronizare, unghiul de flip, numărul de achiziții, etc. O imagine de medicina nucleară (PET) va avea informații despre substanța radio farmaceutică injectată și greutatea pacientului. Aceste date permit ajustarea imaginii funcție de caracteristicile aparatului de investigare imagistică care le-a generat. Metadatele într-o primă instanță (când s-a achiziționat imaginea) conțin numai informații legate de caracteristicile matricei de pixeli obținute printr-o investigație medicală imagistică. Ulterior, metadatele se actualizează cu prelucrări făcute pe imaginea respectivă și de asemenea cu diagnostice relative la imaginea în cauză. Metadatele, din acest considerent, reprezintă un instrument puternic pentru a adnota și exploata informațiile legate de imagine în scopuri clinice și de cercetare, și de a organiza și de a prelua în arhive, imagini și date asociate [10].

Formatele de fișiere de imagine medicale pot fi împărțite în două categorii.

- Primul format este destinat să standardizeze imaginile corelate cu diagnostice aferente, de exemplu, DICOM [55].
- A doua categorie de formate ia în considerare numai imaginile medicale fără să existe posibilitatea atașării unui diagnostic. Sunt prezente numai facilități de prelucrare a imaginilor cu scopul de a obține cât mai multe informații legate de aspectele anatomice prezente, de exemplu, Analyze [52], Nifti [53] și Minc [54].

Fișierele de imagine medicale sunt de obicei stocate folosind una din următoarele două configurații posibile:

- Una în care un singur fișier conține atât metadate cât și imaginii, cu metadatele stocate la începutul fișierului. Această paradigmă este folosită de DICOM, Minc și Nifti.
- A doua modalitate de stocare, utilizează două fișiere, în primul sunt prezente metadatele într-un singur fișier iar datele de imagine într-un al doilea. Formatul de fișier Analyze utilizează paradigma formată din două fișiere (.hdr și .img).

Primul rezultat în domeniul standardizării, care vizează crearea de formate de fișiere standardizate în domeniul imagisticii medicale, a fost formatul Interfile [56]. Acesta a fost creat în 1980 și a fost folosit timp de mai mulți ani pentru gestiunea imaginilor generate de medicina nucleară. O imagine Interfile constă dintr-o pereche de fișiere, unul de metadate în format ASCII (acesta conține informații legate de modul de achiziție a imaginii) și unul care conține datele de imagine. Antetul Interfile poate fi vizualizat și editat cu editorul de text normal.

Al doilea pas a fost dat de realizarea standardului ACR-NEMA care a apărut în 1985. Acesta a fost dezvoltat de ACR (American College of Radiology) și NEMA (National Electrical Manufacturers Association) [19]. Standardul permitea stocarea și

regăsirea imaginilor medicale după conținutul prezent în acestea, fără însă a dispune de facilități de lucru în rețea. În timp, odată cu creșterea dimensiunii bazelor de date, cât și a rețelelor de calculatoare s-au evidențiat limitările impuse de acest tip de utilizare a unei baze de date medicale.

În continuare vom descrie unele dintre cele mai utilizate formate de fișiere de imagini medicale care folosesc standardele mai sus menționate, utilizate în prezent: Analyze, Nifti, Minc și DICOM.

Analyze

Analyze 7.5 a fost creat la sfârșitul anilor 1980 la Clinica Mayo din Rochester, Statele Unite ale Americii. Pentru mai mult de un deceniu, formatul a fost standardul "de facto" în imagistica medicală. Succesul formatului Analyze a fost dat de faptul că acesta a fost proiectat pentru date multidimensionale. În acest format, este posibilă stocarea într-un fișier de date 3D sau 4D (a patra dimensiune fiind de obicei informația temporală) a imaginilor de mari dimensiuni. O imagine Analyze 7.5 este formată din două fișiere binare:

- un fișier de imagine cu extensia ".img", care conține datele brute a matricii de pixeli rezultate în urma unei investigații imagistice medicale și un
- fișier header cu extensia ".hdr", care conține metadate, cum ar fi numărul de pixeli în x, y , a treia dimensiune z, caracteristici de echipament etc.

Antetul are o dimensiune fixă de 348 octeți și este descrisă ca o structură în limbajul de programare C. Formatul este astăzi considerat "vechi", dar este încă utilizat pe scară largă, fiind prezente un număr considerabil de utilitare de procesare a imaginilor. Ca și deficiență poate fi menționat faptul că nu se stochează informații suficiente pentru a stabili în mod clar orientarea imaginii și de asemenea datorită faptului că nu sunt acceptate valori negative în descrierea caracteristicilor imaginii, precum și faptul că apar dificultăți de scalare a acesteia. În Figura 2.9 este prezentată o imagine stocată și analizată de acest format de fișier.




Figura 2.9 **Analyze 7.5** Facilități de procesare a imaginilor (transformări spațiale, modificări a intensității, segmentări de volum, prelucrări matematice etc.) –sursa <http://analyzedirect.com/analyzepro/> accesată în februarie 2017

Nifti

Nifti este un format de fișier creat la începutul anilor 2000 de către un colectiv de cercetare de la National Institutes of Health, cu intenția de a crea un format pentru imagistica neurologică, menținând avantajele formatului Analyze în contextul în care se rezolvă punctele slabe ale acestuia. Nifti poate fi văzut, de fapt, ca un format Analyze revizuit. Formatul utilizează unele dintre câmpurile neutilizate, puțin folosite în antetul Analyze 7.5 pentru a stoca informații noi cum ar fi orientarea imaginii, cu intenția de a evita ambiguitatea stânga-dreapta în studiul creierului. De asemenea este rezolvată problema scalării imaginilor prin acceptarea de valori numerice negative în header-ul formatului. Antetul are o dimensiune de 348 octeți în cazul ".hdr", iar datele definite de matrice de pixeli sunt stocate în fișiere cu extensia ".img". O implementare practică a unui format Nifti pentru prelucrarea datelor obținute prin rezonanță magnetică este descrisă în [57]. Formatul Nifti permite vizualizarea imaginilor 3D scalate din diverse puncte de vedere, fiind asigurată o normalizare a datelor pentru evitarea distorsiunilor [58].

Formatul Nifti a înlocuit rapid formatul Analyze, atunci când se operează cu imagini obținute printr-o investigație imagistică neuronală. O versiune actualizată sub denumirea, Nifti-2, a fost lansată în 2011 pentru a gestiona seturile de date de mari dimensiuni. Această nouă versiune codifică fiecare dintre dimensiunile unei matrice de imagine cu un întreg pe 64 de biți, în loc de un 16 biți ca în Nifti-1, eliminând restricția de a avea o dimensiune limitată la 32.767 pentru imagini pe axele 3D [59].




Figura 2.10 **Nifti** Facilități de procesare a imaginilor (transformări spațiale, modificări a intensității, segmentări de volum, prelucrări matematice etc.)
 sursa <https://rorasa.files.wordpress.com/2013/03/nifti2mat.jpg> accesată în februarie 2017

Minc

Formatul de fișier a fost dezvoltat la Montreal Neurological Institute (MNI), începând din 1992 pentru a furniza un format de date flexibil pentru imagistica medicală. Ideea a fost aceea de a standardiza reprezentarea imaginilor medicale, prin utilizarea unui format standard de reprezentare a datelor și de a utiliza bibliotecile de funcții de prelucrare atașate unei astfel de reprezentări. Această idee a condus la utilizarea formatului NetCDF (Network Common Data Form) [60]. Acesta asigură reprezentarea unui set de date ca un singur fișier care conține două componente:

- Un header de o mărime variabilă, care conține toate informațiile despre atribute, variabile și dimensiunea acestora. Practic, sunt definite toate caracteristicile zonei de date care este atașată respectivului header.
- O parte de date de lungime variabilă care definește setul de date propriu zis.

Utilizându-se această reprezentare standard, s-a realizat o platformă care permite stocarea imaginilor medicale indiferent de natura acestora și modul în care s-au achiziționat, în contextul în care devine posibilă utilizarea unor instrumente de prelucrare care sunt deja dezvoltate pentru standardul în cauză. În prezent, este disponibilă o nouă versiune denumită Minc2. Acesta utilizează un software specializat dezvoltat de MNI Brain Imaging Center, și anume, un vizualizator și o bibliotecă de software de procesare [54].

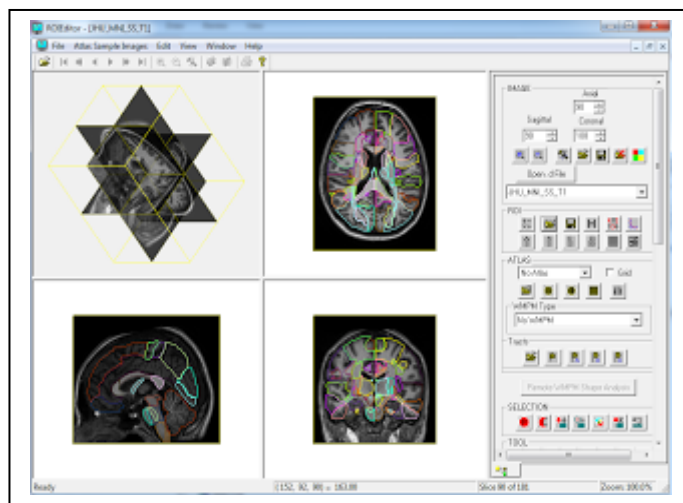


Figura 2.11 **Minc** Facilități de procesare a imaginilor (transformări spațiale, modificări a intensității, segmentări de volum, prelucrări matematice etc.)
 sursa <http://www.mri-resource.kennedykrieger.org/software>
 accesată în februarie 2017

DICOM

Standardul DICOM a fost realizat în 1993 de American College of Radiology împreună cu National Electric Manufacturers Association. Astăzi, standardul DICOM este coloana vertebrală a fiecărui departament de imagistica medicală [15]. DICOM nu este doar un format de fișier, ci de asemenea, un protocol de comunicare în rețea și, deși cele două aspecte nu pot fi complet separate, se va analiza DICOM numai din punctul de vedere al formatului de fișier pe care îl utilizează.

Inovația pe care a introdus-o DICOM, relativă la formatele de fișiere de imagini medicale, constă în faptul că imaginea nu poate fi separată de descrierea procedurii medicale. Cu alte cuvinte, standardul a subliniat conceptul că o imagine care este separată de metadata devine "lipsită de sens".

Metadatale medicale și pixelii imaginii sunt îmbinate într-un fișier unic, iar antetul DICOM, în plus față de informațiile despre matricea imaginii, cuprinde și o descriere completă a întregii proceduri utilizate pentru a genera imaginea (protocolul de achiziție și parametrii echipamentului imagistic utilizat). Antetul conține, de asemenea, informații relative la pacient, cum ar fi numele, sexul, vârsta, greutatea și înălțimea. Din aceste motive, antetul DICOM variază în dimensiune, fiind particular pentru fiecare imagine. În DICOM imaginile sunt reținute în unul din formatele : JPEG, JPEG-LS, JPEG-2000, MPEG2 / MPEG4 [61].

De remarcat este faptul că deși ideea a pornit de la o radiologie, standardul DICOM este un standard adaptabil. Acest lucru a permis să fie acceptat și în alte ramuri medicale care generează imagini, cum ar fi: patologie, endoscopie. În acest sens standardul DICOM a devenit standardul predominant pentru transmiterea imaginilor medicale.

El oferă o serie de facilități cum ar fi:

1. imaginile medicale pot fi vizualizate într-o manieră mult mai rapidă,
2. medicii pot da diagnosticul mult mai rapid,
3. deciziile de tratament pot fi luate mult mai rapid.

De precizat este faptul ca fișierele DICOM nu pot fi vizualizate în mod direct pe un calculator. Legătura dintre imaginile gestionate de formatul de fișier DICOM și alte aplicații informatice auxiliare se face prin intermediul a ceea ce poartă numele de Viewer-e DICOM (Figura 2.12) definită în [11], prin intermediul căruia se face exportul respectiv importul de date imagistice din și spre alte aplicații.




Figura 2.12 Viewer Dicom

Sursa http://www.radiantviewer.com/dicom-viewer-manual/multiplanar_reconstructions_mp.htm

2.6. Concluzii

Datorită dezvoltării tehnologice din ultimii 10 ani, imagistica medicală a devenit una din specializările medicale de top la același nivel și importanță ca specializări tradiționale – interne, chirurgie, etc. Practic, dezvoltarea tehnologică din domeniul calculatoarelor și tehnologiei informației se regăsește aproape în totalitate în diversele componente ale imagisticii medicale. Este de remarcă faptul că datorită diversității de echipamente de achiziție a imaginilor medicale, toate tipurile de formate de tip imagine utilizate în alte domenii diferite de cel medical se regăsesc într-un procent mai mare sau mai mic. Indiferent de tipul de achiziție a imaginii medicale și a formatului utilizat se pune problema stocării acestora un interval, în general, mare de timp. Această problemă nu este rezolvată până în momentul de față. În cadrul prezentului capitol, în urma analizei tipurilor de formate de imagini au rezultat următoarele concluzii:

- Sunt utilizate în imagistica medicală toate tipurile de formate de imagini. Formatul imaginii achiziționate depinde de tipul investigației efectuate și de producătorul care a produs echipamentul de imagistică medicală.
- În marea majoritate a cazurilor, imaginile se stochează clasic (arhivare simplă) pe suporturi de informație. Nu se utilizează baze de date de imagini specializate care să coreleze conținutul informațional al imaginii cu un diagnostic, cu excepția formatului de fișier DICOM.
- Cea mai importantă platformă care asigură o arhivare inteligentă a imaginilor medicală este DICOM. Aceasta este însă disponibilă numai la nivelul unor unități medicale mari, nefiind prezentă în marea majoritate a unităților medicale mici și medii. De asemenea, este de remarcat că formatul utilizat pentru imaginile medicale, care este particular acestei aplicații, face necesar convertirea lui în formate clasice de reprezentare a imaginilor atunci când se pune problema exportului spre alte unități sanitare.

3. OPERATORUL LOCAL BINARY PATTERN

Local Binary Pattern a fost descris pentru prima oară în anul 1996 de către T. Ojala, M. Pietikäinen și D. Harwood, [4]. De atunci, acest operator s-a dovedit a fi un instrument puternic în analiza texturii imaginilor, fiind utilizat până în prezent în domeniul Machine Learning în operații de clasificare și de extragere a caracteristicilor, în care sunt implicate imagini. Deoarece se dorește extinderea domeniului de utilizare a acestui operator, în prezentul capitol se face o analiză amănunțită a variantelor de LBP care s-au dezvoltat de-a lungul timpului. Sunt astfel analizate:

- Operatorul de bază LBP;
- Tipuri de vecinătăți și metode de interpolare;
- Pattern-uri uniforme;
- Invariantul Rotation asociat LBP-ului;
- Variații ale operatorului de baza LBP;

3.1. Operatorul de baza LBP

Operatorul de bază Local Binary Pattern (LBP) introdus de către Ojala se bazează pe faptul că textura cuprinde două elemente complementare: un model – pattern - și puterea sa [4, 5]. Modelul este definit de o singură valoare numerică care caracterizează o zonă de dimensiune variabilă, în varianta de bază de 3 x 3 pixeli. Mărimea acestei valori numerice definește „puterea” modelului. Operatorul se poate aplica atât imaginilor grayscale cât și celor color. În prezenta analiză, se vor discuta tehnicile care sunt aplicate unei imagini grayscale. Pentru imaginile color, principiul de utilizare a operatorului LBP este același, cu observația că acesta se aplică separat pentru fiecare plan de culoare RGB al imaginii.

T. Ojala, M. Pietikäinen și D. Harwood au propus reprezentarea texturii unei imagini printr-un vector, care în varianta de bază are 256 valori numerice. Acest vector se construiește astfel:

- Imaginea este divizată în regiuni de 3x3 pixeli;
- Pentru o regiune (matrice de pixeli) de dimensiune 3x3, pixelul central va fi comparat cu fiecare din cei 8 pixeli care îl înconjoară, el fiind considerat pragul de calcul pentru ceilalți 8 pixeli din matrice;
- Se calculează diferențele dintre valorile pixelilor matricii și valoarea pixelului central și se salvează valoarea 1, dacă diferența este pozitivă, respectiv 0, dacă diferența este negativă. Prin multiplicarea acestor rezultate cu ponderea corespunzătoare și însumarea lor, se obține codul LBP. Cum matricea conține 8 pixeli va rezulta un total de $2^8 = 256$ de etichete diferite posibile, care depind de nivelul de gri al pixelului central și al celorlalți pixeli [6]. În figura următoare se poate urmări operația de bază care conduce la obținerea codului LBP pentru o vecinătate de dimensiune 3x3 pixeli;

- Se repetă această operație pentru fiecare zonă de dimensiune 3x3, pentru pixelii din cadrul imaginii. Se incrementează cu 1 (o unitate) poziția din vectorul de 256 valori numerice la poziția corespunzătoare valorii LBP obținute prin calcul. În baza acestui vector se va construi histograma imaginii care definește univoc imaginea din care provine.

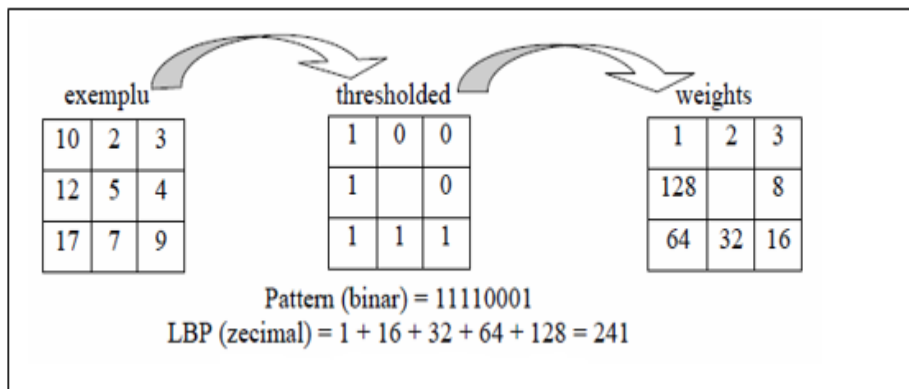


Figura 3.1 – Operatorul de bază LBP

În figura 3. 2 se poate observa histograma unei imagini pentru o vecinătate 3x3 pixeli.




Figura 3.2 Imaginea inițială și histograma aferentă

De-a lungul timpului, au fost dezvoltate plecând de la principiul de bază prezentat anterior, un număr mare de variante care sunt discutate în continuare.

3.2. Tipuri de vecinătăți și metode de interpolare

Operatorul Local Binary Pattern a fost extins pentru a putea utiliza un număr cât mai mare de vecini, astfel că s-au introdus regiunile circulare, numite și vecinătăți circulare [6, 7].

Notăm

- P - numărul de puncte de frontieră cu vecinătăți circulare,
- R - raza vecinătății.




Figura 3.3 Vecinătăți circulare [5]

a) Cazul (P = 8, R=1); b) Cazul (P = 16, R=2); c) Cazul (P = 8, R=2)

Se consideră o imagine monocromatică $I(x,y)$ și variabila g_c care ne dă nivelul de gri al unui pixel arbitrar ales (x,y) , într-o regiune circular uniformă a punctelor de eșantionare P și rază R în jurul punctului ales [5].

$$g_p = I(x_p, y_p), p = 0.000, ..P-1 \quad (3.1)$$

$$x_p = x + R \cdot \cos\left(\frac{2\pi}{P}\right) \quad (3.2)$$

$$y_p = y - R \cdot \sin\left(\frac{2\pi}{P}\right) \quad (3.3)$$

Textura este caracterizată de distribuția nivelelor de gri ale celor $P+1$ puncte:

$$T = t(g_c, g_0, g_1, \dots, g_{P-1}) \quad (3.4)$$

Având în vedere că pixelul central este independent, relația (3.4) poate fi factorizată și formula poate deveni invariantă, nu numai la schimbările de gri, ci și la schimbările de textură, luând în considerare semnul:

$$t(s(g_c - g_c), s(g_1 - g_c), \dots, s(g_{P-1} - g_c)) \quad (3.5)$$

In relația de mai sus, $s(z)$ reprezintă funcția de treaptă:

$$s(z) = \begin{cases} 1, & z \geq 0 \\ 0, & z < 0 \end{cases} \quad (3.6)$$

Operatorul $LBP_{P,R}$ va fi definit după cum urmează:

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) \cdot 2^p \quad (3.7)$$

În practică se folosesc cu precădere regiunile sau vecinătățile circulare. Manipularea imaginilor folosind regiuni circulare aduce dificultăți în practică din două motive: un pixel al unei imagini are coordonatele valori întregi, conform formulelor (3.2) și (3.3) observăm că se obțin valori de tipul real deoarece se iau în considerare parametri precum raze sau număr de puncte.




Figura 3.4 Cazul ($R=2$, $P=8$) [5]

În figura de mai sus observăm că sunt anumite puncte care nu cad în centrul unui pixel ceea ce duce la apariția valorilor reale și a problemelor în practică. După obținerea valorilor reale ale coordonatelor ne confruntăm cu problema de a determina luminozitatea pixelului, adică $I(x,y)$ - valoarea funcției pentru coordonatele calculate. Această funcție ia valori între 0 și 255 în cazul imaginilor monocromatice. Având în vedere că coordonatele (x,y) sunt valori reale, trebuie să facem o aproximare și să determinăm perechea (x', y') de valori întregi; aceasta este diferită de coordonatele inițiale (x,y) .




Figura 3.5 Coordonatele reale și întregi [5]

(x, y) – coordonate reale; (m, n) , $(m+1, n)$, $(m, n+1)$, $(m+1, n+1)$ – valori întregi

Determinarea perechii de valori întregi se poate face în mai multe moduri, cu ajutorul metodelor de interpolare. În continuare se vor trece în revistă cele mai utilizate metode de interpolare [6] utilizate în prezent pentru construirea valorii LBP în contextul unor vecinătăți circulare.

a) Interpolarea de ordinul zero

Considerând că valorile reale ale perechii (x, y) aparțin intervalelor $[m, m+1] \times [n, n+1]$ atunci cea mai simplă și naturală abordare este interpolarea de ordin zero. În acest caz, valoarea funcției $I(x, y)$ este egală cu valorile punctului cel mai apropiat al imaginii, care ia valori întregi drept coordonate și se determină utilizând distanța Euclidiană. Considerăm două puncte $P(x_1, \dots, x_n)$ și $R(y_1, \dots, y_n)$ și distanța Euclidiană (D) dintre cele 2 puncte:

$$D = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (3.8)$$

În practică, trebuie să determinăm distanțele dintre punctul (x, y) și toate cele patru puncte care îl înconjoară. Această metodă nu este eficientă din punct de vedere al costurilor, iar pentru a evita calculul acestor patru distanțe se recurge la o valoare rotunjită a coordonatelor.

b) Interpolare liniară

În acest caz, al interpolării liniare, vom lua în considerare un spațiu unidimensional, iar valoarea funcției pentru coordonatele reale ale pixelului va fi calculată folosind valorile funcțiilor celor mai apropiați doi pixeli.




Figura 3.6 Interpolare liniară [5]

Formula pentru calculul funcției în punctul x este:

$$f(x) = \frac{f([x]+1) - f([x])}{([x]+1) - [x]} \cdot (x - [x]) + f([x]) \quad (3.9)$$

După aplicarea metodei de interpolare obținem:

$$f(x) = (f_2 - f_1) \cdot (x - [x]) + f_1 \quad (3.10)$$

c) Interpolare biliniară

Interpolarea biliniară este o metodă în care toți pixelii aparținând intervalului $[m, m+1] \times [n, n+1]$ contribuie la calcularea valorii funcției $I(x, y)$ de valori reale, prin intermediul aceleași funcții.

Conform celor menționate mai sus, putem spune că interpolarea biliniară este o interpolare liniară aplicată fiecărei dimensiuni; având în vedere că spațiul este bidimensional atunci vom aplica interpolarea liniară de două ori. Vom calcula valorile pentru cele două dimensiuni ale spațiului $[(m+1, n), (m, n)], [(m+1, n+1), (m, n+1)]$, pentru punctele g_1 și g_2 folosind formulele:

$$\begin{aligned} g_1 &= (f_2 - f_1) \cdot (x - m) + f_1 \\ g_2 &= (f_4 - f_3) \cdot (x - m) + f_3 \end{aligned} \quad (3.11)$$

După obținerea acestor două valori vom aplica interpolarea liniară conform formulei (3.11) celor doi parametri g_1 și g_2 și vom obține rezultatele dorite.




Figura 3.7 Interpolare biliniară [5]

3.3. Pattern-uri uniforme

În multe aplicații, pentru analiza imaginilor, se dorește a avea un operator care este invariant sau robust la rotațiile imaginii de intrare. Pattern-ul $LBP_{P,R}$ se obține prin luarea de puncte circulare în jurul pixelului central astfel că rotirea imaginii de intrare are două efecte importante [4]:

- fiecare vecinătate considerată, adică arie, este mutată la o altă locație;
- în cadrul unei vecinătăți punctele considerate de pe cercul care înconjoară punctul de centru sunt rotite într-o orientare diferită.

O altă îmbunătățire a operatorului de bază LBP a fost introducerea așa numitelor pattern-uri uniforme.




Figura 3.8 Cele 9 pattern-uri uniforme corespunzătoare unui pixel cu 8 vecinătăți [7]

Spunem că avem un pattern uniform în cazul în care nu avem mai mult de două tranziții din "0" în "1" și invers din "1" în "0". De exemplu, pattern-urile 00000000 are zero tranziții, 01110000 și 11001111 au câte două tranziții fiecare, sunt uniforme iar pattern-urile 11001001 au patru tranziții și 01010011 au șase tranziții, nu sunt. În cazul mapării cu pattern-uri uniforme, există câte o etichetă diferită pentru fiecare pattern uniform și una singură pentru celelalte pattern-uri [1].

Prin definiție pentru P biți avem $P(P-1)+3$ etichete; adică pentru maparea uniformă a unui pixel cu 8 vecinătăți vom avea 59 de etichete, iar pentru 16 puncte vecine vom avea 243 de etichete ale vecinătăților.

În figura următoare [1] sunt reprezentate cele 58 de etichete posibile pentru pattern-urile uniforme pentru vecinătatea de 3×3 adică 8 biți. Din definiție a 59-a eticheta este folosită pentru toate celelalte pattern-uri.




Figura 3.9 Pattern-uri uniforme pentru o vecinătate 3×3 [5]

Se pretează folosirea pattern-urilor uniforme întrucât majoritatea pattern-urilor sunt uniforme. Ojala a observat în experimentele sale că pattern-urile uniforme se regăsesc în proporție de 90% folosind o vecinătate de (8,1) și în proporție de 70% pentru vecinătatea (16,2). În experimentele făcute pentru recunoașterea feței s-a observat că pattern-urile uniforme se găsesc în proporție de 90.6% pentru o vecinătate de (8, 1) și 85.2% pentru o vecinătate de (8, 2) [1]. De asemenea, folosirea de pattern-uri uniforme este preferată pentru robustețea statistică [5]. Folosind doar pattern-uri uniforme, numărul total de etichete ce se pot reprezenta scade, astfel încât o estimare mai sigură a distribuției pattern-urilor necesită mai puține probe.

Operatorul LBP poate fi considerat o metodă statistică și structurală pentru analiza texturilor [5]. Este de reținut faptul că operatorul atribuie fiecărui pixel eticheta (codul binar) care caracterizează cel mai bine vecinătatea de care aparține, unde vecinătățile pot fi considerate niște micro-texturi. Aceste micro-texturi pot fi de forma: curbe, arii plate, margini etc.




Figura 3.10 Diferite tipuri de micro-texturi determinate de LBP [4]

Folosirea pattern-urilor uniforme a adus rezultate mai bune în ceea ce privește recunoașterea în multe aplicații. Există indicatori care ne arată că aceste pattern-uri sunt mai stabile, mai puțin predispuse la zgomot, iar folosind doar pattern-uri uniforme numărul total de etichete scade considerabil, astfel încât o estimare mai sigură a distribuției necesită mai puține probe.

3.4. Invariantul Rotation asociat LBP-ului

Considerăm un pattern uniform de forma $U(n, r)$, unde n reprezintă numărul de biți de 1 din pattern iar r reprezintă rotația. Dacă este să ne referim la figura 3.10, n corespunde numărului liniei și r corespunde numărului coloanei.

Astfel pentru P puncte, vom avea $n=0, p+1$, unde $p+1$ reprezintă eticheta specială ce marchează toate celelalte pattern-uri neuniforme. Trebuie făcută distincția între numărul posibil de etichete ($P*(P-1)+3$) și numărul $P+1$ de pattern-uri uniforme invariante la rotații.

Astfel în cadrul LBP-ului pentru P vecinătăți vom avea de reprezentat doar $P+2$ pattern-uri (cele invariante la rotații), întrucât celelalte se consideră derivații ale primelor rotații. Rotația unei imagini provoacă translatarea pixelilor la o nouă

locație. Astfel folosind tehnica de mapare invariantă la rotație, fiecare cod binar LBP este circular, rotit la valoarea minimă:

$$LBP_{P,R}^{ri} = \min_i ROR(LBP_{P,R,i}) \quad (3.12)$$




Figura 3.11 Rotația unei vecinătăți circulare 3x3 [26]

În formula 3.12, $ROR(x, i)$ reprezintă rotația secvenței de biți x cu i pași [26]. De exemplu, valorile 00011000b, 00110000b și 01100000b toate se mapează la codul minim 00000011b. Histograma codurilor LBP este invariantă doar la rotațiile imaginii inițiale cu un unghi de $a \cdot (360/P)$, unde $a = 0, 1, \dots, P-1$. Acesta nu este un neajuns, deoarece experimentele de clasificare a imaginilor arată că acest descriptor este foarte robust la rotațiile imaginilor în plan, cu orice unghi.

3.5. Variații ale operatorului de baza LBP

Încă din 1996, anul în care a fost propus operatorul Local Binary Pattern, numeroase variante au fost explorate de literatura de specialitate datorită performanțelor obținute și a simplității de utilizare a acestui operator. Articolul [25] propune o reducere suplimentară a numărului de chei luate în considerare, în scopul clasificării imaginilor. Din cele 59 de coduri ale modelelor uniforme, care sunt obținute prin utilizarea unei regiuni circulare cu raza 1 și numărul de vecini egal cu 8, autorii au reușit să reducă spațiul la 36 de coduri. Prin experimente s-a observat că unele coduri sunt mai relevante pentru clasificare.

Așa cum am menționat mai devreme în acest capitol, operatorul LBP este invariant la schimbările de contrast ale unei imagini. Când o imagine este rotită cu un unghi α , dacă luminozitatea nu se schimbă, contrastul imaginii va rămâne același indiferent de textura acesteia. Prin combinarea operatorului LBP cu măsurarea locală a contrastului, se obține o performanță mai bună în analiza unei imagini rotite [26, 27].

3.6. Concluzii

Operatorul LBP reprezintă un mijloc puternic de reprezentare a texturii unei imagini fiind utilizat în aproape toate subdomeniile care aparțin domeniului Machine Learning. Toate aceste utilizări se referă numai la cazurile în care se urmărește clasificarea de imagini și semnale (electromagnetice, sonore, etc.), descoperirea și recunoașterea de caracteristici prezente în acestea. Funcție de scopul urmărit se utilizează o variantă sau alta de LBP. Astfel din analiza efectuată la nivelul acestui capitol a rezultat că:

- Varianta inițială LBP în care imaginea este descrisă prin zone de 3×3 pixeli pentru care se calculează valoarea LBP utilizată ulterior pentru construirea unui vector cu 256 valori numerice care va defini imaginea, este puțin utilizată deoarece conduce la vectori cu o dimensiune mare. Gradul de acuratețe este maxim în acest caz, aspect care nu este necesar în procesele de tip clasificare imagini.
- Variantele în care vectorul LBP aferent imaginii este rezultatul unor analize în care se utilizează zone circulare de diverse dimensiuni se utilizează atunci când gradul de detaliere nu este important. Situația apare atunci când se pune problema recunoașterii și clasificării imaginilor indiferent de natura lor. Efortul de calcul este mult mai mic decât în cazul anterior.
- Variantele LBP uniform se utilizează atunci când imaginile sunt distorsionate ca poziție în spațiu. Acuratețea de reprezentare este mai mică, aspect care este contrabalansat de o dimensiune mai mică a vectorului LBP rezultat.
- Varianta de construire a vectorului LBP aferent unei imagini este dependentă de natura imaginii pentru care se construiește, de calitatea imaginii și de destinația vectorului LBP rezultat. Acesta se folosește în operații de clasificare a imaginilor, recunoașterea imaginii, de tehnica de recunoaștere sau clasificare utilizată în contextul Machine Learning. Din aceste considerente tehnica de construire a vectorului LBP este aleasă de către utilizator în funcție de scopul urmărit.

Scopul urmărit în cadrul cercetării întreprinse și prezentate în această teză, se referă la un aspect care nu apare până în momentul de față în literatura de specialitate și anume: *definirea unui format de imagine care să extindă paleta formatelor de imagine utilizate în prezent*. Acest format va trebui să prezinte două caracteristici:

1. Să asigure reducerea dimensiunii imaginii;
2. Să prezinte o acuratețe mare relativă la imaginea reprezentată.

Pentru realizarea acestor două deziderate, pentru descrierea texturii imaginii în contextul formatului care se propune, am considerat că cea mai bună variantă de LBP care poate fi luată în considerare este cea care reprezintă varianta de bază, în care textura este descrisă prin zone de 3×3 pixeli. S-a ales această variantă din următoarele considerente:

1. Se obține o acuratețe maximă de reprezentare a texturii imaginii;
2. Rezultatul care se obține prin aplicarea acestei variante nu depinde de caracteristicile de tip poziție a imaginii, distorsiune sau calitate imagistică a acesteia.
3. Această variantă care operează la nivelul unei zone de textură de 3 x 3 pixeli conserva, cu acuratețe maximă, detaliile imaginii, aspect care va asigura o calitate corespunzătoare formatului de imagine propus.

4. COMPRESIA IMAGINILOR STATICE UTILIZAND OPERATORUL LOCAL BINARY PATTERN. FORMATUL LBC.

Metoda propusă în acest capitol are ca punct de plecare trei concluzii care au rezultat în urma analizei efectuate în capitolul 2, referitor la imagistica medicală și anume:

- Imaginile medicale provin de la o mare varietate de echipamente de investigații medicale. Acestea utilizează toată paleta de formate de imagini utilizată în prezent.
- Dimensiunea imaginilor achiziționate este mare. Această dimensiune se asociază cu un număr mare de imagini care se obțin în cursul unei singure investigații medicale.
- Imaginile de tip radiografie, tomografice și respectiv RMN au o precizie mai mică de reprezentare față de cele ecografice. În ambele situații, există o mare cantitate de informații vizuale care sunt redundante și neimportante pentru actul medical.

Având în vedere aceste aspecte devine posibilă definirea unui format de tip imagine pentru imaginile care sunt achiziționate în timpul investigațiilor medicale. Obiectivul pe care l-am avut în vedere este acela de a defini o modalitate de comprimare a imaginilor medicale, pentru stocarea lor pe un suport de informație fără a pierde informația prezentă în imagine, care apoi să poată fi aplicată indiferent de formatul de imagine utilizat de echipamentul imagistic de investigație medicală. Practic, aceste considerente au condus la definirea unui nou tip de format imagine pe care l-am denumit **LBC** (**L**ocal **B**inary **P**attern **C**ompressed). Tehnica utilizează conceptul LBP de descriere a texturii imaginii, concept care s-a prezentat în capitolul 3.

4.1. Compresia imaginilor utilizat operatorul Local Binary Pattern. Principiul metodei propuse

Așa cum s-a specificat într-un capitol anterior, tehnica **Local Binary Pattern** (LBP) permite descrierea texturii unei imagini prin intermediul unui vector care poate avea diverse dimensiuni, funcție de varianta LBP utilizată. În varianta clasică, LBP descrie o zonă de 3x3 a texturii imaginii prin intermediul unui singur pixel.

Practic, acest pixel definește variația pixelilor de pe frontiera zonei LBP raportată la pixelul central al acestei zone. Contorzarea valorilor obținute în urma analizei texturii întregii imagini în care se iau în considerare toate valorile obținute în acest mod, conduce la obținerea unui vector cu o dimensiune de 256 valori care definește univoc imaginea din care a provenit.

4.1.1 Compresia imaginilor

Plecând de la acest mod de construire a unei valori LBP, în varianta de bază descrisă anterior în care se ia în considerare o zonă de dimensiune 3x3 de pixeli, propun descrierea unei imagini grayscale prin două imagini de dimensiune mult mai reduse:

- Prima imagine reprezintă valorile centrale ale zonelor de dimensiune 3x3 care intră în procesul de construire a valorii LBP. Această imagine este văzută ca reprezentând o **valoare medie** a pixelilor care definește textura imaginii.
- Cea de a doua imagine reprezintă valorile LBP obținute în varianta de bază a acestei tehnici. Acest set de valori reprezintă raportul (pixelul are o valoare mai mare sau mai mică) în care se află pixelii de pe frontiera zonei de 3x3 față de pixelul central. Din acest considerent, această imagine este văzută ca o „**dispersie**” a pixelilor de pe frontieră în raport cu pixelul central al zonei. Este necesar de făcut o precizare legată de această a doua imagine și anume: nu este vorba de o dispersie în sensul matematic al acestui concept. Această dispersie definește dacă valoarea pixelilor din jurul valorii medii este mai mică sau mai mare față de valoarea pixelului **valoare medie**. Rămâne ca atunci când se reconstruiește imaginea să se utilizeze o lege de distribuție Gaussiană sau uniformă, care să fie alterată de valorile din imaginea de tip **dispersie** prezentă.

Cele două seturi de imagini reprezintă imaginea comprimată a imaginii din care provin.

Prin urmare formatul în care se reține imaginea este definită de două imagini complementare:

- A. O imagine de tip valorii medii și**
- B. O imagine de tip "dispersie".**

Am denumit acest format de imagine LBC, acronimul de la Local Binary Pattern Compressed.

Un exemplu este dat în figura 4.2.

4.1.2 Restaurarea imaginii comprimate

Plecând de la cele două imagini – **valori medii** și „**dispersii**”, se poate reconstrui imaginea inițială prin generarea valorii fiecărui pixel în jurul valorii medii [38]. În cursul procesului de generare se utilizează informația existentă în imaginea de tip „**dispersie**”. Pentru reconstruirea valorilor pixelilor în jurul valorii medii se pot utiliza două tehnici. Ambele tehnici pleacă de la presupunerea că legea de distribuție a valorii pixelilor în jurul valorii medii poate fi:

- lege de distribuție uniformă sau
- o lege de distribuție Gaussiană.

În ambele cazuri se impune definirea unui factor de dispersie. Acesta este utilizat pentru construirea intervalului în care pot lua valori pixelii. Factorul de dispersie reprezintă practic o valoare numerică de tip procent, care aplicată valorii medii este utilizată pentru construirea intervalului de dispersie a pixelilor în jurul valorii medii. După definirea acestui interval, în funcție de legea de distribuție, se generează valori de pixeli care se adună sau se scad din valoarea pixelului central funcție de sensul operației specificată de imaginea de tip „**dispersie**” atașată.

Relația de calcul care se utilizează pentru reconstruirea imaginii este:

$$Interval\ valori = Valoare\ Medie \pm \frac{Valoare\ Medie \times Procent\ Interval\ Valori}{100} \quad (4.1)$$

unde:

Tabel 4.1 Semnificația variabilelor din formula de calcul a valorii pixelilor în jurul valorii medii

Variabilă	Semnificație
Valoare medie	Reprezintă valoarea pixelului central furnizată de imaginea valori medii ;
Procent interval valori	Valoarea numerică specificată de utilizator care definește dimensiunea intervalului de dispersie în jurul valorii medii. Valoarea a fost determinată experimental în capitolul 5 rezultând valori optime în intervalul [1 , 2]

Intervalul de valori este utilizat pentru calculul valorilor pixelilor în jurul valorii medii a pixelilor valori medii definiți de imaginea **valoare medie**. Relațiile de calcul sunt :

- pentru distribuția uniformă:

$$Valoare\ pixel = f(\text{uniform}(Interval\ Valori), Dispersie) \quad (4.2)$$

- pentru distribuția Gaussiană:

$$Valoare\ pixel = f(\text{gauss}(Interval\ Valori), Dispersie) \quad (4.3)$$

unde *Dispersie* definește "**dispersia**" prezentă în cea de a doua imagine, care alcătuiește formatul LBC.

Mărimea factorului de dispersie și legea de distribuție se determină experimental. Criteriul care se are în vedere este acela a obținerii unui indice de similaritate cât mai mare între imaginea originală și cea rezultată după procesul de compresie / decompresie. Se va arăta în capitolul 4, că valoare indicelui de compresie cât și legea de distribuție depind de natura imaginii cât și de formatul acesteia (JPEG, TIFF, BMP etc.).

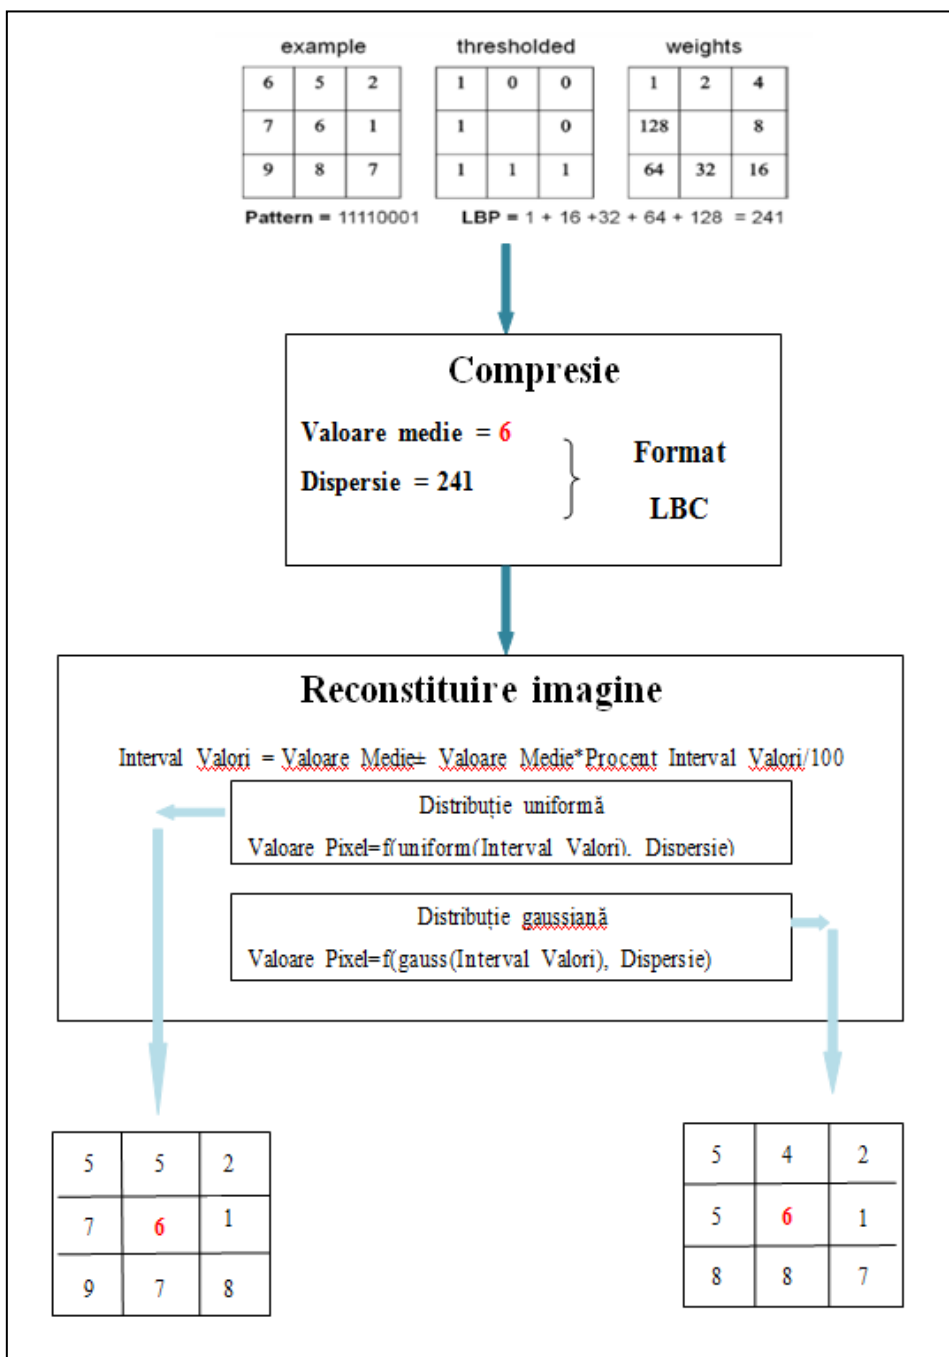


Figura 4.1 – Algoritmul de compresie / decompresie




Figura 4.2 – Procesul de comprimare / decomprimare a unei imagini

4.2 Metrice de similaritate

Imaginile digitale sunt supuse unor degradări în timpul transmisiei, compresiei, prelucrării sau stocării ceea ce poate duce la o degradare a calității vizuale a acestora. Pentru cazurile în care imaginile ajung în final să fie analizate de o persoană, evaluarea calității este subiectivă și lipsită de precizie. Alternativa este utilizarea unei metode obiective care să estimeze calitatea percepută a unei imagini.

Pentru obținerea unei compresii cât mai mare, deci a unui format LBC cât mai bun, s-a impus necesitatea utilizării unei metode de comparare a celor două imagini (inițială și reconstituită) pentru a estima calitatea formatului imaginii utilizat - respectiv LBC.

În acest moment, cel mai utilizat algoritm pentru evaluarea calității este Structural Similarity Index Metric (SSIM) prezentat în articolul din anul 2004: Image Quality Assessment: From Error Visibility to Structural Similarity by Wang. Cele mai frecvente metode utilizate anterior au fost Peak Signal-to-Noise Ratio (PSNR) și Root-Mean-Square Deviation (RMSD). Popularitatea acestor metode a scăzut deoarece nu ia în considerare diferența perceptuală dintre două imagini. O altă

metrică ce ia în considerare diferența perceptuală este cea descrisă în articolul din 2001, "*Spatiotemporal Sensitivity and Visual Attention for Efficient Rendering of Dynamic Environments*" de Hector Yee [40].

- **Peak Signal-to-Noise Ratio (PSNR)**

Reprezintă raportul dintre semnalul de referință și semnalul de distorsiune într-o imagine, date în decibeli. Acest algoritm este cel mai frecvent utilizat pentru a măsura calitatea de reconstrucție a codec-urilor ce folosesc o metodă de compresie cu pierderi. În acest caz, semnalul de referință este dat de datele inițiale iar distorsiunea este eroarea dată de comprimare. PSNR aproximează percepția umană în ceea ce privește calitatea reconstrucției, fiind astfel posibilă efectuarea unei comparații între diferite codec-uri de compresie. O valoare PSNR mai mare indică de obicei o reconstrucție de o calitate mai bună, dar nu în toate cazurile. Trebuie avută mare grijă în ceea ce privește intervalul de validitate al acestei metrici. Acesta este valid doar atunci când se compară rezultate ale aceluiași codec și cu același conținut. PSNR este un algoritm popular deoarece calculele se efectuează ușor și rapid și în același timp oferă rezultate acceptabile.

- **Root-Mean-Square Deviation (RMSD) sau Root-Mean-Square Error (RMSE)**

Sunt metode utilizate în mod frecvent pentru măsurarea diferențelor dintre valorile prezise de un model sau un estimator și valorile reale. Practic, RMSD reprezintă abaterea standard a diferențelor dintre valorile prezise și valorile observate. Aceste diferențe individuale sunt numite reziduri atunci când calculele sunt efectuate asupra setului de date folosit pentru estimare, și se numesc erori de predicție când sunt folosite în afara eșantionului. RMSD are rolul de a agrega magnitudinea erorilor din predicții de mai multe ori într-o singură măsurare a erorii predicative. Algoritmul RMSD este potrivit pentru măsurarea preciziei, dar doar pentru compararea erorilor de predicție ale unor modele diferite pentru aceeași variabilă, nu între variabile. Un alt dezavantaj este faptul că este dependent de metoda de calcul.

- **Structural Similarity Index Metric (SSIM)**

Metodele obiective de evaluare a calității unei imagini au încercat să cuantifice vizibilitatea erorilor dintre o imagine distorsionată și o imagine de referință prin folosirea unor proprietăți ale sistemului vizual uman. Structural Similarity Index Metric (SSIM) este o metrică de evaluare a calității bazată pe degradarea informației structurale. Aceasta a pornit de la ipoteza că percepția vizuală umană este capabilă să extragă informații structurale dintr-un peisaj. Au existat versiuni anterioare ale acestei abordări și au avut rezultate promițătoare în urma unor teste simple. În [41] algoritmul este generalizat pentru a oferi un set mai amplu de rezultate de validare. Luminanța sau strălucirea suprafeței obiectului observat este produsul dintre iluminare și reflexie, dar structura obiectelor din peisaj este independentă de iluminare. Algoritmul își propune să separe influența iluminării. Informația structurală dintr-o imagine este definită ca fiind alcătuită din atributele ce reprezintă structura imaginii independentă de luminanța medie și contrast [41, 42].

Diagrama sistemului SSIM propus pentru evaluarea calității este ilustrată în Figura 4.3.




Figura 13 Diagrama sistemului SSIM (sursa [44])

Se presupune că x și y sunt două semnale ne-negative ale imaginii ce au fost aliniate unul cu celălalt. Considerând că unul dintre semnale este de o calitate perfectă, prin măsurarea similarității putem estima calitatea celui de-al doilea semnal. Algoritmul este împărțit în 3 comparații: luminanță, contrast și structură.

Luminanță

În prima etapă este comparată luminanța celor două semnale. Presupunând că cele două semnale sunt discrete, se estimează intensitatea medie conform formulei (4.4). Funcția de comparare a luminanței este, prin urmare, o funcție de μ_x și μ_y .

$$\mu_x = \frac{1}{n} \sum_{i=1}^n x_i \quad (4.4)$$

În continuare este extrasă intensitatea medie din semnal. Semnalul rezultat $x - \mu_x$ reprezintă proiecția vectorului x pe hiperplanul definit de formula (4.5).

$$\sigma_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \mu_x)(y_i - \mu_y) \quad (4.5)$$

Contrast

În cea de-a doua etapă se estimează contrastul semnalului folosind abaterea standard conform formulei (4.6).

$$\sigma_x = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \mu_x)^2} \quad (4.6)$$

Comparația dintre σ_x și σ_y este notată cu $c(x,y)$ și reprezintă compararea contrastului.

Structura

În a treia etapă semnalul este normalizat prin împărțirea la propria abatere standard. Comparația de structură este notată cu $s(x,y)$ și definește raportul dintre semnalele normalizate:

$$s(x,y) = \frac{\frac{(x - \mu_x)}{\sigma_x}}{\frac{(y - \mu_y)}{\sigma_y}} \quad (4.7)$$

Similaritatea totală

În final, cele trei rezultate sunt combinate pentru a obține similaritatea totală conform formulei (4.8).

$$SSIM(x,y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (4.8)$$

Un aspect important este faptul că cele trei componente sunt relativ independente, astfel încât dacă se modifică contrastul sau luminanța, să nu fie afectată structura[7].

Pentru a completa definirea indicelui SSIM este necesară definirea celor trei valori:

- c_1 reprezintă o constantă introdusă pentru evitarea instabilității atunci când $\mu_x^2 + \mu_y^2$ este foarte aproape de 0.

$$c_1 = (K_1 \cdot L)^2 \quad (4.9)$$

În formula 4.9, L reprezintă intervalul dinamic al valorilor pixelilor (255 în cazul imaginilor în tonuri de gri pe 8 biți), iar $K_1 \ll 1$ este o constantă foarte mică.

- c_2 reprezintă o constantă introdusă pentru corectarea contrastului atunci când $\mu_x^2 + \mu_y^2$ este foarte aproape de 0.

$$c_2 = (K_2 \cdot L)^2 \quad (4.10)$$

În formula 4.10, L reprezintă intervalul dinamic al valorilor pixelilor (255 în cazul imaginilor în tonuri de gri pe 8 biți), iar $K_2 \ll 1$ este o constantă foarte mică.

- σ_{xy} este definită de formula de mai jos:

$$\sigma_{xy} = \frac{1}{n-1} \sum_{i=1}^n (x_i - \mu_x)(y_i - \mu_y) \quad (4.11)$$

În ciuda simplității sale, indexul SSIM are performanțe remarcabile pentru o gamă largă de imagini și tipuri variate de distorsiuni. Față de celelalte metode prezentate, rezultatele obținute aplicând indexul SSIM sunt mult mai consistente, relativ la percepția vizuală.

În prezenta teză s-a utilizat acest index pentru determinarea calității formatului de imagine LBC propus.

4.3 Concluzii

În acest capitol se prezintă metoda propusă de compresie a imaginilor medicale utilizând conceptul Local Binary Pattern utilizat până în momentul de față numai pentru recunoașterea și clasificarea imaginilor. Metoda propusă conduce la definirea unui format nou pe care l-am numit **Local Binary Pattern Compressed** (prescurtat - **LBC**). Metoda presupune descrierea imaginii care se memorează și se stochează pe un suport de informație prin două imagini complementare:

- O imagine de **valori medii**, rezultată prin reținerea pixelului central a zonei LBP de dimensiune 3x3 pixeli care este utilizată pentru analiza imaginii.
- O imagine de tip "**dispersie**" care reprezintă valoarea LBP rezultată în urma calculului de tip LBP.

Formatul care rezultă în urma acestui proces (de tip comprimare) conduce la obținerea unei informații de sinteză care reprezintă imaginea. Această informație este utilizată la refacerea imaginii în cadrul unui proces de decomprimare. La refacerea imaginii se pot utiliza două metode de generare a pixelilor din imagine. În prima metodă se poate utiliza o lege de distribuție uniformă de generare a acestor valori, iar cea de a doua o lege Gaussiană de distribuție. Parametrii acestor legi de distribuție sunt definiți de cele două imagini complementare care definesc imaginea comprimată. Pentru a arăta viabilitatea acestei metode de reprezentare în cadrul tezei s-a efectuat un studiu în capitolul 5 privind oportunitatea utilizării unei legi de distribuție uniformă sau Gaussiană. Viabilitatea a constat în compararea imaginii inițiale, existentă în diverse formate JPEG, GIF, BMP etc. și imaginea în format LBC. Pentru comparare s-a utilizat un indice de similaritate utilizat în prezent, indice care arată cât de similare sunt două imagini din punct de vedere al texturii, contrastului și luminanței. Indicele cunoscut sub denumirea de SSIM (acronimul de la Structural Similarity Index Metric) este analizată, de asemenea, în cadrul acestui capitol.

5. REZULTATE EXPERIMENTALE

În prezentul capitol sunt prezentate experimentele efectuate pentru:

- I. Determinarea legăturii care există între indexul de compresie și dimensiunea imaginii;
- II. Obținerea valorii constantei Gaussiene și Uniforme care determină mărimea intervalului de dispersie în jurul valorii LBP, pentru obținerea celui mai bun indice de similaritate SSIM.

Testele s-au realizat pentru un număr de 80 de imagini (preluate din CURET database [46]) care reprezintă:

- Setul 1 – Imagini ecografice (20 imagini)
- Setul 2 – Blocuri color (20 imagini)
- Setul 3 – Imagini fotografice - clădiri (20 imagini)
- Setul 4 – Imagini fotografice - fluturi (20 imagini)




Figura 5.1 Imagini ecografice




Figura 5.2 Blocuri color




Figura 5.3 Imagini fotografice – clădiri



Figura 5.4 Imagini fotografice – fluturi

Calculul s-a efectuat cu aplicația special dezvoltată pentru această teză, pentru calculul valorii LBP, pentru diverse setări și condiții inițiale, aplicație care este prezentată în Anexă. Calculele statistice s-au realizat utilizându-se pachetul de calcul statistic Origin 8 [45] și o calculator cu 16 giga RAM.

5.1 Corelația dintre indexul de compresie și dimensiunea imaginii

În cadrul acestui test s-a urmărit determinarea legăturii care există între dimensiunea imaginii și factorul de compresie. Testul s-a efectuat pentru fiecare set de imagini. Valoarea pasului de compresie luat în considerare este 1, iar valoarea intervalului maxim în care se modifică pasul de compresie este de 1%, din valoarea LBP calculată pentru imaginea luată în discuție. S-au ales aceste valori deoarece s-a urmărit determinarea legăturii dintre dimensiunea imaginii și factorul de compresie,

motiv pentru care indicele de similaritate dintre imaginea inițială și cea comprimată în această etapă nu a interesat. Rezultatele sunt prezentate în următoarele figuri, pentru fiecare set de date în parte.

- Pentru setul de date care conține imagini ecografice, indicele de compresie este cuprins între 2.715 și 3.557. Din figura 5.5 se observă că acesta crește o dată cu mărirea dimensiunii imaginii. În același timp însă în contextul acestei creșteri apare o dependență puternică de conținutul imaginii.

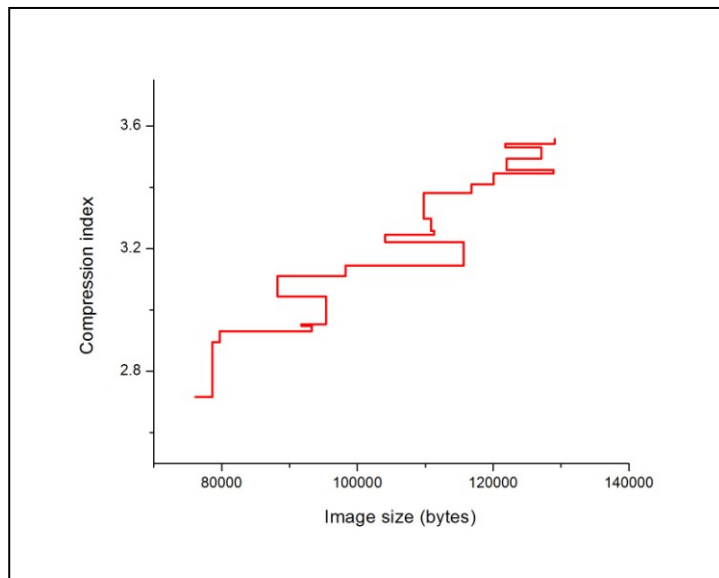


Figura 5.5 Graficul indicelui de compresie pentru imagini ecografice

- Pentru setul de date care conține imagini cu blocuri colorate, indicele de compresie este cuprins între 2.177 și 3.237. Din Figura 5.6, se observă că indicele de compresie crește dependent de tipul majoritar al culorii prezente în imaginea comprimată. Gradientul de culoare variază de la verde (indice de compresie 2.17), roșu (indice de compresie mediu de 2.45), albastru (indice de compresie mediu de 2.67), galben (indice de compresie mediu de 2.9) și respectiv negru (indice de compresie mediu de 3.07).

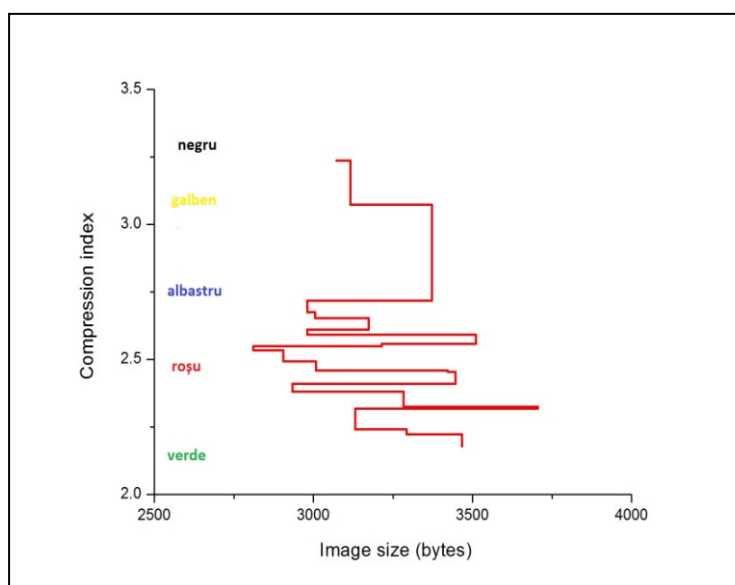


Figura 5.6 Graficul indicelui de compresie pentru imagini de tip blocuri colorate

- Pentru setul de date care conține imagini cu clădiri, indexul de compresie este cuprins între 3.607 și 4.477. Și în acest caz, se observă (Figura 5.7) că indicele de compresie este dependent de mărimea imaginii. Acesta crește o dată cu creșterea dimensiunii imaginii. Variațiile se datorează complexității imaginii (aspect care este dat de complexitatea arhitectonică) și respectiv de culorile dominante în arhitectura prezentă în imagine.

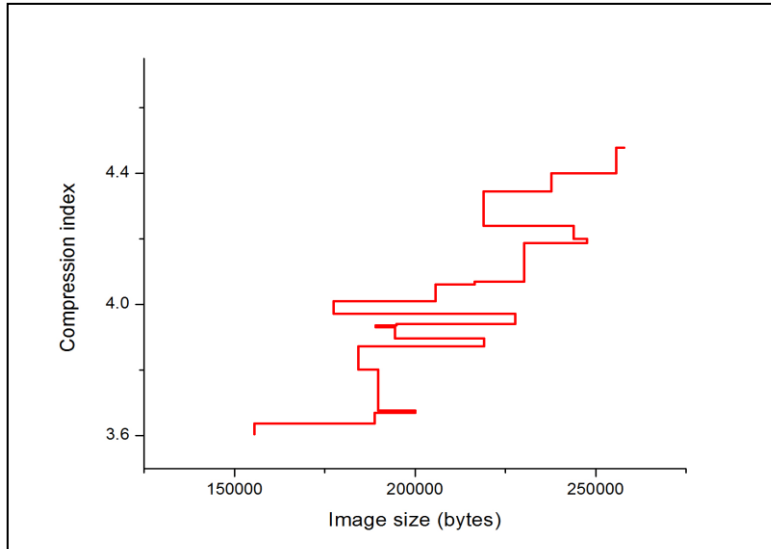


Figura 5.7
Graficul
indicelui de
compresie
pentru imagini
de tip clădiri

- Pentru setul de imagini care reprezintă fluturi, indicele de compresie variază între 3.388 și 4.143. Ceea ce caracterizează acest set de imagini este distribuția culorilor pe suprafețe mici, în contextul existenței unui fundal de imagine din cel mai divers. Se vede din Figura 5.8 că regula care s-a determinat anterior și anume - o dată cu creșterea dimensiunii imaginii crește și indicele de compresie - se aplică și pentru această categorie de imagini. Practic, pentru aceste imagini nu există o culoare dominantă, astfel că apar variații ale indicelui de compresie în funcție de paleta de culori prezentă în imagine.




Figura 5.8
Graficul
indicelui de
compresie
pentru imagini
de tip fluturi

Concluzii

S-a refăcut calcul pentru întregul set de imagini fără a ține cont de natura lor, ceea ce reprezintă acestea. Rezultatul este reprezentat de graficul din Figura 5.9. Se pot trage următoarele concluzii referitoare la legătura dintre dimensiunea imaginii și modul în care se modifică indicele de compresie:

- (a) Valoarea indicelui de compresie este dependentă de mărimea imaginii care se comprimă. O imagine mai mare conduce la un indice de compresie mai mare.
- (b) Legătura dintre aceste două mărimi nu este liniară. Pot apărea variații care se datorează următorilor factori:
 - În imagine este prezentă o culoare dominantă. Tipul culorii va mări sau micșora indicele de compresie, afectând dependența dintre mărimea imaginii și factorul de compresie;
 - Complexitatea imaginii. Aceasta este văzută ca fiind dată de variațiile de culoare în contextul imaginii, de la un pixel la altul a imaginii (textura imaginii este rigidă). Variații mari ale culorilor vor conduce la micșorarea indicelui de compresie.

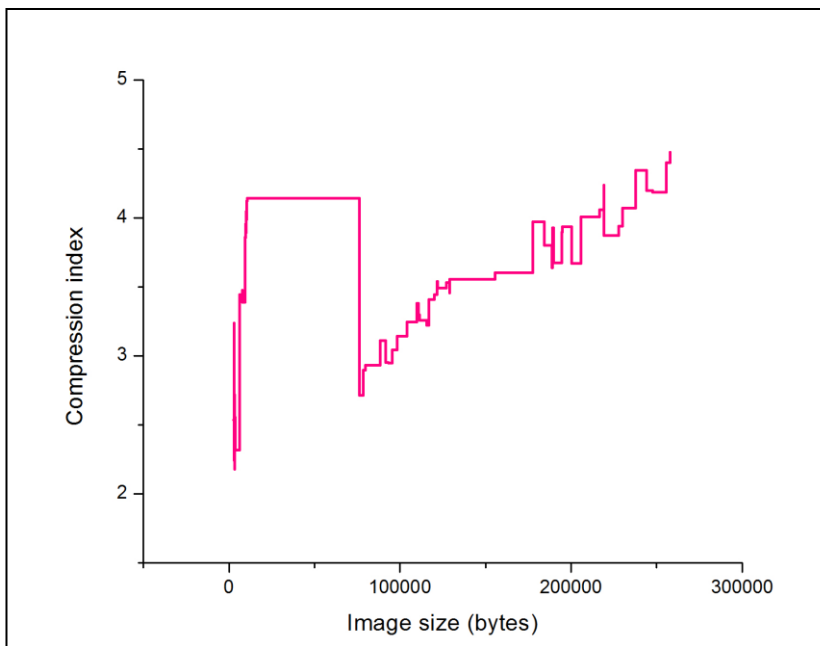


Figura 5.9
Graficul
indicelui de
compresie în
funcție de
dimensiunea
imaginii

5.2 Determinarea valorii constantei Gaussiene și Uniforme pentru obținerea celui mai bun indice de similaritate SSIM

Studiul întreprins se referă la determinarea intervalului de valori (din jurul valori LBP – văzută ca o valoare medie) în care iau valori pixelii, luând în considerare o distribuție inițial Gaussiană și ulterior Uniformă a acestora. Practic, acest aspect conduce la determinarea unei valori procentuale care afectează valoarea medie LBP, valoare care este utilizată pentru specificarea intervalului de dispersie de tip Gaussian, respectiv Uniform în jurul acestei valori medii. În acest scop se ia în considerare un interval de valori de forma [0,1% , 50%] din valoarea medie LBP. Intervalul este parcurs cu un pas de 0.1. Pentru fiecare interval astfel determinat, se calculează factorul de compresie și indicele de similaritate corespunzător. Calculul se face pentru o singură imagine considerată reprezentativă, din cadrul celor 4 seturi de imagini luate în considerare în studiul întreprins.

- Pentru setul de imagini de tip ecografii se obțin rezultatele din Figura 5.10.


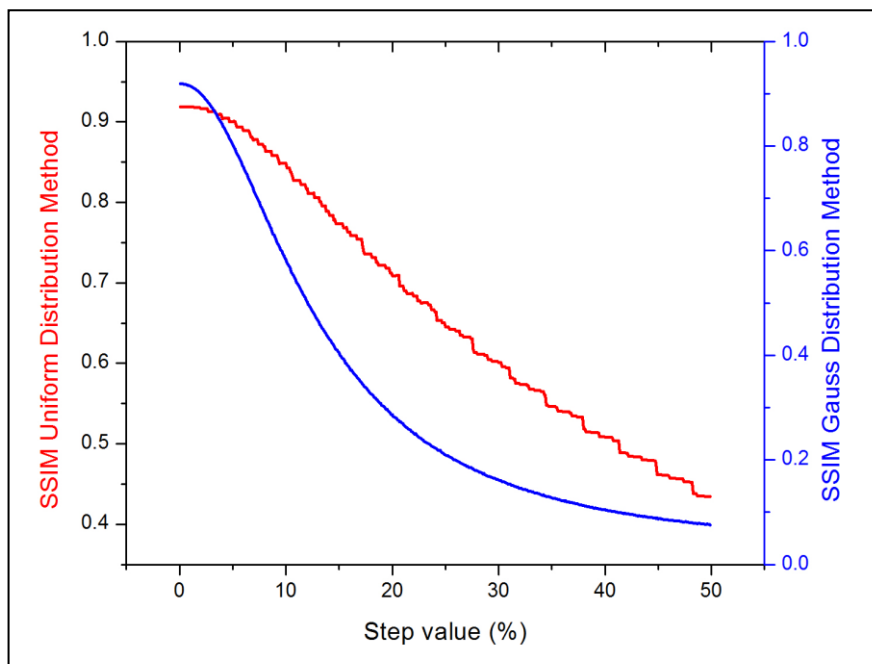


Figura 5.10
Graficul valorii SSIM pentru imaginea Bo - 1.BMP pentru cazul unei reconstrucții a acesteia utilizând o distribuție Gaussiană, respectiv uniformă.

Din figură, se observă că cei mai buni indici de similaritate SSIM apar în intervalul $[0,1 - 3] \%$, cele două metode fiind comparabile. Astfel, dacă se utilizează o distribuție uniformă intervalul în care ia valori SSIM este de $[0,918 - 0,904]$, iar dacă se utilizează o distribuție Gaussiană intervalul în care ia valori SSIM este de $[0,918 - 0,837]$.

- Pentru setul de date care conțin imagini de tip blocuri colorate se obțin rezultatele din Figura 5.11.





Figura 5.11
Graficul valorii SSIM pentru imaginea 15_red_15_green_50_blue.jpg pentru cazul unei reconstrucții a acesteia utilizând o distribuție Gaussiană, respectiv uniformă.

Din figura 5.11, se observă că cei mai buni indici de similaritate SSIM apar în intervalul $[0,1 - 3] \%$, cele două metode fiind comparabile. Astfel dacă se utilizează o

distribuție uniformă, intervalul în care ia valori SSIM-ul este de $[0,918 - 0,904]$, iar dacă se utilizează o distribuție Gaussiană intervalul în care ia valori SSIM-ul este de $[0,918 - 0,837]$.

- Pentru setul de date care conțin imagini de tip clădiri se obțin rezultatele din Figura 5.12.




Figura 5.12
Graficul valorii SSIM pentru imaginea image 101_0141.jpg pentru cazul unei reconstrucții a acesteia utilizând o distribuție Gaussiană, respectiv uniformă.

În contextul în care imaginea conține zone cu culori diferite de mărime medie distribuite aleator, iar trecerile între aceste zone de culoare se face prin zone foarte mici de culori diferite, cele două metode prezintă aproape aceleași valori pentru indicii de tip SSIM. Astfel valorile care sunt acceptabile apar în intervalul $[0,1 - 3]\%$. Astfel, dacă se utilizează o distribuție uniformă intervalul în care ia valori SSIM-ul este de $[0,791 - 0,771]$, iar dacă se utilizează o distribuție Gaussiană intervalul în care ia valori SSIM-ul este de $[0,782 - 0,779]$.

- Pentru setul de date care conțin imagini de tip fluturi se obțin rezultatele din Figura 5.13.




Figura 5.13

Graficul valorii SSIM pentru imaginea 4.jpg pentru cazul unei reconstrucții a acesteia utilizând o distribuție Gaussiană, respectiv uniformă.


Din analiza celor două grafice se observă că cele mai bune valori se obțin pentru mijlocul intervalului care definește procentajul care stabilește intervalul de dispersie în jurul valorii medii. Astfel pentru o distribuție Uniformă cele mai bune valori SSIM apar în intervalul [22 – 23]% (pentru procentajul care stabilește intervalul de dispersie în jurul valorii medii), având valori de [0,698 – 0,697], iar în cazul în care se utilizează o distribuție Gaussiană cele mai bune valori SSIM apar în intervalul [20 – 21] % pentru procentajul care stabilește intervalul de dispersie în jurul valorii medii, având valori de [0,60 – 0,59]. Motivul pentru care se obțin aceste valori relativ mici pentru SSIM se datorează faptului că imaginile sunt de mici dimensiuni (deci conțin un număr mic de pixeli), cu o variație mare a paletei de culori și nuanțe și cu multe detalii.

- Analiza de determinare a intervalului de dispersie în jurul valorii medii – respectiv a procentajului care determină acest interval din valoarea LBP - s-a extins pentru toate imaginile prezente în seturile de date de tip ecografii, respectiv clădiri. Seturile de date care conțin blocuri color și fluturi nu s-au

luat în considerare pentru acest calcul, deoarece reprezintă cazuri particulare de imagini.


- a) Determinarea valorii constantei Gaussiene și Uniforme pentru obținerea celui mai bun indice de similaritate SSIM pentru imagini de tip ecografii

În urma analizei precedente efectuată pentru o singură imagine de tip ecografie, s-a determinat că indicele maxim de similaritate SSIM se obține pentru o valoare a procentajului care determină intervalul de dispersie în jurul valorii medii LBP ca fiind de $[0,1 - 3] \%$. Utilizăm acest interval pentru analiza întregului set de imagini ecografice. Rezultatele sunt prezentate în Figura 5.14a pentru distribuția Uniformă, respectiv Gaussiană în Figura 5.14b.



(a)

Figura 5.14
Graficul valorii SSIM pentru setul de imagini ecografice pentru cazul unei reconstrucții a acesteia, utilizând o distribuție Uniformă (a), respectiv Gaussiană (b)




(b)

Din analiza imaginilor în care apare valoarea medie a indicelui de similaritate (reprezentată de linia continuă orizontală) și dispersia în jurul valorii medii (reprezentată de liniile verticale), se observă în ambele cazuri faptul că:

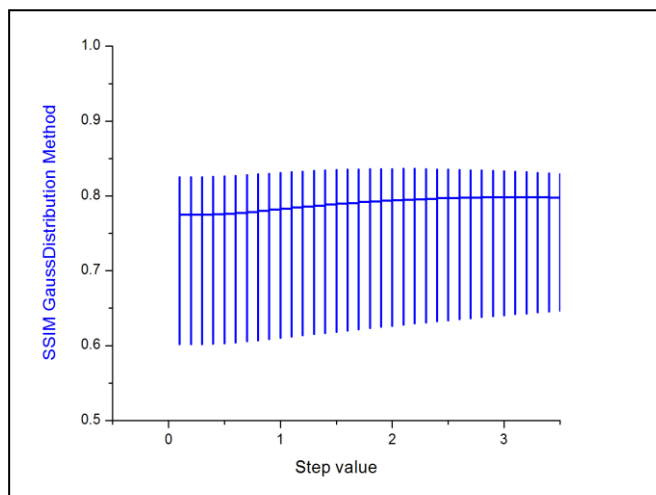
- Cele mai bune valori SSIM apar în intervale de valori a procentajului cuprins între $[0,1 - 1] \%$. Pentru acest interval dispersia indicelui SSIM în jurul valorii medii are o valoare de aproximativ 0,25 unități pentru ambele tipuri de legi de distribuție utilizate.
- Se observă că spre extremitatea intervalului a procentajului care determină intervalul de dispersie în jurul valorii medii LBP, indicele de similaritate SSIM are valori mai mici, dezavantaj care este însă compensat de un interval de dispersie a acestui indice de aproximativ 0,1 unități.

- b) Determinarea valorii constantei Gaussiene și Uniforme pentru obținerea celui mai bun indice de similaritate SSIM pentru imagini de tip clădiri

În urma analizei precedente, efectuată pentru o singură imagine de tip clădire s-a determinat că indicele maxim de similaritate SSIM se obține pentru o valoare a procentajului care determină intervalul de dispersie în jurul valorii medii LBP ca fiind de $[0.1 - 3] \%$. Utilizăm acest interval pentru analiza întregului set de imagini care reprezintă clădiri. Rezultatele sunt prezentate în Figura 5.15a pentru distribuția Uniformă, respectiv Gaussiană în Figura 5.15b.



(a)




(b)

Figura 5.15 Graficul valorii SSIM pentru setul de imagini de tip clădiri, pentru cazul unei reconstrucții a acesteia, utilizând o distribuție Uniformă (a), respectiv Gaussiană (b)


Din analiza imaginilor în care apare valoarea medie a indicelui de similaritate (reprezentată de linia continuă orizontală) și dispersia în jurul valorii medii (reprezentată de liniile verticale), se observă în ambele cazuri faptul că:

- Cele mai bune valori SSIM apar în intervale de valori a procentajului cuprins între [1 – 2] %. Pentru acest interval dispersia indicelui SSIM în jurul valorii medii, are o valoare de aproximativ 0,2 unități pentru ambele tipuri de legi de distribuție utilizate.
 - Se observă că spre extremitatea intervalului a procentajului care determină intervalul de dispersie în jurul valorii medii LBP, indicele de similaritate SSIM începe să scadă spre valori mai mici, păstrând aproximativ aceeași valoare de 0,1 pentru dispersia acestui indice.
- c) Determinarea valorii constantei Gaussiene și Uniforme pentru obținerea celui mai bun indice de similaritate SSIM pentru tot setul de imagini (ecografii, blocuri colorate, clădiri, fluturi)

Din studiile efectuate anterior a rezultat că cele mai bune rezultate se obțin dacă intervalul în care ia valori, procentul care determină intervalul de dispersie în jurul valorii medii LBP, este de [0.1 – 3] %. Acest interval va fi utilizat pentru tot setul de imagini luate împreună pentru a determina dacă această determinare este corectă în contextul existenței unei diversități de tipuri de imagini. Rezultatele obținute sunt prezentate în Figura 5.16a pentru distribuția Uniformă, respectiv Gaussiană în Figura 5.16b.



(a)



(b)

Figura 5.16 Graficul valorii SSIM pentru tot setul de imagini (ecografii, blocuri colorate, clădiri, fluturi), pentru cazul unei reconstrucții a acestora, utilizând o distribuție Uniformă (a), respectiv Gaussiană (b)

Din analiza rezultatelor furnizate de imaginile în care apare valoarea medie a indicelui de similaritate (reprezentată de linia continuă orizontală) și dispersia în jurul valorii medii (reprezentată de liniile verticale), se pot face câteva constatări:

- Pentru ambele tipuri de distribuții utilizate (uniformă, respectiv gaussiană) se poate obține un indice de similaritate SSIM foarte bun, în jur de [0,9 – 1].
- Valoarea constantei procentuale care se utilizează pentru intervalului de dispersie a valorilor LBP pentru care se obține valoarea SSIM specificată anterior se situează în intervalul [0,1 – 2]%.
- Datorită diversității tipurilor de imagini, dispersia pentru valorile SSIM este mare fiind posibilă obținerea de valori pentru acest indicator în intervalul [0,7 – 1]%. Este evident, în acest context, că valoarea constantei procentuale care se utilizează pentru intervalul de dispersie a valorilor LBP pentru care se obține valoarea SSIM, va trebui particularizată în funcție de conținutul imaginii care se comprimă.

5.3 Concluzii

În acest capitol s-au efectuat experimente prin care s-au urmărit două obiective:

- I. Determinarea legăturii care există între indexul de compresie și dimensiunea imaginii;
- II. Obținerea valorii constantei Gaussiene și Uniforme care determină mărimea intervalului de dispersie în jurul valorii LBP, pentru obținerea celui mai bun indice de similaritate SSIM.

În contextul acestor experimente care s-au întreprins, s-a utilizat câte un set de 20 de imagini care reprezintă clase de imagini diferite (ecografii, blocuri colorate, clădiri, fluturi). S-au ales aceste clase datorită diversității texturilor și a culorilor prezente în imagini, cu scopul de a avea la dispoziție o arie cât mai extinsă care să poată defini cât mai corect diversitatea lumii înconjurătoare. În urma calculelor efectuate s-au obținut următoarele concluzii:

- Compresia imaginilor este dependentă de natura informației prezente. Textura imaginii va influența procesul de compresie, aspect care impune determinarea unor criterii privind modul în care acest proces are loc. Aceste criterii se vor referi la determinarea celei mai potrivite tehnici de generare a pixelilor în jurul valorii medii LBP (distribuție Uniformă sau Gaussiană), respectiv determinarea celor mai potrivite constante care determină mărimea intervalului de dispersie în jurul valorii LBP.
- Indiferent de natura informației prezente în imagine (dată de textura acesteia de tip nuanțe de gri sau color) se poate obține un indice de similaritate SSIM bun între imaginea inițială și cea reconstruită după procesul de compresie. Acest indice poate aparține intervalului [0,7 – 1].

- Intervalul de valori în care apare indicele de similaritate SSIM specificat anterior poate fi obținut pentru o valoare a constantei procentuale care se utilizează pentru intervalul de dispersie a valorilor LBP, utilizându-se o valoare care se situează în intervalul $[0,1 - 2]$ % din valoarea medie LBP.

6. COMPRESIA IMAGINILOR DIGITALE MEDICALE STATICE. REZULTATE EXPERIMENTALE

În prezentul capitol sunt prezentate studiile și experimentele efectuate pentru compresia imaginilor medicale digitale statice. În cadrul acestui capitol s-a urmărit:

- Determinarea exactă a constantei Gaussiene și Uniforme care determină mărimea intervalului de dispersie în jurul valorii LBP;
- Stabilirea influenței pe care o prezintă cele mai utilizate formate de imagini medicale (BMP, JPG, PNG) asupra procesului de compresie.

6.1 Determinarea exactă a constantei Gaussiene și Uniforme care determină mărimea intervalului de dispersie în jurul valorii LBP

Așa cum arătat în capitolul 5, intervalul de valori în care poate fi obținut un indice de similaritate SSIM bun (intervalul este de $[0,7 - 1]$) se obține pentru o valoare a constantei procentuale, care se utilizează pentru intervalul de dispersie a valorilor LBP cuprinse în intervalul $[0,1 - 2]\%$ din valoarea medie LBP. Acest interval în care utilizatorul va trebui să aleagă o valoare, de fiecare dată când se dorește reconstrucția imaginii originale, este prea mare. Ar fi de dorit specificarea unei valori exacte a acestei constante, care să asigure automatizarea procesului de compresie și reconstrucție a imaginii medicale. De asemenea, este necesar de stabilit tipul de distribuție uniformă sau gaussiană care urmează a fi utilizat. Studiul se va efectua utilizând o bază de date de imagini ecografice care conține un număr de 6264 imagini de tip JPEG [47, 48, 50, 51].

În Figura 6.1 se prezintă caracteristicile de tip dimensiune (bytes) a imaginilor care sunt prezente în baza de date de imagini ecografice. Prelucrarea statistică s-a efectuat cu programul Origin 8. Valoarea medie a dimensiunii acestor imagini este de 109.6 Ko cu o dispersie de 40.5 Ko în jurul acestei valori. Cea mai mare imagine are o dimensiune de 230.6 Ko, iar cea mai mică de 33 Ko.

Toate imaginile din această bază de date au fost comprimate și reconstruite utilizându-se, pentru constanta procentuală a intervalului de dispersie din jurul valorii LBP, intervalul de valori intervalul $[0,1 - 2]\%$, care s-a parcurs cu un pas de 0.1 atât în cazul utilizării unei distribuții gaussiene, cât și uniforme. Se pot face următoarele constatări pentru această categorie de imagini:

- În Figura 6.2 se poate vizualiza valoarea medie a indicelui de compresie care se poate obține:
 - Valoarea medie obținută este de 3.747
 - Valoarea maximă obținută este de 4.517

- Valoarea minimă obținută este de 2.784
- În Figura 6.3a se poate vizualiza valoarea medie a indicelui de similaritate pentru cazul utilizării unei distribuții gaussiene, care este folosită pentru calculul intervalului de dispersie a valorilor LBP.
 - Valoarea medie obținută este de 0.5256
 - Valoarea minimă obținută este de 0.623
 - Valoarea maximă obținută este de 0.975
- În Figura 6.3b se poate vizualiza valoarea medie a indicelui de similaritate pentru cazul utilizării unei distribuții uniforme, care este folosită pentru calculul intervalului de dispersie a valorilor LBP.
 - Valoarea medie obținută este de 0.867
 - Valoarea minimă obținută este de 0.720
 - Valoarea maximă obținută este de 0.975

Statistics on Columns

Notes

Input Data

Descriptive Statistics

	N total	Mean	Standard Deviation	Sum	Minimum	Median	Maximum
Imagine size	6264	109670.9537	40551.65258	6.86979E8	33026	110151	230655

Extreme Values

		Index	Value
Imagine size	Highest	639	230655
		5823	230655
		3879	230655
		4095	230655
		2799	230655
Imagine size	Lowest	3691	33026
		2827	33026
		1531	33026
		1747	33026
		451	33026

Figura 6.1 Caracteristicile de tip dimensiune (bytes) a imaginilor care sunt prezente în baza de date formată din imagini ecografice

<i>Statistics on Columns</i>							
+ Notes							
+ Input Data							
- Descriptive Statistics							
	N total	Mean	Standard Deviation	Sum	Minimum	Median	Maximum
Compression index	6264	3.73843	0.308	23417.50311	2.78415	3.74763	4.51788

Figura 6.2 Valorile medii, minime respectiv maxime pentru indicele de compresie care se poate obține pentru imaginile ecografice care sunt prezente în baza de date

<i>Statistics on Columns</i>							
+ Notes							
+ Input Data							
- Descriptive Statistics							
	N total	Mean	Standard Deviation	Sum	Minimum	Median	Maximum
SSIM Gauss Distribution Method	6264	0.84207	0.05811	5274.71148	0.62341	0.85256	0.97532
- Extreme Values							
		Index	Value				
SSIM Gauss Distribution Method	Highest	116	0.97532				
		332	0.97532				
		548	0.97532				
		764	0.97522				
		980	0.97482				
	Lowest	6254	0.62341				
		6038	0.63049				
		5822	0.63794				
		6255	0.63851				
		5606	0.64481				


Figura 6.3a Valoarea medie, minimă respectiv maximă a indicelui de similaritate pentru cazul utilizării unei distribuții gaussiene care este folosită pentru calculul intervalului de dispersie a valorilor LBP

0

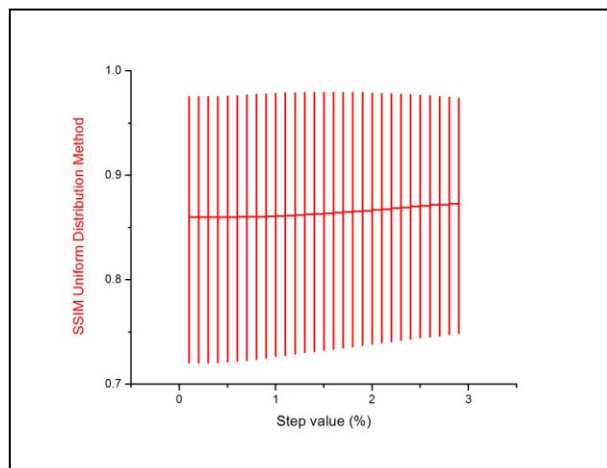
Statistics on Columns							
+ Notes							
+ Input Data							
- Descriptive Statistics							
	N total	Mean	Standard Deviation	Sum	Minimum	Median	Maximum
SSIM Uniform Distribution Method	6264	0.86775	0.05089	5435.60191	0.72089	0.86688	0.97924
- Extreme Values							
		Index	Value				
SSIM Uniform Distribution Method	Highest	3356	0.97924				
		3572	0.97921				
		3788	0.97914				
		3140	0.97914				
	Lowest	2924	0.97907				
		423	0.72089				
		207	0.72089				
		639	0.72089				
		855	0.72091				
		1071	0.72171				

Figura 6.3b Valoarea medie, minimă respectiv maximă a indicelui de similaritate pentru cazul utilizării unei distribuții uniforme, care este folosită pentru calculul intervalului de dispersie a valorilor LBP

- În graficul din Figura 6.4a și 6.4b se poate vizualiza variația indicelui de similaritate pentru cazul utilizării unei distribuții gaussiene, respectiv uniforme care este folosită pentru calculul intervalului de dispersie a valorilor LBP. Se observă că pentru o valoare de aproximativ 1, pentru constanta procentuală a intervalului de dispersie din jurul valorii LBP, se obține o valoare maximă a indicelui de similiaritate.



(a)



(b)

Figura 6.4a, 6.4b Variația indicelui de similaritate pentru cazul utilizării unei distribuții gaussiene, respectiv uniforme care este folosită pentru calculul intervalului de dispersie a valorilor LBP

Recomandarea care se poate face în urma analizei efectuate este aceea de a utiliza o valoare de 1 pentru constanta procentuală a intervalului de dispersie din jurul valorii LBP, în contextul utilizării unei distribuții uniforme a valorii pixelilor în jurul acestei valori.

6.2 Stabilirea influenței pe care o prezintă cele mai utilizate formate de imagini medicale (BMP, JPG, PNG) asupra procesului de compresie

Pentru a completa studiul privind caracteristicile pe care le prezintă procesul de compresie a imaginilor medicale statice care utilizează tehnica propusă în prezenta teză, este necesară pe lângă determinarea constantelor de compresie optime (constantă care determină mărimea intervalului de dispersie în jurul valorii LBP și tipul de distribuție utilizat pentru reconstrucția imaginii originale) este necesar de văzut cum se comportă această tehnică în funcție de formatul imaginii medicale originale. Așa cum s-a mai specificat în capitolele anterioare, cele mai utilizate formate utilizate în prezent în imagistica medicală sunt de tipul BMP, JPG respectiv PNG.

Pentru realizarea acestui studiu s-au luat în considerare un număr de 20 de imagini (radiografii) [4, 5] care au cele 3 tipuri de formate specificate anterior. În Figura 6.5. pot fi văzute două imagini din setul utilizat în cadrul acestui studiu.



Figura 6.5 Imagini radiologice reprezentative pentru setul de imagini de tip BMP, JPG, PNG

Pentru fiecare format de imagine s-au efectuat următoarele calcule:

- Studiul s-a efectuat pentru un interval de variație a constantei procentuale care determină valoarea a intervalului de dispersie de tip LBP cuprins între $[0,1 - 2]$ %, care s-a parcurs cu un pas de 0,1 atât în cazul utilizării unei distribuții gaussiene, respectiv uniforme;
- Pentru fiecare valoare a constantei procentuale care determină valoarea a intervalului de dispersie de tip LBP s-a determinat indicele de compresie și indexul de similaritate de tip SSIM pentru ambele tipuri de distribuții utilizate.

6.2.1 Stabilirea influenței pe care o prezintă formatul de tip BMP asupra procesului de compresie

Rezultatele studiului efectuat pentru această categorie de imagini sunt cele din Figura 6.6.

Statistics on Columns							
+ Notes							
+ Input Data							
- Descriptive Statistics							
	N total	Mean	Standard Deviation	Sum	Minimum	Median	Maximum
Compression index	378	3.88208	0.3224	1467.42779	3.04517	4.01347	4.3181
Constanta % a intervalului de dispersie din jurul valorii LBP	378	0.9955	0.54637	376.3	0.1	1	1.9
SSIM Uniform Distribution Method	378	0.88068	0.05641	332.89579	0.72646	0.89966	0.96094
SSIM Gauss Distribution Method	378	0.89701	0.05655	339.0715	0.72646	0.91487	0.96561

Figura 6.6 Rezultate statistice pentru imagini medicale statice de tip BMP

Rezultatele obținute conduc la următoarele constatări:

- Compresia figurii originale de tip BMP utilizând această metodă, are o valoare medie de 3,88. Acest factor poate lua valori în intervalul [3,04 – 4,31].
- Similaritatea dintre figura originală și cea comprimată este de:
 - (a) Pentru cazul utilizării unei distribuții uniforme de 0.88 cu un interval de valori cuprins între [0.72 – 0.96];
 - (b) Pentru cazul utilizării unei distribuții gaussiene de 0.89 cu un interval de valori cuprins între [0.72 – 0.96].

Este de remarcă faptul că pentru un factor de compresie egal cu 1, indexul de compresie este de 4.01 cu o valoare medie a indicelui de similaritate SSIM de 0.89 pentru cazul utilizării unei distribuții uniforme și de 0.91 pentru cazul în care se utilizează o distribuție gaussiană. Cele două valori de similaritate sunt apropiate astfel încât putem concluziona că ambele pot fi utilizate cu succes pentru comprimarea unor imagini de acest tip de format.

Recomandarea care se poate face în urma analizei imaginilor medicale a căror format este de tip BMP, este aceea de a utiliza valoarea 1 pentru constanta procentuală a intervalului de dispersie din jurul valorii LBP, în contextul utilizării unei distribuții uniforme sau gaussiene.

6.2.2 Stabilirea influenței pe care o prezintă formatul de tip JPG asupra procesului de compresie

Rezultatele studiului efectuat pentru această categorie de imagini sunt cele din Figura 6.7.

Statistics on Columns							
+ Notes							
+ Input Data							
- Descriptive Statistics							
	N total	Mean	Standard Deviation	Sum	Minimum	Median	Maximum
Compression index	379	3.54941	0.33051	1345.2269	2.981	3.59359	4.0908
Constanta % a intervalului de dispersie din jurul valorii LBP	379	1.00079	0.54895	379.3	0.1	1	1.9
SSIM Uniform Distribution Method	379	0.90887	0.04468	344.46352	0.7635	0.91246	0.96118
SSIM Gauss Distribution Method	379	0.92313	0.04633	349.86632	0.7635	0.93371	0.96736

Figura 6.7 Rezultate statistice pentru imagini medicale statice de tip JPG

Rezultatele obținute conduc la următoarele constatări:

- Compresia figurii originale de tip JPG utilizând această metodă, are o valoare medie de 3,54. Acest factor poate lua valori în intervalul [2,98 – 4,09].
- Similaritatea dintre figura originală și cea comprimată este de:
 - (a) Pentru cazul utilizării unei distribuții uniforme de 0,90 cu un interval de valori cuprins între [0,76 – 0,96];
 - (b) Pentru cazul utilizării unei distribuții gaussiene de 0,92 cu un interval de valori cuprins între [0,76 – 0,96].

Este de remarcat faptul că pentru un factor de compresie egal cu 1, indexul de compresie este de 3,59 cu o valoare medie a indicelui de similaritate SSIM de 0,91, pentru cazul utilizării unei distribuții uniforme și de 0,93 pentru cazul în care se utilizează o distribuție gaussiană. Cele două valori de similaritate sunt apropiate, astfel încât putem concluziona că ambele pot fi utilizate cu succes pentru comprimarea unor imagini de acest tip de format.

Recomandarea care se poate face în urma analizei pentru imaginile medicale a căror format este de tip JPG este aceea de a utiliza o valoare de 1 pentru constanta procentuală a intervalului de dispersie din jurul valorii LBP, în contextul utilizării unei distribuții uniforme sau gaussiene a valorii pixelilor în jurul acestei valori.

6.2.3 Stabilirea influenței pe care o prezintă formatul de tip PNG asupra procesului de compresie

Rezultatele studiului efectuat pentru această categorie de imagini sunt cele din Figura 6.8.

Statistics on Columns

Notes

Input Data

Descriptive Statistics

	N total	Mean	Standard Deviation	Sum	Minimum	Median	Maximum
Compression index	380	3.88028	0.32251	1474.50568	3.04517	3.9998	4.3181
Constanta % a intervalului de dispersie din jurul valorii LBP	380	1	0.54844	380	0.1	1	1.9
SSIM Uniform Distribution Method	380	0.88074	0.05627	334.67962	0.72646	0.89925	0.96107
SSIM Gauss Distribution Method	380	0.89723	0.05648	340.94884	0.72646	0.91535	0.96561

Figura 6.8 Rezultate statistice pentru imagini medicale statice de tip PNG

Rezultatele obținute conduc la următoarele constatări:

- Compresia imaginilor originale de tip PNG utilizând această metodă, are o valoare medie de 3.88. Acest factor poate lua valori în intervalul [3,04 – 4,31].
- Similaritatea dintre figura original și cea comprimată este de:
 - (a) Pentru cazul utilizării unei distribuții uniforme de 0,88 cu un interval de valori cuprins între [0,72 – 0,96];
 - (b) Pentru cazul utilizării unei distribuții gaussiene de 0,89 cu un interval de valori cuprins între [0,72 – 0,96].

Este de remarcat faptul că pentru un factor de compresie egal cu 1, indexul de compresie este de 3,99 cu o valoare medie a indicelui de similaritate SSIM de 0,89, pentru cazul utilizării unei distribuții uniforme și de 0.91 pentru cazul în care se utilizează o distribuție gaussiană. Cele două valori de similaritate sunt apropiate, astfel încât putem concluziona că ambele pot fi utilizate cu succes pentru comprimarea unor imagini de acest tip de format.

Recomandarea care se poate face în urma analizei pentru imaginile medicale a căror format este de tip PNG este aceea de a utiliza o valoare de 1 pentru constanta procentuală a intervalului de dispersie din jurul valorii LBP în contextul utilizării unei distribuții uniforme sau gaussiene a valorii pixelilor în jurul acestei valori.

6.2.4 Eficiența algoritmului de compresie

Pentru a determina eficiența algoritmului de compresie din punctul de vedere al mărimii imaginii comprimate funcție de tipul imaginii originale s-au reluat cele trei seturi de imagini utilizate în paragrafele anterioare și s-a determinat relația care există între dimensiunea imaginii originale și imaginea comprimată (formatul LBC). Studiul s-a efectuat pe cele 3 categorii de formate de imagini respectiv pentru BMP, JPG, PNG. Rezultatele sunt prezentate în Figura 6.9 și 6.10.

Statistics on Columns							
Notes							
Input Data							
Descriptive Statistics							
	N total	Mean	Standard Deviation	Sum	Minimum	Median	Maximum
Dimensiune Format LBC	20	92.18905	41.88088	1843.781	15.179	99.4315	140.71
Dimensiune Format BMP	20	2444.7	1094.7391	48894	248	2980	2980
Dimensiune Format JPG	20	47.7535	24.59682	955.07	8.47	43.15	96.1
Dimensiune Format PNG	20	521.63	247.91854	10432.6	86.1	555.5	853

Figura 6.9 Dimensiunea imaginilor (ko) pentru formatele BMP, JPG, PNG originale și dimensiunea imaginilor comprimate (formatul LBC)




Figura 6.10 Raportul între dimensiunea imaginilor în formatele BMP, JPG, PNG originale și dimensiunea imaginilor comprimate (formatul LBC)

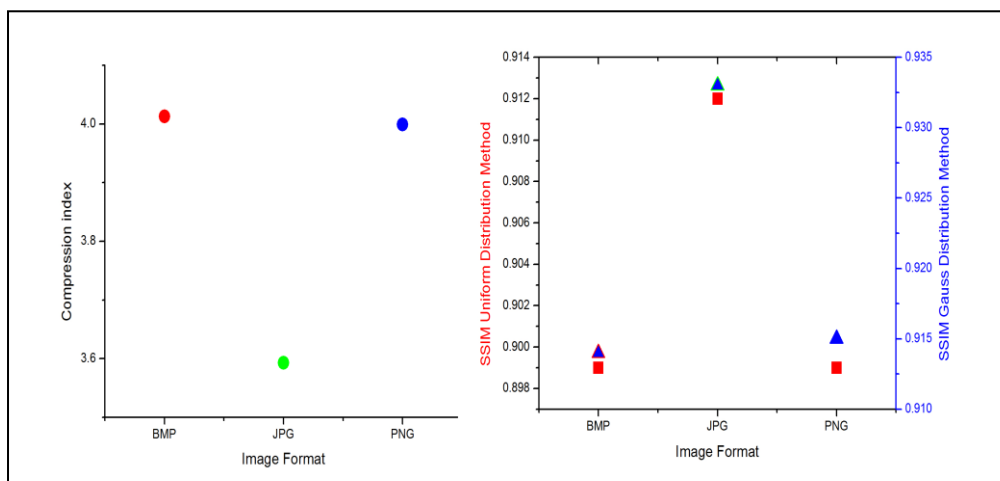
Din analiza rezultatelor obținute se poate afirma că algoritmul de compresie propus în această teză, care a condus la definirea unui nou format de imagine pe care l-am numit LBC (Local Binary Compressed), este foarte eficient pentru compresia imaginilor în format BMP și PNG. Pentru compresia imaginilor în format JPG, algoritmul de compresie conduce la obținerea unor imagini a căror format LBC are o dimensiune comparabilă cu imaginea originală.

Concluzii

Calculule efectuate anterior în acest paragraf, au avut drept scop determinarea influenței pe care o prezintă formatul imaginii medicale statice asupra procesului de compresie. Rezultatele obținute sunt prezentate în Tabelul 6.1 și Figura 6.11.

Formatul Imaginii	Indexul de compresie	SSIM-Metoda de Distribuție Uniformă	SSIM - Metoda de Distribuție Gauss
BMP	4.013	0.899	0.914
JPG	3.593	0.912	0.933
PNG	3.999	0.899	0.915

Tabel 6.1 Relația dintre formatul imaginii, factorul de compresie și indicele de similaritate



(a) (b)

Figura 6.11 Graficele relației dintre:

- (a) formatul imaginii și factorul de compresie
- (b) formatul imaginii și indicele de similaritate

Se observă că indicele de compresie este mai mic pentru formatul de tip JPG (în jur de 3,6) și mai mare pentru imaginile de tip BMP (în jur de 3,99), respectiv PNG (în jur de 4,01). Comportarea este contrară atunci când discutăm despre indicii de similaritate, astfel imaginile în format JPG prezintă cel mai mare indice de similaritate, iar imaginile în format BMP, PNG un indice de similaritate ceva mai mic. Putem considera că formatul imaginii influențează în mică măsură indicii de compresie și cel de similaritate aferent indiferent de tipul legii de distribuție utilizat la reconstrucția imaginii comprimate (uniformă sau normală).

6.3 Concluzii

În studiul efectuat s-a urmărit determinarea indicilor de performanță aferenți tehnicii de compresie a imaginilor. Testele care s-au efectuat au luat în considerare numai imagini de factură medicală, datorită faptului că tehnica de compresie propusă se adresează, în deosebi acestei categorii de imagini. Reamintim faptul că imaginile, de această factură, se caracterizează prin dimensiuni mari și texturi ale imaginii de cele mai diverse faturi, în care contrastul între zonele adiacente este mic. Indicii de performanță care s-au avut în vedere se referă la factorul de compresie și indicii de similaritate, mărimi care sunt direct influențate de determinarea exactă a constantei Gaussiene și Uniforme care stabilește mărimea intervalului de dispersie în jurul valorii LBP și a legii de distribuție care urmează să fie utilizată în procesul de reconstrucție a imaginii (uniformă sau gaussiană). De asemenea, s-a studiat dacă procesul de compresie este influențat de formatul imaginii medicale originale (BMP, JPG, PNG).

Studiul efectuat a condus la următoarele concluzii:

- Performanțele maxime pentru ansamblul de indici de performanță (factor de compresie, indice de similaritate SSIM) se obțin dacă se utilizează pentru constanta care determină mărimea intervalului de dispersie LBP, valoarea 1.
- S-a determinat că cea mai bună lege care poate fi utilizată pentru reconstrucția valorilor pixelilor este cea uniformă. Între utilizarea unei legi de distribuție uniformă și o lege de distribuție gaussiană pentru reconstrucția pixelilor, studiile efectuate au arătat că între cele două legi există deosebiri mici cu un plus de calitate (factor de compresie, indice de similaritate SSIM) pentru cazul în care se utilizează o lege de distribuție uniformă.
- Studiile efectuate au arătat ca tipul imaginii originale care este comprimată (s-au luat în considerare cele mai utilizate formate de imagini medicale - BMP, JPG, PNG) nu influențează semnificativ procesul de compresie. Se poate face însă constatarea că imaginile de tip BMP, respectiv PNG conduc la un factor de comprimare mai mare, cu o scădere a indicelui de similaritate nesemnificativă.

7. CONCLUZII ȘI CONTRIBUȚII PERSONALE

7.1 Concluzii

În cadrul cercetării întreprinse în contextul acestei teze s-a urmărit determinarea unui format de imagine nou. Acest format, se poate utiliza în special pentru reprezentarea imaginilor medicale rezultate din procesul de investigare imagistică a unui pacient. Această direcție este importantă și trebuie dezvoltată și urmărită, deoarece în prezent se generează cantități extrem de mari de imagini medicale de la cele mai diverse tipuri și proveniențe. Toate aceste imagini trebuie salvate pentru a avea o imagine de ansamblu a istoricului medical al unei persoane. Noul format care se propune încearcă să rezolve două probleme ridicate de imagistica medicală și anume:

- A. Dimensiunea imaginilor este mare pe de o parte, iar pe de altă parte numărului mare de imagini care se obțin în cursul unei singure investigații medicale. Ca urmare, formatul imaginii trebuie să prezinte o componentă de compresie care să asigure reducerea dimensiunii acesteia, atunci când imaginea se stochează pe un suport de informație.
- B. Cea de a doua problemă se referă la necesitatea de a asigura o calitate bună a imaginii medicale care să asigure corectitudinea actului medical atunci când imaginea se interpretează.

Pentru atingerea acestor două obiective s-au parcurs mai multe etape și anume:

1. S-a efectuat o analiză a caracteristicilor formatelor de imagine utilizate în prezent. În cadrul acestei analize s-a urmărit definirea caracteristicilor care sunt comune formatelor de imagine existente. Analiza s-a extins și asupra modului în care acestea sunt utilizate în imagistica medicală. De asemenea, s-a avut în vedere și efectuarea unei analize a modului în care se rezolvă stocarea imaginilor medicale corelată cu diagnosticul aferent acestora.
2. S-a realizat o sinteză a conceptului de Local Binary Pattern văzut ca un descriptor al texturii imaginii, care poate îngloba informații structurale ce definesc în mod univoc imaginea. Această sinteză a avut ca finalitate determinarea variantei de LBP care se pretează la construirea unui nou format de imagine.
3. S-a efectuat un studiu a cărei finalitate a reprezentat-o găsirea unei modalități de construire a unui format de imagine robust, care să conducă la un factor de compresie mare a imaginii, în contextul păstrării cât mai fidel a conținutului acesteia.
4. După determinarea tehnicii de construire a formatului de imagine propus, s-a trecut la efectuarea de studii privind calitatea acestui format de imagine.

Rezultatul acestui studiu s-a dorit a avea ca finalitate definirea unor criterii de calibrare a formatului în funcție de contextul în care se utilizează.

5. Efectuarea unui studiu privind oportunitatea utilizării formatului de imagine propus pentru reprezentarea imaginilor rezultate în urma unor investigații medicale imagistice.

Rezultatul cercetării care s-a efectuat de-a lungul celor 5 etape s-a finalizat prin propunerea unui format nou de imagine pe care l-am numit **LBC** (acronimul de la **L**ocal **B**inary **P**attern **C**ompressed).

Metoda presupune descrierea imaginii care se memorează și se stochează pe un suport de informație prin două imagini complementare:

- i. O imagine de **valori medii**, rezultată prin reținerea pixelului central a zonei LBP de dimensiune 3x3 pixeli, care este utilizată pentru analiza imaginii.
- ii. O imagine de tip "**dispersie**" care reprezintă valoarea LBP rezultată în urma calculului de tip LBP.

Formatul care rezultă în urma acestui proces (de tip comprimare) conduce la obținerea unei informații de sinteză care reprezintă imaginea. Această informație este utilizată la refacerea imaginii în cadrul unui proces de decomprimare. Pentru refacerea imaginii se pot utiliza două metode de generare a pixelilor din imagine. În prima metodă se poate utiliza o lege de distribuție uniformă, de generare a acestor valori, iar a doua metodă - o lege Gaussiană de distribuție. Parametrii acestor legi de distribuție sunt definiți de cele două imagini complementare care definesc imaginea comprimată.

Pentru a arăta viabilitatea acestei metode de reprezentare, în cadrul tezei s-a efectuat un studiu în capitolul 5 privind oportunitatea utilizării unei legi de distribuție uniforme sau Gaussiene. Viabilitatea a constat în compararea imaginii inițiale, existente în diverse formate JPEG, GIF, BMP și imaginea în format LBC. Pentru comparare s-a utilizat un indice de similaritate utilizat în prezent numit SSIM, indice care arată cât de asemănătoare sunt două imagini din punct de vedere al texturii, contrastului și luminanței. Aceste experimente au urmărit două obiective:

- I. Determinarea legăturii care există între indexul de compresie și dimensiunea imaginii;
- II. Obținerea valorii constantei Gaussiene și Uniforme care determină mărimea intervalului de dispersie în jurul valorii LBP, pentru obținerea celui mai bun indice de similaritate SSIM.

În contextul acestor experimente care s-au întreprins s-au utilizat imagini din baze de date medicale utilizate în prezent pentru calibrarea metodelor de investigație imagistică (*The American Institute of Ultrasound in Medicine, A digital library of radiology education resources, Medscape [49, 50, 51]*). În urma experimentelor efectuate s-au obținut următoarele concluzii:

- Compresia imaginilor este dependentă de natura informației prezente. Textura imaginii va influența procesul de compresie, aspect care impune determinarea unor criterii privind modul în care acest proces are loc. Aceste criterii se referă la determinarea celei mai potrivite tehnici de generare a pixelilor în jurul valorii medii LBP (distribuție Uniformă sau Gaussiană), respectiv determinarea celei mai potrivite constante care determină mărimea intervalului de dispersie în jurul valorii LBP.
- Indiferent de natura informației prezente în imagine (dată de textura acestuia de tip nuanțe de gri sau color) se poate obține un indice de similaritate SSIM bun între imaginea inițială și cea reconstruită după procesul de compresie. Acest indice poate aparține intervalului [0.7 – 1].
- Intervalul de valori în care apare indicele de similaritate SSIM specificat anterior poate fi obținut pentru o valoare a constantei procentuale care se utilizează pentru intervalul de dispersie a valorilor LBP, utilizându-se o valoare care se situează în intervalul [0.1 – 2] % din valoarea medie LBP.

În studiul efectuat în capitolul 6 s-au efectuat experimente cu formatul propus care au luat în considerare numai imagini de factură medicală, datorită faptului că tehnica de compresie propusă se adresează în deosebi acestei categorii de imagini. Indicii de performanță care s-au avut în vedere se referă la factorul de compresie și indicele de similaritate, mărimi care sunt direct influențate de determinarea exactă a constantei Gaussiene și Uniforme, care stabilește mărimea intervalului de dispersie în jurul valorii LBP și a legii de distribuție, care urmează să fie utilizată în procesul de reconstrucție a imaginii (uniformă sau gaussiană). De asemenea, s-a studiat dacă procesul de compresie este influențat de formatul imaginii medicale originale (BMP, JPG, PNG).

Studiul efectuat a condus la următoarele concluzii:

- Performanțele maxime pentru ansamblul de indici de performanță (factor de compresie, indice de similaritate SSIM) se obțin dacă se utilizează pentru constanta, care determină mărimea intervalului de dispersie LBP, valoarea 1.
- S-a determinat că cea mai bună lege care poate fi utilizată pentru reconstruirea valorilor pixelilor este cea uniformă. Între utilizarea unei legi de distribuție uniformă și o lege de distribuție gaussiană pentru reconstrucția pixelilor, studiile efectuate au arătat că între cele două legi există deosebiri mici cu un plus de calitate (factor de compresie, indice de similaritate SSIM) pentru cazul în care se utilizează o lege de distribuție uniformă.
- Studiile au arătat ca tipul imaginii originale care este comprimată (s-au luat în considerare cele mai utilizate formate de imagini medicale - BMP, JPG, PNG) nu influențează semnificativ procesul de compresie. Se poate face însă constatarea că imaginile de tip BMP, respectiv PNG conduc la un factor de comprimare mai mare cu o scădere a indicelui de similaritate nesemnificativă.

7.1 Contribuții personale

Contribuțiile pe care le-am adus în prezenta teză de doctorat se referă la:

1. Definirea din punct de vedere teoretic a unui format de imagine nou, original, pe care l-am numit LBC (Local Binary Compressed).
2. Efectuarea unei sinteze în cadrul căreia s-au analizat formatele de imagine utilizate în prezent în imagistică în general și în imagistica medicală în special.
3. Efectuarea unei treceri în revistă a operatorului LBP și a variantelor de utilizare a acestuia. În urma acestei sinteze, s-a definit varianta de LBP care este optimă de a fi utilizată la construirea formatului de imagine LBC propus.
4. S-a construit o aplicație care construiește formatul de imagine propus. Aplicația s-a utilizat în cadrul experimentelor de determinare a caracteristicilor funcționale a formatului dezvoltat.
5. S-au efectuat două categorii de studii în care s-a urmărit modul în care se comportă formatul LBC:
 - A. Primul set de studii a fost realizat pentru determinarea setărilor optime pentru formatul LBC. Setările determinate asigură performanțe optime pentru formatul de imagine LBC în comparație cu imaginile clasice în format JPEG, BMP etc, indiferent de tehnica imagistică care a dus la obținerea ei.
 - B. Cel de al doilea set de studii a fost realizat pentru a determina oportunitatea utilizării formatului în imagistica medicală, în care s-au utilizat baze de date de imagini medicale de referință în domeniul imagisticii medicale (*The American Institute of Ultrasound in Medicine, A digital library of radiology education resources, Medscape*)

Rezultatul celor două studii a dus la concluzia că formatul propus poate fi utilizat pentru reprezentarea imaginilor medicale asigurând o compresie considerabilă a imaginii de până la 4 ori, în condițiile unei similitudini cu imaginea medicală originală brută pe care o reprezintă de peste 96%. Din aceste considerente, formatul de imagine propus poate conduce la o micșorare considerabilă a spațiului de stocare a imaginilor în cazul general și a celor de factură medicală în special.

6. Rezultatele obținute au fost validate prin publicarea unui număr de 4 articole din care două sunt indexate ISI, iar două IEEE.

Anexe

A1.

A1.1 LBP Image Compression GUI Tool

Aplicația construiește formatul de imagine LBC propus în această teză [62, 63, 64] care s-a utilizat pentru verificarea viabilității formatului de imagine LBC, pentru diferite formate ale imaginilor inițiale și pentru diferite setări ale parametrilor de generare a acestui format.

Utilizatorul, atunci când deschide aplicația, vede următoarea interfață:

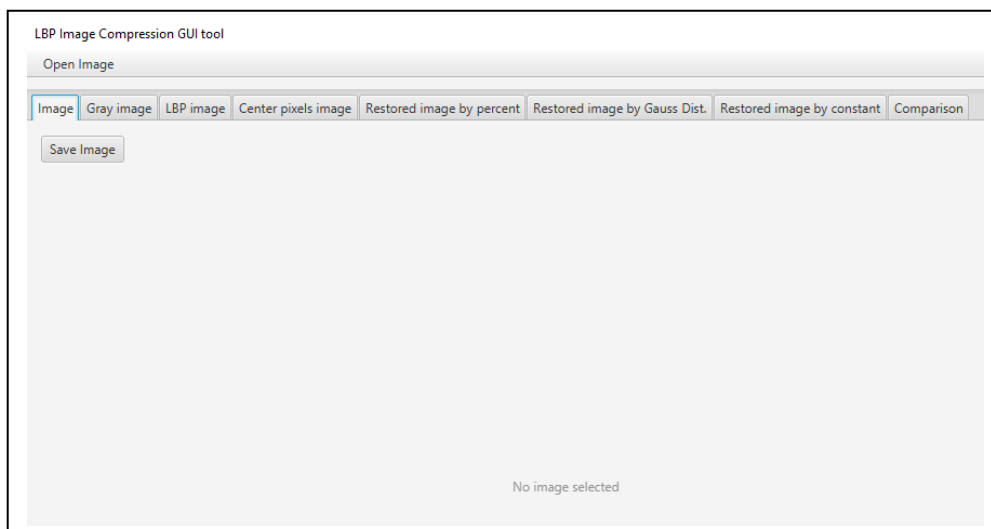


Figura A1.1 Prima pagina din aplicația LBP Image Compression

Construirea formatului LBC se face în următoarele etape:

- I. Utilizatorul selectează prin opțiunea **Open Image** o imagine pentru care se dorește construirea formatului de imagine LBC. Imaginea originală, de la care se pleacă, poate aparține oricărui din formatele de imagine cunoscute în prezent (JPEG, BMP etc.). Imaginea selectată este transformată într-o imagine grayscale care apoi este afișată utilizatorului. Pentru exemplificare, în prezenta anexă, etapele de construire a formatului LBC s-au exemplificat utilizând o imagine color a unei clădiri. S-a făcut această alegere deoarece imaginea prezintă multe detalii și culori diferite, prezentând astfel o complexitate ridicată din punctul de vedere al conținutului imagistic.


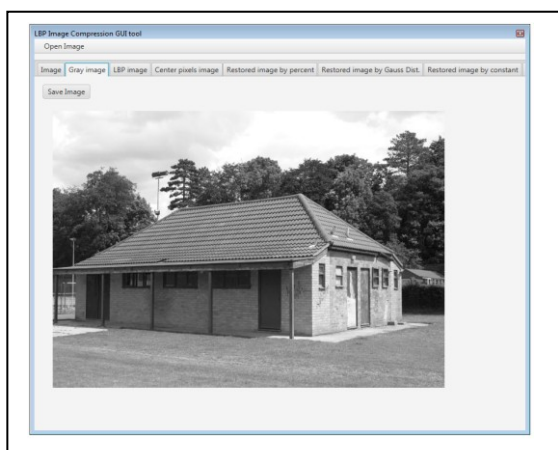


Figura A1.2

(a) Imaginea originală



(b) Imaginea grayscale transformată

II. În următoarea etapă se calculează (fără setări implicite) :

- (a) Imaginea de tip *dispersie* a imaginii luată în considerare. Aceasta reprezintă **LBP Image**, care se calculează în varianta clasică (se iau în considerare zone de dimensiune 3 x 3 pixeli).
- (b) Imagine de tip *valoare medie*. Aceasta se obține alegând opțiunea **Center pixels Image** prin intermediul căreia se rețin valorile centrale ale zonelor de dimensiune 3 x 3 pixeli care se iau în considerare.

Așa cum s-a specificat în cadrul prezentei teze, cele două imagini reprezintă împreună formatul LBC. Aceste componente, care se pot arhiva, reprezintă punctul

de plecare al reconstrucției imaginii originale, proces care se desfășoară în contextul unei etape de decompresie care este ilustrată în imaginile următoare:




Figura A1.2
(a) Imaginea de tip *dispersie*
(b) Imaginea *valoare medie*

III. În această etapă se procedează la construirea formatului de imagine LBC, format care se construiește plecându-se de la cele două informații extrase din imagine, *dispersii* și *valori medii*. Construcția formatului de imagine propus se poate efectua luând în considerare, pentru generarea valorilor pixelilor imaginii, următoarele variante pentru legile de distribuție care se pot utiliza pentru generarea valorii pixelilor imaginii în procesul de decompresie a formatului LBC propus:

- Distribuție Gaussiană
- Distribuție Uniformă
- Metoda valoare-constantă

În cadrul tezei s-au discutat numai primele două legi de distribuție utilizate în reconstrucția imaginii inițiale, plecând de la un format de imagine de tip LBC. Din acest considerent, vom exemplifica funcționarea aplicației numai pentru acestea.

Atunci când se intră în procesul de decompresie și generare a imaginii originale care a generat formatul LBC, se solicită utilizatorului să aleagă:

- legea de distribuție (Gaussiană sau Uniformă)
- mărimea intervalului de dispersie, prin specificarea unei valori procentuale care aplicându-se valorii rezultate din *imaginea valori medii* va defini mărimea intervalului în care acționează legea de distribuție, în contextul prezenței unei valori provenite din *imaginea dispersie* a formatului LBC.

Imaginea care rezultă în urma procesului de decomprimare poate fi prezentată în orice format de imagine utilizat în prezent (JPEG, BMP, etc.). De asemenea aplicația compară imaginea decomprimată cu imaginea originală din care a provenit pentru a determina acuratețea de reprezentare a formatului LBC utilizat. În acest scop se utilizează o metrică de similaritate de tip SSIM [44].

Metoda Gaussiană de generare a imaginii originale

În contextul acestei legi de distribuție se decomprimă formatul de imagine LBC utilizându-se o metodă de generare a imaginii originale în care se face apel la o distribuție normală al cărei parametru de mărime - interval dispersie este definit de utilizator.

În figura A1.3, se observă că dimensiunea intervalului de dispersie este definită de utilizator prin specificarea unei valori numerice - procent. Aceasta va defini intervalul în jurul valorii medii (asigurată de componenta valoare medie din formatul LBC) în care se aplică legea de distribuție Gaussiană. Pentru exemplul dat, utilizatorul a introdus o valoare de 1% în baza căruia a rezultat o imagine reconstruită a cărui indice de similaritate este 0,923.




Figura A1.3
Imagine obținută prin utilizare unei legi de distribuție de tip Gaussian, în care s-a utilizat un interval de dispersie de 1%

Metoda Uniformă de generare a imaginii originale

În contextul acestei legi de distribuție, se decompimă formatul de imagine LBC utilizându-se o metodă de generare a imaginii originale în care se face apel la o distribuție normală a cărei parametru de mărime - interval dispersie este definit de utilizator.

În figura A1.4, se observă că dimensiunea intervalului de dispersie este definită de utilizator prin specificarea unei valori numerice - procent. Acesta va defini intervalul în jurul valorii medii (asigurată de componenta valoare medie din formatul LBC), în care se aplică legea de distribuție Uniformă. Pentru exemplul dat, utilizatorul a introdus o valoare de 1% în baza căruia a rezultat o imagine reconstruită a căruia indice de similaritate este 0.864.

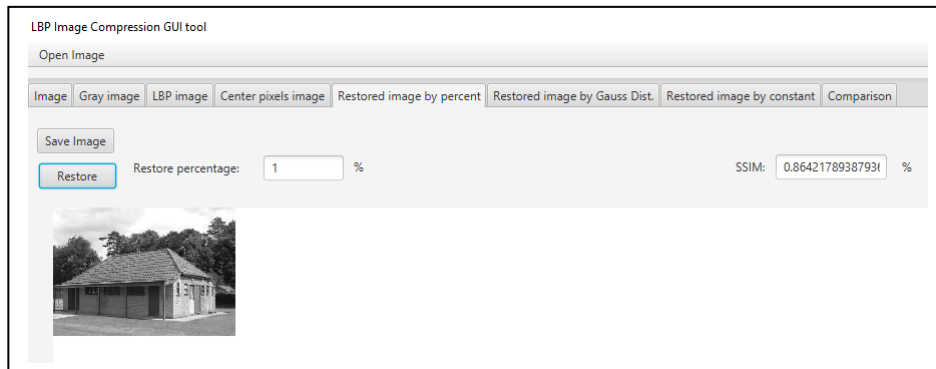


Figura A1.4
Imagine obținută prin utilizare unei legi de distribuție de tip Uniformă în care s-a utilizat un interval de dispersie de 1%

După ce imaginea în format LBC a fost generată, se poate efectua un studiu comparativ în cadrul căruia se obțin informații de sinteză privind calitatea formatului în cauză. Aceste informații se referă la indicii de compresie obținut prin raportarea la imaginea inițială de la care s-a pornit. De asemenea, se face o comparație legată de eficiența formatului raportată la unelte de arhivare de interes general ca de exemplu ZIP, ARJ și respectiv 7z. Studiul se poate face pentru fiecare din modalitățile de generare a imaginii LBC specificate anterior. În Figura A1.5 se prezintă etapa de comparare pentru determinarea indicilor de performanță a imaginii de tip LBC.

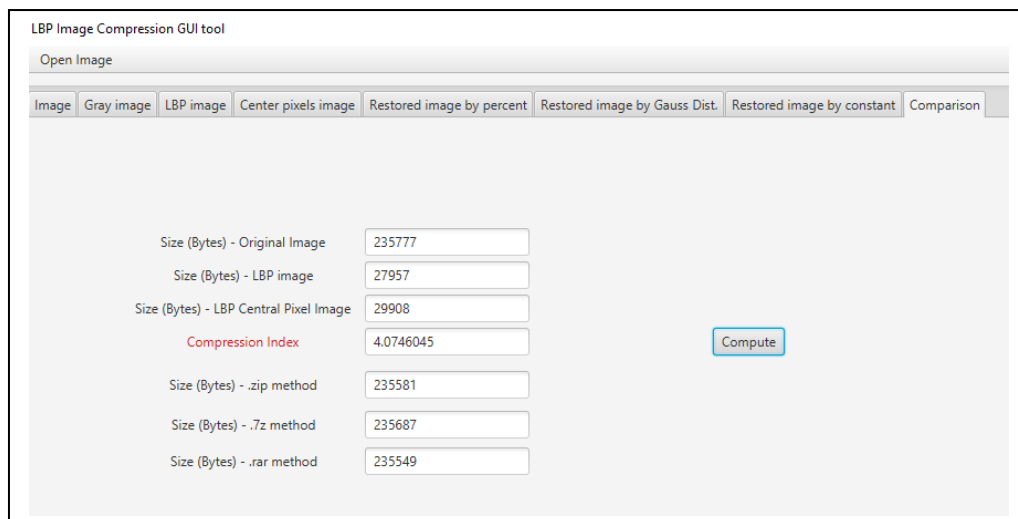


Figura A1.5
Determinarea indicilor de performanță pentru o imagine în formatul LBC.

Din imagine, se observă că formatul LBC pentru imaginea luată ca exemplu în această prezentare a funcționalității platformei de construire a formatului LBC, realizează un indice de compresie de 4.07 în raport cu imaginea de tip JPG care a stat la baza generării formatului LBC. De asemenea, sunt prezentate valorile imaginii de tip JPG care s-au comprimat cu utilitare de tip zip, arj și respectiv 7z. Se observă că mărimea formatul LBC raportat la valorile imaginii comprimate prin aceste 3 metode este foarte eficient. Practic factorul de compresie realizat este de peste 4 (uneori tinde spre 5), indiferent de metoda de arhivare utilizată.

A1.2 Aplicația de comparare pentru compresia LBP

Aplicația este destinată determinării valorii procentuale pe care urmează să o specifice utilizatorul pentru stabilirea intervalului de dispersie a pixelilor la decompimarea unei imagini în format LBC.

Aplicația are doar o singură fereastră principală, de unde utilizatorul poate:

- Aleagă o imagine sau un director întreg de imagini;
- Introduce o valoare de tip pas utilizată pentru a modifica intervalul de dispersie;
- Defini o limită superioară a valorii până unde se poate modifica valoarea de tip pas.

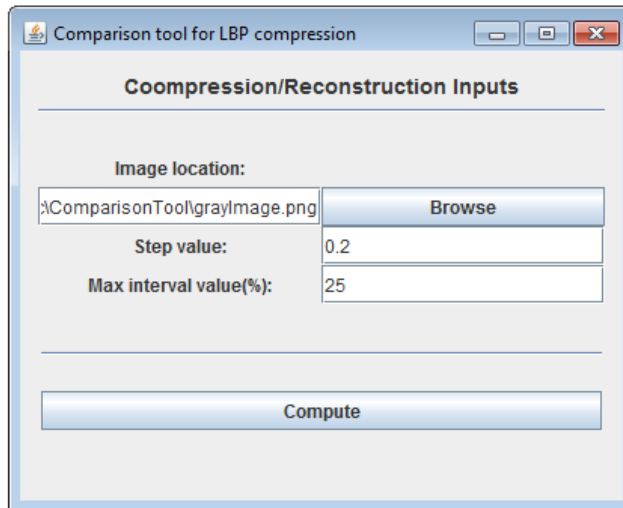


Figura A1.6 Inițializarea procesului
determinării valorii procentuale de stabilire a intervalului de dispersie a pixelilor

După ce utilizatorul a inițiat procesul de căutare prin stabilirea parametrilor procesului de căutare a valorii optime care definește intervalul de dispersie, se lansează procesul de căutare. Stadiul în care se găsește procesul de căutare este specificat printr-o bară de tip progres, Figura A1.7.





Figura A1.7
Computation
progress bar



Rezultatul calculului este un fișier cu extensia .csv, care conține tab-uri cu datele de identificare a imaginii, noua dimensiune a fișierului LBP, indicele de compresie, valoarea pas, valoarea SSIM obținută prin metoda Gauss, dimensiunea imaginii obținută prin metoda Gauss, valoarea SSIM obținută prin metoda distribuție uniformă și dimensiunea imaginii rezultată prin metoda distribuție uniformă.

	A	B	C	D	E	F	G	H	I	J	K	L
1	File name	Gray img size	New format img size	Compression Index	Step value	Const Method SSIM	Const.Method img size	Gauss Method SSIM	Gauss Method img size	Percentage Method SSIM	Percentage Method img size	
2	1	30457	4045	3.4434144	0.1	0.794758923	22068	0.794758923	22068	0.794758923	22068	
3	1	30457	4045	3.4434144	0.2	0.794758923	22068	0.794758923	22068	0.794758923	22068	
4	1	30457	4045	3.4434144	0.3	0.794758923	22068	0.79475484	22145	0.794758923	22068	
5	1	30457	4045	3.4434144	0.4	0.794758923	22068	0.795004744	22866	0.794758923	22068	
6	1	30457	4045	3.4434144	0.5	0.794758923	22068	0.795629485	24484	0.795988675	22430	
7	1	30457	4045	3.4434144	0.6	0.794758923	22068	0.79671426	26554	0.799488305	23022	
8	1	30457	4045	3.4434144	0.7	0.794758923	22068	0.797929266	28243	0.801734906	23379	
9	1	30457	4045	3.4434144	0.8	0.794758923	22068	0.799129159	29680	0.8035844	23774	
10	1	30457	4045	3.4434144	0.9	0.794758923	22068	0.800331159	30673	0.805757552	24101	
11	1	30457	4045	3.4434144	1	0.806599793	25438	0.801334727	31320	0.808226945	24412	
12	1	30457	4045	3.4434144	1.1	0.81563042	26180	0.802427816	32136	0.811179963	24699	
13	1	30457	4045	3.4434144	1.2	0.81563042	26180	0.803602522	32696	0.813245172	24950	
14	1	30457	4045	3.4434144	1.3	0.81563042	26180	0.804542118	33382	0.815368603	25159	
15	1	30457	4045	3.4434144	1.4	0.81563042	26180	0.805298516	33983	0.817318636	25306	
16	1	30457	4045	3.4434144	1.5	0.81563042	26180	0.805847133	34703	0.818669064	25474	
17	1	30457	4045	3.4434144	1.6	0.81563042	26180	0.80669739	35350	0.819754223	25618	
18	1	30457	4045	3.4434144	1.7	0.81563042	26180	0.807206187	35666	0.821153855	25773	
19	1	30457	4045	3.4434144	1.8	0.81563042	26180	0.807292671	36249	0.822236797	25857	
20	1	30457	4045	3.4434144	1.9	0.81563042	26180	0.807654641	36822	0.823308095	25973	
21	1	30457	4045	3.4434144	2	0.821270634	26085	0.807688375	37111	0.823641328	26070	
22	1	30457	4045	3.4434144	2.1	0.824552214	26480	0.807559552	37602	0.823950599	26188	
23	1	30457	4045	3.4434144	2.2	0.824552214	26480	0.807375475	38004	0.824373061	26255	
24	1	30457	4045	3.4434144	2.3	0.824552214	26480	0.807039839	38389	0.824525483	26316	
25	1	30457	4045	3.4434144	2.4	0.824552214	26480	0.806938691	38704	0.824343565	26320	
26	1	30457	4045	3.4434144	2.5	0.824552214	26480	0.806822434	39021	0.824214122	26332	
27	1	30457	4045	3.4434144	2.6	0.824552214	26480	0.806420264	39368	0.824116873	26388	
28	1	30457	4045	3.4434144	2.7	0.824552214	26480	0.806117348	39619	0.823997962	26388	
29	1	30457	4045	3.4434144	2.8	0.824552214	26480	0.804558473	39976	0.824053861	26479	

Figura A1.8 Exemplu de fișier .csv

A2

Testarea aplicației LBP Image Compression GUI Tool

În această anexă sunt prezentate testele efectuate pentru verificarea funcționalității aplicației care construiește formatul de imagine LBP prezentat în anexa A1. Acestea au constat în rularea aplicației pe mai multe tipuri de imagini și cu diferite valori pentru procentul sau dispersia folosite pentru decompimarea imaginii în format LBP [66, 68, 69].

Pentru verificarea funcționalității s-au ales ca imagini de test:

- o schiță în creion,
- o ecografie și
- o fotografie obișnuită.

Imaginile alese sunt ilustrative pentru paleta de imagini care există în prezent, acoperind din punct imagistic această diversitate de tipuri de imagini. Testele au constat din analiza vizuală a rezultatului obținut, care este subiectivă, urmată de o analiză a similarității dintre imagine originală și cea în format LBC, în care se utilizează o metodă matematică de verificare (SSIM).

Analiza VIZUALĂ

Construirea formatului LBC pentru o imagine de tip schiță în creion

Testele s-au efectuat pentru imaginea din Figura A2.1



Figura A2.1 Imagine originală grayscale – tip schiță în creion

Testele care s-au efectuat după construirea formatului de imagine LBC au constat din decompimarea acesteia utilizând o valoare de 5% pentru stabilirea dimensiunii intervalului de dispersie atât în cazul utilizării unei legi de distribuție uniformă cât și în cazul utilizării unei legi de distribuție Gaussiană. Rezultatele obținute sunt cele din Figura A2.2, respectiv A2.3.



Figura A2.2
Imagine grayscale – restaurată
cu un procent de 5 %,
distribuție uniformă



Figura A2.3
Imagine grayscale -
restaurată cu un
procent de 5 %,
distribuție Gaussiană

Prin comparare vizuală se observă că diferențele nu sunt foarte sesizabile la prima vedere. Este foarte greu de spus pentru această structură a imaginii în care sunt prezente linii subțiri și tușe de gri dacă apar distorsiuni între imaginea originală și rezultatul obținut prin restaurarea formatului LBC în contextul utilizării celor două legi de distribuție uniformă și respectiv Gaussiană.

Construirea formatului LBC pentru o imagine medicală tip ecografie

Testele s-au efectuat pentru imaginea din Figura A2.4.



Figura A2.4 Imagine originală grayscale – tip ecografie medicală

Testele care s-au efectuat după construirea formatului de imagine LBC, au constat din decompimarea acesteia, utilizând o valoare de 2% pentru stabilirea dimensiunii intervalului de dispersie atât în cazul utilizării unei legi de distribuție uniformă cât și în cazul utilizării unei legi de distribuție Gaussiană. Rezultatele obținute sunt cele din Figura A2.5 respectiv A2.6.



Figura A2.5
Imagine grayscale - restaurată cu un procent de 2%, distribuție uniformă



Figura A2.6
Imagine grayscale - restaurată cu un procent de 2%, distribuție Gaussiană

Prin comparare vizuală se observă că diferențele sesizabile la prima vedere se referă la distorsiuni minore ale conturului. Este foarte greu de spus pentru această structură a imaginii în care sunt prezente formațiuni definite prin nuanțe de gri, dacă apar distorsiuni între imaginea originală și rezultatul obținut prin

restaurarea formatului LBC în contextul utilizării celor două legi de distribuție uniformă și respectiv Gaussiană.

Construirea formatului LBC pentru o imagine fotografică obișnuită

Testele s-au efectuat pentru imaginea din Figura A2.7.




Figura A2.7 Imagine originală grayscale – tip portret

Testele care s-au efectuat după construirea formatului de imagine LBC, au constat din decompimarea acesteia, utilizând o valoare de 10%, respectiv 2% pentru stabilirea dimensiunii intervalului de dispersie, atât în cazul utilizării unei legi de distribuție uniformă, cât și în cazul utilizării unei legi de distribuție Gaussiană. Rezultatele obținute sunt cele din Figura A2.8 a, respectiv A2.10 a,b.




Figura A2.8a
Imagine grayscale - restaurată
cu un procent de 10%,
distribuție uniformă
(SSIM = 0.86019)




Figura A2.8b
Imagine grayscale - restaurată
cu un procent de 2%, distribuție
uniformă

Pentru a evidenția diferențele de pixeli dintre cele două imagini reconstituite de mai sus, acestea au fost mărite (Figura A2.9).



(a)

(b)

Figura A2.9

Detaliu Imagine grayscale - restaurată cu un procent de

(a) 10% distribuție uniformă (SSIM = 0,86019)

(b) 2% distribuție uniformă (SSIM = 0,91346)

Prin comparare vizuală se observă că diferențele sesizabile la prima vedere se referă la estompări minore ale conturului. Este foarte greu de spus pentru această structură a imaginii în care sunt prezente formațiuni definite prin nuanțe de gri, dacă apar distorsiuni între imaginea originală și rezultatul obținut (prin restaurarea formatului LBC în contextul utilizării unei legi de distribuție uniforme

pentru două cazuri în care s-au utilizat intervale de dispersie diferite de 10% respectiv 2%), care să modifice percepția vizuală.




Figura A2.10a
Imagine grayscale –
restaurată cu un procent
de 10%, distribuție Gaussiană




Figura A2.10b
Imagine grayscale –
restaurată cu un procent
de 2%, distribuție Gaussiană

Pentru a evidenția diferențele de pixeli dintre cele două imagini reconstituite de mai sus, acestea au fost mărite (Figura A2.11).



(a)

(b)

Figura A2.11



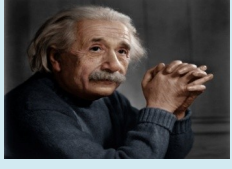

Detaliu imagine grayscale - restaurată cu un procent de
 (a) 10% distribuție Gaussiană (SSIM = 0.60194)
 (b) 2%, distribuție Gaussiană (SSIM = 0.92502)

Prin comparare vizuală se observă că diferențele sesizabile la prima vedere se referă la accentuări minore ale conturului. Este foarte greu de spus pentru această structură a imaginii în care sunt prezente formațiuni definite prin nuanțe de gri, dacă apar distorsiuni între imaginea originală și rezultatul obținut (prin restaurarea formatului LBC în contextul utilizării unei legi de distribuție uniforme pentru două cazuri în care s-au utilizat intervale de dispersie diferite de 10% respectiv 2%), care să modifice percepția vizuală.

Analiza de SIMILARITATE

A constată în verificarea corectitudinii procedurii de construire a formatului LBC, implementată în aplicația **LBP Image Compression GUI Tool**. Pentru aceasta pentru cele trei categorii de imagini analizate anterior s-a construit formatul LBC pentru diverse dimensiuni ale intervalului de dispersie care este utilizat de legile de distribuție uniforme, respectiv Gaussiene utilizate în procesul de decompresie (reconstrucție) a formatului LBC.



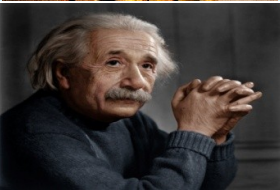

În Tabelul A2.1, în contextul utilizării unei legi de distribuție uniformă, se poate observa: cu cât procentul introdus pentru reconstituire este mai mic, cu atât similaritatea dintre imagini este mai mare. Singura excepție este schița în creion deoarece conține multe linii fine. Și în cazul acesteia, indicele trebuie să fie mai mic, dar cele mai bune rezultate se obțin în jurul valorii 5. Se observă că se poate ajunge până la un indice de similaritate maxim de aproximativ 0,96.

Procent %		25	17	12	9	6	2	
Imagine		SSIM	0.4032	0.511	0.6032	0.6702	0.7315	0.6723
	SSIM	0.5534	0.6364	0.6951	0.7353	0.7776	0.8094	
	SSIM	0.5848	0.7261	0.8231	0.8778	0.9177	0.9194	
	SSIM	0.5173	0.6547	0.767	0.8452	0.9188	0.9635	

Tabelul A2.1
Corelația existentă între natura imaginii / dimensiunea intervalului de dispersie, definită procentual și indicele de similaritate SSIM. Se utilizează o lege de distribuție uniformă.



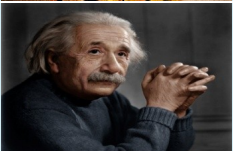

Și în Tabelul A2.2 în contextul utilizării unei legi de distribuție Gaussiene, se aplică concluziile extrase din tabelul precedent.

De asemenea, se poate deduce că în general se obțin similarități mai mari folosind metoda de reconstituire bazată pe un procent. Desigur, există și excepții precum imaginea de pe ultimul rândul din Tabelul A2.1.

Procent Imagine		25	17	12	9	6	2
	SSIM	0.4819	0.5992	0.6717	0.6984	0.6949	0.6143
	SSIM	0.3589	0.4603	0.5607	0.6396	0.7255	0.8024
	SSIM	0.2232	0.3601	0.5169	0.6489	0.7981	0.9249
	SSIM	0.2219	0.3682	0.5333	0.6654	0.8143	0.9519

Tabelul A2.2
Corelația existentă între natura imaginii / dimensiunea intervalului de dispersie, definită procentual și indicele de similaritate SSIM. Se utilizează o lege de distribuție Gaussiană.

Cel mai important rezultat al utilizării formatului LBC îl reprezintă indicele de compresie. Acesta definește raportul dintre dimensiunea imaginii originale și dimensiunea imaginii în format LBC. În Tabelul A2.3 este evidențiat cât spațiu este salvat prin această metodă de compresie.

Imagine Format JPG	Dimensiune imagine originală (KB)	Format LBC		Indice compresie
		Dimensiune imagine <i>dispersie</i> (KB)	Dimensiune imagine <i>valoare medie</i> (KB)	
	486	56	60	4.189
	7106.56	1075.2	956	3.498
	2211.84	292	320	3.614
	10188.8	1280	1228.8	4.061

Tabelul A2.3
Indicii de compresie obținuți prin utilizarea formatului de imagine LBC

Rezultatele obținute arată că similaritatea între imaginea inițială și imaginile reconstituite prin cele două metode poate ajunge și până la 0.96. În acest context, putem spune că imaginile sunt aproape identice. Prin urmare, diferențele dintre imagini sunt sesizabile doar la o analiză mai amănunțită.

Bibliografie

- [1] Data Never Sleeps 2.0, <https://www.domo.com/learn/data-never-sleeps-2> (accesat în ianuarie 2017).
- [2] 2016 Global Medical Trend Rates, http://www.aon.com/attachments/human-capital-consulting/2016_Med_Report_US_WEB.pdf, (accesat în ianuarie 2017).
- [3] Jimeng Sun, Chandan K. Reddy, Big Data Analytics for Healthcare, *SIAM International Conference on Data Mining*, Austin, TX, 2013.
- [4] Ojala T, Pietikäinen M, Harwood D., A comparative study of texture measures with classification based on featured distributions. *Pattern recognition*. 1996;29(1):51-59.
- [5] Pietikäinen M, Ojala T, Xu Z., *Rotation-invariant texture classification using feature distributions*, *Pattern Recognition*. 2000;33(1):43-52.
- [6] Pietikäinen M., *Computer vision using local binary patterns*, 1st ed. London, *Springer*, 2011.
- [7] Pietikäinen M, Hadid A, Zhao G, Ahonen T., Local binary patterns for still images. *Springer*. 2011;13-47.
- [8] Encyclopedia of Graphics File Formats. <http://www.fileformat.info/mirror/egff/> (accesat în februarie 2017).
- [9] Rosset A, Spadola L, Ratib O: OsiriX: an open-source software for navigating in multidimensional DICOM images. *J Digit Imaging* 17(3):205-16, 2004
- [10] Clunie DA: Lossless compression of grayscale medical images: effectiveness of traditional and state-of-the-art approaches. *SPIE-Medical Imaging*, 2000, pp 74-84
- [11] Bidgood Jr, WD, Horii SC, Prior FW, Van Syckle DE: Understanding and using DICOM, the data interchange standard for biomedical imaging. *J Am Med Inform Assoc* 4(3):199-212, 1997
- [12] Robb RA, Hanson DP, Karwoski RA, Larson AG, Workman EL, Stacy MC: Analyze: a comprehensive, operator-interactive software package for multidimensional medical image display and analysis, *Comput Med Imaging Graph* 13(6):433-54, 1989
- [13] ImageJ—Image processing and analysis in Java. <https://imagej.nih.gov/ij/> (accesat în iunie 2016).
- [14] Whitcher B, Schmid VJ, Thornton A: Working with the DICOM and NIFTI Data Standards in R. *Journal of Statistical Software* 44(6):1- 29, 2011
- [15] Digital Imaging and Communications in Medicine (DICOM) documentație. <http://dicom.nema.org/standard.html> (accesat în iunie 2016)
- [16] S. H. C. Ortiz, T. Chiu, M. D. Fox: „Ultrasound image enhancement: A review”, *Biomedical Signal Processing and Control*, Volume 7, Septembrie 2012, pp. 419-428
- [17] [http://www.marketwatch.ro/articol/923/Imagistica_medicala_are_un_nou_aliat - DeepEye Radiology Information System/](http://www.marketwatch.ro/articol/923/Imagistica_medicala_are_un_nou_aliat_-_DeepEye_Radiology_Information_System/) (accesat în februarie 2017)
- [18] http://www.foto-magazin.ro/tutorial_open.php?art=ftm20/archives/2007/09/formate_de_fisi.html (accesat în februarie 2017).
- [19] Bidgood WD Jr1, Horii SC., Introduction to the ACR-NEMA DICOM standard, *Radiographics*. 1992 Mar;12(2):345-55.
- [20] <http://www.radiantviewer.com/> (accesat în noiembrie 2016)

- [21] Sarojadevi H., A novel approach to improve execution time performance of Medical image processing. *Advance Computing Conference (IACC)*, 2014 IEEE pag. 725-730.
- [22] Heikkilä M, Pietikäinen M, Schmid C. Description of interest regions with local binary patterns. *Pattern recognition*. 2009;42(3):425-436.
- [23] 43. Pietikäinen M, Ojala T, Xu Z. Rotation-invariant texture classification using feature distributions. *Pattern Recognition*. 2000;33(1):43-52.
- [24] Malik M, Sulaiman S. Towards the development of an interface model for information visualization in multiple electronic health records. *Computer Medical Applications (ICCA)*, 2013 International Conference on. 2013;1-5.
- [25] T. Ojala, M. Pietikäinen, and D. Harwood, "Performance evaluation of texture measures with classification based on Kullback discrimination of distributions", *Proceedings of the 12th IAPR International Conference on Pattern Recognition (ICPR 1994)*, vol. 1, pp. 582 - 585.
- [26] Timo Ahonen, Jiří Matas, Chu He, Matti Pietikäinen, Rotation Invariant Image Description with Local Binary Pattern Histogram Fourier Features, Volume 5575 of the series *Lecture Notes in Computer Science*, Springer 2009, pp 61-70.
- [27] S. Liao ; Max W. K. Law ; Albert C. S. Chung, Dominant Local Binary Patterns for Texture Classification, *IEEE Transactions on Image Processing* (Volume: 18, Issue: 5, May 2009), pp. 1107 - 1118.
- [28] H Zhou, R Wang, C Wang, A novel extended local-binary-pattern operator for texture analysis, *Information Sciences*, Volume 178, Issue 22, 15 November 2008, Pages 4314–4325.
- [29] Fuxiang Lu, Jun Huang, An improved local binary pattern operator for texture classification, *Acoustics, Speech and Signal Processing (ICASSP)*, 2016 IEEE International Conference on, 20-25 March 2016,
- [30] L Liu, P Fieguth, Y Guo, X Wang, M Pietikäinen, Local binary features for texture classification: Taxonomy and experimental study, *Pattern Recognition* Volume 62, February 2017, Pages 135–160.
- [31] D Liu, S Wang, D Huang, G Deng, F Zeng, Medical image classification using spatial adjacent histogram based on adaptive local binary patterns, *Computers in Biology and Medicine* Volume 72, 1 May 2016, Pages 185–200.
- [32] S Yasmin, MM Rana, Performance Study of Soft Local Binary Pattern over Local Binary Pattern under Noisy Images, *International Journal of Electrical and Computer Engineering*; Yogyakarta6.3 (Jun 2016): 1161-1167.
- [33] SMH Khan, A Hussain, Content Based Image Retrieval Using Uniform Local Binary Patterns, *Proceedings of the International Conference on Data Mining, Multimedia, Image Processing and their Applications (ICDMMIPA)*, Kuala Lumpur, Malaysia, 2016, pp. 49-62.
- [34] T.Ojala, Multiresolution gray-scale and rotation invariant texture classification with local binary patterns, *IEEE Transactions On Pattern Analysis And Machine Intelligence*, Vol. 24, Issue. 7, July 2002.
- [35] P.V.N. Reddy et al., Color image retrieval using mixed binary patterns, *International Journal of Engineering Sciences Research*, Vol 4, Issue 1, 2013.
- [36] Ildikó-Angelica SZÖKE, Vasile STOICU-TIVADAR, Diana LUNGEANU., Sleep fragmentation. A study on how daily activities affect out sleeping, *Intelligent Engineering Systems (INES)*, 2015 IEEE 19th International

- Conference on 3-5 Sept 2015; Pages: 259-263, DOI: 10.1109/INES.2015.7329718
- [37] Radu Andrei ȘTEFAN, Ildikó-Angelica SZÖKE, Ștefan HOLBAN. Hierarchical clustering techniques and classification applied in Content Based Image Retrieval (CBIR), *Applied Computational Intelligence and Informatics (SACI)*, 2015 IEEE 10th Jubilee International Symposium on 21-23 May 2015; Pages: 147-52, DOI: 10.1109/SACI.2015.7208188
- [38] Ildikó-Angelica SZÖKE, Diana LUNGEANU, Ștefan HOLBAN. Image compression techniques using Local Binary Pattern, *Applied Machine Intelligence and Informatics (SAMI)*, 2015 IEEE 13th International Symposium on 22-24 January 2015; Pages 139-143, DOI: 10.1109/SAMI.2015.7061863.
- [39] Ildikó-Angelica SZÖKE, Vasile STOICU – TIVADAR, Diana LUNGEANU. A comparative study of using the LBC format for compressing medical images, *15th IEEE International Symposium on Applied Machine Intelligence and Informatics*, on 26-28 January 2017.
- [40] Hector Yee, Sumanita Pattanaik, Donald P. Greenberg, Spatiotemporal sensitivity and visual attention for efficient rendering of dynamic environments, *Journal ACM Transactions on Graphics (TOG)*, Volume 20 Issue 1, Jan. 2001, Pages 39-65, ACM New York, NY, USA.
- [41] Wang, Zhou; Bovik, A.C.; Sheikh, H.R.; Simoncelli, E.P., Image quality assessment: from error visibility to structural similarity, *IEEE Transactions on Image Processing*, 13 (4), 2004, pp. 600–612.
- [42] Dosselmann, Richard; Yang, Xue Dong ,A comprehensive assessment of the structural similarity index. *Signal, Image and Video Processing* 5 (1), 2009, pp. 81–91
- [43] Acharya T., Tsai P.S.: JPEG2000 Standard for Image Compression: Concepts, Algorithms and VLSI Architectures. *John Wiley & Sons Inc.*, New York (2005).
- [44] Zoran Kotevski, Pece Mitrevski, Experimental Comparison of PSNR and SSIM Metrics for Video Quality Estimation, *Chapter ICT Innovations 2009*, pp 357-366.
- [45] Origin 8, "Scientific graphing and data analysis software", <http://originlab.com/> (accesat decembrie 2016).
- [46] The CURET database, <http://www.cs.columbia.edu/CAVE/software/curet/> (accesat decembrie 2016).
- [47] Diagnostic Ultrasound gallery, <http://www.ultrasound-images.com/> (accesat decembrie 2016).
- [48] General Ultrasound cases, *The Gelderse Vallei Hospital, Ede*, Netherlands, <http://www.ultrasoundcases.info/> (accesat decembrie 2016).
- [49] The American Institute of Ultrasound in Medicine, <http://www.aium.org/patients/gallery.aspx> (accesat decembrie 2016).
- [50] A digital library of radiology education resources, <http://www.radiologyeducation.com/> (accesat octombrie 2016).
- [51] Medscape , <http://emedicine.medscape.com/article/366426-overview> (accesat decembrie 2016).
- [52] Robb RA, Hanson DP, Karwoski RA, Larson AG, Workman EL, Stacy MC: Analyze: a comprehensive, operator-interactive software. package for multidimensional medical image display and analysis. *Comput Med Imaging*

- Graph 13(6):433–54, 1989
- [53] NIFTI documentation. <http://nifti.nimh.nih.gov/nifti-1/documentation> (accesat in septembrie 2016)
 - [54] MINC software library and tools, <http://www.bic.mni.mcgill.ca/ServicesSoftware/MINC> (accesat în septembrie 2016).
 - [55] Bidgood Jr, WD, Horii SC, Prior FW, Van Syckle DE: Understanding and using DICOM, the data interchange standard for biomedical imaging. *J Am Med Inform Assoc* 4(3):199–212, 1997.
 - [56] Todd-Pokropek A, Craddock TD, Deconinck F: A file format for the exchange of nuclear medicine image data: a specification of Interfile version 3.3. *Nucl Med Commun* 13(9):673–99, 1992.
 - [57] Patel V, Dinov ID, Van Horn JD, Thompson PM, Toga AW: LONI MiND: metadata in NIFTI for DWI. *Neuroimage* 51(2):665–76, 2010.
 - [58] Brett M, Johnsrude IS, Owen AM: The problem of functional localization in the human brain. *Nat Rev Neurosci* 3(3):243–9, 2002.
 - [59] The NIFTI-2 header. <http://brainmap.wustl.edu/wiki/index.php/Nifti2.h> (accesat în septembrie 2016).
 - [60] Kit A. Peterson, Digital Conversion Specialist, June 2005, Introduction to Basic Measures of a Digital Image for Pictorial Collections
 - [61] [Sebastian Montabone, Beginning Digital Image Processing: Using Free Tools For Photographers, Editura „Apress”, ISBN 978-1-4302-2841-7, SUA, 2010
 - [62] <http://www.eclipse.org/documentation/> (accesat în iunie 2016).
 - [63] Majid Rabbani, Paul W. Jones, Digital Image Compression Techniques, *SPIE Optical Engineering Press*, ISBN-13 978-0819406484, SUA, 1991
 - [64] Wei-Yi Wei, An Introduction To Image Compression, *National Taiwan University, Taipei, Taiwan, ROC*.
 - [65] Photographers, Editura „Apress”, ISBN 978-1-4302-2841-7, SUA, 2010
 - [66] [Matti Peitkinen, Abdenour Hadid, Guoying Zhao, Timo Ahonen- Computer Vision Using Local Binary Patterns, *Computational Imaging and Vision*, Volume 40 Springer-Verlag London Limited 2011
 - [67] Loris Nannia, Alessandra Lumini, Sheryl Brahmam, Local binary patterns variants as texture descriptors for medical image analysis, *Artificial Intelligence in Medicine* 49 (2010).
 - [68] Hyndman, Rob J. Koehler, Anne B, Another look at measures of forecast accuracy, *International Journal of Forecasting* 679–688, 2006
 - [69] Z. Wang, A. C. Bovik, H. R. Sheikh and E. P. Simoncelli, Image quality assessment: From error visibility to structural similarity, *IEEE Transactions on Image Processing*, vol. 13, no. 4, pp. 600-612, 2004.