

Aplicații data mining în telecomunicații

Teză destinată obținerii
titlului științific de doctor inginer
la
Universitatea Politehnica Timișoara
în domeniul Inginerie Electronică, Telecomunicații și
Tehnologii Informaționale
de către

Ing. Georgiana-Alina MAGU

Președintele comisiei:	prof.univ.dr.ing. Dan LASCU
Conducător științific:	prof.univ.dr.ing. Alexandru ISAR
Referenți științifici:	prof.univ.dr.ing. Corina NAFORNIȚĂ
	prof.univ.dr.ing. Corneliu RUSU
	prof.univ.dr.ing. Romulus TEREBEȘ

30 Martie 2022

Seriile Teze de doctorat ale UPT sunt:

- | | |
|---|---|
| 1. Automatică | 11. Știința și Ingineria Materialelor |
| 2. Chimie | 12. Ingineria Sistemelor |
| 3. Energetică | 13. Inginerie Energetică |
| 4. Inginerie Chimică | 14. Calculatoare și Tehnologia Informației |
| 5. Inginerie Civilă | 15. Ingineria Materialelor |
| 6. Inginerie Electrică | 16. Inginerie și Management |
| 7. Inginerie Electronică și Telecomunicații | 17. Arhitectură |
| 8. Inginerie Industrială | 18. Inginerie Civilă și Instalații |
| 9. Inginerie mecanică | 19. Inginerie Electronică, Telecomunicații și Tehnologii Informaționale |
| 10. Știința Calculatoarelor | |

Universitatea Politehnică 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 Politehnică – Timișoara, 2021

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 Politehnică Timișoara. Toate încălcările acestor drepturi vor fi penalizate potrivit Legii române a drepturilor de autor.

România, 300223 Timișoara, Bd. Vasile Pârvan 2B
Tel./fax 0256 404677
e-mail: editura@upt.ro

Cuvânt înainte

Teza de doctorat a fost elaborată pe parcursul activității mele în cadrul Departamentului de Comunicații, Facultatea de Electronică, Telecomunicații și Tehnologii Informaționale, din cadrul Universității Politehnica Timișoara.

În primul rând, un deosebit respect și mulțumiri adresez conducătorului științific al acestei teze de doctorat prof.univ.dr.ing. Alexandru ISAR pentru încredere, profesionalism, calitatea științifică valoroasă, împărtășirea experienței domniei sale în cercetarea de top, pentru răbdarea și înțelegerea oferite de-a lungul acestei perioade, dar și multe alte lecții de viață.

Adresez mulțumiri membrilor comisiei de îndrumare pentru indicațiile oferite asupra modului de prezentare a rezultatelor obținute în cadrul tezei.

Doresc să le mulțumesc tuturor colegilor care de-a lungul timpului mi-au însoțit și călăuzit pașii, dar și prin faptul că mi-au insuflat dorința de a cunoaște și de a cerceta. În mod special doresc să adresez mulțumirile mele doamnei prof.univ.dr.ing. Corina Naforniță și domnului ș.l.univ.dr.ing. Radu Lucaciu pentru suportul moral și științific în realizarea acestei cercetări.

O prețuire nespusă o am pentru părinții mei, cei mai importanți oameni din viața mea, care întotdeauna m-au încurajat și m-au sprijinit cu tot ce le-a stat în putință să îmi urmez și realizez visele. Au fost lângă mine ori de câte ori am avut nevoie, oferindu-mi atât sprijin material, cât mai ales moral. Nu pot în cuvinte să mulțumesc pentru ce au făcut pentru mine, atât în timpul doctoratului, cât mai ales de-a lungul vieții mele de până acum. Fără ei, astăzi nu eram aici.

Timișoara, Martie, 2022

Georgiana-Alina Magu

Părinților mei...

MAGU, Georgiana-Alina

Aplicații data mining în telecomunicații

Teze de doctorat ale UPT, Seria X, Nr. YY, Editura Politehnica, 2022, 205 pagini, 80 figuri, 11 tabele.

ISSN:

ISBN:

Cuvinte cheie

Telecomunicații, data mining, prelucrarea imaginilor, senzori RADAR pentru industria auto, funcții wavelet, optimizare convexă

Rezumat

Datorită creșterii fără precedent a volumelor de date vehiculate în telecomunicații, înregistrată la începutul mileniului 3, tehnologia Data Mining este utilizată tot mai frecvent în aplicații complexe bazate pe prelucrarea imaginilor și a altor semnale provenite de la senzori (de exemplu RADAR). Obiectivul tezei de față este de a diversifica algoritmi de implementare a pașilor standardului Data Mining, propunând noi metode de prelucrare a semnalelor și imaginilor bazate pe funcții wavelet. Teza conține un număr de opt contribuții originale validate științific prin publicarea în volumele unor conferințe internaționale sau ale unor reviste de prestigiu.

CUPRINS

LISTA DE FIGURI	6
LISTA DE TABELE.....	10
Acronime	11
CAPITOLUL 1	13
INTRODUCERE.....	13
1.1. Prezentarea domeniului tezei de doctorat	13
1.2. Scopul tezei de doctorat.....	16
1.3. Conținutul tezei de doctorat.....	17
CAPITOLUL 2.....	19
UTILIZAREA FUNCȚIILOR WAVELET ÎN PRELUCRAREA IMAGINILOR.....	19
2.1. Transformări wavelet.....	19
2.1.1. Perspectivă istorică	20
2.1.2. Familii de funcții wavelet.....	21
2.1.3. Diferite tipuri de transformări wavelet.....	25
2.2. Denoising.....	42
2.2.1. Imagini digitale și zgomot	42
2.2.2. Algoritmi de denoising	43
2.2.3. Mediarea locală și ecuațiile cu derivate parțiale cu coeficienți constanți	44
2.2.4. Minimizarea variației totale.....	45
2.2.5. Filtre în domeniul frecvență	46
2.2.6. Metoda neparametrică	47
2.2.7. Metoda parametrică.....	49
2.2.8. Global sau local.....	56
2.2.9. Alte metode Bayes-iene de denoising	57
2.2.10. Algoritmul BM3D	63
2.2.11. Algoritmi de denoising folosind noi transformări derivate din transformata wavelet.....	64
2.2.12 Algoritmi de denoising bazați pe dicționare	65
2.2.13 Un nou algoritm de denoising.....	65
2.3. Compresia.....	74
2.3.1. Introducere	74
2.3.2. Compresia imaginii folosind funcții wavelet.....	75
2.4. Îmbunătățirea contrastului	95
2.4.1. Metoda de îmbunătățire a contrastului	96
2.5. Detecția muchiilor	102
2.5.1. Metode bazate pe gradient	103
2.5.2. Metode bazate pe Laplacian.....	104
2.5.3. Metoda lui Canny	107
2.5.4. Abordări pentru imagini color.....	110
2.6. Extragerea caracteristicilor și analiza componentelor principale din imagini	112
2.6.1. Metodologia de extragere a caracteristicilor.....	115

2.6.2. Implementarea PCA prin identificarea direcțiilor principale ale unei imagini folosind pachete de funcții wavelet hiperanaltice	116
CAPITOLUL 3.....	124
UTILIZARE FUNCȚIILOR WAVELET LA PRELUCRAREA SEMNALELOR RADAR	124
3.1. Introducere	124
3.1.1. Principiul de funcționare al RADAR-ului	125
3.1.2. RADAR pentru automobile.....	127
3.2. Influența zgomotului de tip clutter.....	132
3.2.1. Modele de clutter	135
3.3. Detecția țintelor cu rată de alarmă falsă constantă	136
3.3.1. Detecția	136
3.3.2. Apariția alarmei false.....	136
3.3.3. Detecția țintelor cu rată de alarmă falsă constantă	138
3.4. Urmărirea țintelor. Asocierea datelor cu țintele	157
3.4.1. Filtrul Kalman	158
3.4.2. Algoritmul maghiar de asociere a datelor	159
3.5. Îmbunătățirea performanțelor algoritmilor de urmărire a țintelor. 163	
3.5.1. Ipoteze folosite	165
3.5.2. Reducerea incertitudinii la ieșirea filtrului Kalman.....	165
CAPITOLUL 4.....	178
CONCLUZII, CONTRIBUȚII ORIGINALE ȘI PERSPECTIVE	178
Lista publicațiilor	189
BIBLIOGRAFIE	190

Lista de figuri

Figura 1. Schema bloc a unui sistem de DM în conformitate cu standardul CRISP-DM.	13
Figura 2. Autosimilaritatea fractală a uneia dintre funcțiile wavelet-mamă introdusă de Daubechies.	21
Figura 3. Un exemplu pentru familia Daubechies – funcția de scalare și funcția wavelet mamă d4 corespunzătoare.	22
Figura 4. Symlet 4 – funcția de scalare și funcția wavelet mamă corespunzătoare.	22
Figura 5. Coiflet 4 – funcția de scalare (stânga) și funcția wavelet mamă corespunzătoare (dreapta)	23
Figura 6. Bior 3.5 – funcția de scalare (stânga) φ_a și funcția wavelet mamă corespunzătoare (dreapta) ψ_a de analiză.	23
Figura 7. Bior 3.5 – funcția de scalare (stânga) φ_s și funcția wavelet mamă corespunzătoare (dreapta) ψ_s de sinteză.	23
Figura 8. Un exemplu de aplicare a procedurii de lifting: a) Perechea (φ_a, ψ_a) CDF1; b) Perechea (φ_{ns}, ψ_{ns}) rezultată în urma procedurii de lifting.	24
Figura 9. Un element al familiei Discret Meyer – funcția de scalare (stânga) și funcția wavelet mamă corespunzătoare (dreapta).	25
Figura 10. Bior 2.2-funcțiile de scalare de analiză (stânga) și sinteză (dreapta) de tip spline (de ordinul II).	25
Figura 11. Analiza timp-frecvență de tip scalogramă a semnalului de tip „chirp”: a) forma de undă a semnalului; b) reprezentarea timp-frecvență de tip scalogramă.	28
Figura 12. Acoperirea benzii ocupate de spectrul semnalului studiat cu sub-benzi.	31
Figura 13. Schema bloc pentru calculul a) DWT și b) IDWT pentru cazul funcțiilor wavelet mamă biortogonale.	33
Figura 14. Un exemplu de implementare a transformatei cu pachete de funcții wavelet (sus). Implementarea transformatei inverse (jos).	36
Figura 15. Arhitectura sistemului de calcul a transformării wavelet cu pachete hiperanalitice (HWPT).	39
Figura 16. Cele patru direcții principale a trei imagini naturale: a) Lena, b) Barbara, c) Boats; marcate cu culori diferite.	40
Figura 17. Arhitectura sistemului de denoising cu două etaje.	66
Figura 18. Compararea rezultatelor obținute $\sigma_n=30$. Prima coloană: imaginea originală; a doua coloană: imaginea zgomotoasă; a treia : rezultatul metodei propuse.	68
Figura 19. Rezultatele diferitelor metode de înlăturare a zgomotului de tip speckle aplicate unei imagini de test [96]: imaginea de testare; filtrul Lee; filtrul Kuan; algoritmului MBD; filtrul Frost și metoda propusă.	70
Figura 20. Rezultatele metodei propusă aplicate unei imagini SAR aeriene. De sus în jos și de la stânga la dreapta: imagine originală; rezultatul primului etaj de denoising; rezultatul final al denoising-ului.	71

Figura 21. Zoom, imagine originală (stânga), rezultatul primului etaj (centru) și rezultatul final (dreapta).	72
Figura 22. Rezultatele metodei propuse aplicată unei imagini SONAR: imaginea originală (sus); Rezultatul primului etaj de denoising (mijloc); rezultatul final de denoising (jos).	73
Figura 23. (a) Codarea bazată pe transformare. (b) Descompunerea în sub-benzi utilizată în standardul de compresie a amprentelor FBI.	74
Figura 24. Compresia imaginii.....	76
Figura 25. Decompresia imaginii	76
Figura 26.a) Imagine „Lena”, 8 bpp. b) Modulele coeficienților obținuți după transformata wavelet a imaginii a), cu valori mai mari decât un prag=8. c) Inversa transformării wavelet a imaginii b), PSNR=39,14 dB.	77
Figura 27. Ordinea coeficienților wavelet scanați pentru transformări pe 2 și 3 niveluri de descompunere.....	78
Figura 28. Histograma coeficienților wavelet ai imaginii „Lena”.	79
Figura 29. Primele două etape ale EZW. (a) Ordinea scanării pe 3 niveluri. (b) Transformarea wavelet pe 3 niveluri. (c) Etapa 1. (d) Etapa 2.	81
Figura 30. a) Cuantizare la sfârșitul celei de-a doua etape, MSE=48.6875. b) După rotunjire la punctele medii, MSE=39.6875, reducere cu mai mult de 18%.....	83
Figura 31. Diagrama de tranziții de stare pentru STW.	84
Figura 32. (a) Valori semnificative, sub-banda verticală de la al doilea nivel de descompunere, pragul 16. (b) Valori semnificative, sub-banda verticală de la primul nivel de descompunere, pragul 8.	87
Figura 33. a) Imagine de amprentă digitală comprimată JPEG, 0.6 biți/pixel.	89
Figura 34. Imagine de amprentă digitală comprimată WSQ, 0.6 biți/pixel.	90
Figura 35. a) interval 4x4 (negru), domeniu 8x8 (umbrit). b) sub-arborele wavelet corespunzător.	94
Figura 36. Schema bloc a metodei de îmbunătățire a contrastului propusă. L(i),L1,L2 și L(o) corespund luminanțelor de intrare, pre-procesată, îmbunătățită și respectiv de ieșire.	97
Figura 37. Regula utilizată pentru indexarea sub-imaginilor (sub-benzi) care reprezintă rezultatele HWPT cu două niveluri de descompunere.	117
Figura 38. O imagine sintetică, compusă din linii, concepută pentru a testa selectivitatea direcțională a HWPT.	118
Figura 39. Cele patru componente principale ale imaginii Lena și direcțiile corespunzătoare marcate cu linii colorate.....	120
Figura 40. Două realizări ale unui semnal aleator cu grade de netezime diferite. a) H=0.9; b) H=0.1.....	121
Figura 41. Un exemplu de imagine izotropă. Imaginea D33 din baza de date Brodatz are o valoare medie a exponentului Hurst global de 0.39.....	122
Figura 42. Un exemplu de imagine anizotropă. Imaginea D31 din baza de date Brodatz are o valoare medie a exponentului Hurst global de 0.46... ..	122
Figura 43. Schema bloc a unui stand demonstrativ pentru senzori RADAR.	125

Figura 44. Suprafețele de undă generate de o sursă omnidirecțională care se deplasează pe orizontală.....	126
Figura 45. Principiul de funcționare al unui RADAR pentru automobile....	128
Figura 46. Schema bloc a unui RADAR pentru automobile.	128
Figura 47. O comparație între frecvențele instantanee ale semnalelor emis și recepționat în cazul formei de undă sinusoidale.	129
Figura 48. Forme de undă și frecvențele instantanee corespunzătoare a două semnale de tip chirp.	130
Figura 49. O comparație a formelor de variație în timp ale frecvențelor instantanee ale semnalelor emis și recepționat în cazul unui RADAR folosit pentru estimarea distanței.	130
Figura 50. O comparație a formelor de variație în timp ale frecvențelor instantanee ale semnalelor emis și recepționat în cazul unui RADAR monopuls.....	131
Figura 51. Diagrama de procesare RADAR.	139
Figura 52. Procesorul CFAR. Estimarea puterii medii a clutter-ului.	145
Figura 53. Detectorul CA-CFAR.	146
Figura 54. Detectorul CAGO- CFAR.	147
Figura 55. Fereastra de analiză utilizată de detectoarele CA-CFAR și CAGO-CFAR.	137
Figura 56. Harta Range-Doppler pentru SNR=-30 dB.	149
Figura 57. Răspunsul distanță-viteză al detectorului OS-CFAR pentru SNR=-30 dB.	150
Figura 58. Harta Range-Doppler pentru SNR=-35 dB.	150
Figura 59. Răspunsul distanță-viteză al detectorului OS-CFAR pentru SNR=-35 dB.	151
Figura 60. Rezultatul operației de denoising a hărții Range-Doppler pentru SNR=-35 dB.....	153
Figura 61. Răspunsul distanță-viteză al detectorului W-CFAR pentru SNR=-35 dB.	153
Figura 62. Răspunsul distanță-viteză al detectorului W-CFAR pentru SNR=-35 dB, vedere de sus.....	154
Figura 63. Harta Range-Doppler pentru SNR=-40 dB.	154
Figura 64. Rezultatul operației de denoising a hărții Range-Doppler pentru SNR=-40 dB.....	155
Figura 65. Răspunsul distanță-viteză al detectorului W-CFAR pentru SNR=-40 dB, vedere de sus.....	155
Figura 66. Un exemplu de traiectorie estimată de un sistem de urmărire pe baza unui filtru Kalman.....	164
Figura 67. Drumuri din cartier lângă clădirea facultății noastre.....	164
Figura 68. Câteva cadre extrase din înregistrările video (mulțumiri Hella Timișoara).....	167
Figura 69. Scăderea incertitudinii de la ieșirea filtrelor Kalman prin potrivire polinomială implicită.....	168
Figura 70. Rezultate parțiale și finale ale primului experiment cu date simulate, a) răspândirea spațială a țintelor; b) efectul colaborării dintre	

algoritmul maghiar și filtrul Kalman; c, d) efectul metodei de potrivire polinomială explicită.....	170
Figura 71. Rezultate parțiale și finale ale celui de al doilea experiment cu date simulate: a) răspândirea spațială a țintelor; b) efectul filtrării Kalman; c), d) efectul metodei de potrivire polinomială explicită.....	171
Figura 72. Rezultate parțiale și finale ale celui de al treilea experiment cu date simulate: a) răspândirea spațială a țintelor; b) efectul filtrării Kalman; c), d) efectul metodei de potrivire polinomială explicită.....	174
Figura 73. Rezultate parțiale și finale ale unui experiment cu date simulate: a) traiectoria dorită a țintei; b) traiectoria țintei obținută la ieșirea filtrului Kalman; c) efectul metodei de potrivire polinomială bazată pe funcții wavelet.....	177
Figura 74. O imagine a interfeței grafice a aplicației OVL [283].	179
Figura 75. O reprezentare detaliată a unei regiuni din imaginea interfeței grafice a aplicației OVL. Fronturile de undă ale curentului Agulash sunt reprezentate prin curbe de culoare albă.	179
Figura 76. Imagine de tipul Single Look Complex Stripmap SAR achiziționată de unul dintre sateliții Sentinel-1 pe data de 11 martie 2015, de pe coasta Africii de Sud.	182
Figura 77. O variantă a imaginii din figura 76 obținută printr-o prelucrare de tipul multi-looking.	182
Figura 78. O comparație între imaginile de intrare a) și ieșire b) ale metodei de îmbunătățire a contrastului descrisă în paragraful 2.4.1.....	183
Figura 79. O comparație a rezultatelor a două metode de îmbunătățire a contrastului: propusă în paragraful 2.4.1 (proposed) și metoda de îmbunătățire a contrastului bazată pe egalizarea histogrammei denumită CLAHE.	184
Figura 80. a) traiectoria generată folosind datele achiziționate de senzor. b) traiectoria obținută în urma aplicării procedurii de potrivire polinomială..	188

Lista de tabele

Tabelul 1. Imaginea Lena. O comparație a rezultatelor obținute pentru metoda propusă pentru diferite valori ale abaterii standard a zgomotului..	68
Tabelul 2. Imaginea Boat. O comparație a rezultatelor obținute pentru diferite valori ale abaterii standard a zgomotului.	68
Tabelul 3. Imagine Barbara. O comparație a rezultatelor obținute pentru metoda propusă pentru diferite valori ale abaterii standard a zgomotului.	69
Tabelul 4. Imaginea Lena. Performanța PSNR [dB] a diferitelor sisteme de înlăturare a zgomotului de tip speckle bazate pe funcții wavelet.....	70
Tabelul 5. Imagine Lena. Performanța PSNR [dB] a diferitelor sisteme de înlăturare a zgomotului de tip speckle: rezultate raportate în [96]: MAP-S; SA-WBMAE, PPB, SAR-BM3D, H-BM3D; și rezultatele metodei propuse..	71
Tabelul 6. Comparația performanțelor etajelor sistemului de denoising în termeni de îmbunătățire a numărului de vederi (Enhancement of the Number of Looks-ENL).....	72
Tabelul 7. Cod pentru tranziții de stare, • indică faptul că tranziția SV → SV este sigură (deci nu este necesară codarea).	84
Tabelul 8. Corespondența între sub-benzile de detalii ale HWPT (cu două niveluri de descompunere) și orientările principale.	117
Tabelul 9. Direcții principale ale imaginii din figura 38.....	118
Tabelul 10. Comparație între funcționările a două tipuri de detector CFAR.	151
Tabelul 11. Comparație între funcționările a trei tipuri de detector CFAR.	156

Acronime

ADC	Analog-Digital Converter
ACC	Adaptive Cruise Control
ADAS	Advanced Driving Assistance Systems
ADT	Admission Discharge Transfer
AEB	Automatic Emergency Brake
AI	Artificial Intelligence
ASTF	Adaptive Soft Thresholding Filter
ASWDR	Adaptively Scanned Wavelet Difference Reduction
AWGN	Additive White Gaussian Noise
BBP	Biți pe pixel
BLS	Bayesian Least Squares
BLS-GSM	Bayesian Least Square – GSM
BM3D	Block Matching in 3 Dimensions
BSM	Blind Spot Monitoring
BP	Basis Pursuit
CA-CFAR	Cell Averaging – CFAR
CAGO-CFAR	Cell-Averaging Greatest Of-CFAR
CAN	Controller Area Network
CDWT	Complex Discrete Wavelet Transform
CE	Contrast Enhancement
CFAR	Constant False Alarm Rate
CLAHE	Contrast Limited Adaptive Histogram Equalization
CPI	Coherent Processing Interval
CRISP-DM	CRoss Industry Standard Process-Data Mining
CWT	Continuous Wavelet Transform
DCT	Discrete Cosine Transform
DEI	Despeckling Evaluation Index
DM	Data Mining
DoG	Difference of Gaussians
DTCWT	Dual-Tree Complex Wavelet Transform
DWPT	Discrete Wavelet Packet Transform
DWT	Discret Wavelet Transform
EMD	Empirical Mode Decomposition
ENL	Equivalent Number of Looks
EZW	Embedded Zerotree Wavelet
FastICA	Fast Independent Component Analysis
fBM	Fractional Brownian Motion
ICI	Inter Carrier Interference
FBI	Federal Bureau of Investigation
FCW	Forward Collision Warnings
FD	Fractal Distance
FDA	Fisher Discriminative Analysis
FFT	Fast Fourier Transform
GPS	Global Positioning System
GSM	Gauss Scales Mixtures
GSM-MPGSM	Gauss Scales Mixtures-MPGSM
HMM	Hidden Markov Model
HSL	Hue-Saturation-Lightness
HSV	Hue-Saturation-Value
HTH	Hard Thresholding

HWPT	Hyperanalytic Wavelet Packets Transform
HWT	Hyperanalytic Wavelet Transform
IDWT	Inverse Discrete Wavelet Transform
IFS	Iterated Function Systems
IHWPT	Inverse Hyperanalytic Wavelet Packets Transform
JPDA	Joint Probabilistic Data Association
JPEG	Joint Photographic Experts Group
KLLD	K Locally Learned Dictionaries
K-SVD	K-means Singular Value Decomposition
LASSO	Least Absolute Shrinkage And Selection Operator
LCA	Lane Change Assistance
LIDAR	Light Detection and Ranging
LoG	Laplacian of Gaussian
LPA	Local Polynomial Approximations
MAP	Maximum a Posteriori
MBD	Model-Based Despeckling
MHJP	Multiple Hypothesis Joint Probabilistic
ML	Machine Learning
MMSE	Minimum Mean Square Error
MPGSM	Mixtures Of Projected Gaussian Scale Mixtures
MRA	Multi Resolution Analysis
MMSG-VQ	Mean-Removed Shape-Gain Vector Quantization
MSE	Mean Squared Error
MS-KSVD	Multi Scale K-means Singular Value Decomposition
MTT	Multiple Target Tracking
MW	Mother Wavelet
NL	Number of Looks
NLM	Non-Local Means
NP	Neyman-Pearson
NP-CFAR	Neyman-Pearson – CFAR
OS-CFAR	Ordered Statistics – CFAR
OVL	Ocean Virtual Laboratory
PC	Principal Components
PCA	Principal Component Analysis
PDE	Partial Differential Equation
PDF	Probability Density Function
PMF	Positive Matrix Factorization
PPB	Probabilistic Patch-Based
PR	Perfect Reconstruction
PSNR	Peak Signal-to-Noise Ratio
PSO	Particle Swarm Optimization
RADAR	Radio Detection and Ranging
RCS	RADAR Cross Section
RFS	Random Finite Sets
RGB	Red-Green-Blue
RMSE	Root Mean Squared Error
ROI	Region of Interest

SADCT	Shape-Adaptive Discrete Cosine Transform
SAR	Synthetic Aperture Radar
SAR-BM3D	Synthetic-Aperture Radar-BM3D
SFDA	Slow Feature Discriminant Analysis
SINR	Signal to Interference plus Noise Ratio
SNR	Signal-To-Noise Ratio
SONAR	Sound Navigation and Ranging
SPIHT	Set Partitioning in Hierarchical Trees
SQS	Self-Quantized Subtrees
SQWS	Self-Quantized Wavelet Subtrees
SSH	Sea Surface Height
SSIM	Structural Similarity Index Measure
STW	Spatial Orientation Tree Wavelet
SVD	Singular Value Decomposition
SVM	Support Vector Machine
SWT	Stationary Wavelet Transform
STH	Soft Thresholding
SURE	Stein's Unbiased Risk Estimator
TV	Total Variation
UDWT	Undecimated Discrete Wavelet Transforms
VM	Vanishing Moments
VQ	Vector Quantization
WDR	Wavelet Difference Reduction
WSQ	Wavelet Scalar Quantization
2DDWT	Two Dimensional DWT

Capitolul 1

Introducere

Capitolul introductiv prezintă motivația lucrării și o scurtă schiță a tezei.

1.1. Prezentarea domeniului tezei de doctorat

Fără îndoială, una dintre caracteristicile marcante ale evoluției societății umane este explozia actuală de informații în aproape toate compartimentele acestei societăți dar mai ales în știință și în tehnologie. Această explozie este resimțită în special în domeniile de cercetare moderne, cum este de exemplu domeniul telecomunicațiilor. Explozia de informații afectează în două moduri cercetarea în telecomunicații: accelerând necesitatea rezolvării problemelor și crescând volumul de date de prelucrat. Dacă prima problemă poate fi rezolvată prin creșterea numărului echipelor de cercetare și prin cooptarea mașinilor, cu ajutorul tehnicilor de inteligență artificială (Artificial Intelligence-AI) și de învățare a mașinilor (Machine Learning-ML), un aport important la rezolvarea celei de a doua probleme îl aduce metodologia de „forare” a datelor (Data Mining-DM). DM este un domeniu de cercetare interdisciplinar care reunește tehnici de ML, recunoașterea formelor, statistică, baze de date și vizualizare, pentru a aborda extragerea de informații din baze de date foarte mari, [1].

De aceea au fost alese ca subiect al acestei teze aplicațiile DM în telecomunicații. În figura 1 este prezentată schema bloc a unui sistem DM propusă de standardul CRISP-DM [2].




Figura 1. Schema bloc a unui sistem de DM în conformitate cu standardul CRISP-DM.

Primul pas al unui proiect DM este înțelegerea aplicației pe care trebuie să o realizeze (înțelegerea problemei). Acest obiectiv este implementat iterativ, prin colaborarea cu alte faze ale proiectului, ca de exemplu faza de înțelegere a datelor sau faza de evaluare. Cel de al doilea pas al proiectului DM este înțelegerea datelor. El este bazat pe primul pas și are de asemenea o implementare iterativă. Obiectivul de înțelegere a datelor poate fi privit ca și o reacție la obiectivul de înțelegere a problemei. O primă formă de înțelegere a problemei permite o formă preliminară de înțelegere a datelor. Cu această cunoaștere dobândită, procesul de înțelegere a

problemei este îmbunătățit și drept consecință și procesul de înțelegere a datelor se îmbunătățește. Cea de a treia fază a proiectului DM este pregătirea datelor. În general, datele brute sunt afectate de imprecizii ale senzorilor și ale sistemelor de achiziție, de exemplu există date lipsă în secvențele înregistrate în bazele de date. Faza de pregătire a datelor dintr-un proiect DM presupune transformarea datelor într-o formă mai potrivită pentru următoarele faze ale proiectului. La fel ca în cazul perechii de faze compusă din faza de înțelegere a problemei și faza de înțelegere a datelor, fazele proiectului DM de pregătire a datelor și de modelare sunt interdependente. Pasul de modelare este unul dintre cele mai importante pentru un proiect DM pentru că el conduce la reprezentarea datelor într-o formă favorabilă pentru extragerea unor caracteristici utile pentru aplicația considerată. Și faza de evaluare este foarte importantă deoarece permite aprecierea calității modelului selectat. De asemenea, faza de evaluare are și o funcție de regularizare a proiectului DM, influențând prima fază a acestuia (de înțelegere a problemei). Ultimul pas al unui proiect DM constă în aprecierea performanțelor acestuia după aplicare. Baza matematică a majorității algoritmilor folosiți pentru implementarea celor șase pași ai unui proiect DM este algebra liniară [3]. Cele mai importante metode de algebra liniară folosite în DM sunt: aproximarea de medie pătratică minimă; analiza cu componente principale; analiza lineară discriminantă; indexarea semnatică latentă; sistemele de recomandare și descompunerea în valori singulare [3].

Cea mai mare cantitate de informații este primită de o persoană prin intermediul vederii sub formă de imagini. Vizualizarea este una dintre cele mai directe și preferate maniere de a observa informațiile transportate de date, care sunt adesea masive și perturbate de semnale nedorite. Pentru a dezvălui informațiile prin forare, datele trebuie să fie procesate. În acest scop, procesarea imaginii, care include multe sarcini diferite (care pot fi rezolvate de obicei cu metode de algebra liniară), cum ar fi: compresia; înlăturarea zgomotului; îmbunătățirea contrastului; detecția de muchii; segmentarea; recunoașterea modelului și clasificarea [4], a jucat un rol critic.

Dacă primele două blocuri ale schemei din figura 1 presupun participarea nemijlocită a proiectantului, fiind foarte greu de automatizat, operația de pregătire a datelor, care reprezintă sarcina celui de al treilea bloc din figura 1, poate fi automatizată. Pregătirea datelor presupune „curățirea” acestora și reducerea dimensiunii volumului de date. Curățirea datelor de tip imagine poate fi realizată prin înlăturarea zgomotului, îmbunătățirea contrastului și detecție de muchii iar reducerea volumului de date poate fi realizată prin transformare (exprimarea datelor de imagini într-un alt domeniu mai economic decât domeniul spațial) sau compresie. Și blocurile de modelare și evaluare pot fi automatizate. Există modele statistice pentru datele de tip imagine. Pentru evaluarea calității forării de date de tip imagine pot fi utilizate metode de prelucrarea imaginilor de tipul: segmentare, recunoașterea modelului sau clasificare.

Din punct de vedere istoric, la început prelucrarea imaginilor a fost văzută ca o ramură a procesării semnalului, astfel multe metode „clasice” de prelucrare digitală a imaginilor reprezintă generalizări ale unor algoritmi tradiționali de procesare a semnalului bazați pe serii sau pe transformate Fourier.

În ultimele decenii, au apărut numeroase metode noi concurente. Dintre acestea, cele bazate pe: funcții wavelet; tehnici variaționale și cu ecuații cu derivate parțiale (Partial Differential Equations-PDE) și pe metode statistice; au arătat performanțe remarcabile. De exemplu, funcțiile wavelet au devenit instrumentul dominant în procesarea imaginilor din următoarele motive. Aceste funcții asigură o bună localizare în spațiul timp-frecvență a semnalelor pe care le analizează. Datorită

faptului că implementează analize multirezoluție, funcțiile wavelet au o capacitate mare de concentrare a energiei. Aceste funcții nu corelează zgomotul alb Gaussian, iar transformatele wavelet pot fi implementate cu algoritmi rapizi. Popularitatea tehnicilor variaționale și cu PDE este determinată de calitățile lor deosebite de înțelegere și manipulare a caracteristicilor geometrice ale imaginilor.

Metodele tradiționale de procesare a imaginilor se bazează în principal pe transformări (ca de exemplu transformarea Fourier sau transformarea wavelet) sau pe abordări statistice. Cel mai bun exemplu îl reprezintă standardele internaționale actuale de compresie a imaginilor, JPEG și JPEG2000, care se bazează în mare măsură pe transformata cosinus discretă (Discrete Cosinus Transform-DCT) și respectiv pe transformata wavelet. Din acest motiv, multe imagini sunt stocate folosind coeficienții lor wavelet. Marele succes al funcțiilor wavelet în procesarea imaginilor este explicat de proprietățile lor remarcabile, în mod special de caracterul economic al transformării wavelet. Mii de cercetători și-au dedicat eforturile dezvoltării teoriei funcțiilor wavelet, analizei și concepției algoritmilor bazați pe funcții wavelet pentru diferite aplicații. Contribuțiile majore la nașterea acestei teorii includ: definiția și construcția primelor funcții wavelet ortogonale realizată de Yves Meyer [6], construcția primelor funcții wavelet ortogonale cu suport compact realizată de Ingrid Daubechies [7] și analiza multirezoluție introdusă de Stephan Mallat [8], [9]. Contribuții ulterioare importante sunt citate în cărți precum [10], [11], [12], [13], [14].

Funcțiile wavelet au fost generalizate obținându-se noi funcții generatoare pentru analize multi-rezoluție, ca de exemplu funcțiile: ridgelets [15]; curvelets [16]; beamlets [17]; sau bandelets [18]. Metodele de prelucrare bazate pe folosirea funcțiilor wavelet au fost combinate cu metode variaționale și cu PDE [19], [20], [21] pentru a le îmbunătăți performanțele, mai ales atunci când caracteristicile geometrice ale imaginilor sunt importante. Din toate aceste motive, este important studiul metodelor de prelucrare a imaginilor bazate pe funcții wavelet pentru concepția unor proiecte DM în telecomunicații.

O altă sursă importantă de date de telecomunicații este constituită de sistemele RADAR. Pe lângă datele înregistrate de sateliți în formatul imaginilor RADAR cu apertură sintetică (Synthetic Aperture Radar-SAR), un volum foarte mare de date este vehiculat și de senzorii RADAR folosiți în industria constructoare de automobile. Ritmul alert în care s-a dezvoltat această industrie aduce cu sine o serie de noi provocări în domeniile DM și ML atât pentru oamenii de știință cât și pentru ingineri. Încă de la apariția primului vehicul și până în prezent, industria constructoare de automobile a înregistrat un progres semnificativ în ceea ce privește concepția, producția și testarea vehiculelor complexe. În prezent se urmărește introducerea automobilelor autonome pentru reducerea numărului de accidente rutiere, diminuarea nivelului de stres resimțit de șoferi și asigurarea unui confort sporit pe toată durata călătoriei. Pentru a facilita tranziția către automobilul autonom, în ultimii ani s-au dezvoltat tot mai mult sistemele de asistare a șoferului. Acestea se bazează pe utilizarea unui număr din ce în ce mai mare de tipuri de senzori, ca de exemplu: RADAR, LIDAR, cu ultrasunete sau camere de luat vederi.

Informațiile de la ieșirea senzorului RADAR auto sunt adesea fuzionate cu informațiile de la ieșirile altor senzori, cum ar fi senzorul LIDAR, camera de luat vederi sau senzorii cu ultrasunete. Senzorii LIDAR [22] sunt mai preciși decât senzorii RADAR și pot contribui la îmbunătățirea capacității de discriminare și la reducerea costurilor de calcul, oferind un răspuns mai rapid. Mai mult, senzorul LIDAR este mai sensibil decât senzorul RADAR la factorii de mediu precum zăpada, ceața, praful și ploaia [23]. Atunci când se utilizează mai mulți senzori, ciclurile lor

de măsurare ar trebui sincronizate cu un ceas comun folosind marcarea orei. Observațiile de la senzori individuali pot fi atunci fuzionate pentru a forma date globale. Acestea reprezintă datele cărora li se pot aplica sisteme de DM pentru a putea extrage informațiile necesare pentru navigație: plasarea relativă a țintelor; orientarea și modelele matematice ale fiecărui senzor. Detalii despre tehnicile de fuziune ale datelor de la senzori, cum ar fi fuziunea la nivel de listă de obiecte sau la nivel de caracteristică, sunt discutate în [23] și [24]. Principalele funcționalități ale unui sistem DM de asistență a șoferului sau de conducere autonomă ar trebui să fie următoarele: detecția țintelor, urmărirea țintelor și trasarea traiectoriilor acestora, vizualizarea țintelor în timp real, clasificarea țintelor în timp real, declanșarea de alarme de avertizare sau de decizii de conducere pentru evitarea coliziunilor în timp real. Mai multe informații despre detecția obiectelor în timp real folosind algoritmi de învățare pot fi găsite în [25].

Algoritmii asociați metodelor de prelucrare a semnalelor RADAR sunt adesea verificați prin intermediul simulărilor, pentru a reduce costul prototipării și testării. În timp ce sistemele RADAR sunt simulate în amănunt, țintele și canalele luate în considerare sunt de obicei considerate ideale. Țintele sunt simulate ca obiecte cu reflectivitate perfectă și se presupune că undele electromagnetice se propagă pe căi neobstrucționate. Pentru a verifica viabilitatea diferiților algoritmi de estimare RADAR în lumea reală, ar fi necesară utilizarea unor produse software pentru propagarea undelor electromagnetice care să simuleze mai precis antenele de transmisie și recepție, suprafețele de intersecție RADAR (RADAR Cross Section-RCS) ale țintelor, canalele dintre sistemul RADAR și ținte precum și interferențele dintre ținte [26], deoarece studiile analitice evidențiază sensibilitatea redusă a sistemului RADAR în astfel de cazuri. O caracteristică suplimentară a sistemului de asistență a șoferului sau a sistemului de conducere autonomă ar putea fi includerea comunicării vehicul-vehicul [27], [28].

O modalitate de creștere a performanțelor sistemelor DM aplicate în telecomunicații, evaluate în cel de al cincilea bloc al sistemului din figura 1 este folosirea optimizării convexe la concepția subsistemelor care implementează cel de al treilea și cel de al patrulea bloc ale aceluși sistem [29].

1.2. Scopul tezei de doctorat

Lucrarea de față își propune abordarea unei teme de actualitate și să aducă contribuții la îmbunătățirea performanțelor unor metode de prelucrare a semnalelor RADAR și a imaginilor (în special de tip SAR) folosind metode de optimizare convexă și funcții wavelet. Aceste metode au fost create pentru a fi folosite la concepția unor sisteme DM care să faciliteze supravegherea unor regiuni de pe glob și studiul unor fenomene care se desfășoară la scară planetară sau să ofere asistență șoferilor de autovehicule sau să ia decizii în cazul autovehiculelor fără șofer.

Din punct de vedere științific, teza a avut următoarele obiective.

Primul obiectiv al tezei a fost diversificarea aplicațiilor funcțiilor wavelet în telecomunicații.

Cel de-al doilea obiectiv al tezei a fost îmbunătățirea performanțelor unor metode de prelucrare a imaginilor, ca de exemplu: înlăturarea zgomotului; compresia; îmbunătățirea contrastului și detecția muchiilor; folosind funcții wavelet.

Cel de-al treilea obiectiv al tezei a fost îmbunătățirea performanțelor sistemelor cu senzori RADAR auto prin perfecționarea unor metode de prelucrare a semnalelor, ca de exemplu: detecția sau urmărirea țintelor, folosind funcții wavelet.

Din punct de vedere metodologic, obiectivul principal a fost publicarea contribuțiilor științifice în reviste cu factor de impact cât mai mare precum și în actele unor conferințe internaționale cât mai bine cotate. Acceptarea acestor articole de către comitetele de lectură ale acestor reviste sau conferințe reprezintă o validare a contribuțiilor științifice realizate.

1.3. Conținutul tezei de doctorat

Capitolul 1 reprezintă sinteza lucrării de doctorat și prezintă conținutul acesteia.

În capitolul 2 se face o trecere în revistă a teoriei funcțiilor wavelet în prelucrarea imaginilor, introducându-se principalele familii de funcții wavelet și diferite tipuri de transformare wavelet: continuă, discretă, staționară, complexă cu arbore dublu, analitică (hiperanalitică, Hyperanalytic Wavelet Transform-HWT) sau cu pachete de funcții wavelet. **Se formulează o primă contribuție a tezei în legătură cu interpretarea transformării cu pachete de funcții wavelet hiperanalitice ca o analiză în componente principale a imaginii. Această transformare originală a fost publicată într-o lucrare de conferință indexată ISI:**

G. A. Magu, M. Kovaci, „Images’ Principal Component Analysis using Hyperanalytic Wavelet Packets”, 2018 International Symposium on Electronics and Telecommunications (ISETC), 1-4.

De asemenea, se prezintă principalele aplicații ale funcțiilor wavelet în prelucrarea imaginilor: înlăturarea zgomotului (denoising), compresie, îmbunătățirea contrastului, detecția de muchii și evaluarea gradului de netezime a unor suprafețe din imagine cu ajutorul valorilor locale ale exponentului Hurst.

Cea de-a doua contribuție a tezei se referă la o nouă metodă de înlăturare a zgomotului aditiv alb Gaussian din imaginile naturale respectiv a zgomotului de tip speckle din imaginile SAR, bazată pe HWT.

Cea de-a treia contribuție originală a tezei constă într-o metodă robustă (la zgomotul aditiv alb Gaussian respectiv la zgomotul de tip speckle) de detecție a muchiilor din imaginile naturale respectiv din imaginile SAR care constă în aplicarea detectorului Canny după metoda de înlăturare a zgomotului care constituie cea de-a doua contribuție. Aceste două metode și rezultatele de simulare aferente au fost publicate într-un articol dintr-o revistă indexată ISI Q1:

A. Isar, C. Nafornita, G. Magu, „Hyperanalytic Wavelet-Based Robust Edge Detection”, Remote Sensing 13 (15), 2888.

Cea de-a patra contribuție a tezei se referă la evaluarea gradului de netezime a unor suprafețe din imagini. Deoarece gradul de netezime al unei suprafețe într-o anumită regiune poate fi evaluat prin estimarea exponentului Hurst local și deoarece estimarea exponentului Hurst local poate fi realizată cu ajutorul funcțiilor wavelet, cea de a patra contribuție a tezei constă într-o metodă de generare a unor texturi cu exponent Hurst specificat. Această metodă de generare poate fi folosită pentru calibrarea metodelor de evaluare a gradului de rugozitate a unei regiuni. Validarea științifică a acestei metode a fost făcută prin publicarea unui articol indexat BDI:

P. Gajitzki, A. Isar, G. Magu, „A New Algorithm for Fractional Brownian Motion Processes Generation”, Acta Technica Napocensis 59 (1), 6-9.

Capitolul 3 al tezei de față este destinat studiului metodelor de prelucrare a semnalelor generate de senzorii RADAR. Se prezintă metodele de detecție a țintelor cu rată de alarmă falsă constantă (Constant False Alarm Rate-CFAR) și se studiază metodele de urmărire a țintelor.

Cea de-a cincea contribuție a tezei constă într-o metodă de detecție a țintelor cu raport semnal pe zgomot foarte mic bazată pe funcții wavelet. Validarea științifică a acestei contribuții a fost făcută prin publicarea la o conferință internațională indexată ISI a lucrării:

A. Isar, C. Nafornita, A. Macaveiu, G. Magu, „Wavelet Based Adaptive Detection of Automotive Radar Single Target with Low SNR”, 2020 International Symposium on Electronics and Telecommunications (ISETC), 1-6.

Cea de-a șasea, de-a șaptea și de-a opta contribuție a tezei constau în metode de reducere a incertitudinii metodelor de urmărire a țintelor bazate pe potrivirea polinomială implicită, explicită respectiv bazată pe funcții wavelet, care au fost validate științific prin publicarea a două lucrări la conferințe internaționale indexate ISI:

G. Magu, R. Lucaciu, A. Isar, „Polynomial Based Kalman Filter Result Fitting to Data”, 2020, 43rd International Conference on Telecommunications and Signal Processing, Milano, Italy

și

G. Magu, R. Lucaciu, „Multiple Radar Targets Tracking and Trajectories Fitting”, 2020 International Symposium on Electronics and Telecommunications (ISETC), 11-14,

precum și a unui articol într-o revistă indexată ISI Q2:

G. Magu, R. Lucaciu, A. Isar, „Improving the Targets’ Trajectories Estimated by an Automotive RADAR Sensor Using Polynomial Fitting”, Applied Sciences, 11 (1), 361.

Capitolul 4 este destinat concluziilor și prezentării contribuțiilor științifice ale autoarei tezei.

Capitolul 2

UTILIZAREA FUNCȚIILOR WAVELET ÎN PRELUCRAREA IMAGINILOR

2.1. Transformări wavelet

Transformata wavelet este un instrument care realizează analiza spectrală evolutivă (în timpul derulării semnalului). Acest tip de analiză spectrală are avantaje asupra metodelor tradiționale de analiză spectrală (Fourier) în cazul semnalelor care conțin discontinuități și vârfuri ascuțite. Funcțiile wavelet au fost dezvoltate independent în domeniile matematică, fizică cuantică, electrotehnică și geologie seismică. În ultimii ani, interacțiunile dintre aceste domenii au condus la multe aplicații noi, cum ar fi compresia imaginii, analiza tulburenței, viziunea umană, RADAR-ul și predicția cutremurelor.

Ideea fundamentală din spatele funcțiilor wavelet este analiza în funcție de scară. Unii cercetători ai acestui domeniu consideră că, prin utilizarea funcțiilor wavelet, se adoptă o mentalitate sau o perspectivă complet nouă în prelucrarea datelor.

Funcțiile wavelet îndeplinesc anumite cerințe matematice și sunt utilizate în reprezentarea datelor. Această idee nu este nouă, descompunerea funcțiilor fiind practică încă de la începutul anilor 1800, când Joseph Fourier a descoperit că poate folosi sinusul și cosinusul pentru reprezentarea altor funcții. Cu toate acestea, în analiza wavelet, scara pe care o folosim pentru a reprezenta datele joacă un rol important. Algoritmii wavelet prelucrează date la diferite scări sau rezoluții. De exemplu, dacă privim un semnal într-o „fereastră” largă, observăm caracteristici brute. Dacă ne uităm la același semnal într-o „fereastră” îngustă, observăm detalii. Cu alte cuvinte, rezultatul analizei wavelet este de a vedea atât „pădurea” cât și „copacii”.

Acest lucru face ca funcțiile wavelet să fie interesante și folositoare. De mai multe decenii, oamenii de știință și-au dorit funcții mai adecvate pentru descompunere decât sinusurile și cosinusurile, care constituie bazele analizei Fourier. Procedura de analiză wavelet este de a adopta o funcție wavelet prototip, numită funcție wavelet mamă și de a genera funcții wavelet prin scalarea și translația cu întregi a funcției prototip. Analiza se realizează cu versiuni contractate și dilatate ale funcției wavelet mamă. La ora actuală există numeroase funcții wavelet mamă prin a căror scalare și translație cu întregi se obțin baze ortonormale ale spațiului semnalelor de energie finită. Orice semnal de energie finită poate fi descompus în serie folosind aceste baze.

Deoarece semnalul original poate fi descompus într-o serie de funcții wavelet în care funcțiile wavelet sunt ponderate cu așa numiții coeficienți wavelet, operațiile care se dorește a fi efectuate asupra semnalului pot fi efectuate asupra coeficienților wavelet corespunzători. Dacă se alege cea mai bună funcție wavelet mamă pentru reprezentarea semnalului respectiv (cea care conduce la un număr minim de coeficienți wavelet nenuli) și dacă se nelijează coeficienții mai mici decât

un prag impus, se obține o reprezentare economică (sparse) a semnalului considerat. Această proprietate de codificare „rară”, face din funcțiile wavelet un instrument excelent în domeniul compresiei datelor.

2.1.1. Perspectivă istorică

În istoria matematicii, analiza wavelet are mai multe origini [30]. O mare parte din muncă a fost efectuată în anii 1930, și, la vremea respectivă, eforturile separate nu păreau să facă parte dintr-o teorie coerentă.

Înainte de 1930, principală ramură a matematicii care putea avea legătură cu funcțiile wavelet era analiza armonică. Dezvoltarea analizei armonice a început cu Joseph Fourier (1807) care a pus bazele analizei de frecvență (analiza spectrală), denumită acum analiză Fourier. El a afirmat că orice funcție, $f(x)$, periodică de perioadă 2π poate fi descompusă într-o serie Fourier trigonometrică:

$$a_0 + \sum_{k=1}^{\infty} (a_k \cos kx + b_k \sin kx) \quad (2.1)$$

Coeficienții a_0 , a_k și b_k sunt calculați prin:

$$a_0 = \frac{1}{2\pi} \int_0^{2\pi} f(x) dx, \quad a_k = \frac{1}{\pi} \int_0^{2\pi} f(x) \cos(kx) dx, \quad b_k = \frac{1}{\pi} \int_0^{2\pi} f(x) \sin(kx) dx \quad (2.2)$$

Afirmația lui Fourier a jucat un rol esențial în evoluția ideilor matematicienilor despre funcții. El a deschis ușa către un nou univers funcțional.

După 1807, explorând semnificația funcțiilor, convergența seriei Fourier, sistemele ortogonale, matematicienii au trecut treptat de la analiza de frecvență la analiza de scară. Prima mențiune despre funcții wavelet a apărut într-o anexă la teza lui A. Haar (1909). Prima proprietate a funcțiilor wavelet remarcată de Haar este că aceste funcții au suport compact, ceea ce înseamnă că sunt identic nule în afara unui interval de lungime finită. Din păcate, funcțiile wavelet propuse de Haar nu sunt diferențiabile, ceea ce duce la limitarea aplicațiilor lor.

În anii 1930, mai multe grupuri care lucrau independent au cercetat reprezentarea funcțiilor folosind funcții de bază de scară variabilă. Înțelegerea conceptului de funcție de bază de scară variabilă este esențial pentru înțelegerea funcțiilor wavelet. Folosind o funcție de bază cu scară variabilă, numită funcția de bază a lui Haar, Paul Levy, un fizician, a investigat mișcarea Browniană, un tip de semnal aleator [11], în anul 1930. El a găsit funcția de bază a lui Haar superioară funcțiilor bazei Fourier pentru studierea detaliilor fine ale mișcării Browniene.

Un alt efort de cercetare din anii 1930 a fost realizat de Littlewood, Paley și Stein în legătură cu calculul energiei funcției $f(x)$ folosind descompunerea acesteia în serie:

$$\text{energia} = \frac{1}{2} \int_0^{2\pi} |f(x)|^2 dx \quad (2.3)$$

Calculul a produs rezultate diferite, dacă energia a fost concentrată în jurul câtorva puncte sau distribuită pe un interval mai larg. Acest rezultat i-a deranjat pe oamenii de știință, deoarece indică faptul că energia nu ar putea fi conservată. Cercetătorii au descoperit o funcție care poate genera o bază ortonormală a spațiului semnalelor de energie finită prin scalare și translație cu întregi și poate conserva energia. Munca lor i-a oferit lui David Marr prilejul de a concepe un algoritm eficient pentru procesarea numerică a imaginilor folosind funcții wavelet.

În 1985, Stephane Mallat a produs un salt în teoria funcțiilor wavelet găsiind numeroase aplicații în prelucrarea semnalelor digitale. El a descoperit unele relații între filtrele conjugate și oglindite în cuadratură, algoritmi piramidali și bazele ortonormate. Inspirat de aceste rezultate, Yves Meyer a construit primele funcții wavelet ne-banale. Spre deosebire de funcțiile wavelet ale lui Haar, funcțiile wavelet introduse de Meyer [30] sunt continuu diferențiabile dar nu au suport compact. Câțiva ani mai târziu, Ingrid Daubechies a folosit lucrarea lui Mallat pentru a construi un set de funcții de bază ortonormale care sunt poate cele mai elegante, și au devenit piatra de temelie a aplicațiilor de tip wavelet.

Un lucru important de reținut este că dezvoltarea unui semnal în serii de funcții wavelet nu este unică, ca și dezvoltarea în serie Fourier, care utilizează doar funcțiile sinus și cosinus pentru generarea bazei ortonormale. Există un set mult mai larg de funcții de bază. Diferitele familii de funcții wavelet mamă fac diferența între cât de compact sunt localizate funcțiile de bază în spațiul timp frecvență și cât de netede sunt acestea.

Unele baze de funcții wavelet au structură fractală. Familia de funcții wavelet mamă propusă de Daubechies este un exemplu (figura 2).




Figura 2. Autosimilaritatea fractală a uneia dintre funcțiile wavelet-mamă introdusă de Daubechies.

În cadrul fiecărei familii de funcții wavelet (cum ar fi familia Daubechies) se află subclasele de funcții wavelet cu un anumit număr de momente nule. O funcție wavelet mamă, $\psi(t)$ are r momente nule dacă:

$$\int_{-\infty}^{\infty} t^k \psi(t) dt = 0; 0 \leq k \leq r \quad (2.4)$$

2.1.2. Familii de funcții wavelet

a) Familia Daubechies (,db')

Familia de funcții wavelet Daubechies conține funcții wavelet mamă cu suport compact prin a căror scalare și translație se obțin baze ortonormale ale spațiului funcțiilor de energie finită care pot fi folosite pentru calculul unei

transformate wavelet discretă [11]. Elementele familiei Daubechies se diferențiază prin numărul de momente nule. Asociată cu fiecare tip de funcție wavelet mamă, ce aparține acestei familii, există o funcție de scalare (numită „funcție wavelet tată”) care generează o analiză multirezoluție ortogonală. Funcțiile wavelet mamă de tip Daubechies au suport compact de lungime minimă. Din acest motiv, cu excepția funcției wavelet de tip Haar, funcțiile wavelet mamă de tip Daubechies nu sunt simetrice.

Funcțiile wavelet mamă din familia Daubechies se indexează după numărul de coeficienți ai filtrului digital care le generează: D2-D20, respectiv prin numărul de momente nule d1-d10. De exemplu, D2/d1 (funcția wavelet mamă de tip Haar) are un moment nul, D4/d2 are două momente nule, etc.




Figura 3. Un exemplu pentru familia Daubechies – funcția de scalare și funcția wavelet mamă d4 corespunzătoare.

b) Familia Symlet (,sym')

Această familie de funcții wavelet este o versiune modificată a familiei Daubechies cu scopul de a crește simetria formelor de undă ale funcțiilor wavelet mamă. Suporturile acestor funcții sunt compacte, dar lungimea acestor suporturi nu mai este minimă.




Figura 4. Symlet 4 – funcția de scalare și funcția wavelet mamă corespunzătoare.

c) Familia Coiflet(,coif')

Această familie a fost concepută de Ingrid Daubechies ca un omagiu adus lui Ronald Coifman din dorința de a crește localizarea în domeniul frecvență a funcțiilor wavelet mamă. Funcțiile wavelet mamă de tip Coiflet sunt aproape simetrice, având $N/3$ momente nule, unde N reprezintă numărul de coeficienți ai filtrului digital care generează respectiva funcție wavelet mamă.




Figura 5. Coiflet 4 – funcția de scalare (stânga) și funcția wavelet mamă corespunzătoare (dreapta)

d) Familii biortogonale; funcția wavelet mamă biortogonală 3.5 (bior 3.5')

În cazul familiilor biortogonale există două perechi de funcție de scară-funcție wavelet mamă, o pereche pentru analiză și o pereche pentru sinteză. Această familie de funcții wavelet permite folosirea unor grade de libertate suplimentare. De exemplu, pot fi construite funcții wavelet simetrice. În acest caz vom discuta despre două funcții de scalare φ_a și φ_s . Aceste două funcții generează două funcții wavelet diferite ψ_a și ψ_s .




Figura 6. Bior 3.5 – funcția de scalare (stânga) φ_a și funcția wavelet mamă corespunzătoare (dreapta) ψ_a de analiză.




Figura 7. Bior 3.5 – funcția de scalare (stânga) φ_s și funcția wavelet mamă corespunzătoare (dreapta) ψ_s de sinteză.

e) Familii obținute prin lifting

Wim Swelden [13] a diversificat familia funcțiilor wavelet biortogonale printr-un procedeu pe care l-a numit lifting. Pornind de la o pereche funcție de scalare-funcție wavelet mamă de analiză (φ_a, ψ_a) și de la o pereche funcție de scalare-funcție wavelet mamă de sinteză (φ_s, ψ_s) precum și de la o secvență $l[k]$, pe baza procedurii de lifting, se pot construi noi perechi funcție de scalare-funcție wavelet mamă de analiză (φ_{na}, ψ_{na}) și de sinteză (φ_{ns}, ψ_{ns}). De exemplu, în figura 8a) se prezintă perechea funcție de scalare funcție wavelet mamă de analiză propusă de Cohen, Daubechies și Fauveau CDF1 iar în figura 8b) se prezintă perechea funcție de scalare funcție wavelet mamă de sinteză rezultată în urma aplicării procedurii de lifting.

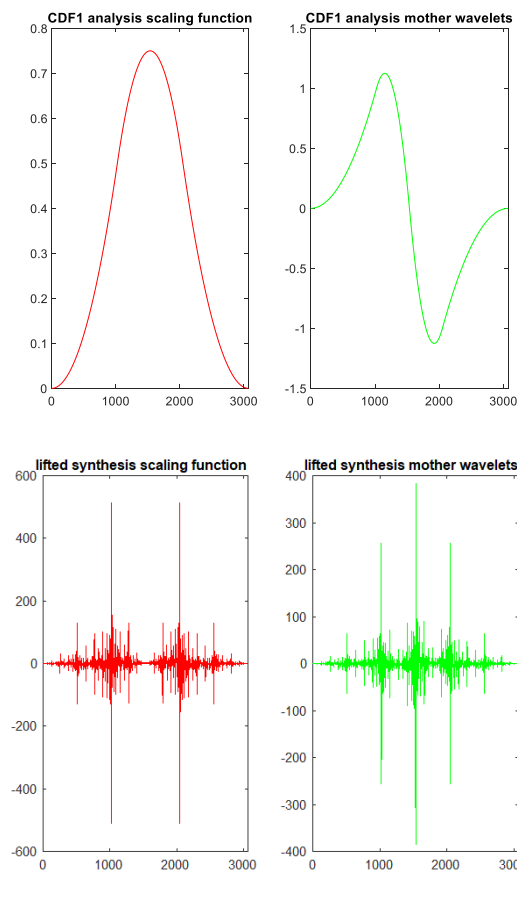


Figura 8. Un exemplu de aplicare a procedurii de lifting: a) Perechea (φ_a, ψ_a) CDF1; b) Perechea (φ_{ns}, ψ_{ns}) rezultată în urma procedurii de lifting

f) Familia Discrete Meyer ('dmey')

Apare după anul 1980, elementele sale nu au suport compact dar sunt continuu diferențiabile.




Figura 9. Un element al familiei Discret Meyer – funcția de scalare (stânga) și funcția wavelet mamă corespunzătoare (dreapta).

f) Familia Battle-Lemarié

Funcțiile wavelet mamă din această familie se construiesc pornind de la funcții de scară de tip spline. Deși nici aceste funcții wavelet nu au suport compact, totuși viteza lor de descreștere este mai mare decât viteza de descreștere a funcțiilor wavelet de tip Discret Meyer. În figura 10 se prezintă un exemplu de funcții de scară de analiză și sinteză de tip spline din compoziția grupului de funcții generatoare bior2.2.

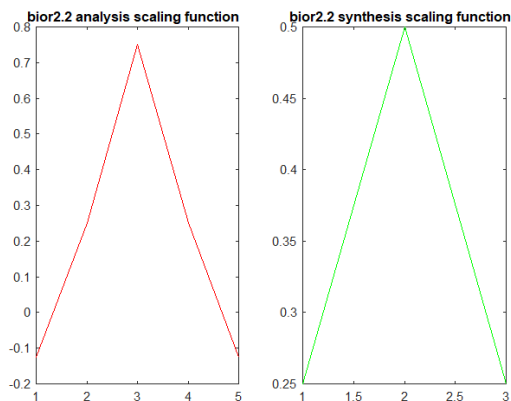


Figura 10. Bior 2.2-funcțiile de scalare de analiză (stânga) și sinteză (dreapta) de tip spline (de ordinul II).

2.1.3. Diferite tipuri de transformări wavelet

Se poate face o clasificare a transformărilor wavelet după tipul de semnal pe care îl analizează, și anume: transformarea wavelet discretă (Discrete Wavelet Transform-DWT, destinată analizei semnalelor numerice) și transformarea wavelet continuă (Continuous Wavelet Transform-CWT destinată analizei semnalelor analogice). În cazul CWT, generarea funcțiilor wavelet pornind de la funcția wavelet

mamă se face efectuând modificări de scară și translații cu numere reale, în timp ce în cazul DWT, generarea funcțiilor wavelet pornind de la funcția wavelet mamă se face folosind modificări de scară cu factor putere a lui 2 și translații cu numere întregi.

A. Transformata wavelet continuă (CWT)

Se consideră un semnal real sau complex care satisface următoarele două condiții:

$$\int_{-\infty}^{\infty} \psi(t) dt = 0, \quad \int_{-\infty}^{\infty} |\psi(t)|^2 dt < \infty \quad (2.5)$$

Prima proprietate, conform căreia semnalul are valoare medie nulă, sugerează un posibil aspect oscilant, iar cea de a doua proprietate, referitoare la valoarea finită a energiei, indică faptul că semnalul are concentrată cea mai mare parte a energiei într-un interval finit de timp.

Cele 2 condiții sunt suficiente pentru ca un semnal să se „califice” drept un semnal de tip wavelet mamă. Este important de subliniat că în literatură au fost propuse numeroase astfel de semnale, unele dintre ele cu durată finită (având deci suport compact), iar altele cu durată infinită, dar cu energia concentrată într-un interval de timp finit.

Fie un semnal $f(t)$ cu energie finită. Definiția CWT pentru acest semnal este prezentată în ecuația (2.6) [11]

$$W(a,b) = \int_{-\infty}^{\infty} f(t) \frac{1}{\sqrt{|a|}} \psi^* \left(\frac{t-b}{a} \right) dt \quad (2.6)$$

a și b sunt constante reale, iar simbolul $*$ semnifică operația de conjugare complexă. Introducând notația:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi \left(\frac{t-b}{a} \right) \quad (2.7)$$

în care funcția $\psi(t)$ reprezintă funcția wavelet mamă iar funcțiile $\psi_{a,b}(t)$ reprezintă funcțiile wavelet (generate prin scalarea cu $1/a$ și translația cu b a funcției wavelet mamă), definiția CWT devine:

$$W(a,b) = \int_{-\infty}^{\infty} f(t) \psi_{a,b}^*(t) dt \quad (2.8)$$

Ca urmare, este ușor de observat că definiția CWT presupune calculul produsului scalar dintre semnalul analizat și semnalele $\psi_{a,b}(t)$. Factorul de normalizare $1/\sqrt{|a|}$ asigură păstrarea energiei semnalelor $\psi_{a,b}(t)$ indiferent de valorile reale particulare ale parametrilor a și b :

$$\int_{-\infty}^{\infty} |\psi_{a,b}(t)|^2 dt = \int_{-\infty}^{\infty} |\psi(t)|^2 dt \quad (2.9)$$

Interpretarea intuitivă a semnalelor $\psi_{a,b}(t)$ este imediată: aceste semnale reprezintă versiuni translate și scalate (dilate sau comprimate de-a lungul axei timpului) ale semnalului prototip $\psi(t)$, de unde și denumirea sugestivă a celui din

urmă: funcție wavelet mamă. Scalarea se poate face prin dilatare (când $a > 1$) sau comprimare (pentru $a < 1$).

Există câteva aspecte care diferențiază clar transformatele wavelet și Fourier:

- în ambele situații evaluarea transformatei presupune calculul unui produs scalar dintre semnalul analizat și un set de semnale care formează o bază particulară în spațiul vectorial al semnalelor de energie finită. Dacă în cazul Fourier, baza este formată întotdeauna din același tip de semnale (exponențiale complexe sau semnale armonice de tip sinus și cosinus), în cazul wavelet avem la dispoziție o paletă largă de forme de undă, în particular existând și posibilitatea de a construi o bază optimală în raport cu semnalul particular analizat (în literatură a fost introdus conceptul *best basis selection* [31], care are în vedere criterii de optimizare specifice teoriei transmisiunii informației);
- baza în raport cu care se face reprezentarea de tip Fourier este ortogonală, pe când în cazul wavelet există posibilitatea de a utiliza și baze formate din vectori liniar independenți care nu sunt ortogonali (un caz particular îl reprezintă bazele biortogonale [11], [32], formate din 2 grupe de vectori pentru care condiția de ortogonalitate este îndeplinită numai în cadrul grupului respectiv).
- spre deosebire de transformata Fourier, care depinde numai de un singur parametru, transformata de tip wavelet depinde de 2 parametri, a și b . Ca urmare, inclusiv modalitatea de reprezentare grafică a spectrului este diferită (și, din păcate, mai puțin intuitivă) în cazul CWT. CWT conduce la o reprezentare mai complicată decât transformata Fourier, deoarece CWT este o reprezentare timp-frecvență (inversul scării, $1/a$ se poate asocia cu frecvența). De exemplu, reprezentarea timp-frecvență de tip SCALOGRAMĂ a unui semnal nu este altceva decât pătratul modulului transformării wavelet continue a aceluși semnal.


În figura 11 se prezintă un exemplu de scalogramă. Semnalul analizat este un semnal modulat în frecvență cu un modulator liniar variabil în timp (semnal „chirp”) și are forma de undă reprezentată în figura 11a). Scalograma sa, calculată folosind funcția wavelet mamă de tip Morlet, este reprezentată în figura 11b). Din figura 11a) se constată că transformarea wavelet continuă este o reprezentare foarte redundantă care se concentrează pe frecvența instantanee a semnalului considerat.

Există mai multe posibilități de interpretare a transformatei wavelet continue:


- a) dacă se pornește de la definiția produsului scalar al semnalelor de energie finită, rezultă imediat că evaluarea CWT presupune calculul unui set de astfel de produse scalare între semnalul analizat și colecția de semnale $\psi_{a,b}(t)$:

$$W(a,b) = \langle f(t), \psi_{a,b}(t) \rangle \quad (2.10)$$

Produsul scalar a două semnale permite și calculul funcției lor de intercorelație, care exprimă gradul lor de asemănare:



a)



b)

Figura 11. Analiza timp-frecvență de tip scalogramă a semnalului de tip „chirp”: a) forma de undă a semnalului; b) reprezentarea timp-frecvență de tip scalogramă.

$$R_{x,y}(\tau) = \int_{-\infty}^{\infty} x(t)y^*(t-\tau)dt = \langle x(t), y(t-\tau) \rangle \quad (2.11)$$

unde τ este valoarea întârzierii care separă semnalele considerate. Pornind de la această definiție, calculul CWT poate fi rescris sub forma:

$$W(a,b) = \langle f(t), \psi_{a,b}(t) \rangle = \langle f(t), \psi_{a,0}(t-b) \rangle = R_{f,\psi_{a,0}}(b) \quad (2.12)$$

Transformata CWT este de fapt rezultatul evaluării repetate a intercorelației dintre semnalul considerat și versiunile translate ale unui ansamblu de semnale de tip wavelet afectate de diferite grade de dilatare sau contracție.

Mai mult decât atât, devine posibilă identificarea valorilor particulare ale parametrilor a și b , pentru care putem obține un semnal $\psi_{a,b}(t)$ puternic corelat cu

cel analizat trasând graficul funcției $|W(a,b)|^2$ (graficul este denumit scalogramă, figura 11) și identificând valorile maxime. Cu alte cuvinte, astfel de valori extreme pot indica cu precizie intervalul de timp în care apar în semnalul analizat impulsuri de durată scurtă sau eventuale salturi bruște.

a) pornind de la definiția produsului de convoluție a 2 semnale analogice:

$$h(t) * x(t) = \int_{-\infty}^{\infty} h(\tau)x(t - \tau)d\tau \quad (2.13)$$

definiția CWT se poate rescrie astfel:

$$W(a,b) = f(b) * \psi_{a,0}^*(-b) \quad (2.14)$$

cu alte cuvinte, pentru o valoare dată a parametrului de scalare a , mărimea $W(a,b)$ reprezintă ieșirea unui filtru având răspunsul la impuls $\psi_{a,0}^*(t)$ și semnalul de intrare $f(b)$.

Dacă notăm cu $\Psi(\omega)$ transformata Fourier a semnalului de tip wavelet mamă $\psi(t)$, atunci o proprietate binecunoscută a acestuia se poate scrie astfel:

$$\psi(t) \leftrightarrow \Psi(\omega) \Rightarrow \psi(t/a) \leftrightarrow |a| \Psi(a\omega) \quad (2.15)$$

Altfel spus, atât frecvența centrală cât și frecvențele care delimitează banda de trecere de la -3 dB a răspunsului în frecvență al sistemului cu răspunsul la impuls $\psi_{a,0}(t) = \psi(t/a)$ vor fi scalate cu același factor $1/|a|$ față de parametrii răspunsului în frecvență al sistemului cu răspunsul la impuls funcția wavelet mamă $\psi(t)$. Cu alte cuvinte, deoarece raportul dintre frecvența centrală și lărgimea benzii la -3 dB a unui filtru trece bandă definește factorul de calitate Q , CWT presupune aplicarea semnalului analizat la intrarea unui continuum de filtre cu Q constant.

Există posibilitatea de a reface un semnal, pornind de la transformata CWT asociată acestuia, $W(a,b)$. Prin analogie cu transformata Fourier, pentru care formele directă și inversă sunt asemănătoare, se pot identifica condițiile în care există transformata wavelet inversă. Calculul CWT presupune folosirea unui set de versiuni translate și scalate ale unei forme de undă generice, de tip wavelet mamă. Posibilitatea inversării CWT există, însă presupune îndeplinirea condiției de admisibilitate, exprimată astfel [11], [32]:

$$0 < C < \infty, \text{ cu } C = \int_{-\infty}^{\infty} \frac{|\Psi(\omega)|^2}{|\omega|} d\omega \quad (2.16)$$

unde $\Psi(\omega)$ este transformata Fourier a semnalului de tip wavelet mamă $\psi(t)$. Această condiție este suficientă, dar nu și necesară (pentru cazul în care setul de parametri (a,b) este discretizat) iar atunci când este îndeplinită, semnalul a cărui transformata CWT este dată de valorile $W(a,b)$ se calculează cu formula:

$$f(t) = \frac{1}{C} \int_{a=-\infty}^{\infty} \int_{b=-\infty}^{\infty} \frac{1}{|a|^2} W(a,b) \psi_{a,b}(t) da db \quad (2.17)$$

Relația (2.16) conduce la faptul că transformata Fourier $\Psi(\omega)$ trebuie să aibă valoare medie nulă $|\Psi(0)|^2=0$, pentru a putea justifica afirmația că un filtru a cărui funcție pondere este dată de o versiune scalată a semnalului de tip wavelet mamă are caracter trece-bandă.

B. Transformata wavelet discretă (DWT)

Pentru implementarea DWT a fost necesar un algoritm de calcul și o schemă de implementare. Mallat [13] a rezolvat aceste probleme prin introducerea conceptului analizei multi-rezoluție (MRA), care este legată de structurile de filtru de reconstrucție perfectă (PR).

Există câteva elemente care fac dificilă utilizarea practică a transformatei wavelet continue. Un prim aspect se referă la gradul ridicat de redundanță al setului de valori $W(a,b)$ (care poate fi observat și în figura 11b)): după cum s-a arătat anterior, evaluarea acestora presupune calculul intercorelației dintre semnalul analizat și un continuum de versiuni translate și scalate ale aceleiași funcții. Cum aceste versiuni nu sunt ortogonale (altfel spus, astfel de versiuni afectate de translații mici vor fi încă suficient de asemănătoare), devine evident că vor apare subseturi de coeficienți $W(a,b)$ foarte apropiați ca valoare, situație care este ineficientă în practică. Al doilea motiv îl reprezintă faptul că definiția (2.8) presupune folosirea unui număr infinit de valori ale parametrilor a și b , deși am prefera să lucrăm numai cu un număr limitat al acestora. În sfârșit, un dezavantaj major îl reprezintă inexistența unor soluții analitice capabile să furnizeze expresia transformatei CWT pentru semnale oarecare, astfel încât suntem nevoiți, exact ca în cazul transformatei Fourier, să facem apel la metode numerice de calcul. Din acest punct de vedere, vom fi interesați de elaborarea unor algoritmi rapizi, așa cum în cazul transformatei Fourier avem la dispoziție varianta Fast Fourier Transform (FFT). În cele ce urmează vom analiza pe rând posibilitățile de a elimina aceste neajunsuri.

✓ Eliminarea redundanței în reprezentarea de tip wavelet

Soluția avută în vedere se referă la discretizarea valorilor parametrilor a și b pentru care se efectuează calculul CWT, folosindu-se o reprezentare de forma [32]:

$$f(t) = \sum_{k=-\infty}^{\infty} \sum_{l=-\infty}^{\infty} d[k,l] 2^{-k/2} \psi(2^{-k}t - l) \quad (2.18)$$

care se numește descompunere în serie de funcții wavelet. Setul de coeficienți $d(k,l)$ definește Transformata Wavelet Discretă (DWT). Este important de observat faptul că discretizarea afectează numai parametrii a și b , semnalele $f(t)$ și $\psi(t)$ rămânând semnale analogice. Intuitiv, acest tip de descompunere seamănă cu seria Fourier asociată unui semnal periodic, în care apar numai componente ale căror frecvențe sunt multipli întregi ai frecvenței fundamentale.

Eliminarea efectivă a redundanței se produce prin alegerea unui set ortogonal de funcții $\psi_{a,b}(t)$, care respectă condiția:

$$\langle \psi_{a,b}(t), \psi_{c,d}(t) \rangle = \int_{-\infty}^{\infty} \psi_{a,b}(t) \psi_{c,d}^*(t) dt = \begin{cases} 1, & a = c, b = d \\ 0, & \text{în rest} \end{cases} \quad (2.19)$$

Două observații merită făcute în acest context:

- ortogonalitatea nu este o condiție necesară în reprezentarea semnalelor, însă este eficientă din punct de vedere practic;
- discretizarea parametrilor a și b implică caracterul variabil în timp al reprezentării: dacă avem la dispoziție 2 semnale identice, care diferă numai printr-o întârziere relativă, reprezentările lor bazate pe relația (2.18) nu vor fi identice (și afectate de aceeași întârziere), ci vor fi diferite.

✓ Limitarea setului de valori (a,b)

Odată rezolvată problema eliminării redundanței în reprezentarea de tip wavelet, ne propunem să identificăm modalitatea prin care putem renunța la

evaluarea acestora într-un număr infinit de perechi de valori (a,b) . Dacă în cazul translației, indexată în pași discreți de parametrul b , este evident că durata semnalului impune o limită superioară, lucrurile sunt mai dificile în cazul parametrului a care indexează scara. Să ne reamintim una dintre interpretările transformatei CWT precizate anterior: calculul presupune de fapt aplicarea semnalului analizat la intrarea unui ansamblu (banc) de filtre de tip trece-bandă, cu factor de calitate constant, ale căror frecvențe centrale (și benzi de trecere la -3 dB) se vor dubla la fiecare dublare a valorii parametrului a . Ca urmare, ne putem imagina ușor spectrul semnalului studiat „acoperit” de o serie de sub-benzi de trecere ale acestor filtre, ca în figura 12. Deoarece filtrele nu sunt ideale, acoperirea uniformă presupune o anumită suprapunere parțială a benzilor corespunzătoare filtrelor adiacente. Notând frecvența maximă din spectrul semnalului analizat cu Ω_{max} , filtrele utilizate vor avea (în ordine descrescătoare a frecvenței) benzi de trecere de forma $[0.5\Omega_{max}, \Omega_{max}]$, $[0.25\Omega_{max}, 0.5\Omega_{max}]$, $[0.125\Omega_{max}, 0.25\Omega_{max}]$,... . Pentru că intenția noastră este totuși de a folosi un număr finit de valori ale parametrului a care indexează scara (și care fixează numărul de filtre trece-bandă utilizat) una dintre cele mai naturale idei este de a realiza „acoperirea” spectrului semnalului analizat printr-o combinație dintre un număr oarecare de filtre trece-bandă și un filtru trece-jos. Acest filtru trece-jos este asociat unei așa-numite funcții de scalare, care va depinde în mod nemijlocit de clasa de semnale de tip wavelet aleasă pentru reprezentarea descrisă prin relația (2.18).




Figura 12. Acoperirea benzii ocupate de spectrul semnalului studiat cu sub-benzi.

Funcția de scalare trebuie să îndeplinească anumite condiții [32]:

$$\int_{-\infty}^{\infty} \phi(t) dt = 1$$

$$\int_{-\infty}^{\infty} |\phi(t)|^2 dt = 1 \quad (2.20)$$

$$\langle \phi(t), \phi(t-n) \rangle = \delta(n)$$

Pe lângă aceste condiții se adaugă o proprietate fundamentală numită ecuație de dilatație [11]:

$$\phi(t) = \sum_{n=-\infty}^{\infty} c[n] \phi(2t-n) \quad (2.21)$$

$c[n]$ sunt coeficienții reali (numiți coeficienți de aproximare) și, de regulă, numărul acestora este finit. Prin înlocuirea lui t cu $2^{-k}t$ putem rescrie relația (2.21) astfel:

$$\phi(2^{-k}t) = \sum_{n=-\infty}^{\infty} c[n] \phi(2^{-(k-1)}t-n) \quad (2.22)$$

Această relație poate fi interpretată astfel: funcția de scalare corespunzătoare unei anumite scări de reprezentare poate fi exprimată în raport cu valorile aceleiași funcții la o scară inferioară (cu mai multă informație).

Setul de coeficienți $c[n]$ poate fi interpretat drept funcția pondere a unui filtru discret, notând cu $C(\omega)$ răspunsul în frecvență al acestuia, putem scrie:

$$|C(\omega)|^2 + |C(\omega + \pi)|^2 = 1 \quad (2.23)$$

Legătura dintre funcția de scalare și funcția de tip wavelet mamă rezultă din impunerea condiției de ortogonalitate, care se adaugă celor descrise în relațiile (2.5) și (2.19):

$$\langle \psi(t), \phi(t-n) \rangle = 0, n \in Z \quad (2.24)$$

Și în acest caz există o ecuație de dilatație care implică funcția wavelet mamă $\psi(t)$ asemănătoare ecuației (2.21) [32]:

$$\psi(t) = \sum_{n=-\infty}^{\infty} d[n] \phi(2t-n) \quad (2.25)$$

unde setul de coeficienți $d[n]$ (numiți coeficienți de detalii) reprezintă funcția pondere a unui filtru în timp discret cu răspunsul în frecvență $D(\omega)$, care îndeplinește următoarele condiții:

$$\sum_{n=-\infty}^{\infty} d[n] = 0$$

$$\frac{1}{2} \sum_{m=-\infty}^{\infty} d[m] d[m-2l] = \delta[l], l \in Z \quad (2.26)$$

$$|D(\omega)|^2 + |D(\omega + \pi)|^2 = 1$$

Legătura dintre $\phi(t)$ și $\psi(t)$ se deduce din următoarele relații:

$$\langle \psi(t), \phi(t-l) \rangle = \frac{1}{2} \sum_{m=-\infty}^{\infty} d[m]c[m-2l] = 0$$

$$|C(\omega)|^2 + |D(\omega)|^2 = 4 \tag{2.27}$$

$$C^*(\omega)C(\omega + \pi) + D^*(\omega)D(\omega + \pi) = 0$$

Relația (2.25) se poate rescrie astfel, înlocuind pe t cu $2^{-k}t$:

$$\psi(2^{-k}t) = \sum_{n=-\infty}^{\infty} d[n]\phi(2^{-(k-1)}t - n) \tag{2.28}$$

Cu alte cuvinte, relația (2.18) sugerează posibilitatea de a exprima un semnal sub forma unei combinații liniare de versiuni traslate și scalate ale funcției wavelet mamă $\psi(t)$, care ea însăși poate fi exprimată, în acord cu relația (2.28), drept o combinație liniară de versiuni scalate și traslate ale funcției de scalare $\phi(t)$.

Transformata DWT este cea mai frecvent utilizată formă de transformată wavelet deoarece este rapidă, neredundantă și asigură reconstrucția perfectă. Această transformată poate fi calculată cu ajutorul algoritmului lui Mallat care este rapid (mai rapid decât algoritmul transformării Fourier rapide-Fast Fourier Transform-FFT). Schema bloc de implementare a algoritmului lui Mallat este prezentată în figura 13a).

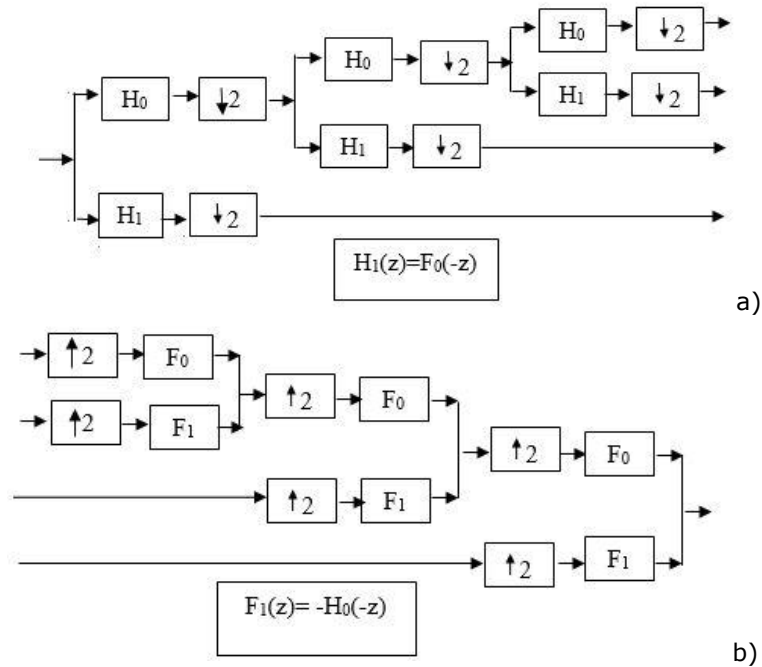


Figura 13. Schema bloc pentru calculul a) DWT și b) IDWT pentru cazul funcțiilor wavelet mamă biortogonale.

Pentru calculul DWT se folosesc filtre digitale de tip trece-jos cu funcția de transfer $H_0(z)$ (dedusă din funcția de scalare de analiză), filtre digitale de tip trece-sus cu funcția de transfer $H_1(z)$ (deduse din funcția wavelet mamă de analiză) și decimatoare cu factor 2 (blocurile marcate cu săgeată în jos urmată de 2). La ieșirea ramurii care conține filtre trece-jos se obțin coeficienții de aproximare iar la ieșirile ramurilor care conțin filtre trece-sus se obțin coeficienții de detalii. Pentru calculul IDWT se folosesc filtre digitale de tip trece-jos cu funcția de transfer $F_0(z)$ (dedusă din funcția de scalare de sinteză), filtre digitale de tip trece-sus cu funcția de transfer $F_1(z)$ (deduse din funcția wavelet mamă de sinteză) și interpolatoare cu factor 2 (blocurile marcate cu săgeată în sus urmată de 2).

Transformata DWT are câteva inconveniente [33]:

- Deoarece funcțiile wavelet reprezintă răspunsuri la impuls de filtre trece-bandă, coeficienții wavelet tind să oscileze în jurul singularităților semnalului analizat.
- O mică translație în timp a semnalului analizat perturbă puternic forma de oscilație a coeficienților wavelet în jurul singularităților. Pentru a examina proprietatea de invarianță la translații a unei transformări, Kingsbury [34] a propus o metodă bazată pe păstrarea unui singur tip de coeficienți wavelet (de aproximare sau de detalii) pentru un singur nivel de descompunere. De exemplu se păstrează doar coeficienții de detalii de la cel de al treilea nivel de descompunere și se anulează toți ceilalți coeficienți wavelet. Dacă semnalul reconstruit doar pe baza acestor coeficienți nu suferă de aliere atunci se poate spune că transformarea este invariantă la translații la acel nivel de descompunere.
- Spațierea largă a coeficienților wavelet datorată folosirii iterative a operației de sub-eșantionare la fiecare nivel de descompunere rezultă în aliere substanțială. Prin calculul IDWT se anulează această aliere dacă valorile coeficienților wavelet nu se modifică. Orice prelucrare a coeficienților wavelet (eliminarea coeficienților cu valoarea absolută mai mică decât o valoare de prag, filtrare, cuantizare) conduce la distorsiuni ale semnalului reconstruit.

Acest ultim inconvenient al DWT poate fi corectat prin creșterea redundanței transformării.

Transformările wavelet inversabile care pun în corespondență întregi cu întregi se aplică cu succes în compresia fără pierderi. În [35] sunt prezentate două metode de construcție a unei transformări wavelet discretă, care pune în corespondență întregii cu întregi. În cazul transformării wavelet discrete, filtrele trece-jos și trece-sus folosite pentru implementare au răspunsuri la impuls cu coeficienți calculați în virgulă mobilă. De exemplu, dacă se folosesc filtre corespunzătoare unor funcții de scară și wavelet mamă de tip Daubechies atunci coeficienții filtrelor folosite sunt numere reale, care pot fi calculate cu precizie mare, dar pentru care nici măcar nu există o expresie analitică. Atunci când datele de intrare constau dintr-o secvență de întregi (ca în cazul imaginilor), ieșirile filtrelor trece-jos și trece-sus nu mai sunt secvențe de numere întregi. Pentru compresia fără pierderi ar fi interesant să se poată caracteriza rezultatul complet cu numere întregi. Cele două metode de construcție a unei transformări wavelet discretă, care pune în corespondență întregii cu întregi, propuse în [35] nu au ca rezultat o transformare wavelet cu filtre trece-jos și trece-sus având coeficienți ai răspunsurilor la impuls numere întregi. Calculele încă se fac cu numere în virgulă mobilă, dar rezultatele sunt numere întregi. Aceasta nu afectează viteza în aplicațiile software deoarece în majoritatea microprocesoarelor folosite în prezent calculele în

virgulă mobilă și cele cu întregi se efectuează la fel de rapid. Cea de a doua metodă prezentată în [35] se bazează pe combinarea construcției de funcții wavelet prin lifting (amintită la 2.2.2 e)) cu o metodă de rotunjire într-un mod reversibil.

C. Transformata wavelet staționară (nedecimată)

Înlăturând sistemele de sub-eșantionare din schema de implementare a DWT se obține schema de implementare a unei alte transformate wavelet discretă, numită transformata wavelet nedecimată (Undecimated Discrete Wavelet Transform-UDWT) sau transformată wavelet staționară (Stationary Wavelet Transform-SWT). Aceasta poate fi calculată cu ajutorul algoritmului 'à trous', conceput de Holschneider [36] în 1989 pentru aplicații de sinteză a muzicii. UDWT este o transformare foarte redundantă, dar este invariantă la translații.

D. Transformata wavelet complexă cu arbore dublu

Toate dezavantajele DWT pot fi corectate folosind transformări wavelet complexe (Complex Wavelet Transforms-CWT) care sunt transformări cu redundanță scăzută. În 1998, Kingsbury a introdus transformata wavelet complexă cu arbore dublu (Dual Tree Complex Wavelet Transform-DTVWT) [37], o transformare complexă aproape invariantă la translații, cu redundanță scăzută, care a fost analizată și de Selesnick [38].

E. Transformarea wavelet analitică

Transformarea DWT complexă (Complex Discrete Wavelet Transform-CDWT) propusă în [37] este aproape analitică, corectează dezavantajele DWT și are o redundanță slabă. Poate fi calculată folosind doi arbori de calcul al DWT, conectați în paralel. Unul calculează partea reală a CDWT folosind o funcție wavelet mamă ψ iar celălalt calculează partea imaginară a CDWT folosind funcția wavelet mamă obținută prin transformarea Hilbert a funcției ψ , $H\{\psi\}$. Conectarea în paralel a celor doi arbori este echivalentă cu o transformare wavelet complexă care folosește drept funcție wavelet mamă, semnalul analitic asociat semnalului ψ : $\psi_a = \psi + jH\{\psi\}$. În continuare, această transformare wavelet complexă este echivalentă cu DWT a semnalului analitic asociat semnalului de la intrare calculată cu funcția wavelet mamă reală ψ . Astfel, operația de asociere cu semnalul analitic comută cu operația de calcul al DWT folosind funcția wavelet mamă ψ . Această proprietate este numită, folosind o expresie preluată din electronică, reducere la intrare. Și CDWT este aproape invariantă la translații [40].

F. Pachete de funcții wavelet

Există situații în care sub-benzile filtrelor trece-bandă din figura 12 nu sunt suficient de înguste pentru a se obține o analiză spectrală de calitate folosind transformata wavelet discretă. Acest lucru se datorează faptului că doar ieșirile blocurilor compuse din filtru trece-jos și decimator cu factor 2 din figura 13 sunt filtrate atât trece-jos cât și trece-sus. În partea stângă din figura 14 este prezentată schema unei transformate wavelet în care atât ieșirile blocurilor compuse din filtru

trece-jos și decimator cât și ieșirile blocurilor compuse din filtru trece-sus și decimator sunt în continuare filtrate atât trece-jos cât și trece-sus. Aceasta se numește transformata wavelet discretă cu pachete (Discrete Wavelet Packet Transform-DWPT).

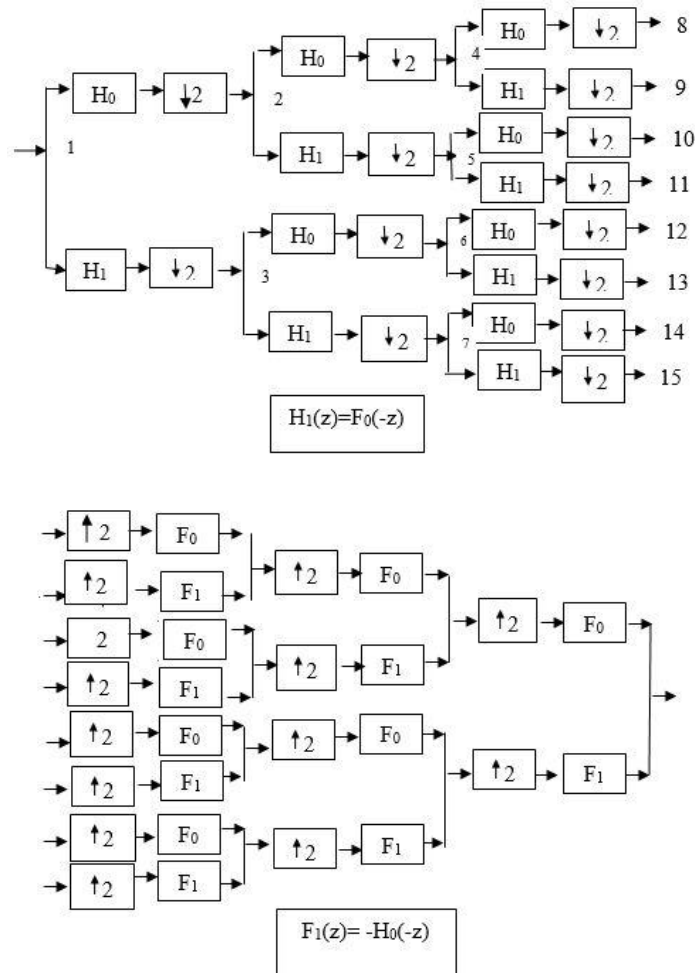


Figura 14. Un exemplu de implementare a transformatei cu pachete de funcții wavelet (sus). Implementarea transformatei inverse (jos).

O astfel de transformată se numește transformată cu pachete de funcții wavelet. În partea de jos este prezentată schema de implementare a transformatei cu pachete de funcții wavelet inversă. Transformata cu pachete de funcții wavelet este foarte flexibilă. Alegând diferite noduri ca ieșiri se obțin diferite versiuni ale transformatei cu pachete de funcții wavelet. De exemplu, dacă alegem ca ieșiri nodurile: 8, 9, 5 și 3, obținem transformata wavelet discretă. Dacă alegem ca ieșiri nodurile: 8, 9, 10, 11, 12, 13, 14 și 15, se obține transformata cu pachete de funcții wavelet cu cel mai mare număr de sub-benzi. Mladen Viktor Wikerhauser,

inventatorul pachetelor de funcții wavelet, a propus o modalitate de alegere a nodurilor care să adapteze transformata cu pachete de funcții wavelet la semnalul de prelucrat. Această metodă de optimizare, numită căutarea celei mai bune baze, presupune inițial calculul transformării cu pachete de funcții wavelet cu cel mai mare număr de sub-benzi (care presupune parcurgerea tuturor nodurilor) și determinarea coeficienților wavelet corespunzători fiecărui nod. Apoi se compară o anumită măsură (de exemplu entropia) a coeficienților nodurilor copii cu aceeași măsură a coeficienților nodului părinte. Dacă măsura nodului părinte este mai mică decât minimul măsurilor nodurilor copii, atunci acel nod părinte se declară ieșire. În caz contrar, se continuă căutarea pe arbore.

G. Transformări wavelet bidimensionale

Toate transformările wavelet unidimensionale deja amintite au generalizări bidimensionale mai simple sau mai complicate. Generalizarea transformărilor wavelet la două dimensiuni este realizată prin filtrare separată pe linii și apoi pe coloane. La baza implementării transformării DWT bidimensionale stau conceptele de multirezoluție și de bază de funcții wavelet bidimensionale. La fel ca DWT și transformarea DWT bidimensională este neredundantă și are aceleași dezavantaje. Un dezavantaj suplimentar al transformării DWT bidimensionale este selectivitatea direcțională redusă. Transformarea DWT bidimensională are doar trei orientări preferențiale: orizontală, verticală și diagonală. O analiză statistică de ordinul doi a coeficienților transformării DWT bidimensionale pune în evidență dependența inter-scară și inter-benzi a acestora [41]. Imaginile de intrare au fost modelate ca procese aleatoare bidimensionale staționare în sens larg. Au fost obținute expresii analitice pentru funcțiile de corelație ale coeficienților wavelet în toate scenariile posibile: inter-scară și inter-bandă; inter-scară și intra-bandă; intra-scară și inter-bandă; și intra-scară și intra-bandă. Rezultate de simulare confirmă rezultatele teoretice obținute. În ceea ce privește transformarea UDWT a imaginilor, bazele de funcții wavelet bidimensionale separabile reprezintă din nou punctul de plecare pentru construcție [42]. Și transformarea UDWT bidimensională este invariantă la translații și foarte redundanță.

Transformarea DTCWT poate fi generalizată la două dimensiuni prin filtrare separate pe linii și apoi pe coloane la fiecare dintre nivelurile transformării unidimensionale [34]. Transformarea DTCWT bidimensională are o redundanță de 4, este aproape invariantă la translații și are șase orientări preferențiale. Funcția wavelet mamă care o generează este cvasi-analitică.

Generalizarea conceptului de analiticitate în două dimensiuni nu este simplă deoarece există mai multe definiții ale transformării Hilbert în cazul funcțiilor bidimensionale [39]. Semnalul analitic asociat unui semnal real unidimensional este o funcție complexă a cărei parte reală este identică cu semnalul real și a cărei parte imaginară este egală cu transformata Hilbert a semnalului real. Deci semnalul analitic asociază numere complexe (perechi de numere reale a căror mulțime are o structură de algebră) unor numere reale. Semnalul analitic asociat unei imagini reale (funcție de două variabile) este numit imagine hiperanalitică și are patru componente: partea reală, partea imaginară în raport cu prima variabilă, partea imaginară în raport cu cea de a doua variabilă și partea imaginară în raport cu ambele variabile ale funcției bidimensionale de intrare. Astfel, imaginea hiperanalitică este o funcție „de două ori complexă” care asociază numere reale la mulțimi ordonate de patru numere reale, numite numere hipercomplexe. Mulțimea numerelor hipercomplexe are o structură de algebră. Tabelul de înmulțire asociat acestei algebre definește fiecare relație între unitățile imaginare ale numerelor

hipercomplexe și definește proprietățile specifice ale algebrei numerelor hipercomplexe. Pentru fiecare formă particulară de tabel de înmulțire se obține o definiție diferită a imaginii hipercomplexe. De exemplu, următorul tabel de înmulțire:

$$ij = -ji = k, jk = -kj = i, ki = -ik = j, ik = -ki = -j, i^2 = j^2 = k^2 = -1 \quad (2.29)$$

corespunde algebrei cuaternionilor [43]. Aceasta este o algebră hipercomplexă asociativă dar necomutativă folosită în [39] pentru construcția unei transformări wavelet hiperanalitice. Datorită lipsei comutativității algebrei hiperanalitice a cuaternionilor, transformarea wavelet hipercomplexă din [39] nu poate fi redusă la intrare.

În [44] a fost aleasă algebra hipercomplexă comutativă cu următorul tabel de înmulțire, propusă în [45]:

$$ij = ji = k, jk = kj = i, ki = -ik = j, ik = ki = -j, i^2 = j^2 = -k^2 = -1 \quad (2.30)$$

Pornind de la funcția wavelet mamă reală $\psi(x, y)$ și de la funcția de scalare reală $\varphi(x, y)$, s-au definit funcțiile wavelet mamă și de scalare hipercomplexe:

$$\psi_a(x, y) = 1\psi(x, y) + iH_x\{\psi(x, y)\} + jH_y\{\psi(x, y)\} + kH_x\{H_y\{\psi(x, y)\}\} \quad (2.31)$$

$$\varphi_a(x, y) = 1\varphi(x, y) + iH_x\{\varphi(x, y)\} + jH_y\{\varphi(x, y)\} + kH_x\{H_y\{\varphi(x, y)\}\} \quad (2.32)$$

unde s-a notat cu H_x transformata Hilbert unidimensională calculată pe linii iar cu H_y transformata Hilbert unidimensională calculată pe coloane. Se notează transformata wavelet hiperanalitică corespunzătoare cu HWT. Coeficienții săi de detalii sunt definiți ca produs scalar dintre imaginea de intrare $f(x, y)$ și funcțiile wavelet hiperanalitice corespunzătoare iar coeficienții săi de aproximare sunt definiți ca produse scalare dintre imaginea de intrare și funcțiile de scalare hiperanalitice corespunzătoare.

HWT poate fi redusă la intrare deoarece [44]:

$$HWT\{f(x, y)\} = 2DDWT\{f_a(x, y)\} \quad (2.33)$$

unde $f_a(x, y)$ reprezintă forma hiperanalitică a imaginii de intrare. Deci, transformata wavelet hiperanalitică a imaginii de intrare poate fi calculată ca și transformare DWT bidimensională a formei hiperanalitice a imaginii de intrare. De aceea pentru implementarea HWT se folosesc patru arbori, fiecare calculând câte o transformare DWT bidimensională. HWT are o redundanță de 4. Primul arbore este aplicat imaginii de intrare. Cel de al doilea și cel de al treilea arbore sunt aplicate transformatelor Hilbert unidimensionale ale imaginii de intrare calculate pe linii (H_x) respectiv pe coloane (H_y). Cel de al patrulea arbore este aplicat rezultatului obținut după calculul transformatelor Hilbert unidimensionale pe liniile și pe coloanele imaginii de intrare. Schema de implementare a HWT propusă în [44] este compusă din două blocuri. Primul calculează forma hiperanalitică a imaginii de intrare și cele patru DWT bidimensionale, ale căror secvențe de ieșire se notează cu d_1, d_2, d_3 și d_4 . Cel de-al doilea bloc îmbunătățește selectivitatea direcțională a transformatei. Creșterea selectivității direcționale a HWT se realizează la fel ca și în cazul transformării DTCWT bidimensionale, [34], [46], prin combinații lineare ale coeficienților de detalii din fiecare sub-bandă a fiecăreia din cele patru DWT bidimensionale:

$$\begin{aligned} z_+ &= (d_1 - d_4) + j(d_2 + d_3) \\ z_- &= (d_1 + d_4) + j(d_2 - d_3) \end{aligned} \quad (2.34)$$

La fel ca și DTCWT bidimensională, HWT are șase orientări preferențiale: $\pm \arctg(1/2)$, $\pm \pi/4$ și $\pm \arctg(2)$. Transformarea DWT bidimensională are doar trei

orientări preferențiale: $0, \pi/4, \pi/2$, nefăcând diferența între direcțiile celor două diagonale principale.

O altă transformată wavelet bidimensională este transformata wavelet cu pachete hiperanalitice (Hiperanalytic Wavelet Packet Transform-HWPT) care moștenește arhitectura de la HWT dar în locul transformatelor DWT bidimensionale de pe cei patru arbori folosește transformări bidimensionale cu pachete de funcții wavelet (DWPT). Schema bloc a HWPT este prezentată în figura 15.

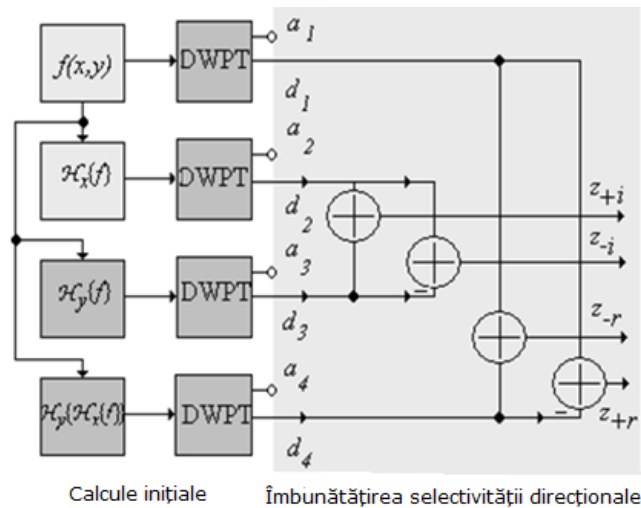


Figura 15. Arhitectura sistemului de calcul a transformării wavelet cu pachete hiperanalitice (HWPT).

La fel ca în cazul HWT, pentru implementarea HWPT se folosesc patru arbori, fiecare calculând câte o transformare DWPT bidimensională. HWPT are o redundanță de 4. Primul arbore este aplicat imaginii de intrare $f(x,y)$. Cel de al doilea și cel de al treilea arbore sunt aplicate transformărilor Hilbert unidimensionale ale imaginii de intrare calculate pe linii (\mathcal{H}_x) respectiv pe coloane (\mathcal{H}_y). Cel de al patrulea arbore este aplicat rezultatului obținut după calculul transformărilor Hilbert unidimensionale pe liniile și pe coloanele imaginii de intrare. Schema de implementare a HWPT propusă în [47] este compusă din două blocuri. Primul calculează forma hiperanalitică a imaginii de intrare și cele patru DWPT bidimensionale, ale căror secvențe de ieșire se notează cu (a_k, b_k) , $k=1, 2, 3, 4$. Cel de al doilea bloc îmbunătățește selectivitatea direcțională a transformatei. Creșterea selectivității direcționale a HWPT se realizează prin combinații lineare ale coeficienților de detalii din fiecare sub-bandă a fiecăreia din cele patru DWPT bidimensionale, folosind ecuația (2.34). Întrucât DWPT are o selectivitate direcțională mult mai mare decât DWT și HWPT va avea o selectivitate direcțională mult mai mare decât HWT (care are șase orientări preferențiale). Selectivitatea direcțională a HWPT depinde de numărul de niveluri de descompunere ale acestei transformate. Fiecare sub-bandă a HWPT corespunde unei orientări direcționale diferite. De exemplu, dacă se consideră doar două niveluri de descompunere atunci HWPT are 16 orientări preferențiale [48]. Această valoare poate fi crescută dacă se crește numărul de iterații. Valoarea varianței coeficienților HWPT de detalii dintr-o anumită sub-bandă indică dacă direcția preferențială asociată acelei sub-benzi

reprezintă sau nu una dintre direcțiile principale ale imaginii analizate. Dacă valoarea varianței din sub-bandă este mare, considerăm că direcția preferențială asociată cu acea sub-bandă este o direcție principală pentru imaginea analizată. În figura 16 sunt prezentate cele patru direcții principale a trei imagini naturale, obținute aplicând metoda din [49].



Figura 16. Cele patru direcții principale a trei imagini naturale: a) Lena, b) Barbara, c) Boats; marcate cu culori diferite.

Alte proprietăți utile ale HWPT sunt următoarele:

- Este aproape invariantă la translații (la fel ca HWT);
- Este cvasi-analitică;
- Este hiperanalitică;
- Îmbunătățește localizarea frecvențială a HWT la fel cum DWPT îmbunătățește localizarea frecvențială a DWT.

Analiza cu componente principale (Principal Component Analysis-PCA) este denumirea unei tehnici statistice care transformă un număr mare de variabile, posibil corelate, într-un număr mai mic de variabile, denumite componente principale (Principal Components-PC). Direcțiile principale ale unei imaginii reprezintă valorile proprii ale matricii de covarianță a acelei imaginii [3]. Componentele principale ale acelei imaginii se obțin ca proiecții ale pixelilor centrați ai acelei imaginii pe direcțiile sale principale.

Ideea principală a lucrării [49] este calculul valorilor principale ale unei imagini cu ajutorul transformării sale HWPT. Orientările preferențiale ale sub-benzilor HWPT cu cele mai mari valori ale varianțelor coeficienților de detalii reprezintă direcțiile principale ale imaginii analizate. **Interpretarea transformării cu pachete de funcții wavelet hiperanalitice ca o analiză în componente principale a imaginii reprezintă o primă contribuție a tezei de față. Această interpretare originală a fost publicată în lucrarea de conferință indexată ISI [49]:**

G. A. Magu, M. Kovaci, „Images’ Principal Component Analysis using Hyperanalytic Wavelet Packets”, 2018 International Symposium on Electronics and Telecommunications (ISETC), 1-4.

2.2. Denoising

Imaginile naturale conțin informație redundantă. Această manifestare este implicit sau explicit luată în considerare în orice aplicație a prelucrării imaginilor. Există trei tipuri de metode de prelucrarea imaginilor: de pregătire a imaginilor pentru prelucrare (pre-processing); de prelucrare propriu-zisă și de finisare a imaginilor după prelucrare (post-processing). În particular codarea și compresia imaginilor depind aproape în întregime de cât de redundantă este imaginea pentru a reduce numărul de biți cu care este ea reprezentată digital. Și metodele de reconstrucție a imaginilor se bazează pe ipoteze implicite sau explicite referitoare la imaginea „adevărată” care a suferit degradări. De aceea, cunoașterea statisticilor imaginilor naturale este fundamentală pentru înțelegerea oricărei metode de prelucrare a imaginilor. Există legături puternice între statisticile imaginilor naturale și sistemul vizual uman. Vederea, sursa cea mai importantă de informații pentru oameni, a evoluat milioane de ani pentru a se acomoda la mediul înconjurător. Această evoluție a sistemului vizual din creier a avut ca scop minimizarea redundanței în reprezentarea imaginilor naturale pentru a dobândi eficiență metabolică și eficiență în reprezentare și învățare. Luând în considerare legătura recunoscută dintre teoria funcțiilor wavelet și sistemul vizual uman, în continuare se prezintă exemple de metode de prelucrare a imaginilor care folosesc teoria funcțiilor wavelet.

În sens larg, cuvântul „zgomot” se referă la orice sunet nedorit. Atât în electronica analogică, cât și în cea digitală, zgomotul este o perturbare nedorită a semnalului util; semnalul perturbator se numește zgomot ca o generalizare a zgomotului audio perceput la ascultarea unei transmisii radio de calitate slabă. Zgomotul este perceput acustic dacă este redat printr-un difuzor și se manifestă ca „zăpadă” pe o imagine de televiziune sau dintr-o secvență video. Zgomotul poate bloca, distorsiona, modifica sau interfera cu un mesaj atât în comunicarea umană, cât și în cea electronică. În procesarea semnalului, eșantioanele de zgomot pot fi considerate date nedorite fără semnificație; nu transportă informație utilă, ci rezultă pur și simplu ca un produs secundar nedorit al altor activități. Termenul „denoising”, are semnificația de „reducerea zgomotului”. Aceasta este una dintre cele mai importante metode de pregătire a imaginilor pentru prelucrare. Algoritmul de denoising are ca scop diminuarea zgomotului fără afectarea detaliilor semnalului util. Cea mai mare dificultate pentru un algoritm de denoising constă în separarea semnalului util de zgomot.

La ora actuală există numeroase metode de denoising: în domeniul spațial; în domeniul unei transformate (de exemplu Fourier sau wavelet); cu operatori de concentrare (shrinking); Bayesiene; cu filtre de mediere nelocale; cu rețele neuronale. Una dintre cele mai des utilizate clasificări ale acestor metode presupune existența a două clase de metode: parametrice și neparametrice.

2.2.1. Imagini digitale și zgomot

Imaginile obținute cu camere digitale sau cu camere cu film convenționale înglobează zgomotul provenit dintr-o varietate de surse. Multe utilizări ulterioare ale acestor imagini necesită ca zgomotul să fie (parțial) eliminat - în scopuri estetice ca în lucrări artistice sau în marketing sau în scopuri practice, cum ar fi viziunea computerizată. În funcție de modelul folosit pentru a caracteriza zgomotul, putem întâlni zgomotul de tip „sare și piper”, zgomotul Gaussian și multe altele. O altă

posibilă clasificare ia în considerare modul în care zgomotul afectează imaginea, rezultând zgomot aditiv și zgomot multiplicativ.

O histogramă realizează o estimare a densității de probabilitate a zgomotului. În timp ce alte distribuții sunt posibile, distribuția Gaussiană (normală) este de obicei un model bun, datorită teoremei limită centrală care spune că suma zgomotelor independente tinde să aibă o distribuție Gaussiană.

În continuare va fi luat în considerare cazul zgomotului aditiv alb Gaussian (AWGN) de medie (statistică) nulă. Imaginea achiziționată este exprimată în acest caz în următoarea formă:

$$\mathbf{x} = \mathbf{s} + \mathbf{n} \quad (2.35)$$

unde \mathbf{x} este imaginea observată/achiziționată, \mathbf{s} este componenta utilă a imaginii și \mathbf{n} este componenta AWGN.

În ceea ce privește zgomotul de tip sare și piper, pixelii zgomotoși din imagine sunt foarte diferiți ca și culoare respectiv intensitate față de pixelii din jur; caracteristica definitorie este că valoarea unui pixel zgomotos nu are nici o legătură cu valorile pixelilor din jur. În general, acest tip de zgomot va afecta doar un număr mic de pixeli ai imaginii. Când este vizualizată, imaginea conține puncte luminoase și întunecate, de unde și termenul de zgomot de tip sare și piper. Sursele tipice pentru acest zgomot includ pete de praf în interiorul camerei convenționale sau elemente CCD defecte în cazul camerei digitale.

Un exemplu de zgomot de tip sare și piper este zgomotul speckle, care apare datorată reflexiilor multiple pe microrelieful suprafețelor în cazul imaginilor RADAR sau SONAR. Zgomotul speckle este modelat ca zgomot multiplicativ, imaginea observată având expresia:

$$\mathbf{x} = \mathbf{s} \cdot \mathbf{n} \quad (2.36)$$

unde \mathbf{n} reprezintă zgomotul speckle.

În ambele cazuri, zgomotele care afectează diferiți pixeli sunt necorelate fiind independente și distribuite identic.

În cazul unei transmisii de imagini, zgomotul termic al receptorului se modelează ca un proces aleator AWGN iar zgomotul rezultat în urma propagării undei electromagnetice se modelează ca un proces aleator multiplicativ.

2.2.2. Algoritmi de denoising

În cartea sa, [13], Mallat a declarat că estimarea semnalelor perturbate de zgomot aditiv este optimizată prin găsirea unei reprezentări care să discrimineze semnalul de zgomot.

Există o mare diversitate de estimatori folosiți ca sisteme de denoising. O trecere în revistă a unor astfel de sisteme poate fi găsită în [50]. Aceste sisteme se pot clasifica în două categorii: cele aplicate direct semnalului și cele care utilizează o transformată înainte de procesare. Din prima categorie, trebuie să menționăm sistemele de denoising propuse în [51] și [52]. Primul se bazează pe transformarea cosinus discretă adaptată la forma semnalului de prelucrat (SADCT), transformată care poate fi calculată pe un suport de formă arbitrară. Al doilea este un filtru Maximum a Posteriori (MAP) care acționează în domeniul spațial.

Operatorii liniari au predominat mult timp în aplicațiile de înlăturare a zgomotului datorită simplității lor, în ciuda performanțelor limitate. Este posibil să păstrăm simplitatea în timp ce îmbunătățim performanța folosind sisteme neliniare aplicate unei reprezentări rare a semnalului de prelucrat.

Optimalitatea estimatorilor cu prag (operatori de concentrare) este dovedită pentru semnale și imagini regulate (cu variație mărginită).

Criterii de evaluare a performanței

Eroarea medie pătratică (Mean Square Error-MSE) și raportul semnal pe zgomot de vârf (Peak Signal to Noise Ratio-PSNR) sunt cei doi indicatori de calitate utilizați cel mai frecvent pentru a evalua performanța unei metode de denoising atunci când componenta utilă a imaginii de prelucrat este cunoscută.

Cu cât valoarea MSE este mai mică, cu atât este mai mare PSNR. Pentru a calcula PSNR, se calculează mai întâi eroarea medie pătratică utilizând următoarea formulă:

$$MSE = \frac{\sum_{m=1, n=1}^{M, N} [I_o(m, n) - I_i(m, n)]^2}{M \cdot N} \quad (2.37)$$

unde I_i este componenta utilă a imaginii de intrare, I_o este imaginea de ieșire, M și N reprezintă numărul de linii și de coloane ale matricii care descrie imaginea de intrare. Apoi, PSNR este calculat folosind următoarea formulă:

$$PSNR = 10 \log_{10} \left(\frac{R^2}{MSE} \right) \quad (2.38)$$

unde R este fluctuația maximă a tipului de date din imaginea de intrare.

Un al treilea criteriu de evaluare a calității unei metode de prelucrare a imaginilor, care necesită cunoașterea componentei utile a imaginii achiziționate este indexul de similaritate structurală (Structural Similarity Index-SSIM) între componenta utilă a imaginii achiziționate X și rezultatul operației de denoising Y :

$$SSIM = \frac{(2\mu_X\mu_Y + 2.55)(2\sigma_{XY} + 7.65)}{(\mu_X^2 + \mu_Y^2 + 2.55)(\sigma_X^2 + \sigma_Y^2 + 7.65)} \quad (2.39)$$

unde μ_X și μ_Y sunt mediile statistice ale imaginilor X și Y , σ_X^2 și σ_Y^2 sunt varianțele imaginilor X și Y , iar σ_{XY} este covarianța imaginilor X și Y . Pot fi amintiți și indicatori de calitate care nu necesită cunoașterea componentei utile a imaginii achiziționate, cum ar fi numărul echivalent de vederi (Equivalent Number of Looks-ENL), cu ajutorul căruia poate fi apreciată calitatea prelucrării zonelor omogene din imagine sau indicele de evaluare a despecklizării (Despeckling Evaluation Index-DEI), cu ajutorul căruia poate fi apreciată calitatea prelucrării muchiilor din imagine. De asemenea, un indicator de calitate foarte sugestiv este zgomotul metodei (method's noise) care reprezintă raportul sau diferența dintre imaginea inițială și imaginea obținută prin prelucrare.

2.2.3. Medierea locală și ecuațiile cu derivate parțiale cu coeficienți constanți

Multe metode clasice de denoising a imaginilor se bazează pe o mediere locală. Valoarea unui pixel prelucrat este obținută ca medie a valorilor pixelilor vecini. Cel mai utilizat algoritm de mediere locală este filtrarea Gaussiană. În acest caz, valoarea unui pixel prelucrat se obține ca o medie ponderată în care ponderea fiecărui pixel depinde de distanța până la cel prelucrat. Acest filtru trece jos tinde să

estompeze imaginea. Acest lucru este cunoscut sub numele de „efect de mediere locală”.

Filtrele de mediere nelocală (Non Local Means-NLM), [53], evită efectul de estompere, restricționând media la pixeli (nu neapărat vecini) având o valoare similară a nivelului de gri. Ideea este că, valorile nivelului de gri dintr-o regiune omogenă fluctuează ușor, în timp ce pixelii aparținând unor regiuni omogene diferite au o diferență mai mare de nivel de gri. Principala dificultate a unei astfel de abordări constă în aprecierea similarității nivelurilor de gri ale pixelilor. O comparație pixel cu pixel pentru toți pixelii din imagine este foarte laborioasă, de aceea se recurge la comparații între regiuni de pixeli. Filtrul de vecinătate ia o medie ponderată a valorilor pixelilor cu niveluri de gri apropiate dintr-o vecinătate a pixelului de prelucrat. Ponderile se calculează pe baza similarității dintre regiuni. Similaritatea dintre regiuni este definită ca o distanță Euclidiană ponderată cu un nucleu Gaussian. Această măsură a similarității este potrivită pentru zgomot aditiv.

În cazul altor tipuri de zgomot, alte măsuri de similaritate sunt mai potrivite. De exemplu, în [54], în locul distanței Euclidiene se folosește o distanță stohastică.

O altă măsură a similarității dintre regiuni este propusă în [55]. Este vorba despre o abordare a contrariu, care necesită un model de referință. În [55] se alege un model de referință Gaussian. Se propune și un algoritm de detecție a redundanței regiunilor similare.

În general, filtrele de imagine pot fi mai bine înțelese prin stabilirea acțiunii lor asimptotice atunci când sunt făcute din ce în ce mai locale. Această acțiune este apoi descrisă printr-o ecuație diferențială cu derivate parțiale (Partial Differential Equation-PDE).

2.2.4. Minimizarea variației totale

Filtrarea bazată pe variația totală (Total Variation-TV) a fost introdusă de Rudin [19]. Este o metodă eficientă și robustă de filtrare pentru recuperarea regiunilor omogene. Mulți algoritmi au fost propuși pentru a implementa filtrarea prin minimizarea variației totale. Variația totală a unei imagini măsoară cât de mult se schimbă imaginea între eșantioanele sale consecutive. În mod explicit, variația totală a unei imagini digitale de N pixeli, $\mathbf{x}(n)$, $1 \leq n \leq N$ este definită ca:

$$TV(\mathbf{x}) = \sum_{n=2}^N |x(n) - x(n-1)| \quad (2.40)$$

Variația totală a lui \mathbf{x} poate fi scrisă și ca:

$$TV(\mathbf{x}) = \|\mathbf{D}\mathbf{x}\|_1 \quad (2.41)$$

unde:

$$\mathbf{D} = \begin{pmatrix} -1 & 1 & & \\ & -1 & 1 & \\ & & & \ddots \\ & & & & -1 & 1 \end{pmatrix} \quad (2.42)$$

este o matrice de dimensiune $(N-1) \times N$.

Presupunem că observăm imaginea \mathbf{x} coruptă de zgomotul aditiv alb Gaussian \mathbf{n} ,

$$\mathbf{y} = \mathbf{x} + \mathbf{n}, \quad \mathbf{y}, \mathbf{x} \in \mathbb{R}^N \quad (2.43)$$

O abordare pentru a estima \mathbf{x} este minimizarea funcției obiectiv:

$$J(\mathbf{x}) = \|\mathbf{y} - \mathbf{x}\|_2^2 + \lambda \|\mathbf{D}\mathbf{x}\|_1 \quad (2.44)$$

Această abordare se numește TV denoising. Parametrul de regularizare, λ , controlează cât de mult se efectuează netezirea lui \mathbf{y} . Nivelurile de zgomot mai mari necesită o valoare λ mai mare. Ultima ecuație reprezintă soluția unei probleme de optimizare convexă care apare în regularizarea rară a problemelor inverse [57]. λ se numește parametru de regularizare. Un volum impresionant de lucrări științifice a fost publicat recent de cercetători din diferite domenii având ca subiect proprietățile structurale ale acestui operator de minimizare [57]. Ecuația este atrăgătoare din punct de vedere computațional și poate fi rezolvată eficient [58]. În prelucrarea semnalelor și imaginilor această metodă de minimizare este cunoscută sub denumirea urmărirea bazei (Basis Pursuit-BP) [60]. În statistică, metoda este cunoscută sub numele LASSO [61].

2.2.5. Filtre în domeniul frecvență

Efectul medierii pixelilor cei mai apropiați din punct de vedere spațial poate fi obținut și în domeniul frecvență. Convoluția unei imagini cu un nucleu \mathbf{k} este echivalentă cu înmulțirea transformării sale Fourier cu \mathbf{K} . Medierea pixelilor apropiați spațial este atunci echivalentă cu atenuarea frecvențelor înalte. Această atenuare duce la estomparea imaginii și la un efect Gibbs. Filtrul optim din punct de vedere al erorii medii pătratice este filtrul Wiener, care nu anulează frecvențele înalte, dar atenuează toate frecvențele. Coeficienții Fourier de modul superior deviației standard a zgomotului rămân aproape nemodificați, în timp ce coeficienții cu o valoare mai mică a modulelor sunt atenuați. Prin utilizarea bazei Fourier, caracteristicile globale ale imaginii pot prevala asupra celor locale. Pentru a evita aceste efecte, baza trebuie să țină seama de mai multe caracteristici locale, așa cum fac transformata wavelet discretă și transformata cosinus discretă (Discrete Cosine Transform-DCT).

David Donoho a introdus cuvântul denoising în asociere cu teoria funcțiilor wavelet [56]. Estimatorii bazați pe operatori de concentrare (shrinking), care sunt neliniari, sunt studiați în bazele de pachete de funcții wavelet și în bazele de funcții wavelet și sunt utilizați pentru a suprima zgomotele aditive și a restabili semnalele degradate prin supra-netezire (oversmoothing), fenomen specific filtrelor trece-jos. Estimările neliniare din reprezentări rare sunt, de asemenea, studiate în [56] pentru a reduce incertitudinea estimării spectrului de putere.

Analiza multi-rezoluție efectuată de transformarea wavelet s-a dovedit a fi un instrument puternic în reducerea zgomotului. În domeniul wavelet, zgomotul este răspândit uniform în coeficienți, în timp ce cea mai mare parte a informațiilor despre imagine este concentrată în cei câțiva coeficienți de detalii de module mai mari (raritatea reprezentării wavelet). Cea mai simplă modalitate de a distinge informația de zgomot în domeniul wavelet constă în compararea coeficienților wavelet de detalii cu un prag. Filtrul soft thresholding (sth) este cel mai popular operator de concentrare pentru denoising [56]. Acest operator se folosește în cadrul unui algoritm de denoising în trei etape:

1. calculul transformării wavelet a semnalului achiziționat și separarea coeficienților de aproximare și de detalii,
2. filtrarea coeficienților wavelet de detalii cu un operator de concentrare,

3. concatenarea vechilor coeficienți de aproximare cu noii coeficienți de detalii și calculul transformării wavelet inverse a rezultatului obținut.

Donoho și Johnstone folosesc DWT și filtrul stf în [56]. Deoarece singura ipoteză explicită care se face asupra componentei utile a imaginii achiziționate este că este suficient de netedă, rezultă că această metodă de denoising este neparametrică. Această metodă este eficientă dacă zgomotul este AWGN. Filtrul stf este folosit pentru a anula toți coeficienții wavelet de detalii cu valoarea absolută mai mică decât valoarea unui prag. Valoarea acestui prag este selectată pentru a minimiza eroarea de aproximare minimax a componentei utile a imaginii achiziționate. În consecință, în ceea ce privește algoritmul de denoising în trei pași, există două caracteristici de ales: transformarea wavelet și pragul filtrului.

În [42], [62] a fost utilizată UDWT, în [33], [63], [64] DTCWT și în [65], [59], DWT. În ceea ce privește a doua alegere, în domeniul wavelet pot fi utilizate numeroase tipuri de filtre neliniare.

O posibilă clasificare a acestor filtre se bazează pe natura componentei fără zgomot a imaginii care urmează să fie procesată. Practic, există două categorii de filtre: cele construite presupunând doar cunoașterea statisticilor de zgomot (o abordare non-parametrică) și cele bazate pe cunoașterea atât a statisticilor de semnal cât și de zgomot (o abordare parametrică). Din prima categorie pot fi menționate: filtrul hard thresholding (hth) [56], filtrul soft thresholding (stf) [56], [13], care minimizează eroarea de estimare minimax și filtrul care minimizează eroarea estimatorului de risc nepolarizat al lui Stein (Stein's Unbiased Risk Estimator-SURE) [59].

Din a doua categorie fac parte filtrele obținute prin minimizarea unui risc Bayesian exprimat sub forma unei funcții de cost, de obicei o funcție delta (estimare MAP [33], [42], [63], sau eroarea medie pătratică (Minimum Mean Square Error-MMSE [62]). Coeficienții wavelet ai unei imagini au o distribuție statistică cu coadă grea (Laplace, Pearson sau $S\alpha S$). Distribuția statistică a coeficienților wavelet se modifică de la sub-bandă la sub-bandă și de la scară la scară. Algoritmii de denoising propuși în [33], [59], [62], [63], [65], exploatează dependența interscară a coeficienților wavelet de detalii. Metoda propusă în [62] ia în considerare și dependența intra-scară a coeficienților wavelet. Pentru a face față acestei dinamici, există două soluții. Prima presupune utilizarea unui model simplu fix pentru toate sub-benzile și toate scările, riscând o scădere a preciziei estimatorului. În acest fel, există șansa de a obține o formă explicită a relației intrare-ieșire pentru filtrul MAP. O astfel de relație intrare-ieșire are două avantaje: simplifică implementarea filtrului și permite analiza sensibilității acestuia la variațiile parametrilor săi. A doua soluție presupune utilizarea unui model generalizat, definit printr-o familie de distribuții și identificarea celui mai potrivit element al acestei familii pentru distribuția coeficienților wavelet într-o sub-bandă și la o scară dată (de exemplu, familia distribuțiilor Pearson din [42], familia distribuțiilor $S\alpha S$ în [63] și modelul câmpului aleator Gauss-Markov în [65]). Utilizarea unui model generalizat face prelucrarea mai precisă, dar necesită soluții implicite pentru ecuația filtrului MAP, care poate fi adesea rezolvată doar numeric.

2.2.6. Metoda neparametrică

Termenul „neparametric” este utilizat pentru a defini toate metodele dezvoltate fără o cunoaștere a priori a distribuției statistice a semnalului care

urmează să fie procesat. Această abordare neparametrică este motivată de faptul că, în majoritatea situațiilor practice, distribuția semnalelor care compun observația nu este cunoscută și este dificil de estimat cu precizie.

Chiar dacă nu avem nici o informație cu privire la distribuția statistică a semnalului de estimat, este posibil să estimăm satisfăcător acest semnal dacă avem o metodă care permite discriminarea de zgomot. Se știe că proiecția zgomotului AWGN pe o bază ortonormală nu modifică natura zgomotului. Dacă dispunem de o bază ortonormală capabilă să „concentreze” energia componentei utile a semnalului achiziționat într-un număr mic de elemente ale bazei, care vor fi ponderate cu coeficienți de descompunere de valoare mare, atunci descompunerea observației într-o astfel de bază va fi compusă dintr-o clasă mică de termeni având coeficienți de ponderare relativ mari (conținând în principal informații despre componenta utilă a semnalului) și o clasă mare de termeni având coeficienți de ponderare relativ mici (care se datorează în principal zgomotului). Estimarea componentei utile a semnalului achiziționat implică recuperarea și, în cele din urmă, prelucrarea coeficienților mari, după anularea celor mici. O astfel de estimare se realizează prin compararea valorilor coeficienților descompunerii semnalului achiziționat cu o valoare de prag și anularea acelor coeficienți care au modulul mai mic decât valoarea de prag. Se spune că o bază capabilă să concentreze o mare parte din energia imaginii într-un număr mic de elemente ponderate de coeficienți de descompunere de valori mari face o reprezentare rară a imaginii [56]. Această definiție nu este cu adevărat precisă, deoarece termenii „mic” și „mare” nu sunt clar definiți, rezultând o reprezentare rară în sens larg. Se poate spune despre o bază că realizează o reprezentare rară în sens strict dacă, pentru un semnal dat, energia acestui semnal este „în întregime” conținută într-un număr mic de elemente ponderate de coeficienți de valori mari. În acest tip de raritate, toți coeficienții calificați drept „mici” sunt de fapt nuli și prin urmare nu conțin informații asupra semnalului achiziționat. În cazul reprezentării rare în sens larg, ar putea fi util să se proceseze uniform coeficienții mici. În acest caz, anularea elementelor cu coeficienți mai mici decât valoarea de prag poate fi înlocuită cu o atenuare selectivă, în sensul că nu se anulează toate elementele având coeficienți mici, ci li se impune o atenuare mai mare decât atenuarea care se impune elementelor care au coeficienți mari.

Pentru a realiza estimarea neparametrică, care tocmai a fost descrisă, trebuie aleasă o reprezentare rară și o funcție de atenuare adecvată.

2.2.6.1. Filtrul Soft thresholding

Algoritmul de denoising în trei pași propus de Donoho și Johnstone [56], menționat deja, folosește DWT și sth.

Relația intrare-ieșire a sth este:

$$\hat{W}_s(W_x) = \begin{cases} W_x - t, & W_x > t \\ 0, & |W_x| \leq t \\ W_x + t, & W_x < -t \end{cases} \quad (2.45)$$

unde $W_x = W_s + W_n$, iar t este pragul.

W_x reprezintă secvența coeficienților wavelet de detalii ai imaginii achiziționate (zgomotoasă), W_s reprezintă secvența coeficienților de detalii ai componentei fără zgomot (utilă) a imaginii achiziționate și W_n reprezintă secvența coeficienților

wavelet ai zgomotului din imaginea achiziționată. Intervalul $(-t, t)$ se numește zonă moartă, deoarece toți coeficienții wavelet de detalii care au valorile în acest interval sunt anulați de sth.

De obicei valoarea pragului t este aleasă în funcție de valoarea deviației standard a zgomotului. Varianța zgomotului poate fi estimată în domeniul wavelet utilizând relația:

$$\hat{\sigma}_{W_n}^2 = \frac{\text{median}(|W_x|)}{0.6745}, \quad W_x \in D_1^3 \quad (2.46)$$

unde D_1^3 reprezintă sub-imaginea de detalii diagonale de la primul nivel de descompunere al transformării wavelet discrete a imaginii achiziționate. În cazul minimizării erorii de aproximare minimax, constanta care înmulțește deviația standard a zgomotului pentru a obține valoarea de prag t este egală cu $\sqrt{2 \ln N}$, unde N reprezintă numărul de pixeli ai imaginii observate.

2.2.6.2. Filtrul Hard-Thresholding

Un alt tip de filtru neparametric este filtrul Hard-Thresholding (HTH). Acesta este, de asemenea, un operator de concentrare. Relația intrare-ieșire a acestui filtru este:

$$\text{hard}(y, t) = (|y| - t)_+ = \begin{cases} y, & |y| \geq t \\ 0, & |y| < t \end{cases} \quad (2.47)$$

unde

$$(X)_+ = \begin{cases} X, & X > 0 \\ 0, & \text{în rest} \end{cases} \quad (2.48)$$

Și acest filtru are o zonă moartă.

2.2.7. Metoda parametrică

Scopul procesului de denoising este îmbunătățirea calității vizuale a imaginii achiziționate și, în mod ideal, recuperarea exactă a componentei utile. Din punct de vedere matematic, este necesar să se minimizeze eroarea dintre imaginea prelucrată și componenta utilă a imaginii originale. Această eroare este scrisă ca o distanță și, pentru simplitate, poate fi utilizată distanța Euclidiană. Pentru a optimiza procesul de restaurare, definiția unei astfel de erori ar trebui să încorporeze informațiile a priori despre imaginea originală și zgomot, atunci când sunt disponibile.

2.2.7.1. Filtre Maximum A Posteriori (MAP)

Vom începe prin prezentarea caracteristicilor generale ale estimării Bayesiene atât în domeniul spațial, cât și în cel al coeficienților wavelet.

a) Filtre MAP în domeniul spațial

Fie $\mathbf{x} = \mathbf{s} + \mathbf{n}$, unde \mathbf{s} este componenta utilă a imaginii achiziționate, \mathbf{n} este zgomotul și \mathbf{x} este imaginea achiziționată. Problema constă în a estima \mathbf{s} când

singurele date disponibile sunt \mathbf{x} . Ne interesează densitatea de probabilitate a estimatei $\hat{\mathbf{s}}$ fiind date măsurătorile \mathbf{x} , adică $p(\hat{\mathbf{s}}|\mathbf{x})$. Aceasta se numește distribuție a posteriori a lui $\hat{\mathbf{s}}$ și conține toată informația pe care putem să o inferăm despre un \mathbf{x} dat. Dacă distribuția a posteriori a lui $\hat{\mathbf{s}}$ este unimodală având o singură valoare maximă S atunci am putea alege drept estimată a lui \mathbf{s} valoarea S care maximizează distribuția a posteriori. Aceasta se numește estimată MAP. Să remarcăm că aceasta distribuție ne spune chiar mai mult. Există un interval de valori ale lui $\hat{\mathbf{s}}$ care apar cu probabilități destul de mari. Acesta poate fi privit ca interval de încredere pentru estimată.

Teorema lui Bayes permite calculul probabilității a posteriori $p_{S/X}(s|x)$ pe baza probabilității a priori $p_{X/S}(x|s)$:

$$p_{S/X}(s|x) = \frac{p_{X/S}(x|s) \cdot p_S(s)}{p_X(x)} \quad (2.49)$$

unde $p_S(s)$ este densitatea de probabilitate a componentei utile a imaginii achiziționate, iar $p_X(x)$ este densitatea de probabilitate a imaginii achiziționate. Distribuția a priori a componentei utile a imaginii achiziționate $p_S(s)$ înmagazinează toate cunoștințele pe care le avem înaintea efectuării măsurărilor. Densitatea de probabilitate a priori este mai ușor de calculat decât densitatea de probabilitate a posteriori, reprezentând funcția de plauzibilitate a imaginii \mathbf{s} fiind dată imaginea \mathbf{x} , $L(\mathbf{s}) = p_{X|S}(x|s)$. În cazul problemei de față, $\mathbf{x} = \mathbf{s} + \mathbf{n}$, iar inferența $\hat{\mathbf{s}} = S$ implică faptul că zgomotul poate fi exprimat ca $\mathbf{n} = \mathbf{x} - S$ și funcția de plauzibilitate a lui \mathbf{s} devine egală cu $L(\mathbf{s}) = p(\mathbf{x}|\mathbf{s} = S) = p_n(\mathbf{x} - \mathbf{s})$, unde p_n reprezintă densitatea de probabilitate a zgomotului, considerat AWGN (independent).

Numitorul $p_X(x)$ din membrul drept al ecuației (2.49) se numește evidență și este necesar ca factor de normalizare. Odată observația făcută, valoarea sa este constantă și adesea poate fi ignorat.

Estimarea MAP a lui \mathbf{s} , bazată pe observația $\mathbf{x} = \mathbf{s} + \mathbf{n}$ este descrisă de ecuația

$$\hat{\mathbf{s}}(\mathbf{x}) = \arg \max_{\mathbf{s}} \{ \ln [p_n(\mathbf{x} - \mathbf{s}) p_S(\mathbf{s})] \} \quad (2.50)$$

b) Filtre MAP în domeniul wavelet

Criteriul MAP poate fi aplicat și în domeniul coeficienților wavelet. Dacă luăm în considerare imaginea achiziționată $\mathbf{x} = \mathbf{s} + \mathbf{n}$, întrucât transformata wavelet este o transformare liniară, vom obține următoarele relații între coeficienții wavelet de aproximare (A) și coeficienții wavelet de detalii (W) de la nivelul de descompunere j :

$$\begin{aligned} A_X^j &= A_S^j + A_n^j \\ W_X^j &= W_S^j + W_n^j \end{aligned} \quad (2.51)$$

În cele ce urmează se vor lua în considerare doar coeficienții wavelet de detalii. Prin repetarea aceluiași considerații expuse anterior, funcția de densitate de probabilitate a posteriori a coeficienților wavelet de detalii ai semnalului fără zgomot este $p_{W_X|W_S}(W_X|W_S)$. Prin urmare, aplicând regula lui Bayes și luând în considerare zgomotul independent de semnal, avem:

$$\begin{aligned}
 p_{W_S|W_X}(W_S | W_X) &= \frac{p_{W_X|W_S}(W_X | W_S) \cdot p_{W_S}(W_S)}{p_{W_X}(W_X)} \\
 &= \frac{p_{W_n}(W_X - W_S) \cdot p_{W_S}(W_S)}{p_{W_X}(W_X)}.
 \end{aligned} \tag{2.52}$$

Estimarea MAP a lui \mathbf{W}_s , bazată pe observația \mathbf{W}_x este descrisă de ecuația:

$$\hat{W}_s(W_x) = \underset{W_s}{\operatorname{argmax}} \left\{ \ln \left[p_{W_n}(W_x - W_s) p_{W_S}(W_s) \right] \right\}. \tag{2.53}$$

2.2.7.1.2. Filtrul Wiener

Filtrul Wiener reduce zgomotul care afectează imaginea utilă comparând imaginea achiziționată cu o estimare a componentei sale utile și minimizând eroarea medie pătratică, în acest sens filtrul Wiener putând fi considerat un filtru MMSE. În cele ce urmează voi lua în considerare, pentru simplitate, secvențe din domeniul spațial, dar ecuațiile deduse sunt valabile și în domeniul coeficienților wavelet.

Fie $x=s+n$ imaginea observată aplicată la intrarea filtrului Wiener cu răspunsul la impuls h . Estimarea dată de filtru va fi:

$$\hat{s}[k] = (x * h)[k] = \sum_{i=0}^N h_i x[k-i] \tag{2.54}$$

Eroarea estimării este:

$$e[k] = \hat{s}[k] - s[k] = \sum_{i=0}^N h_i x[k-i] - s[k] \tag{2.55}$$

Coeficienții filtrului, adică elementele vectorului h , sunt soluțiile ecuației:

$$h_i = \operatorname{argmin} \{ E \{ e^2[k] \} \}, \tag{2.56}$$

unde cu E s-a notat operatorul de mediere statistică. Aceasta este o problemă de optimizare convexă, deoarece funcția de cost $E \{ e^2[k] \}$ este convexă în raport cu necunoscutele h_i , $i = 0, 1, \dots, N$. Pentru rezolvarea acestei probleme, se rezolvă sistemul de ecuații obținut prin egalarea cu zero a derivatelor erorii medii pătratice în raport cu necunoscutele h_i :

$$\mathbf{R} \mathbf{x} \mathbf{h} = \mathbf{r} \tag{2.57}$$

unde \mathbf{R} reprezintă matricea de autocorelație a imaginii achiziționate (este o matrice Toeplitz) iar \mathbf{r} reprezintă matricea de intercorelație dintre imaginea achiziționată și estimata căutată. În cazul în care se respectă următoarele ipoteze:

- imaginile \mathbf{s} și \mathbf{n} sunt necorelate;
- imaginea \mathbf{n} este un zgomot AWGN de două variabile de medie nulă și de varianță σ_n^2 ;
- componenta utilă a imaginii achiziționate este un proces aleator de tip zgomot alb Gaussian de medie nulă și varianță σ^2 ;

expresia eșantioanelor răspunsului la impuls al filtrului Wiener (numit în acest caz filtru Wiener de ordinul zero) obținută rezolvând sistemul de ecuații (2.57) devine:

$$h(\alpha, \beta) = \frac{\sigma^2}{\sigma^2 + \sigma_n^2} \delta(\alpha, \beta) \quad (2.58)$$

Acest filtru Wiener poate fi privit și ca și un filtru MAP, dacă se consideră densitățile de probabilitate:

$$p_S(s) = \frac{1}{(2\pi)^{\frac{1}{2}} |C_S|^{\frac{1}{2}}} \cdot e^{-\frac{s^T \cdot C_S^{-1} \cdot s}{2}} \quad \text{și} \quad p_n(n) = \frac{1}{(2\pi)^{\frac{1}{2}} |C_n|^{\frac{1}{2}}} \cdot e^{-\frac{n^T \cdot C_n^{-1} \cdot n}{2}} \quad (2.59)$$

unde s-a notat cu $|C_s|$ determinantul matricii de covarianță a imaginii s și cu $|C_n|$ determinantul matricii de covarianță a imaginii n, în ecuația (2.50). Acestea sunt densitățile de probabilitate ale unor procese aleatoare Gaussiene de două variabile și de varianță σ^2 respectiv σ_n^2 . Folosind definiția normei l^p pentru imagini digitale,

$$\|z\|_p^p = \sum_{k=1}^p |z_k| \quad (2.60)$$

cele două densități de probabilitate din relația (2.59) pot fi exprimate ca:

$$p_S(s) = \frac{1}{2\pi\sigma^2} e^{-\frac{\|s\|_2^2}{2\sigma^2}} \quad \text{și} \quad p_n(n) = \frac{1}{2\pi\sigma_n^2} e^{-\frac{\|n\|_2^2}{2\sigma_n^2}} \quad (2.61)$$

Unul dintre avantajele transformărilor wavelet este că nu corelează imaginile. Dacă dispunem de o imagine descrisă printr-un proces aleator de tipul zgomot alb Gaussian de medie nulă și de varianță σ_n^2 , transformata DWT bidimensională a acelei imagini va fi tot un zgomot alb Gaussian de medie nulă și de aceeași varianță. În consecință, din punct de vedere al zgomotului, aplicarea filtrului Wiener de ordinul 0 în domeniul wavelet este o idee bună. Din păcate, modelul Gaussian nu este potrivit și pentru coeficienții wavelet ai componentei utile a imaginii.

2.2.7.1.3. Filtrul soft thresholding văzut ca filtru MAP

Dacă alegem valoarea pragului filtrului soft-thresholding egală cu:

$$t = \frac{\sqrt{2}\sigma_n^2}{\sigma}, \quad (2.62)$$

unde s-a notat cu σ deviația standard a imaginii utile, acesta devine echivalent cu un filtru MAP, corespunzător unei distribuții Laplace bidimensionale pentru coeficienții wavelet de detalii ai imaginii utile:

$$p_{W_S}(W_S) \approx e^{-\frac{\sqrt{2}\|W_S\|_1}{\sigma}}, \quad (2.63)$$

și unei distribuții Gaussiene bidimensionale pentru imaginea de zgomot:

$$p_{W_n}(W_n) = \frac{1}{2\pi\sigma_n^2} e^{-\frac{\|W_n\|_2^2}{2\sigma_n^2}} \quad (2.64)$$

În continuare vom denumi acest filtru Adaptive Soft Thresholding Filter (ASTF). Modelul Laplace-ian este mult mai potrivit pentru coeficienții wavelet ai componentei utile a imaginii decât modelul Gaussian, [73]. De aceea filtrul ASTF se dovedește superior filtrului Wiener de ordinul 0 în îndepărtarea zgomotului AWGN care perturbă imaginile folosind funcții wavelet. Cu notația $\lambda = \frac{2\sqrt{2}\sigma_n^2}{\sigma}$, soluția ecuației filtrului MAP (2.53), corespunzător densităților de probabilitate (2.63) și (2.64), poate fi pusă în forma:

$$\hat{W}_s(W_x) \approx \arg \min_{W_s} \left\{ \|W_x - W_s\|_2^2 + \lambda \|W_s\|_1 \right\} \quad (2.65)$$

care reprezintă problema de optimizare convexă specifică regularizării rare pentru probleme inverse amintită în paragraful 2.2.4 sub denumirea de Basis Pursuit sau LASSO. Iată cum, filtrul sth unifică trei probleme de optimizare: minimax, Bayesiană și convexă.

2.2.7.1.4. Filtrul Bishrink

Densitatea de probabilitate Laplace-iană din relația (2.63) este o funcție de două variabile, construită ca produs a două densități de probabilitate Laplace-iene unidimensionale, care caracterizează variabile aleatoare independente. Această densitate de probabilitate nu ține seama de dependența între scări succesive a coeficienților wavelet de detalii cu aceleași coordonate geometrice. Această dependență a fost considerată și în [82]. În [33] a fost propusă următoarea densitate de probabilitate Laplace-iană, pentru a descrie distribuția coeficienților wavelet de detalii ai componentei utile a imaginii achiziționate:

$$p_{W_s}(W_s) \approx \frac{3}{2\pi\sigma^2} e^{-\frac{\sqrt{3}\|W_s\|_2}{\sigma}}, W_s = [W_{s_1}, W_{s_2}] \quad (2.66)$$

Considerând că densitatea de probabilitate a zgomotului este descrisă de relația:

$$p_{W_n}(W_n) = \frac{1}{2\pi\sigma_n^2} e^{-\frac{\|W_n\|_2^2}{2\sigma_n^2}}, W_n = [W_{n_1}, W_{n_2}] \quad (2.67)$$

În [33] a fost construit filtrul MAP numit bishrink, pe baza relațiilor (2.53), (2.66) și (2.67), obținându-se următoarea relație intrare-ieșire:

$$\hat{W}_{s_1} = \frac{\left(\sqrt{W_{x_1}^2 + W_{x_2}^2} - \frac{\sqrt{3}\sigma_n^2}{\sigma} \right)}{\sqrt{W_{x_1}^2 + W_{x_2}^2}} \pm W_{x_1} \quad (2.68)$$

În relațiile (2.66), (2.67) și (2.68) au fost indexați cu 1 coeficienții wavelet părinți iar cu indice 2 au fost indexați coeficienții wavelet copii. Coeficienții wavelet părinți se găsesc la aceleași coordonate geometrice ca și coeficienții wavelet copii dar la scara următoare scării la care se găsesc coeficienții wavelet copii. Performanțele filtrului bishrink sunt superioare performanțelor filtrului ASTF tocmai datorită faptului că în cazul filtrului bishrink se iau în considerare dependențele statistice dintre coeficienții părinți și coeficienți copii, pe când în cazul filtrului ASTF coeficienții copii se consideră independenți de coeficienții părinți.

2.2.7.1.5. Alte filtre MAP

La fel ca în cazul filtrului bishrink și în cazul filtrului MAP propus în [63] este luată în considerare dependența părinte-copil a coeficienților wavelet de detalii în expresiile densităților de probabilitate bidimensionale ale componentei utile a imaginii achiziționate, respectiv a zgomotului. Densitatea de probabilitate a coeficienților wavelet de detalii ai zgomotului are expresia din relația (2.67) iar pentru densitatea de probabilitate a coeficienților wavelet de detalii ai componentei utile a imaginii achiziționate se consideră o distribuție Cauchy izotropă:

$$p_{W_s}(W_s) = \frac{\gamma}{2\pi \left(\|W_s\|_2^2 + \gamma^2 \right)^{\frac{3}{2}}} \quad (2.69)$$

unde γ reprezintă dispersia distribuției. Rezolvarea ecuației (2.53) în cazul folosirii modelelor statistice (2.67) și (2.69) revine la rezolvarea unei ecuații algebrice de gradul al treilea, în acest caz.

În [42] este propusă o metodă de denoising bazată pe asocierea dintre UDWT și un filtru MAP construit folosind un model statistic de tip Pearson. Atât componenta utilă a imaginii achiziționate cât și zgomotul sunt modelate ca variabile aleatoare Pearson, iar rezolvarea ecuației (2.53) revine la rezolvarea unei ecuații algebrice de gradul al treilea.

În [82] este propusă o metodă de denoising a imaginilor care asociază UDWT cu un filtru MAP construit folosind procese aleatoare de tipul Gaussiană generalizată. Soluția ecuației (2.53) nu are formă analitică, aceasta nefiind o ecuație algebrică, poate fi rezolvată doar cu metode numerice.

În [83] este propusă o metodă de denoising bazată pe asocierea dintre transformata DWT bidimensională și un filtru MAP construit cu un model statistic Student pentru coeficienții wavelet de detalii ai componentei utile a imaginii achiziționate. Repartiția coeficienților de detalii ai zgomotului se presupune Gaussiană de medie nulă.

Alte filtre MAP pot fi construite folosind diferite ipoteze pentru ecuația (2.53). În [84] este prezentat un mecanism pentru a lua în considerare dependența intra-scară a coeficienților wavelet de detalii.

Un alt filtru MAP acționând în domeniul funcțiilor wavelet este propus în [65].

2.2.7.1.6. Echivalența dintre filtrele MAP și problemele de optimizare convexă

În [57] se demonstrează că problemele de regularizare, care reprezintă un caz particular de optimizare convexă, sunt echivalente cu filtrele MAP. De exemplu, așa cum am afirmat deja la sfârșitul paragrafului 2.2.7.1.3, regularizarea LASSO este echivalentă cu filtrul MAP de tip ASTF. În continuare se justifică această

afirmație. Pentru $\lambda = \frac{2\sqrt{2}\sigma_n^2}{\sigma}$, putem exprima membrul drept al ecuației (2.65) (care descrie problema regularizării LASSO) ca:

$$\begin{aligned} \hat{W}_S(W_X) &\sim \underbrace{\operatorname{argmin}}_{W_S} \left\{ \|W_X - W_S\|_2^2 + \frac{2\sqrt{2}\sigma_n^2}{\sigma} \|W_S\|_1 \right\} = \\ &= \underbrace{\operatorname{argmin}}_{W_S} \left\{ 2\sigma_n^2 \left[\frac{\|W_X - W_S\|_2^2}{2\sigma_n^2} + \frac{\sqrt{2}}{\sigma} \|W_S\|_1 \right] \right\} \end{aligned} \quad (2.70)$$

Deci:

$$\hat{W}_S(W_X) \sim \underbrace{\operatorname{argmin}}_{W_S} \left\{ \frac{\|W_X - W_S\|_2^2}{2\sigma_n^2} + \frac{\sqrt{2}}{\sigma} \|W_S\|_1 \right\} \quad (2.71)$$

deoarece $2\sigma_n^2$ este o constantă pozitivă. Căutarea minimumului unei variabile poate fi transformată în căutarea maximumului diferenței dintre o constantă și acea variabilă.

Alegând constanta $\log\left(\frac{1}{2\pi\sigma_n^2}\right) + \log\left(\frac{2}{2\pi\sigma^2}\right)$ ecuația anterioară devine:

$$\hat{W}_S(W_X) \sim \underbrace{\operatorname{argmin}}_{W_S} \left\{ \log\left(\frac{1}{2\pi\sigma_n^2}\right) + \log\left(\frac{1}{2\pi\sigma^2}\right) - \frac{\|W_X - W_S\|_2^2}{2\pi\sigma^2} - \frac{\sqrt{2}}{\sigma} \|W_S\|_1 \right\} \quad (2.72)$$

Exprimând ultimii doi termeni ai argumentului din membrul drept ca logaritmi naturali de exponențiale:

$$-\frac{\|W_X - W_S\|_2^2}{2\sigma_n^2} = \log e^{-\frac{\|W_X - W_S\|_2^2}{2\sigma_n^2}} \quad \text{și} \quad -\frac{\sqrt{2}}{\sigma} \|W_S\|_1 = \log e^{-\frac{\sqrt{2}}{\sigma} \|W_S\|_1} \quad (2.73)$$

ultima ecuație devine:

$$\hat{W}_S(W_X) \sim \underset{W_S}{\operatorname{arg\,max}} \left\{ \log \left(\frac{1}{2\pi\sigma_n^2} \right) + \log \left(\frac{2}{2\pi\sigma^2} \right) + \log \left(e^{-\frac{\|W_X - W_S\|_2^2}{2\pi\sigma^2}} \right) + \log \left(e^{-\frac{\sqrt{2}}{\sigma} \|W_S\|_1} \right) \right\} \quad (2.74)$$

sau, aplicând operațiile algebrice pentru logaritmi:

$$\hat{W}_S(W_X) \sim \underset{W_S}{\operatorname{arg\,max}} \left\{ \log \frac{1}{2\pi\sigma_n^2} e^{-\frac{\|W_X - W_S\|_2^2}{2\sigma_n^2}} \frac{2}{2\pi\sigma^2} e^{-\frac{\sqrt{2}}{\sigma} \|W_S\|_1} \right\} \quad (2.75)$$

în care recunoaștem definiția filtrului MAP (descrisă în relația (2.53)) de tipul ASTF, având ca argument al logaritmului din membrul drept produsul dintre densitățile de probabilitate ale componentei fără zgomot a transformatei wavelet a imaginii achiziționate și a zgomotului din relațiile (2.63) și (2.64). Deci regularizarea LASSO este echivalentă cu filtrarea MAP folosind filtrul ASTF. În mod asemănător se poate demonstra că regularizarea Tihonov este echivalentă cu filtrarea Wiener de ordinul zero. Aceste echivalențe au transferat problema înlăturării zgomotului în domeniul optimizării convexe, obținându-se numeroase rezultate noi în: [66], [67], [68], [69], [70] și [71]. Există și metode de denoising bazate pe optimizare neconvexă [72].

2.2.8. Global sau local

Toate filtrele MAP descrise prelucrează pe rând fiecare coeficient wavelet de detalii al imaginii achiziționate. Considerând că și rezultatul aplicării transformării wavelet imaginii achiziționate este tot o imagine, filtrele MAP descrise prelucrează pixel după pixel această imagine.

În paragrafele anterioare au fost prezentate câteva filtre MAP aplicate în domeniul funcțiilor wavelet, care nu iau în considerare dependența părinte-copil a coeficienților wavelet. În cazul acestor filtre, modelele statistice folosite pentru coeficienții wavelet de detalii ai componentei utile a imaginii achiziționate respectiv pentru coeficienții wavelet de zgomot sunt unidimensionale. Astfel de filtre MAP se numesc marginale.

Pentru a putea aplica aceste filtre este necesară estimarea parametrilor densităților de probabilitate: σ și σ_n . Dacă acești parametri sunt estimați o singură dată pentru întreaga imagine, filtrul MAP corespunzător se numește global. Rezultate mai bune de estimare a componentei utile a imaginii achiziționate pot fi obținute dacă se folosesc filtre MAP locale. În cazul acestora se fac estimări locale

ale parametrilor densității de probabilitate a coeficienților wavelet de detalii ai componentei utile a imaginii achiziționate. Acești parametri sunt estimați în ferestre alunecătoare la fiecare nivel de descompunere și în fiecare sub-bandă. Pot fi folosite ferestre dreptunghiulare (de exemplu de dimensiune 5x5) sau ferestre eliptice, având axele principale paralele cu direcțiile preferențiale ale sub-benzilor transformării wavelet folosite pentru a favoriza selectivitatea direcțională a metodei de denoising. Estimările locale ale parametrilor densității de probabilitate a coeficienților wavelet de detalii ai componentei utile a imaginii achiziționate îmbunătățesc calitatea denoising-ului și în cazul în care se folosesc filtre MAP care iau în considerare dependența părinte-copil a coeficienților wavelet de detalii, dar în acest caz în locul ferestrelor alunecătoare se folosesc vecinătăți tri-dimensionale alunecătoare, care includ și coeficienți părinți.

2.2.9. Alte metode Bayes-iene de denoising

În [85] se descrie o metodă de reducerea zgomotului conținut în imagini digitale bazată pe modelarea statistică a coeficienților obținuți prin descompunerea imaginii achiziționate într-o bază supra-completă conținând elemente de la mai multe scări cu orientări preferențiale diferite. Această descompunere este denumită piramidă dirijabilă.

2.2.9.1. Algoritmul BLS-GSM

Imaginea achiziționată este împărțită în sub-benzi cu ajutorul unor filtre separabile în coordonate polare în domeniul frecvență. Sub-benzile obținute au o lățime de o octavă în domeniul scării. Din punct de vedere al orientărilor preferențiale, mulțimea filtrelor la o anumită scară acoperă un subspațiu invariant la rotații. Această descompunere poate fi privită drept o transformare wavelet invariantă la translații având o selectivitate direcțională foarte bună. Dependențele intra-scară și inter-scară ale coeficienților obținuți prin aplicarea piramidei dirijabile unei imaginii achiziționate pot fi modelate statistic cu procese Gaussiene la diferite scări amestecate (Gauss Scales Mixtures - GSM).

Pentru o imagine coruptă de AWGN de varianță σ_n^2 , un vector \mathbf{y} corespunzând unei vecinătăți formată din d coeficienți ai reprezentării piramidale poate fi exprimat folosind modelul GSM ca:

$$\mathbf{y} = \mathbf{w} + \mathbf{n} = \sqrt{z} \cdot \mathbf{x} + \mathbf{n} \quad (2.76)$$

unde \mathbf{w} este reprezentarea piramidală a vecinătății corespunzătoare a componentei utile a imaginii achiziționate iar \mathbf{n} este reprezentarea piramidală a aceleiași vecinătăți a componentei de zgomot a imaginii achiziționate. Pentru o vecinătate mică de coeficienți, un vector GSM, \mathbf{w} este produsul a două variabile aleatoare independente: un scalar pozitiv z numit multiplicator ascuns sau variabilă de mixare și un vector aleator Gaussian \mathbf{x} . Cele trei variabile aleatoare din membrul drept al ecuației (2.76) sunt independente. Atât \mathbf{x} cât și \mathbf{n} sunt vectori Gaussieni de valoare medie nulă și de matrici de covarianță \mathbf{C}_x și \mathbf{C}_n .

În cazul acestui model estimata Bayesiană a celor mai mici pătrate (Bayesian least squares-BLS) a fiecărui coeficient se reduce la o medie ponderată a estimatelor liniare locale obținute cu toate valorile posibile ale variabilei de mixare z . Pentru fiecare vecinătate, coeficientul din centrul vecinătății w_c , trebuie estimat din \mathbf{y} , mulțimea coeficienților observați. Estimata BLS este tocmai media condiționată:

$$\begin{aligned}
E\{w_C | y\} &= \int_{-\infty}^{\infty} w_C p(w_C | y) dw_C = \int_{-\infty}^{\infty} \int_0^{\infty} w_C p(w_C, z | y) dz dw_C = \quad (2.77) \\
&= \int_{-\infty}^{\infty} \int_0^{\infty} w_C p(w_C | y, z) p(z | y) dz dw_C = \int_0^{\infty} E(w_C | y, z) \cdot p(z | y) dz
\end{aligned}$$

Pentru a găsi toate valorile lui w_C , ecuația (2.77) trebuie aplicată pixel după pixel. Pentru a calcula integrala din membrul drept al ecuației (2.77) trebuie calculați cei doi factori ai integrandului.

Calculul primului factor se bazează pe un avantaj cheie al modelului GSM, vectorul coeficienților vecini \mathbf{x} este Gaussian atunci când este condiționat de z . Acest fapt, cuplat cu ipoteza AWGN înseamnă că valoarea medie $E\{x_C | y\}$ este o simplă estimată Wiener locală. Forma matricială a estimatorului Wiener local este:

$$\hat{\mathbf{w}} = \mathbf{C}_w \cdot (\mathbf{C}_w + \mathbf{C}_n)^{-1} \cdot \mathbf{y} \quad (2.78)$$

Luând în considerare modelul GSM și independența variabilelor aleatoare z și \mathbf{x} , rezultă că $\mathbf{C}_w = z\mathbf{C}_x$ deoarece se presupune că z variază destul de încet pentru a putea fi considerată constantă pe vecinătatea de coeficienți considerată. Deci, în acea vecinătate, \mathbf{x} este o variabilă aleatoare Gaussiană multidimensională cu varianță unitară iar \mathbf{w} este o transformare afină a lui \mathbf{x} . Covarianța variabilei aleatoare obținută prin aplicarea transformării afine considerate este $(\sqrt{z})^T \cdot \mathbf{C}_x (\sqrt{z}) = z\mathbf{C}_x$. În consecință \mathbf{w} este o variabilă aleatoare Gaussiană multidimensională de varianță z .

Expresia estimatei Wiener locală (2.78) devine:

$$\hat{\mathbf{w}} = z\mathbf{C}_x \cdot (z\mathbf{C}_x + \mathbf{C}_n)^{-1} \cdot \mathbf{y} \quad (2.79)$$

de unde:

$$E\{\mathbf{w} | \mathbf{y}, z\} = z\mathbf{C}_x \cdot (z\mathbf{C}_x + \mathbf{C}_n)^{-1} \cdot \mathbf{y} \quad (2.80)$$

Această dependență poate fi simplificată diagonalizând matricea $z\mathbf{C}_x + \mathbf{C}_n$, [85].

Cel de al doilea factor al integrandului din membrul drept al ecuației (2.77) este $p(z|\mathbf{y})$ -repartiția multiplicatorului condiționată de coeficienții imaginii aciziționate din vecinătatea considerată. Aceasta poate fi calculată cu ajutorul regulii lui Bayes:

$$p(z | \mathbf{y}) = \frac{p(\mathbf{y} | z) \cdot p_z(z)}{\int_0^{\infty} p(\mathbf{y} | \alpha) \cdot p_z(\alpha) d\alpha} \quad (2.81)$$

Pentru calculul acestei repartiții, e necesară cunoașterea expresiilor pentru $p(\mathbf{y}|z)$ și $p_z(z)$.

Considerând încă odată ecuația (2.76) se poate observa că atât \mathbf{x} cât și \mathbf{n} sunt vectori aleatori Gaussieni independenți de medie statistică nulă cu matrici de

covarianță \mathbf{C}_x și \mathbf{C}_n . Densitatea de probabilitate a reprezentării de tip piramidă dirijată a imaginii achiziționate condiționată de z în vecinătatea observată corespunde unei repartiții Gaussiene de medie statistică nulă și de matrice de covarianță

$$\mathbf{C}_{y|z} = \mathbf{C}_w + \mathbf{C}_n = z\mathbf{C}_x + \mathbf{C}_n :$$

$$p(\mathbf{y} | z) = \frac{1}{\sqrt{(2\pi)^d |\mathbf{z}\mathbf{C}_x + \mathbf{C}_n|}} \cdot e^{-\mathbf{y}^T (\mathbf{z}\mathbf{C}_x + \mathbf{C}_n)^{-1} \mathbf{y}} \quad (2.82)$$

Dacă se alege $p_z(z) = \frac{1}{z}$, pentru $z \geq 0$ se obține următoarea structură a algoritmului

BLS-GSM:

- 1) Descompunerea imaginii achiziționate în sub-benzi,
- 2) Pentru fiecare sub-bandă (cu excepția sub-benzii de aproximări):
 - a) Calculul matricii covarianței zgomotului pentru coeficienții din vecinătate, \mathbf{C}_n , pe baza matricii corespunzătoare a covarianței zgomotului din domeniul spațial,
 - b) Estimarea matricii covarianței reprezentării piramidale a imaginii achiziționate din vecinătate \mathbf{C}_y ,
 - c) Estimarea matricii covarianței \mathbf{C}_x din \mathbf{C}_n și \mathbf{C}_y folosind $\mathbf{C}_x = \mathbf{C}_y - \mathbf{C}_n$,
 - d) Pentru fiecare vecinătate:
 - i) Pentru fiecare valoare z din domeniul de integrare:
 - A) Se calculează $E\{w_c | \mathbf{y}, z\}$,
 - B) Se calculează $p(\mathbf{y} | z)$ folosind (2.82),
 - ii) Se calculează $p(z | \mathbf{y})$ folosind (2.81) și $p_z(z) = \frac{1}{z}$,
 - iii) Se calculează $E\{w_c | \mathbf{y}\}$ numeric folosind (2.77),
- 3) Se reconstruiește imaginea prelucrată din sub-benzile obținute anterior și din sub-banda de aproximări.

Structura de vecinătate propusă în [85] pentru implementarea algoritmului BLS-GSM este compusă dintr-o regiune de dimensiuni 3×3 centrată pe coeficientul curent, împreună cu coeficientul din aceeași poziție geometrică aparținând sub-benzii cu aceeași orientare dar aflat la scara următoare (coeficientul părinte). Integrala din relația (2.77) se calculează numeric. Domeniul de integrare și spațierea eșantioanelor sunt alese ca un compromis între precizia calculului și costul acestuia.

Algoritmul BLS-GSM a reprezentat cea mai bună metodă de denoising din punctul de vedere al îmbunătățirii PSNR o lungă perioadă de timp. Performanțele acestui algoritm pot fi îmbunătățite prin înlocuirea reprezentării de tip piramidă dirijată cu transformata DTCWT bidimensională.

O îmbunătățire a modelului GSM este propusă în [86]. În acest nou model statistic vecinătățile coeficienților wavelet din aceeași sub-bandă sunt considerate ca amestecuri de GSM (Mixtures of linear projected GSM-MPGSM). În fiecare astfel de proiecție se obține o aproximare de dimensiune mai mică a vecinătății locale care totuși modelează cele mai puternice corelații din acea vecinătate. Performanțele de înlăturare a zgomotului obținute cu acest nou model sunt superioare performanțelor algoritmului BLS-GSM. Modelul GSM este folosit și în [87] pentru coeficienții wavelet. Parametrii componente utile a imaginii și ai zgomotului sunt estimați prin minimizarea divergenței Kulback-Leibler dintre o familie model de distribuții de probabilitate și distribuțiile de probabilitate corespunzătoare din imaginea analizată.

2.2.9.2. Importanța informației conținută în faza transformărilor wavelet complexe

Algoritmul BLS-GSM folosind transformări multi-scară supra-complete are rezultate impresionante ca urmare a modelării imaginilor pe baza activității din vecinătăți ale coeficienților wavelet și atenuării puternice a coeficienților wavelet din regiuni 'inactive' pentru a reduce zgomotul. Totuși, în forma sa originală, algoritmul BLS-GSM nu face distincție între componentele de bază ale imaginii care fac ca o regiune să fie activă. Această omisiune conduce la oscilații în vecinătatea muchiilor și a discontinuităților când este eliminat un nivel ridicat de zgomot.

Regiunile active ale imaginilor digitale ar putea fi împărțite în două categorii: arii de textură și parametri multi-scară de muchii și de contururi (numiți parametri structurali). Texturile, la rândul lor pot fi împărțite în două categorii: periodice și aleatoare.

În [88] este propusă o metodă de înlăturare a zgomotului AWGN din imagini digitale bazată pe modelarea statistică a coeficienților DTCWT. Se folosesc două tipuri de modele pentru coeficienții wavelet, bazate pe modelarea coeficienților vecini în spațiu și în scară. Modelarea discontinuităților de la muchii și de la contururi se face cu ajutorul coeficienților wavelet roțiți cu dublul fazei coeficientului cu aceleași coordonate geometrice dar de la scara următoare (coeficientul părinte). Celelalte regiuni ale imaginii sunt modelate folosind coeficienți wavelet obișnuiți. Pentru alegerea modelului potrivit pentru fiecare vecinătate se folosește un cadru Bayesian adaptiv. Nivelul de activitate este modelat de multiplicatorul ascuns din modelele GSM. Un cadru dual de modelare împarte zonele active în două categorii: caracteristici structurale și alte caracteristici, inclusiv textura.

Caracteristicile structurale sunt modelate folosind relații de fază între scări ale coeficienților wavelet. Metoda este bazată pe noii coeficienți roțiți introduși în [88]. În această lucrare au fost introduși coeficienți wavelet complecși care sunt roțiți în sens invers (derotated) cu dublul fazei coeficientului părinte, adică coeficientul de la următoarea scară având aceeași localizare spațială. În acest mod, faza coeficienților roțiți devine invariantă la muchiile multi-scară și este consistentă cu fiecare sub-bandă pentru fiecare tip de caracteristică.

Corelația coeficienților roțiți este mai mare decât corelația coeficienților obișnuiți la discontinuitățile produse de muchiile sau contururile componente utile a imaginii achiziționate. De aceea, potențialul estimării în aceste regiuni în cazul zgomotului AWGN este crescut în cazul folosirii coeficienților roțiți.

Ecuția (2.83) definește noii coeficienți roțiți w_d , unde w sunt coeficienții DTCWT iar w_p este coeficientul părinte corespunzător.

$$|w_d| = |w| \quad \text{și} \quad \angle(w_d) = \angle(w) - 2\angle(w_p) \quad (2.83)$$

Pentru o vecinătate de coeficienți wavelet w , rotirea poate fi descrisă matricial:

$$w_d = A \cdot w \quad (2.84)$$

unde w_d este un vector de coeficienți roțiți iar A este o matrice unitară de rotație care rotește faza fiecărui coeficient cu dublul fazei coeficientului său părinte. Modelarea specifică a caracteristicilor structurale este combinată cu modelarea obișnuită folosind coeficienți wavelet complecși în cadrul unui model Bayesian adaptiv de selecție.

Deoarece coeficienții roțiți au aceleași module ca și coeficienții DTCWT obișnuiți, se poate reține modelul GSM al coeficienților wavelet folosit în [85], pentru a captura caracteristicile de grupare și de persistență de-a lungul scărilor ale modulelor coeficienților wavelet pentru ambele modele. Pentru a integra modelarea specifică a caracteristicilor structurale ale imaginii cu modelarea GSM standard se consideră două modele pentru vecinătățile coeficienților \mathbf{w} care se combină într-un cadru Bayesian. Aceste modele sunt prezentate în ecuațiile (2.85) și (2.86).

Modelul 1 este destinat reprezentării texturilor folosind coeficienți wavelet obișnuiți iar modelul 2 se folosește pentru caracteristicile structurale majore ale imaginii și folosește coeficienți wavelet roțiți.

Modelul 1

$$\mathbf{w} = \sqrt{z} \cdot \mathbf{x} \quad (2.85)$$

Modelul 2

$$\mathbf{w} = \mathbf{A} \cdot \mathbf{u} = \sqrt{z} \cdot \mathbf{A} \cdot \mathbf{q} \quad (2.86)$$

Modelul 1 este modelul GSM standard al unei vecinătăți de coeficienți wavelet \mathbf{w} așa cum este descris în [85] unde z este variabila ascunsă iar \mathbf{x} este vecinătatea de variabile Gaussiene cu medie statistică nulă și covarianță \mathbf{C}_x . În modelul 2, \mathbf{q} este un vector de variabile aleatoare distribuite Gaussian cu covarianța \mathbf{C}_q . \mathbf{A} este o matrice inversă unitară de rotire variabilă în spațiu, care convertește o mulțime de coeficienți roțiți \mathbf{q} în coeficienții DTCWT corespunzători folosind fazele coeficienților părinți interpolați. Pe baza ipotezei că o caracteristică de muchie sau contur cu o anumită polaritate este egală cu una de polaritate opusă, se presupune că vectorul \mathbf{q} are medie statistică nulă. Pentru fiecare vecinătate de coeficienți, un coeficient central w_c trebuie estimat dintr-o mulțime de coeficienți zgomotoși \mathbf{y} . Pentru a administra selecția între cele două modele a fost introdusă o variabilă aleatoare discretă m care poate lua valorile m_1 și m_2 . Estimata Bayesiană MMSE se deduce la fel ca în [85]:

$$\begin{aligned} \hat{w}_c &= E\{w_c | \mathbf{y}\} = \int w_c p(w_c | \mathbf{y}) dw_c = \\ &= \int \int \sum_{b=1}^2 w_c p(w_c, z, m_b | \mathbf{y}) dz dw_c = \\ &= \int \sum_{b=1}^2 p(z, m_b | \mathbf{y}) E\{w_c | \mathbf{y}, z, m_b\} dz \end{aligned} \quad (2.87)$$

Rămâne să se determine valoarea medie statistică a coeficientului central din vecinătate w_c pentru o variabilă aleatoare z dată pentru fiecare model și o expresie pentru probabilitatea a posteriori comună pentru model și pentru variabilele de multiplicare condiționate de coeficientul zgomotos observat, $p(z; m | \mathbf{y})$.

Un avantaj cheie al cadrului GSM este tractabilitatea estimatorului, $E\{w_c | \mathbf{y}, z, m\}$. Deoarece atât zgomotul cât și vectorii \mathbf{x} și \mathbf{q} sunt Gaussiene, pentru ambele modele valorile medii statistice sunt estimate Wiener condiționate de o valoare pentru z și în cazul modelului 2 de matricea de rotație \mathbf{A} , cu covarianța $z\mathbf{C}_x$ pentru modelul 1 și $z\mathbf{A}\mathbf{C}_q\mathbf{A}^T$ pentru modelul 2. Estimatorii pentru fiecare model sunt prezentați în ecuațiile (2.88) și (2.89).

Modelul 1

$$E\{w|\mathbf{y}, z, m_1\} = \mathbf{zC}_x (\mathbf{zC}_x + \mathbf{C}_n)^{-1} \mathbf{y} \quad (2.88)$$

Modelul 2

$$E\{w|\mathbf{y}, z, m_2\} = \mathbf{zAC}_q \mathbf{A}^T (\mathbf{zAC}_q \mathbf{A}^T + \mathbf{C}_n)^{-1} \mathbf{y} \quad (2.89)$$

Probabilitatea a posteriori comună pentru model și pentru multiplicatorul GSM se determină folosind formula lui Bayes, așa cum se arată în (2.90) cu numitorul prezentat în ecuația (2.91).

$$p(z, m | \mathbf{y}) = \frac{p(\mathbf{y} | z, m) \cdot p_{z, m}(z, m)}{p(\mathbf{y})} \quad (2.90)$$

$$p(\mathbf{y}) = \int \sum_{\mu=1}^2 p(\mathbf{y} | a, \mu) \cdot p_{z, m}(a, \mu) da \quad (2.91)$$

În (2.90), $p(\mathbf{y}|z, m)$ este Gaussiană cu medie statistică nulă și covarianță $\mathbf{zC}_x + \mathbf{C}_n$ pentru modelul 1 și cu covarianță $\mathbf{zAC}_q \mathbf{A}^T + \mathbf{C}_n$ pentru modelul 2.

Modelul 1

$$p_{\mathbf{y}|z, m}(\mathbf{y} | z, m_1) = \frac{1}{(2\pi)^{N/2} |\mathbf{zC}_x + \mathbf{C}_n|^{1/2}} \cdot e^{-\frac{\mathbf{y}^T (\mathbf{zC}_x + \mathbf{C}_n)^{-1} \mathbf{y}}{2}} \quad (2.92)$$

Modelul 2

$$p_{\mathbf{y}|z, m}(\mathbf{y} | z, m_2) = \frac{1}{(2\pi)^{N/2} |\mathbf{zAC}_q \mathbf{A}^T + \mathbf{C}_n|^{1/2}} \cdot e^{-\frac{\mathbf{y}^T (\mathbf{zAC}_q \mathbf{A}^T + \mathbf{C}_n)^{-1} \mathbf{y}}{2}} \quad (2.93)$$

Ipoteza a priori se descompune folosind relația $p(z, m) = p(z | m) \cdot p(m)$. Deși ipoteza a priori pentru multiplicatorul ascuns $p(z|m)$ ar putea fi dependentă de model, de obicei se folosește o ipoteză a priori de tip Jeffreys pentru ambele modele: $p(z | m_1) = p(z | m_2) = 1/z$. Și în [85] a fost folosită o ipoteză de tip Jeffreys. Nu este logic să se aplice modelul 2 unei vecinătăți dacă caracteristica dominantă a vecinătății nu este multi-scară. Asta înseamnă că dacă modulele coeficienților părinți nu sunt suficient de mari, faza coeficienților roțiți devine fără sens. Această problemă poate fi rezolvată după cum urmează: dacă suma ponderată normalizată a modulelor coeficienților părinți dintr-o vecinătate este mai mică decât abaterea standard a zgomotului care perturbă fiecare coeficient wavelet complex atunci faza coeficientului părinte este considerată de ne-încredere și $p(m_2)$ este considerat egal cu 0 pentru acea vecinătate. Altfel, se presupune că nu există nici o informație despre plauzibilitatea caracteristicilor structurale în imaginea achiziționată și modelelor li se dau probabilitățile a priori egale, $p(m_1) = p(m_2) = 0.5$. Aceasta este descris în ecuațiile următoare:

$$p(m_2) = \begin{cases} 0, & \text{daca } \sum_{n=1}^d \gamma_n |\hat{w}_{pn}| < \sigma_n \\ 0.5, & \text{altfel} \end{cases} \quad (2.94)$$

$$p(m_1) = 1 - p(m_2) \quad (2.95)$$

unde \hat{w}_{p_n} sunt estimatele părinților coeficienților din vecinătate folosiți pentru rotire iar σ_n reprezintă abaterea standard a zgomotului care afecează un coeficient complex în sub-banda părinților. Ponderile pozitive γ_n , a căror sumă este egală cu 1, sunt definite în ecuația următoare:

$$\gamma_n = \frac{|\tilde{c}_q(c, n)|}{\sum_{n=1}^d |\tilde{c}_q(c, n)|} \quad (2.96)$$

unde c este indicele coeficientului complex care trebuie prelucrat. Am notat cu tilda matricea de covarianță complexă pentru coeficienții roțiți obținută din matricea de covarianță reală (de dimensiuni mai mari) \mathbf{C}_q . Expresia acestei matrici este prezentată în următoarea ecuație, unde \mathbf{q}_r și \mathbf{q}_i sunt părțile reală și imaginară din \mathbf{q} .

$$\mathbf{C}_q = E \left\{ \begin{bmatrix} \mathbf{q}_r \\ \mathbf{q}_i \end{bmatrix} \begin{bmatrix} \mathbf{q}_r^T & \mathbf{q}_i^T \end{bmatrix} \right\} = \begin{bmatrix} \mathbf{C}_{rr} & \mathbf{C}_{ri} \\ \mathbf{C}_{ir} & \mathbf{C}_{ii} \end{bmatrix} \quad (2.97)$$

Matricea de covarianță complexă pentru coeficienții roțiți este calculată folosind:

$$\tilde{\mathbf{C}}_q = \mathbf{C}_{rr} + \mathbf{C}_{ii} + i(\mathbf{C}_{ir} - \mathbf{C}_{ri}). \quad (2.98)$$

În literatura recentă, dimensiunea vecinătății este selectată într-o manieră ad-hoc. Există multe variante de alegere a ferestrei folosită pentru estimarea varianței și pentru definirea modelului GSM. Voloshynovskiy și ceilalți folosesc vecinătăți de dimensiuni diferite la scări diferite [89]. Strela și ceilalți folosesc vecinătăți de forme diferite în sub-benzi de orientare diferită asociate cu o formă primitivă de GSM în încercarea de a captura structura de corelație de-a lungul muchiilor [90]. Mihçak și ceilalți determină dimensiunea vecinătății dinamic folosind metoda bootstrap [91]. Pentru denoising-ul GSM folosind transformarea piramidală dirijabilă [85], Portilla și ceilalți au optimizat structura vecinătății și au ales o vecinătate de tipul '3x3+p' constând din coeficientul care trebuie prelucrat, cei opt coeficienți înconjurători din aceeași sub-bandă și coeficientul părinte din aceeași poziție spațială dar de la scara următoare.

2.2.10. Algoritmul BM3D

O combinație a abordărilor bazate pe medierea ne-locală, NLM și pe prelucrarea în domeniul unei transformate a condus la dezvoltarea metodei de denoising BM3D (Block Matching in 3 Dimensions) [93], care este considerată în prezent cea mai bună metodă de denoising. Această metodă operează la nivelul regiunilor (patches, bloks) și pentru fiecare regiune de referință din imagine colectează un grup de regiuni similare, chiar suprapuse parțial (după un pas inițial de pre-filtrare bazat pe DCT), care sunt apoi „stivuite” împreună pentru a forma un volum tridimensional (3D). Întregul volum este proiectat pe o bază de transformare 3D (produs de baze DCT, biortogonală și Haar) pentru a obține o mulțime de coeficienți cărora li se aplică apoi operatorul hard-thresholding. Regiunile filtrate sunt reconstruite apoi prin inversarea transformării. Grupul de operații format din transformarea 3D directă, filtrarea cu filtrul hard-thresholding și calculul transformării 3D inverse, se numește filtrare colaborativă. Acest proces este repetat pentru întreaga imagine folosind o fereastră alunecătoare cu medierea nelocală a

ipotezelor pentru a obține un rezultat intermediar. Procesul repetat conduce la agregare. Această imagine este apoi filtrată cu un filtru Wiener pentru a obține rezultatul final.

Deși rezultatele obținute folosind metoda de denoising BM3D sunt admirabile, trebuie remarcat că metoda este complicată, necesitând ajustarea unor caracteristici cum ar fi: alegerea bazelor, dimensiunea regiunii, pragurile transformării 3D, etc. În [94] se compară metoda bazată pe asocierea filtrului MAP cu DTCWT propusă în [63] cu BM3D din punct de vedere al indicelui de similaritate structurală (SSIM) și se evidențiază faptul că deși BM3D conduce la valori superioare ale PSNR, metoda bazată pe asocierea transformatei wavelet cu filtrul MAP conduce la valori superioare ale SSIM.

2.2.11. Algoritmi de denoising folosind noi transformări derivate din transformata wavelet

Transformata framelet este similară cu transformata wavelet cu excepția câtorva diferențe. Ea folosește două sau mai multe bancuri de filtre (funcții wavelet mamă), care produc mai multe sub-benzi decât în cazul transformării DWT. În acest mod se poate realiza o mai bună localizare timp-frecvență a elementelor cadrului (frame) de analiză. Există o redundanță între sub-benzile framelet, ceea ce înseamnă că modificarea unor coeficienți dintr-o sub-bandă poate fi compensată de modificarea altor coeficienți dintr-o altă sub-bandă. Coeficienții dintr-o sub-bandă sunt corelați cu coeficienții din alte sub-benzi. În [74] este dat un exemplu de transformare framelet, în care se folosesc două bancuri de filtre generate de două funcții wavelet mamă diferite. Spectrul primei funcții wavelet mamă este concentrat între spectrul celei de a doua funcții wavelet mamă și spectrul variantei dilatate a celei de a doua funcții wavelet mamă. Această transformată framelet este numită transformată wavelet discretă cu densitate dublă. Ea este aproape invariantă la translații și conține scări intermediare. Cadrul wavelet corespunzător acestei transformări este format din funcții wavelet cu suport compact care au momente nule. Tehnicile de denoising descrise anterior pot fi asociate și cu transformata framelet.

O altă transformată derivată din transformata wavelet, folosită la denoising este transformata curvelet [75]. Această transformare este o piramidă multi-scară cu multe direcții preferențiale și poziții la fiecare scară. Ea este mult mai economică (rară) decât transformata wavelet. Folosind un număr foarte mic de termeni ai transformatei curvelet se pot obține reconstrucții surprinzătoare de exacte din punct de vedere al geometriei muchiilor din imaginea analizată. În [76] se prezintă o analiză statistică a transformatei curvelet, făcându-se distincția între două clase: semnalul de interes, care este compusă din coeficienții care conțin o componentă neafectată de zgomot și zgomot. Investigând statisticile marginale, în [76] se obține un model statistic a priori pentru coeficienții curvelet. Analiza dependențelor intra-bandă și inter-benzi a coeficienților conduce la construcția unui indicator local de activitate pentru funcțiile curvelet. Pe baza acestuia, în [76] se propune o nouă metodă de denoising.

În toate referințele bibliografice amintite până acum, funcțiile generatoare (wavelet mamă) bidimensionale erau separabile după cele două variabile spațiale, fiind construite ca produse de funcții generatoare unidimensionale de fiecare dintre cele două variabile spațiale. În [77] se introduce transformata contourlet, care folosește funcții generatoare bidimensionale neseperabile. Aceasta este o

reprezentare multi-rezoluție și multi-direcție construită cu ajutorul bancurilor de filtre neseperabile. În [78] se propune o metodă de denoising care aplică Basis Pursuit (metodă descrisă în domeniul wavelet prin ecuația (2.65)) în domeniul transformatei contourlet. Autorii lucrării [78] generalizează metoda Basis Pursuit prin înlocuirea celui de al doilea termen din membrul drept al ecuației (2.65) $\lambda \|W_S\|_1$ cu $\sum_i \lambda_i |W_{S_i}|$ unde λ_i reprezintă ponderea proprie a coeficientului W_{S_i} .

Inspirându-se de la filtrul bishrink, autorii lucrării [78] localizează estimarea ponderilor λ_i la un sistem de vecinătăți, luând în considerare dependențele inter-scară și inter-bandă ale coeficienților transformatei contourlet. Și alte transformate derivate din transformata wavelet, ca de exemplu: transformata shearlet [79], transformata directionlet [80], sau transformata în pachete de funcții wavelet [81] au fost folosite pentru denoising.

2.2.12 Algoritmi de denoising bazați pe dicționare

În cazul metodelor bazate pe transformare se utilizează o bază (ortonormală sau Riesz) fixă pentru reprezentarea semnalului. Există însă metode bazate pe învățarea bazei din statisticile imaginii sau a regiunilor acesteia. Printre acestea sunt de interes baze supra-complete (Riesz), numite dicționare, a căror redundanță inerentă conduce la reprezentări mai economice (rare) ale semnalelor naturale. Unul dintre cei mai populari algoritmi pentru construcția de dicționare supra-complete este algoritmul K-means Singular Value Decomposition (K-SVD) [95]. Învățarea se realizează prin minimizare alternativă pornind de la regiuni suprapuse dintr-o imagine afectată de zgomot folosind actualizări SVD în funcție de coloană. O variantă multi-scară a acestui algoritm, Multi Scale K-SVD (MS-KSVD), construiește dicționare pentru reprezentarea regiunilor la două sau mai multe scări, crescând în continuare redundanța reprezentării. Spre deosebire de metodele deja amintite, care permit învățarea unui dicționar unic pentru întreaga imagine, algoritmul de învățare a unor dicționare locale (K Locally Learned Dictionaries-KLLD) realizează un pas suplimentar de grupare (clustering) folosind algoritmul K-Means asupra regiunilor prefiltrate dintr-o imagine afectată de zgomot și apoi filtrează regiunile din fiecare grupare separat proiectându-le pe baze de rang inferior, învățate folosind metoda de analiză în componente principale (Principal Component Analysis-PCA) printr-o metodă de regresie. Întreaga procedură este iterată pentru creșterea performanțelor.

2.2.13 Un nou algoritm de denoising

Pe baza paragrafelor 2.2.7.1.3 și 2.2.7.1.4 din lucrarea de față am conceput un nou algoritm de denoising cu două etaje. Conceptul de sistem de denoising cu două etaje a fost introdus în [96]. Am aplicat acest concept în [96]. În această referință bibliografică primul etaj separă componenta de zgomot a imaginii achiziționate cu ajutorul unui prim sistem de denoising, care utilizează transformata HWT notată în figura 17 cu W_1 . Componenta de zgomot extrasă de primul etaj servește ca pilot pentru cel de-al doilea etaj, care este un alt sistem de denoising bazat pe HWT. O a doua transformată HWT, notată cu W_2 , este utilizată în cel de al doilea etaj. Prin aplicarea transformatei DWT bidimensională (2DDWT) imaginii pilot, se estimează separat, pe baza ecuației (2.99), abaterea standard σ_n a componentei de zgomot a imaginii de prelucrat,

$$\hat{\sigma}_n = \frac{\text{median}(|y|)}{0.6745}, y \in D_1^3 \quad (2.99)$$

unde y reprezintă coeficienții wavelet de detalii ai 2DDWT a imaginii pilot și D_1^3 reprezintă sub-banda de detalii diagonale a 2DDWT a imaginii pilot la primul nivel de descomponere [96].

Apoi, filtrul MAP aplicat în domeniul W_2 utilizează această caracteristică pentru a estima abaterea standard a componentei fără zgomot a imaginii de intrare, σ , folosind următoarea ecuație:

$$\sigma_y^2 = \sigma^2 + \sigma_n^2 \quad (2.100)$$

unde σ_y reprezintă abaterea standard a pixelilor transformatei HWT a imaginii achiziționate. Principalul avantaj al acestor două etape de abordare a denoising-ului este că evită limitările impuse în general schemelor de denoising cu filtre MAP, ca de exemplu raportul semnal pe zgomot (Signal to Noise Ratio-SNR) scăzut.

Pentru primul etaj se folosește un filtru ASTF marginal, notat ca Sh în figura 17, iar pentru cel de al doilea etaj se folosește un filtru bishrink îmbunătățit [96]. Îmbunătățirile bishrink constau în utilizarea: ferestrelor direcționale; unei metode noi de extindere a sub-imaginilor părinte și unui calcul mai precis al abaterilor standard locale.

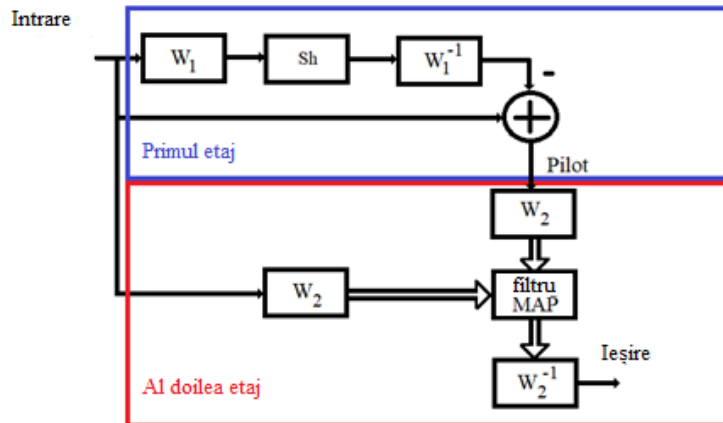


Figura 17. Arhitectura sistemului de denoising cu două etaje.

Sistemul din figura 17 reprezintă un nucleu de denoising pentru zgomot aditiv. Metoda de denoising cu două etaje poate fi aplicată și în cazul imaginilor de teledeteție afectate de zgomot multiplicativ de tip speckle. În cazul imaginilor de teledeteție, nucleul de denoising pentru zgomot aditiv este precedat de un bloc pentru calculul logaritmului și de un bloc pentru estimarea mediei statistice a imaginii achiziționate. Nucleul de eliminare a zgomotului aditiv este urmat în cazul imaginilor de teledeteție de un bloc de corecție a mediei statistice și de un bloc pentru inversarea logaritmului. Blocul de calcul al logaritmului este utilizat pentru conversia zgomotului multiplicativ în zgomot aditiv. Grupul format din blocul de calcul al logaritmului, nucleul de denoising pentru zgomot aditiv și blocul de inversare a logaritmului formează un sistem de denoising homomorfic. Marele dezavantaj al unui sistem de denoising homomorfic este că produce o estimare a componentei utile a imaginii achiziționate abătută. Pentru corecția acestei abateri,

profitând de faptul că media statistică a zgomotului de tip speckle este unitară, se folosește blocul de corecție a mediei statistice de la ieșirea nucleului de denoising pentru zgomot aditiv. Acesta determină media statistică a imaginii obținute după inversarea logaritmului, o scade din această imagine și la rezultatul obținut adună media statistică a imaginii achiziționate (determinată de blocul de estimare a mediei statistice a imaginii achiziționate).

Pentru a evalua performanța metodei propuse pe imagini sintetizate, am efectuat simulări folosind imagini naturale, precum Lena, Boat și Barbara; care au fost utilizate anterior pentru a evalua alte metode de procesare a imaginilor. Imaginile Lena și Boat conțin caracteristici structurale dominante, cum ar fi margini, linii, colțuri, etc. Cel mai frecvent, textura acestor imagini este departe de a fi periodică. Dimpotrivă, imaginea Barbara conține trăsături texturale dominante periodice (în cea mai mare parte corespunzătoare hainelor). Toate imaginile de testare au dimensiunea 512×512 . Am adăugat imaginilor zgomot alb Gaussian independent și distribuit identic (independent and identical distributed-iid) la diferite valori de PSNR determinate de varianța zgomotului σ_n^2 . Am sintetizat și zgomot speckle. Acesta urmează o distribuție Rayleigh cu medie unitară. Calculând rădăcina pătrată a unei sume de pătrate a două zgomote albe Gaussiene de medie zero, având aceeași varianță, am generat zgomotul cu distribuția Rayleigh. Modificând valoarea acestei varianțe, am obținut imagini corespunzătoare unor numere diferite de vederi (Number of Looks-NL) notate cu L [96]. Descompunerea wavelet a fost efectuată până la nivelul $L_0=7$. Am implementat toți algoritmi în MATLAB folosind WaveLab Toolbox [96].

Am considerat de asemenea imagini de tele-deteție [96]: imagini SAR aeriene și SONAR, ca imagini reale. Am selectat aceste tipuri de imagini, pentru a fi cât mai diferite, pentru a evidenția universalitatea metodei de denoising. Imaginea SAR aeriană utilizată în primul exemplu de aplicare a metodei propuse pe imaginile reale de teledeteție este achiziționată cu un sistem NASA/JPL Airborne SAR- sistem RADAR cu apertură sintetică montat la bordul unei aeronave modificate NASA DC-8, utilizând deteție liniară. În timpul colectării datelor, avionul a zburat la o înălțime de 8 kilometri peste munți din Elveția. Numărul de vederi, L , este egal cu 2. Pentru al doilea exemplu de aplicare a metodei propuse la imaginile de teledeteție, am selectat o imagine SONAR. Această imagine arată epava Swansea eșuată în Golful Le Goulet lângă Brest în timpul Primului Război Mondial. A fost achiziționată de un sistem SONAR militar deținut de GESMA și are un număr de vederi $L=1$. În cazul zgomotului AWGN, rezultatele pentru imaginea Lena sunt prezentate în Tabelul 1. În figura 18 se prezintă rezultatele corespunzătoare ultimei linii din Tabelul 1. Pe prima linie din figura 18 este prezentată imaginea de intrare (fără zgomot). Pe a doua linie din figura 18 este prezentată imaginea zgomotoasă. Rezultatul obținut aplicând metoda de denoising propusă este prezentat pe linia a treia a figurii 18. Analizând Tabelul 1, se poate remarca faptul că, în cazul imaginii Lena perturbată de AWGN, metoda propusă îmbunătățește PSNR și SSIM.

Tabelul 1. Imaginea Lena. O comparație a rezultatelor obținute pentru metoda propusă pentru diferite valori ale abaterii standard a zgomotului.

σ_n	PSNR intrare	PSNR ieșire	SSIM ieșire
10	28.13	35.19	0,9989
15	24,59	33,41	0,9983
20	22.10	32.06	0,9977
25	20.21	31.06	0,9971
30	18,61	30.20	0,9964

Figura 18. Compararea rezultatelor obținute $-\sigma_n=30$. Prima coloană: imaginea originală; a doua coloană: imaginea zgomotoasă; a treia : rezultatul metodei propuse.

Aceste constatări sunt confirmate de analiza figurii 18. Observații similare pot fi formulate analizând și Tabelul 2 pentru imaginea Boats și Tabelul 3 pentru imaginea Barbara, în cazul imaginilor naturale perturbate de AWGN.

În tabelul 2 este analizat cazul imaginii Boat iar în tabelul 3 este analizat cazul imaginii Barbara.

Tabelul 2. Imaginea Boat. O comparație a rezultatelor obținute pentru diferite valori ale abaterii standard a zgomotului.

σ_n	PSNR intrare	PSNR ieșire	SSIM ieșire
10	28,13	33,11	0,9981
15	24,59	31,20	0,9970
20	22,10	29,86	0,9959
25	20,21	28,82	0,9948
30	18,61	28,08	0,9935

Tabelul 3. Imagine Barbara. O comparație a rezultatelor obținute pentru metoda propusă pentru diferite valori ale abaterii standard a zgomotului.

σ_n	PSNR intrare	PSNR ieșire	SSIM ieșire
10	28,13	33,23	0,9987
15	24,59	31,31	0,9978
20	22,10	29,41	0,9968
25	20,21	28,21	0,9956
30	18,61	27,06	0,9943

Îmbunătățirile PSNR și SSIM sunt măsuri cantitative obiective de performanță pentru un sistem de denoising care nu au legătură directă cu aspectul vizual al rezultatului.

În general, putem aprecia aspectul vizual prin inspecție directă. În cazul unui zgomot speckle sintetizat, în figura 19, sunt comparate vizual filtrele clasice de înlăturare a acestui tip de zgomot: Lee, Kuan și Frost; aplicate folosind o fereastră alunecătoare de dimensiune 7×7 , cu algoritmul MBD din [96] și cu metoda propusă, folosind imaginea de referință propusă în [96].

Putem observa vizual, analizând figura 19, că filtrele clasice de înlăturare a zgomotului de tip speckle (Lee, Kuan și Frost) nu sunt capabile să elimine întregul zgomot. Acest efect este mai vizibil în regiunile omogene. Mai mult, filtrele clasice estompează texturile și muchiile, ștergând contururile slabe. Din punct de vedere vizual, cele mai bune rezultate dintre filtrele clasice aparțin filtrului Frost.

Algoritmul MBD are performanțe mai bune decât filtrele clasice de înlăturare a zgomotului de tip speckle referitoare la texturi și contururi, dar unii pixeli zgomotoși rămân în regiunile omogene.

Filtrul propus are cele mai bune performanțe, eliminând practic tot zgomotul din regiunile omogene și păstrând texturile și muchiile. Rezultatele prezentate pe ultima linie din figura 19 demonstrează anizotropia metodei de denoising propusă, care este consecința selectivității direcționale îmbunătățite a HWT.

În tabelele 4 și 5, sunt comparate câteva metode de înlăturare a zgomotului de tip speckle, folosind imaginea Lena perturbată de zgomotul de tip speckle sintetizat.

În tabelul 4 se compară următoarele metode: asocierea HWT cu un ASTF marginal [96]; asocierea HWT cu filtrul Bishrink, obținute folosind două funcții wavelet mamă diferite: Daubechies 4 (D4) și Biorthogonal Daubechies 9/7 (B9/7). Cele mai bune rezultate au fost marcate cu bold.

Au fost folosite trei valori diferite ale varianței zgomotului corespunzătoare la trei numere de vederi diferite, NL: 1, 4 și 16. Am comparat cantitativ metoda de înlăturare a zgomotului de tip speckle propusă cu metode de ultimă generație. Algoritmul H-BM3D are cele mai bune rezultate din punct de vedere al PSNR, urmat îndeaproape de algoritmul SAR-BM3D (Tabelul 5). Rezultatele obținute aplicând metoda de denoising propusă aici sunt bune, depășind rezultatele obținute cu alte metode de denoising bazate pe funcții wavelet, cum ar fi: PPB, MAP-S, SA-WBMAE, HWT-Bishrink, HWT-filtru ASTF marginal (Tabelul 4 și 5). Comparând rezultatele obținute aplicând asocierea HWT-Bishrink cu rezultatele metodei de denoising propuse remarcăm că ideea sistemului cu două etaje și îmbunătățirile propuse ale filtrului bishrink sunt eficiente. Algoritmul propus este mai rapid decât algoritmi SAR-BM3D și H-BM3D.




Figura 19. Rezultatele diferitelor metode de înlăturare a zgomotului de tip speckle aplicate unei imagini de test [96]: imaginea de testare; filtrul Lee; filtrul Kuan; algoritmului MBD; filtrul Frost și metoda propusă.

Tabelul 4. Imaginea Lena. Performanța PSNR [dB] a diferitelor sisteme de înlăturare a zgomotului de tip speckle bazate pe funcții wavelet.

NL	Zgomotos	Rezultatul în [82]		HWT -		HWT -	
		D4	B9 / 7	ASTF marginal		Bishrink	
		D4	B9 / 7	D4	B9 / 7	D4	B9 / 7
1	12.1	26.0	26.2	25.4	25.6	25.7	26.2
4	17.8	29.3	29.6	29.9	30.0	29.9	30.4
16	23.7	32.9	33.1	33.2	32.9	33.0	33.3

Tabelul 5. Imagine Lena. Performanța PSNR [dB] a diferitelor sisteme de înlăturare a zgomotului de tip speckle: rezultate raportate în [96]: MAP-S; SA-WBMAE, PPB, SAR-BM3D, H-BM3D; și rezultatele metodei propuse.

NL	Zgomotos	SA- WB MMAE	MAP- S	PPB	SAR- BM3D	H- BM3D	Propusă
1	12.1	25.0	26.3	26.7	27.9	26.4	26.4
4	17.8	29.0	29,8	29,8	29.6	31.2	30.6
16	23.7	32.4	33.2	32.7	34.1	34.5	33,5

O imagine SAR aeriană reprezintă obiectul primului exemplu de prelucrare a imaginilor reale cu metoda propusă. În figura 20 sunt prezentate imaginile, care caracterizează sistemul de denoising propus în cazul acestei imagini. În cazul imaginii aeriene prezentate în figura 20, zgomotul de tip speckle afectează puternic imaginea originală ($L=2$). Primul etaj al sistemului de denoising propus nu este capabil să îndepărteze complet zgomotul. Al doilea etaj al sistemului de denoising propus îndepărtează complet zgomotul de tip speckle. Pentru a aprecia mai bine calitatea vizuală a metodei de denoising propuse, se prezintă în figura 21, zoom-uri în cele trei imagini corespunzătoare aceleiași regiuni a imaginii achiziționate, a rezultatului primului etaj și a rezultatului final al denoising-ului.




Figura 20. Rezultatele metodei propusă aplicate unei imagini SAR aeriene. De sus în jos și de la stânga la dreapta: imagine originală; rezultatul primului etaj de denoising; rezultatul final al denoising-ului

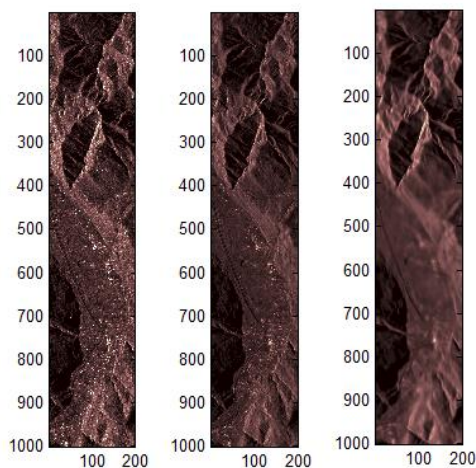


Figura 21. Zoom, imagine originală (stânga), rezultatul primului etaj (centru) și rezultatul final (dreapta).

Pentru a evalua mai corect mecanismele de înlăturare a zgomotului descrise, se analizează, în tabelul 6, zgomotul rejectat de ambele etaje ale sistemului de denoising propus. Primul etaj al sistemului de înlăturare a zgomotului de tip speckle propus nu elimină complet zgomotul iar rezultatul final al sistemului de denoising propus este ușor netezit.

Tabelul 6. Comparația performanțelor etajelor sistemului de denoising în termeni de îmbunătățire a numărului de vederi (Enhancement of the Number of Looks-ENL).

Metodă	Parametrii	
	ENL	Rejecția zgomotului
Imagine de intrare	2	Indisponibil
Primul etaj (ASTF marginal HWT)	3.4	Cel mai prost rezultat
Întregul sistem	7.61	Cel mai bun rezultat

Primul etaj al sistemului de denoising propus mărește ENL, dar nu este capabil să elimine în totalitate zgomotul de tip speckle. Sistemul de denoising propus rejectează complet zgomotul și mărește mai mult ENL. Prin urmare, sistemul de eliminare a zgomotului de tip speckle propus are performanțe bune în cazul imaginilor SAR aeriene degradate de zgomot de tip speckle, în ciuda valorii mici a numărului de vederi, dar netezește ușor imaginea de intrare.

O imagine SONAR face obiectul celui de-al doilea exemplu de prelucrare a imaginilor reale cu metoda propusă. În figura 22 sunt prezentate imaginile care descriu sistemul de denoising propus în acest caz. Prima este imaginea achiziționată de sistemul SONAR. Cea de-a doua imagine este rezultatul primului etaj al sistemului de înlăturare a zgomotului propus, iar a treia imagine reprezintă rezultatul metodei propuse.




Figura 22. Rezultatele metodei propuse aplicată unei imagini SONAR: imaginea originală (sus); Rezultatul primului etaj de denoising (mijloc); rezultatul final de denoising (jos).

Și în cazul imaginii SONAR se observă că metoda propusă rejectează complet zgomotul de tip speckle dar că are un ușor efect de netezire a scenei din imaginea achiziționată, dar forma epavei este ușor de perceput pe baza ultimei imagini din figura 22, în ciuda numărului redus de vederi, $L=1$, al imaginii originale. **Această metodă de denoising a fost validată prin publicarea articolului [96] și reprezintă una dintre contribuțiile acestei teze de doctorat.**

2.3. Compresia

2.3.1. Introducere

Una dintre cele mai importante aplicații ale funcțiilor wavelet este compresia imaginilor bazată pe transformare (numită și codare). Un astfel de codificator (figura 23a)) funcționează transformând datele pentru a elimina redundanța, apoi cuantificând coeficienții de transformare și apoi crescând factorul de compresie printr-o codare entropică. Datorită proprietăților superioare de concentrare a energiei și datorită asemănării cu modul de funcționare a sistemului vizual uman, metodele de compresie care folosesc funcții wavelet au produs rezultate obiective și subiective superioare [103]. Deoarece o bază de funcții wavelet conține atât elemente cu suport scurt (utile pentru reprezentarea semnalelor de frecvențe înalte), cât și elemente cu suport lung (utile pentru reprezentarea semnalelor de frecvențe joase), zone netede de suprafețe mari ale unei imagini pot fi reprezentate cu foarte puțini biți și se pot adăuga detalii acolo unde este nevoie.

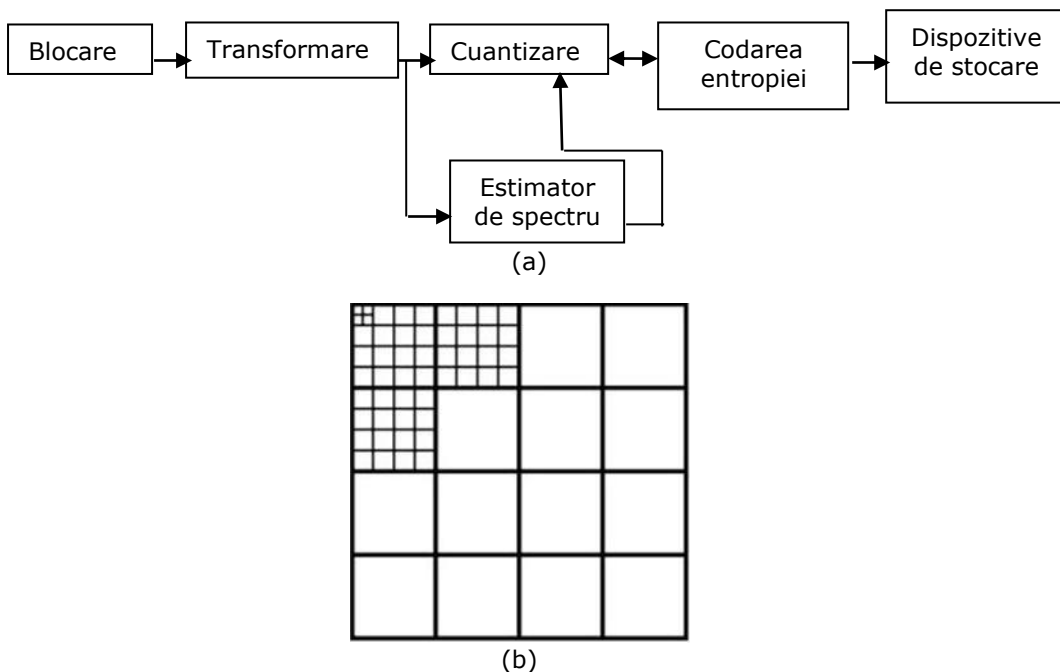


Figura 23. (a) Codarea bazată pe transformare. (b) Descompunerea în sub-benzi utilizată în standardul de compresie a amprentelor FBI.

Pentru compresia imaginilor au fost utilizate atât funcțiile wavelet ortogonale [46], cât și cele bi-ortogonale [99], [150]. Standardul de compresie a amprentelor conceput de FBI [150] folosește funcții wavelet diadice simetrice și performanțele sale depășesc în mod semnificativ performanțele standardului JPEG (Joint Picture Expert Group) [126] la rapoarte de compresie de peste 10:1. Figura 23b) prezintă

descompunerea în sub-benzi utilizată în standardul de compresie a amprentelor conceput la FBI. Interesant este faptul că arborele de descompunere utilizat în specificația FBI are 4 canale și este realizat prin cascada de filtre cu 2 canale (corespunde unei transformări de tipul wavelet packets).

Majoritatea algoritmilor de compresie cu pierderi de înaltă calitate folosesc astăzi unele forme de transformare. Un standard utilizat pe scară largă este standardul JPEG, bazat pe transformarea cosinus discretă (DCT) [126]. Imaginea este partiționată în blocuri de dimensiune 8×8 pixeli, fiecare dintre acestea fiind apoi transformat printr-un produs tensorial de două DCT în 8 puncte. Coeficienții de transformare sunt apoi aranjați în 64 de sub-benzi și sunt cuantificați scalar. Algoritmul JPEG dă rezultate bune pentru rapoarte de compresie de 10:1 și mai mici (pe imagini cu mai multe niveluri de gri formate din pixeli a căror intensitate este reprezentată pe 8 biți), dar la rapoarte de compresie mai mari încep să se observe distorsiuni după reconstrucție (operația inversă compresiei). Când raportul de compresie atinge valoarea de 24:1, doar coeficientului de componentă continuă (de frecvența cea mai mică) i se mai alocă biți, varianta comprimată a imaginii de intrare fiind reprezentată cu un set de blocuri de dimensiune 8×8 care au câte un singur element nenul. În consecință, imaginea decomprimată are artefacte de blocare substanțiale pentru rapoarte de compresie medii și ridicate. Cercetătorii au aplicat codarea în sub-benzi la prelucrarea imaginilor de peste un deceniu [143], [149]; dar rezultatele obținute au atins un nou nivel de calitate doar odată cu apariția transformatei wavelet. Mai mult, folosind transformări multirezoluție; metodele de compresie bazate pe funcții wavelet se degradează mult mai încet decât metodele bazate pe DCT odată cu creșterea raportului de compresie. Un algoritm bazat pe funcții wavelet, codorul EZW, produce o compresie acceptabilă la un raport de 100:1 [132].

2.3.2. Compresia imaginii folosind funcții wavelet

Există două tipuri de compresie a imaginilor: fără pierderi și cu pierderi. În cazul compresiei fără pierderi, imaginea originală este recuperată exact după decompresie. Din păcate, cu imagini de scene naturale, rareori este posibil să se obțină o compresie fără pierderi la o rată de peste 2:1. Se pot obține rapoarte de compresie mult mai mari dacă este permisă o anumită pierdere între imaginea decomprimată și imaginea originală, care este de obicei dificil de perceput. Aceasta este compresia cu pierderi. În multe cazuri, nu este necesar sau chiar de dorit să existe o reproducere fără pierderi a imaginii originale. De exemplu, dacă există un zgomot, atunci eroarea datorată zgomotului respectiv va fi de obicei redusă semnificativ prin intermediul unei metode de denoising înainte de compresie. Într-un astfel de caz, cantitatea mică de eroare introdusă de compresia cu pierderi poate fi acceptabilă. Compresia cu pierderi este acceptabilă și în transmiterea rapidă a imaginilor statice prin internet.

În continuare ne concentrăm pe compresia cu pierderi bazată pe funcții wavelet a imaginilor statice cu mai multe niveluri de gri. Când există 256 de niveluri de intensitate posibile pentru fiecare pixel, atunci vom numi aceste imagini ca fiind imagini de 8 bpp (biți pe pixel). Imaginile cu 4096 de niveluri de gri sunt denumite 12 bpp. De asemenea, prezentăm câteva comentarii scurte cu privire la imaginile color și descriem pe scurt câteva metode de compresie fără pierderi bazate pe funcții wavelet.

În continuare ne concentrăm pe compresia cu pierderi bazată pe funcții wavelet a imaginilor statice cu mai multe niveluri de gri.

2.3.2.1. Compresia cu pierderi

Există mai multe metode de compresie cu pierderi a imaginilor bazate pe funcții wavelet: algoritmul EZW (care încorporează arborele zero wavelet), algoritmul SPIHT (set de partiționare în arbori ierarhici), algoritmul WDR (reducerea diferenței între coeficienți wavelet corespunzători) și algoritmul ASWDR (reducerea diferenței între coeficienții wavelet corespunzători scanată adaptativ). Aceștia sunt algoritmi relativ recenți, care ating unele dintre cele mai mici erori pe rata de compresie și cea mai înaltă calitate perceptivă raportată până acum.

În continuare, vom schița pașii de bază care sunt comuni pentru toți algoritmi de compresie a imaginii pe bază de funcții wavelet. Cele cinci etape de compresie și decompresie sunt prezentate în figurile 24 și 25. Toți pașii indicați în diagrama de compresie sunt inversabili, deci fără pierderi, cu excepția etapei de cuantizare. Cuantizarea se referă la o reducere a preciziei de reprezentare a valorii coeficientului wavelet, care este de obicei de 32 sau de 64 de biți. În cazul compresiei 8 bpp sau 12 bpp, coeficienții wavelet se exprimă pe mai puțini biți. Acest lucru duce la o eroare de rotunjire. Din acest motiv, după aplicarea transformării wavelet inverse, din faza de decompresie se obține o imagine diferită de imaginea originală. Aceasta este eroarea inerentă compresiei cu pierderi.




Figura 24. Compresia imaginii



Figura 25. Decompresia imaginii

Relația dintre pașii de cuantizare și codare, prezentată în figura 24, este aspectul crucial al compresiei bazată pe transformata wavelet. Fiecare dintre ceilalți algoritmi adoptă o abordare diferită a acestei relații.

Scopul servit de transformarea wavelet este acela de a produce un număr cât mai mare de coeficienți având valori absolute egale cu zero sau aproape de zero. De exemplu pentru imaginea „Lena”, figura 26a) se prezintă în figura 26b), rezultatul transformării wavelet discretă calculată cu ajutorul funcției wavelet mamă Daub 9/7 pe 7 niveluri de descompunere. Pentru realizarea compresiei s-a utilizat un prag de valoare 8. Toate valorile de coeficienți wavelet cu module mai mici decât 8 au fost setate pe 0; ele apar ca un fundal gri uniform în imaginea din figura 26b). Aceste zone mari de fundal gri indică faptul că există un număr mare de pixeli de valoare zero după compararea valorilor coeficienților wavelet cu valoarea de prag.

Dacă se aplică imaginii din figura 26b) transformarea wavelet discretă inversă (faza de decompresie) și valorile eşantioanelor obținute se rotunjesc la valori întregi între 0 și 255 se obține imaginea din figura 26c). Este dificil să detectezi cu ochiul liber vreo diferență între imaginile din figurile 26a) și 26c).




Figura 26. a) Imagine „Lena”, 8 bpp. b) Modulele coeficienților obținuți după transformata wavelet a imaginii a), cu valori mai mari decât un prag=8. c) Inversa transformării wavelet a imaginii b), PSNR=39,14 dB.

Imaginea din figura 26c) a fost produsă folosind doar cele 32.498 valori diferite de zero obținute după compararea modulelor coeficienților wavelet cu valoarea de prag, în loc de toate cele 262.144 valori de coeficienți wavelet obținute după aplicarea transformatei wavelet discretă imaginii originale. Aceasta reprezintă un raport de compresie 8:1. Bineînțeles, s-au ignorat problemele dificile, cum ar fi modul de transmitere concisă a pozițiilor coeficienților wavelet cu valori diferite de zero după compararea cu valoarea de prag sau codificarea acestor valori diferite de zero cu cât mai puțini biți. Soluțiile la aceste probleme sunt descrise mai jos, când sunt prezentați și diferiții algoritmi de compresie bazați pe utilizarea funcțiilor wavelet.

Două măsuri de calitate utilizate în mod obișnuit pentru cuantificarea erorii dintre imaginea de intrare și imaginea reconstruită (în urma compresiei) sunt eroare medie pătratică (MSE) și raportul semnal/zgomot de vârf (PSNR). MSE între două imagini f și g este definită de

$$\text{MSE} = \frac{1}{N} \sum_{j,k} (f[j,k] - g[j,k])^2 \quad (2.101)$$

unde suma dublă (după indicii j și k) se efectuează pentru toți cei N pixeli din imagine. Pentru imaginile din figura 26a) și 26c), MSE este 7.921. PSNR între două imagini (8 bpp) este exprimat în decibeli cu formula:

$$\text{PSNR} = 10 \log_{10} \left(\frac{255^2}{\text{MSE}} \right) \quad (2.102)$$

PSNR tinde să fie citat mai des, deoarece este o măsură logaritmică, iar creierul nostru pare să răspundă logaritmic la intensitatea luminoasă. Creșterea PSNR corespunde la o descreștere a gradului de compresie. Pentru imaginile din figura 26a) și 26c), PSNR este de 39,14 dB. În general, atunci când PSNR este de 40 dB sau mai mare, cele două imagini sunt practic indistincte pentru observatorii umani. În acest caz, putem vedea că raportul de compresie 8:1 ar trebui să producă o imagine aproape identică cu cea originală. Metodele descrise mai jos produc de fapt astfel de rezultate cu un PSNR chiar mai mare decât tocmai am obținut cu abordarea brută pe care am exemplificat-o.

Înainte de a începe expunerea diferiților algoritmi „de ultimă generație”, poate fi util să prezentăm pe scurt un algoritm de compresie de bază de genul descris în Davis și Nossratinia [110] și Mallat [13]. Acest algoritm are două părți principale.

În primul rând, pozițiile coeficienților wavelet cu module de valori semnificative-mai mari decât pragul T -sunt determinate de scanarea coeficienților așa cum se arată în figura 27. Pozițiile valorilor semnificative sunt apoi codificate folosind o metodă de compresie de tipul run-length. În acest scop se construiește o hartă a semnificației coeficienților wavelet:

$$s(m) = \begin{cases} 0, & |w(m)| < T \\ 1, & |w(m)| \geq T \end{cases} \quad (2.103)$$

unde m este indicele de scanare și $w(m)$ este valoarea coeficientului wavelet la indexul m .

1	2	5	8	17	24	25	32
3	4	6	7	18	23	26	31
9	10	13	14	19	22	27	30
12	11	15	16	20	21	28	29
33	34	35	36	49	50	54	55
40	39	38	37	51	53	56	61
41	42	43	44	52	57	60	62
48	47	46	45	58	59	63	64

(a) 2-niveluri

1	2	5	8	17	24	25	32
3	4	6	7	18	23	26	31
9	10	13	14	19	22	27	30
12	11	15	16	20	21	28	29
33	34	35	36	49	50	54	55
40	39	38	37	51	53	56	61
41	42	43	44	52	57	60	62
48	47	46	45	58	59	63	64

(b) 3-niveluri

Figura 27. Ordinea coeficienților wavelet scanați pentru transformări pe 2 și 3 niveluri de descompunere.

Scanarea coeficienților wavelet se realizează în zig-zag în sub-banda de aproximare, pe coloană în sub-benzile de detalii verticale, pe linie în sub-benzile de detalii horizontale și în zig-zag în sub-benzile de detalii diagonale. Pozițiile valorilor semnificative pot fi apoi codificate concis înregistrând secvențe de 6 biți conform următorului model:

0 abcde : avem biți de $0r(abcde)_2$

1 abcde : avem biți de $1(abcde)_2$

O compresie fără pierderi, cum ar fi codarea Huffman sau compresia aritmetică, a acestor date este, de asemenea, efectuată pentru o reducere suplimentară a numărului de biți necesari pentru reprezentarea coeficienților wavelet.

În al doilea rând, valorile coeficienților semnificativi sunt codificate. Acest lucru se poate face prin împărțirea gamei de valori a coeficienților în subintervale și rotunjirea fiecărei valori de coeficient la valoarea centrală a intervalului căruia îi aparține. Figura 28 arată histograma valorilor coeficienților wavelet semnificativi obținuți calculând transformata wavelet discretă a imaginii „Lena” pe 7 niveluri de descompunere cu ajutorul funcției wavelet mamă Daub 9/7 (reprezentată în figura 26b). Scăderea extrem de rapidă a frecvențelor de apariție a coeficienților de valori absolute mari implică faptul că valorile de module foarte mici, care apar mult mai frecvent, ar trebui codate folosind secvențe de biți de lungime mai mică. Acest lucru se face de obicei fie cu codare Huffman, fie cu codare aritmetică. Dacă se utilizează codarea aritmetică, atunci numărul mediu de biți necesari pentru a codifica fiecare

valoare semnificativă în cazul imaginii „Lena” este de aproximativ 1 bit. Am schițat mai sus, pe scurt pașii din acest algoritm.

Scopul nostru în discutarea algoritmului de compresie amintit este de a introduce câteva concepte de bază, cum ar fi ordinea scanării și pragurile, care sunt necesare pentru examinarea algoritmilor de compresie care se prezintă în continuare. Algoritmul prezentat (numit în continuare de bază) a fost unul dintre primii algoritmi bazați pe utilizarea funcțiilor wavelet [99].




Figura 28. Histograma coeficienților wavelet ai imaginii „Lena”.

Algoritmul de bază suferă de unele defecte pe care algoritmi ulteriori le-au remediat. De exemplu, cu algoritmul de bază este foarte dificil, dacă nu imposibil, să specifici în prealabil valoarea exactă a ratei de compresie sau valoarea exactă a erorii de reconstrucție. Acesta este un defect grav. O altă problemă a algoritmului de bază este că nu permite transmiterea progresivă. Cu alte cuvinte, nu este posibil să se trimită pachete de date succesive (prin Internet, de exemplu) care produc rezoluție crescând succesiv pentru imaginea recepționată. Transmiterea progresivă este vitală pentru aplicațiile care includ un anumit nivel de interacțiune cu receptorul.

2.3.2.1.1. ALGORITMUL EZW

Algoritmul EZW a fost unul dintre primii algoritmi care au arătat întreaga putere a compresiei de imagine bazată pe funcții wavelet. Vom descrie EZW în detaliu, deoarece o înțelegere solidă a acestuia va face mult mai ușor să înțelegem ceilalți algoritmi pe care îi vom prezenta. Acești alți algoritmi se bazează pe conceptele fundamentale care au fost introduse pentru prima dată cu EZW.

Discuția noastră despre EZW se va concentra pe ideile fundamentale care stau la baza acestei metode de compresie. Nu vom folosi algoritmul EZW pentru a comprima vreo imagine, deoarece această metodă de compresie a fost înlocuită de un algoritm mult superior, SPIHT. Deoarece SPIHT este doar o versiune foarte rafinată a EZW, este logic să descriem mai întâi EZW. Embedded Zerotrees of

Wavelet transforms (EZW) înseamnă transformare wavelet cu arbore zero încorporat. O codare încorporată este un proces de codare a mărimilor transformate care permite transmiterea progresivă a imaginii comprimate. Arborii zero încorporați permit o codare concisă a pozițiilor valorilor semnificative care rezultă în timpul procesului de codare. Mai întâi vom discuta codarea încorporată și apoi vom examina noțiunea de arbore zero.

Codarea planurilor de biți:

Pas 1: Inițializare. Se alege un prag inițial, $T=T_0$, astfel încât toate valorile modulelor coeficienților wavelet să satisfacă condiția $|w(m)| < T_0$ și cel puțin modulul unui coeficient wavelet să satisfacă condiția $|w(m)| \geq T_0/2$.

Pas 2: Actualizare prag. Fie $T_k = T_k/2$.

Pas 3: Transfer semnificație. Se scanează printre valorile mai puțin semnificative folosind metoda de scanare specifică. Se testează fiecare valoare $w(m)$ după cum urmează:

Dacă $|w(m)| \geq T_k$, atunci semnul ieșirii este semnul lui $w(m)$;

Se fixează $w_Q(m) = T_k$,

Altfel dacă $|w(m)| < T_k$ atunci $w_Q(m)$ se fixează egal cu 0.

Pas 4: Rafinare. Se scanează printre valorile mai semnificative găsite folosind un prag de valoare mai mare T_j , pentru $j < k$ (dacă $k=1$ se sare peste acest pas). Pentru fiecare valoare semnificativă $w(m)$, se fac următoarele operații:

Dacă $|w(m)| \in (w_Q(m), w_Q(m) + T_k)$, atunci bitul de ieșire se fixează de valoare 0.

Altfel, dacă $|w(m)| \in (w_Q(m) + T_k, w_Q(m) + 2T_k)$, atunci bitul de ieșire se fixează de valoare 1 și se înlocuiește $w_Q(m)$ cu $w_Q(m) + T_k$.


Această procedură de codare a planului de biți poate fi continuată atât timp cât este necesar pentru a obține module de coeficienți de transformare wavelet cuantificați $w_Q(m)$ de valori la fel de apropiate pe cât se dorește de modulele coeficienților wavelet de transformare $|w(m)|$. În timpul decodării, semnele și biții obținuți prin această metodă pot fi folosiți pentru a construi o transformare wavelet aproximativă la orice grad dorit de precizie. Dacă, în schimb, se dorește un raport de compresie dat, atunci acesta poate fi realizat prin oprirea codării planului de biți de îndată ce un număr dat de biți (un buget de biți) este epuizat. În ambele cazuri, executarea procedurii de codare a planului de biți se poate termina în orice punct (nu doar la sfârșitul uneia dintre bucle).

Codarea planului de biți constă pur și simplu în calcularea expansiunilor binare-folosind T_0 ca unitate-pentru valorile transformării și înregistrarea în ordine de mărime doar a biților semnificativi din aceste expansiuni. Deoarece primul bit semnificativ este întotdeauna 1, acesta nu este codat. În schimb, semnul valorii transformării este codat mai întâi. Această ordonare coerentă a codării, cu biți de cea mai mare valoare absolută codați mai întâi, este ceea ce permite transmiterea progresivă.

Transformatele wavelet sunt deosebit de bine adaptate pentru codarea planului de biți, în cazul imaginilor de scene naturale deoarece valorile absolute mari apar rar și se găsesc mai ales în sub-benzile de cel mai înalt nivel. Aceste valori de modul mari sunt mai întâi approximate grosier în timpul buclelor inițiale ale codării în planuri de biți, producând astfel o versiune a imaginii cu rezoluție mică, dar deseori permițând recunoașterea obiectelor conținute. Buclele ulterioare codează valori de modul mai mici și cresc precizia valorilor de modul ridicate, adăugând detalii suplimentare la imagine și rafinând detaliile existente. Astfel, transmisia progresivă este posibilă, iar codarea/decodarea poate înceta odată cu epuizarea unui anumit buget de biți sau cu atingerea unei ținte de eroare date.

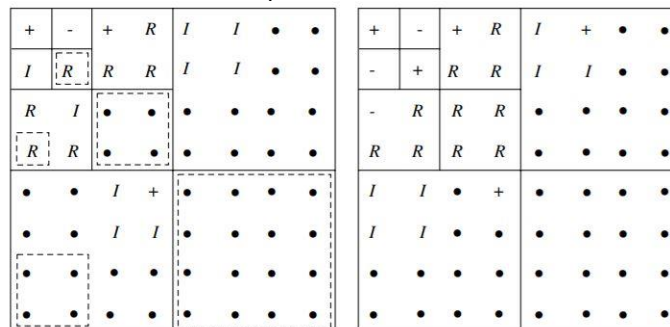
Acum, că am descris codarea încorporată a valorilor coeficienților wavelet, vom descrie metoda arbore zero (zerotree) prin care EZW transmite pozițiile valorilor de transformare wavelet semnificative. Metoda arbore zero oferă o descriere implicită, foarte compactă, a localizării valorilor semnificative prin crearea unei descrieri foarte comprimate a localizării valorilor ne semnificative. Pentru multe imagini de scene naturale, cum ar fi imaginea „Lena”, de exemplu, valorile ne semnificative la un prag dat T sunt organizate în arbori zero.

Pentru a defini un arbore zero definim mai întâi un arbore cvadruplu-un arbore de locații de coeficienți wavelet cu o rădăcină de coordonate $[i,j]$ și copiii săi situați la $[2i,2j]$, $[2i+1,2j]$, $[2i,2j+1]$ și $[2i+1,2j+1]$ și fiecare dintre copiii lor și așa mai departe. Acești descendenți ai rădăcinii ajung până la primul nivel de descompunere a transformatei wavelet. De exemplu, figura 29a) prezintă doi arbori cvadrupli (închiși în cutii reprezentate cu linie întreruptă). Un arbore cvadruplu are rădăcină la indicele 12 și copii la indicii $\{41, 42, 47, 48\}$. Acest arbore cvadruplu are două niveluri și se notează cu $\{12|41, 42, 47, 48\}$. Celălalt arbore cvadruplu din figura 29a), care are trei niveluri, își are rădăcina la indicele 4, copiii acestei rădăcini la indicii $\{13, 14, 15, 16\}$, iar copiii lor la indicii $\{49, 50, \dots, 64\}$. Este notat cu $\{4 | 13, \dots, 16|49, \dots, 64\}$.



(a) Ordinea de scanare cu 2 arbori cvadrupli

(b) Transformarea wavelet



(c) Prag=32

(d) Prag=16

Figura 29. Primele două etape ale EZW. (a) Ordinea scanării pe 3 niveluri. (b) Transformarea wavelet pe 3 niveluri. (c) Etapa 1. (d) Etapa 2.

Acum, că am definit un arbore cuadruplu, putem da o definiție simplă a unui arbore zero. Un arbore zero este un arbore cvadruplu care, pentru un prag dat T , are valori nesemnificative ale transformatei wavelet la fiecare dintre locațiile sale. De exemplu, dacă pragul este $T=32$, atunci fiecare dintre cei doi arbori arătați în figura 29a) este un arbore zero pentru transformarea wavelet cu coeficienții din figura 29b). Dar dacă pragul este $T=16$, atunci $\{12|41, 42, 47, 48\}$ rămâne un arbore zero, dar $\{4|13, \dots, 16|49, \dots, 64\}$ nu mai este un arbore zero, deoarece valoarea sa rădăcină nu mai este nesemnificativă.

Utilizarea arborilor zero poate oferi descrieri foarte compacte ale locațiilor valorilor nesemnificative ale coeficienților wavelet, deoarece este necesar doar să se codeze un simbol, cum ar fi R , pentru a marca locația rădăcină. Decodorul poate deduce că toate celelalte locații din arborele zero au valori nesemnificative, deci locațiile lor nu sunt codate. Pentru pragul $T=32$, în exemplul tocmai discutat, două simboluri R sunt suficiente pentru a specifica toate cele 26 de locații din cei doi arbori zero. Arborii zero pot fi utili numai dacă apar frecvent. Din fericire, cu transformări wavelet a scenelor naturale, structura multirezoluție a transformatei wavelet produce mulți arbori zero (mai ales la praguri mai mari).

Ca exemplu al metodei EZW, se ia în considerare transformata wavelet prezentată în figura 29b), care va fi scanată utilizând ordinea de scanare prezentată în figura 29a). Să presupunem că pragul inițial este $T_0=64$. În prima buclă, pragul este $T_1=32$. Rezultatele primei treceri de semnificație sunt prezentate în figura 29c). Ieșirea codorului după această primă buclă ar fi:

$$+ - IR + RRRRIRR IIII + I I$$

corespunzătoare unei transformări cuantizate având doar două valori nenule: ± 32 ; $+32$ la fiecare locație marcată cu un semn plus în figura 29c), -32 la fiecare locație marcată cu un semn minus și 0 la toate celelalte locații. În a doua buclă, cu pragul $T_2=16$, rezultatele trecerii de semnificație sunt indicate în figura 29d). Se poate observa, în special, că simbolul R se află în poziția 10 în ordinea de scanare deoarece semnul plus care se află într-o locație copil este din bucla anterioară, deci este tratat ca zero. Prin urmare, poziția 10 se află la rădăcina unui arbore zero. Există, de asemenea, o trecere de rafinare făcută în această a doua buclă. Ieșirea din această a doua buclă este apoi:

$$- + RRR - RRRRRRIII + IIII 1 0 1 0$$

cu transformata wavelet cuantizată corespunzător prezentată în figura 30a). MSE dintre această transformare cuantizată și transformarea originală este 48.6875. Aceasta reprezintă o reducere de 78% a erorii de la începutul metodei (când transformarea cuantizată are toate valorile zero).

Câteva observații finale cu privire la metoda EZW se prezintă în continuare. În primul rând, ar trebui să fie clar din discuția de mai sus că decodorul, a cărui structură este evidențiată în figura 25 de mai sus, poate inversa fiecare etapă a codorului și poate produce transformata wavelet cuantizată. Este o practică standard ca decodificatorul să rotunjească apoi valorile cuantizate la punctele medii ale intervalelor la care au fost găsite ultima dată în timpul procesului de codare (adică, se adaugă jumătate din ultimul prag utilizat la determinarea mărimilor lor). Acest lucru reduce în general MSE. De exemplu, în cazul pe care tocmai l-am analizat, dacă această rotunjire se face la transformarea cuantizată din figura 30a), atunci rezultatul este prezentat în figura 30b). MSE este atunci 39.6875, realizându-se o reducere de peste 18%. O discuție interesantă despre justificarea teoretică a acestei tehnici de rotunjire poate fi găsită în [13]. Această metodă de rotunjire va fi utilizată de toți ceilalți algoritmi pe care îi vom discuta.

48	-32	48	0	0	16	0	0	56	-40	56	0	0	24	0	0
-16	16	0	0	0	0	0	0	-24	24	0	0	0	0	0	0
-16	0	0	0	0	0	0	0	-24	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	32	0	0	0	0	0	0	0	40	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

a) b)

Figura 30. a) Cuantizare la sfârșitul celei de-a doua etape, MSE=48.6875. b) După rotunjire la punctele medii, MSE=39.6875, reducere cu mai mult de 18%.

În al doilea rând, întrucât trăim într-o lume digitală, este de obicei necesar să transmitem doar biți. O simplă codare a simbolurilor algoritmului EZW în grupuri de biți ar presupune utilizarea unui cod precum $+ = 0\ 1$, $- = 0\ 0$, $R = 1\ 0$ și $I = 1\ 1$. Deoarece decodorul poate deduce întotdeauna cu exactitate când codarea acestor simboluri se încheie (trecerea de semnificație este completă), codarea biților de rafinare poate fi realizată pur și simplu cu biții simpli 0 și 1. Această formă de codare este cel mai rapid de realizat, dar nu atinge cel mai mare factor de compresie. În [132], a fost recomandată o formă fără pierderi de codare aritmetică pentru a comprima în continuare fluxul de biți din codor.

2.3.2.1.2. ALGORITMUL SPIHT

Algoritmul SPIHT este o versiune foarte rafinată a algoritmului EZW. A fost introdus în [130], [131]. Unele dintre cele mai bune rezultate - cele mai mari valori de PSNR pentru rapoarte de compresie date - pentru o mare varietate de imagini au fost obținute cu SPIHT. În consecință, este probabil cel mai utilizat algoritm bazat pe funcții wavelet pentru compresia de imagini, oferind un standard de bază de comparație pentru toți algoritmi ulteriori.

Set Partitioning In Hierarchical Trees (SPIHT) înseamnă setarea partiționării în arbori ierarhici. Termenul de arbori ierarhici se referă la arborii cuadrupli din EZW. Setarea partiționării se referă la modul în care acești arbori cuadrupli împart valorile coeficienților wavelet la un prag dat. Printr-o analiză atentă a acestei partiționări a valorilor transformării, Said și Pearlman au reușit să îmbunătățească foarte mult algoritmul EZW, crescând semnificativ rata de compresie.

Prezentarea algoritmului SPIHT care urmează va consta în trei părți. În primul rând, descriem o versiune modificată a algoritmului introdus în Said și Pearlman. Ne referim la acesta ca algoritmul de arbore wavelet orientat spațial (STW). Acesta este în esență algoritmul SPIHT; singura diferență este că SPIHT este puțin mai elaborat în organizarea ieșirii. În al doilea rând, descriem algoritmul SPIHT. Este mai ușor să explici SPIHT folosind conceptele care stau la baza STW. În al treilea rând, vedem cât de bine comprimă imaginile SPIHT.

Singura diferență între STW și EZW este că STW utilizează o abordare diferită pentru codarea informațiilor despre arborele zero. STW utilizează un model

de tranziție de stare. De la un prag la altul, locațiile valorilor semnificative ale coeficienților wavelet suferă tranziții de stare. Acest model permite STW să reducă numărul de biți necesari pentru codare. Algoritmul STW folosește stările I_R , I_V , S_R și S_V și generează cod pentru tranziții de stare precum $I_R \rightarrow I_V$, $S_R \rightarrow S_V$ etc. Pentru un prag dat T , stările I_R , I_V , S_R și S_V sunt definite de:

- $m \in I_R$ dacă și numai dacă $|w(m)| < T$, $S(m) < T$,
- $m \in I_V$ dacă și numai dacă $|w(m)| < T$, $S(m) \geq T$,
- $m \in S_R$ dacă și numai dacă $|w(m)| \geq T$, $S(m) < T$,
- $m \in S_V$ dacă și numai dacă $|w(m)| \geq T$, $S(m) \geq T$.

De reținut este faptul că, odată ce o locație m ajunge în starea S_V , va rămâne în starea respectivă. În plus, există doar două tranziții de la stările I_V și S_R la starea S_V , astfel încât aceste tranziții pot fi codate cu câte un singur bit. O simplă codare binară pentru aceste tranziții de stare este prezentată în Tabelul 7.

Cu toate acestea, pentru STW aceste tranziții sunt descrise de simbolurile $+S_R$, $-S_R$ și $+S_V$, care reprezintă o reducere substanțială a informațiilor pe care STW trebuie să le codifice. Nu există prea multe diferențe între STW și SPIHT. Singurul lucru pe care SPIHT îl face în mod diferit este să organizeze cu atenție ieșirea de biți în codarea tranzițiilor de stare din Tabelul 7, astfel încât să se producă un singur bit odată. De exemplu, pentru tranziția $I_R \rightarrow S_R$, care este codată ca 1 0 în Tabelul 1, SPIHT scoate primul 1 și apoi (după procesarea ulterioară) scoate un 0. Chiar dacă bugetul de biți este epuizat înainte ca al doilea bit să fie ieșit, primul bit de 1 indică faptul că există o nouă valoare semnificativă.




Figura 31. Diagrama de tranziții de stare pentru STW.

Tabelul 7. Cod pentru tranziții de stare, • indică faptul că tranziția $S_V \rightarrow S_V$ este sigură (deci nu este necesară codarea).

Vechi/Nou	I_R	I_V	S_R	S_V
I_R	00	01	10	11
I_V		0		1
S_R			0	1
S_V				•

2.3.2.1.3. ALGORITMUL WDR

Unul dintre defectele SPIHT este că localizează implicit doar poziția coeficienților semnificativi. Acest lucru face dificilă efectuarea operațiilor care depind de poziția exactă a valorilor semnificative ale transformării, cum ar fi selecția regiunii din datele comprimate. Prin selecția regiunii, cunoscută și sub numele de regiune de interes (ROI), ne referim la selectarea unei porțiuni dintr-o imagine comprimată care necesită o rezoluție sporită. Acest lucru se poate întâmpla, de exemplu, cu o porțiune a unei imagini medicale cu rezoluție scăzută care a fost trimisă la o rată de bpp redusă pentru a ajunge rapid.

Astfel de operații asupra datelor comprimate sunt posibile cu algoritmul de reducere a diferenței wavelet (Wavelet Difference Reduction-WDR) a lui Tian și Wells. Termenul de reducere a diferenței se referă la modul în care WDR codează locațiile valorilor semnificative ale transformatei wavelet. Deși WDR nu va produce în mod obișnuit valori PSNR mai mari decât SPIHT, vom vedea că WDR poate produce imagini perceptiv superioare, în special la rapoarte de compresie ridicate.

Singura diferență între WDR și codarea planului de biți descrisă mai sus este în trecerea de semnificație. În WDR, ieșirea din trecerea de semnificație constă din semnele valorilor semnificative împreună cu secvențe de biți care descriu concis locațiile precise ale valorilor semnificative. Cel mai bun mod de a vedea cum se face acest lucru este să luăm în considerare un exemplu simplu.

Să presupunem că valorile semnificative sunt $w(2)=+34.2$, $w(3)=-33.5$, $w(7)=+48.2$, $w(12)=+40.34$ și $w(34)=-54.36$. Indicii pentru aceste valori semnificative sunt 2, 3, 7, 12 și 34. În loc să lucreze cu aceste valori, WDR funcționează cu diferențele lor succesive: 2, 1, 4, 5, 22. În această din urmă listă, primul număr este indicele de pornire și fiecare număr succesiv este numărul de pași necesari pentru a ajunge la următorul index. Extensiile binare ale acestor diferențe succesive sunt $(10)_2$, $(1)_2$, $(100)_2$, $(101)_2$ și $(10110)_2$. Deoarece bitul cel mai semnificativ pentru fiecare dintre aceste expansiuni este întotdeauna 1, acest bit poate fi eliminat și semnele valorilor semnificative ale transformării pot fi folosite în schimb ca separatori în fluxul de simboluri. Fluxul de simboluri rezultat pentru acest exemplu este +0 - +00 + 01 - 0110.

Când bitul cel mai semnificativ 1 este abandonat, ne vom referi la expansiunea binară care rămâne ca expansiunea binară redusă. Observăm că expansiunea binară redusă de 1 este goală. Expansiunea binară redusă de 2 este doar bitul 0, expansiunea binară redusă de 3 este doar de 2 biți și așa mai departe.

Nu este greu de văzut că WDR nu are o complexitate de calcul mai mare decât SPIHT. În primul rând, WDR nu are nevoie să caute prin arbori cuadrupli, așa cum face SPIHT. Calculele expansiunilor binare reduse adaugă o oarecare complexitate WDR-ului, dar acestea pot fi realizate rapid cu operații de transfer de biți. După cum s-a explicat în Tian și Wells, ieșirea codificării WDR poate fi comprimată aritmetic. Metoda pe care o descriu se bazează pe algoritmul de codare aritmetică elementară descris în Witten, Neal și Cleary. Această formă de codificare aritmetică este substanțial mai puțin complexă (cu prețul unei performanțe mai slabe) decât codarea aritmetică utilizată de SPIHT.

Ca exemplu al algoritmului WDR, se ia în considerare ordinea de scanare și transformarea wavelet prezentate în figura 29. Pentru pragul $T_1=32$, valorile semnificative sunt $w(1)=63$, $w(2)=-34$, $w(5)=49$ și $w(36)=47$. Ieșirea pasului de semnificație WDR va fi următorul șir de simboluri: + - + 1 + 1111 + 1101 + care se compară favorabil cu ieșirea EZW. Ultimele șase simboluri sunt codul pentru marcajul final. Pentru pragul $T_2=16$, noile valori semnificative sunt $w(3)=-31$,

$w(4)=23$, $w(9)=-25$ și $w(24)=18$. Deoarece indicii anteriori 1, 2, 5 și 36, sunt eliminați din secvența indicilor nesemnificativi, valorile lui n în trecerea de semnificație WDR vor fi 1, 1, 4 și 15. În acest caz, valoarea lui n pentru marker-ul final este 40. Adăugând cei patru biți de rafinament, ieșirea WDR pentru acest al doilea prag este: - + - 0 0 + 111 + 01000 + 1010, care este, de asemenea, o ieșire mai mică decât ieșirea EZW corespunzătoare. De asemenea, este clar că, pentru acest caz simplu, WDR nu produce o ieșire la fel de compactă ca STW.

2.3.2.1.4. ALGORITMUL ASWDR

Unul dintre cei mai recentți algoritmi de compresie a imaginilor pe bază de funcții wavelet este algoritmul de scanare adaptată a reducerii diferenței wavelet (Adaptively Scanned Wavelet Difference Reduction-ASWDR) a lui Walker. Adjectivul scanat adaptiv se referă la faptul că acest algoritm modifică ordinea de scanare utilizată de WDR pentru a obține performanțe mai bune.

ASWDR adaptează ordinea de scanare astfel încât să prezică locațiile noilor valori semnificative. Dacă o predicție este corectă, atunci ieșirea care specifică că locația va fi doar semnul noii valori semnificative-expansiunea binară redusă a numărului de pași va fi goală. Prin urmare, o schemă de predicție bună va reduce semnificativ ieșirea de codare a WDR.

Metoda de predicție utilizată de ASWDR este următoarea: dacă coeficientul wavelet $w(m)$ este semnificativ pentru pragul T , atunci se estimează că valorile copiilor lui m vor fi semnificative pentru jumătate de prag $T/2$. Pentru multe imagini naturale, această metodă de predicție este una rezonabilă. De exemplu, figura 32 prezintă două sub-benzi verticale pentru o transformare wavelet discretă calculată folosind funcția wavelet mamă Daub 9/7 a imaginii „Lena”.

Imaginea din figura 32a) este a acelor valori semnificative din sub-banda verticală de la nivelul al doilea de descompunere pentru un prag de 16. În Figura 32b), sunt prezentate valorile semnificative din sub-banda verticală de la primul nivel de descompunere pentru un prag de valoare 8. Se observă o mare asemănare între cele două imagini. Deoarece imaginea din figura 32a) este mărită de două ori în fiecare dimensiune, pixelii săi albi reprezintă de fapt predicțiile pentru locațiile valorilor semnificative din sub-banda verticală de la primul nivel de descompunere. Deși aceste predicții nu sunt perfect exacte, există o mare suprapunere între cele două imagini. Observăm, de asemenea, modul în care locațiile valorilor semnificative sunt puternic corelate cu locația muchiilor din imaginea „Lena”. Ordinea de scanare a ASWDR se adaptează dinamic la locațiile muchiilor dintr-o imagine, iar acest lucru îmbunătățește rezoluția acestor muchii în imaginile comprimate ASWDR.




Figura 32. (a) Valori semnificative, sub-banda verticală de la al doilea nivel de descompunere, pragul 16. (b) Valori semnificative, sub-banda verticală de la primul nivel de descompunere, pragul 8.

Imagini cu un raport de compresie ridicat, precum acestea, sunt utilizate în recunoașterea obiectelor și în aplicații medicale, unde sunt folosite transmisii rapide și ROI, precum și la detecția obiectelor multirezoluție. Algoritmii WDR și ASWDR permit alegerea ROI, în timp ce SPIHT nu. În plus, performanța lor superioară în afișarea muchiilor la rate de biți reduse facilitează detecția multirezoluție a obiectelor din imagini. Se fac cercetări suplimentare privind îmbunătățirea algoritmului ASWDR. O îmbunătățire importantă va fi încorporarea unei scheme predictive îmbunătățite, bazată pe valorile ponderate ale mărimilor transformate în vecinate, așa cum este descris în [104].

2.3.2.2. Compresia fără pierderi

Compresia fără pierderi a imaginii este o metodă de compresie a datelor care respectă cerințele de comunicare și stocare a imaginilor digitale fără a pierde informație. Pentru a îndeplini această sarcină, algoritmii de compresie fără pierderi exploatează diverse redundanțe care există în datele de imagine.

Redundanța spațială privește corelațiile puternice care există între valorilor pixelilor vecini în imaginile naturale. După decorelare, multe eșantioane de date vor avea o mărime mai mică, necesitând mai mulți biți în cod decât valorile inițiale ale pixelilor. Procedurile obișnuite de decorelare includ codarea predictivă (de exemplu, modularea diferențială a impulsurilor în cod) și codarea prin transformare (de exemplu transformarea cosinus discretă sau transformarea wavelet discretă).

Redundanța de codare rezultă din reprezentarea neuniformă a valorilor eșantionului în datele imaginii. În special după decorelare, eșantioanele de date vor lua valori de mărime mică, cu o frecvență mult mai mare decât valorile de mărime mai mari. Devine ineficient să folosim același număr de biți pentru a reprezenta fiecare valoare, în schimb ar trebui codate valori frecvente cu mai puțini biți decât valorile care apar mai rar. Procesul de eliminare a acestor redundanțe este denumit codare entropică și este de obicei unul dintre ultimii pași ai unui algoritm de compresie cu pierderi. Exemple de tehnici de codare entropică includ codarea Huffman, codarea pe lungime de rulare (Run-Length) și codarea aritmetică.

2.3.2.2.1. Performanța de compresie

Performanța unui algoritm de compresie a imaginii fără pierderi este determinată de capacitatea sa de a reduce numărul de biți necesari pentru a reprezenta în mod unic o imagine. Un mod natural de a exprima acest lucru este prin raportul de compresie din ecuația (2.104), care este un raport dintre lungimile fluxurilor de biți înainte și după compresie:

$$\text{raport de compresie} = \frac{D_r D_c B}{L_C} \quad (2.104)$$

Numărătorul din ecuația (2.103) dă lungimea fluxului de biți necomprimat, unde D_r și D_c reprezintă numărul de pixeli exprimați cu B biți de pe fiecare linie și respectiv de pe fiecare coloană. Numitorul L_C reprezintă lungimea fluxului de biți comprimat. Raportul de compresie este o măsură de calitate relativă fără unități de măsură, care nu indică cerințele reale de stocare ale unui flux de biți comprimat. Rata de biți (R) este o măsură absolută care indică în medie numărul de biți utilizați pentru codarea eşantioanelor de date individuale. Pentru imagini, pixelii sunt considerați eşantioane individuale, iar rata de biți este descrisă în biți pe pixeli (bpp) în ecuația (2.105):

$$R = \frac{L_C}{D_r D_c} \text{ biți/pixel} \quad (2.105)$$

Un aspect nou al metodelor de compresie/decompresie schematizate în figurile 24 și 25 este că transformărilor wavelet obișnuite (cum ar fi de exemplu transformata wavelet discretă calculată cu funcția wavelet mamă Daub 9/7) descrise până acum pot fi înlocuite cu transformările wavelet cu coeficienți întregi. O transformată wavelet cu coeficienți întregi produce o imagine cu mai multe niveluri de gri ai cărei pixeli au valori întregi [35]. Deoarece n niveluri de cuantizare uniformă necesită o cuantă de $T_0/2^n$, rezultă că ori de câte ori 2^n este mai mare decât T_0 nu va exista eroare de cuantizare. Cu alte cuvinte, rezultatul cuantizării va fi exact același cu cel al transformatei wavelet originală; prin urmare se realizează cuantizarea fără pierderi (permițând și transmisia progresivă).

2.3.2.3. Compresia amprentelor FBI

Standardul FBI, care folosește o abordare cunoscută sub numele de codare a imaginii cu transformare wavelet/cuantificare scalară (Wavelet Scalar Quantization-WSQ), a fost dezvoltat de liderul de proiect Tom Hopper de la Divizia de Servicii de Informații a Justiției Criminale a FBI și de Jonathan Bradley și Chris Brislawn de la Grupul de cercetare și aplicații informatice la laboratorul național din Los Alamos. Standardul, care se află în întregime în domeniul public, implică o transformată cu pachete de funcții wavelet discretă bidimensională (DWPT), cuantificare scalară uniformă și codare entropică sau Huffman (adică, codarea ieșirii DWT cuantizate cu un număr minim de biți).

FBI are o bază de date formată din aproximativ 200 de milioane de înregistrări de amprente, stocate pe hârtie (așa cum au fost încă de la începutul secolului) sub formă de desene cu cerneală. Ca parte a unui program de modernizare, FBI digitalizează aceste înregistrări ca imagini pe 8 biți în tonuri de gri, cu o rezoluție spațială de 500 de puncte pe inch. Acest lucru are ca rezultat ocuparea unei zone de memorie semiconductoare de aproximativ 10 mega-octeți pe amprentă, ceea ce face ca arhiva actuală să aibă o dimensiune de aproximativ 2.000 de terabiți. Mai mult, FBI primește în jur de 30.000 de amprente noi (\equiv 300 gigaoceteți) pe zi, din toată țara, pentru verificări de fond.

După luarea în considerare a acestor numere, FBI a decis că o anumită formă de compresia a datelor ar fi necesară și a efectuat o anchetă asupra tehnologiei disponibile de compresie a imaginilor. Compresia datelor din domeniul transformării se bazează pe găsirea unei reprezentări a semnalului, de preferință una calculabilă printr-un algoritm de transformare rapidă, care oferă capacitatea de a reprezenta semnalele complicate cu precizie cu un număr relativ mic de biți. Acest rol a fost îndeplinit în mod tradițional de Transformarea Fourier Rapidă și variantele sale trigonometrice rapide aferente, în special transformarea cosinus discretă. Cu toate acestea, transformarea în pachete de funcții wavelet oferă o alternativă importantă, proprietățile sale făcând-o potrivită pentru codarea imaginilor de înaltă rezoluție. Primul algoritm de codare a imaginii luat în considerare de FBI a fost standardul de compresie a imaginilor elaborat de către grupul mixt de experți fotografici al Organizației Internaționale a Standardelor (cunoscut sub numele de „JPEG”). Standardul JPEG se bazează pe partiționarea unei imagini digitale în blocuri de 8×8 pixeli, aplicarea unei transformări cosinus discretă bidimensională la fiecare bloc și compresia fără pierderi a ieșirii fiecărei transformate. Cu toate acestea, chiar la rapoarte de compresie moderate, algoritmul JPEG produce uneori „artefacte de placare” inacceptabile; vezi figura 33. Pentru comparație, în figurile 33b) și 33a) sunt prezentate o versiune necomprimată a imaginii originale și o versiune comprimată JPEG, având un factor de compresie în jur de 0,6 biți /pixel.




Figura 33. a) Imagine de amprentă digitală comprimată JPEG, 0.6 biți/pixel.

În figura 34 este prezentat rezultatul reconstrucției după compresia WSQ a imaginii din figura 33 b) cu același factor de compresie (0.6 biți/pixel). Comparând vizual imaginile din figurile 33 a) și 34 observăm lipsa artefactelor de placare în cazul imaginii din figura 34. În plus față de lipsa artefactelor de placare din imaginea WSQ, reținem și păstrarea mai bună a detaliilor la scară fină din imagine, cum ar fi porii sudoripari din mijlocul creștelor amprentelor digitale. (Acestea sunt puncte de identificare legal admisibile!)




Figura 34. Imagine de amprentă digitală comprimată WSQ, 0.6 biți/pixel.

Strategiile de cuantificare a coeficienților de transformare cosinus discretă tind să sacrifice conținutul de înaltă frecvență al semnalului pentru a păstra informații mai importante de frecvență joasă, producând netezirea excesivă a muchiilor. O anumită formă de artefacte de placare este, prin urmare, o componentă inevitabilă a oricărui algoritm de compresie a imaginii bazat pe transformata Fourier. Din păcate, artefactele de placare inerente codării imaginilor JPEG sunt deosebit de supărătoare în aplicația de amprentă digitală din cauza faptului că frecvența spațială de plăci corespunzătoare dimensiunii blocurilor de 8x8 pixeli impusă de standardul JPEG este apropiată de frecvența spațială naturală a creștelor de amprentă digitală în scanări de 500 dpi. Pe baza testărilor efectuate de FBI și grupul de cercetare a poliției din cadrul biroului intern al Regatului Unit, se pare că artefactele de placare JPEG sunt inevitabile în imaginile de amprentă digitală la rapoarte de compresie peste 10:1, chiar și cu algoritmi JPEG personalizați. Mai mult, din moment ce aceste artefacte tind să apară brusc și cu vizibilitate ridicată pe măsură ce se măresc rapoartele de compresie, standardul JPEG nu este robust în ceea ce privește chiar erorile de supracompresie ușoare, care pot fi de așteptat în sistemele extrem de automatizate. Artefactele de placare sunt nu numai inacceptabile din punct de vedere vizual, dar rezultatele obținute de Hopper și Preston [111] indică faptul că acestea afectează, de asemenea, performanța unui utilizator final cheie pentru imaginile de amprentă digitală: programele de extragere automată a caracteristicilor de amprentă digitală. Acestea sunt algoritmi computerizați care marchează amprente pentru comparații automate, urmărind creștele amprentei și localizând capetele și bifurcațiile creștei, un proces complicat de muchiile ascuțite și colțurile asociate cu artefacte de placare.

În contrast, descompunerile bazate pe bancuri de filtre digitale realizează localizarea simultană în frecvență fără a fi nevoie de ferestre. În loc să producă artefacte de placare la rapoarte de compresie ridicate, rezultatele schemelor de compresie a imaginii bazate pe bancuri de filtre se degradează prin pierderea rezoluției detaliilor de înaltă frecvență din imagine. Acest tip de estompere treptată pe măsură ce crește raportul de compresie este considerat de FBI ca un răspuns mai grațios la erorile de supracompresie decât apariția bruscă a artefactelor pronunțate de placare. Mai mult, Hopper și Preston au descoperit că, estompări ușoare nu afectează în mod negativ performanța programelor de detecție a muchiilor.

Datorită performanței nesatisfăcătoare a algoritmului JPEG la compresia imaginilor de amprente digitale, FBI a investigat o serie de metode alternative de

compresie a imaginii. În plus față de standardul JPEG, algoritmi studiați în [110] au inclus o transformată cosinus discretă locală și o descompunere ortogonală în pachete de funcții wavelet în cea mai bună bază, ambele dezvoltate la Universitatea Yale; un algoritm de transformare wavelet cu funcții wavelet mamă biortogonale cu patru niveluri de descompunere la scară de o octavă; un algoritm de cuantizare vectorială dezvoltat la Los Alamos; și o descompunere wavelet folosind o funcție wavelet mamă biortogonală specială și cuantizare scalară (WSQ), dezvoltată de FBI. Algoritm bazat pe transformarea cosinus locală a avut artefacte de placare mai puțin pronunțate decât JPEG, dar nu a produs un grad de calitate a imaginii la fel de ridicat ca cele trei metode bazate pe funcții wavelet. Algoritm bazat pe descompunerea în pachete de funcții wavelet în cea mai bună bază a produs o calitate ridicată a imaginii, dar a durat mult mai mult pentru a comprima o imagine (de 4 sau 5 ori mai mult) decât algoritmi care asociază o transformată wavelet discretă cu o cuantizare scalară sau vectorială, care au produs o calitate a imaginii satisfăcătoare. Spre deosebire de aceste două metode, care folosesc ambele o descompunere de tipul transformare wavelet discretă fixă pe toate imaginile, metoda de descompunere în pachete de funcții wavelet în cea mai bună bază construiește o descompunere cu localizare în domeniul frecvență optimă, care minimizează un cost funcțional pentru fiecare imagine individuală. Această optimizare nu a justificat însă creșterea timpului de rulare de 4 sau de 5 ori. În mod similar, cuantizarea vectorială nu a reușit să producă îmbunătățiri ale performanței rată/distorsiuni suficient de mari față de cuantizarea scalară care are complexitate mai mică. Aceste rezultate sugerează că, cel puțin pentru această aplicație, a fost puțin de câștigat din utilizarea tehnicilor mai complexe decât o descompunere bazată pe transformata wavelet discretă fixă și pe cuantizarea scalară uniformă adaptivă. Alte experimente ale FBI au indicat că există, de asemenea, un avantaj mic sau deloc în utilizarea tehnicilor de codare aritmetică de complexitate mai mare față de algoritmul de codare Huffman relativ simplu. Pe baza acestor constatări, FBI a adoptat un standard de codare a imaginilor de amprente, WSQ, care încorporează unele dintre cele mai bune caracteristici ale algoritmului de cuantizare wavelet/vector Los Alamos. Acestea includ utilizarea metodelor de extensie simetrică pentru a gestiona condițiile de limitare la marginile imaginilor și un algoritm de proiectare al cuantizorului. Proiectarea optimă a cuantizorului este dată de soluția la o problemă de optimizare neliniară supusă unei constrângeri (liniare) asupra ratei de biți globale și a constrângerilor (convexe) de non-negativitate asupra ratelor de biți individuale utilizate pentru a coda sub-benzile transformării wavelet discrete. Aceasta oferă utilizatorului final un control eficient asupra ratei de compresie impuse unei imagini și acționează ca un „buton de calitate” care poate fi setat pentru a asigura o calitate uniformă a imaginilor comprimate. De exemplu, FBI a descoperit că imaginile produse de sisteme mai vechi de scanare în timp real (dispozitive care scanează vârful degetului mai degrabă decât un desen cu cerneală pe hârtie) sunt mai sensibile la zgomotul de cuantizare decât imaginile produse de o tehnologie mai nouă. Algoritm WSQ tolerează sistemele mai vechi și păstrează în continuare standarde ridicate de calitate a imaginii, stabilindu-le „butoanele de calitate” la un raport de compresie mai mic decât sistemele de imagistică mai noi. Specificația FBI [110] permite utilizarea potențială a unei clase întregi de sisteme de cuantizare diferite; de exemplu, diferite funcții wavelet mamă sau bancuri de filtre și diferite strategii de proiectare a cuantizorului. Coeficienții de filtru necesari, parametrii de cuantizare și tabelele Huffman sunt transmise ca informații laterale pentru a permite unui decodor universal să reconstruiască imaginile codate de

orice codor conform. Acest lucru va permite îmbunătățiri viitoare în proiectarea codorului. Până în prezent, FBI a aprobat doar un codor, utilizând un banc de filtre bazat pe funcții wavelet mamă simetrice biortogonale concepute de Cohen, Daubechies și Feauveau [106]. Ținta de compresie pentru acest codor de primă generație este de aproximativ 0.75 biți/pixel, ceea ce corespunde unei compresii de aproximativ 15:1 la imaginile medii de amprentă.

2.3.2.4. Compresia fractală

Compresia fractală este o nouă tehnică de codare compactă a imaginilor. Se bazează pe auto-similarități locale în cadrul imaginilor. Blocurile de imagine sunt văzute ca și copii rescalate și cu intensitatea transformată a unor blocuri găsite în altă parte a imaginii. Aceasta oferă o descriere autoreferențială a datelor imaginii, care-atunci când este decodată-prezintă o structură tipică fractală. Cea mai directă abordare a compresiei fractale este pe baza asemănării cu o anumită variantă de cuantizare vectorială.

Tehnicile fractale au fost introduse în grafica computerizată pentru modelarea fenomenelor naturale. Una dintre aceste idei noi a venit dintr-o teorie matematică numită sisteme de funcții iterate (Iterated Function Systems-IFS). Fractalii care se pot genera cu ușurință cu un sistem de funcții iterate sunt toți de un anumit tip. Ei sunt imagini care pot fi privite ca și colaje de deformare și intensitate transformată ale unor copii ale lor însele. Astfel, într-o codare IFS a unei imagini a unei fețe ar trebui să se vadă copii mici distorsionate ale feței peste tot. Acest lucru pare nu numai nenatural dar și irealizabil din punct de vedere tehnic. Apoi, în 1989, Arnaud Jacquin a realizat un prim sistem de codare fractală automat, lăsând în urmă gândirea rigidă în ceea ce privește mapările IFS globale. Ideea de bază abordată de Jacquin este foarte simplă. O imagine nu trebuie privită ca fiind un colaj de copii ale întregii imagini, ci de copii ale unor părți mai mici ale acesteia. De exemplu, o parte dintr-un nor cu siguranță nu arată ca un întreg peisaj cu nori, dar nu pare atât de puțin probabil să găsești o altă secțiune a unui nor sau a unei alte structuri în imagine care să arate ca secțiunea de nori dată.

Astfel, abordarea generală este de a împărți mai întâi imaginea într-o partiție-blocuri pătrate de dimensiune fixă în cel mai simplu caz-și apoi de a găsi câte o porțiune de imagine care să se asemene cu fiecare bloc. Această abordare a fost numită sistem local sau partiționat de funcții iterate.

Dezvoltarea lui Jacquin a fost ca cea a unui motor. În jurul motorului a construit un prim vehicul, o implementare viabilă de compresie a imaginii. Cu toate acestea, modul de proiectare optimă a unui astfel de vehicul a rămas de investigat. Există patru moduri de a vedea compresia fractală a imaginilor:

1. Sisteme de funcții iterate (IFS). Astfel de sisteme sunt operatori în spații metrice și au submulțimi fractale ca atractori.
2. Auto-cuantizare vectorială. Codarea fractală de bază este foarte asemănătoare cu un anumit tip de cuantizare vectorială (Vector Quantization-VQ), și anume așa-numita cuantizare vectorială cu câștig de formă prin eliminarea mediei (Mean-Removed Shape-Gain Vector Quantization-MRSG-VQ). În această abordare, un bloc de imagine este aproximat prin suma unei componente continue și o copie la scară a unui bloc de imagine preluată din cartea de coduri VQ. Compresia fractală diferă de MRSG-VQ deoarece cartea de coduri nu este disponibilă în mod explicit la decodor, ci mai degrabă dată implicit într-un mod auto-referențial.

3. Arbori wavelet auto-cuantizați (Self-Quantized Wavelet Subtrees-SQWS). Davis [110] a observat că în anumite cazuri compresia fractală este identică cu un anumit tip de compresie bazată pe transformată wavelet. Ideea este de a organiza coeficienții wavelet (obținuți prin calculul transformatei wavelet discretă cu ajutorul funcției wavelet mamă de tip Haar) într-un arbore și de a aproxima sub-arbori prin copii scalate ale altor sub-arbori mai apropiați de rădăcina arborelui wavelet.
4. Codarea bazată pe transformarea de tip convoluție. S-a observat că operațiunile efectuate la căutarea unei regiuni de imagine similară cu o regiune dată sunt, în esență, echivalente cu o operație de convoluție. Pentru codul fractal este selectat doar unul dintre termenii convoluției. Aceasta stabilește o relație strânsă cu codarea bazată pe transformare.

Fiecare dintre aceste patru puncte de vedere ale compresiei fractale a condus la o mai bună înțelegere a subiectului și a inspirat tot mai mulți cercetători. Relația cu funcțiile wavelet deschide posibilități interesante pentru codări hibride care pot conduce la cele mai bune curbe rată/distorsiuni posibile cu tehnicile fractale.

2.3.2.4.1. Funcții wavelet și compresia fractală a imaginilor

În compresia fractală, de obicei un bloc pătrat de dimensiune $2^r \times 2^r$ este aproximat de alt bloc de imagine cu dimensiunea $2^{r+1} \times 2^{r+1}$ printr-o corepondență liniară. Astfel, se încearcă găsirea unor structuri similare la două scări diferite. Deoarece fractalul are proprietatea de auto-similaritate la scări diferite, este firesc să se utilizeze metode multi-rezoluție pentru o analiză a compresiei fractale. Să explicăm pe scurt această idee printr-un exemplu. Pentru o imagine cu mai multe niveluri de gri de 512×512 pixeli, partiționată în blocuri de 16×16 pixeli, care nu se suprapun, un cod fractal C este determinat în mod standard, având în vedere grupul de domenii de blocuri de 32×32 pixeli care nu se suprapun. C conține informațiile despre 32×32 transformări. În decodare, C este utilizat pentru a calcula atractorul A_1 de dimensiune 512×512 . Dar C poate fi, de asemenea, aplicat iterativ la o imagine arbitrară de 256×256 pixeli, partiționată în blocuri de dimensiune 8×8 , calculând un atractor A_2 , sau la o imagine de 128×128 pixeli, partiționată în blocuri de dimensiune 4×4 , calculând un atractor A_3 și așa mai departe. Astfel, se ajunge la piramida de atractori A_1, A_2, \dots, A_5 , descriind diferite rezoluții ale atractorului A_1 . Relația dintre aceste straturi poate fi ușor de înțeles, de exemplu, folosind transformata wavelet discretă calculată cu funcția wavelet mamă de tip Haar.

Astfel de formulări explicite ale compresiei fractale prin intermediul analizei de tip wavelet sunt date în lucrările lui Davis [110] și Wallace [147].

După aplicarea transformatei wavelet folosind funcția wavelet mamă de tip Haar, un interval sau un domeniu este dat de media blocului și de un sub arbore wavelet, așa cum este prezentat în figura 35. Mediarea și subeșantionarea blocului de domeniu se traduce, în esență, prin trunchierea subarborelui wavelet de domeniu prin tăierea unor frunze. Pentru funcțiile wavelet mamă simetrice sau antisimetrice, operațiile de izometrie sunt ușor de încorporat. Astfel, în compresia fractală, o versiune la scară a arborelui de domeniu trunchiat este utilizată ca predicție pentru un subarbore wavelet de interval. Reținem că subarborile oferă partea dinamică a unui bloc; valoarea medie trebuie stocată separat. Ortogonalitatea transformării wavelet, permite calcularea parametrilor de scalare în domeniul wavelet.




Figura 35. a) interval 4x4 (negru), domeniu 8x8 (umbrit). b) sub-arborele wavelet corespunzător.

Părțile umbrite încrucișate ale subarborelui wavelet de domeniu pot fi utilizate pentru o predicție a subarborelui wavelet de interval.

Cunoașterea mediilor blocului de interval și a parametrilor de transformare a arborelui permite ca decodarea să se realizeze prin producția coeficienților de frecvență mai mare cu ajutorul coeficienților de frecvență mai mică. Numărul de octave decodate în acest mod determină rezoluția atractorului rezultat.

Funcția wavelet mamă de tip Haar este utilizată pentru a demonstra mecanismele de compresie fractală în spațiul timp-frecvență. Utilizarea funcțiilor wavelet-mamă de ordin superior oferă rezultate mult mai bune din punct de vedere vizual, deoarece nu există o blocare strictă a intervalelor. Cu alte cuvinte, în cazul folosirii funcțiilor wavelet de ordin superior se lucrează cu partiții suprapuse. Eliminarea efectelor de placare este una dintre caracteristicile principale ale abordării combinate a compresiei fractale și a compresiei cu funcții wavelet.

Un alt avantaj important al acestei abordări constă în schema de auto-cuantizare a subarborelui (SQS) propusă de Davis. Aici, metodele fractale din domeniul wavelet sunt combinate cu codificarea cu arbore zero, codarea scalară și un mod inteligent de utilizare a diferitelor scheme în mod optim. Comparând SQS cu metoda de compresie bazată pe funcții wavelet cu arbore zero încorporat propusă de Shapiro, se constată că schema SQS obține rezultate competitive din punct de vedere al ratei de compresie.

2.4. Îmbunătățirea contrastului

Senzorii de vedere nocturnă, cum ar fi, de exemplu cei în infraroșu, sunt folosiți frecvent pentru captarea imaginilor nocturne. Calitatea imaginii rezultate poate fi extrem de redusă, cu contrast slab, rezoluție scăzută, interval dinamic limitat și granulație. Gama dinamică a imaginilor și videoclipurilor poate fi afectată de diverși factori, cum ar fi: intensitatea luminii în scenă (în special noaptea, sau în cazul condițiilor meteorologice defavorabile, iluminarea insuficientă), expunerea neuniformă (umbre), ciclul de declanșare prea scurt al camerei și intervalul dinamic prea mic al sensorului sau al dispozitivului de afișare. În toate cazurile, intervalul dinamic redus distorsionează contrastul din imagine și are ca rezultat niveluri ridicate de zgomot. Acest lucru duce adesea la confuzie de obiecte și texturi, incapacitatea de a le segmenta corect și la iluzii vizuale, care rezultă în dezorientare, oboseală a utilizatorului, performanțe slabe de detectare și clasificare. Pentru a îmbunătăți calitatea vizuală a imaginii, este necesar să-i modificăm valorile de intensitate și, în special, să-i sporim contrastul.

Cele mai frecvent utilizate metodologii de îmbunătățire a contrastului unei imagini (Contrast Enhancement-CE) includ transformări ale nivelurilor de gri prin intermediul funcțiilor neliniare (logaritm [154], ridicare la pătrat [155], funcție gamma [4] etc.), tehnici bazate pe histograme [156], [157], [158], [159], [160] [161], [162], [163], [164], [165], [166], [167], optimizarea tonurilor [168], filtrarea pătratică neliniară [169] și metodele care operează în domeniul frecvenței, cum ar fi filtrul homomorfic [170]. Adesea, o combinație de mai multe tehnici oferă rezultate îmbunătățite, de exemplu transformarea logaritmică a pixelilor combinată cu operații morfologice utilizate pentru a modifica intensitatea [171]. Deși majoritatea metodelor de transformare a nivelurilor de gri funcționează în domeniul spațial, mai mulți autori au susținut în ultimii ani utilizarea funcțiilor wavelet și a altor transformări multi-scară (curvelets [172], [173], piramide direcționabile [174] etc.) sau transformarea cosinus discretă [175]. Avantajul utilizării acestor reprezentări este capacitatea lor de a analiza și modifica caracteristicile imaginii pe baza conținutului lor de frecvență spațială la diferite rezoluții.

Primele încercări de îmbunătățire a contrastului cu ajutorul funcțiilor wavelet au fost raportate în [176] unde s-a aplicat o funcție hiperbolică parametrizată gradientului coeficienților wavelet și în [177] unde contrastul imaginilor ecocardiografice a fost îmbunătățit prin aplicarea unei combinații de funcții sigmoide asupra coeficienților wavelet. Mulți alți autori au raportat îmbunătățirea contrastului cu ajutorul altor funcții parametrizate. În mod specific, acestea includ: scalare bazată pe derivate a doua a măsurii de contrast [178] sau aplicată gradientului multi-scară [179], funcția gamma aplicată fie coeficienților transformării curvelet [172], fie coeficienților piramidei direcționabile [174], funcțiilor liniare pe porțiuni [180], [181], [182], sau o combinație de curbe sigmoide [173] aplicată coeficienților curvelet, sau o tangentă hiperbolică ponderată de o Gaussiană aplicată coeficienților transformării contourlet [183], [184], [185].

S-a demonstrat că tehnicile de îmbunătățire a contrastului care acționează pe mai multe scări depășesc alte tehnici convenționale, cum ar fi corecția gamma și întinderea histogramei sau egalizarea în termeni de impresie vizuală. Atunci când se utilizează funcții de îmbunătățire a contrastului parametrizate, o problemă comună este alegerea parametrilor potriviți, care trebuie să fie estimați pentru a calcula o funcție de transfer optimă pentru o anumită imagine [161], [162], [167].

Practica des întâlnită în literatura de specialitate este de a determina parametrii imaginii, de exemplu, câștigul și intervalul de creștere și parametrii funcției parametrizate, pe baza unui test off-line pe un set reprezentativ de imagini [159], [160], [163], [164], [174], [180], [183], [187].

Excepții notabile sunt metodele care fac ca unii parametri să depindă de statisticile sub-benzilor wavelet sau de unele caracteristici generale asumate ale imaginii „naturale” sau „ideale” [172], [174], [180]. Se pare, totuși, că un grad mare de manipulare euristică este încă necesar atunci când se stabilește o relație directă între parametru și caracteristicile imaginii și, în cele din urmă, sunt utilizați diferiți parametri sau multiplicatori definiți de utilizator. Necesitatea unei proceduri automate de îmbunătățire a contrastului devine și mai evidentă la procesarea secvențelor video, unde estimarea off-line poate să nu fie posibilă. Atunci când se îmbunătățesc videoclipuri sau secvențe de imagini cu lumină slabă, cadru cu cadru, utilizarea metodelor menționate mai sus poate provoca un efect de sclipire în scene cu schimbări rapide. Această problemă, deși recunoscută ocazional de diverși autori, este rareori abordată corect. Soluțiile propuse includ media câștigului imaginii de ieșire pe mai multe cadre [160], [187] cu ponderile determinate prin teste de tipul încercare și eroare, condiționarea histogramei actuale de histograma cadrului anterior [163] și modelarea adaptării la schimbarea de luminanță a ochilui uman folosind funcția de descompunere exponențială [188]. Prin urmare, niciuna dintre aceste metode nu garantează pe deplin absența pâlpâirii într-o gamă largă de videoclipuri.

În acest subcapitol, este prezentată proiectarea unui algoritm CE rapid și simplu care funcționează pe o gamă largă de imagini fără a fi nevoie de intervenția utilizatorului. Algoritmul îmbunătățește contrastul în imagini și secvențe de imagini în mod adaptiv și, spre deosebire de abordările globale, estimează parametrii pe baza statisticilor locale ale coeficienților wavelet ai unei imagini. Mai mult, amplificarea zgomotului din imagine este evitată prin denoising simultan al coeficienților wavelet pe baza aceluiași ipoteze statistice. Pentru a aborda problema pâlpâirii din videoclipul îmbunătățit, se utilizează o schemă simplă de normalizare. Modificarea datorată normalizării este compensată de modificarea contrastului acceptabilă din punct de vedere perceptual derivată dintr-un model Nuanță-Saturație-Valoare (Hue-Saturation-Value - HSV). La evaluarea rezultatelor îmbunătățirii contrastului, pe lângă metoda subiectivă bazată pe observarea vizuală se folosesc și măsuri de calitate obiective, obținute prin calcul.

Acest subcapitol este organizat după cum urmează. Metoda de îmbunătățire a contrastului propusă este descrisă în detaliu în secțiunea 2.4.1, unde sunt date o nouă măsură de contrast și bazele matematice ale metodei de îmbunătățire a contrastului. Performanțele metodei sunt evaluate pe un set de imagini și sunt comparate cu alte tehnici CE în secțiunea 2.4.2.

2.4.1. Metoda de îmbunătățire a contrastului

Scopul principal al metodei de îmbunătățire a contrastului în imagini și videoclipuri propusă este prelucrarea imaginilor înregistrate în condiții de expunere slabă sau inegală. Astfel de imagini sunt adesea caracterizate prin niveluri ridicate de zgomot și distribuții foarte inegale ale intensității spațiale. În general, pentru a îmbunătăți o imagine cu lumină scăzută, pixelii de intensitate mică și medie ar trebui să fie amplificați, în timp ce pixelii de intensitate ridicată ar trebui să fie lăsați neschimbați sau atenuați. Ar trebui să se acorde o atenție deosebită la amplificarea pixelilor de mică intensitate, astfel încât zgomotul din imagine să nu fie amplificat.

În mod ideal, contrastul din imagine ar trebui să fie îmbunătățit local, menținând în același timp intensitatea echilibrată la nivel global în imagine. Schema bloc a metodei de îmbunătățire a contrastului propusă este prezentată în figura 36 și explicată în paragrafele următoare.




Figura 36. Schema bloc a metodei de îmbunătățire a contrastului propusă. $L(i)$, $L1$, $L2$ și $L(o)$ corespund luminanțelor de intrare, pre-procesată, îmbunătățită și respectiv de ieșire.

2.4.1.1. Transformare RGB în HSV

Când se prelucrează imagini color, în loc să îmbunătățească contrastul în fiecare canal de culoare separat, reprezentarea Roșu-Verde-Albastru (Red-Green-Blue RGB) este convertită în reprezentarea HSV și numai canalul V este procesat în continuare. Această abordare permite reducerea dimensionalității datelor procesate și reconstrucția perfectă a culorilor originale în imaginea de ieșire (procesarea separată a canalelor R, G și B duce adesea la modificarea culorilor în imaginea de ieșire). Astfel, componenta V este tratată ca o imagine cu mai multe niveluri de gri în timpul procesării ulterioare. Cele trei canale H, S și V sunt obținute după cum urmează [189]:

$$V = \max(R, G, B) \quad (2.106)$$

$$S = \begin{cases} 0, & V = 0 \\ \frac{C}{V}, & \text{în rest} \end{cases} \quad (2.107)$$

$$H = \begin{cases} \frac{G - B}{S}, & R = V \\ 2 + \frac{B - R}{S}, & G = V \\ 4 + \frac{R - G}{S}, & B = V \end{cases} \quad (2.108)$$

unde C (crominanța) se calculează astfel:

$$C = \begin{cases} 1, & V = \min(R, G, B) \\ V - \min(R, G, B), & \text{în rest} \end{cases} \quad (2.109)$$

2.4.1.2. Pre-procesare

Pixelii imaginilor sau videoclipurilor înregistrate în scenarii cu lumină slabă sunt caracterizați de obicei printr-un interval dinamic foarte scăzut, care nu se potrivește cu cel al dispozitivului de detecție și/sau afișare utilizat. Prin urmare, este necesar să se normalizeze imaginile sau cadrele video, astfel încât să fie utilizată întreaga gamă dinamică.

Pentru imagini statice este suficient să se transforme luminanța liniar, pentru a acoperi întregul interval [0 1]:

$$L_1(k) = \frac{L^{(i)}(k) - \min\{L^{(i)}(k)\}}{\max\{L^{(i)}(k) - \min\{L^{(i)}(k)\}}} \quad (2.110)$$

unde $L^{(i)}(k)$ este luminanța cadrului video de intrare la momentul k și operatorii \max și \min sunt utilizați pentru a obține luminanța maximă și minimă în cadrul dat. Cu toate acestea, atunci când se tratează videoclipuri, intervalul dinamic de luminanță se poate schimba rapid de la cadru la cadru, de exemplu ca urmare a intrării unui obiect luminos sau întunecat în scenă, o schimbare bruscă a condițiilor de lumină (de exemplu, aprinderea unor lumini puternice) sau ajustări bruște ale sensibilității camerei. Astfel, normalizarea fiecărui cadru poate provoca pâlpare nedorită în videoclipul îmbunătățit care poate distra atenția sau poate obosei operatorul uman. Schimbările rapide ale luminozității în videoclipul îmbunătățit pot fi evitate prin introducerea dependenței temporale a luminanței în normalizare. În scopul normalizării cu luarea în considerare a dependenței temporale, contrastul în cadrul k , este definit după cum urmează:

$$W(k) = \frac{\bar{L}^{(i)}(k) - \min\{L^{(i)}(k)\}}{\min\{L^{(i)}(k)\} + 1} \quad (2.111)$$

Utilizarea valorii medii a luminanței $\bar{L}^{(i)}$ asigură limitarea efectului asupra estimării contrastului. Valoarea minimă a luminanței poate fi ajustată pentru a fi constantă pentru toate cadrele, $\min\{L^{(i)}(k)\} = 0$ și deci din (2.111) rezultă:

$$\Delta W(k) = W(k+1) - W(k) = \bar{L}^{(i)}(k+1) - \bar{L}^{(i)}(k) = \Delta \bar{L}^{(i)}(k) \quad (2.112)$$

S-a arătat în [190] că pragurile de detecție ale sistemului vizual uman (Human Visual System-HVS) ΔW_{thr} (de la un cadru la altul) pentru întreaga gamă de contrast vizibil (măsurătorile publicate în [191]) pot fi modelate prin aplicarea unei funcții continue la datele empirice:

$$\Delta W_{thr}(k) = 0.0928W(k)^{1.08} + 0.0046W(k)^{-0.183} \quad (2.113)$$

Redimensionarea intervalului de intensitate în cadrul $k+1$ care determină schimbarea contrastului $\Delta W(k) = \Delta W_{thr}(k)$ se realizează prin amplificarea imaginii cu un factor g calculat după cum urmează:

$$g = 1 + \text{sign}(\Delta \bar{L}^{(i)}(k)) \frac{\Delta W_{thr}}{\bar{L}^{(i)}(k)} \quad (2.114)$$

Se propune ca, în cazul procesării unui videoclip, primul cadru să fie normalizat în conformitate cu (2.110) și apoi următoarele cadre să fie ajustate folosind (2.114).

2.4.1.3. Transformarea wavelet complexă cu arbore dual

De preferință, caracteristicile care apar la anumite scări ar trebui îmbunătățite selectiv, iar transformarea wavelet ne permite să atingem acest obiectiv cu cheltuieli de calcul foarte mici, rezultând o performanță îmbunătățită. Imaginii pre-procesate i se aplică, prin urmare, o analiză multi-rezoluție. În acest scop, se recomandă o transformare wavelet bidimensională

complexă, ca de exemplu transformata wavelet complexă cu arbore dual (Dual Tree Complex Wavelet Transform-DTCWT) [192], introdusă în paragraful 2.1.3.G). Aceasta este o reprezentare multi-scară redundantă, caracterizată prin cvasi-invarianță la translații și selectivitate direcțională îmbunătățită față de Transformarea Wavelet Discretă convențională. În urma recomandărilor din [34], [193] și a unei verificări experimentale, s-a decis utilizarea filtrelor *AntonB* cu niveluri de descompunere alese în funcție de dimensiunea imaginii conform următoarelor formule: $J = \lceil (\log_2 \min\{N_w, N_h\}) \rceil - 4$, unde N_w și N_h sunt lățimea și respectiv înălțimea imaginii.

2.4.1.3. Denoising cu distribuție Cauchy izotropă

Așa cum s-a menționat la începutul subcapitolului, atunci când se efectuează îmbunătățirea contrastului, ar trebui evitată amplificarea zgomotului prezent în imaginile cu lumină slabă. Acest lucru se realizează prin combinarea îmbunătățirii contrastului cu operația de denoising. Dovezile din studiile anterioare (de exemplu [194], [195] și referințele acestora), arată că, repartiția coeficienților wavelet ai componentelor utile ale imaginilor (w_j) urmează frecvent un model care se abate semnificativ de la modelul Gaussian fiind mai apropiat de un model cu o distribuție α stabilă ($S\alpha S$). Acest filtru MAP a fost prezentat în paragraful 2.2.7.1.5. Alegerea distribuțiilor $S\alpha S$ ca model statistic al componentei utile a imaginii de prelucrat se bazează pe două argumente teoretice importante [196], [197]. În primul rând, variabilele aleatoare stabile satisfac proprietatea de stabilitate care afirmă că, orice combinație liniară de variabile aleatoare stabile este tot o variabilă aleatoare stabilă. Cuvântul stabil este utilizat deoarece forma distribuției este neschimbată (sau stabilă) în cadrul unor astfel de combinații liniare. În al doilea rând, procesele aleatoare stabile apar ca procese la limită ale sumelor de variabile aleatoare independente și identic distribuite (independent and identical distributed-iid) prin intermediul teoremei limită centrală generalizată. Procesele Gaussiene sunt procese stabile cu $\alpha=2$, în timp ce procesele Cauchy rezultă atunci când $\alpha=1$. De fapt, nu se cunosc expresii analitice explicite pentru repartițiile $S\alpha S$, cu excepția proceselor Gaussian și Cauchy. Densitatea de probabilitate a unui proces Cauchy bidimensional este formulată în ecuația (2.69) și ia în considerare dependențele inter-scară ale coeficienților wavelet. Dacă se consideră că zgomotul care perturbă imaginea de prelucrat este un proces aleator Gaussian bidimensional având repartiția din ecuația (2.67) atunci determinarea relației intrare-ieșire a acestui filtru MAP conduce la construcția operatorului de denoising A_d :

$$\hat{w}_j = A_d(x_j)x_j \quad (2.115)$$

2.4.1.4. Îmbunătățirea contrastului

Există mai multe măsuri ale contrastului:

$$C_s = \frac{\max\{L\}}{\min\{L\}}, \text{ contrast simplu} \quad (2.116)$$

$$C_W = \frac{\Delta L}{\min\{L\}}, \text{ fracția Weber} \quad (2.117)$$

$$C_l = \log_{10} \left(\frac{\max\{L\}}{\min\{L\}} \right), \text{ raport logaritmic} \quad (2.118)$$

$$C_M = \frac{|\max\{L\} - \min\{L\}|}{\max\{L\} + \min\{L\}}, \text{ contrastul Michelson} \quad (2.119)$$

unde L reprezintă luminanța pixelului de imagine. Aceste măsuri au fost inițial concepute pentru domeniul spațial și se referă la o relație pixel-la-vecinătate. Atunci când sunt aplicate în domeniul unei transformate, aceste măsuri pot deveni nesigure. Astfel, în acest subcapitol, se propune o nouă măsură de contrast, potrivită pentru domeniul transformatei wavelet, definită în funcție de dispersia locală a coeficienților wavelet:

$$C(x_j) = \frac{\max\{\hat{\gamma}_j(x_j)\}}{\hat{\gamma}_j(x_j)} \quad (2.120)$$

Măsura (2.120) este calculată într-o fereastră glisantă de dimensiune 3×3 pixeli centrată în jurul fiecărui coeficient wavelet x_j . Contrastul $C(x_j)$ este calculat în raport cu dispersia maximă în sub-banda wavelet curentă, $\max\{\hat{\gamma}_j\}$, $x_j \in X_j$; estimarea sa servește drept valoare de referință către care se măresc coeficienții wavelet pentru a obține contrastul dorit.

Valorile contrastului local sunt utilizate pentru a ajusta coeficienții wavelet corespunzători prin intermediul unei funcții exponențiale A_c :

$$A_c(x_j) = \exp\left(-\frac{1}{C(x_j)}\right) + A_0 \quad (2.121)$$

unde $A_0 = 1 - \exp(-1)$ este o constantă de normalizare care asigură că funcția converge la 1 în zonele cu dispersie ridicată. Deoarece funcțiile de denoising și îmbunătățire a contrastului sunt aplicate secvențial, coeficientul wavelet de detalii îmbunătățit poate fi estimat ca produs al funcției generale de îmbunătățire A_e și al coeficientului wavelet de detalii original,

$$\hat{w}_j = A_e(x_j)x_j = (A_d(x_j)A_c(x_j))x_j \quad (2.122)$$

unde A_d este funcția de denoising (2.115) și A_c este funcția de îmbunătățire a contrastului (2.121). Contrastul coeficienților de aproximare este optimizat cu metoda de Egalizare Adaptivă a Histogramei cu Contrast Limitat (Contrast Limited Adaptive Histogram Equalization-CLAHE) [156], [157], [159].

Această metodă populară împarte o imagine în mai multe regiuni care nu se suprapun (în cazul nostru, lățimea și înălțimea nu depășesc 8 coeficienți). În fiecare regiune este calculată o histogramă normalizată care este limitată la o valoare specificată (0.03 în cazul nostru). Pixelii care depășesc această limită sunt redistribuiți, dând naștere unei funcții de mapare. Pentru a evita distorsiunile în imaginea de ieșire, mapările nivelurilor de gri sunt interpolate între regiunile curente și cele învecinate.

2.4.1.5. Post-procesarea

În sistemul de îmbunătățire a contrastului imaginii propus, post-procesarea constă în logaritizarea imaginii cu luminanța L_2 , obținută după inversarea transformatei DTCWT (figura 36), obținându-se rezultatul final imaginea de ieșire $L^{(0)}$.

$$L(o) = \frac{\max\{L_2\}}{\log(\max\{L_2\} + 1)} \log(L_2 + 1) \quad (2.123)$$

Funcția logaritm aproximează transformarea realizată de retină și a fost utilizată pe scară largă pentru a comprima gama dinamică a imaginii [4], [174], [190]. Transformarea de acest tip amplifică valorile pixelilor întunecați în timp ce atenuază valorile de nivel ridicat ale pixelilor imaginii.

2.4.1.6. Transformarea HSV în RGB

În mod similar cu etapa de pre-procesare a sistemului, în etapa de post-procesare se efectuează o transformare HSV în RGB, prin combinarea componentelor originale H și S cu componenta V modificată, așa cum se arată în figura 36, conform următoarei formule [189]:

$$(R,G,B)=(R'+m,G'+m,B'+m) \quad (2.124)$$

unde $m=V-C$, este recuperată ca $C=VS$ și (R, G, B) este definit după cum urmează:

$$(R',G',B') = \begin{cases} (C, X, 0), & 0 \leq H < 1 \\ (X, C, 0), & 1 \leq H < 2 \\ (0, C, X), & 2 \leq H < 3 \\ (0, X, C), & 3 \leq H < 4 \\ (X, 0, C), & 4 \leq H < 5 \\ (C, 0, X), & 5 \leq H < 6 \\ (0, 0, 0), & \text{în rest} \end{cases} \quad (2.125)$$

2.5. Detecția muchiilor

Una dintre operațiile fundamentale de analiză a imaginii este detecția muchiilor. Muchiile sunt descriptori vitali pentru imagini, atât în vederea biologică cât și în vederea computerizată.

Noțiunea cotidiană de muchie este una fizică, legată fie de formele obiectelor în trei dimensiuni, fie de proprietățile materialului lor.

Descrise în termeni geometrici, există două tipuri de muchii:

1. setul de puncte de-a lungul cărora există o schimbare bruscă a orientării locale a unei suprafețe;
2. setul de puncte care descriu granița dintre două sau mai multe regiuni distincte ale unei suprafețe.

Majoritatea simțurilor noastre, inclusiv vederea, adună informații prin utilizarea receptorilor care funcționează în cel mult două dimensiuni.

Procesul imagistic realizează o proiecție dintr-o scenă 3-D într-o reprezentare bidimensională (2-D) a scenei, în conformitate cu poziția și caracteristicile dispozitivului care captează imaginea. Din cauza acestui proces de proiecție, muchiile din imagini pot avea o semnificație diferită de semnificația muchiilor fizice. Deși definiția precisă depinde de contextul aplicației, o muchie poate să fie definită ca o delimitare sau un contur care separă regiuni de imagine adiacente având trăsături (proprietăți) relativ distincte conform unor caracteristici de interes. Cel mai adesea această caracteristică este nivelul de gri sau luminața, dar uneori sunt folosite alte caracteristici, cum ar fi reflectanța, culoarea sau textura. În cea mai frecventă situație, în care caracteristica de interes este luminața, pixelii muchiei sunt localizați acolo unde apar schimbări bruște ale nivelului de gri. Pentru a elimina punctele izolate, un punct al unei muchii trebuie să facă parte dintr-o structură de muchie, având o anumită întindere minimă, adecvată pentru scara de interes. Detecția muchiilor este procesul de determinare a pixelilor care aparțin unei muchii.

Rezultatul procesului de detecție a muchiilor este de obicei o hartă de muchii, o nouă imagine binară care descrie rezultatul clasificării pixelilor din imaginea originală în pixeli care aparțin unei muchii și pixeli care nu aparțin vreunei muchii. Există, de obicei, o corespondență puternică între muchiile fizice ale unui set de obiecte și muchiile din imaginile care conțin vederi ale acelor obiecte. Sugarii și copiii mici învață acest lucru pe măsură ce dezvoltă coordonarea mână-ochi, asociind treptat tiparele vizuale cu senzațiile de atingere, pe măsură ce simt și manipulează obiecte din vecinătatea lor. Cu toate acestea, există multe situații în care muchiile dintr-o imagine nu corespund cu muchii fizice. Diferențele de iluminare sunt de obicei responsabile pentru acest efect; de exemplu, limita (granița) unei umbre proiectată (aruncată) peste o astfel de suprafață uniformă. Muchiile fizice nu dau întotdeauna naștere la muchii în imagini. Acest lucru poate fi cauzat de iluminare și de proprietățile suprafețelor obiectelor din imagine.

Dacă se definește o muchie ca o modificare bruscă a nivelului de gri, atunci derivata sau gradientul acelei imagini reprezintă o bază naturală pentru un detector de muchii. Natura discretă a imaginilor digitale necesită utilizarea unei aproximări a derivatei. Deoarece operația de derivare acționează ca un filtru trece-sus, detectoarele de muchii bazate pe aceasta sunt sensibile la zgomot. O mare varietate de algoritmi de detecție a muchiilor au fost dezvoltați în ultimele trei decenii, în mare parte, din cauza numeroaselor modalități propuse pentru a face față

zgomotului și efectelor sale. Majoritatea algoritmilor utilizează un anumit fel de filtrare de suprimare a zgomotului înainte de a aplica detectorul de muchii propriuzis. Unele descompun imaginea într-un set de versiuni trece-jos sau trece-bandă, aplică detectorul de margine la fiecare versiune și îmbină rezultatele. Alții utilizează metode adaptive, modificând parametrii și comportamentul detectorului de muchii în funcție de caracteristicile de zgomot ale imaginii date.

Există un compromis important între detectarea corectă a muchiilor reale și locația exactă a pozițiilor lor. Erorile în detectarea muchiilor pot apărea sub două forme: fals pozitive și fals negative. Erorile de detecție de ambele tipuri tind să crească odată cu creșterea puterii zgomotului, ceea ce face foarte importantă suprimarea zgomotului în scopul atingerii unei precizii ridicate de detecție.

2.5.1. Metode bazate pe gradient

După cum s-a arătat deja, putem vorbi despre gradientul continuu sau despre gradientul discret.

2.5.1.1. Gradient continuu

În formă continuă, gradientul este un vector bi-dimensional ale cărui componente sunt derivatele parțiale ale imaginii în raport cu cele două axe de coordonate, orizontală și verticală.

Modulul gradientului continuu, $|\nabla f_c(x_0, y_0)|$, măsoară rata de schimbare a intensității imaginii în punctul (x_0, y_0) . Argumentul gradientului continuu măsoară direcția pe care are loc cea mai mare creștere a intensității. Pentru a obține un detector de muchii, se caută extremele locale ale lui $\nabla f_c(x, y)$. Înțelesul precis al lui „local” este aici foarte important. Dacă pentru determinarea maximelor gradientului se utilizează vecinătăți 2-D, rezultatul este mai degrabă un set de puncte izolate decât contururile de muchie dorite. Problema provine din faptul că modulul gradientului este rareori constant de-a lungul unei muchii date, deci căutarea maximelor locale 2-D găsește doar cele mai puternice puncte de muchie. Pentru a construi muchii continue, este mai bine să se folosească vecinătăți locale 1-D, și anume segmente de linie, ale căror direcții sunt alese să traverseze muchia. Acum problema devine cum să se selecteze direcția cea mai bună pentru segmentul de linie utilizat pentru căutare. Cea mai utilizată metodă de a produce segmente de muchii constă din două etape: comparația cu prag și subțierea. În etapa de comparație cu prag, modulul gradientului este comparat în fiecare pixel cu o valoare de prag predefinită, T . Toate punctele pentru care modulul gradientului este mai mare sau egal cu valoarea de prag sunt clasificate ca puncte de muchie candidat. Setul de puncte de muchie candidat tinde să formeze benzi, care au lățime strict pozitivă. Deoarece, de obicei se dorește ca muchiile să aibă lățime zero, o etapă de prelucrare ulterioară este necesară pentru a subția benzile până la muchiile finale. Subțierea marginii poate fi realizată în mai multe moduri, în funcție de aplicație, dar subțierea prin suprimarea valorilor ne-maxime este de obicei cea mai bună alegere. În general, ne dorim să suprimăm orice punct care nu este, în sens 1-D, un maxim local al modulului gradientului. Privind în direcția gradientului, se caută pe direcția perpendiculară pe direcția muchiei. Metoda este eficientă deoarece nu este necesar să se caute în mai multe direcții. De asemenea, tinde să producă segmente de muchie având o bună precizie de localizare.

Dacă s-ar face doar subțierea, fără comparația cu valoarea de prag, adică dacă s-ar alege acele puncte de muchie care au valoare maximă a modulului gradientului local, atunci s-ar detecta multe puncte de muchie false din cauza zgomotului. Zgomotul tinde să creeze puncte de muchie false, deoarece unele puncte din zone fără muchii se întâmplă să aibă modulul gradientului local de valoare maximă. Comparația cu o valoare de prag este adesea utilă pentru a reduce zgomotul înainte de subțiere. A fost dezvoltată o varietate de metode adaptive de alegere a pragului. În cadrul acestor metode, pragul este ajustat în funcție de anumite caracteristici ale imaginii, cum ar fi de exemplu, o estimare a raportului semnal-zgomot local. Pragurile adaptive pot face adesea o treabă mai bună de suprimare a zgomotului reducând în același timp gradul de fragmentare a muchiei.

Selectarea valorii pragului T este un compromis între dorința de a captura pe deplin muchiile reale din imagine și dorința de a elimina zgomotul. Creșterea lui T scade sensibilitatea la zgomot cu costul eliminării celor mai slabe muchii, forțând segmentele de muchie să devină mai frânte și fragmentate. Prin scăderea lui T , putem obține muchii mai conectate și mai bogate, dar sensibilitatea mai mare la zgomot este probabil să producă mai multe margini false.

Uneori este util un detector de muchii direcțional. Poate fi obținut prin descompunerea gradientului în componente orizontală și verticală și aplicarea lor separat.

2.5.1.2. Operatori cu gradient discret

În imaginea analogică, $f_c(x, y)$, x și y reprezintă axele orizontală și respectiv verticală. Fie imaginea digitală obținută prin reprezentarea lui $f_c(x, y)$ în spațiu discret, $f(n_1, n_2)$, cu n_1 descriind poziția pe orizontală și n_2 descriind poziția pe verticală. Pentru utilizare pe imagini digitale, componentele operatorului gradient continuu trebuie approximate sub formă discretă. Aproximarea ia forma unei perechi de filtre orientate ortogonal, $h_1(n_1, n_2)$ și $h_2(n_1, n_2)$, care trebuie să fie convoluționate separat cu imaginea digitală. Sunt necesare două filtre, deoarece gradientul necesită calculul unei perechi ortogonale de derivate direcționale.

Fiecare dintre cele două filtre implementează o derivată și ar trebui să aibă răspuns zero la o constantă, deci sumele coeficienților răspunsurilor la impuls ale celor două filtre ar trebui să fie egale cu zero.

Există mai multe tipuri de filtre de aproximare a derivatelor care pot fi utilizate în estimarea gradientului digital: Roberts; Prewitt; Sobel; Frei-Chen; Haralick [207].

La fel ca în cazul metodelor de detecție a muchiilor bazate pe gradient continuu și metodele de detecție a muchiilor bazate pe gradient discret sunt sensibile la zgomot. Suprimarea zgomotului poate fi îmbunătățită prin metodele descrise în [207].

2.5.2. Metode bazate pe Laplacian

Extremele gradientului pot fi găsite rezolvând ecuația obținută prin egalarea derivatei gradientului cu zero. Întrucât gradientul reprezintă derivata întâia a intensității imaginii, derivata gradientului va reprezenta derivata a doua a intensității imaginii. Această derivată a doua se mai numește și Laplacian.

2.5.2.1. Laplacian-ul continuu

Laplacian-ul este definit ca gradient al gradientului. Treccerile prin zero ale lui $\nabla^2 f_c(x, y)$ apar în punctele de extrem ale lui $\nabla f_c(x, y)$ din cauza acțiunii celei de-a doua derivate. Detectarea muchiilor bazată pe Laplacian are proprietatea remarcabilă că produce muchii de lățime zero, ceea ce face necesară etapa de subțiere a muchiilor. Acest lucru se datorează faptului că punctele de trecere prin zero ale Laplacian-ului în sine definesc locațiile pixel-ilor de muchie.

Laplacian-ul continuu este izotrop, nefavorizând nici o orientare particulară a muchiei. Un detector de muchie bazat exclusiv pe trecerile prin zero ale Laplacian-ului continuu produce contururi închise dacă imaginea, $f(x, y)$ îndeplinește anumite constrângeri de netezime [207]. Contururile sunt închise deoarece intensitatea pixel-ilor de muchie nu este luată în considerare, deci chiar cea mai graduală tranziție de intensitate produce o trecere prin zero a Laplacian-ului. De fapt, contururile de trecere prin zero ale Laplacian-ului definesc limitele care separă regiunile de intensitate aproape constantă în imaginea originală. Treccerile prin zero ale celei de-a doua derivate au loc în extremele locale ale primei derivate, dar multe treceri prin zero ale Laplacian-ului nu sunt maxime locale ale modulului gradientului. Unele minime locale ale modulului gradientului dau naștere la muchii fantomă, care pot fi în mare măsură eliminate prin comparare cu un prag a valorilor intensității pixel-ilor de pe muchie și eliminarea valorilor inferioare pragului.

Zgomotul reprezintă o problemă pentru detectorul de muchii Laplacian. În primul rând, acțiunea celei de-a doua derivate face ca Laplacian-ul să fie și mai sensibil la zgomot decât gradientul, care este bazat pe prima derivată. În al doilea rând, zgomotul produce multe contururi de muchie false deoarece introduce variații în regiuni de intensitate constantă în imaginea fără zgomot. În al treilea rând, zgomotul modifică locațiile punctelor de trecere prin zero ale Laplacian-ului, producând erori de localizare de-a lungul muchiilor. Problema muchiilor false induse de zgomot poate fi abordată prin aplicarea unui test suplimentar în punctele de trecere prin zero ale Laplacian-ului. Doar trecerile prin zero care satisfac acest nou criteriu sunt considerate puncte de muchie. O tehnică frecvent utilizată clasifică o trecere prin zero a Laplacian-ului ca un punct de muchie dacă variația locală a nivelului de gri în acel punct depășește un prag. O altă metodă este de a selecta muchiile puternice prin compararea modulului gradientului sau a pantei ieșirii Laplacian-ului la trecerea prin zero cu un prag și eliminarea punctelor care au valori inferioare pragului. Ambele criterii servesc la anularea punctelor de trecere prin zero ale Laplacian-ului care sunt cauzate mai probabil de zgomot decât de o muchie reală din scena originală. Desigur, eliminarea trecerilor prin zero ale Laplacian-ului în această manieră tinde să rupă contururile închise.

2.5.2.2. Laplacian-ul discret

Spre deosebire de gradientul discret, care este un vector, Laplacian-ul discret este un scalar. Prin urmare, este suficient un singur filtru digital, cu răspunsul la impuls $h(n_1, n_2)$, pentru realizarea unui operator Laplacian digital. Estimarea Laplacian-ului discret al imaginii digitale $f(n_1, n_2)$, este obținută prin convoluția acestei imaginii cu răspunsul la impuls $h(n_1, n_2)$.

2.5.2.3. Operatorul Marr-Hildreth

De obicei o singură imagine conține atât obiecte mari cât și obiecte mici. Pentru detecția muchiilor tuturor obiectelor din imagine sunt necesare detectoare de muchii care să acționeze la scări diferite. Informații despre scara muchiei sunt adesea utile pentru înțelegerea imaginii. De exemplu, muchiile la scară mare (rezoluție mică) tind să indice obiecte mari (forme grosiere), în timp ce muchiile la scară mică (rezoluție mare) tind să indice obiecte mici (textură). O muchie detectată pe o scară mare este mai probabil să fie semnificativă din punct de vedere fizic în scenă decât o muchie găsită doar la o scară mică. Mai mult, efectele zgomotului sunt de obicei mai dăunătoare la scări mai fine.

Marr și Hildreth [207] au susținut necesitatea unui operator care să poată fi reglat pentru a detecta muchiile la o anumită scară. Metoda lor se bazează pe filtrarea imaginii cu un nucleu Gaussian selectat pentru o anumită scară a muchiei (prin alegerea valorii deviației standard σ). Operația de netezire Gaussiană servește pentru a limita banda imaginii la un interval redus de frecvențe, reducând sensibilitatea la zgomot a detectorului de muchii bazat pe trecerile prin zero ale Laplacian-ului. Imaginea este filtrată pe o varietate de scări și trecerile prin zero ale Laplacian-ului sunt înregistrate pentru fiecare scară. Se obține astfel o colecție de hărți de muchii în funcție de scară. Fiecare punct de muchie poate fi considerat ca aparținând unei regiuni a spațiului scărilor, locația sa fiind o funcție de x , y și σ . Spațiul scărilor a fost folosit cu succes pentru a rafina și analiza hărțile de muchii. Nucleul Gaussian are câteva proprietăți foarte utile pentru această procedură de detecție a muchiilor. În primul rând, funcția Gaussiană este netedă și localizată în ambele domenii, atât în spațiu cât și în frecvență, oferind un bun compromis între nevoia de evitare a muchiilor false și necesitatea minimizării erorilor de localizare. După cum se știe (principiul incertitudinii), funcția Gaussiană minimizează incertitudinea de localizare în spațiul timp-frecvență. Operatorul Laplacian din Gaussiană (Laplacian of Gaussian-LoG) acționează ca un filtru trece-bandă (aplicarea nucleului Gaussian este echivalentă cu o filtrare trece-jos iar aplicarea Laplacian-ului este echivalentă cu o filtrare trece-sus). Nucleul Gaussian este separabil, ceea ce ajută la eficientizarea calculului. Răspunsul în frecvență al nucleului Gaussian este tot o funcție Gaussiană. Deoarece operațiile de convoluție cu nucleul Gaussian și de calcul al Laplacian-ului sunt ambele liniare și invariante la translații, ordinea lor poate fi inversată, eficientizându-se din punct de vedere computațional implementarea detectorului de muchii.

Pentru a implementa operatorul LoG într-o formă discretă, se poate construi un filtru, cu răspunsul la impuls $h(n_1, n_2)$, prin eșantionarea operatorului LoG continuu.

2.5.2.4. Diferența de Gaussiene

Operatorul LoG poate fi bine aproximat prin diferența dintre două Gaussiene (Difference of Gaussians-DoG) având scări alese corespunzător. Cu toate acestea, LoG este preferat de obicei, deoarece este optim din punct de vedere teoretic iar separabilitatea sa permite un calcul eficient [207]. Pentru aceeași precizie a rezultatelor, DoG necesită o dimensiune a filtrului puțin mai mare [207].

Natura folosește diferența de Gaussiene ca bază pentru arhitectura câmpului receptor vizual al retinei. Răspunsul la impuls în domeniul spațial al unei celule fotoreceptoare din retina mamiferelor are o formă aproximativ Gaussiană. Ieșirea fotoreceptorului transmite impulsuri electrice înspre celulele orizontale din stratul

adiacent de neuroni. Fiecare celulă orizontală calculează media răspunsurilor receptorilor din vecinătatea sa imediată, producând un răspuns la impuls în formă Gaussiană cu un σ mai mare decât cel al unui singur fotoreceptor. Ambele straturi își trimit ieșirile către cel de-al treilea strat, unde neuronii bipolari scad mediile vecinătăților cu σ mare din răspunsurile fotoreceptorilor centrali cu σ mic. Aceasta este o realizare biologică a diferenței de Gaussiene, aproximând comportamentul operatorului LoG. Retina implementează de fapt filtre trece bandă DoG la mai multe frecvențe spațiale [207].

2.5.3. Metoda lui Canny

Metoda lui Canny [207] folosește elemente ale ambelor abordări ale detecției de muchii, bazate pe gradient și respectiv pe Laplacian, deja prezentate. Metoda lui Canny are trei obiective simultane: rata scăzută a erorilor de detecție, localizarea bună a muchiilor și unicitatea răspunsului detectat pentru o muchie. Canny a presupus că erorile de detecție fals-pozitive și fals-negative sunt la fel de nedorite și le-a dat pondere egală. El a presupus că fiecare muchie are secțiune transversală și orientare aproape constante, dar metoda sa include o modalitate de a se detecta efectiv și muchiile curbate sau colțurile. Cu aceste constrângeri, Canny a determinat detectorul de muchii 1-D optim pentru muchiile de tip treaptă și a arătat că răspunsul său la impuls poate să fie aproximat destul de bine prin derivata unei funcții Gaussiene.

O calitate importantă a detectorului de muchii de tip Canny este prevenirea răspunsurilor multiple la o muchie adevărată. Fără acest criteriu, detectorul optim pentru muchiile de tip treaptă ar avea un răspuns la impuls de forma funcției semn (signum) trunchiată. Dar acest tip de filtru are o lățime de bandă mare, permițând zgomotului sau texturii să producă mai multe maxime locale în apropierea muchiei propriu-zise. De aceea și în cazul metodei lui Canny se folosește un nucleu Gaussian. Efectul acestui nucleu este prevenirea răspunsurilor multiple prin netezirea răspunsului la impuls de forma funcției semn trunchiată pentru a permite un singur vârf de răspuns în vecinătatea muchiei. Alegerea deviației standard a nucleului Gaussian controlează lățimea de bandă a filtrului și gradul de netezire. Astfel se controlează lățimea vecinătății în care se permite existența unui singur vârf în răspuns. Valoarea selectată pentru dispersia funcției Gaussiene ar trebui să fie proporțională cu puterea zgomotului prezent. Dacă valoarea dispersiei aleasă este prea mică, filtrul poate produce detecții multiple pentru o singură muchie; dacă această valoare este prea mare, localizarea muchiei este afectată. Deoarece valorile rapoartelor semnal pe zgomot ale diferitelor muchii dintr-o anumită imagine sunt diferite, este probabil ca implementarea unui singur filtru Gaussian în structura unui detector de muchii de tip Canny să nu conducă la detecția tuturor acestor muchii. Prin urmare, o procedură fiabilă de detecție a muchiilor ar trebui să funcționeze la mai multe scări.

Abordarea lui Canny începe prin netezirea imaginii cu un filtru Gaussian. Apoi se calculează gradientul rezultatului obținut și se estimează în fiecare pixel direcția gradientului. Dintr-un set pregătit de măști, se alege filtrul pentru detecția muchiilor având orientarea cea mai apropiată de direcția gradientului pentru pixelul vizat. Când este aplicat imaginii netezite Gaussian, acest filtru produce o estimată a modulului gradientului în acel pixel. Apoi, se suprimă pixelii corespunzători valorilor ne-maxime ale modulului gradientului prin testarea într-o fereastră mobilă de dimensiuni 3x3, comparând valoarea modulului din pixelul central cu valorile pixelilor aflați în celelalte poziții din fereastră.

Pixelii care supraviețuiesc în urma acestor teste sunt candidați pentru harta de muchii. Pentru a produce o hartă de muchii din acești pixeli candidați, Canny compară valorile modulelor gradientului din aceste poziții cu un prag calculat adaptiv folosind un comparator cu histerezis. O estimare a zgomotului din imagine determină valorile unei perechi de praguri, cu valoarea pragului superior de obicei de două sau trei ori mai mare decât valoarea pragului inferior. Un segment de muchie candidat este inclus în harta de muchii de ieșire dacă cel puțin unul dintre pixelii săi are modulul gradientului mai mare decât pragul superior, dar pixelii care au modulul gradientului mai mic decât pragul inferior sunt excluși. Această histereză ajută la evitarea ruperii conturilor, îmbunătățind în același timp capacitatea detectorului de a rejecta zgomot.

Se poate produce un set de hărți de muchii pe o gamă de scări, modificând valorile lui σ utilizate pentru a filtra Gaussian imaginea. Deoarece netezirea la diferite scări produce erori diferite de localizare a muchiei, un segment de muchie care apare în mai multe hărți, la scări diferite poate prezenta poziții diferite. Canny a propus unificarea setului de hărți de muchii într-un singur rezultat prin utilizarea unei tehnici pe care a numit-o „sinteza caracteristicilor”.

Filtrele de detecție a muchiilor preorientate, menționate anterior, au câteva proprietăți interesante. Fiecare mască include o derivată a funcției Gaussiene pentru a efectua derivata direcțională aproape optimă de-a curmezișul muchiei considerate. Un profil lin de mediere apare în mască de-a lungul direcției muchiei considerate, pentru a reduce zgomotul fără a compromite claritatea profilului muchiei. Pe direcția de netezire, întinderea filtrului este de obicei de câteva ori mai mare decât pe direcția derivatei când filtrul este destinat muchiilor drepte. Metoda lui Canny include un test „de potrivire” pentru a determina dacă filtrul selectat este adecvat înainte de a fi aplicat. Testul examinează varianța nivelului de gri în banda de pixeli de-a lungul direcției de netezire a filtrului. Dacă varianța este mică, atunci muchia trebuie să fie aproape liniară și filtrul este o alegere bună. Varianța mare indică prezența curburii sau a unui colț, caz în care o alegere mai bună a filtrului ar conduce la o întindere mai mică în direcția de netezire. De obicei se folosesc șase filtre orientate. Cea mai mare nepotrivire direcțională între gradientul real și filtrul cel mai apropiat este de 15° , ceea ce produce o variație maximă a valorii modulului gradientului de $\sim 15\%$ din valoarea reală.

După cum s-a amintit deja, muchiile pot fi detectate fie din maximele modulului gradientului fie din trecerile prin zero ale Laplacian-ului. Laplacianul nu este vector, deci nu are direcție. O altă modalitate de implementare a metodei lui Canny este de a căuta treceri prin zero ale derivatei direcționale de ordinul doi luată de-a lungul direcției gradientului și include o componentă luată paralel cu muchia și alta perpendiculară pe muchie. În cazul metodei lui Canny este considerată doar componenta în direcția gradientului, perpendiculară pe muchie. O derivată luată de-a lungul unei muchii este contraproductivă deoarece introduce zgomot fără a îmbunătăți capacitatea de detecție a muchiilor.

O altă metodă de detecție a muchiilor pe mai multe scări combină detectorul lui Canny și multiplicarea scării. Un instrument cu adevărat cuprinzător pentru detecția muchiilor pe mai multe scări este transformarea wavelet. Mallat a dovedit echivalența unui detector de muchii multicanal de tip Canny cu găsirea maximelor locale din fiecare sub-bandă a unei transformate wavelet utilizând o funcție de netezire Gaussiană. Abordarea pe mai multe scări combină maximele locale ale unei transformări wavelet găsite la diferite scări pentru a obține harta de muchii rezultată sau înmulțește coeficienții wavelet la două scări adiacente.

Imperfecțiunile sistemelor de achiziție produc imagini contaminate de zgomot, care necesită detectoare de muchii robuste. Putem găsi deja diferite detectoare de muchii robuste în literatură. Cel mai recent publicat este un detector de muchii robust, bazat pe funcții wavelet hiperanalitice [96] și reprezintă una dintre contribuțiile acestei teze de doctorat. Pentru a asigura robustețea la zgomot, imaginii achiziționate i se aplică mai întâi procedura de denoising bazată pe funcții wavelet hiperanalitice, descrisă în paragraful 2.2.13 iar rezultatului obținut i se aplică metoda lui Canny de detecție a muchiilor.

În continuare se compară rezultatele metodei propuse cu rezultatele obținute aplicând detectorul de muchii al lui Canny direct la imaginea achiziționată pentru două tipuri de zgomot: AWGN și speckle. Evaluăm abordarea propusă atât pe imagini sintetizate, cât și pe imagini reale. Pentru a evalua performanța metodei propuse pe imagini sintetizate, am efectuat simulări folosind imagini naturale, precum Lena, Boat și Barbara. Am adăugat imaginilor zgomot alb Gaussian independent și distribuit identic (iid) la diferite PSNR determinate de varianța zgomotului σ_n^2 . Am sintetizat și zgomot de tip speckle. Am considerat imaginile SAR aeriene și SONAR pe care le-am folosit și în paragraful 2.2.13 și în plus o imagine SENTINEL-1 ca imagini reale de teledetecție. Imaginea aeriană am folosit-o în primul exemplu de aplicare a metodei robuste de detecție a muchiilor pe imagini reale. O imagine SAR achiziționată prin satelit cu număr de vederi îmbunătățit este obiectul celui de-al doilea exemplu de aplicare a metodei de detecție de muchii la imagini reale. Este o imagine Sentinel-1 Stripmap Ground Range Detected High Resolution (GRDH). În cazul imaginilor Sentinel-1 Stripmap, procesorul de semnal SAR utilizează istoricul de date complet și apertura sintetică completă pentru a produce cea mai mare rezoluție posibilă, care corespunde unei imagini SAR complexe cu o singură vedere (Single Look Complex-SLC).

Imaginea de amplitudine corespunzătoare unei imagini SAR SLC este obținută prin detecție pătratică. Imaginea de intensitate corespunzătoare unei imagini SAR SLC se obține ca pătratul imaginii de amplitudine. Numărul multiplu de vederi poate fi generat prin mediere a imaginilor SAR SLC peste celulele de azimut și/sau de rezoluție. Produsele Ground Range Detected (GRD) constau din date SAR focalizate care au fost detectate, transformate pentru a avea un număr mai mare de vederi și proiectate folosind un model de elipsoid al Pământului la sol. Imaginea Sentinel-1 Stripmap GRDH utilizată în cel de-al doilea exemplu de aplicare a metodei propuse de detecție a muchiilor la imagini de teledetecție reale are un număr de vederi $L=8$. Această imagine reprezintă un segment al graniței dintre curentul Agulhas și coasta Africii de Sud. Pentru al treilea exemplu de aplicare a metodei propuse de detectare a muchiilor la imaginile de teledetecție, am folosit aceeași imagine SONAR ca în cel de al doilea exemplu din paragraful 2.2.13.

În cazul imaginilor Lena, Barbara și Boat, perturbate de zgomot AWGN am obținut rezultate de detecție a muchiilor foarte bune, numărul de alarme false produse de zgomotul alb Gaussian de medie nulă scăzând foarte mult în cazul folosirii sistemului de denoising înaintea detectorului lui Canny. Metoda propusă depășește metoda de detecție a muchiilor a lui Canny pentru toate valorile abaterii standard a zgomotului în ceea ce privește valorile erorii medii pătratice (MSE) la muchii. Detectorul de muchii al lui Canny nu este robust împotriva zgomotului, în ciuda utilizării filtrului Gaussian în primul pas al algoritmului, introducând numeroase muchii false atunci când este aplicat direct la imagine zgomotoasă. Metoda propusă pierde unele muchii slabe din cauza efectului de netezire introdus în pasul de denoising. În cazul simulărilor efectuate cu zgomot

speckle sintetizat am constatat că robustețea detectorului lui Canny este crescută, indiferent de metoda de denoising care o precede dar harta de muchii obținută aplicând metoda de denoising descrisă în paragraful 2.2.13 este una dintre cele mai bune. În cazul celor trei imagini reale de teledetecție s-au obținut rezultatele următoare. În cazul imaginii aeriene și în cazul imaginii SONAR, care au un număr mic de vederi ($L=2$ și respectiv $L=1$), zgomotul speckle afectează grav imaginea originală. Primul etaj al sistemului de denoising nu este capabil să îndepărteze complet zgomotul. Sistemul de denoising propus elimină complet zgomotul de tip speckle. Detectorul de muchii al lui Canny introduce numeroase muchii false în cazul imaginilor zgomotoase. Numărul muchiilor false rămâne ridicat chiar și după aplicarea primului etaj al sistemului de denoising care reprezintă primul pas al metodei de detecție de muchii propusă. Metoda de detecție a muchiilor propusă este robustă împotriva zgomotului de tip speckle. Nu observăm muchii false în rezultatele obținute.

Această metodă robustă la zgomotul aditiv alb Gaussian respectiv la zgomotul de tip speckle de detecție a muchiilor din imaginile naturale respectiv din imaginile SAR constă în aplicarea detectorului Canny după metoda de înlăturare a zgomotului care constituie cea de a doua contribuție a tezei și constituie cea de a treia contribuție originală a tezei. Valoarea științifică a metodei robuste de detecție a muchiilor a fost validată prin publicarea acesteia într-un articol dintr-o revistă indexată ISI, Q1: A Isar, C Naforita, G Magu, Hyperanalytic Wavelet-Based Robust Edge Detection, Remote Sensing 13 (15), 2888.

2.5.4. Abordări pentru imagini color

Detecția muchiilor pentru imaginile color prezintă dificultăți suplimentare datorită celor trei componente de culoare utilizate. Cea mai simplă tehnică este de a efectua detecția muchiilor pe componenta de luminanță a imaginii, ignorând informațiile cromatice. Principalul dezavantaj al detecției de muchii numai pe bază de luminanță este că există muchii importante care nu se limitează numai la componenta de luminanță.

O altă abordare a detecției de muchii în imaginile color, destul de evidentă, este aplicarea unei metode dorite de detecție a muchiilor separat pe fiecare componentă de culoare și construcția unei hărți de muchii cumulativă. O posibilitate pentru calculul modulului gradientului general, este prezentată în ecuația următoare pentru spațiul de culoare RGB și combină modulele gradientelor componentelor de culoare:

$$|\nabla f_C(x, y)| = |\nabla f_R(x, y)| + |\nabla f_G(x, y)| + |\nabla f_B(x, y)| \quad (2.126)$$

Cu toate acestea, rezultatele sunt influențate de proprietățile spațiului de culoare particular utilizat. Este adesea important să se folosească un spațiu de culoare adecvat aplicației țintă. De exemplu, detecția muchiilor care este destinată aproximării comportamentului sistemului vizual uman ar trebui să utilizeze un spațiu de culoare având o bază perceptivă, cum ar fi CIELUV sau poate HSL. O altă complicație este faptul că vectorii gradient ai componentelor este posibil să nu fie întotdeauna orientați similar, ceea ce face căutarea maximelor locale ale lui $|\nabla f_C|$ de-a lungul direcției gradientului mai dificilă. Dacă o imagine gradient total trebuia calculată prin însumarea vectorilor gradient ai componentelor de culoare, nu doar a modulelor lor, atunci orientările neconsecvente ale gradientelor componente ar putea interfera distructiv și anula unele muchii.

Abordările vectoriale pentru detecția muchiilor în imaginile color, deși în general mai puțin eficiente din punct de vedere al calculului, tind să aibă o mai bună justificare teoretică. Distanța Euclidiană în spațiul de culoare dintre vectorii de culoare ai unui pixel dat și vectorii de culoare ai vecinilor săi poate fi o bază bună pentru un detector de muchii în imaginile color [207]. Pentru cazul RGB, modulul vectorului gradient este:

$$|\nabla f_C(x, y)| = \sqrt{|\nabla f_R(x, y)|^2 + |\nabla f_G(x, y)|^2 + |\nabla f_B(x, y)|^2} \quad (2.127)$$

2.6. Extragerea caracteristicilor și analiza componentelor principale din imagini

Pe măsură ce cantitatea de informații crește exponențial, extragerea caracteristicilor devine o tehnică indispensabilă pentru separarea informațiilor relativ semnificative din datele achiziționate. Unul dintre avantajele extragerii caracteristicilor este că permite o înțelegere mai bună și mai rapidă a principalelor proprietăți ale unui set de date. De îndată ce este găsită caracteristica informației, aceasta poate fi utilizată și pentru compresia acelor date, sau pentru compararea lor cu alte date pentru identificarea unor informații conexe. O aplicație majoră a extragerii caracteristicilor este analiza imaginii. Odată cu creșterea numărului de imagini și videoclipuri din viața noastră, este utilă utilizarea unor mașini inteligente pentru a identifica obiectul prezentat într-o imagine sau pentru a detecta apariția unui anumit obiect într-un videoclip. O abordare interesantă pentru extragerea caracteristicilor imaginilor se bazează pe folosirea analizei de tip wavelet [208]. Transformata wavelet utilizată în [208] este transformata wavelet discretă calculată cu ajutorul funcției wavelet mamă de tip Haar. S-a ales această funcție wavelet mamă deoarece eficientizează calculul. Spațiul caracteristicilor Haar ale imaginii conține descrieri bogate ale modelului.

O altă tehnică frecvent utilizată pentru extragerea caracteristicilor, în special în detectarea feței, este analiza componentelor principale (Principal Component Analysis-PCA). PCA proiectează imagini din domeniul spațial (care are o dimensiune mare) într-un spațiu cu dimensiune inferioară. Limitarea principală a PCA este că nu poate elimina complet zgomotul din imaginea achiziționată. Prin urmare, o soluție mai bună este combinarea analizei wavelet (care are după cum s-a văzut deja capacitatea de a elimina complet zgomotul) cu PCA, obținându-se o nouă variantă de PCA, numită wavelet PCA, care poate îmbunătăți rezultatul extragerii caracteristicilor [210]. Wavelet PCA se utilizează în autentificarea biometrică pe baza caracteristicilor faciale. Algoritmul proiectat pentru autentificarea biometrică pe baza caracteristicilor faciale folosește DWT pentru compresia imaginii (așa după cum s-a arătat în paragraful 2.3) și PCA pentru extragerea caracteristicilor și pentru metodologia de identificare. Autentificarea se realizează prin compararea caracteristicilor extrase din imaginea curentă cu caracteristicile imaginilor înregistrate deja în baza de date. Limitările metodei de extragere a caracteristicilor care folosește doar PCA sunt o viteză de recunoaștere scăzută și un volum mare de calcul necesar. Pentru a elimina aceste limitări, se aplică DWT cu trei niveluri de descompunere, utilizând o funcție wavelet mamă de tip Daubechies și apoi PCA. Prin aplicarea DWT se obține o imagine descrisă printr-o matrice rară, ceea ce reduce volumul de calcul necesar pentru PCA. Pentru aprecierea asemănării dintre imaginea curentă și imaginile din baza de date se folosește distanța Euclideană. Rezultatele comparării PCA cu wavelet PCA arată că wavelet PCA oferă o rată de recunoaștere mai mare decât PCA, cu un timp de acces redus.

Extragerea caracteristicilor este fundamentală în cadrul recunoașterii tiparelor. În aplicațiile de clasificare, în care datele brute sunt colectate din experimente științifice sau simulări, datele rezultate pot fi afectate de zgomot, de dinamica externă sau de incertitudini care nu au fost luate în considerare în timpul procesului de achiziție. În plus, datele pot fi de dimensiuni mari, ceea ce poate împiedica acuratețea algoritmilor de decizie. La fel ca în majoritatea proiectelor de recunoaștere a modelelor, și în cazul recunoașterii tiparelor, e necesară o precizie de

clasificare aproape perfectă, precum și minimizarea alarmelor false și a detecțiilor ratate. Alte criterii includ timpul acordat pentru clasificarea tiparului necunoscut, precum și suma costurilor permise pentru implementarea metodologiei în hardware. Prin urmare, este esențial ca metodele de extragere a caracteristicilor să îmbunătățească separabilitatea tiparelor în datele brute pentru a îmbunătăți acuratețea clasificării și pentru a reduce complexitatea de calcul pentru clasificare.

Abordările de învățare automată folosesc de obicei mai multe etape de pre-procesare pentru a ajuta la îmbunătățirea capacității clasificatorului de a discrimina tiparele din date. De exemplu, acești pași pot include condiționarea semnalului pentru denoising, normalizarea intrării și îmbunătățirea extragerii caracteristicilor pentru creșterea separabilității claselor. Tehnicile standard pentru extragerea caracteristicilor includ PCA [214], analiza Fisher discriminativă (Fisher Discriminative Analysis-FDA) [215], încorporarea liniară locală [216] și extensiile suplimentare prezentate în literatura de specialitate. Li și colaboratorii [217] au prezentat o metodă de extragere a caracteristicilor bazată pe logică fuzzy, utilizând FDA. Huang și colaboratorii [218] au folosit Slow Feature Analysis [219] pentru a propune Slow Feature Discriminant Analysis (SFDA), pentru recunoașterea cifrelor scrise de mână, care folosește o funcție obiectiv bazată pe variații temporale. Mo și colaboratorii [220] au folosit Kernel PCA pentru extragerea caracteristicilor într-un mediu de poziționare interior. Jiang și colaboratorii [221] au implementat factorizarea matricei pozitive (Positive Matrix Factorization-PMF) pentru a extrage caracteristicile din droguri și explozivi ascunși. Zabalza și colaboratorii [222] au propus abordarea Folded-PCA care poate îmbunătăți eficiența extragerii caracteristicilor și precizia clasificării. Li și colaboratorii [223] au prezentat o extracție semi-supervizată a caracteristicilor bazată pe FDA fuzzy pentru clasificarea imaginilor hiperspectrale. Gu și colaboratorii [224] au extins SFDA utilizând caracteristici necorelate și proiecții globale de conservare.

Analiza wavelet, cu beneficiile cunoscute referitoare la localizarea simultană în domeniile timp și frecvență, a fost aplicată recent pentru extragerea caracteristicilor în problemele de recunoaștere a modelelor. Godfrey și colaboratorii [225] au aplicat transformata wavelet continuă într-o arhitectură de arbore de clasificare pentru identificarea delirului. Yu și colaboratorii [226] au implementat extracția de caracteristici wavelet pe bază de grup propusă pentru diagnosticarea defecțiunilor automobilelor. Eristi și colaboratorii [227] au folosit analiza wavelet și selectarea secvențială pentru extragerea caracteristicilor utilizată pentru a clasifica perturbările sistemului de alimentare. Avci și colaboratorii [228] au proiectat un extractor de caracteristici care utilizează energia coeficienților wavelet și entropia lor pentru a antrena o rețea neuronală optimizată de un algoritm genetic. Saravanan și colaboratorii [229] au folosit funcțiile wavelet discrete pentru extragerea și selectarea caracteristicilor pentru diagnosticarea defecțiunilor incipiente ale cutiei de viteze. Histogramele energiei locale din domeniul wavelet sunt propuse de Dong și colaboratorii [230] pentru clasificarea imaginilor texturilor de tip Brodatz. Shankar și colaboratorii [231] au aplicat funcțiile wavelet discrete ca și caracteristici pentru un clasificator fuzzy de imagini de teledetecție. Liu și colaboratorii [232] au propus modelul de codare rară ca metodă de extragere a caracteristicilor din coeficienții wavelet pentru diagnosticarea defecțiunilor rulmenților. Guo și colaboratorii [233] au implementat un sistem de extracție a caracteristicilor bazat pe 4 programe genetice, utilizând coeficienții wavelet pentru clasificarea epilepsiilor. Seshadrinath și colaboratorii [234] au prezentat o metodologie de clasificare pentru semnăturile de curent ale motoarelor prin aplicarea analizei wavelet pentru a antrena un algoritm de clasificare bazat pe rețea neuronală. Bafroui și colaboratorii [235] au folosit

energia și entropia coeficienților wavelet pentru a proiecta o metodă de extragere a caracteristicilor pentru clasificarea defecțiunilor cutiei de viteze.

Alte lucrări din literatura de specialitate explorează extensiile sau alternativele analizei wavelet. Xian și colaboratorii [236] au folosit pachete de funcții wavelet și au propus un clasificator (Support Vector Machine-SVM) hibrid pentru diagnosticarea defecțiunilor de mașini rotative.

Lin și colaboratorii [237] au îmbunătățit metoda de descompunere în mod empiric (Empirical Mode Decomposition-EMD) pentru extragerea caracteristicilor vibrațiilor și a semnalelor electrice din creier. Huang și colaboratorii [238] au asociat funcții wavelet separabile cu câmpuri aleatoare Gauss-Markov pentru extragerea caracteristicilor irisului. Khushaba și colaboratorii [239] au propus o metodă de extragere a caracteristicilor bazată pe mulțimi fuzzy pentru clasificarea somnolenței șoferului. Această metodă găsește arborele optim de descompunere în pachete de funcții wavelet din fiecare canal de date și combină aceste caracteristici pentru a forma un vector de descriptori. Wang și colaboratorii [240] au aplicat pachetele de funcții wavelet împreună cu selecția celei mai bune baze pentru extragerea caracteristicilor în scopul detecției condițiilor de declanșare a crizelor epileptice. Bin și colaboratorii [241] au aplicat metoda EMD și pachetele de funcții wavelet ca bază pentru un extractor de caracteristici ale mașinilor rotative. Li și colaboratorii [242] au folosit EMD pentru a calcula coeficienții de variație și indicii de fluctuație care au fost utilizați pentru a detecta convulsiile cu SVM.

Deepa și colaboratorii [243] au implementat combinația dintre transformata Fourier discretă și transformata cosinus discretă pentru extragerea caracteristicilor și optimizarea roiurilor de particule (Particle Swarm Optimization-PSO) pentru selectarea caracteristicilor pentru recunoașterea feței. Chen și colaboratorii [244] au propus transformarea wavelet discretă cu factor de dilatare rațional pentru extragerea caracteristicilor defectelor cutiei de viteze. Han și colaboratorii [245] au folosit pachete de funcții wavelet combinate cu o versiune îmbunătățită a algoritmului Fast-ICA. Wang și colaboratorii [246] au aplicat EMD combinată cu o transformată wavelet reglabilă cu factor de calitate variabil pentru extragerea caracteristicilor defectelor lagărelor. Poornima și colaboratorii [247] au propus o tehnică de extragere a caracteristicilor bazată pe PCA combinată cu transformări multi-scară pentru recunoașterea feței. Lu și colaboratorii [248] au proiectat un extractor de caracteristici care utilizează transformări multi-wavelet adaptive pentru diagnosticarea defecțiunilor rotoarelor. Bennet și colaboratorii [249] au folosit funcții wavelet discrete asociate cu o tehnică de fereastră în mișcare pentru extragerea și selectarea caracteristicilor aplicate clasificării cancerului. Wang și colaboratorii [250] au aplicat pachetele de funcții wavelet (lifting wavelet packets) asociate cu metoda fuzzy c-means pentru clasificarea caracteristicilor dinamicii sarcinii. Zhang și colaboratorii [251] au proiectat un filtru wavelet pentru extragerea informațiilor despre rulmenți. Yuwono și colaboratorii [252] au propus un extractor de frecvență care utilizează bancurile de filtre wavelet pentru a genera un vector caracteristic al frecvenței defectelor. Acești vectori caracteristici sunt utilizați pentru a instrui stările ascunse ale unui Model Markov Ascuns (HMM) utilizat pentru clasificare.

Metodele de mai sus sunt utile pentru a extrage caracteristici pentru clasificarea modelului cu ajutorul funcțiilor wavelet. În ciuda beneficiilor dimensiunii suplimentare prezente în domeniul wavelet, aceste metode au și dezavantaje. Complexitatea de calcul este mai mare în cazul utilizării metodelor wavelet PCA pentru învățarea automată. Mai mult, informațiile din domeniul wavelet care nu sunt utile pentru separarea claselor pot, de fapt, să degradeze performanța unui clasificator. Astfel, este necesară o nouă abordare de filtrare care să poată utiliza

beneficiile funcțiilor wavelet și să selecteze cele mai utile regiuni din domeniul wavelet pentru a extrage caracteristici pentru îmbunătățirea performanței clasificatorului și reducerea complexității.

2.6.1. Metodologia de extragere a caracteristicilor

Analiza wavelet este utilizată în mod obișnuit pentru a surprinde caracteristicile comune de timp și frecvență ale datelor dintr-o serie temporală netaționară. Deși în literatura de specialitate se găsesc aplicații ale funcțiilor wavelet în extragerea caracteristicilor imaginilor, încă nu se cunosc pe deplin descriptorii wavelet care rezează cele mai reprezentative caracteristici de separare a claselor. Mai mult, selectarea funcției wavelet-mamă afectează caracteristicile extrase.

2.6.1.1. Analiza în componente principale

Se dă o listă de date de dimensiune n , $X=(X_1, X_2, \dots, X_n)$, de valoare medie

$E[X] = (\sum X_i) / n$ și deviație standard $s = \sqrt{\frac{\sum (X_i - E[X])^2}{n-1}}$ care ilustrează cât de răspândite sunt datele în jurul valorii medii. O altă modalitate de a descrie răspândirea datelor în jurul mediei este varianța:

$$\text{Var}(x) = E[(X - E[X])^2] \quad (2.128)$$

Cu toate acestea, varianța descrie doar modul în care X este răspândit pe axă. Se presupune că este dată o altă listă de date Y , de dimensiune m . Aceasta va fi folosită pentru a vedea cum sunt distribuite punctele (X_i, Y_i) în plan. Se definește covarianța celor două liste de date ca:

$$\text{Cov}(X, Y) = E[(X - E[X])(Y - E[Y])] \quad (2.129)$$

Se definește matricea de covarianță ca:

$$C^{m \times n} = (c_{i,j}, c_{i,j} = \text{Cov}(\text{Dim}_i, \text{Dim}_j)).$$

În caz tridimensional C poate fi scris ca:

$$C = \begin{pmatrix} \text{cov}(X, X) & \text{cov}(X, Y) & \text{cov}(X, Z) \\ \text{cov}(Y, X) & \text{cov}(Y, Y) & \text{cov}(Y, Z) \\ \text{cov}(Z, Y) & \text{cov}(X, Y) & \text{cov}(Z, Z) \end{pmatrix} \quad (2.130)$$

a) Mecanismul PCA

Se consideră punctele din spațiul n dimensional. Se presupune că avem $X_i=(x_1, x_2, \dots, x_n)^T$, $1 \leq i \leq n$ satisfăcând condiția $E[X_i]=0$. PCA rotește punctele împreună în spațiu astfel încât să se distribuie numai de-a lungul axelor X și Y . Pentru a vedea o descriere matematică, se definește $X=[X_1, X_2, \dots, X_m]$, astfel încât X este o matrice de tip $n \times m$ care conține toate informațiile cunoscute despre date. Prin definiția de mai sus, matricea de covarianță a acestor puncte în spațiu este pur și simplu:

$$C_X = \frac{1}{m} X X^T \quad (2.131)$$

În continuare dorim să găsim o matrice ortonormală P care transformă X în Y cu $Y=PX$, astfel încât matricea de covarianță a lui Y , C_Y , să fie o matrice diagonală. Liniile lui P reprezintă componentele principale ale lui X .

b) Implementarea PCA folosind descompunerea în vectori proprii

Fie $Y=PX$, unde P este o matrice ortonormală. Se calculează:

$$C_Y = \frac{1}{m} YY^T = \frac{1}{m} (PX)(PX)^T = \frac{1}{m} PXX^T P^T = P\left(\frac{1}{m} XX^T\right)P^T = PC_X P^T \quad (2.132)$$

O matrice A este simetrică dacă este egală cu transpusa sa. Fie $A=XX^T$. Calculăm transpusa matricii A :

$$A^T = (XX^T)^T = XX^T = A \quad (2.133)$$

Prin urmare matricea C_X este simetrică.

c) Cele mai mari componente principale

Am demonstrat că pentru transformarea $Y=PX$ în cazul în care P este o matrice ortonormală, C_Y reprezintă matricea valorilor proprii ale matricii C_X . Întrucât orice matrice de valori proprii este diagonală rezultă că C_Y este o matrice diagonală.

Să presupunem că suntem interesați doar de spațiul n -dimensional în care sunt repartizate majoritatea punctelor. Atunci trebuie să alegem C_Y pentru a fi o matrice de dimensiuni $k \times k$ de valori proprii în care $\lambda_1, \lambda_2, \dots, \lambda_k$ reprezintă cele mai mari k valori proprii ale matricii C_X . Fie e_1, e_2, \dots, e_k vectorii proprii corespunzători. Prin urmare, P este compusă din $(e_1, e_2, \dots, e_k)^T$. Astfel Y va conține coordonatele proiecției punctelor pe acele axe principale.

2.6.2. Implementarea PCA prin identificarea direcțiilor principale ale unei imagini folosind pachete de funcții wavelet hiperanalitice

În cazul imaginilor, noțiunea de direcție, folosită în definiția PCA are o interpretare fizică. Deci, PCA de imagini ar putea avea interpretare fizică, ceea ce îmbunătățește înțelegerea acestui concept abstract. Așa după cum s-a arătat deja în paragraful 2.2.3 G), PCA a unei imagini poate fi implementată cu ajutorul HWPT a acelei imagini, [3], [47], [48], [49], [253], [254].

2.6.2.1. HWPT

Subimaginile z_+ și z_- , care reprezintă rezultatele HWPT sunt indexate ca în figura 37. Asocierea dintre cele douăzeci și patru de sub-benzi ale rezultatului și orientările preferențiale ale HWPT este prezentată în tabelul 8. Analizând tabelul 8, observăm că există direcții asociate cu mai multe subbenzi, ca de exemplu direcțiile $\pm \arctg(1)$. Aceste două direcții sunt asociate cu subbenzile indexate cu 4, 8, 17 și 20. Chiar dacă au aceleași orientări preferențiale, aceste sub-benzi diferă prin conținutul de frecvență (frecvență centrală și lățime de bandă).

5	6	9	10
7	8 ₁	11	12 ₂
13	14	17	18
15	16 ₃	19	20 ₄

Figura 37. Regula utilizată pentru indexarea sub-imaginilor (sub-benzi) care reprezintă rezultatele HWPT cu două niveluri de descompunere.

Tabelul 8. Corespondența între sub-benzile de detalii ale HWPT (cu două niveluri de descompunere) și orientările principale.

Indice sub-bandă	Direcție preferențială	Indice sub-bandă	Direcție preferențială
2	$\pm \arctg(2)$	8, 17, 20	$\pm \arctg(1)$
3	$\pm \arctg(1/2)$	9, 13	$\pm \arctg(1/5)$
4	$\pm \arctg(1)$	10, 14	$\pm \arctg(3/5)$
6	$\pm \arctg(3)$	11, 15	$\pm \arctg(1/7)$
7	$\pm \arctg(1/3)$	12, 16	$\pm \arctg(3/7)$
18	$\pm \arctg(7/5)$	19	$\pm \arctg(5/7)$

2.6.2.2. Identificarea direcțiilor principale ale imaginilor

Pentru a identifica direcțiile principale ale unei imagini, trebuie să selectăm numărul iterațiilor HWPT (în cele ce urmează vom lucra cu 2 iterații), pentru a calcula coeficienții HWPT, pentru a determina varianța acestora în fiecare sub-bandă și pentru a compara aceste rezultate. Direcțiile principale corespund varianțelor mai mari.

Această procedură a fost aplicată în [47], [48] pentru imaginea sintetică din figura 38. Există următoarele unsprezece direcții principale în imaginea sintetică din figura 38: 0° , $\arctg(1)$, $\arctg(2)$, 90° , $-\arctg(1)$, $-\arctg(1/2)$, 180° , $\arctg(1/2)$, 270° , $-\arctg(2)$ și $-\arctg(1/2)$. Am indicat direcțiile liniilor din figura 38 cu căsuțe dreptunghiulare, pentru a facilita analiza selectivității direcționale a HWPT. Unele dintre aceste direcții corespund liniilor continue din figura 38, celelalte direcții corespund liniilor întrerupte. După aplicarea procedurii deja descrise, am reanalizat rezultatele raportate în [48] și am completat tabelul 9.

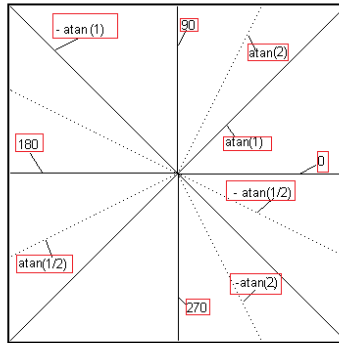


Figura 38. O imagine sintetică, compusă din linii, concepută pentru a testa selectivitatea direcțională a HWPT.

Tabelul 9. Direcții principale ale imaginii din figura 38.

Sub-bandă	Varianță	Numărul de ordine al componentei principale	Orientarea preferențială	Direcția identificată
min_2	2.5094e+007	21	-arctg(2)	-arctg(2)
min_3	2.8934e+007	19	-arctg(1/2)	0°
min_4	3.9506e+007	11	-arctg(1)	-arctg(1)
min_6	3.3212e+007	16	-arctg(3)	270°
min_7	4.0067e+007	10	-arctg(1/3)	-arctg(1/2)
min_8	5.4326e+007	5	-arctg(1)	-arctg(1)
min_9	3.7571e+007	13	-arctg(1/5)	180°
min_10	2.8271e+007	20	-arctg(3/5)	-arctg(1/2)
min_13	3.8188e+007	12	-arctg(1/5)	180°
min_15	2.9738e+007	18	-arctg(1/7)	0°
min_17	6.1605e+007	3	-arctg(1)	-arctg(1)
min_20	6.4469e+007	2	-arctg(1)	-arctg(1)
pl_2	3.1002e+007	17	arctg(2)	arctg(2)
pl_4	4.2663e+007	8	arctg(3/7)	arctg(1/2)
pl_6	3.5417e+007	14	arctg(3)	90°
pl_7	3.5346e+007	15	arctg(1/3)	0°
pl_8	5.3255e+007	6	arctg(1)	arctg(1)
pl_9	5.1034e+007	7	arctg(1/5)	0°
pl_10	3.0197e+007	18	arctg(3/5)	arctg(1)
pl_13	4.1975e+007	9	arctg(1/5)	0°
pl_15	3.0019e+007	19	arctg(1/7)	0°
pl_17	6.1235e+007	4	arctg(1)	arctg(1)
pl_20	7.1437e+007	1	arctg(1)	arctg(1)

În prima coloană a tabelului, sunt indicate subimaginele luate în considerare, urmând ordinea din figura 38, atât pentru coeficienții $z+(pl)$, cât și $z-(min)$. Pe a doua coloană sunt scrise varianțele corespunzătoare fiecărei sub-benzi. În a treia coloană

este indicată ordinea de importanță a componentei principale considerate a imaginii din figura 38 determinată. Am considerat doar douăzeci și una de componente principale. Pe prima coloană a tabelului este indicată orientarea preferențială a HWPT care corespunde sub-imaginii luate în considerare. Analizând tabelul 9 se pot face următoarele observații.

1. Toate cele unsprezece direcții din imaginea din figura 38 au fost identificate ca direcții principale, dar importanța lor este diferită.
2. Cele mai importante direcții sunt: $\arctg(1)$ (nr.ordine: 1, 4, 6, 18), $-\arctg(1)$ (nr.ordine: 2, 3, 5, 11), 0° (nr.ordine: 7, 9, 15, 19), $\arctg(1/2)$ (nr.ordine:8), $-\arctg(1/2)$ (nr.ordine: 10, 20), 180° (nr.ordine: 12, 13), 90° (nr.ordine: 14), 270° (nr.ordine: 16), $\arctg(2)$ (nr.ordine: 17) și $-\arctg(2)$ (nr.ordine: 21).
3. Variațiile corespunzătoare nu sunt foarte diferite, variația cea mai mare corespunde sub-imaginii pl_20 și este egală cu $7.1437e+007$ și cea mai mică variație corespunde subimaginii min_2 și este egală cu $2.5094e+007$. Deci, toate variațiile au același ordin de mărime.
4. Direcțiile principale corespund liniilor continue, cum ar fi direcțiile $\arctg(1)$, $-\arctg(1)$ și 0° . Direcțiile mai puțin importante corespund liniilor întrerupte ca de exemplu $\arctg(2)$.

Există direcții în figura 38 care coincid cu orientările preferențiale ale HWPT, ca de exemplu: $\arctg(1)$ sau $-\arctg(1)$ și altele care nu coincid cu orientările preferențiale ale HWPT, ca de exemplu 0° . Direcțiile din imaginea de intrare care nu coincid cu una dintre orientările preferențiale ale HWPT sunt penalizate deoarece filtrele direcționale implementate de 2D HWPT sunt selective.

2.6.2.3. Reprezentarea componentelor principale

După cum s-a spus deja, componentele principale ale unei imagini sunt proiecțiile pixelilor săi pe direcțiile principale ale imaginii respective. Putem reprezenta componentele principale ale unei imagini ca sub-imaginii ale coeficienților HWPT de detalii ai acelei imagini, care corespund direcțiilor principale. Primele patru componente principale ale imaginii Lena sunt prezentate în figura 39. Selectând un număr de componente principale mai mic decât numărul total posibil și reconstituind imaginea inițială folosind numai componentele selectate, vom realiza o reducere a dimensiunii datelor. Această reducere a dimensiunii datelor are două caracteristici importante: factorul de compresie și fidelitatea reconstrucției. Selecția acestor caracteristici depinde de aplicații. Dacă numărul de componente principale este mai mare, atunci fidelitatea reconstrucției va fi mare, dar factorul de compresie va fi mai redus. Dimpotrivă, dacă numărul componentelor principale selectate este mai mic, atunci fidelitatea reconstrucției va fi mai mică, dar factorul de compresie va fi mai important. În cazul PCA propusă, numărul total posibil de componente principale poate fi stabilit prin alegerea numărului de iterații (niveluri de descompunere) ale HWPT. Apoi, primele componente principale (constituite din sub-benzi cu valori ale varianței mai mari decât un prag impus) sunt extrase și următoarele componente principale (constituite din sub-benzi cu varianțe de valori mai mici decât valoarea de prag) sunt respinse prin punerea la zero a tuturor coeficienților de detalii HWPT din sub-benzile corespunzătoare. În figura 39a) este prezentată prima componentă principală-pl_6, cu varianța $3.8471e+007$ și direcția principală $\arctan(3)$.




Figura 39. Cele patru componente principale ale imaginii Lena și direcțiile corespunzătoare marcate cu linii colorate.

În figura 39b) este prezentată a doua componentă principală-min₆, cu varianța $3.4375e+007$ și direcția principală $-\arctg(3)$. În imaginea c) din figura 39 este arătată a treia componentă principală-pl₇ cu varianța $1.5123e+007$ și direcția principală $\arctg(1/5)$ și în figura 39d) se vede a patra componentă principală-pl₈ cu varianța $1.0834e+007$ și direcția principală $\arctg(3/5)$.

După cum se poate observa analizând componentele principale din figura 39, sub-imaginile corespunzătoare sunt „rare”, necesitând un număr redus de biți pentru reprezentare. Imaginile secundare corespunzătoare componentelor principale respinse sunt chiar mai rare, necesitând un singur bit pentru reprezentare. Deci, numărul de biți necesari pentru reprezentarea tuturor coeficienților HWPT de detalii obținut după PCA este mai mic decât numărul de biți ai imaginii originale, producându-se reducerea dimensiunii datelor menționată deja. De exemplu, pentru experimentul descris în tabelul 9, am selectat 21 de componente principale dintr-un număr total posibil de 36 de componente (în figura 37 există 20 de sub-imagini pentru fiecare semn de direcție (pl sau min), dar 2 subimagini corespund la coeficienții de aproximare). Fără a lua în considerare efectul rarității HWPT, putem concluziona că factorul de compresie obținut fără utilizarea algoritmilor de codare

eficientă a poziției decrși în paragraful 2.3.3. A1) – A4) este mai mare de 1.71. **Acest algoritm de implementare a PCA prin identificarea direcțiilor principale din imagine cu ajutorul HWPT reprezintă o contribuție originală a tezei de doctorat și a fost validat prin publicarea articolului [49].**

Netezimea unui semnal este una dintre cele mai importante caracteristici ale sale, care poate fi exploatată pentru optimizarea prelucrării semnalului. De exemplu, o metodă de prelucrare bazată pe funcții wavelet poate fi optimizată prin alegerea funcției wavelet mamă având același grad de netezime ca și semnalul care trebuie prelucrat [255].

Una dintre caracteristicile semnificative ale unei imagini este gradul de rugozitate al suprafețelor obiectelor din imaginea respectivă. Rugozitatea este o caracteristică a unei suprafețe care arată cât de puțin netedă este suprafața respectivă. Cu cât este o suprafață mai netedă cu atât este ea mai puțin rugoasă (adică mai fină).

În figura 40 sunt prezentate două semnale cu grade de netezime diferite.




Figura 40. Două realizări ale unui semnal aleator cu grade de netezime diferite. a) $H=0.9$; b) $H=0.1$.

Cele două grafice din figura 40 reprezintă realizări ale unui semnal aleator de tipul mișcare Browniană fracționară (fractional Brownian motion-fBm). Un semnal aleator de tip fBm este un semnal aleator continuu care depinde de valoarea exponentului Hurst, H . Comparând graficele celor două semnale din figura 40 se constată că semnalul din panelul a) este mai neted decât semnalul din panelul b). Deci gradul de netezime al unui semnal este invers proporțional cu valoarea exponentului Hurst al aceluși semnal.

Folosirea exponentului Hurst pentru estimarea gradului de netezime poate fi generalizată și pentru cazul imaginilor [256], așa după cum se poate observa în figura 41. Gradul de netezime al imaginii D33 poate fi apreciat global pentru că această imagine este izotropă. În ciuda faptului că imaginile din figurile 41 și 42 au un conținut informațional foarte diferit, valorile exponenților Hurst globali corespunzători sunt foarte apropiate. În cazul imaginilor anizotrope, cum este de exemplu imaginea din figura 42, estimarea exponentului Hurst global nu mai este suficientă, deoarece imaginile anizotrope conțin mai multe direcții principale (câteva dintre aceste direcții sunt marcate în figura 42).




Figura 41. Un exemplu de imagine izotropă. Imaginea D33 din baza de date Brodatz are o valoare medie a exponentului Hurst global de 0.39.




Figura 42. Un exemplu de imagine anizotropă. Imaginea D31 din baza de date Brodatz are o valoare medie a exponentului Hurst global de 0.46.

Considerând fiecare dintre aceste direcții, pot fi estimate diferite valori ale exponenților Hurst direcționali, adică valori ale gradelor de netezime corespunzătoare acestor direcții.

Există mai multe metode de estimare a exponentului Hurst al semnalelor respectiv imaginilor. O parte dintre aceste metode au fost descrise pentru cazul semnalelor unidimensionale în [257]. O categorie de metode de estimare a exponentului Hurst se bazează pe utilizarea funcțiilor wavelet. Pentru cazul exponenților Hurst direcționali, Vidakovic și ceilalți [258] au estimat distanța anizotropică fractală (Fractal Distance-FD) pe direcțiile orizontală, verticală și diagonală, folosind transformata wavelet discretă bidimensională. Nelson și ceilalți [256] au folosit transformata bidimensională DTCWT pentru a crește numărul de direcții principale după care pot fi calculați exponenții Hurst direcționali la șase. Acest număr a fost crescut în continuare în [253] prin utilizarea transformării wavelet cu pachete hiperanalitice.

Pentru calibrarea acestor metode de estimare a exponentului Hurst pot fi folosiți algoritmi de generare a unor semnale aleatoare cu valori specificate ale exponentului Hurst. De exemplu, un astfel de algoritm este folosit în cazul funcției

Matlab wfbm care generează semnale aleatoare de tipul mișcare Browniană fracționară cu exponent Hurst de valoare impusă. Un algoritm de acest tip, bazat pe funcții wavelet, este folosit în [259] pentru generarea semnalelor aleatoare de tipul mișcare Browniană fracționară. Acest algoritm are doi pași. Primul pas constă în generarea unei secvențe de tipul semnal aleator în timp discret alb Gaussian de medie nulă și dispersie unitară și în transformarea acestei secvențe în noi secvențe de tipul semnal aleator în timp discret alb Gaussian de medie nulă și dispersii proporționale cu $2^j(2H+1)$ unde H reprezintă valoarea dorită a exponentului Hurst iar j este un număr natural, care specifică scara. Cel de al doilea pas al metodei de generare a semnalului aleator de tip mișcare Browniană fracționară presupune interpretarea secvențelor de zgomot alb Gaussian deja amintite ca niveluri succesive de descompunere ale transformării wavelet discretă a semnalului aleator de tipul mișcare Browniană fracționară care se dorește a fi generat. Cel de al doilea pas al algoritmului presupune inversarea acestei transformate wavelet discretă. În urma simulărilor raportate în [259], rezultă că rezultatele aplicării acestui algoritm se compară favorabil cu rezultatele obținute aplicând funcția Matlab wfbm. Din acest motiv, **acest algoritm de generare a semnalelor aleatoare de tip mișcare Browniană fracționară este considerat drept o contribuție a tezei de față, a cărei valoare științifică a fost validată prin publicarea articolului [259] într-o revistă indexată BDI.**

Capitolul 3

UTILIZARE FUNCȚIILOR WAVELET LA PRELUCRAREA SEMNALELOR RADAR

RADAR-ele auto, împreună cu alți senzori, cum ar fi: lidar, cu ultrasunete sau camerele de luat vederi, formează coloana vertebrală a sistemelor avansate de asistență a conducătorului auto (Advanced Driving Assistance Systems-ADAS) și a automobilelor cu conducere automată. Aceste progrese tehnologice sunt realizate cu ajutorul unor sisteme extrem de complexe, cu o cale lungă de procesare a semnalului de la senzori la sistemele de control și execuție. Sistemele RADAR auto sunt responsabile pentru detectarea obiectelor și obstacolelor, precum și de estimarea poziției și vitezei radiale a acestora. Dezvoltarea tehnicilor de procesare a semnalului împreună cu progresul în tehnologia semiconductoarelor cu unde milimetrice (unde mm) joacă un rol cheie în sistemele RADAR auto. S-au dezvoltat diverse tehnici de procesare a semnalului pentru a oferi o rezoluție mai bună și performanțe de estimare superioare pentru toate mărimile care trebuie măsurate: distanță, unghiuri de elevație și azimut și viteza țintelor din jurul vehiculelor.

3.1. Introducere

Principalele obiective ale unui sistem RADAR sunt de a detecta prezența unei sau mai multor ținte de interes și de a estima distanța, unghiul și mișcările lor în raport cu RADAR-ul [260]. Progresele în tehnologia circuitelor consolidate de noii algoritmi de procesare a semnalului, învățare automată, inteligența artificială și tehnicile de control cu calculatorul au făcut ca mașinile cu conducere automată să devină realitate. Astfel de mașini se bazează, de asemenea, pe utilizarea mai multor senzori, cum ar fi: LASER, camere de luat vederi, senzori cu ultrasunete, sisteme de poziționare globală prin satelit și RADAR. Dintre acești senzori, RADAR-ul oferă posibilitatea de a „vedea” la distanțe mari în jurul mașinii în condiții de vizibilitate redusă, ceea ce poate ajuta la evitarea coliziunilor [261]. De exemplu, mașina cu conducere automată a Google [262] are RADAR-e montate atât pe barele de protecție din față cât și pe cele din spate ale vehiculului pentru a detecta obiecte din împrejurimile sale.

RADAR-ele auto au fost lansate în urmă cu câteva decenii. Evoluția RADAR-ului auto de la începuturile sale până în prezent a fost discutată în detaliu în [263]. Cu circuite de undă milimetrică integrate și ieftine, implementate în siliciu, sistemele compacte de siguranță RADAR auto au devenit populare [264], [265] [266], [267], [268], [269].

Scopul acestui capitol este de a revizui principalele evoluții în tehnicile de procesare a semnalului aplicate pentru estimarea parametrilor semnificativi ai țintelor, cum ar fi distanța până la ținte, viteza radială a țintei și unghiul dintre direcția automobilului și a țintei. Figura 43 descrie diverse astfel de sub-sisteme RADAR care fac parte din sistemele ADAS. Fiecare sub-sistem are funcționalitate unică și cerințe specifice în ceea ce privește gama RADAR-ului și capacitatea de

măsurare unghiulară. Un RADAR poate transmite și primi simultan unde electromagnetice (EM) în benzi de frecvență cuprinse între 3 MHz și 300 GHz. Acesta este conceput pentru a extrage informații (de exemplu: distanță, viteză radială și secțiune transversală RADAR (RADAR Cross Section-RCS)) despre ținte folosind undele EM reflectate de acele ținte. Sistemele RADAR auto funcționează de obicei în benzi centrate pe frecvențele de 24 GHz și 77 GHz din spectrul EM (unde milimetrice). Funcționarea RADAR-ului implică estimarea a trei variabile definitorii pentru ținte: distanța, viteza radială relativă și direcția. În automotive, sistemele RADAR sunt montate pe autovehicule și se utilizează pentru supravegherea celorlalte autovehicule participante la trafic, prin măsurarea distanței față de acestea și a vitezei relative a acestora. În figura 43 este prezentată schema bloc a unui stand demonstrativ pentru senzori RADAR, cu ajutorul căreia pot fi înțelese mai ușor funcțiile senzorilor RADAR folosiți în automotive.

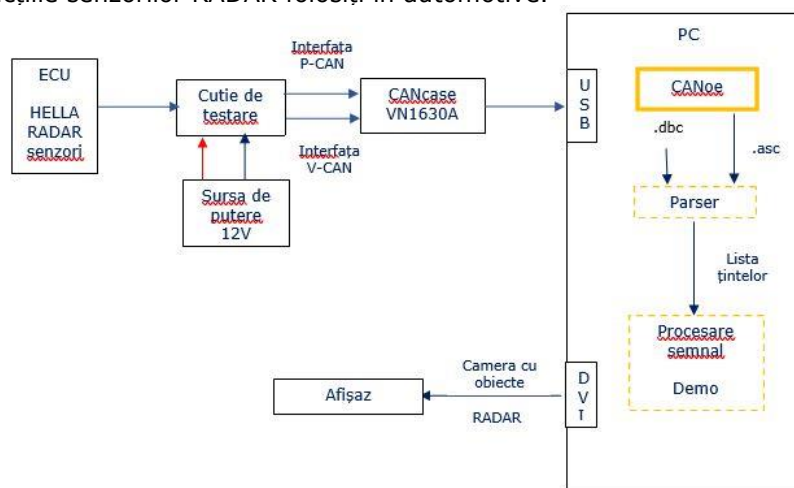


Figura 43. Schema bloc a unui stand demonstrativ pentru senzori RADAR.

Senzorul RADAR este conectat prin intermediul cutiei de testare la sursa de alimentare și la controler-ul automobilului prin intermediul interfeței CAN, controlată de software-ul CANoe. Cu ajutorul acestui software pot fi citite cele câteva sute de semnale pe care le generează senzorul RADAR. Semnalele de interes pot fi selectate cu ajutorul unui parser și cu ajutorul lor pot fi realizate prin simulare diferite programe de demonstrație. De exemplu, pot fi vizualizate hărțile range-Doppler ale unor scene sau pot fi trasate traiectoriile unor ținte.

3.1.1. Principiul de funcționare al RADAR-ului

Principiul de funcționare al RADAR-ului constă în emisia și reflexia unei unde electromagnetice. Reflexia undelor electromagnetice este foarte asemănătoare cu reflexia undelor sonore. Dacă o persoană strigă în direcția unui obiect care reflectă sunetele (cum ar fi într-un canion, într-un tunel sau într-o peșteră), va auzi un ecou. Cunoscând viteza sunetului în aer, se poate estima distanța până la acel obiect. RADAR-ul folosește unde electromagnetice la fel.

Un semnal de radiofrecvență este emis în spațiu și reflectat de către un obiect (numit țintă). O mică parte din energia semnalului emis este reflectată înapoi pe direcția emițătorului. Acest semnal poartă denumirea de semnal ecou, ca și în cazul undelor sonore. Sistemul RADAR utilizează semnalul ecou pentru a determina direcția respectivului obiect, precum și distanța până la acel obiect.

În cazul în care ținta și RADAR-ul se află în mișcare (sau când doar unul dintre acestea se află în mișcare) poate fi măsurată și componenta radială a vitezei relative dintre țintă și RADAR pe baza efectului Doppler.

3.1.1.1. Efectul Doppler

Apare atunci când o sursă se deplasează. Mișcarea sursei modifică lungimea de undă și deci și frecvența undei emise. Efectul este sesizabil atunci când se ascultă semnalul sonor emis de o locomotivă în mișcare sau semnalul emis de o mașină de salvare. În figura 44 se prezintă suprafețele de undă generate de o sursă electromagnetică omnidirecțională (antena omnidirecțională excitată cu un semnal sinusoidal) aflată în mișcare orizontală, evidențiindu-se efectul Doppler.

Vectorul viteză, care descrie mișcarea sursei este reprezentat cu roșu. Lungimile de undă sunt marcate cu galben. Se observă că lungimea de undă pe direcția mișcării, λ_1 , este mai mică decât lungimea de undă pe direcția opusă, λ_2 .




Figura 44. Suprafețele de undă generate de o sursă omnidirecțională care se deplasează pe orizontală.

Din figură se poate vedea că undele ce se emit în sensul direcției de mișcare a sursei dau naștere unor semnale cu frecvențe mai mari decât cele emise în sens invers direcției de mișcare. Notând cu λ_0 lungimea de undă a radiației electromagnetice generată de sursă atunci când aceasta este fixă și cu T perioada undei corespunzătoare, avem:

$$\lambda_1 = T(c - v) = \frac{\lambda_0}{c} (c - v) = \lambda_0 \left(1 - \frac{v}{c}\right) \quad (3.1)$$

$$f_1 = \frac{c}{\lambda_1} = \frac{c}{\lambda_0 \left(1 - \frac{v}{c}\right)} = f_0 \left(1 - \frac{v}{c}\right)^{-1} \quad (3.2)$$

$$\lambda_2 = T(c+v) = \frac{\lambda_0}{c} (c+v) = \lambda_0 \left(1 + \frac{v}{c}\right) \quad (3.3)$$

$$f_2 = f_0 \left(1 + \frac{v}{c}\right)^{-1} \quad (3.4)$$

Deoarece viteza v a sursei emitente este mult mai mică decât viteza luminii c , putem scrie, pe baza aproximării cu serie Taylor, că:

$$v \ll c \rightarrow f_1 \cong f_0 + f_0 \frac{v}{c} \quad (3.5)$$

$$f_2 \cong f_0 - f_0 \frac{v}{c} \quad (3.6)$$

Cel de-al doilea termen din membrul drept al ultimelor două relații se numește frecvență Doppler și se notează cu f_D .

Pentru un semnal emis de un RADAR, semnal ce întâlnește o țintă care se mișcă cu viteza v și se reflectă de pe țintă, apare de două ori modificarea frecvenței semnalului astfel că efectul Doppler are valoarea:

$$f_D = \frac{2v}{c} f_0 = \frac{2v}{c} f_t \quad (3.7)$$

Semnalul recepționat de RADAR va avea frecvența:

$$f_r = f_t \pm \frac{2v}{c} f_t \quad (3.8)$$

cu semnul plus, dacă ținta se apropie cu viteza relativă v de RADAR sau cu semnul minus dacă ținta se îndepărtează cu viteza relativă v de RADAR.

Pentru a da un ordin de mărime pentru frecvența Doppler, fie un RADAR pe 77 GHz, de care se apropie o țintă cu aproximativ 56 m/sec (cam 200 km/oră). Frecvența Doppler este de :

$$f_D = \frac{2v}{c} f_t = \frac{2 \cdot 56}{3 \cdot 10^8} \cdot 77 \cdot 10^9 \cong 28.75 \text{ KHz} . \quad (3.9)$$

Pentru o viteză $v=0.5$ m/sec, ce corespunde mișcării membrilor umani, va rezulta o frecvență Doppler de numai 257 Hz.

3.1.2. RADAR pentru automobile

În figura 45 se arată o mașină țintă pentru un RADAR aflat pe altă mașină sau în afara șoselei. Unda emisă se reflectă de pe țintă și revine la locul de emisie cu un defazaj $\phi(t)$, cauzat de viteza țintei și de distanța $R(t)$ la care se află.




Figura 45. Principiul de funcționare al unui RADAR pentru automobile.

Se folosește un RADAR mono-puls, a cărui structură (generică) este prezentată în figura 46. Un astfel de sistem este capabil să detecteze și să localizeze mai multe ținte simultan. RADAR-ul monopuls este compus dintr-un emițător și dintr-un receptor, ambele conectate la câte o antenă. Semnalul recepționat este heterodinat cu două variante ale semnalului emis, una în fază și cealaltă în cuadratură, folosind două circuite multiplicatoare (conversie în jos) obținându-se semnale cu frecvențe de bătaie date de efectul Doppler corespunzător fiecărei ținte. După eșantionare și conversie analog numerică (CAN) se face analiza în frecvență, utilizând algoritmul FFT și un procesor de semnal.

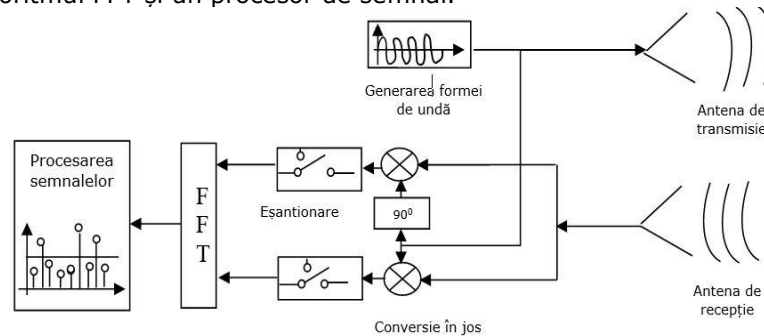


Figura 46. Schema bloc a unui RADAR pentru automobile.

Cea mai simplă formă de undă pentru semnalul emis este cea sinusoidală.

Frecvența Doppler pentru unda reflectată de către o țintă, aflată la distanța $R(t)$ de RADAR, se poate determina apreciind modificarea de fază a ecoului recepționat de RADAR. Drumul dus-întors parcurs de undă este $2R(t)$, așa că modificarea de fază a ecoului recepționat, care este dată de: $\phi(\tau) = 2\pi f_0 \tau$, unde întârzierea cu care sosește unda reflectată s-a notat cu τ , poate fi exprimată cu formula:

$$\varphi(\tau) = 2\pi f_0 \tau = 2\pi f_0 \frac{2R(\tau)}{c} = 2\pi \frac{2R(\tau)}{c} = 2\pi \frac{2R(\tau)}{\lambda_0} \quad (3.10)$$

Pulsația Doppler reprezintă derivata acestei modificări de fază în raport cu timpul:

$$\omega_D = \frac{d\varphi(t)}{dt} = 2\pi \frac{2}{\lambda_0} v = 2\pi \frac{2v}{\lambda_0} \quad (3.11)$$

iar frecvența Doppler este:

$$f_D = \frac{2v}{c} f_0 \quad (3.12)$$

Considerăm, mai întâi că ținta nu se mișcă, adică $v=0$. Apare o întârziere de propagare a undei, de valoare:

$$\tau = \frac{2R(t)}{c} = \frac{2R_0}{c} \quad (3.13)$$

Dacă ținta se mișcă și, spre exemplu, se îndepărtează de RADAR cu viteza v atunci întârzierea devine:

$$\tau = \frac{2R(t)}{c} = \frac{2(R_0 + vt)}{c} = \frac{2R_0}{c} + \frac{2vt}{c} \quad (3.14)$$

iar semnalul reflectat, recepționat, are forma:

$$\begin{aligned} \cos[2\pi f_T(t - \tau)] &= \cos\left[2\pi f_T t - 2\pi f_T \frac{2R_0}{c} - 2\pi f_T \frac{2vt}{c}\right] = \\ &= \cos\left[2\pi\left(f_T - \frac{2v}{\lambda}\right)t - 2\pi f_T \frac{2R_0}{c}\right] \end{aligned} \quad (3.15)$$

unde $f_T=f_0$. Se observă că frecvența semnalului recepționat este egală cu diferența dintre frecvența semnalului emis și frecvența Doppler.

Faza instantanee a semnalului recepționat are expresia:

$$\varphi(t) = 2\pi(f_0 - f_D)t - 2\pi f_0 \tau \quad (3.16)$$

Pulsația instantanee a semnalului recepționat este egală cu derivata fazei instantanee în raport cu timpul:

$$\omega_f(t) = 2\pi(f_0 - f_D) \quad (3.17)$$

În figura 47 se prezintă o comparație între frecvențele instantanee ale semnalelor emis și recepționat.




Figura 47. O comparație între frecvențele instantanee ale semnalelor emis și recepționat în cazul formei de undă sinusoidale.

Se constată că pe baza măsurării frecvenței instantanee a semnalului recepționat (care se face după heterodinare) se poate determina valoarea frecvenței Doppler, cu ajutorul căreia poate fi calculată viteza țintei:

$$v = \frac{\lambda_0}{2} f_D . \quad (3.18)$$

Acest tip de RADAR este folosit de poliția rutieră pentru verificarea încadrării vitezei automobilelor în limitele legale.

În cazul în care se dorește și determinarea distanțelor față de țintă, se preferă forme de undă de tip chirp, ca în figura 48. Acestea sunt semnale modulate în frecvență cu modulator liniar variabil în timp.

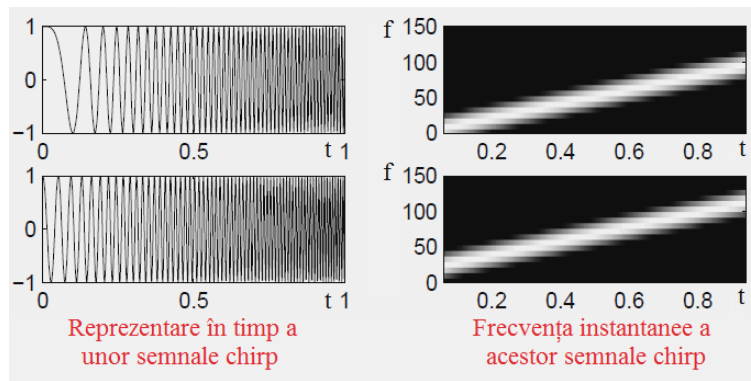


Figura 48. Forme de undă și frecvențele instantanee corespunzătoare a două semnale de tip chirp.

În figura 49 este prezentată variația în timp a frecvențelor instantanee ale semnalului emis, respectiv a semnalului recepționat de un RADAR folosit pentru estimarea distanței.




Figura 49. O comparație a formelor de variație în timp ale frecvențelor instantanee ale semnalelor emis și recepționat în cazul unui RADAR folosit pentru estimarea distanței.

Semnalul emis de RADAR are frecvența liniar variabilă într-o bandă B_{SWEEP} , pe care o acoperă în timpul T_{CPI} . Dacă $v=0$, nu apare efectul Doppler ci numai o întârziere a semnalului recepționat, determinată de distanța de propagare $2R$:

$$\tau = \frac{2R(t)}{c} = \frac{2R_0}{c} \quad (3.19)$$

După heterodinare apare o frecvență de bătaie care este măsurabilă. Din asemănarea triunghiurilor ABC și MNP:

$$\frac{f_B}{\tau} = \frac{B_{sw}}{T_{CPI}} \rightarrow f_B = \frac{B_{sw}}{T_{CPI}} \frac{2R}{c} \quad (3.20)$$

Cunoscând valoarea frecvenței de bătaie, a benzii de baleiere, a duratei chirp-ului și a vitezei luminii putem determina, pe baza ultimei ecuații, valoarea distanței până la țintă, R. Dacă ținta se mișcă apar două efecte de deplasare a frecvenței, dar ambele de valori foarte reduse în comparație cu frecvențele emise. Putem deci considera că frecvența de bătaie care apare este suma celor două componente, cauzate de mișcarea țintei și de distanța RADAR-țintă. Pentru a putea separa aceste componente avem nevoie de două chirp-uri ca în figura 50.




Figura 50. O comparație a formelor de variație în timp ale frecvențelor instantanee ale semnalelor emise și recepționate în cazul unui RADAR monopuls.

În virtutea discuției anterioare, frecvențele de bătaie ce apar sunt aproximabile cu expresiile:

$$f_{B1} = -\frac{2v}{\lambda} + \frac{2B_{sw}R}{cT_{CPI}} = f_D + f_\tau \quad (3.21)$$

$$f_{B2} = -\frac{2v}{\lambda} + \frac{2B_{sw}R}{cT_{CPI}} = f_D - f_\tau \quad (3.22)$$

Aceste două ecuații formează un sistem. Necunoscutele sistemului sunt v , viteza radială și distanța R , soluția fiind unică, așa cum rezultă din figură. Dacă sunt două sau mai multe ținte, apar ținte fantomă, motiv pentru care această soluție simplă nu se poate utiliza.

3.2. Influența zgomotului de tip clutter

Clutter-ul RADAR este răspunsul primit de către RADAR de la un obiect care nu reprezintă o țintă.

Comparând clutter-ul cu zgomotul termic al receptorului putem evidenția următoarele diferențe:

- zgomotul termic nu conține o componentă spațială, pe când clutter-ul conține o componentă spațială ce variază cu poziția și cu rezoluția RADAR-ului,
- clutter-ul variază la schimbarea frecvenței iar zgomotul termic este independent de frecvența transmisă,
- dacă condițiile de mediu se vor schimba, clutter-ul va varia în același timp cu acestea, pe când zgomotul termic este independent de acestea,
- valoarea medie a zgomotului termic este mereu constantă și nu depinde de poziția spațială a RADAR-ului pe când la schimbarea tipului de clutter media temporală va fi diferită în cazul diferitelor poziții ale RADAR-ului,
- zgomotul termic este un semnal aleator cu distribuție Rayleigh pe când clutter-ul este un semnal aleator cu repartiție Weibull,
- clutter-ul este un semnal de bandă îngustă pe când zgomotul termic are o lățime de bandă foarte mare,
- puterea clutter-ului depinde de nivelul semnalului RADAR transmis pe când puterea zgomotului termic al receptorului nu depinde de nivelul acestuia,
- clutter-ul poate fi corelat între impulsuri, zgomotul termic fiind independent de repetiția impulsurilor.

Fie un fascicul RADAR ce iluminează un număr de dispersori, fiecare de reflectivitate diferită, σ_i și distanța față de RADAR, d_i . Amplitudinea câmpului electric (componenta de polarizare orizontală sau verticală) măsurată la nivelul RADAR-ului, datorită ecoului de la al i -lea dispersor, va fi descrisă de ecuația:

$$|E_i| = \left[\frac{P_t G^2 \lambda^2 \sigma_i}{(4\pi)^3 L_s d_i^4} \right]^{\frac{1}{2}} \quad (3.23)$$

unde: P_t reprezintă puterea transmisă, G reprezintă câștigul antenei, λ reprezintă lungimea de undă, iar L_s reprezintă pierderile sistemului incluzând pierderile sistemului hardware și pierderile atmosferice. Faza câmpului electric recepționat relativă la faza undei transmise este determinată de faza dispersorilor reflectați: θ_i și de distanța de propagare:

$$\arg\{E_i\} = \theta_i - \frac{4\pi}{\lambda} d_i = \theta_i + \phi_i \quad (3.24)$$

Dispersorii aflați în aceeași zonă vor genera ecouri care se vor întoarce, cu aceeași defazare de timp și cu aceeași fază, la RADAR. Fiecare dispersor va avea aceeași fază de reflexie, pentru o constantă θ ($\theta_i = \theta$). Dispersorii cu nivele diferite, dar din același fascicul, vor avea faze ale ecoului diferite. Amplitudinea câmpului electric la nivelul radarului, E , este direct proporțională cu suma vectorilor amplitudine câmp electric și fază a fiecărui grup de dispersori, care contribuie la o măsurare RADAR.

Rezultanta câmpului electric E este determinată de:

$$E = \sum_i E_i = \sum_i k \frac{\sqrt{\sigma_i}}{d_i^2} \exp \left[-j \left(\frac{4\pi}{\lambda} d_i + \theta_i \right) \right]$$

$$\approx \frac{k}{d^2} \sum_i \sqrt{\sigma_i} \exp \left[-j \left(\frac{4\pi}{\lambda} d_i + \theta_i \right) \right] \equiv \frac{k'}{d^2} \sqrt{\sigma} \exp [j\phi]$$
(3.25)

unde: constanta k , reprezintă toți factorii care sunt aceeași pentru fiecare dispensor în parte, d reprezintă gama de rezoluții a celulei, σ reprezintă secțiunea RADAR transversală (RADAR Cross Section-RCS) a răspunsului provenit de la clutter, ϕ reprezintă faza echivalentă, iar $\sqrt{\sigma} \exp [j\phi]$ reprezintă coeficientul clutter-ului.

La scanarea zonei de către fasciculul RADAR, gama dispensorilor se schimbă, deci vor apărea schimbări și la nivelul rezultantei echivalente RCS. Zgomotul se va întoarce ca o sumă aleatoare a ecurilor individuale ale dispensorilor. Reducerea valorii acestei sume este foarte importantă. La fiecare scanare, unii dispensori vor dispărea și vor fi înlocuiți cu alții. În cazul folosirii unui sistem mecanic, scanarea este delicată pe când în cazul unui sistem electronic, scanarea va avea un pas mai abrupt. Cât timp dispensorii vor emite, la orice moment dat, aceștia vor avea amplitudini și faze similare, răspunsul va arăta ca un zgomot cu o statistică a parametrilor constantă. Dacă vor fi scanați dispensori diferiți, și caracterul răspunsului se va schimba.

Clutter-ul poate varia în funcție de tip, polarizare, mediu înconjurător, condiții geometrice, ceea ce face foarte dificilă crearea unui model matematic. Experimental s-a arătat faptul că măsurătorile clutter-ului se pot descrie ca funcții de diferiți parametri de care depinde acesta.

Pentru definirea mai exactă a clutter-ului, ecuația RADAR poate fi scrisă astfel:

$$P_r = \frac{P_t G^2 \lambda^2 \sigma}{(4\pi)^3 L_s R^4}$$
(3.26)

variabilele fiind aceleași ca și cele folosite în ecuația (3.23). Această ecuație este foarte potrivită pentru țintele de tip punct (ținte mai mici decât rezoluția RADAR) dar nu este foarte utilă în cazul țintelor distribuite, cum ar fi clutter-ul, unde mulți dispensori contribuie la ecoul total. Pentru clutter-ul de suprafață se definește RCS pe unitate de zonă (reflectivitate de suprafață) :

$$\sigma^0 \equiv \frac{\sigma}{A}$$
(3.27)

unde: σ reprezintă contribuția RCS la clutter, iar A reprezintă aria clutter-ului care contribuie, definit de fasciculul RADAR intersectat cu suprafața sa.

Pentru clutter-ul de volum, RCS pe unitatea de volum (reflectivitatea volumului), se definește ca:

$$\eta \equiv \frac{\sigma}{V}$$
(3.28)

unde: V reprezintă volumul definit de fasciculul RADAR și gama de rezoluție a celulei.

O valoare a σ^0 dată, va ajuta la introducerea ariei A în calculul RCS, prin folosirea ecuației RADAR, suprafața clutter-ului va fi determinată de lățimea fasciculului și de gama de rezoluție a RADAR-ului. Vor apărea două situații:

- gama de rezoluție este mai mare în comparație cu proiecția verticală a fascicului pe suprafață și
 - gama de rezoluție este mai mică decât proiecția.
- În cel de-al doilea caz:

$$A = \pi R^2 \tan\left(\frac{\theta_3}{2}\right) \tan\left(\frac{\phi_3}{2}\right) \csc \delta \quad (3.29)$$

unde: θ_3 reprezintă azimutul antenei, ϕ_3 reprezintă unghiul de elevație al antenei, iar δ reprezintă unghiul de înclinare al antenei pe suprafața clutter-ului.

În cazul impulsurilor limitate, zona definită de fascicul este descrisă de:

$$A = \left(\frac{c\tau}{2}\right) 2R \tan\left(\frac{\theta_3}{2}\right) \sec \delta = c\tau R \tan\left(\frac{\theta_3}{2}\right) \sec \delta \quad (3.30)$$

În acest caz, aria clutter-ului este proporțională cu R și nu cu R².

Unghiul de înclinare, se poate descrie astfel:

$$\tan \delta = \frac{\pi R \tan(\phi_3 / 2)}{c\tau} \quad (3.31)$$

Aceeași generalizare a ecuației RADAR se poate aplica și în cazul clutter-ului de volum:

$$V = \pi \left(\frac{R\theta_3}{2}\right) \left(\frac{R\phi_3}{2}\right) \left(\frac{c\tau}{2}\right) = \left(\frac{\pi R^2 \theta_3 \phi_3}{4}\right) \left(\frac{c\tau}{2}\right) \quad (3.32)$$

Proprietățile de dispersie ale clutter-ului sunt dependente de polarizarea de la nivelul transmițătorului și receptorului.

Matricea de polarizare a dispersorilor este:

$$S = \begin{bmatrix} \sqrt{\sigma_{HH}} e^{j\phi_{HH}} & \sqrt{\sigma_{HV}} e^{j\phi_{HV}} \\ \sqrt{\sigma_{VH}} e^{j\phi_{VH}} & \sqrt{\sigma_{VV}} e^{j\phi_{VV}} \end{bmatrix} \quad (3.33)$$

Prima linie reprezintă polarizarea la nivelul receptorului, iar a doua polarizarea la nivelul transmițătorului. Elementele matricii S reprezintă coeficienții clutter-ului în cele patru cazuri de polarizare:

- cazul 1: transmițătorul și receptorul au o polarizare orizontală,
- cazul 2: transmițătorul este polarizat orizontal și receptorul vertical,
- cazul 3: transmițătorul este polarizat vertical și receptorul orizontal,
- cazul 4: transmițătorul și receptorul au o polarizare verticală.

În cazul unei frecvențe specifice și a unor parametri ai mediului, matricea de dispersie a clutter-ului va conține toată informația despre răspunsul clutter-ului în momentul în care se realizează măsurarea. Un RADAR care ar putea transmite toți cei patru coeficienții de polarizare este foarte scump dar și foarte complex în realizare, dar datorită existenței teoremei de reciprocitate, care spune că doi termeni polarizați încrucișat sunt egali, va rezulta că:

$$\begin{cases} \sigma_{VH} = \sigma_{HV} \\ \phi_{VH} = \phi_{HV} \end{cases} \quad (3.34)$$

Prin cunoașterea valorilor a trei coeficienți, întreaga matrice de polarizare poate fi recompusă.

Holm a descoperit că, pentru o detecție eficientă, trebuie ca o celulă să cuprindă doar răspunsuri de la ținte sau doar răspunsuri de la clutter. Dacă o celulă

va cuprinde atât răspunsuri de la clutter cât și de la ținte, chiar dacă valoarea amplitudinii clutter-ului este mai mică, eficiența va fi mai scăzută.

Clutter-ul reprezintă una dintre limitările majore în detecția țintelor, măsurarea clutter-ului fiind un domeniu de interes încă din al doilea război mondial. Dezvoltarea tehnicilor de înregistrare digitală a crescut calitatea și cantitatea datelor. Deoarece clutter-ul arată fluctuația zgomotului în puterea ecoului, acesta este caracterizat în parametri statistici de variabilele η și σ^0 dar și de următoarele:

- valori medii sau mediane,
- deviații standard sau varianțe,
- lățimi de bandă spectrală pentru variabilitate temporală,
- funcții de autocorelație,
- funcții de densitate spectrală pentru variații temporale și spațiale,
- funcții de densitate de probabilitate.

Valorile măsurate includ efectele factorului de propagare. Efectele create de mediu pot fi minimizate prin utilizarea calibrării țintelor din apropierea clutter-ului, dar acestea nu pot fi eliminate. Măsurătorile RADAR pot fi diferite în funcție de nivelul de precipitații.

3.2.1. Modele de clutter

Principalele modele de clutter considerate la detecția țintelor sunt:

- clutter uniform,
- clutter de margine,
- ținte duble.

3.2.1.1. Clutter-ul uniform

Acest tip de clutter descrie situația întâlnită în majoritatea cazurilor, în care în fereastra de referință este prezent un zgomot staționar. Utilizarea acestui model este recomandată în următoarele cazuri:

- o țintă din celula de test este în fața unui alt mediu uniform,
- zgomotul este uniform de-a lungul ferestrei de referință.

Zgomotul din vecinătate are o statistică uniformă astfel încât variabilele X_1, \dots, X_N din fereastra de referință vor fi independente statistic și identic distribuite.

3.2.1.2. Clutter-ul de margine

Acest model este necesar în cazul în care se vor întâlni zone de tranziție între zone din mediu ce prezintă caracteristici deloc asemănătoare. Modelul este reprezentat de clutter și zgomot din mediu. Se recomandă utilizarea acestui model în următoarele cazuri:

- amplitudinile clutter-ului sunt distribuite pe baza distribuției Rayleigh și sunt statistic independente,
- clutter-ul are un răspuns constant în amplitudine.

Acestea se întâlnesc în cazul fenomenelor meteo cu statistici fluctuante și amplitudini parțial corelate.

3.3. Detecția țintelor cu rată de alarmă falsă constantă

3.3.1. Detecția

Sistemele RADAR îndeplinesc trei funcții principale: căutarea și urmărirea țintelor și reprezentarea traiectoriilor. Funcția de căutare se referă la procesele de localizare și detecție a țintei. Urmărirea țintei constă în realizarea unor măsurători succesive ale poziției țintei. O categorie de astfel de sisteme urmăresc ținta prin fixarea fasciculului de radiație al antenei pe țintă, iar la deplasarea țintei se va deplasa și fasciculul. Funcția de urmărire era realizată în sistemele RADAR concepute la început cu circuite analogice, care comandau antena RADAR. În senzorii RADAR moderni se folosesc circuite digitale care vor găsi coordonatele carteziene ale vectorului țintă (poziție, accelerație, viteză). Există RADAR-e care realizează una, două sau toate cele trei funcții. Se pot realiza și sisteme multi-RADAR, fiecare RADAR încorporat în sistemul global va realiza o funcție. Aceste tipuri de sisteme prezintă următoarele dezavantaje: limitarea de putere și necesitatea unui spațiu mai mare. Un compromis în acest caz este reprezentat de un RADAR ce va îndeplini atât funcția de detecție a țintei cât și cea de urmărire.

Rar, o țintă este detectată cu un singur impuls, în majoritatea cazurilor, fasciculul antenei este îndreptat spre țintă și sunt emise mai multe impulsuri până la detectarea ei. În acest caz raportul semnal pe zgomot (Signal to Noise Ratio-SNR) va fi determinat de puterea medie, și de durata trenului de impulsuri T_d -timp de așteptare (dwell time). Acesta reprezintă timpul în care se transmit și se recepționează n impulsuri pentru detecție. Dacă impulsurile sunt procesate cu ajutorul Transformatei Fourier rapide (Fast Fourier Transform-FFT), acest interval se numește interval de procesare coerent (Coherent Processing Interval – CPI).

Detecția unei ținte implică procesul de decizie, dacă aceasta va prezenta sau nu interes. În sistemele moderne, detecția este realizată de procesoare de date. Detecția se realizează prin stabilirea unui nivel de prag, în funcție de nivelul perturbațiilor care vor fi întâlnite în aceea zonă (zgomot intern, zgomot extern, clutter, zgomot termic). Într-o celulă se detectează o țintă dacă semnalul generat de aceasta depășește pragul de detecție. Când se ating vârfuri de zgomot, semnalul recepționat depășește pragul de detecție deși semnalul generat de țintă este mai mic decât pragul și se realizează detecția creându-se o alarmă falsă, nefiind vorba de o țintă.

În foarte puține cazuri, pentru detecția țintei se transmite un singur impuls, în majoritatea cazurilor fiind necesară transmiterea mai multor impulsuri.

3.3.2. Apariția alarmei false

În cazul ideal, în care clutter-ul nu este prezent iar singura sursă de zgomot o reprezintă zgomotul termic al receptorului, câștigul receptorului poate fi setat ca și cum zgomotul ar fi la o valoare constantă și cunoscută. Astfel, pragul de detecție poate fi setat la o valoare fixă mai mare decât nivelul zgomotului, pentru a scădea probabilitatea apariției unei alarme false. Perturbația cauzată de clutter sau de bruiaje este variabilă. RADAR-ele moderne au un prag de detecție adaptiv, care se calculează automat în funcție de nivelul perturbațiilor, realizându-se o rată de alarmă falsă constantă. Nivelul semnalului generat de țintă trebuie să depășească valoarea pragului de detecție, pentru care ținta să fie detectată.

În cazul în care clutter-ul are un nivel mai mare decât al semnalului generat de țintă, procesarea semnalului recepționat va avea ca obiectiv reducerea clutter-ului la un nivel mai mic decât cel al semnalului țintă. Sistemele afectate de clutter și de bruiaj, vor utiliza tehnici de procesare adaptive spațio-temporale.

Zgomotul la recepție este un semnal aleator. Semnalul generat de o țintă este un semnal aleator complex. Amplitudinea și faza acestui semnal sunt variabile aleatoare. Procesul de detecție a țintei este un proces aleator, caracterizat de probabilitatea de detecție P_D și de probabilitatea de alarmă falsă P_{FA} , care va trebui să fie cât mai apropiată de zero.

Zgomotul fluctuează și suma semnalului țintă și a zgomotului ν depinde de funcțiile lor de densitate de probabilitate (probability density function-pdf): $(PDF)_s$ și $p_\nu(\nu)$. Aceste funcții descriu intervalul relativ în care o variabilă aleatoare poate avea diferite valori.

Funcțiile de densitate de probabilitate sunt folosite la calculul probabilităților de alarmă falsă și detecție corectă.

Probabilitatea ca variabila aleatoare ν să depășească pragul de tensiune V_t este:

$$P\{\nu > V_t\} = \int_{V_t}^{\infty} p_\nu(\nu) d\nu \quad (3.37)$$

Pentru un prag de tensiune dat, pentru determinarea P_{FA} se consideră $p_i(\nu)$ ca fiind pdf a zgomotului. Un prag de tensiune V_t va avea un nivel mai mare decât valoarea medie a zgomotului pentru limitarea posibilității de apariție a alarmelor false:

$$P_{FA} = \int_{V_t}^{\infty} p_i(\nu) d\nu \quad (3.38)$$

Parametrul V_t , va influența valoarea P_{FA} care este direct proporțională cu acesta.

Probabilitatea de detecție a țintei P_D depinde de pdf a tensiunii semnalului plus zgomot p_{s+i} ce va varia în funcție de zgomot, de variația semnalului generat de țintă sau de SNR:

$$P_D = \int_{V_t}^{\infty} p_{s+i}(\nu) d\nu \quad (3.39)$$

În absența semnalului țintă, orice perturbație interpretată greșit ca un semnal țintă va reprezenta o alarmă falsă. Pentru a se determina probabilitatea de apariție a unei alarme false, trebuie să se cunoască obligatoriu valoarea pdf a zgomotului. Sistemele RADAR necoerente folosesc pentru detecție doar amplitudinea semnalului generat de țintă. Sistemele RADAR coerente, cele actuale, folosesc pentru detecție forma complexă a semnalului recepționat, reprezentat ca un vector cu amplitudinea ν și faza ϕ . Circuitul de detecție utilizează atât componenta în fază (I) a vectorului cât și componenta sa în cuadratură (Q).

Pentru un detector liniar, dacă semnalul ce reprezintă perturbația este zgomotul termic, fiecare componentă de semnal va avea o distribuție aleatoare a tensiunii de medie zero și amplitudinea vectorului se exprimă astfel:

$$\nu = \sqrt{I^2 + Q^2} \quad (3.40)$$

În acest caz, având în vedere că cele două componente în fază și în cuadratură sunt repartizate normal, rezultanta amplitudinii zgomotului este distribuită conform pdf de tip Rayleigh:

$$p_i(v) = \frac{v}{\sigma_n^2} \exp\left(\frac{-v^2}{2\sigma_n^2}\right) \quad (3.41)$$

unde: v – reprezintă anvelopa tensiunii detectate iar σ_n^2 – reprezintă varianța (dispersia) zgomotului.

Probabilitatea alarmei false este redusă de faptul că detecția țintei se produce atât în faza de căutare cât și în cea de confirmare.

Pentru un singur eșantion de zgomot cu o distribuție Rayleigh, probabilitatea de alarmă falsă va deveni:

$$P_{FA} = \int_{V_T}^{\infty} \frac{r}{\sigma_n^2} e^{\frac{-r^2}{2\sigma_n^2}} dr = e^{\frac{-V_T^2}{2\sigma_n^2}} \quad (3.42)$$

Pragul de detecție, V_T , necesar pentru a obține o probabilitate de alarmă falsă de valoare P_{FA} , se poate calcula astfel:

$$V_T = \sqrt{2\sigma_n^2 \ln\left(\frac{1}{P_{FA}}\right)} \quad (3.43)$$

Fiecare sistem de căutare este realizat în așa fel încât detecția să se realizeze într-o anumită poziție la o anumită încercare, rezultatul putând fi și o alarmă falsă, de aceea se încearcă încă o căutare pentru a se verifica dacă se va depăși din nou pragul sau nu. Uneori alarma falsă poate persista, chiar dacă ținta se va deplasa. Rezultatele încercărilor succesive sunt independente. Probabilitatea alarmei false pe ansamblul celor n încercări, $P_{FA}(n)$, este asociată probabilității de alarmă falsă a unei încercări $P_{FA}(1)$:

$$P_{FA}(n) = [P_{FA}(1)]^n \quad (3.44)$$

Probabilitatea ca o alarmă falsă să se repete pentru două încercări consecutive este $P_{FA}^2(1)$, pentru trei încercări consecutive va fi $P_{FA}^3(1)$, iar pentru n încercări va fi $P_{FA}^n(1)$.

3.3.3. Detecția țintelor cu rată de alarmă falsă constantă

Procesul de detecție a unei ținte începe cu compararea rezultatului măsurării RADAR cu pragul de detecție setat anterior. Rezultatele care vor depăși pragul se vor considera a fi răspunsuri de la o țintă, iar rezultatele care se vor situa sub valoarea de prag vor fi considerate răspunsuri la zgomot termic, sau răspunsuri la alte surse de perturbație (bruij, răspunsuri de la suprafețe terestre sau suprafețe acoperite de apă). Detectorul trebuie să atingă cea mai mare valoare posibilă pentru probabilitatea de detecție a țintei pentru o valoare a SNR specificată și o valoare a probabilității de alarmă falsă anterior fixată.

În absența unei ținte, dacă sursa de perturbație va produce un semnal care va depăși pragul de detecție, se va produce o alarmă falsă. Sistemul RADAR este

conceput să atingă și să mențină o anumită probabilitate de alarmă falsă. Alarmerile false, epuizează resursele RADAR, uneori conducând la ignorarea adevăratelor ținte, ceea ce va avea ca rezultat degradarea performanțelor sistemului RADAR.

Dacă se cunosc date anterioare despre perturbațiile care pot apărea, pragul poate fi selectat corespunzător unei valori cât mai mici a probabilității de alarmă falsă. De obicei forma funcției de densitate de probabilitate a perturbației este cunoscută dar parametrii distribuției nu se cunosc sau se schimbă în funcție de timp și spațiu.

3.3.3.1. Detectorul CFAR

Detectorii cu rată de alarmă falsă constantă (Constant False Alarm Rate - CFAR) urmăresc variația perturbațiilor și modifică valoarea de prag pentru ca probabilitatea de alarmă falsă să se mențină la un nivel constant.

Decizia de detecție a RADAR-ului se bazează pe semnalele recepționate și pe zgomotul termic al receptorului. Eșantioanele pot fi colectate în una sau mai multe dimensiuni (gamă, unghi, efect Doppler). Semnalele recepționate vor fi eșantionate la un interval de spațiere egal cu rezoluția sistemului RADAR. Detectorul compară valorile eșantioanelor cu pragul și alege între cele două ipoteze (țintă prezentă sau absentă).

Eșantioanele care vor depăși pragul se va considera că sunt răspunsuri de la țintă și sunt asociate ipotezei semnal țintă prezent (ipoteza H_1). Eșantioanele de valori sub nivelul pragului se consideră răspunsuri de la sursele de perturbații și sunt asociate ipotezei nule (ipoteza H_0). Aceste răspunsuri pot proveni de la: zgomotul receptorului, bruiaje intenționate, clutter. Răspunsurile de tip clutter provin de la reflexiile pe obiectele din mediu ce nu reprezintă ținte. În figura 51 se prezintă schema bloc a sistemului de prelucrare a semnalului RADAR din receptor pentru detecție.




Figura 51. Diagrama de procesare RADAR.

Convertorul Analog-Digital (A/D) transformă semnalul analogic recepționat în eșantioane digitale. Următorul bloc din schema de procesare a semnalului RADAR prezentată în figura 51 acționează asupra acestor eșantioane pentru a realiza maximizarea raportului semnal-pe-interferență-plus-zgomot la nivelul detectorului. Algoritmii de realizare a maximizării include procesarea Doppler, compresia impulsului și metode adaptive de spațiere în timp. Acești algoritmi utilizează eșantioane complexe. Partea reală și partea imaginară a acestor eșantioane, corespund una componentei în fază a receptorului, (I) și cealaltă componentei în cuadratură, (Q). Semnalele complexe obținute vor trece prin rectificator. Rectificatorul convertește eșantioanele complexe în valori absolute sau valori absolute la pătrat. Un rectificator de tip logaritmic, spre deosebire de unul liniar va compresiona gama dinamică a valorilor măsurate și va evita mascarea țintelor. Mascarea țintelor poate avea ca efect ratarea unor detecții dacă valoarea pragului de detecție CFAR cade între valorile amplitudinilor răspunsurilor celor două ținte. Detectorul este ultimul bloc din diagrama de procesare RADAR și există trei

posibilități de răspuns la ieșirea acestuia: o detecție corectă, o alarmă falsă sau o detecție ratată.

O detecție corectă corespunde cazului în care detectorul declară, conform realității, prezența sau după caz absența unei ținte.

O detecție ratată corespunde cazului în care detectorul declară că ținta nu este prezentă, deși datele recepționate conțin semnal recepționat de la țintă.

O alarmă falsă corespunde cazului în care detectorul declară că ținta este prezentă, deși datele recepționate nu conțin informații despre aceasta.

Atât semnalul provenit din cauza perturbațiilor cât și cel de la țintă sunt modelate ca și procese aleatoare caracterizate de densitatea spectrală de putere, de densitatea de probabilitate sau de funcțiile de corelație.

Răspunsul la semnalul generat de țintă dar și răspunsul la perturbație sunt semnale aleatoare. Datorită acestui fapt, performanțele detectorului trebuie exprimate în funcție de probabilități. Posibilitatea detecției unei ținte, este specificată în termenii probabilității de detecție P_D . Posibilitatea unei alarme este exprimată în termenii probabilității de alarmă falsă P_{FA} . Detectorul poate optimiza performanțele pe baza unei funcții de cost care va cântări fiecare decizie.

3.3.3.2. Detectorul CFAR Neyman-Pearson

Detectorul CFAR Neyman Pearson, are un prag de detecție fix, care maximizează probabilitatea de detecție corectă P_D , în cazul unei probabilități de alarmă false constantă cunoscută deja. În cazul detectorului Neyman Pearson, perturbațiile se consideră funcții independente și identic distribuite. În majoritatea cazurilor parametrii acestor distribuții nu sunt în totalitate cunoscuți. Un detector ar trebui să estimeze acești parametri pentru datele măsurate, pentru a atribui o valoare de prag cât mai corectă.

Apariția unei alarme false este cauzată de epuizarea resurselor RADAR, care sunt limitate. Cu cât rata de apariție a alarmei este mai mare, cu atât impactul negativ asupra performanței detectorului va fi mai mare. Rata de alarmă falsă reprezintă numărul de alarme false ce se produc într-un interval de timp stabilit și se calculează cu formula:

$$FAR = \frac{P_{FA}M}{T_M} = N_D P_{FA} \quad (3.45)$$

unde: M-reprezintă numărul de celule din care se colectează datele pentru un anumit interval de timp ce este definit de T_M . $N_D=M/T_M$ -reprezintă numărul de detecții realizate într-o unitate de timp.

După detecția țintelor, resursele procesorului de semnal RADAR sunt alocate pentru verificare, urmărirea țintelor detectate și măsurarea caracteristicilor țintelor din următorul ciclu de măsurare al senzorului RADAR. Aceste resurse sunt finite. Un număr mare de alarme false poate supraîncărca procesorul de semnal RADAR, și pot rezulta întreruperi ale detecției.

Rata de alarme false se poate modifica în funcție de puterea perturbațiilor. Nivelul puterii perturbațiilor poate varia în funcție de bruiatul intenționat sau de reflectivitatea terenului.

Puterea medie estimată a semnalului RADAR transmis este utilizată ca o statistică în algoritmi CFAR.

Distribuția perturbațiilor este de tip Rayleigh în cazul detectoarelor liniare și de tip exponențial în cazul detectoarelor de medie pătratică:

$$p_z(Z) = \begin{cases} \frac{1}{\sigma_i^2} \exp\left(\frac{-z}{\sigma_i^2}\right), & z \geq 0 \\ 0, & z < 0 \end{cases} \quad (3.46)$$

unde $z = |y|^2$ - reprezintă perturbația în cazul detectorului de medie pătratică, y este semnalul de perturbație complex iar σ_i^2 reprezintă valoarea dispersiei lui z , adică puterea medie a perturbației.

În acest caz probabilitatea de alarmă falsă este:

$$P_{FA} = \int_T^\infty \frac{1}{\sigma_i^2} \exp\left(\frac{-z}{\sigma_i^2}\right) dz \quad (3.47)$$

Pentru un prag fix T , creșterea puterii perturbației va duce la creșterea probabilității alarmei false:

$$P_{FA} = \exp\left(\frac{-T}{\sigma_i^2}\right) \quad (3.48)$$

În cazul în care puterea medie a perturbației scade de k ori și pragul de detecție nu este ajustat, se poate scrie următoarea relație între probabilitățile de alarmă falsă din cele două situații:

$$P_{FA_{final}} = \left(P_{FA_{initial}}\right)^{1/k} \quad (3.49)$$

unde: $P_{FA_{initial}}$ - reprezintă probabilitatea inițială (de dinainte de creșterea puterii medii a perturbației) de alarmă falsă, iar $P_{FA_{final}}$ - reprezintă valoarea finală (de după creșterea puterii medii a perturbației) a probabilității de alarmă falsă.

Pentru uniformitatea funcționării este important ca probabilitatea de alarmă falsă să fie menținută constantă, indiferent de variația puterii perturbației. Detectorul CFAR estimează statistica perturbației în funcție de rezultatele măsurărilor efectuate de senzorul RADAR și modifică valoarea pragului de detecție pentru a menține o valoare fixă a P_{FA} .

Un detector Neyman-Pearson presupune două ipoteze: H_0 - la intrarea receptorului este prezentă doar perturbația și H_1 - la intrarea receptorului este prezentă suma dintre semnalul RADAR transmis de emițător și perturbație.

Se consideră o țintă fixă și o perturbație repartizată Rayleigh. În cazul ipotezei H_0 , canalele în fază și cuadratură vor conține perturbații normal distribuite:

$$y = I_i + jQ_i \quad (3.50)$$

unde: $I_i \sim N\left(0, \frac{\sigma_i^2}{2}\right)$, $Q_i \sim N\left(0, \frac{\sigma_i^2}{2}\right)$.

În cazul ipotezei H_1 , ieșirea receptorului se exprimă ca:

$$y = (I_i + I_t) + j(Q_i + Q_t) \quad (3.51)$$

unde: $I_t \sim N\left(0, \frac{\sigma_t^2}{2}\right)$, $Q_t \sim N\left(0, \frac{\sigma_t^2}{2}\right)$, iar i și t sunt indici care reprezintă perturbația

respectiv ținta.

Considerăm că z reprezintă variabila unui detector de medie pătratică și că în cazul ipotezei H_0 (sunt prezente doar perturbații) este distribuită exponențial conform ecuației (3.46).

În cazul ipotezei H_1 (sunt prezente ținte și perturbații), variabila z este repartizată tot exponențial:

$$p_Z(Z) = \begin{cases} \frac{1}{\sigma_i^2 + \sigma_t^2} \exp\left(\frac{-z}{\sigma_i^2 + \sigma_t^2}\right), & z \geq 0 \\ 0, & z < 0 \end{cases} \quad (3.52)$$

Ecuția anterioară se poate exprima și în funcție de raportul-semnal-pe-zgomot-plus interferență (Signal to Interference plus Noise Ratio-SINR):

$$p_Z(Z) = \begin{cases} \frac{1}{\sigma_2^2(1 + \text{SINR})} \exp\left(\frac{-z}{\sigma_2^2(1 + \text{SINR})}\right), & z \geq 0 \\ 0, & z < 0 \end{cases} \quad (3.53)$$

definit ca:

$$\text{SINR} = \frac{\sigma_t^2}{\sigma_i^2} \quad (3.54)$$

Detectorul CFAR de tip Neyman-Pearson urmărește maximizarea probabilității de detecție corectă P_D , la o valoare a probabilității de alarmă falsă constantă impusă. Logaritmând natural în ambii membri ai ecuației (3.48) putem exprima pragul de detecție în forma:

$$T = -\ln(P_{FA})\sigma_i^2 \quad (3.55)$$

Această valoare de prag reprezintă produsul dintre doi factori:

$\ln(P_{FA})$ – logaritmul valorii dorite a probabilității de alarmă falsă și σ_i^2 – puterea perturbației.

În general, pragul detectorului CFAR se definește ca:

$$T = \alpha \hat{g} \quad (3.56)$$

unde: \hat{g} – reprezintă o statistică a perturbației și este estimată din datele măsurate, iar α – reprezintă o constantă CFAR și poate fi aleasă pentru a obține valoarea dorită a P_{FA} .

Pentru a se obține o valoare specifică a P_{FA} trebuie să se cunoască puterea perturbației, chiar și o mică creștere a puterii perturbației poate produce creșteri foarte mari ale P_{FA} . De aceea este foarte important ca detectorul CFAR să își adapteze pragul în funcție de nivelul perturbațiilor.

3.3.3.3. Detectorul CA-CFAR

Algoritmul CFAR de mediere a celulelor (Cell Averaging CFAR CA-CFAR) calculează valoarea pragului detectorului pe baza unei estimări a puterii medii a perturbației. În cazul acestuia se pot face următoarele afirmații:

- perturbațiile sunt distribuite IID,
- distribuțiile perturbațiilor sunt de tip Rayleigh,
- rectificatorul din figura 51 este de medie pătratică, perturbațiile de la ieșirea sa fiind distribuite exponențial,
- puterea medie a perturbațiilor de la ieșirea rectificatorului este necunoscută și trebuie estimată.

Pentru început trebuie calculată valoarea medie a acestei puteri folosind eșantioanele din fereastra de referință. Perturbația de la intrarea detectorului este distribuită exponențial conform ecuației (3.46).

Densitatea de probabilitate comună a celor N eșantioane IID din fereastra de referință, este:

$$p_Z = \frac{1}{(\sigma_i^2)^N} \exp\left(-\sum_{n=1}^N \frac{z_n}{\sigma_i^2}\right), z \geq 0 \quad (3.57)$$

unde $z = \{z_1, z_2, \dots, z_N\}$.

Estimarea puterii perturbației poate fi făcută cu următoarea formulă:

$$\hat{\sigma}_i^2 = \frac{1}{N} \sum_{n=1}^N z_n^2 \quad (3.58)$$

Pragul detectorului CA-CFAR, T_{CA} se calculează pe baza relației (3.56) ca produsul puterii estimate în ecuația anterioară și constanta CFAR, α_{CA} :

$$T_{CA} = \alpha_{CA} \hat{\sigma}_i^2 \quad (3.59)$$

Următoarea etapă este reprezentată de calculul probabilității medii de detecție a țintei în funcție de valoarea de prag estimată. Probabilitatea de detecție corectă a unei ținte se va obține în conformitate cu ecuația (3.53) astfel:

$$P_D = \int_{\alpha_{CA} \hat{\sigma}_i^2}^{\infty} \frac{1}{\sigma_i^2 (1 + \text{SINR})} \exp\left(-\frac{z}{\sigma_i^2 (1 + \text{SINR})}\right) dz \quad (3.60)$$

Integrând, se obține:

$$P_D(\hat{\sigma}_i^2) = \exp\left(\frac{-\alpha_{CA} \hat{\sigma}_i^2}{\sigma_i^2 (1 + \text{SINR})}\right) \quad (3.61)$$

Se observă că probabilitatea de detecție $P_D(\hat{\sigma}_i^2)$ este o variabilă aleatoare obținută prin aplicarea funcției definite în ecuația (3.61) variabilei aleatoare $\hat{\sigma}_i^2$ (exprimată în ecuația (3.58)).

Densitatea de probabilitate a variabilei aleatoare putere estimată $\hat{\sigma}_i^2$ se poate calcula cu ajutorul formulei de calcul a densității de probabilitate a unei variabile aleatoare obținută prin transformarea funcțională (a se vedea ecuația (3.58)) a unei alte variabile aleatoare (a se vedea ecuația (3.57)) [267] și are următoarea formulă:

$$p_{\hat{\sigma}_i^2}(\hat{\sigma}_i^2) = \frac{N^N (\hat{\sigma}_i^2)^{N-1} \exp\left(\frac{-N\hat{\sigma}_i^2}{\sigma_i^2}\right)}{(\sigma_i^2)^N (N-1)!}, \hat{\sigma}_i^2 \geq 0 \quad (3.62)$$

Probabilitatea medie de detecție \bar{P}_D se calculează ca medie statistică a probabilității de detecție din relația (3.61) folosind densitatea de probabilitate a puterii estimate astfel:

$$\bar{P}_D = \int_0^\infty p_{\hat{\sigma}_i^2}(\hat{\sigma}_i^2) \exp\left(\frac{-\alpha_{CA} \hat{\sigma}_i^2}{\sigma_i^2 (1 + \text{SINR})}\right) d\hat{\sigma}_i^2 \quad (3.63)$$

Ținând seama de identitatea:

$$\int_0^\infty x^n \exp(-\alpha x) dx = \frac{n!}{\alpha^{n+1}} \quad (3.64)$$

unde: x – reprezintă o variabilă reală $\alpha > 0$, n – întreg pozitiv, ecuația (3.63) poate fi exprimată în următoarea formă simplificată:

$$\bar{P}_D = \left[1 + \frac{\frac{\alpha_{CA}}{N}}{(1 + \text{SINR})} \right]^{-N} \quad (3.65)$$

Probabilitatea medie de alarmă falsă se poate obține prin egalarea SINR din ecuația anterioară cu zero (ceea ce înseamnă că puterea semnalului transmis este egală cu zero, motiv pentru care nu apare nici o țintă și se detectează doar perturbații, producându-se alarme false) și are valoarea:

$$\bar{P}_{FA} = \left[1 + \frac{\alpha_{CA}}{N} \right]^{-N} \quad (3.66)$$

Se observă că probabilitatea medie de alarmă falsă nu depinde de valoarea puterii perturbațiilor σ_i^2 . Această proprietate este definitorie pentru detectorul CFAR.

Ridicând în ambii membri ai ecuației (3.65) la puterea $-1/N$, putem determina valoarea constantei CFAR din cazul detectorului CA-CFAR:

$$\alpha_{CA} = N \left[\bar{P}_{FA}^{-1/N} - 1 \right] \quad (3.67)$$

3.3.3.4. O comparație între detectoarele CFAR de tipurile CA-CFAR și Neyman-Pearson

Într-un mediu omogen, detectorul CFAR este conceput pentru a atinge o probabilitate medie de apariție a alarmei false de valoare impusă. Variația incertă a statisticilor CFAR va produce în cazul detectorului de tip CA-CFAR o valoare de prag mai mare decât cea din cazul detectorului CFAR Neyman-Pearson (NP), pentru aceeași valoare a P_{FA} . O valoare mai mare a pragului în cazul detectorului CA-CFAR presupune și o valoare mai mare a SINR decât în cazul detectorului NP pentru a obține o anumită valoare pentru P_D . Într-un sistem RADAR, un detector cu o valoare

mare a SINR poate fi considerat ca și un dezavantaj, dar nici detectorul NP cu o valoare SINR mică nu poate ajunge la valoarea P_D dorită. Pierderea de performanță a detectorului CA-CFAR în comparație cu detectorul NP-CFAR se poate calcula ca și raport dintre SINR necesar detectorului CA-CFAR și SINR necesar detectorului Neyman-Pearson pentru a atinge aceeași probabilitate de alarmă falsă.

În cazul unui mediu înconjurător heterogen, existența țintelor multiple și variația puterii perturbațiilor vor duce la degradarea performanțelor detectorului CFAR. Răspunsurile de la ținte apropiate din fereastra de analiză, ce sunt comparate cu un prag de detecție anterior estimat, pot duce la fenomenul de mascare a țintelor (unele dintre aceste ținte nu sunt detectate deoarece valoarea pragului de detecție este mai mare decât răspunsurile acestor ținte). După cum s-a amintit deja, în cazul detectorului CA-CFAR valoarea pragului de detecție este mai mare decât în cazul detectorului NP. Dar cu cât valoarea pragului de detecție este mai mare, cu atât mai redusă va fi valoarea probabilității de detecție P_D . De aceea, pentru a obține o valoare cât mai bună a P_D este necesară creșterea valorii SINR.

3.3.3.5. Estimarea puterii perturbațiilor folosind filtre cu ordonare statistică

În cazul sistemelor RADAR actuale nu se mai poate vorbi de un clutter uniform. De aceea, pentru estimarea puterii perturbațiilor trebuie cunoscute cât mai multe date despre clutter-ul care apare în fereastra de analiză a celulei RADAR de test. Tehnicile CFAR utilizate anterior (estimarea puterii perturbațiilor bazată pe mediere aritmetică), au fost modificate abordându-se proceduri noi inspirate din procesarea imaginilor. Datele din fereastra de analiză sunt utilizate de acești algoritmi pentru calculul valorii pragului de decizie. De exemplu, în figura 52 se prezintă sub-sistemul procesorului RADAR de estimare a puterii medii a clutter-ului (notată în figura 52 cu Z), pe baza căreia se estimează puterea perturbației cu ajutorul căreia se fixează valoarea pragului detectorului, notat în figura 52 cu S.

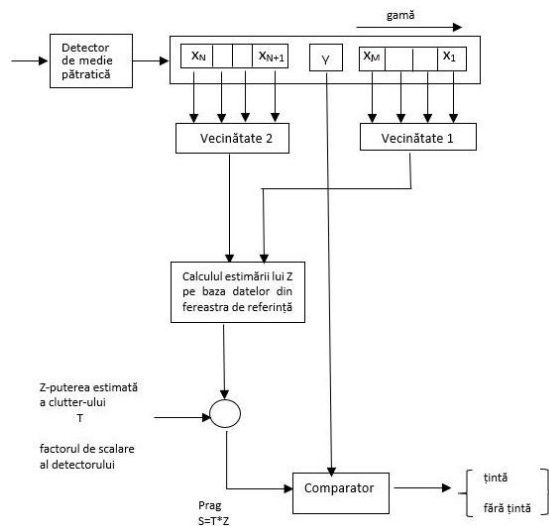


Figura 52. Procesorul CFAR. Estimarea puterii medii a clutter-ului.

Prima operație constă în măsurarea puterii medii a clutter-ului, Z . În cea de a doua operație, se va multiplica rezultatul acestei estimări Z , cu factorul de scalare T , care depinde de metoda de detecție aplicată și de rata de alarmă falsă dorită. Rezultatul, care este dat de produsul TZ , reprezintă valoarea pragului detectorului și se va compara cu ieșirea unui filtru cu ordonare statistică cu ajutorul comparatorului de la ieșirea sistemului cu schema bloc prezentată în figura 52.

Filtrul cu Ordonare Statistică (OS) din figura 52 estimează puterea clutter-ului. Filtrele cu OS asociază elementele secvenței dintr-o fereastră temporală de analiză cu una dintre caracteristicile statistice ale acelei secvențe, cum ar fi: valoarea maximă (greatest of-GO), valoarea minimă, valoarea medie sau valoarea mediană. Detectorul CFAR care folosește pentru estimarea puterii medii a clutter-ului filtrul cu OS care calculează valoarea maximă a secvenței din fereastra de analiză se numește detector CAGO-CFAR. Dacă se alege drept caracteristică statistică de ieșire a filtrului cu OS valoarea medie atunci sistemul din figura 52 ia forma din figura 53 și reprezintă tocmai detectorul CA-CFAR deja prezentat

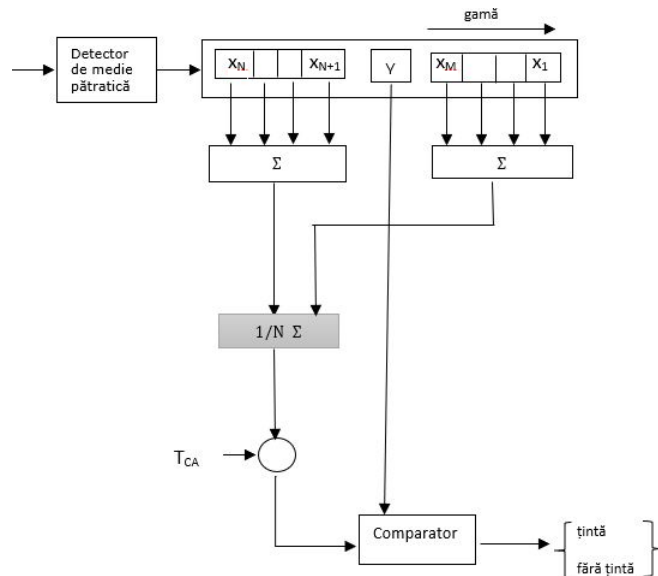


Figura 53. Detectorul CA-CFAR.

Schema bloc a detectorului CAGO-CFAR este prezentată în figura 54. Pentru a putea compara detectoarele CA-CFAR și CAGO-CFAR, trebuie considerate două tipuri diferite de mediu: staționar, caracterizat de clutter uniform și nestaționar, caracterizat de clutter neuniform (clutter de margine).

Comparația se poate face în cazul unor ținte dense, de exemplu în cazul a două ținte foarte apropiate ca și valoare și azimut, dar având unghiuri de elevație diferite, situate în aceeași fereastră de analiză. La estimarea puterii perturbației se va ține seama doar de clutter, zgomotul termic al receptorului precum și semnalul util fiind neglijate. De fapt puterea perturbației se va estima pe baza măsurării puterii semnalului reflectat de țintă. În consecință, puterea perturbației va fi aproximată cu puterea clutter-ului. Astfel se va obține o valoare mare a pragului detectorului și una sau chiar ambele ținte pot rămâne nedectate, chiar dacă

amplitudinea semnalelor reflectate de cele două ținte au valori suficient de mari.

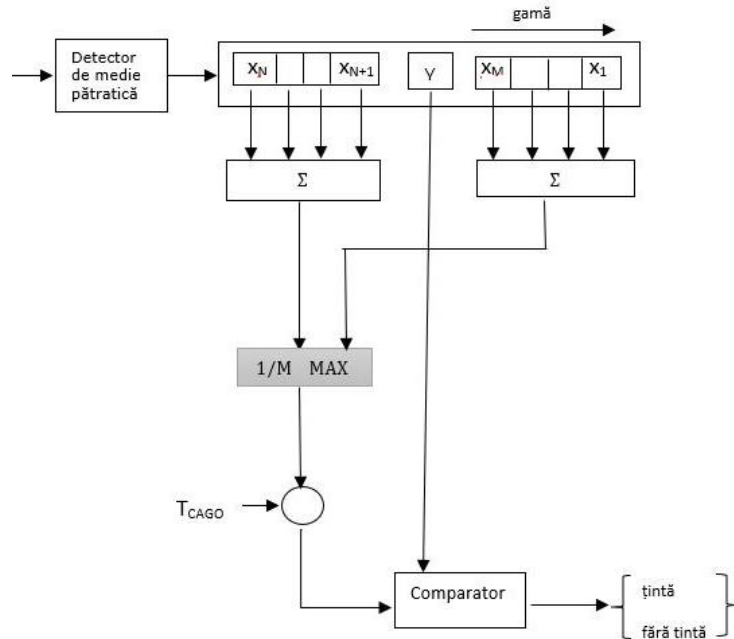


Figura 54. Detectorul CAGO- CFAR.

Structura ferestrei de analiză folosită de detectoarele CA-CFAR și CAGO-CFAR, cu schemele prezentate în figurile 53 și 54, este prezentată în figura 55.




Figura 55. Fereastra de analiză utilizată de detectoarele CA-CFAR și CAGO-CFAR.

Celulele de gardă (vecine celulelor de test), hașurate în figura 55, se ignoră. Acest lucru se practică mai ales în cazul țintelor unice deoarece energia semnalului se va împrăști în celulele adiacente ceea ce poate conduce, în cazul ambelor tipuri de detectoare: CA-CFAR și CAGO-CFAR; la estimare eronată a puterii clutter-ului. Prin modificarea parametrilor N și T poate fi îmbunătățită detectia țintelor din vecinătate.

În cazul în care, în fereastra de referință vor exista două ținte cu valori diferite de amplitudine, ținta cu amplitudine mai mare poate masca ținta cu amplitudine mai mică.

Procedurile de detecție CFAR deja prezentate sunt create în special pentru cazul în care în fereastra de analiză este prezent clutter uniform. Dar procedurile CFAR trebuie să prezinte robustețe și să ofere estimări bune ale clutter-ului în situații variate. Puterea clutter-ului depinde de valoarea parametrilor densității sale de probabilitate. Acești parametri se estimează pe baza valorilor eșantioanelor din fereastra de analiză (referință). Cu ajutorul valorilor acestor eșantioane se construiește histograma semnalului digital achiziționat, care reprezintă o aproximare a densității de probabilitate a acestui semnal. Pe baza histogramei se estimează puterea clutter-ului. În cazul detectorului CA-CFAR, pentru estimarea puterii clutter-ului se calculează momentul de ordinul întâi al histogramei. În cazul detectoarelor CFAR moderne, pentru estimarea puterii clutter-ului se folosesc, pe rând, celule ale ferestrei de referință, care reprezintă grupuri cu același număr de elemente de valori de eșantioane. În cazul detectoarelor CFAR care utilizează filtre cu OS (detectoare OS-CFAR), valorile aflate în celulele care flanchează la stânga și la dreapta celulele de gardă sunt ordonate în funcție de mărime și se selectează câte o caracteristică statistică: media, minimul, maximumul, mediana sau orice altă caracteristică statistică; pentru fiecare celulă. Practica a dovedit că performanțele detectoarelor OS-CFAR sunt superioare performanțelor detectoarelor CA-CFAR sau CAGO-CFAR. În [270] au fost prezentate rezultatele simulării unui detector OS-CFAR. Pentru simulare, s-a utilizat simulatorul Matlab descris în [271]. Acesta simulează un senzor RADAR cu frecvența purtătoare de 24 GHz și cu o bandă de baleiere de 150 MHz, care folosește o formă de undă de tipul Rapid Chirps conținând 256 de semnale chirp. Senzorul RADAR este capabil să estimeze distanțe la țintă de până la 200 m și viteze radiale ale țintelor de până la 250 km/h. Ambele transformate Fourier rapide (Fast Fourier Transforms-FFT) necesare pentru estimarea hărții range-Doppler a scenei "vizualizate" sunt calculate în 2048 de puncte. Valorile extreme ale rapoartelor semnal pe zgomot (Signal to Noise Ratio-SNR) ale semnalelor reflectate de ținte care pot fi simulate sunt: $SNR_{\min} = -25$ dB și $SNR_{\max} = 20$ dB. Valoarea pragului de detecție a fost aleasă empiric de $1,5 \cdot 10^{-3}$. Sunt disponibile trei scenarii de simulare: fără perturbații; cu perturbații de tip zgomot termic (fără clutter) și cu perturbații de tip mixt: zgomot termic și clutter.

Pentru testarea detectorului OS-CFAR, s-a implementat în Matlab următorul algoritm.

1. Generarea țintei: distanța până la senzor, viteza radială a țintei, SNR al semnalului reflectat de țintă;
2. Simularea estimării distanței până la țintă și a vitezei radiale a acesteia efectuate de receptorul RADAR și reprezentarea hărții Range-Doppler corespunzătoare;
3. Calculul pragului de detecție pentru detectorul OS-CFAR: se extrage mediana fiecărei celule de rezoluție și se determină valoarea maximă a acestor mediane;
4. Detecția propriu-zisă: se identifică maximele locale ale hărții Range-Doppler trasate la punctul 2 și se compară valorile lor cu pragul de detecție reținându-se valorile și coordonatele punctelor în care valorile maximelor locale sunt mai mari decât valoarea pragului de detecție. Rezultatele obținute în urma detecției sunt afișate într-o imagine de tipul hartă Range-Doppler, numită răspuns distanță-viteză. Când se detectează cu succes o țintă, i se afișează estimatele distanței până la senzorul RADAR și a vitezei radiale.

În continuare se prezintă câteva rezultate de simulare raportate în [11]. Se consideră cazul unei singure ținte, situată la distanța de 100 m de senzorul RADAR, care se deplasează cu o viteză radială relativă de 30 km/h. Se iau în considerare

diferite valori ale raportului semnal pe zgomot al semnalului reflectat de țintă, mai mici sau egale decât SNR_{min} așa după cum se vede în Tabelul 10. Pentru $SNR \geq -25$ dB atât detectorul propriu simulatorului (a cărui valoare de prag de detecție este aleasă empiric) cât și detectorul OS-CFAR lucrează corect (ambele detectează țintele).

Pentru $SNR = -30$ dB, detectorul propriu simulatorului pierde ținta. Harta Range-Doppler obținută în acest caz este prezentată în figura 56. Pe abscisa imaginii din figura 56 este reprezentată viteza radială a țintei (măsurată în km/h) iar pe ordonata imaginii este reprezentată distanța dintre senzorul RADAR și țintă. Valoarea amplitudinii semnalului reflectat de ținta localizată într-un anumit pixel al imaginii din figura 56 este indicată de "temperatura" culorii aceluia pixel. Culorile calde corespund valorilor mari de amplitudine. Analizând imaginea din figura 56 se constată că cea mai mare amplitudine, corespunzătoare țintei (așa cum este indicat pe figură) corespunde unei distanțe de 100 m și unei viteze radiale de 30 km/h, ceea ce dovedește calitatea estimărilor realizate de către receptorul RADAR considerat. Deoarece valoarea acestei amplitudini este mai mică decât valoarea pragului de detecție al detectorului propriu simulatorului, acest detector nu funcționează corect pentru $SNR = -30$ dB. În cazul detectorului OS-CFAR, valoarea obținută pentru pragul de detecție este de $2.66 \cdot 10^{-4}$. Comparând valoarea maximă de pe harta Range-Doppler (corespunzătoare țintei) cu această valoare se constată că detectorul OS-CFAR funcționează corect în acest experiment.

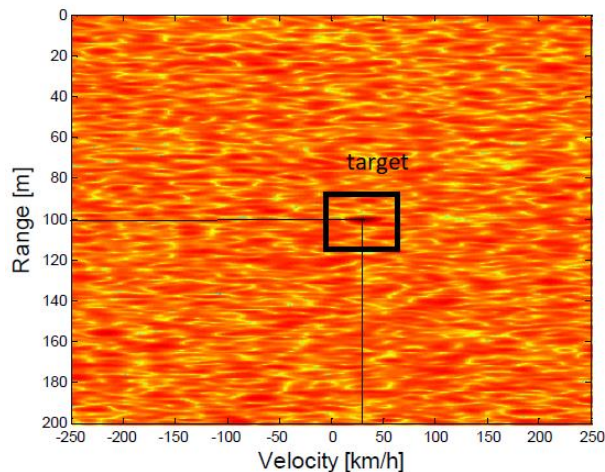


Figura 56. Harta Range-Doppler pentru $SNR = -30$ dB.

În figura 57 este prezentat răspunsul distanță-viteză al detectorului OS-CFAR în cazul acestui experiment. Se constată că a fost detectată o singură țintă, în poziția corectă, ceea ce dovedește corectitudinea funcționării detectorului OS-CFAR în experimentul considerat. Deci, detectorul OS-CFAR are performanțe superioare detectorului propriu simulatorului folosit pentru $SNR = -30$ dB.




Figura 57. Răspunsul distanță-viteză al detectorului OS-CFAR pentru SNR=-30 dB.

Pentru SNR=-35dB, detectorul OS-CFAR pierde ținta. Harta Range-Doppler obținută în cel de al doilea pas al algoritmului pentru acest caz este prezentată în figura 58.




Figura 58. Harta Range-Doppler pentru SNR=-35 dB.

Valoarea pragului de detecție pentru detectorul OS-CFAR obținută în acest caz este de $2.1 \cdot 10^{-4}$. În figura 59 este prezentat răspunsul distanță-viteză al detectorului OS-CFAR obținut în acest caz.




Figura 59. Răspunsul distanță-viteză al detectorului OS-CFAR pentru SNR=-35 dB.

Analizând figura 59 se constată detectia unor ținte false. În consecință, se poate afirma că detectorul OS-CFAR funcționează corect în cazul unei singure ținte dacă raportul semnal pe zgomot al acesteia este mai mare sau egal cu -30 dB.

Tabelul 10. Comparație între funcționările a două tipuri de detector CFAR.

Tip de detector/SNR	-25 dB	- 30 dB
Detector propriu simulatorului	DA	NU
Detector OS-CFAR	DA	DA

3.3.3.6. Îmbunătățirea performanțelor detectoarelor CFAR folosind funcții wavelet

În conformitate cu [270], performanțele detectorului OS-CFAR pot fi îmbunătățite, la rândul lor, cu ajutorul funcțiilor wavelet. În [270] este propus un detector CFAR al cărui algoritm completează algoritmul detectorului OS-CFAR, prezentat în paragraful anterior, cu un pas de denoising realizat cu ajutorul transformării DWT. Vom numi în continuare acest detector Wavelet CFAR - WCFAR. Algoritmul corespunzător are următoarea structură:

1. Generarea țintei: distanța până la senzor, viteza radială a țintei, SNR al semnalului reflectat de țintă;
2. Simularea estimării distanței până la țintă și a vitezei radiale a acesteia efectuate de receptorul RADAR și reprezentarea hărții Range-Doppler corespunzătoare;
3. Prelucrarea imaginii hărții Range-Doppler prin denoising folosind asocierea DWT-filtru Hard-Thresholding:

3-a. Calculul pragului filtrului Hard-Thresholding folosind OS: se extrage mediana din fiecare celulă de rezoluție și se determină maximul acestor mediane;

3-b. Se calculează DWT a imaginii hărții Range-Doppler și se separă coeficienții wavelet de aproximare și de detalii;

3-c. Filtrarea Hard-Thresholding a coeficienților de detalii folosind pragul calculat la pasul 3-a;

3-d. Concatenarea coeficienților de aproximare obținuți la pasul 3-b cu coeficienții de detalii obținuți la pasul 3-c și calculul IDWT. Rezultatul acestui pas reprezintă imaginea hărții Range-Doppler după denoising și se afișează.

4. Calculul pragului de detecție: se determină valoarea maximă a imaginii hărții Range-Doppler după denoising și se împarte această valoare la 1.01.

5. Detecția: se compară valoarea maximă a imaginii hărții Range-Doppler după denoising, determinată la pasul 4 cu pragul de detecție calculat la pasul 4 și se rețin valorile și coordonatele punctelor unde maximele locale ale imaginii hărții Range-Doppler sunt mai mari decât pragul de detecție. Se afișează rezultatele obținute după comparație. De asemenea se afișează și răspunsul distanță-viteză al detectorului W-CFAR. În cazul detecțiilor corecte se afișează distanța până la țintă și viteza radială a țintei.

Pentru a compara performanțele OS-CFAR cu performanțele W-CFAR se prezintă în continuare și alte rezultate de simulare raportate în [270].

Se consideră, la fel ca în paragraful anterior, cazul unei singure ținte, situată la distanța de 100 m de senzorul RADAR, care se deplasează cu o viteză radială relativă de 30 km/h. Se iau în considerare diferite valori ale raportului semnal pe zgomot al semnalului reflectat de țintă, mai mici sau egale decât SNR_{min} așa după cum se vede în Tabelul 11. Testat la $SNR \geq -30$ dB, se constată că detectorul W-CFAR funcționează corect.

Pentru calculul DWT s-a utilizat funcția wavelet mamă de tip Haar.

Pentru $SNR = -35$ dB, în figura 60 este prezentată imaginea obținută în urma prelucrării prin denoising a imaginii din figura 58 folosind pentru filtrul Hard-Thresholding un prag de valoare $2.1 \cdot 10^{-4}$. Comparând imaginile din figurile 58 și 60 poate fi observat efectul prelucrării prin denoising. Majoritatea maximelor locale din imaginea hărții Range-Doppler din figura 58, care corespund perturbației, au fost reduse de denoising (culoarea zonelor respective s-a răcit). Analizând figura 60 poate fi observat că valoarea corespunzătoare țintei este mai mare decât toate valorile înregistrate în celelalte maxime locale. Valoarea obținută pentru pragul detectorului W-CFAR cu ajutorul algoritmului propus este de $4.9 \cdot 10^{-4}$. Rezultatul comparării valorilor imaginii hărții Range-Doppler după denoising din figura 60 cu acest prag de detecție este prezentat în forma unui răspuns distanță-viteză în figura 61. Analizând această figură se constată că detectorul W-CFAR funcționează corect pentru $SNR = -35$ dB. Răspunsul distanță-viteză al detectorului W-CFAR din figura 61 este foarte bun, diferența dintre valoarea corespunzătoare țintei și valorile înconjurătoare fiind mai mare decât 10 dB. Pentru a evidenția precizia sistemului RADAR echipat cu un detector W-CFAR, în figura 62 se prezintă o vedere de sus a răspunsului distanță-viteză din figura 61.

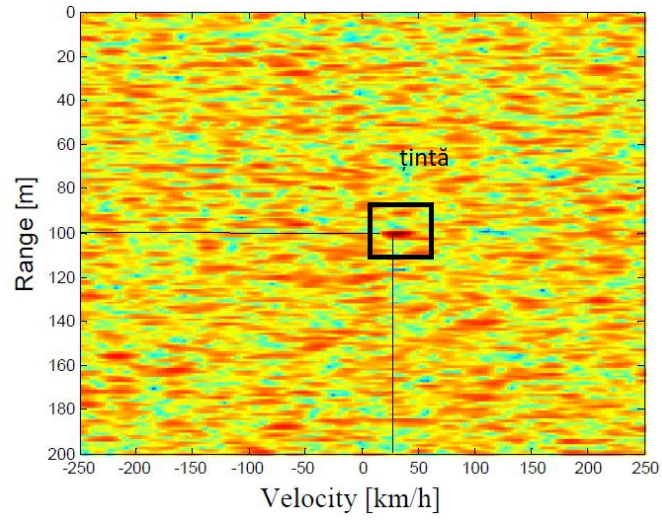


Figura 60. Rezultatul operației de denoising a hărții Range-Doppler pentru SNR=-35 dB.




Figura 61. Răspunsul distanță-viteză al detectorului W-CFAR pentru SNR=-35 dB.




Figura 62. Răspunsul distanță-viteză al detectorului W-CFAR pentru $SNR = -35$ dB, vedere de sus.

Analizând figura 62 se constată că senzorul RADAR considerat, echipat cu detector W-CFAR, estimează precis distanța până la țintă și viteza radială relativă a țintei în ciuda faptului că raportul semnal pe zgomot al țintei este foarte mic.

Comparând imaginea din figura 61 cu imaginea din figura 59 se constată că performanțele de detecție ale detectorului W-CFAR sunt superioare performanțelor detectorului OS-CFAR.

Pentru $SNR = -40$ dB, nici detectorul propriu simulatorului RADAR folosit, nici detectorul OS-CFAR nu funcționează corect. Imaginea hărții Range-Doppler corespunzătoare este prezentată în figura 63.




Figura 63. Harta Range-Doppler pentru $SNR = -40$ dB.

În imaginea din figura 63 se observă mai multe maxime locale cu valori apropiate de valoarea corespunzătoare țintei. Valoarea obținută pe baza OS pentru

pragul filtrului Hard-Thresholding este de $1.99 \cdot 10^{-4}$. Imaginea obținută prin denoising este arătată în figura 64.




Figura 64. Rezultatul operației de denoising a hărții Range-Doppler pentru SNR=-40 dB.

Se observă că valoarea corespunzătoare țintei este mai mare decât valorile celorlalte maxime locale. Valoarea pragului de detecție obținută aplicând algoritmul propus în acest caz este de $2,98 \cdot 10^{-4}$, mai mare decât valorile tuturor celorlalte maxime locale din figura 64. Răspunsul distanță-viteză al detectorului W-CFAR este prezentat în imaginea din figura 65.




Figura 65. Răspunsul distanță-viteză al detectorului W-CFAR pentru SNR=-40 dB, vedere de sus.

În consecință, detectorul W-CFAR funcționează corect și la $SNR = -40$ dB, așa după cum se vede în Tabelul 11.

Tabelul 11. Comparație între funcționările a trei tipuri de detector CFAR.

Tip de detector/SNR	-25 dB	- 30 dB	-35 dB	-40 dB
Detector propriu simulatorului	DA	NU	NU	NU
Detector OS-CFAR	DA	DA	NU	NU
Detector W-CFAR	DA	DA	DA	DA

Algoritmul asociat detectorului W-CFAR prezentat în acest paragraf reprezintă o contribuție a acestei teze de doctorat, a cărei valoare științifică este certificată de publicarea articolului [270].

3.4. Urmărirea țintelor. Asocierea datelor cu țintele

Urmărirea țintelor se efectuează prin colaborarea unui algoritm de asociere a datelor RADAR cu țintele cu un algoritm de urmărire propriu-zisă (de exemplu un filtru Kalman). Scopul asocierii datelor este de a stabili o corespondență între observații (datele furnizate de senzorul RADAR) și țintele existente. Senzorii RADAR estimează în fiecare ciclu de măsurare distanțele până la și vitezele radiale ale unor obiecte detectate, fără a identifica țintele asociate cu aceste obiecte. Identificarea țintelor este una dintre sarcinile algoritmului de urmărire. În faza sa de inițializare, algoritmul de asociere a datelor definește țintele drept clase de obiecte detectate. Apoi, algoritmul de asociere a datelor clasifică obiectele detectate în aceste clase în ciclul curent de măsurare. Pentru fiecare țintă este rulat un algoritm de urmărire propriu-zisă. Algoritmul de urmărire propriu-zisă identifică coordonatele distanță și viteză ale țintei, prezice poziția viitoare a acesteia și îi trasează traiectoria. Această predicție este folosită în iterația următoare a algoritmului de asociere a datelor pentru clasificarea măsurărilor efectuate în următorul ciclu de măsurare al senzorului RADAR. Fiecărei ținte identificate astfel i se aplică iterația următoare a algoritmului de urmărire propriu-zisă. În mod obișnuit, algoritmi de urmărire a țintelor multiple (Multiple Target Tracking-MTT) sunt proiectați pentru scenarii cu mai multe obiecte situate departe de senzor. Un obiect nu este întotdeauna detectat de senzor în astfel de scenarii și dacă este detectat, acesta apare într-o anumită celulă de rezoluție a senzorului.

Există câteva ipoteze specifice pentru modelul matematic al problemelor MTT, a căror rezolvare a evoluat destul de mult în ultimii ani:

- Evoluția obiectelor țintă este independentă;
- Modelul fiecărui obiect este un punct la un moment dat;
- Fiecare obiect produce cel mult o măsurare pe scanare.

Pentru un număr crescut de măsurători, există un număr foarte mare de asocieri date-ținte posibile la un moment de timp dat.

Pentru a găsi asocierea date-ținte corectă, toate aceste asocieri posibile ar trebui să fie verificate. Acest lucru necesită un volum foarte mare de calcul. Pentru a reduce acest volum de calcul, la începutul procedurii de asociere date-ținte se crează o regiune de validare (fereastră) în jurul poziției prezise a țintei considerate, pentru a elimina împerecherile eronate. Datele furnizate de senzorul RADAR observate în interiorul acestei ferestre la momentul de timp considerat (numite în continuare observații) sunt candidați buni pentru asocierea cu ținta considerată. O observație poate fi asociată cu o țintă și utilizată pentru actualizarea filtrului Kalman care estimează traiectoria acelei ținte dacă este singura observație din interiorul ferestrei corespunzătoare și dacă nu se află în interiorul ferestrei oricărei alte ținte. Când o observație se încadrează în ferestrele mai multor ținte sau când mai multe observații se încadrează în fereastra unei ținte într-un mediu dens de ținte, este necesară o logică suplimentară.

Pentru ținte multiple, algoritmi de asociere date-ținte folosiți cel mai frecvent sunt enumerați în continuare:

- Probabilitatea comună (Joint Likelihood-JL): o variantă a algoritmului de separare cu ipoteze multiple a traiectoriilor extinse la traiectorii multiple [272];
- Asocierea de date cu probabilitate comună (Joint probabilistic data association-JPDA): pentru fiecare traiectorie, acest algoritm actualizează filtrele

Kalman pe baza unei probabilități comune de asociere a ultimului set de date generate de senzorul RADAR cu fiecare traiectorie de țintă [273];

- Probabilitatea comună cu ipoteze multiple (Multiple Hypothesis Joint Probabilistic-MHJP): o variantă a filtrului Bayesian optimal care folosește probabilități comune ale unor asocieri cu traiectorii multiple pentru ipoteze multiple [274];

- Abordări cu mulțimi aleatoare finite (Random Finite Sets-RFS): se bazează pe modelarea obiectelor și măsurătorilor ca mulțimi aleatoare.

Inspirată de [275], [276], [277], voi folosi în această lucrare algoritmul maghiar (algoritmul Kuhn–Munkres) [278] pentru asocierea datelor furnizate de senzorul RADAR cu traiectoriile urmărite de filtrele Kalman. Algoritmul maghiar rezolvă problema repartizării personalului într-o firmă. El găsește cea mai bună repartizare a unei mulțimi de persoane pentru o mulțime de sarcini. În cazul urmăririi țintelor RADAR, necesitatea de a asocia poziția unui obiect detectat la traiectoria unei ținte poate fi satisfăcută prin construirea unei matrici de distanțe între estimatele traiectoriilor la momentul de timp considerat și măsurătorile generate de senzorul RADAR la acel moment de timp. Algoritmul maghiar realizează repartizarea optimă a traiectoriilor (liniile matricii) la măsurători (coloanele matricii). Rezultatul este un vector coloană care conține numărul coloanei repartizate (măsurătoare) din fiecare linie (traiectorie). Absența unei măsurători asociate la pasul curent pentru traiectoria respectivă este marcată cu un zero în această matrice.

Pentru urmărirea țintelor RADAR este necesar ca algoritmul de asociere a datelor achiziționate de sistemul RADAR cu țintele să colaboreze cu un algoritm de estimare a traiectoriilor fiecărei ținte. Pentru această sarcină se utilizează de obicei filtre Kalman. Pentru fiecare țintă descoperită de algoritmul de asociere a datelor se utilizează câte un filtru Kalman.

3.4.1. Filtrul Kalman

Urmărirea propriu-zisă a datelor, realizată de obicei cu filtre Kalman, este procesul de estimare a traiectoriei (adică poziția, viteza și, eventual, accelerația) unei ținte din măsurătorile (de exemplu, distanța, viteza radială și elevația) care au fost atribuite acelei ținte. Una dintre aplicațiile filtrului Kalman este urmărirea aeronavelor spațiale în sistemul de navigație Apollo. Filtrarea Kalman este utilizată într-un proces de urmărire pentru a realiza o estimare a stării sistemului la momentul actual t . Această operație se realizează prin combinarea valorilor măsurătorilor la momentul de timp curent t cu predicția stării sistemului realizată la momentul precedent $t-1$. Soluția este calculată recursiv de către filtru. Starea curentă a sistemului la momentul t constă din coordonatele carteziene ale poziției și vitezei:

$$\mathbf{x} = [x \ y \ v_x \ v_y]^T \quad (3.68)$$

unde cu T s-a notat operația de transpunere a matricii. Având în vedere cel mai simplu model pentru mișcarea ținte (viteza constantă), predicția stării la momentul t pe baza stării anterioare poate fi descrisă de formula:

$$\mathbf{x}_t = \mathbf{A}\mathbf{x}_{t-1} + \mathbf{w}_{t-1} \quad (3.69)$$

unde \mathbf{A} este matricea de tranziție a stării și \mathbf{w}_{t-1} este vectorul zgomotului de stare Gaussian cu matrice de valoare medie statistică zero, sau echivalent avem:

$$\begin{bmatrix} x \\ y \\ v_x \\ v_y \end{bmatrix}_t = \begin{bmatrix} 1 & 0 & T & 0 \\ 0 & 1 & 0 & T \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \\ v_x \\ v_y \end{bmatrix}_{t-1} + \begin{bmatrix} 0 \\ 0 \\ w_x \\ w_y \end{bmatrix}_{t-1} \quad (3.70)$$

unde T este perioada de măsurare. Ecuația de măsurare este scrisă ca:

$$\mathbf{z}_t = \mathbf{H} \cdot \mathbf{x}_t + \mathbf{n}_t, \quad (3.71)$$

unde \mathbf{H} este matricea de măsurare și \mathbf{n} este zgomotul de măsurare.

Când sunt estimate doar pozițiile țintei (așa cum vom proceda în cele ce urmează), matricea de măsurare este exprimată ca:

$$\mathbf{H} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix} \quad (3.72)$$

Ecuațiile filtrului Kalman descriu previziunea curentă a stării și estimarea stării, ele fiind următoarele:

$$\begin{aligned} \bar{\mathbf{x}}_t &= \mathbf{A} \cdot \mathbf{x}_{t-1} \\ \bar{\mathbf{P}}_t &= \mathbf{A} \cdot \mathbf{P}_{t-1} \cdot \mathbf{A}^T + \mathbf{E}_x \\ \mathbf{K}_t &= \bar{\mathbf{P}}_t \cdot \mathbf{H}^T \cdot (\mathbf{H} \cdot \bar{\mathbf{P}}_t \cdot \mathbf{H}^T + \mathbf{E}_z)^{-1} \\ \mathbf{x}_t &= \bar{\mathbf{x}}_t + \mathbf{K}_t \cdot (\mathbf{z}_t - \mathbf{H} \cdot \bar{\mathbf{x}}_t) \\ \mathbf{P}_t &= (\mathbf{I} - \mathbf{K}_t \cdot \mathbf{H}) \cdot \bar{\mathbf{P}}_t \end{aligned} \quad (3.73)$$

unde \mathbf{K} este câștigul Kalman, $\bar{\mathbf{P}}$ este predicția matricii de covarianță a erorii și \mathbf{P} este matricea de covarianță a erorii de estimare a stării. Această eroare exprimă rezultatul incertitudinii filtrului Kalman menționat anterior. În formularea tradițională, dinamica și matricile de ieșire sunt considerate atribute ale sistemului. Pentru restul lucrării, matricea de covarianță a zgomotului de măsurare \mathbf{E}_z și estimarea erorii de stare \mathbf{E}_x sunt selectate pe baza a câtorva criterii:

- Valori mici pentru elementele matricii \mathbf{E}_z înseamnă că tindem să ne bazăm mai mult pe măsurătorile zgomotoase decât pe acuratețea modelului;
- Valori mari pentru elementele matricii \mathbf{E}_x înseamnă că nu ne bazăm prea mult pe model.

După cum am prezentat, filtrarea Kalman cooperează cu procedura de asociere a datelor în timpul urmării țintei. La un moment dat, filtrul Kalman, care urmărește o țintă specificată, este informat de algoritmul de asociere a datelor care sunt măsurătorile pe care le poate folosi pentru a prezice următoarea stare a sistemului.

După acest lucru, filtrul Kalman informează algoritmul de asociere a datelor despre noua traiectorie. Apoi, algoritmul de asociere a datelor caută noile măsurători care sunt cele mai potrivite pentru această nouă traiectorie. Prin urmare, colaborarea dintre algoritmul de asociere a datelor și filtrul Kalman este un proces iterativ.

3.4.2. Algoritmul maghiar de asociere a datelor

Problema alocării personalului presupune găsirea celei mai potrivite asocieri a elementelor unei mulțimi de persoane cu elementele unei mulțimi de sarcini, în care asocierile posibile sunt evaluate prin scoruri. Aceasta este o problemă de programare liniară. Ea poate fi considerată ca și un caz degenerat al problemei transportului, fiind privită ca și o alternativă la problema vânzătorului călător (the travelling salesman problem) [278].

Problema alocării simple este ilustrată de următorul exemplu elementar:

Patru indivizi (notați cu $i = 1, 2, 3, 4$) sunt disponibili pentru patru sarcini (notate cu $j = 1, 2, 3, 4$). Ei au următoarele calificări:

$$\text{Individul } \begin{cases} 1 \\ 2 \\ 3 \\ 4 \end{cases} \text{ este calificat pentru sarcina } \begin{cases} 1, 2, 3 \\ 3, 4 \\ 4 \\ 4 \end{cases}$$

Această informație poate fi prezentată efectiv cu ajutorul unei matrici de calificare:

$$Q = \begin{bmatrix} 1 & 1 & 1 & 0 \\ 0 & 0 & 1 & 1 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

În care liniile se referă la indivizi și coloanele se referă la sarcini: un individ calificat este marcat cu un 1 iar un individ necalificat este marcat cu un 0. Atunci, problema alocării simple cere să se determine cel mai mare număr de sarcini care poate fi alocat indivizilor calificați (cu nu mai mult decât o sarcină fiecărui individ). Această cerință poate fi formulată abstract cu ajutorul matricii Q , în următorul mod: Care este numărul maxim de 1 care poate fi ales din Q fără a folosi de două ori aceeași linie sau aceeași coloană?

Putem începe o alocare plasând indivizi nealocați la sarcini nealocate pentru care acești indivizi sunt calificați. Am putea alocă indivizii 1 și 2 pentru sarcinile 3 și 4. Această informație este marcată în matricea de mai jos cu asterix-uri,

$$\begin{bmatrix} 1 & 1 & 1^* & 0 \\ 0 & 0 & 1 & 1^* \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

Deoarece este imposibil să se îmbunătățească această alocare plasând încă un individ nealocat pentru o sarcină încă nealocată pentru care este calificat, se zice că această alocare este completă. Dacă o alocare este completă, este natural să se încerce o îmbunătățire cu ajutorul unui transfer. De exemplu, transferul:

Mută individul 1 de la sarcina 3 la sarcina 1,

Mută individul 2 de la sarcina 4 la sarcina 3,

rezultă în următoarea alocare incompletă:

$$\begin{bmatrix} 1^* & 1 & 1 & 0 \\ 0 & 0 & 1^* & 1 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

Aici putem alocă individul 3 sau individul 4 la sarcina 4 pentru a completa alocarea. Dacă alocăm individul 3 la sarcina 4 se obține:

$$\begin{bmatrix} 1^* & 1 & 1 & 0 \\ 0 & 0 & 1^* & 1 \\ 0 & 0 & 0 & 1^* \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

care reprezintă o alocare optimă. Deci, deși mai există un transfer posibil în această alocare optimă (mutarea individului 1 de la sarcina 1 la sarcina 2) acesta nu îmbunătățește alocarea. Situația prezentată în acest exemplu este generală, se poate obține întotdeauna o alocare optimă printr-o succesiune de transferuri urmată de alocări suplimentare, efectuate până când nici o alocare suplimentară nu mai este posibilă [278].

În cazul general se presupune că n indivizi ($i = 1, \dots, n$) sunt disponibili pentru n sarcini ($j = 1, \dots, n$) și că este dată o matrice de calificare $Q=(q_{i,j})$ unde $q_{i,j}=1$ dacă individul i este calificat pentru sarcina j și $q_{i,j} = 0$ în rest. Dacă o alocare (nu neapărat optimă) a anumitor indivizi calificați pentru anumite sarcini este disponibilă, atunci cea mai ușoară cale de a îmbunătăți alocarea este să se asocieze orice individ încă nealocat la o sarcină nealocată pentru care este calificat acel individ. Dacă această operație este posibilă, atunci acea alocare se zice că este incompletă, altfel ea este completă. Dacă alocarea este completă, atunci este rezonabil să se încerce o îmbunătățire cu ajutorul unui transfer. Un transfer schimbă asocierea a r indivizi distincți, i_1, \dots, i_r folosiți pentru sarcinile j_1, \dots, j_r . El mută individul i_1 la sarcina nealocată încă j_0 și individul i_k la sarcina j_{k-1} pentru $k = 2, \dots, r$. Se presupune că toate noile asocieri (i_k la j_{k-1}) corespund unor indivizi calificați pentru noile sarcini $k = 1, \dots, r$. Este convenabil să numim transfer și lăsarea neschimbată a tuturor asocierilor. Vom denumi fiecare individ deja alocat în urma unui astfel de transfer individ esențial și fiecare sarcină alocată unui individ neesențial sarcină esențială.

Pe baza acestor considerente, în [278] este demonstrat următorul rezultat esențial pentru problema alocării simple.

TEOREMA 1. Pentru o alocare dată, dacă fiecare transfer conduce la o alocare completă, atunci, pentru fiecare individ calificat pentru o sarcină, fie individul fie sarcina este esențial(ă) și este posibil ca atât individul cât și sarcina să fie esențiale.

Acest rezultat este completat în [278] de următorul rezultat esențial pentru problema alocării simple:

TEOREMA 2. Există o alocare care este completă după fiecare transfer posibil.

Problema alocării simple poate fi analizată și dintr-un alt punct de vedere.

Se consideră un buget posibil pentru asocierea unui individ cu o sarcină pentru care este calificat. Un astfel de buget va aloca fie o unitate fie nici o unitate la fiecare individ și la fiecare sarcină. Un buget este considerat adecvat dacă, pentru fiecare individ calificat pentru o sarcină, sau individului sau sarcinii sau amândorura le este alocată o unitate. În legătură cu acest nou punct de vedere, în [278] este prezentat următorul rezultat.

TEOREMA 3. Alocarea totală a oricărui buget adecvat nu este mai mică decât cel mai mare număr de sarcini care pot fi asociate unor indivizi calificați.

Pe baza rezultatelor deja enunțate, în [278] se demonstrează următoarea teoremă.

TEOREMA 4. Există un buget adecvat și o asociere astfel încât alocarea totală a bugetului să fie egală cu numărul de sarcini asociate la indivizi calificați.

Utilizând cele patru teoreme enunțate mai sus se poate formula răspunsul la problema alocării simple: Numărul maxim de sarcini care poate fi alocat unor indivizi calificați este egal cu cea mai mică alocare totală a unui buget adecvat. Orice alocare simplă este optimă dacă și numai dacă ea este completă după fiecare transfer posibil.

Problema alocării simple poate fi generalizată luându-se în considerare și cât de potrivit este un anumit individ pentru o anumită sarcină (pentru care este calificat), obținându-se problema alocării generale. Aceasta are următorul enunț.

Se consideră că n indivizi ($i = 1, \dots, n$) sunt disponibili pentru n sarcini ($j = 1, \dots, n$) și că există o matrice de potrivire $R = (r_{i,j})$ unde $r_{i,j}$ sunt numere întregi pozitive pentru orice i și j . O alocare constă în alegerea unei sarcini j_i pentru fiecare individ i astfel încât nici o sarcină să nu fie asociată cu doi indivizi. Astfel toate sarcinile sunt alocate și o alocare este o permutare

$$\begin{pmatrix} 1 & 2 & \dots & n \\ j_1 & j_2 & \dots & j_n \end{pmatrix}$$

a întregilor $1, 2, \dots, n$. Întrebarea problemei alocării generale este: Pentru care alocare suma potrivirilor $r_{1j_1} + r_{2j_2} + \dots + r_{nj_n}$ ia cea mai mare valoare?

Și în cazul problemei alocării generale pot fi considerate bugete adecvate, adică alocări de valori integrale ne-negative de u_i fiecărui individ și de v_j la fiecare sarcină astfel încât suma alocărilor individului i și sarcinii j să nu fie mai mici decât potrivirea aceluși individ pentru acea sarcină.

În [278] este formulat următorul răspuns la problema alocării generale: „Cea mai mare valoare posibilă a sumei potrivirilor pentru orice alocare este egală cu cea mai mică alocare totală a oricărui buget adecvat. Această valoare poate fi calculată rezolvând o secvență finită de probleme de asociere simplă.”

Algoritmul de rezolvare a problemei de asociere generală se numește metoda maghiară și este prezentat în [278].

În urmărirea țintelor RADAR, necesitatea de a atribui corect poziția unei ținte detectate pe traiectoria corespunzătoare poate fi realizată prin calcularea unei matrici „distanță” între estimările țintei (realizate cu ajutorul filtrului Kalman corespunzător) la momentul actual și măsurători.

Algoritmul maghiar efectuează atribuirea optimă între ținte (linii ale matricii) și măsurători (coloanele matricii). Rezultatul este un vector coloană care conține indicii de coloană (măsurare) atribuite la fiecare linie (țintă). Absența măsurătorilor atribuite la pasul curent pentru ținta respectivă este marcată cu o valoare zero în această matrice.

3.5. Îmbunătățirea performanțelor algoritmilor de urmărire a țintelor

Problema urmăririi țintelor folosind măsurătorile unui senzor RADAR auto presupune integrarea măsurătorilor pe termen lung într-o imagine [271].

O estimare a traiectoriei are întotdeauna o incertitudine asociată, așa cum se poate observa în figura 66. Această incertitudine îngreunează localizarea țintei. Prin urmare, reducerea acestei incertitudini este foarte importantă pentru acuratețea traiectoriei și pentru îmbunătățirea localizării țintei.

Filtrele Kalman sunt utilizate pe scară largă pentru a estima starea unui sistem liniar dinamic din măsurători cu zgomot [271] [276] [279] [280]. În ciuda utilizării îndelungate și a succesului obținut, filtrul Kalman nu este încă complet automatizat, iar utilizatorii filtrului Kalman încă sunt nevoiți să realizeze reglarea manuală a parametrilor săi.

Ca rezultat, există o anumită incertitudine la ieșirea filtrului Kalman. O modalitate de a reduce această incertitudine constă în selectarea adaptivă a parametrilor în timpul procesului de filtrare. În cele ce urmează acest filtru va fi numit filtru Kalman adaptiv.

Mulți cercetători au propus metode pentru reglarea automată a parametrilor filtrului Kalman. Cercetătorii au propus diferite metode de procesare a semnalului pentru a îndeplini acest lucru. De exemplu, au încercat să învețe împreună parametrii și secvența de stare/ieșire.

Astfel au fost propuse strategii diferite, de exemplu: algoritmul de maximizare a așteptărilor sau diferite abordări de optimizare, cum ar fi algoritmul simplex; algoritmul celei mai rapide descreșteri a dispersiei coordonatelor; algoritmi genetici; programare neliniară folosind diferențierea finită pentru a estima gradientul; optimizarea Bayesiană; învățarea prin întărire și reglarea automată a hiper-parametrilor cu minimizarea celor mai mici pătrate ale erorii. În acest subcapitol, ne propunem să utilizăm potrivirea polinomială pentru a reduce incertitudinea sistemului de urmărire. Această abordare pleacă de la presupunerea că aproape toate traiectoriile întâlnite într-un senzor RADAR auto și în problemele de localizare realizată prin sistemul de poziționare globală (GPS - Global Positioning System) sunt polinoame în coordonate carteziane, deoarece traiectoriile drumurilor sunt polinoame, așa cum se poate observa în exemplul din figura 67. În continuare se evidențiază, prin simulări, îmbunătățirea preciziei traiectoriei estimate datorită potrivirii polinomiale în cazul țintelor simple sau multiple și, în plus, sunt propuse trei metode noi de potrivire polinomială pentru traiectoriile estimate de filtrele Kalman [277].




Figura 66. Un exemplu de traiectorie estimată de un sistem de urmărire pe baza unui filtru Kalman.




Figura 67. Drumuri din cartier lângă clădirea facultății noastre.

Primele două metode propuse asigură îndeplinirea condiției ca cele două traiectorii, care corespund celor două axe de coordonate, x și y , obținute la ieșirea filtrului Kalman să aibă o dependență polinomială $y(x)$ prin potrivire polinomială (polynomial fitting) separată pe fiecare axă.

A treia metodă propusă realizează potrivirea polinomială a datelor de la ieșirea filtrului Kalman cu ajutorul funcțiilor wavelet și are doi pași pentru fiecare axă de coordonate: eliminarea zgomotului prin denoising și extragerea părții polinomiale.

Această metodă se compară favorabil cu primele două metode de potrivire polinomială a datelor propuse. Efectul metodelor de post-procesare propuse este vizibil, precizia estimărilor traiectoriei țintelor crescând destul de mult.

3.5.1. Ipoteze folosite

Estimarea traiectoriilor țintelor multiple realizată de către un senzor RADAR auto presupune următoarele operații:

- Măsurarea pozițiilor fiecărei ținte;
- Estimarea distanței, vitezei radiale, unghiurilor de azimut și de elevație, estimarea raportului semnal-zgomot (SNR) și a altor parametri ai fiecărei ținte;
- Detecția țintelor;
- Asocierea datelor (identificarea țintelor din măsurători);
- Filtrarea Kalman a fiecărei traiectorii.

Primele trei operații depind de particularitățile senzorului RADAR și, mai precis, de tipul formei de undă utilizate. Ultimele două operații sunt efectuate împreună deoarece rezultatele intermediare ale uneia dintre metode servesc ca inițializări pentru iterațiile celeilalte metode și reciproc. În continuare se vor folosi algoritmul maghiar (Kuhn – Munkres) pentru asocierea datelor și filtrul Kalman pentru urmărirea mai multor ținte RADAR.

3.5.2. Reducerea incertitudinii la ieșirea filtrului Kalman

În ciuda utilizării frecvente și a succesului larg obținut până în prezent, practicienii care utilizează filtrul Kalman trebuie să recurgă la reglarea manuală a parametrilor săi [279]. Ca urmare a prezenței zgomotului, a posibilelor date lipsă și a imperfecțiunilor modelelor, la ieșirea filtrului Kalman apare o anumită incertitudine. Această incertitudine poate fi redusă prin transformarea filtrului Kalman într-un filtru adaptiv sau prin postprocesare. O abordare oarbă de post-procesare este mai rapidă decât abordările adaptive deoarece nu este iterativă și este mai robustă. Abordarea de față a fost propusă în [281] și dezvoltată în [277]. Această metodă presupune potrivirea polinomială a datelor obținute la ieșirea filtrului Kalman.

3.5.2.1. Potrivire polinomială

Semnificația potrivirii datelor este găsirea unei descrieri matematice pentru date. Această descriere matematică ar trebui să fie cât mai precisă.

O măsură pentru abaterea modelului de la datele măsurate, frecvent utilizată în practică, este eroarea medie pătratică (RMSE- Root Mean Squared Error). Deci, potrivire înseamnă a găsi un minim al RMSE.

Pentru a realiza acest lucru, o funcție de ajustare f , care conține în general parametri reglabili, a_i , $i = 0 \dots n$,

$$y_t \approx f(a_0, \dots, a_n, x_t) \quad (3.74)$$

trebuie definită.

Să luăm în considerare cazul simplu al unui set de date y_t , $t=1, \dots, M$, care sunt colectate ca o funcție de variabila independentă x în punctele x_t . Am dori ca

funcția de potrivire f să descrie aceste date într-un mod aproximativ ca: $y_t \approx f(a_0, \dots, a_n, x_t)$.

Pentru a găsi parametrii a_i pentru cea mai bună aproximare, eroarea medie pătratică r trebuie redusă la minimum:

$$r = \sum_t (y_t - f(a_0, \dots, a_n, x_t))^2 \quad (3.75)$$

Forțând derivatele lui r în raport cu parametrii a_i să fie zero, putem găsi minimul RMSE. Prin urmare, potrivirea datelor este o problemă de optimizare convexă. Potrivirea polinomială presupune utilizarea celui mai simplu tip de funcții de potrivire: polinoame,

$$\frac{\partial r}{\partial a_0} = 0, \frac{\partial r}{\partial a_1} = 0, \dots, \frac{\partial r}{\partial a_n} = 0 \quad (3.76)$$

$$f(a_0, \dots, a_n, x_t) = a_0 + a_1 x_t + \dots + a_n x_t^n \quad (3.77)$$

În cazul potrivirii polinomiale, relația (3.76) reprezintă un sistem de $n+1$ ecuații liniare cu $n+1$ necunoscute, a_i . Sistemul poate fi rezolvat prin metode standard pentru ecuații liniare. În general, nu sunt necesare proceduri de optimizare deoarece sistemul de ecuații are o soluție unică.

Dezavantajul acestei metode de potrivire a datelor este necesitatea de a cunoaște a priori gradul polinomului $f(a_0, \dots, a_n, x_t)$, n .

În cazul datelor de la ieșirea filtrului Kalman avem două secvențe de coordonate: $\{x_t\}$ și $\{y_t\}$ (așa cum se poate observa în ecuațiile (3.68) sau (3.70)), care reprezintă coordonatele orizontală și verticală ale poziției unei ținte la momentul t în sistemul de referință unde este reprezentată traiectoria țintei respective.

Pentru a realiza potrivirea polinomială a acestor date, putem proceda în doi pași: în primul rând, aplicăm procedura de potrivire polinomială a datelor $\{x_t\}$ și, în continuare, aplicăm procedura de potrivire polinomială a datelor $\{y_t\}$, deoarece prin compunerea a două funcții polinomiale se obține o altă funcție polinomială. Această metodă va fi denumită în continuare metoda de potrivire polinomială implicită. Rezultatul este polinomial, dar cronologia nu este neapărat păstrată. Un alt dezavantaj al metodei de potrivire polinomială implicită este posibila pierdere a extremelor uneia sau ambelor secvențe de date $\{x_t\}$ și / sau $\{y_t\}$ ca o consecință a efectului de netezire a metodei de potrivire polinomială aplicată pe fiecare axă. Acest dezavantaj poate fi contracarat prin aplicarea unei metode de potrivire polinomială explicită. Această metodă de potrivire polinomială are următorii pași:

- Potrivirea polinomială a secvenței $\{x_t\}$: $x=P(t)$;
- Inversarea rezultatului obținut: $t=P^{-1}(x)$;
- Potrivirea polinomială a secvenței $\{y_t\}$: $y=Q(t)$;
- Înlocuirea rezultatului celui de-al doilea pas în rezultatul celui de-al treilea pas: $y=Q(P^{-1}(x))$.

Pentru aplicarea metodei de potrivire polinomială explicită a datelor de la ieșirea filtrelor Kalman trebuie luate unele măsuri de precauție cu privire la monotonia funcțiilor P și Q pentru a obține un rezultat corect deoarece polinoamele sunt funcții inversabile numai pe intervale.

Un dezavantaj al celor două metode de potrivire polinomială propuse este complexitatea ridicată de calcul necesară în cazul unor grade mari de polinom. Când n are o valoare mare, procedura de rezolvare a sistemului din relația (3.76) implică o complexitate de calcul ridicată.

În continuare se prezintă simulările celor două metode de reducere a incertitudinii de la ieșirile filtrelor Kalman bazate pe potrivirea polinomială, raportate în [275], [277] și [281]. Se disting două cazuri de simulare: cu o singură țintă și cu mai multe ținte. În [281] se prezintă aplicarea celor două metode de potrivire polinomială pe date reale. Este vorba despre un experiment care se referă la deplasarea unui automobil fără șofer. Există două tipuri de date: video-generate de două camere de luat vederi și RADAR-generate de senzori RADAR. În figura 68 sunt prezentate câteva cadre extrase din datele video.




Figura 68. Câteva cadre extrase din înregistrările video (mulțumiri Hella Timișoara).

Aceste înregistrări video sunt acompaniate de date achiziționate de doi senzori RADAR având frecvența purtătoare de 24 GHz, cu un ciclu de măsurare de 50 ms și o distanță maximă până la care pot fi detectate ținte de 105 m, construiți la Hella Timisoara. Luând în considerare faptul că fiecare senzor generează 336 de semnale diferite, s-a folosit un parser, care a extras semnalele necesare pentru caracterizarea mișcării automobilului din figura 68. Printre aceste semnale există semnale necesare pentru realizarea urmăririi: momentele de declanșare ale ciclurilor de măsurare, estimările distanțelor până la ținte, estimările vitezelor radiale ale țintelor și estimările unghiurilor dintre direcțiile senzorului și țintei. Au fost aplicate câteva metode de prelucrarea semnalelor ca: separarea țintelor în mișcare de clutter, conversia din coordonate polare în coordonate carteziene sau asocierea de date pe criterii geometrice. Apoi am aplicat filtre Kalman datelor primite de la ambii senzori RADAR și am fuzionat rezultatele acestor filtre, rezultând datele reprezentate cu albastru în figura 69.




Figura 69. Scăderea incertitudinii de la ieșirea filtrelor Kalman prin potrivire polinomială implicită.

Zona de jos a imaginii din figura 69, marcată cu galben, conține poziții ale țintelor în care nu se poate avea încredere, deoarece se află față de senzorii RADAR la o distanță mai mare decât distanța maximă la care se poate realiza o detecție corectă. Zona din mijloc, marcată cu portocaliu, corespunde cadrelor înregistrărilor video din panelurile a) și b) ale figurii 68, care preced pornirea automobilului țintă. Zona de sus, marcată cu albastru, corespunde cadrelor înregistrărilor video din panelurile e) și f) ale figurii 68, care înfățișează manevra de oprire a automobilului. Deci automobilul pornește de la o distanță de aproximativ 85 m, se deplasează pe o traiectorie liniară și se oprește lângă automobilul staționar care poartă senzorii RADAR și camerele de luat vederi. Împrăștierea punctelor albastre ilustrează incertitudinea datelor de la ieșirile filtrelor Kalman. Pentru a reduce această incertitudine, am aplicat metoda de potrivire polinomială implicită, propusă în acest paragraf, impunând gradul întâi polinoamelor P și Q, și am obținut traiectoria reprezentată cu verde în figura 69. Se constată că nedeterminarea de la ieșirile filtrelor Kalman a fost complet eliminată pentru pozițiile țintei situate la distanțe mai mici decât 50 m față de senzorii RADAR.

În continuare se prezintă simulările metodei de potrivire polinomială raportate în [277] și [281]. De această dată nu mai lucrăm cu date reale ci vom folosi date simulate pentru ținte multiple. Evaluăm acuratețea metodelor propuse prin compararea traiectoriilor generate de simulare (date de intrare) cu traiectoriile estimate prin colaborarea algoritmului maghiar de asociere a datelor cu algoritmul de filtrare Kalman urmată de potrivirea polinomială explicită a datelor de la ieșirile filtrelor Kalman (date de ieșire). Am conceput trei scenarii de simulare. Pentru simularea țintelor, se generează două traiectorii polinomiale $x [t]$ și $y [t]$, una pentru fiecare coordonată geometrică, definind punctele inițiale și considerând


că mișcarea țintelor pe fiecare coordonată geometrică este uniformă cu o viteză definită. Profilele de viteză sunt generate de asemenea pentru fiecare coordonată geometrică $v_x[t]$ și $v_y[t]$. Am înregistrat expresiile analitice ale traiectoriilor și vitezei pentru fiecare coordonată geometrică obținută pentru evaluarea ulterioară a calității reducerii incertitudinii realizată prin metoda de potrivire polinomială explicită.

Pentru a simula incertitudinea măsurărilor, la fiecare semnal: $x[t]$, $y[t]$, $v_x[t]$ și $v_y[t]$, a fost adunat un zgomot alb Gaussian (Additive White Gaussian Noise- AWGN) obținându-se semnalele $x_p[t]$, $y_p[t]$, $v_{(x_p)}[t]$ și $v_{(y_p)}[t]$, $p=1,2,3$, cu un raport semnal/zgomot de 0 dB.

După generarea traiectoriilor pentru fiecare scenariu, am generat și țintele, inserând „dectării” în fiecare punct al fiecărei traiectorii.

În cele din urmă, am generat datele de intrare pentru fiecare experiment, combinând parametrii celor trei ținte: traiectorii și profiluri de viteză $x_p[t]$, $y_p[t]$, $v_{(x_p)}[t]$ și $v_{(y_p)}[t]$, $p=1,2,3$. Al doilea pas al experimentelor realizate cu date simulate constă în simularea urmăririi, bazată pe cooperarea algoritmului maghiar cu algoritmul filtrului Kalman pentru fiecare țintă. Etapa finală a fiecărui experiment constă în aplicarea metodei de potrivire polinomială explicită pentru reducerea incertitudinii la ieșirea sistemului de urmărire.

În primul scenariu (figura 70), se observă două ținte din care prima se deplasează orizontal de la stânga spre dreapta iar a doua țintă se deplasează vertical de jos în sus. Coordonatele inițiale ale țintelor sunt: pentru prima țintă: $x=-80$ m, $y=-70$ m, iar pentru a doua țintă: $x=0$ m, $y=-140$ m. Măsurătorile corespunzătoare celor două ținte sunt prezentate în figura 70a). Traiectoriile celor două ținte generate de filtrele Kalman asociate cu fiecare țintă pot fi văzute în figura 70b). După aplicarea procedurii de potrivire polinomială explicită se obțin traiectoriile reprezentate împreună în figura 70c) și separat în figura 70d).



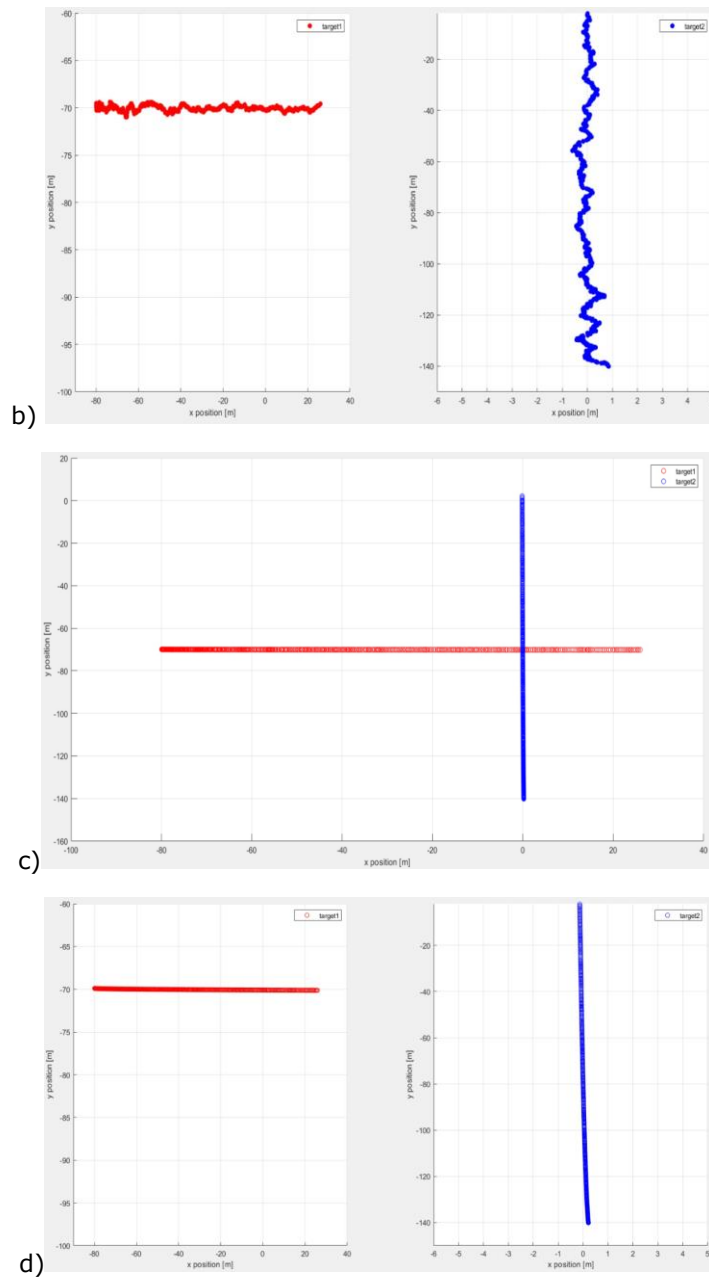




Figura 70. Rezultate parțiale și finale ale primului experiment cu date simulate, a) răspândirea spațială a țintelor; b) efectul colaborării dintre algoritmul maghiar și filtrul Kalman; c, d) efectul metodei de potrivire polinomială explicită.

Trajectoriile estimate sunt identice cu traiectoriile inițiale. În cel de al doilea scenariu (figura 71), se observă trei ținte din care prima se deplasează orizontal de la

3.5 – Îmbunătățirea performanțelor algoritmilor de urmărire a țintelor 171

stânga spre dreapta, a doua se deplasează vertical de jos în sus iar a treia țintă se deplasează oblic de jos în sus. De data aceasta, coordonatele inițiale ale țintelor sunt: pentru prima țintă: $x=-90$ m, $y=-75$ m, pentru a doua țintă: $x=0$ m, $y=-140$ m, iar pentru a treia țintă: $x=-65$ m, $y=-130$ m. Măsurătorile corespunzătoare celor trei ținte sunt prezentate în figura 71a).

După aplicarea filtrării Kalman pentru fiecare țintă s-au obținut traiectoriile din figura 71b). După aplicarea procedurii de potrivire polinomială explicită se obțin traiectoriile reprezentate împreună în figura 71c) și separat în figura 71d).



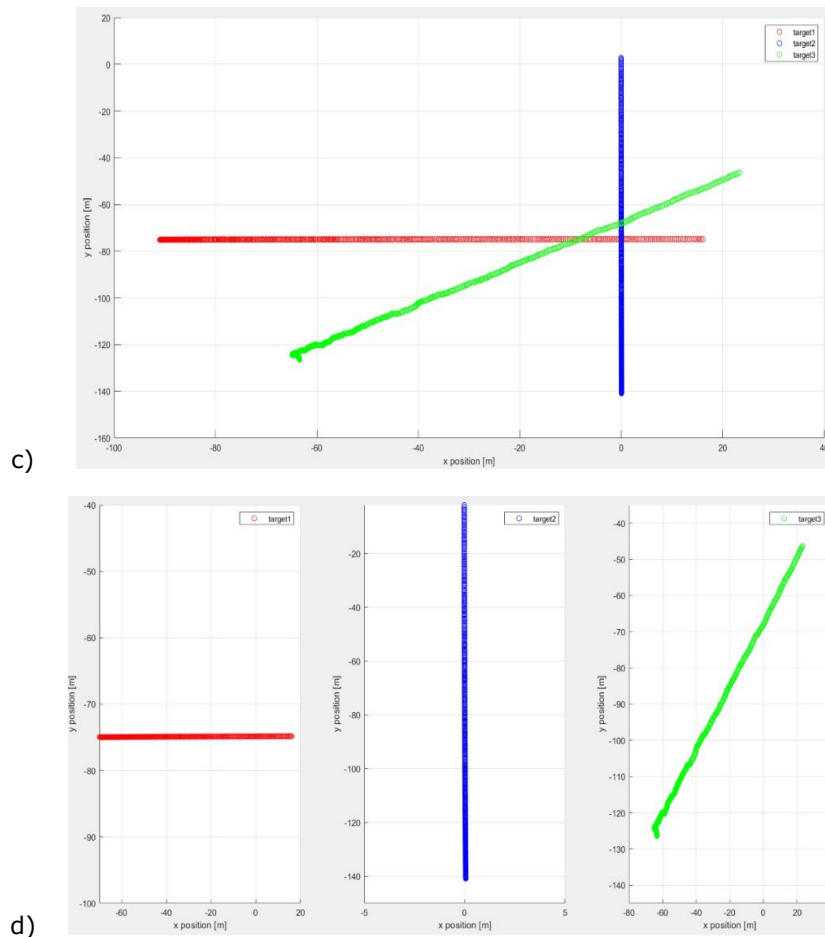





Figura 71. Rezultate parțiale și finale ale celui de al doilea experiment cu date simulate: a) răspândirea spațială a țintelor; b) efectul filtrării Kalman; c), d) efectul metodei de potrivire polinomială explicită.

În al treilea scenariu (figura 72), se observă patru ținte din care prima țintă se deplasează orizontal de la stânga spre dreapta, a doua țintă se deplasează vertical de jos în sus, a treia țintă se deplasează oblic de jos în sus, iar a patra țintă se deplasează oblic de jos în sus.

Coordonatele inițiale ale celor patru ținte sunt: pentru prima țintă: $x=-80$ m, $y=-70$ m, pentru a doua țintă: $x=0$ m, $y=-140$ m, pentru a treia țintă: $x=-65$ m, $y=-130$ m, iar pentru a patra țintă: $x=-65$ m, $y=-130$ m.

Măsurătorile corespunzătoare celor patru ținte sunt prezentate în Figura 72a). După aplicarea colaborării dintre algoritmul maghiar și patru filtre Kalman s-au obținut traiectoriile din figura 72b). Așa după cum se poate observa, aceste traiectorii nu sunt perfect rectilinii. După aplicarea procedurii explicite de potrivire polinomială, se obțin traiectoriile reprezentate împreună în figura 72c) și separat în figura 72d).

3.5 – Îmbunătățirea performanțelor algoritmilor de urmărire a țintelor 173






Figura 72. Rezultate parțiale și finale ale celui de al treilea experiment cu date simulate: a) răspândirea spațială a țintelor; b) efectul filtrării Kalman; c), d) efectul metodei de potrivire polinomială explicită.

Aceste trei experimente demonstrează că procedura de potrivire polinomială explicită este eficientă în cazul traiectoriilor polinomiale de ordinul întâi. Am comparat părțile utile ale traiectoriilor generate de simulare (primul experiment are două traiectorii, al doilea experiment conține trei traiectorii iar al treilea experiment conține patru traiectorii) cu traiectoriile corespunzătoare obținute după aplicarea procedurii de potrivire polinomială explicită propusă și am remarcat că acele traiectorii sunt identice. Prin urmare, în cazul traiectoriilor liniare, procedura de potrivire polinomială explicită poate elimina întreaga incertitudine produsă la ieșirile filtrelor Kalman. **Metodele de reducere a incertitudinii de la ieșirile filtrelor Kalman bazate pe potrivirea polinomială implicită și explicită reprezintă două contribuții ale acestei teze și au fost validate științific prin publicarea articolelor [275], [277] și [281].**

Procedura de rezolvare a sistemului de ecuații (3.76) poate fi evitată prin extragerea directă a părților polinomiale ale secvențelor $\{x_t\}$ și $\{y_t\}$. Extracția directă a părții polinomiale a unui semnal poate fi efectuată în domeniul wavelet.

3.5.2.2. Potrivirea polinomială bazată pe funcții wavelet

Funcțiile wavelet sunt definite pornind de la o analiză ortogonală multirezoluție. Adaptarea rezoluției semnalului permite extragerea detaliilor relevante pentru o anumită sarcină și prelucrarea lor separată. De exemplu, în viziunea computerizată este posibil să se proceseze mai întâi o imagine cu rezoluție mică și apoi să se mărească selectiv rezoluția atunci când este necesar.

Una dintre cele mai interesante proprietăți ale unei funcții wavelet mamă (MW), care îi caracterizează regularitatea, este numărul său de momente nule (Vanishing Moments-VM). Conexiunea dintre teoria funcțiilor wavelet și polinoame este dată de următoarea remarcă: o funcție MW cu r VM este ortogonală pe polinoamele de grad $r-1$ [13]. Reprezentarea polinoamelor în serie de funcții wavelet este redusă (doar primii r termeni ai acestei descompuneri sunt diferiți de zero dacă

se utilizează pentru descompunere o funcție MW cu r VM). Extracția părții polinomiale a unui semnal bazată pe funcții wavelet constă în calculul transformării sale wavelet discrete (DWT), în separarea coeficienților de aproximare și a coeficienților de detalii urmate de reținerea doar a coeficienților de aproximare. Apoi, se calculează transformarea wavelet discretă inversă (Inverse DWT-IDWT).

Deoarece secvențele $\{x_t\}$ și $\{y_t\}$ de la ieșirea filtrului Kalman sunt afectate de incertitudinea deja menționată, modelul matematic al acestor secvențe este o sumă a părții polinomiale a secvenței și a unui zgomot. Din acest motiv, se recomandă aplicarea unei proceduri de eliminare a zgomotului înainte de extragerea părții polinomiale. În cazul metodei de potrivire polinomială bazată pe funcții wavelet propusă în [281] și dezvoltată în [277] se folosește metoda de denoising a lui Donoho [56]. Aceasta este compusă din trei pași:

- Calculul DWT și separarea coeficienților de detalii;
- Filtrarea neliniară a coeficienților de detalii folosind (de exemplu) filtrul hard thresholding;
- Concatenarea secvenței coeficienților de aproximare, extrasă în primul pas, cu noua secvență de coeficienți de detalii obținută după al doilea pas și calculul IDWT.

Metoda de potrivire polinomială propusă are următorii pași:

- Se aplică procedura de denoising secvențelor $\{x_t\}$ și $\{y_t\}$ de la ieșirea fiecărui filtru Kalman (pentru calculul DWT al secvenței $\{x_t\}$ se recomandă o funcție MW cu 2 VM iar pentru calculul DWT al secvenței $\{y_t\}$ se recomandă o funcție MW cu maximum 4 VM).
- Se extrage partea polinomială a fiecărui rezultat de denoising.
- La fel ca în cazul metodei de potrivire polinomială implicită, se reprezintă rezultatul obținut pentru axa ordonatelor în funcție de rezultatul obținut pentru axa absciselor.

Ca și în cazul metodelor de potrivire polinomială prezentate în paragraful anterior, principalul inconvenient al metodei de potrivire polinomială bazată pe funcții wavelet este necesitatea de a cunoaște a priori gradul polinomului de potrivire, $r-1$, pentru a deduce regularitatea funcției MW care trebuie utilizată pentru extragerea părții polinomiale.

Acest inconvenient ar putea fi eliminat folosind aproximări polinomiale locale (LPA-Local Polynomial Approximations) [282].

Se poate folosi o abordare nouă pentru a rezolva o problemă de selecție a dimensiunii ferestrei de analiză pentru filtrarea unui semnal de imagine perturbat de un zgomot. Abordarea se bazează pe regula de intersecție a intervalelor de încredere (Intersection of Confidence Intervals-ICI) și oferă un algoritm simplu de implementat și aproape optim din punct de vedere al minimizării erorii medii pătratice de aproximare. LPA este utilizată pentru a obține transformate 2D adaptive ale imaginii cu proprietăți reproductive prescrise în ceea ce privește componentele polinomiale (netede) ale semnalelor, fiind un instrument puternic în procesarea semnalului și a imaginii. Aceasta a fost utilizată într-o serie de aplicații legate de procesarea imaginilor, cum ar fi denoising, reconstrucția imaginii, interpolarea matricii de filtre de culori etc. LPA se bazează pe estimarea neparametrică a semnalului. Semnalul poate fi reprezentat ca o combinație liniară de polinoame centrate pe coordonatele de observație. Inițial, LPA a fost propusă și dezvoltată în metode statistice pentru procesarea datelor multidimensionale zgomotoase. Este o tehnică puternică care oferă estimări polinomiale locale de eroare medie pătratică minimă într-o fereastră glisantă.

Selecția optimă a dimensiunii ferestrei a fost studiată cu atenție de mulți autori. Aceste metode optime de alegere a dimensiunii ferestrei bazate pe date, prezintă un interes special pentru problemele în care aproximările polinomiale pe porțiuni sunt cele mai naturale și relevante. Se poate remarca faptul că problema selecției optime a dimensiunii ferestrei admite o formulare matematică precisă în ceea ce privește abordarea neparametrică, unde dimensiunea optimă a ferestrei este definită de un compromis între abaterea și varianța estimării.

Se prezintă în continuare rezultatele de simulare a metodei de reducere a incertitudinii de la ieșirile filtrelor Kalman prin potrivire polinomială bazată pe funcții wavelet raportate în [275] și [281]. Majoritatea scenariilor de simulare sunt identice cu cele folosite pentru evaluarea performanțelor metodelor de potrivire polinomială implicită și explicită.

În cazul experimentului descris în figurile 68 și 69, e vorba despre o singură țintă și se folosesc date reale, după realizarea colaborării dintre algoritmul maghiar de asociere a datelor și algoritmul de filtrare Kalman se aplică metoda de potrivire polinomială bazată pe funcții wavelet. S-a considerat că polinoamele obținute pentru cele două axe de coordonate sunt de gradul întâi. De aceea pentru calculul DWT s-a folosit o funcție MW cu două momente nule. S-a obținut traiectoria reprezentată cu roșu în figura 69. Se observă că aceasta reduce incertitudinea de la ieșirea filtrului Kalman pe întregul parcurs al automobilului studiat începând din zona portocalie (de unde pornește automobilul) și terminând în zona albastră (unde se oprește automobilul). În consecință metoda de potrivire polinomială bazată pe funcții wavelet este mai bună decât metoda de potrivire polinomială implicită (traiectoria corespunzătoare este marcată cu verde în figura 69) care nu face reducerea incertitudinii pe întregul parcurs al automobilului.

În [281] este prezentat un experiment în care este urmărită o țintă simulată, care se deplasează pe o traiectorie neliniară. Rezultatul acestui experiment este prezentat în figura 73. Pentru înlăturarea zgomotului și pentru extragerea părții polinomiale a secvenței $\{x_t\}$ s-a folosit o funcție MW cu două VM (s-a presupus că polinomul corespunzător este de gradul întâi) iar pentru înlăturarea zgomotului și extragerea părții polinomiale a secvenței $\{y_t\}$ s-a folosit o funcție MW cu patru VM (gradul polinomului corespunzător fiind 3). În figura 73a) se prezintă traiectoria dorită a țintei, s-a generat un polinom $\{y_t\}$ de gradul 3. Cele două componente ale acestui polinom, $\{x_t\}$ și $\{y_t\}$ au fost adunate cu semnale aleatoare de tipul AWGN simulându-se datele achiziționate de senzorul RADAR. Acestor date li s-a aplicat colaborarea dintre algoritmul maghiar de asociere a datelor și algoritmul de filtrare Kalman și compunând aceste două rezultate s-a obținut traiectoria din figura 73b). Aplicând potrivirea polinomială bazată pe funcții wavelet a rezultat traiectoria finală din figura 73c), care se observă că este foarte asemănătoare cu traiectoria inițială din figura 73a). În consecință, metoda de potrivire polinomială bazată pe funcții wavelet funcționează foarte bine și în acest exemplu.




Figura 73. Rezultate parțiale și finale ale unui experiment cu date simulate: a) traiectoria dorită a țintei; b) traiectoria țintei obținută la ieșirea filtrului Kalman; c) efectul metodei de potrivire polinomială bazată pe funcții wavelet.

Metoda de reducere a incertitudinii de la ieșirile filtrelor Kalman cu ajutorul potrivirii polinomiale bazate pe funcții wavelet reprezintă o contribuție a acestei teze și a fost validată științific prin publicarea articolelor [277] și [281].

Capitolul 4

CONCLUZII, CONTRIBUȚII ORIGINALE ȘI PERSPECTIVE

Aplicațiile DM în telecomunicații reprezintă un subiect vast. Tratarea sa exhaustivă depășește cu mult cadrul unei teze de doctorat. De aceea, în lucrarea de față au fost considerate doar câteva soluții constructive ale unor blocuri funcționale ale arhitecturii standard a unui sistem de DM (prezentată în figura 1 din capitolul 1). S-au considerat doar soluții bazate pe funcții wavelet și doar două aplicații posibile din domeniul telecomunicațiilor. Prima aplicație se referă la supravegherea unor regiuni de pe glob și la studiul unor fenomene care se desfășoară la scară planetară prin analiza fluxurilor de imagini SAR prelevate de sateliți. Cea de a doua aplicație se referă la acordarea de asistență șoferilor de autovehicule prin prelucrarea semnalelor generate de senzorii RADAR în cadrul unui sistem ADAS.

În cazul aplicației DM dedicate supravegherii unor regiuni de pe glob și studiului unor fenomene care se desfășoară la scară planetară este vorba despre tema contractului cu Agenția Spațială Europeană (European Space Agency-ESA) intitulat SY4SCI SYNERGY STUDY: OCEAN VIRTUAL LABORATORY [283]. Scopul proiectului a fost să permită experților în oceanografie să descopere existența și apoi să exploateze în comun, într-un mod convenabil, flexibil și intuitiv, din diferite puncte de vedere, diferitele baze de date de observare a unor regiuni de interes ale Pământului. În acest scop au fost folosite date provenite de la diferite familii de sateliți, printre care și imaginile SAR achiziționate de sateliții Sentinel-1.

Pentru exemplificarea funcționării aplicației care a constituit rezultatul acestui proiect, denumită Laborator Oceanic Virtual (Ocean Virtual Laboratory-OVL), a fost aleasă regiunea oceanică de la estul și sudul Africii de Sud prezentată în figura 75 (marcată cu nuanțe de brun și gri), iar ca exemplu de fenomen care se desfășoară la scară planetară a fost ales curentul Agulash ale cărui fronturi de undă sunt de asemenea prezentate în aceeași figură (marcate prin curbe albe). Pentru o mai bună observare a acestor fronturi de undă, în figura 76 se prezintă o regiune din figura 75 mărită.




Figura 74. O imagine a interfeței grafice a aplicației OVL [283].

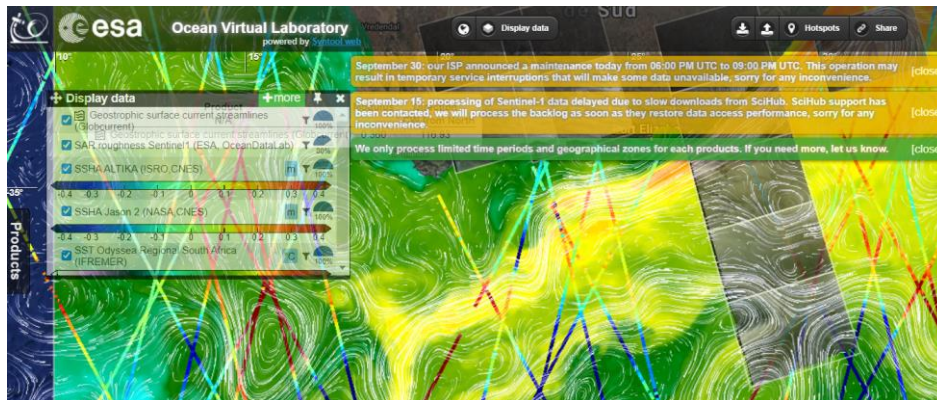


Figura 75. O reprezentare detaliată a unei regiuni din imaginea interfeței grafice a aplicației OVL. Fronturile de undă ale curentului Agulash sunt reprezentate prin curbe de culoare albă.

În legenda din colțul din stânga sus al figurii 75 sunt prezentate bazele de date din care au fost extrase datele folosite pentru supravegherea curentului Agulash din acest exemplu. Pe prima linie a legendei sunt evidențiate fronturile de undă care reprezintă rezultatul analizei. Pe cea de a doua linie a legendei sunt menționate imaginile SAR care sunt reprezentate cu mai multe niveluri de gri. Pe ultimele trei linii ale legendei sunt specificate cele trei categorii de date altimetrice (Sea Surface Height-SSH): ALTIKA, JASON și respectiv ODYSSEA, care au fost folosite. Cu ajutorul altimetrelor montate pe sateliți se măsoară înălțimea valurilor din zonele de acoperire ale altimetrelor. Regiunile din care au fost colectate aceste date sunt reprezentate în figura 75 cu linii drepte multicolore. Aplicația OVL funcționează pe baza fuziunii dintre datele altimetrice și datele SAR. Se calculează gradientul dintre date SSH achiziționate la același moment de timp în puncte vecine

geografic, obținându-se direcția curentă a frontului de undă al curentului Agulash din vecinătatea respectivă. Întrucât, așa după cum se vede în figură, densitatea punctelor în care se fac înregistrări altimetrice este scăzută, pentru completarea traiectoriilor fronturilor de undă se folosește interpolarea. Cunoscut fiind faptul că erorile de interpolare cresc cu scăderea frecvenței de eșantionare, rezultă că e necesar ca traiectoriile prezise pe baza măsurării înălțimii valurilor să fie corectate din când în când. În acest scop se folosesc imaginile SAR.

Deși nu mai este la „modă”, având o istorie „contemporană” de peste 30 de ani, teoria funcțiilor wavelet continuă să ofere soluții originale și eficiente problemelor actuale de prelucrarea datelor, cum ar fi, de exemplu, problema creșterii exponențiale a volumului de date (big data). Această performanță este datorată proprietăților remarcabile ale funcțiilor wavelet. O parte dintre aceste proprietăți sunt utile în cazul semnalelor deterministe: buna localizare în spațiul timp-frecvență, economicitatea (sparsity) reprezentării pentru majoritatea tipurilor de date, posibilitatea implementării analizelor multirezoluție, caracterul multi-scară al reprezentării, adecvarea la modelarea sistemului vizual uman și a sistemului auditiv periferic uman, ș.a.m.d. Alte proprietăți ale funcțiilor wavelet sunt utile în cazul semnalelor aleatoare: decorelarea semnalelor de tip zgomot colorat, necorelarea semnalelor de tip zgomot alb Gaussian, invarianța tipului densității de probabilitate a coeficienților wavelet la tipurile de densitate de probabilitate ale datelor de intrare, ș.a.m.d. Exploatarea acestor proprietăți poate conduce la elaborarea unor metode elegante de prelucrarea a datelor, cu rezultate foarte bune, dacă se utilizează optimizarea convexă pentru proiectarea lor.

Primul obiectiv științific al tezei a fost diversificarea aplicațiilor funcțiilor wavelet în telecomunicații. În capitolul 2 se face o trecere în revistă a teoriei funcțiilor wavelet în prelucrarea imaginilor, introducându-se principalele familii de funcții wavelet și diferite tipuri de transformare wavelet: continuă, discretă, staționară, complexă cu arbore dublu, analitică (hiperanalitică, Hyperanalytic Wavelet Transform-HWT) sau cu pachete de funcții wavelet. **Se formulează o primă contribuție a tezei în legătură cu interpretarea transformării cu pachete de funcții wavelet hiperanalitice ca o analiză în componente principale a imaginii. Această interpretare originală a fost publicată într-o lucrare de conferință indexată ISI:**

G. A. Magu, M. Kovaci, Images' Principal Component Analysis using Hyperanalytic Wavelet Packets, 2018 International Symposium on Electronics and Telecommunications (ISETC), 1-4.

Această implementare a analizei în componente principale a imaginilor permite identificarea orientărilor principale conținute în acele imagini și poate fi folosită în faza de pregătire a datelor pentru reducerea dimensionalității în proiecte DM.

În continuarea capitolului doi se prezintă principalele aplicații ale funcțiilor wavelet în prelucrarea imaginilor: denoising, compresie, îmbunătățirea contrastului, detecție de muchii și evaluare a gradului de netezime a unor suprafețe din imagine cu ajutorul valorilor locale ale exponentului Hurst.

Cel de al doilea obiectiv științific al tezei a fost îmbunătățirea performanțelor acestor metode de prelucrare a imaginilor. O parte dintre contribuțiile tezei se referă la astfel de îmbunătățiri și au fost obținute folosind metode de optimizare convexă.

Cea de a doua contribuție a tezei este o nouă metodă de înlăturare a zgomotului aditiv alb Gaussian din imaginile naturale respectiv a zgomotului de tip speckle din imaginile SAR, bazată pe HWT. Ideea acestei metode de denoising este cooperarea a două filtre neliniare: o variantă îmbunătățită

de filtru bishrink și filtrul ASTF; în domeniul HWT. Filtrul ASTF este rezultatul aplicării metodei de optimizare convexă denumită regularizare LASSO. Rezultatele simulărilor efectuate dovedesc superioritatea acestei metode de denoising în comparație cu alte metode de înlăturare a zgomotului bazate pe funcții wavelet sau nu. O direcție viitoare de cercetare ar putea fi înlocuirea HWT cu HWPT, deoarece HWPT reprezintă un dicționar mai potrivit decât HWT având un număr superior de direcții preferențiale. Metoda propusă ar putea fi utilizată în viitor ca metodă de pre-procesare în aplicații de prelucrarea imaginilor insuficient de robuste la zgomot. Și această contribuție poate fi utilizată în faza de pregătire a datelor a unui proiect DM.

Cea de a treia contribuție originală a tezei constă într-o metodă robustă (la zgomotul aditiv alb Gaussian respectiv la zgomotul de tip speckle) de detecție a muchiilor din imaginile naturale respectiv din imaginile SAR, care constă în aplicarea detectorului Canny după metoda de înlăturare a zgomotului care constituie cea de a doua contribuție a tezei. Aceste două metode și rezultatele de simulare aferente au fost publicate într-un articol dintr-o revistă indexată ISI, Q1:

A Isar, C Nafornta, G Magu, Hyperanalytic Wavelet-Based Robust Edge Detection, Remote Sensing 13 (15), 2888.

Rezultatele de detecție a muchiilor din imagini naturale perturbate de zgomot alb Gaussian respectiv din imagini de radio-locăție reale sunt remarcabile. Un rezultat important din punct de vedere practic este stabilirea numărului maxim de vederi al imaginilor de radio-locăție pentru care utilizarea sistemului de denoising înaintea detectorului Canny este încă necesară, la opt. Metoda propusă de detecție a muchiilor este mai adecvată în cazul imaginilor de radio-locăție decât metodele de tipul ML, fiind mult mai rapidă. Și această contribuție a tezei poate fi utilizată în faza de modelare a unui proiect DM.

Cea de a patra contribuție a tezei se referă la evaluarea gradului de netezime a unor suprafețe din imagini folosind funcții wavelet. Deoarece gradul de netezime al unei suprafețe într-o anumită regiune poate fi evaluat prin estimarea exponentului Hurst local și deoarece estimarea exponentului Hurst local poate fi realizată cu ajutorul funcțiilor wavelet, cea de a cincea contribuție a tezei constă într-o metodă de generare a unor texturi cu exponent Hurst specificat. Această metodă de generare poate fi folosită pentru calibrarea metodelor de evaluare a gradului de rugozitate a unei regiuni. Validarea științifică a acestei metode a fost făcută prin publicarea unui articol într-o revistă indexată BDI:

P Gajitzki, A Isar, G Magu, A New Algorithm for Fractional Brownian Motion Processes Generation, Acta Technica Napocensis 59 (1), 6-9.

Metoda de generare a proceselor aleatoare de tipul mișcare Browniană fracționară cu exponent Hurst specificat bazată pe funcții wavelet este complet justificată din punct de vedere teoretic iar rezultatele de simulare obținute au o calitate superioară rezultatelor obținute folosind funcția Matlab wfbm. Metoda de estimare a exponentului Hurst local bazată pe funcții wavelet permite evaluarea rugozității unor regiuni din imagine și implicit detecția valurilor dintr-o imagine de ocean, putând fi utilizată în faza de evaluare a unui proiect DM.

Aplicația OVL, amintită mai sus, ar putea fi implementată și ca proiect DM dedicat supravegherii unor regiuni de pe glob și studiului unor fenomene care se desfășoară la scară planetară fără fuziune de date. Acest proiect DM ar putea folosi doar imagini SAR. În figura 76 este dat un exemplu de astfel de imagine.




Figura 76. Imagine de tipul Single Look Complex Stripmap SAR achiziționată de unul dintre sateliții Sentinel-1 pe data de 11 martie 2015, de pe coasta Africii de Sud.

Acest tip de imagine Sentinel-1 are cea mai mare rezoluție spațială dar și cel mai mare conținut de zgomot speckle.

Faza proiectului DM de pregătire a datelor ar presupune reducerea zgomotului de tip speckle (folosind cea de a doua contribuție a tezei) și eventual scăderea dimensionalității datelor (folosind prima contribuție a tezei). În figura 77 este prezentată o variantă a imaginii din figura 76 obținută printr-o prelucrare de reducere a zgomotului denumită multi-looking.



Figura 77. O variantă a imaginii din figura 76 obținută printr-o prelucrare de tipul multi-looking.

Avantajul procedurii de tip multi-looking este înlăturarea completă a zgomotului de tip speckle iar dezavantajul acestei proceduri este scăderea rezoluției spațiale a imaginii.

Faza de modelare a proiectului DM ar presupune segmentarea imaginii în regiune de pământ și regiune de ocean și detecția valurilor din regiunea de ocean. Detecția valurilor ar putea fi realizată prin detecția muchiilor (folosind cea de a treia

contribuție a tezei), luând în considerare culoarea albă a creștelor valurilor din partea de ocean a figurii 77, sau prin îmbunătățirea contrastului folosind funcții wavelet. În figura 78 se prezintă o comparație dintre imaginea din figura 77 (stânga) și rezultatul îmbunătățirii contrastului imaginii din figura 77 (dreapta) folosind metoda de îmbunătățire a contrastului cu funcții wavelet descrisă în lucrarea de față.




Figura 78. O comparație între imaginile de intrare a) și ieșire b) ale metodei de îmbunătățire a contrastului descrisă în paragraful 2.4.1.

În urma detecției maximelor din regiunea de ocean a imaginii din figura 78b) se obține imaginea din figura 79.

După cum se vede în imaginea din mijloc a figurii 79, pozițiile creștelor valurilor pot fi detectate cu precizie folosind metoda propusă în paragraful 2.4.1. Faza de evaluare a acestui proiect DM ar putea consta în aprecierea preciziei de poziționare a creștelor valurilor efectuând comparații cu rezultatele obținute de altimetre în puncte aparținând traiectoriilor acestora. O altă implementare posibilă a fazei de evaluare ar presupune compararea rezultatelor obținute folosind metoda descrisă deja cu rezultatele obținute folosind metoda de estimare a rugozității suprafețelor din imagine care stă la baza celei de a patra contribuții a tezei, deoarece valoarea exponentului Hurst local are variații bruște la granița de separare dintre regiunile luminoase și întunecate din zona de ocean a imaginii obținute în urma îmbunătățirii contrastului.




Figura 79. O comparație a rezultatelor a două metode de îmbunătățire a contrastului: propusă în paragraful 2.4.1 (proposed) și metoda de îmbunătățire a contrastului bazată pe egalizarea histogrammei denumită CLAHE.

În consecință proiectul DM dedicat supravegherii unor regiuni de pe glob și studiului unor fenomene care se desfășoară la scară planetară ar putea fi implementat și fără fuziune de date, folosind exclusiv metode de prelucrare a imaginilor de radio locație bazate pe funcții wavelet.

În cazul aplicației DM dedicate acordării de asistență șoferilor de autovehicule prin prelucrarea semnalelor generate de senzorii RADAR este vorba despre concepția unei componente a unui sistem ADAS.

Pe lângă creșterea securității transporturilor rutiere, alte obiective ale sistemelor ADAS sunt: creșterea confortului pasagerilor și eficientizarea consumului de energie al automobilelor. ADAS este o nouă tehnologie de conducere a automobilului bazată pe controlul adaptiv al croazierei (Adaptive Cruise Control-ACC), frânarea de urgență automată (Automatic Emergency Brake-AEB), monitorizarea unghiului mort (Blind Spot Monitoring-BSM), asistența la depășire (Lane Change Assistance-LCA) și avertizarea la pericolul de ciocnire (Forward Collision Warnings-FCW). Sistemul ADAS integrează aceste aplicații folosind date de la senzori diferiți: RADAR, LIDAR, cu ultrasunete, camere de luat vederi, etc.

Motorul automobilului primește prin intermediul sistemelor hardware de acționare: actuatoare, frână, direcție; comenzile de la senzori pentru a permite sistemului ADAS să ia decizii privind alertarea șoferului pentru detectarea obiectelor periculoase, localizarea sau oprirea vehiculului dacă este necesar. De exemplu, detectarea unui automobil (care se pregătește să depășească) în unghiul mort realizată de sub-sistemul BSM permite emiterea unui semnal de alarmă în legătură cu interzicerea depășirii de către sub-sistemul LCA al sistemului ADAS [137]. Datele generate de senzori sunt supuse unui proces de fuziune în urma căruia se obțin datele care sunt folosite de unitatea centrală de calcul a automobilului pentru a activa driver-ul sistemului ADAS. Acest sistem ia decizii legate de: asistența pentru parcare, frânare automată de urgență, detecția pietonilor, vedere înconjurătoare și chiar somnolența șoferului. Componentele funcționale ale automobilului, precum

diferitele tipuri de senzori (care colectează permanent date din mediul înconjurător) sunt legate de arhitectura sistemului ADAS. De exemplu sub-sistemul FCW al sistemului ADAS este de obicei situat în parbriz, iar sub-sistemul BSM poate fi amplasat în oglinzile laterale.

Capitolul 3 al tezei de față este destinat studiului metodelor de prelucrare a semnalelor generate de senzorii RADAR. Se prezintă metodele de detecție a țintelor cu rată de alarmă falsă constantă cu CFAR și se studiază metodele de urmărire a țintelor.

Cel de al treilea obiectiv științific al tezei a fost îmbunătățirea performanțelor sistemelor cu senzori RADAR auto prin perfecționarea unor metode de prelucrare a semnalelor, ca de exemplu: detecția sau urmărirea țintelor, folosind funcții wavelet.

Cea de a cincea contribuție a tezei constă într-o metodă de detecție a țintelor cu raport semnal pe zgomot foarte mic bazată pe funcții wavelet. Validarea științifică a acestei contribuții a fost făcută prin publicarea la o conferință internațională indexată ISI a lucrării:

A Isar, C Nafornita, A Macaveiu, G Magu, Wavelet Based Adaptive Detection of Automotive Radar Single Target with Low SNR, 2020 International Symposium on Electronics and Telecommunications (ISETC), 1-6.

Senzorii RADAR care echipează automobilele moderne folosesc pentru detecția țintelor hărțile range-Doppler generate pentru fiecare ciclu de măsurare. Pozițiile instantanee ale țintelor pot fi estimate pe baza distanțelor instantanee între RADAR și ținte (range) prin detectarea maximelor locale din harta range-Doppler. Pentru a păstra constantă rata de alarme false (Constant False Alarm Rate-CFAR) este necesar ca țintele să aibă un raport semnal pe zgomot suficient de mare, în așa fel încât puterile semnalelor provenite de la ținte să fie mai mari decât puterea semnalelor perturbatoare (zgomot termic și clutter). De aceea, detecția unei ținte se realizează prin compararea valorii maximumului local corespunzător cu un prag a cărui valoare se alege proporțională cu puterea semnalelor perturbatoare. În cazul în care valoarea maximumului local este superioară valorii de prag se detectează ținta corepunzătoare. Rezultă că țintele cu raport semnal pe zgomot foarte mic nu vor fi detectate (vor fi pierdute). Valoarea minimă a raportului semnal pe zgomot pentru care ținta este încă detectată corect se notează SNR_{min} . Modalitatea de alegere a valorii de prag folosită de detector se bazează de obicei pe tehnici de ordonare statistică. Această contribuție a tezei presupune aplicarea unei operații de denoising imaginii hărții range-Doppler anterior detecției, care are ca efect creșterea artificială a raportului semnal pe zgomot al țintelor. S-a ales ca metodă de denoising asocierea dintre transformarea DWT bidimensională și filtrul hard thresholding. Pentru alegerea valorii pragului filtrului hard thresholding s-a folosit o metodă de ordonare statistică bazată pe filtrarea mediană. Rezultatele simulărilor raportate sunt încurajatoare, valoarea SNR_{min} scăzând cu 5 dB. Importanța acestui rezultat rezidă în faptul că prin scăderea SNR_{min} poate fi crescută distanța maximă până la care poate fi detectată corect o țintă. Principala limitare a acestei metode este că în implementarea curentă metoda permite detecția unei singure ținte. Pentru detecția mai multor ținte cu raport semnal pe zgomot foarte mic ar fi necesară o procedură iterativă de tipul matching pursue [13]. Maximele locale de pe harta range-Doppler ar trebui ordonate în ordine descrescătoare. Apoi, la prima iterație ar trebui detectată doar ținta corespunzătoare celui mai mare maxim local, după care acest maxim local ar trebui șters de pe harta range-Doppler inițială, obținându-se o a doua hartă range-Doppler. Aceasta ar trebui prelucrată la cea de a doua iterație, detectându-se cea de a doua țintă, ștergându-se maximumul local corespunzător și obținându-se cea de a treia hartă range-Doppler. Această procedură ar trebui să

continue până la atingerea unui număr de iterații egal cu numărul de maxime locale detectate în imaginea hărții range-Doppler inițială.

Cea de a șasea, de a șaptea și de a opta contribuție a tezei constau într-o metodă de reducere a incertitudinii metodelor de urmărire a țintelor bazată pe potrivirea polinomială implicită, explicită respectiv bazată pe funcții wavelet, care au fost validate științific prin publicarea a două lucrări la conferințe internaționale indexate ISI:

G Magu, R Lucaciu, A Isar, Polynomial Based Kalman Filter Result Fitting to Data, 2020, 43rd International Conference on Telecommunications and Signal Processing, Milano, Italy

și

G Magu, R Lucaciu, Multiple Radar Targets Tracking and Trajectories Fitting, 2020 International Symposium on Electronics and Telecommunications (ISETC), 11-14,

precum și a unui articol într-o revistă indexată ISI Q2:

G Magu, R Lucaciu, A Isar, Improving the Targets' Trajectories Estimated by an Automotive RADAR Sensor Using Polynomial Fitting, Applied Sciences, 11 (1), 361.

Pentru urmărirea țintelor RADAR se recurge de obicei la asocierea a două tipuri de algoritmi dintre care unul realizează asocierea datelor generate de senzorul RADAR cu țintele (se folosește de obicei algoritmul maghiar) iar celălalt trasează traiectoria țintei (se folosește de obicei algoritmul de filtrare Kalman pentru fiecare țintă). Datorită: erorilor de estimare a poziției și vitezei relative a țintelor, zgomotului termic al receptorului și clutter-ului, datelor lipsă, erorilor de modelare a cinematicii țintelor pentru filtrarea Kalman; urmărirea țintelor este afectată de o anumită incertitudine, existând diferențe între traiectoriile adevărate ale țintelor și traiectoriile obținute la ieșirile filtrelor Kalman. Această incertitudine poate fi redusă pe baza conjecturii că traiectoriile țintelor sunt polinomiale în plan (justificată de observația că traiectoriile drumurilor pe care se deplasează țintele interesante pentru senzorii RADAR montați pe automobile sunt polinomiale în plan din rațiuni constructive). Estimatele traiectoriilor obținute la ieșirile filtrelor Kalman asociate țintelor sunt funcții de două variabile: abscisa x și ordonata y . Fiecare dintre aceste variabile este funcție de timp, t . Pentru ca traiectoria f , $y=f(x)$, să fie polinomială este necesar și suficient ca funcțiile $x(t)$ și $y(t)$ să fie polinomiale, deoarece prin compunerea a două funcții polinomiale (x și f) se obține o altă funcție polinomială (y). Există algoritmi de „potrivire” polinomială a funcțiilor de o singură variabilă. Acești algoritmi rezolvă o problemă de optimizare convexă. Pe baza folosirii acestor algoritmi au fost concepute două metode de reducere a incertitudinii tehnicilor de urmărire a țintelor. Prima metodă de potrivire polinomială a traiectoriei țintei se numește implicită și are trei pași:

- Potrivirea polinomială a dependenței de timp a abscisei țintei,
- Potrivirea polinomială a dependenței de timp a ordonatei țintei,
- Reprezentarea în plan a rezultatelor obținute prin aplicarea celor doi pași anteriori.

Avantajul acestei metode de potrivire polinomială a traiectoriei țintei este că algoritmul aferent este rapid. Dezavantajul acestei metode este că estimarea traiectoriei nu este foarte precisă, existând posibilitatea ca valori extreme ale abscisei respectiv ordonatei să fie pierdute ca urmare a potrivirii polinomiale separate pe cele două axe de coordonate. Cea de a doua metodă de potrivire polinomială a traiectoriei țintei se numește explicită și are doi pași suplimentari față de metoda de potrivire polinomială implicită a traiectoriei țintei. În continuare se

enumeră pașii acestei a doua metode de potrivire polinomială a traiectoriei unei ținte RADAR:

- Potrivirea polinomială a dependenței de timp a abscisei ținte,
- Inversarea polinomului obținut la pasul anterior,
- Potrivirea polinomială a dependenței de timp a ordonatei ținte,
- Substituția rezultatului celui de al doilea pas în rezultatul celui de al patrulea pas,
- Reprezentarea în plan a rezultatului obținut la pasul anterior.

Avantajul metodei de potrivire polinomială explicită a traiectoriei ținte este precizia sa ridicată. Dezavantajul acestei metode este că algoritmul aferent este mai lent decât algoritmul asociat metodei de potrivire polinomială implicită a traiectoriei ținte. A treia metodă de potrivire polinomială a traiectoriei ținte propusă în teză este bazată pe funcții wavelet. Algoritmul aferent acestei metode are structura algoritmului asociat metodei de potrivire implicită a traiectoriei ținte, dar potrivirea polinomială a dependenței de timp a abscisei și respectiv a ordonatei ținte se realizează cu ajutorul funcțiilor wavelet folosind un algoritm cu doi pași:

- Îndepărtarea incertitudinii de estimare a abscisei respectiv ordonatei prin denoising,
- Extragerea părții polinomiale din semnalul obținut după denoising.

Pentru denoising se folosește asocierea DWT-filtru hard-thresholding iar pentru extragerea părții polinomiale se folosește proprietatea de regularitate a funcției wavelet mamă [13] amintită în paragraful 3.4.2.2. Rezultatele de simulare prezentate dovedesc că metoda de potrivire polinomială a traiectoriei ținte bazată pe funcții wavelet este la fel de precisă ca și metoda de potrivire polinomială explicită a traiectoriei deoarece datorită operației de denoising nu mai există posibilitatea ca valori extreme ale abscisei respectiv ordonatei să fie pierdute ca urmare a potrivirii polinomiale separate pe cele două axe de coordonate. De asemenea, datorită faptului că algoritmul de calcul al transformatei wavelet discretă este rapid (mult mai rapid decât algoritmul de implementare a potrivirii polinomiale pe o singură coordonată), metoda bazată pe funcții wavelet este cea mai rapidă dintre cele trei metode de potrivire polinomială a traiectoriei ținte propuse. Pentru aplicarea oricăreia dintre aceste trei metode este necesară cunoașterea gradelor polinoamelor care exprimă variațiile în timp ale celor două coordonate. Întrucât aceste două numere nu sunt cunoscute a priori, în practică se folosește pentru axa absciselor gradul întâi iar pentru axa ordonatelor gradul 3. De exemplu în figura 80 este prezentat rezultatul obținut în urma aplicării metodei de potrivire polinomială a traiectoriei bazată pe funcții wavelet considerând valorile indicate ale gradelor celor două polinoame (1 pe x și 3 pe y) pentru date reale provenite de la un automobil echipat cu un senzor RADAR cu frecvența purtătoare de 77 de GHz, care executa o manevră de parcare.




Figura 80. a) traiectoria generată folosind datele achiziționate de senzor. b) traiectoria obținută în urma aplicării procedurii de potrivire polinomială.

Deși este mult mai precis decât un senzor RADAR cu frecvența purtătoare de 24 de GHz (așa după cum se poate constata comparând lățimile liniilor curbe din figura 80a) și a liniilor albastre din figura 69 din capitolul 3), dezavantajul achiziției realizate cu senzorul RADAR cu frecvența purtătoare de 77 de GHz al cărui rezultat este prezentat în figura 80a) constă în pierderea unor date (aproximativ o șesime din date lipsesc). Așa după cum se poate vedea în figura 80b), toate aceste date au fost completate folosind metoda de potrivire polinomială a traiectoriei țintei bazată pe funcții wavelet. Prin compararea înregistrării video a scenei cu figura 80b) se poate observa că traiectoria automobilului a fost estimată corect folosind metoda propusă în ciuda faptului că este destul de complexă (conține două curbe, a doua fiind destul de ascuțită).

O direcție posibilă de continuare a acestei cercetări este realizarea potrivirii polinomiale a traiectoriei folosind metode de prelucrare a imaginilor bazate pe funcții wavelet.

Unul dintre sub-sistemele sistemului ADAS care folosește datele achiziționate de senzori RADAR și care se pretează la o implementare DM este sub-sistemul BSM. Unghiul mort poate fi monitorizat cu ajutorul unui senzor RADAR montat pe partea din spate a automobilului. În intervalele de timp în care automobilul din spate s-a apropiat suficient de mult ca să nu mai poată fi observat în oglindă, acest senzor poate alerta șoferul de intenția iminentă de depășire a partenerului la trafic din spate. În faza de pregătire a datelor din cadrul acestui proiect DM ar putea fi utilizată cea de a cincea contribuție a tezei pentru detecția primeia dintre țintele RADAR care sunt situate în spatele automobilului. În faza de modelare a proiectului DM, în urma detecției țintelor și urmăririi acestora (realizată prin cooperarea dintre algoritmul maghiar de asociere a datelor și filtrele Kalman corespunzătoare fiecărei ținte) ar putea fi utilizată una dintre cele trei metode de potrivire polinomială a traiectoriei care reprezintă ultimele trei contribuții ale tezei. În sfârșit în faza de evaluare a acestui proiect DM ar putea fi detectat momentul în care distanța dintre automobilul pe care este montat senzorul RADAR și primul automobil din spatele acestuia scade sub distanța corespunzătoare intrării în unghiul mort și poate fi declanșată alarmarea șoferului.

Lista publicațiilor

- [1] **G. Magu**, R. Lucaciu and A. Isar, „Improving the Targets’ Trajectories Estimated by an Automotive RADAR Sensor Using Polynomial Fitting,” *Appl. Sci.* 2021, 11, 361.
- [2] **G. Magu**, R. Lucaciu and A. Isar, „Polynomial Based Kalman Filter Result Fitting to Data”, *Proceedings of 43rd International Conference on Telecommunications and Signal Processing (TSP)*, 7-9 July 2020, Milan, Italy.
- [3] **G. Magu**, R. Lucaciu, „Multiple Radar Targets Tracking and Trajectories Fitting,” *In Proceedings of the International Symposium on Electronics and Telecommunications (ISETC)*, Timisoara, Romania, 5–6 November 2020.
- [4] V. C. Vasile, G. Magu, R. Coșnița, C. Nafornița, A. Isar, M. Borda, „EGNOS Performance Improvements Using Monitoring Stations in Romania,” *In Proceedings of the International Symposium on Electronics and Telecommunications (ISETC)*, Timisoara, Romania, 1–6 November 2018.
- [5] P. Gajitzki, A. Isar, **G. Magu**, „A New Algorithm for Fractional Brownian Motion Processes Generation”, *Acta Technica Napocensis* 59 (1), 6-9.
- [6] A. Isar, C. Nafornita, **G. Magu**, „Hyperanalytic Wavelet-Based Robust Edge Detection”, *Remote Sensing*, iunie 2021.
- [7] A. Isar, C. Nafornita, A. Macaveiu, **G. Magu**, „Wavelet Based Adaptive Detection of Automotive Radar Single Target with Low SNR,” *In Proceedings of 2020 International Symposium on Electronics and Telecommunications (ISETC)*, 5-6 Nov. 2020, Timisoara, Romania.
- [8] **G. A. Magu**, M. Kovaci, „Images’ Principal Component Analysis using Hyperanalytic Wavelet Packets”, *2018 International Symposium on Electronics and Telecommunications (ISETC)*, Timișoara, 2018.

Bibliografie

- [1] P. Cabena, P. Hadjinian, R. Stadler, J. Verhees and A. Zanasi, „Discovering Data Mining: From Concept to Implementation“, Prentice Hall, Upper Saddle River, NJ, 1998.
- [2] C. Schröder, F. Kruseb, J. M. Gómez, „A Systematic Literature Review on Applying CRISP-DM Process Model“, *Procedia Computer Science* Volume 181, 2021, pp. 526-534.
- [3] D. A. Simovici, „Linear Algebra Tools for Data Mining“, World Scientific, NJ, USA, 2012.
- [4] R. C. Gonzalez and R. E. Woods, „Digital Image Processing“, Addison Wesley, 1993.
- [5] A. K. Jain, „Fundamentals of Digital Image Processing“, Prentice Hall, Englewood Cliffs, New Jersey, 1989.
- [6] Y. Meyer, „Wavelets and operators“, Advanced mathematics, Cambridge University Press, 1992.
- [7] I. Daubechies, „Orthonormal Bases of Compactly Supported Wavelets“, *Comm. Pure Appl. Math.* 41(1988), pp. 909-996.
- [8] S. Mallat, „Multiresolution Approximation and Wavelet Orthonormal Bases of $L^2(\mathbb{R})$ “, *Tran. Amer. Math. Soc.* 315(1989), pp. 69-87.
- [9] S. Mallat, „A Theory of Multiresolution Signal Decomposition: The Wavelet Representation“, *IEEE Trans. PAMI*, 11, 1989, pp. 674-693.
- [10] C. K. Chui, „Wavelet: A Mathematical Tool for Signal Analysis“, SIAM, 1997.
- [11] I. Daubechies, „Ten Lectures on Wavelets“, SIAM 1992.
- [12] E. Hernandez and G. Weiss, „A First Course on Wavelets“, CRC Press, 1996.
- [13] S. Mallat, „A Wavelet Tour of Signal Processing“, Academic Press, 1998.
- [14] G. Strang and T. Nguyen, „Wavelets and Filter Banks“, Wellesley-Cambridge Press, 1996.
- [15] E. Candès and D. Donoho, „Ridgelets: a Key to Higher-dimensional Intermittency?“, *Phil. Trans. R. Soc. Lond. A* (1999).
- [16] E. Candès and D. Donoho, „Curvelets: A Surprisingly Effective Nonadaptive Representation of Objects with Edges“, *Tech. Report, Dept. of Stat., Stanford Univ.*, 1999.
- [17] D. Donoho and X. Huo, „Beamlets and multiscale image analysis, *Multiscale and Multiresolution Methods*“, Springer Lecture Notes in Computational Science and Engineering (Editors T.J. Barth, T. Chan, and R. Haimes), vol. 20, pp. 149-196, 2002.
- [18] Gabriel Peyré, Stéphane Mallat, „Surface Compression With Geometric Bandelets“. *ACM Transactions on Graphics, Association for Computing Machinery*, 2005, 24 (3), pp.601–608.
- [19] L. Rudin, S. Osher and E. Fatemi, „Nonlinear Total Variation Based Noise Removal Algorithms“, *Physica D*, Vol 60(1992), pp. 259-268.
- [20] P. Perona and J. Malik, „Scale-space and edge detection using anisotropic diffusion“, *IEEE T PATTERN ANAL.* 12:(7), July, 1990, pp. 629-639.
- [21] D. Göhring, M. Wang, M. Schnürmacher, and T. Ganjineh, „Radar/lidar sensor fusion for car-following on highways“, in *Proc. Int. Conf. Automation, Robotics and Applications, Wellington, New Zealand*, 2011, pp. 407–412.

- [22] R. H. Rasshofer and K. Gresser, „Automotive radar and lidar systems for next generation driver assistance functions,” *Adv. Radio Sci.*, vol. 3, pp. 205–209, May 2005.
- [23] M. Mahlich, R. Hering, W. Ritter, and K. Dietmayer, „Heterogeneous fusion of video, LIDAR and ESP data for automotive ACC vehicle tracking,” in *Proc. IEEE Int. Conf. Multisensor Fusion and Integration for Intelligent Systems*, Heidelberg, Germany, 2006, pp. 139–144.
- [24] B. Steux, C. Laugeau, L. Salesse, and D. Wautier, „Fade: A vehicle detection and tracking system featuring monocular color vision and radar data fusion,” in *Proc. IEEE Intelligent Vehicle Symp.*, Versailles, France, 2002, vol. 2, pp. 632–639.
- [25] P. Viola and M. Jones, „Robust real-time object detection,” *Int. J. Comput. Vis.*, vol. 4, Feb. 2001.
- [26] G. M. Brooker, „Mutual interference of millimeter-wave radar systems,” *IEEE Trans. Electromagnet. Compat.*, vol. 49, no. 1, pp. 170–181, Feb. 2007.
- [27] P. Papadimitratos, A. D. La Fortelle, K. Evenssen, R. Brignolo, and S. Cosenza, „Vehicular communication systems: Enabling technologies, applications, and future outlook on intelligent transportation,” *IEEE Commun. Mag.*, vol. 47, no. 11, pp. 84–95, Nov. 2009.
- [28] F. Ye, M. Adams, and S. Roy, „V2V wireless communication protocol for rear-end collision avoidance on highways,” in *Proc. IEEE Int. Conf. Communications Workshop*, Beijing, China, 2008, pp. 375–379.
- [29] S. Boyd and L. Vandenberghe, „*Convex Optimization*”, Cambridge University Press, New York, 2004.
- [30] Y. Meyer, „*Wavelets: Algorithms and Applications*”, Society for Industrial and Applied Mathematics, Philadelphia, 1993, pp. 13–31, 101–105.
- [31] R. Coifman, M. Wickerhauser, „Entropy-based algorithms for best basis selection,” *IEEE Trans. Inform. Theory*, vol. 38, pp. 713–718, 1992.
- [32] R. M. Rao, A. S. Bopardikar, „*Wavelet Transforms: Introduction to the theory and applications*”, Addison-Wesley, 1998.
- [33] L. Sendur, I. W. Selesnick, „Bivariate shrinkage functions for wavelet-based denoising exploiting interscale dependency”, *IEEE Trans. on Sig. Proc.* 50 (11), pp. 2744–2756, 2002.
- [34] N. G. Kingsbury, „Complex wavelets for shift invariant analysis and filtering of signals”, *Journal of Applied and Computational Harmonic Analysis*, 10(3): 234–253, 2001.
- [35] A. R. Calderbank, I. Daubechies, W. Sweldens and B.-L. Yeo, „Wavelet Transforms That Map Integers to Integers”, *Applied and Computational Harmonic Analysis* 5, 332–369, 1998.
- [36] M. Holschneider, R. Kronland-Martinet, J. Morlet, P. Tchamitchian, „*Wavelets. Time-frequency Methods and Phase Space*,” chapter A Real-Time Algorithm for Signal Analysis with the Help of the Wavelet Transform, Springer-Verlag, Berlin, 289–297, 1989.
- [37] N. G. Kingsbury, „The dual-tree complex wavelet transforms: a new efficient tool for image restoration and enhancement”, *Proc.EUSIPCO 98*, Rhodes, 319–322, 1998.
- [38] I. W. Selesnick, „The Characterization and Design of Hilbert Transform Pairs of Wavelet Bases”. In 2001 Conference on Information Science and Systems, Johns Hopkins University, 2001.
- [39] S. C. Olhede, G. Metikas, „The Hyperanalytic Wavelet Transform”, Technical report, Imperial College Statistics Section, 2006.

- [40] I. Firoiu, Teză de doctorat: „Complex Wavelet Transform: application to denoising”, Politehnica University Timisoara, Romania, 2010.
- [41] A. Isar, C. Nafornta, „On the statistical decorrelation of the 2D discrete wavelet transform coefficients of a wide sense stationary bivariate random process,” *Digital Signal Processing*, 24, 95-105, 2014.
- [42] S. Foucher, B. G. Benie, J.-M. Boucher, „Multiscale MAP Filtering of SAR images”, *IEEE Trans. on Img. Proc.*, 10(1), 49-60, 2001.
- [43] D. Alfsmann, H. G. Göckler, S. G. Sangwine, T. A. Ell, „Hypercomplex Algebras in Digital Signal Processing: Benefits and Drawbaks”, *Proceedings EUSIPCO 2007, Poznan, Poland*, 2007.
- [44] I. Firoiu, C. Nafornta, J.- M. Boucher, A. Isar, „Image Denoising Using a New Implementation of the Hyperanalytic Wavelet Transform”, *IEEE Transactions on Instrumentation and Measurement*, 58(8), 2410-2416, 2009.
- [45] C. Clyde, M. Davenport, „A commutative hypercomplex algebra with associated function theory”, in *Clifford Algebras with Numeric and Symbolic Computations*, R. Ablamowicz (Ed.), Birkhäuser, Boston, 213–227, 1996
- [46] I. W. Selesnick, R. G. Baraniuk, N. G. Kingsbury, „The dual-tree complex wavelet transform,” *IEEE Signal Proc. Magazine*, 22, 6, pp. 123–151, 2005.
- [47] I. Firoiu, D. Isar, J. M. Boucher, A. Isar, „Hyperanalytic Wavelet Packets”, *Proc. Internat. Conf. WISP 2009, Budapest*, pp. 67-72.
- [48] C. Nafornta, A. Isar, I. Nafornta, „The Hyperanalytic Wavelet Packets – A Solution to Increase the Directional Selectivity in Image Analysis”, *Proc. Internat. Sympo. ISETc2012, Timisoara*, 2012.
- [49] **G. A. Magu**, M. Kovaci, „Images’ Principal Component Analysis using Hyperanalytic Wavelet Packets”, 2018 International Symposium on Electronics and Telecommunications (ISETC), Timișoara, 2018.
- [50] A. Buades, Image and film denoising by non-local means. PhD thesis, Universitat de les Illes Balears, Dpt. de matemàtiques - informàtica, 2007.
- [51] A. Foi, V. Katkovnik and K. Egiazarian, „Pointwise Shape-Adaptive DCT for High-Quality Denoising and Deblocking of Grayscale and Color Images”, *IEEE Transactions on Image Processing*, 16, no.5:1395–1411, 2007.
- [52] M. Walessa and M. Datcu, „Model-Based Despeckling and Information Extraction from SAR Images”, *IEEE Trans. Geo. Rem. Sens.*, vol. 38, no. 5, '00, 2258- 2269.
- [53] A. Buades, B. Coll and J. M. Morel, „A review of image denoising algorithms, with a new one,” *Multiscale Modeling & Simulation*, vol. 4, pp. 490-530, 2005.
- [54] A. A. Bindilatti, M. A. C. Vieira, P. R. Bakic, A. D. A. Maidment and N. D. A. Mascarenhas, „Filtering Poisson Noise in Digital Breast Tomosynthesis using an Iterative Non-Local Means Scheme based on Stochastic Distances”, *Proceedings of XI Workshop de Visão Computacional - October 05th-07th*, 2015.
- [55] V. De Bortoli, A. Desolneux, B. Galerne, A. Leclaire, „Patch redundancy in images: a statistical testing framework and some applications”, *SIAM Journal on Imaging Sciences*. 2019, vol. 12, n° 2, p. 893-926, Society for Industrial and Applied Mathematics.
- [56] D. L. Donoho and I. M. Johnstone, „Ideal spatial adaptation by wavelet shrinkage”, *Biometrika*, vol. 81, no. 3: 425 455, 1994.
- [57] J. -L. Starck, D. L. Donoho, M. J. Fadili, A. Rassat, „Sparsity and the Bayesian perspective”, *Astronomy&Astrophysics*, 552, A133, 2013.

- [58] D. Tomassi, D. Milone, J. D. B. Nelson, „Wavelet shrinkage using adaptive structured sparsity constraints”, *Signal Processing* 106, 73–87, 2015.
- [59] F. Luisier, T. Blu and M. Unser, „A New SURE Approach to Image Denoising: Inter-Scale Orthonormal Wavelet Thresholding”, *IEEE Transactions on Image Processing*, 16, no. 3: 593–606, 2007.
- [60] S. Chen, D. Donoho, M. Saunders, „Atomic decomposition by basis pursuit”, *SIAM J. Sci. Comput.* 20(1), 33–61, 1998.
- [61] R. Tibshirani, „Regression shrinkage and selection via the lasso”, *J. R. Stat. Soc. Ser. B* 58, 267–288, 1994.
- [62] A. Pizurica and W. Philips, „Estimating the probability of the presence of a signal of interest in multiresolution single and multiband image denoising”, *IEEE Transactions on Image Processing*, 15, no. 3: 654 – 665, 2006.
- [63] A. Achim and E. E. Kuruoglu, „Image Denoising Using Bivariate α -Stable Distributions in the Complex Wavelet Domain”, *IEEE Signal Processing Letters*, 12 (1): 17 – 20, 2005.
- [64] P. -L. Shui, „Image Denoising Algorithm via Doubly Local Wiener Filtering with Directional Windows in Wavelet Domain”, *IEEE Signal Processing Letters*, 12, No. 6: 681 – 684, 2005.
- [65] D. Gleich and M. Datcu, „Gauss–Markov Model for Wavelet-Based SAR Image Despeckling”, *IEEE Sig. Proc. Let.*, vol. 13, no. 6, 2006, 365–368.
- [66] C. Naornita, A. Isar and J. D. B. Nelson, „Regularised, semi-local hurst estimation via generalised lasso and dual-tree complex wavelets,” 2014 IEEE International Conference on Image Processing (ICIP), Paris, 2014, pp. 2689–2693, doi: 10.1109/ICIP.2014.7025544.
- [67] J. D. B. Nelson, C. Naornita and A. Isar, „Generalised M-Lasso for robust, spatially regularised hurst estimation,” 2015 IEEE Global Conference on Signal and Information Processing (GlobalSIP), Orlando, FL, 2015, pp. 1265–1269, doi: 10.1109/GlobalSIP.2015.7418401.
- [68] J. D. B. Nelson, C. Naornita and A. Isar, „Semi-Local Scaling Exponent Estimation With Box-Penalty Constraints and Total-Variation Regularization,” in *IEEE Transactions on Image Processing*, vol. 25, no. 7, pp. 3167–3181, July 2016, doi: 10.1109/TIP.2016.2551365.
- [69] C. Naornita, A. Isar and J. D. B. Nelson, „Denoising of Single Look Complex SAR Images using Hurst Estimation”, 12th International Symposium on Electronics and Telecommunications (ISETC), 2016, 26–27 Oct. 2016, Timisoara, Romania, pp 333–338.
- [70] C. Naornita, J. D. B. Nelson and A. Isar, „Performance Analysis of SAR Image Denoising Using Scaling Exponent Estimator”, *proceedings of Communications 2016*, Bucharest, June 9–11 2016, Pages: 33 – 36.
- [71] O. Karakuş, I. Rizaev, A. Achim, „A Simulation Study to Evaluate the Performance of the Cauchy Proximal Operator in Despeckling SAR Images of the Sea Surface”, *IGARSS 2020*.
- [72] J. Guo and Q. Chen, „Image denoising based on nonconvex anisotropic total-variation regularization”, *Signal Processing*, Vol. 186, September 2021.
- [73] I. W. Selesnick, „The Estimation of Laplace Random Vectors in Additive White Gaussian Noise”, *IEEE Transactions on Signal Processing*, 56(8), 3482 – 3496, 2008.
- [74] I. W. Selesnick, „A Higher Density Discrete Wavelet Transform”, *IEEE Transactions on Signal Processing*, vol. 54, Issue 8, Aug. 2006, 3039–3048.

- [75] E. J. Candès and D. Donoho, „New tight frames of curvelets and optimal representations of objects with smooth singularities”, Tech. Rep., Stanford University, 2002.
- [76] L. Tessens, A. Pižurica, A. Alecu, A. Munteanu, W. Philips, „Context adaptive image denoising through modeling of curvelet domain statistics”, *Journal of Electronic Imaging* 17(3), 033021 (Jul-Sep 2008).
- [77] M. N. Do and M. Vetterli, „The Contourlet Transform: An Efficient Directional Multiresolution Image Representation”, *IEEE TRANSACTIONS ON IMAGE PROCESSING*, VOL. 14, NO. 12, DECEMBER 2005, 2091-2106.
- [78] B. Matalon, M. Zibulevsky and M. Elad, „Image denoising with the Contourlet transform”, in *Proceedings of the SPIE conference wavelets*, July 2005, vol. 5914.
- [79] K. Guo and D. Labate, „Optimally sparse multidimensional representation using shearlets”, *SIAM J. MATH. ANAL.*, 2007, Society for Industrial and Applied Mathematics, Vol. 39, No. 1, pp. 298-318.
- [80] V. Velisavljevic, B. Beferull-Lozano, M. Vetterli and P. L. Dragotti, „Directionlets: Anisotropic Multidirectional Representation With Separable Filtering”, *Ieee Transactions On Image Processing*, VOL. 15, NO. 7, JULY 2006, 1916-1933.
- [81] A. Averbuch, P. Neittaanmäki, V. A. Zheludev, „Analytic and directional wavelet packets in the space of periodic signals”, *CoRR abs/1907.01479* (2019).
- [82] F. Argenti, T. Bianchi, L. Alparone, „Multiresolution MAP Despeckling of SAR Images Based on Locally Adaptive Generalized Gaussian PDF Modeling”, *IEEE Transactions on Image Processing*, vol. 15, no. 11, Nov. 2006, pp. 3385-3399.
- [83] A. Synyavskyy, S. Voloshynovskiy and I. Prudyus, „Wavelet-Based Map Image Denoising Using Provably Better Class of Stochastic I.I.D. Image Models”, *Facta Universitatis (Nis)*, Series: Electronics and Energetics vol. 14, No. 3, December 2001, 375-385.
- [84] A. Pizurica, W. Philips, I. Lemahieu and M. Acheroy, „A Joint Inter-and Intrascale Statistical Model for Bayesian Wavelet Based Image Denoising”, *IEEE Transactions on Image Processing*, vol. 11, no. 5, May 2002, 545-557.
- [85] J. Portilla, V. Strela, M. J. Wainwright, and E. P. Simoncelli, „Image denoising using Gaussian scale mixtures in the wavelet domain”, *IEEE Transactions on Image Processing*, vol. 12, no. 11, pp. 1338-1351, Nov 2003.
- [86] B. Goossens, A. Pizurica, W. Philips, „Image denoising using mixtures of projected Gaussian Scale Mixtures”, *IEEE Trans Image Process.* 2009.
- [87] M. Hanif and A. -K. Seghouane, „An effective image restoration using Kullback-Leibler divergence minimization”, 2014 IEEE International Conference on Image Processing (ICIP), Paris, France, 27-30 Oct. 2014.
- [88] M. Miller, N. Kingsbury, „Image Denoising Using Derotated Complex Wavelet Coefficients”, *IEEE Transactions on Image Processing*, vol. 17, no. 9, September 2008, 1500-1511.
- [89] S. Voloshynovskiy, O. Koval, and T. Pun, „Wavelet-based image denoising using non-stationary stochastic geometrical image priors,” in *ISJT/SPIE's Annual Symposium, Electronic Imaging 2003: Image and Video Communications and Processing V*, Santa Clara, CA, Jan 2003, pp. 675-687.

- [90] V. Strela, J. Portilla, and E. P. Simoncelli, „Image denoising using a local Gaussian scale mixture model in the wavelet domain,” in Proc SPIE 45th Annual Meeting, San Diego, CA, Jul 2000, pp. 363–371.
- [91] M. K. Mihçak, I. Kozintsev, and K. Ramchandran, „Spatially adaptive statistical modeling of wavelet image coefficients and its application to denoising,” in IEEE International Conference on Acoustics, Speech, and Signal Processing, vol. 6, Phoenix, AZ, Mar 1999, pp. 3253–3256.
- [92] P. Ishwar and P. Moulin, „On the Equivalence between Set Theoretic and Maxnet MAP Estimation”, IEEE Trans. on Signal Processing, Vol. 51, No. 3, pp. 698-713, March 2003.
- [93] K. Dabov, „Image and Video Restoration with Nonlocal Transform-Domain Filtering”, PhD Thesis, Department of Signal Processing at Tampere University of Technology, Finland.
- [94] P. R. Hill, A. M. Achim, D. R. Bull, M. E. Al-Mualla, „Dual-tree complex wavelet coefficient magnitude modelling using the bivariate Cauchy-Rayleigh distribution for image denoising”, Signal Processing, 105, 2014, 464-472.
- [95] M. Aharon, M. Elad, and A. Bruckstein, „K-SVD: An algorithm for designing overcomplete dictionaries for sparse representation”, *IEEE Transactions on Signal Processing*, 54, 4311–4322, 2006.
- [96] A. Isar, C. Nafornta, **G. Magu**, „Hyperanalytic Wavelet-Based Robust Edge Detection”, *Remote Sensing*, iunie 2021.
- [97] S. P. Ghael, A. M. Sayeed, R. G. Baraniuk, „Improved wavelet denoising via empirical Wiener filtering”, *Proc. SPIE* 1997, 389–399.
- [98] A. Isar, I. Firoiu, C. Nafornta, S. Moga, „SONAR Images Denoising”, *Sonar Syst.*, 2011.
- [99] M. Antonini, M. Barlaud, P. Mathieu and I. Daubechies, „Image coding using the wavelet transform”, *IEEE Trans. on Image Processing*, 1, 205–220, 1992.
- [100] R. H. Bamberg, S. L. Eddins and V. Nuri, „Generalized symmetric extension for size-limited multirate filter banks”, *IEEE Trans. on Image Processing*, 3, 82–86, 1994.
- [101] C. Brislawn, „Classification of symmetric wavelet transforms”, Los Alamos Tech. Report, 1993.
- [102] C. Brislawn, „A simple lattice architecture for even-order linear-phase perfect reconstruction filter banks”, *Proc. IEEE-SP Intl. Symp. Time-Frequency and Time-Scale Analysis*, Philadelphia, PA, 124–127, 1994.
- [103] B. V. Brower, „Low-bit-rate image compression evaluations”, *Proc. SPIE*, Orlando, FL, April 4–9, 1994.
- [104] R. W. Buccigrossi and E. P. Simoncelli, „Image compression via joint statistical characterization in the wavelet domain”, *IEEE Trans. on Image Processing*, 8(12), 1999.
- [105] A. Cohen, „Ondelettes, analyses multirésolutions et traitement numérique du signal”, Ph.D. thesis, Université Paris IX, Dauphine, 1990.
- [106] A. Cohen, I. Daubechies and J. -C. Feauveau, „Biorthogonal bases of compactly supported wavelets”, *Comm. Pure Appl. Math.*, 45, 1992.
- [107] E. L. Schwartz, A. Zandi, M. Boliek, „Compression with Reversible Embedded Wavelets,”
- [108] <http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.31.938>. [Accesat:11.11.2021].

- [109] I. Daubechies and J. Lagarias, „Two-scale difference equations I. Existence and global regularity of solutions”, *SIAMJ. Math. Anal.*, 22, 1388–1410, 1991.
- [110] G. M. Davis and A. Nosratinia, „Wavelet-based image coding: an overview”, *Applied and Computational Control, Signals and Circuits*, 1(1), 1998.
- [111] Tom Hopper, Fred Preston, "Compression of Grey-Scale FingerPrint Images", pp309-317, DCC'92 Data Compression Conference, IEEE Computer Society Press, Los Alamitos, Ca, 1992
- [112] P. Pawar, K. Shriwas, J. J. Gurav, A. Yadav, „Comparison between WDR & ASWDR Techniques using Image Compression with Different Wavelet,” *International Journal of Engineering Research & Technology (IJERT)* ISSN: 2278-0181, Special Issue, 2017.
- [113] R. A. Gopinath, J. E. Odegard and C. S. Burrus, „Optimal wavelet representation of signals and the wavelet sampling theorem”, *IEEE Transaction on Circuits & Systems II*, 41, 262–277, 1994.
- [114] P. N. Heller and Jr. R. O. Wells, „Spectral theory of multiresolution operators and applications, in *Wavelets: Theory, Algorithms, and Applications*”, Chui, C.K., Ed., Academic Press, San Diego, CA, 13–31, 1994.
- [115] https://www.researchgate.net/publication/272921899_An_extension_of_the_interscale_SURE-LET_approach_for_image_denoising/figures?lo=1.
[Accesat:10.10.2021]
- [116] A. Islam and W. A. Pearlman, „An embedded and efficient low-complexity hierarchical image coder”, *Proc. SPIE 3653, Visual Communications and Image Processing '99*, San Jose, CA, Jan. 1999.
- [117] H. Kiya, K. Nishikawa and M. Iwahashi, „A development of symmetric extension method for subband image coding”, *IEEE Trans. on Image Processing*, 3, 78–81, 1994.
- [118] M. Shen and C. C. Jay Kuo, „Artifact removal in low bit rate wavelet coding with robust nonlinear filtering”, *MMSp98*, 480–485, 1998.
- [119] W. Lawton, „Necessary and sufficient conditions for construction orthonormal wavelet bases”, *J. Math. Phys.*, 32, 57–61, 1991.
- [120] J. Li and S. Lei, „An embedded still image coder with rate-distortion optimization”, *IEEE Trans. on Image Processing*, 8(7), 913–924, 1999.
- [121] E. Majani and M. Lightstone, „Biorthogonal wavelets for image compression”, *Proc. 1994 Data Compression Conference*, Snowbird, Utah, 462, 1994.
- [122] S. Mallat, „A theory for multiresolution signal decomposition: the wavelet representation”, *IEEE Trans. PAMI*, 11, 674–693, 1989.
- [123] S. Mallat, „Multifrequency channel decomposition of images and wavelet models”, *IEEE Trans. on Acoust. Speech and Signal Processing*, 37(12), 2091–2110, 1989.
- [124] H. Malvar, „Progressive wavelet coding of images”, *Proc. of IEEE Data Compression Conference*, Salt Lake City, UT, 336–343, March 1999.
- [125] F. Mintzer, „Filters for distortion-free two-band multirate filter banks”, *IEEE Trans. on ASSP*, 626–630, 1985.
- [126] W. B. Pennebaker and J. L. Mitchell, „JPEG: Still Image Compression Standard”, Van Nostrand Reinhold, NewYork, 1993.
- [127] O. Rioul, „A discrete-time multiresolution theory”, *IEEE Trans. on Signal Processing*, 41, 2591–2606, 1993.
- [128] O. Rioul and M. Vetterli, „Wavelets and signal processing”, *IEEE Signal Processing Magazine*, 8(3), 14–38, 1991.

- [129] J. C. Russ, „The Image Processing Handbook”, CRC Press, Boca Raton, FL, 1995.
- [130] A. Said and W. A. Pearlman, „Image compression using the spatial-orientation tree”, *IEEE Int. Symp. on Circuits and Systems*, Chicago, IL, 279–282, 1993.
- [131] A. Said and W. A. Pearlman, „An image multi-resolution representation for lossless and lossy image compression”, *IEEE Trans. Image Processing*, 5(9), 1303–1310, 1996.
- [132] J. M. Shapiro, „Embedded image coding using zerotrees of wavelet coefficients”, *IEEE Trans. on Signal Processing*, 41, 3445–3462, 1993.
- [133] Y. Shoham and A. Gersho, „Efficient bit allocation for an arbitrary set of quantizers”, *IEEE Trans. on ASSP*, 36, 1445–1453, 1988.
- [134] M. J. T. Smith and T. P. Barnwell, „Exact reconstruction techniques for treestructured subband coders”, *IEEE Trans. ASSP*, 434–441, 1986.
- [135] M. J. T. Smith and S. Eddins, „Analysis-synthesis techniques for subband image coding”, *IEEE Trans. ASSP*, 38, 1446–1456, 1990.
- [136] G. Strang, „Wavelets and dilation equations”, *SIAM Review*, 31, 614–627, 1989.
- [137] Pradip Kumar Sarkar, Driver Assistance Technologies, Open access peer-reviewed chapter, IntechOpen 2020, DOI: 10.5772/intechopen.94354, <https://www.intechopen.com/chapters/73821>. [Acces:09.11.2021]
- [138] P. P. Vaidyanathan, „Multirate Systems and Filter Banks”, Prentice-Hall, Englewood Cliffs, NJ, 1993.
- [139] P. P. Vaidyanathan and P. Q. Hoang, „Lattice structures for optimal design and robust implementation of two-channel perfect-reconstruction QMF banks”, *IEEE Trans. on ASSP*, 36, 81–94, 1988.
- [140] J. Tian and Jr. R. O. Wells, „A lossy image codec based on index coding”, *IEEE Data Compression Conference*, DCC '96, 456, 1996.
- [141] J. Tian and Jr. R. O. Wells, „Embedded image coding using wavelet-difference reduction, in Wavelet Image and Video Compression, Topiwala”, P., Ed., 289–301, Kluwer Academic, Norwell, MA, 1998.
- [142] J. Tian, R. O. Wells, Jr., „Image data processing in the compressed wavelet domain”, *3rd International Conference on Signal Processing Proc.*, Yuan, B. and Tang, X., Eds., 978–981, Beijing, China, 1996.
- [143] M. Vetterli, „Multidimensional subband coding: some theory and algorithms”, *Signal Processing*, 6, 97–112, 1984.
- [144] L. Villemoes, „Energy moments in time and frequency for two-scale difference equation solutions and wavelets”, *SIAM J. Math. Anal.*, 23, 1519–1543, 1992.
- [145] J. S. Walker, „A lossy image codec based on adaptively scanned wavelet difference reduction”, July 2000, *Optical Engineering* 39(7):715-836
- [146] Umhara Rasool, Sanna Mairaj, Tamanna Nazeer, Suhaib Ahmed, „Wavelet Based Image Compression Techniques: Comparative Analysis and Performance Evaluation”, *International Journal of Emerging Technologies in Engineering Research (IJETER)*, Volume 5, Issue 9, September 2017, 9-13.
- [147] G. K. Wallace, „The JPEG still picture compression standard”, *Comm. of the ACM*, 34(4), 30–44, 1991.
- [148] I. Witten, R. Neal and J. Cleary, „Arithmetic coding for compression”, *Comm. of the ACM*, 30(6), 1278–1288, 1986.
- [149] J. Woods and S.D. O’Neil, „Subband coding of images”, *IEEE Trans. on ASSP*, 34, 1278–1288, 1986.

- [150] J. N. Bradley and C. M. Brislawn, „The Wavelet /Scalar Quantization Compression Standard for Digital Fingerprint Images,”
- [151] https://www.nist.gov/system/files/documents/2020/09/03/11-wsq_bradley_brislawn_standard_ieee_iscs_-_19940530.pdf
[Accesat:11.11.2021]
- [152] K. Ramchandran, and M. Orchard, „Joint optimization of scalar and tree-structured quantization of wavelet image decomposition”, 27th Asilomar Conf., Pacific Grove, CA, November 1993.
- [153] W. R. Zettler, J. Huffman and D. Linden, „The application of compactly supported wavelets to image compression”, *Proc. SPIE*, 1244, 150–160, 1990.
- [154] E. Peli, „Contrast in complex images”, *J. Opt. Soc. Amer. A* 7(10) (1990) 2032–2040.
- [155] A. Beghdadi, A. Le Negrate, „Contrast enhancement technique based on local detection of edges”, *Comput. Vis. Graph. Image Process.* 46 (2) (1989) 162–174.
- [156] K. Zuiderveld, „Contrast limited adaptive histogram equalization”, in: *Graphics Gems IV*, 1994, pp. 474–485.
- [157] E. D. Pisano, S. Zong, B. M. Hemminger, M. DeLuca, R. E. Johnston, K. E. Muller, M. P. Braeuning, S. M. Pizer, „Contrast limited adaptive histogram equalization image processing to improve the detection of simulated spiculations in dense mammograms”, *J. Digit. Imaging* 11 (4) (1998) 193–200.
- [158] F. Lamberti, B. Montrucchio, A. Sanna, „CMBFHE: A novel contrast enhancement technique based on cascaded multistep binomial filtering histogram equalization”, *IEEE Trans. Consum. Electron.* 52(3) (2006) 966–974.
- [159] A. M. Reza, „Realization of the contrast limited adaptive histogram equalization (CLAHE) for real-time image enhancement”, *VLSI Signal Process.* 38 (1) (2004) 35–44.
- [160] Q. Wang, R. Ward, „Fast image/video contrast enhancement based on weighted thresholded histogram equalization”, *IEEE Trans. Consum. Electron.* 53(2) (2007), 757–764.
- [161] R. Lakshmanan, M.S. Nair, M. Wilscy, R. Tatavarti, „Automatic contrast enhancement for low contrast images: A comparison of recent histogram based techniques”, in: *International Conference on Computer Science and Information Technology, IEEE Computer Society*, Los Alamitos, CA, USA, 2008, pp. 269–276.
- [162] K. Panetta, E. Wharton, S. Agaian, „Human visual system-based image enhancement and logarithmic contrast measure”, *IEEE Trans. Syst. Man Cybern. Part B: Cybern.* 38 (1) (2008) 174–188.
- [163] T. Arici, S. Dikbas, Y. Altunbasak, „A histogram modification framework and its application for image contrast enhancement”, *IEEE Trans. Image Process.* 18 (9) (2009) 1921–1935.
- [164] T. Celik, T. Tjahjadi, „Contextual and variational contrast enhancement”, *IEEE Trans. Image Process.* 20 (12) (2011) 3431–3441.
- [165] M. Kaur, J. Kaur, J. Kaur, „Survey of contrast enhancement techniques based on histogram equalization”, *Int. J. Adv. Comput. Sci. Appl.* 2 (7) (2011) 137–141.
- [166] T. Iwanami, T. Goto, S. Hirano, M. Sakurai, „An adaptive contrast enhancement using regional dynamic histogram equalization”, in: *IEEE*

- International Conference on Consumer Electronics, ICCE, 2012, pp. 719–722.*
- [167] T. Celik, T. Tjahjadi, „Automatic image equalization and contrast enhancement using Gaussian Mixture Modeling”, *IEEE Trans. Image Process.* 21 (1) (2012) 145–156.
- [168] X. Wu, „A linear programming approach for optimal contrast-tone mapping”, *IEEE Trans. Image Process.* 20 (5) (2011) 1262–1272.
- [169] C. Gao, K. Panetta, S. Agaian, „A new color contrast enhancement algorithm for robotic applications”, *2012 IEEE International Conference on Technologies for Practical Robot Applications, TePRA, 2012, pp. 42–47.*
- [170] J. Short, J. Kittler, K. Messer, „A comparison of photometric normalisation algorithms for face verification”, in: *Proceedings of the Sixth IEEE International Conference on Automatic Face and Gesture Recognition, 2004, pp. 254–259.*
- [171] A. Jimenez-Sanchez, J. Mendiola-Santibanez, I. Terol-Villalobos, G. Herrera Ruiz, D. Vargas-Vazquez, J. Garcia-Escalante, A. Lara-Guevara, „Morphological background detection and enhancement of images with poor lighting”, *IEEE Trans. Image Process.* 18 (3) (2009) 613–623.
- [172] J.- L. Starck, F. Murtagh, E. Candès, D. Donoho, „Gray and color image contrast enhancement by the curvelet transform”, *IEEE Trans. Image Process.* 12 (6) (2003) 706–717.
- [173] Q. Li, X. Ni, G. Liu, „Ceramic image processing using the second curvelet transform and watershed algorithm”, in: *IEEE International Conference on Robotics and Biomimetics, ROBIO, 2007, pp. 2037–2042.*
- [174] N. Bonnier, E. Simoncelli, „Locally adaptive multiscale contrast optimization”, *IEEE International Conf. on Image Processing, vol. 1, ICIP, 2005, pp. I-949–I-952.*
- [175] J. Tang, E. Peli, S. Acton, S. Member, S. Member, „Image enhancement using a contrast measure in the compressed domain”, *IEEE Signal Process. Lett.* 10 (2003) 289–292.
- [176] J. Lu, D. Healy, „Contrast enhancement via multiscale gradient transformation”, in: *Proceedings of IEEE International Conference on Image Processing, vol. 2, ICIP-94, 1994, pp. 482–486.*
- [177] X. Zong, A. Laine, E. Geiser, „Speckle reduction and contrast enhancement of echocardiograms via multiscale nonlinear processing”, *IEEE Trans. Med. Imag.* 17 (4) (1998) 532–540.
- [178] S. Nercessian, S. S. Agaian, K. A. Panetta, „Multi-scale image enhancement using a second derivative-like measure of contrast”, in: *Image Processing: Algorithms and Systems X; and Parallel Processing for Imaging Applications II, Proc.SPIE 8295 (2012), pp.9.*
- [179] J. Lu, D. M. Healy, J. B. Weaver, „Contrast enhancement of medical images using multiscale edge representation”, *Opt. Eng.* 33 (07) (1994) 2151–2161.
- [180] H. Kaiqi, W. Zhenyang, W. Qiao, „Image enhancement based on the statistics of visual representation”, *Image Vis. Comput.* 23 (1) (2005) 51–57.
- [181] A. Mencattini, F. Caselli, M. Salmeri, R. Lojacono, „Wavelet based adaptive algorithm for mammographic images enhancement and denoising”, in: *Proceedings ICIP-05 (IEEE International Conference on Image Processing), vol. 1, 2005, pp. I-1141–I-1144.*

- [182] D. Heric, B. Potocnik, „Image enhancement by using directional wavelet transform”, in: *28th International Conference on Information Technology Interfaces*, 2006, pp. 201–206.
- [183] E. Nezhadarya, M. Shamsollahi, „Image contrast enhancement by contokeywordset transform”, in: *48th International Symposium ELMAR-2006 focused on Multimedia Signal Processing and Communications*, 2006, pp. 81–84.
- [184] M. Asmare, V. Asirvadam, L. Iznita, „Multi-sensor image enhancement and fusion for vision clarity using contokeywordset transform”, in: *International Conference on Information Management and Engineering, ICIME'09*, 2009, pp. 352–356.
- [185] K. Li, X. Chen, X. Hu, X. Shi, L. Zhang, „Image denoising and contrast enhancement based on nonsubsampled contourlet transform”, in: *2010 3rd IEEE International Conference on Computer Science and Information Technology (ICCSIT)*, vol.2,2010, pp.131–135.
- [186] A. Toet, „Multiscale contrast enhancement with applications to image fusion”, *Opt. Eng.* 31 (1992) 1026–1031.
- [187] T. Jinno, K. Mouri, M. Okuda, „HDR video tone mapping based on gamma blending”, in: *Proceedings of International Conference on Image Processing*, 2010, pp. 2521–2524.
- [188] G. Krawczyk, K. Myszkowski, H. -P. Seidel, „Perceptual effects in real-time tone mapping”, in: *Proceedings of the 21st Spring Conference on Computer Graphics, SCCG'05*, ACM, New York, NY, USA, 2005, pp. 195–202.
- [189] D. F. Rogers, „Procedural Elements of Computer Graphics”, 2nd ed., McGraw–Hill, 1997.
- [190] R. Mantiuk, K. Myszkowski, H. -P. Seidel, „A perceptual framework for contrast processing of high dynamic range images”, *ACM Trans. Appl. Percept.* 3 (3) (2006) 286–308.
- [191] P. Whittle, „Increments and decrements: Luminance discrimination”, *Vis. Res.* 26 (10) (1986) 1677–1691.
- [192] N. G. Kingsbury, „Image processing with complex wavelets”, *Philos. Trans. R. Soc. Lond. Ser. A Math. Phys. Eng. Sci.* 357 (1999) 2543–2560.
- [193] P. Hill, N. Canagarajah, D. Bull, „Image fusion using complex wavelets”, in: *Proc.13th British Machine Vis. Conf., BMVC-2002*, 2002, pp. 487–496.
- [194] A. Achim, A. Loza, D. R. Bull, C. N. Canagarajah, „Statistical modelling for wavelet domain image fusion”, in: T. Sthathaki (Ed.), *Image Fusion: Theory and Applications*, Academic Press, 2008, pp. 119–138.
- [195] A. Loza, D. Bull, N. Canagarajah, A. Achim, „Non-Gaussian model-based fusion of noisy images in the wavelet domain”, *Comput. Vis. Image Underst.* 114 (1) (2010) 54–65.
- [196] G. Samorodnitsky, M. S. Taqqu, „Stable Non-Gaussian Random Processes: Stochastic Models with Infinite Variance”, Chapman and Hall, New York, 1994.
- [197] C. L. Nikias, M. Shao, „Signal Processing with Alpha-Stable Distributions and Applications”, John Wiley and Sons, 1995.
- [198] A. Achim, D. Herranz, E. Kuruoglu, „Astrophysical image denoising using bivariate isotropic Cauchy distributions in the undecimated wavelet domain”, *Proceedings of International Conference on Image Processing*, vol. 2, 24–27 Oct. 2004, pp. 1225–1228.

- [199] R. Coifman, D. Donoho, „Time-invariant wavelet denoising”, A. Antoniadis, G. Oppenheim (Eds.), *Wavelet and Statistics*, in: *Lecture Notes in Statist.* vol. 103, Springer-Verlag, 1995, pp. 125–150.
- [200] P. J. Huber, „Robust estimation of a location parameter”, *Ann. of Math. Stat.* 35 (1) (1964) 73–101.
- [201] C. Shannon, „A mathematical theory of communication”, *Tech. Rep.*, Bell Syst.Tech. J. 27 (1948) 379.
- [202] Z. Wang, A. Bovik, H. Sheikh, E. Simoncelli, „Image quality assessment: From error visibility to structural similarity”, *IEEE Trans. Image Process.* 13 (4) (2004) 600–612.
- [203] C. Thum, „Measurement of the entropy of an image with application to image focusing”, *Opt. Acta* 31 (1984) 203–211.
- [204] B. Funt, F. Ciurea, J. McCann, „Retinex in matlab”, in: *Proceedings of the IS&T/SID Eighth Color Imaging Conference: Color Science, Systems and Applications*, 2000, pp. 112–121.
- [205] D. Sheet, H. Garud, A. Suveer, M. Mahadevappa, J. Chatterjee, „Brightness preserving dynamic fuzzy histogram equalization”, *IEEE Trans. Consum. Electron.* 56 (4) (2010) 2475–2480.
- [206] A. Loza, D. R. Bull, P. R. Hill and A. M. Achim, „Automatic contrast enhancement of low-light images based on local statistics of wavelet coefficients”, *Digital Signal Processing*, 23, 2013, 1856–1866.
- [207] A. Bovik, „Handbook of Image and Video Processing”, Academic Press, 2000.
- [208] C. Papageorgiou and T. Poggio, „A Trainable System for Object Detection”, *International Journal of Computer Vision* 38(1), 15C33, 2.
- [209] <http://cbcl.mit.edu/publications/ps/papageorgiou-poggio-IJCV-2000.pdf>.
[Accesat: 09.09.2021]
- [210] M. R. Gupta and N. P. Jacobson, „Wavelet Principal Component Analysis and its Application to Hyperspectral Images”, Department of Electrical Engineering, University of Washington.
- [211] D. F. Walnut, „An Introduction to Wavelet Analysis”, Department of Mathematical Science, George Mason University, pp. 116 – 159.
- [212] S. Lang, „Introduction to Linear Algebra”, Department of Mathematics, Yale University. pp.250 – 258.
- [213] J. Shlens, „A Tutorial on Principal Component Analysis”, Center for Neural Science, New York University.
- [214] L. Chiang, E. Russell and R. Braatz, „Fault diagnosis in chemical processes using fisher discriminant analysis, discriminant partial least squares, and principal component analysis,” *Chemometrics and Intelligent Laboratory Systems*, vol. 50, no. 2, pp. 243–252, Mar. 2000.
- [215] L. Chiang, M. Kotanchek and A. Kordon, „Fault diagnosis based on fisher discriminant analysis and support vector machines,” *Computers and Chemical Engineering*, vol. 28, no. 8, pp. 1389–1401, July 2004.
- [216] S. Roweis and L. Saul, „Nonlinear dimensionality reduction by locally linear embedding,” *Science*, vol. 290, no. 5500, pp. 2323–2326, Dec. 2000.
- [217] C. Li, B. Kuo, and C. Lin, „Lda-based clustering algorithm and its application to an unsupervised feature extraction,” *IEEE Transactions on Fuzzy Systems*, vol. 19, no. 1, pp. 152–163, Feb. 2011.
- [218] Y. Huang, J. Zhao et al., „Slow feature discriminant analysis and its application on handwritten digit recognition,” in *International Joint Conference on Neural Networks*, 2009, June 2009, pp. 1294–1297.

- [219] L. Wiskott and T. Sejnowski, "Slow feature analysis: unsupervised learning of invariances," *Neural Computation*, vol. 14, no. 4, pp. 715–770, Apr. 2002.
- [220] Y. Mo, Z. Zhang et al., "Random forest based coarse locating and KPCA feature extraction for indoor positioning system," *Mathematical Problems in Engineering*, vol. 2014, no. 1, pp. 1–8, Oct. 2014.
- [221] Y. Jiang and P. Liu, "Feature extraction for identification of drug and explosive concealed by body packing based on positive matrix factorization," *Measurement*, vol. 47, no. 1, pp. 193–199, Jan. 2014.
- [222] J. Zabalza, J. Ren et al., "Novel folded-pca for improved feature extraction and data reduction with hyperspectral imaging and sar in remote sensing," *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 93, no. 1, pp. 112–122, July 2014.
- [223] C. Li, H. Ho et al., "A semi-supervised feature extraction based on supervised and fuzzy-based linear discriminant analysis for hyperspectral image classification," *Applied Mathematics and Information Sciences*, vol. 9, no. 1, pp. 81–87, Feb. 2015.
- [224] X. Gu, C. Liu et al., "Uncorrelated slow feature discriminant analysis using globality preserving projections for feature extraction," *Neuralcomputing*, May 2015.
- [225] A. Godfrey, R. Conway, M. Leonard et al., "A continuous wavelet transform and classification method for delirium motoric subtyping," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 17, no. 3, pp. 298–307, June 2009.
- [226] G. Yu, C. Li, and S. Kamarthi, "Machine fault diagnosis using a cluster-based wavelet feature extraction and probabilistic neural networks," *The International Journal of Advanced Manufacturing Technology*, vol. 42, no. 1–2, pp. 145–151, May 2009.
- [227] H. Eristi, A. Ucar, and Y. Demir, "Wavelet-based feature extraction and selection for classification of power system disturbances using support vector machines," *Electric Power Systems Research*, vol. 80, no. 1, pp. 743–752, July 2010.
- [228] E. Avci, A. Sengur, and D. Hanbay, "An optimum feature extraction method for texture classification," *Expert Systems with Applications*, vol. 36, no. 3, pp. 6036–6043, Apr. 2009.
- [229] N. Saravanan and K. Ramachandran, "Incipient gear box fault diagnosis using discrete wavelet transform (dwt) for feature extraction and classification using artificial neural network (ann)," *Expert Systems with Applications*, vol. 37, no. 6, pp. 4168–4181, June 2010.
- [230] Y. Dong and J. Ma, "Wavelet-based image texture classification using local energy histograms," *IEEE Signal Processing Letters*, vol. 18, no. 4, pp. 247–250, Feb. 2011.
- [231] B. Shankar, S. Meher, and A. Ghosh, "Wavelet-fuzzy hybridization: Feature-extraction and land-cover classification of remote sensing images," *Applied Soft Computing*, vol. 11, no. 3, pp. 2999–3011, Apr. 2011.
- [232] H. Liu, C. Liu, and Y. Huang, "Adaptive feature extraction using sparse coding for machinery fault diagnosis," *Mechanical Systems and Signal Processing*, vol. 25, no. 2, pp. 558–574, Feb. 2011.
- [233] L. Guo, D. Rivero et al., "Automatic feature extraction using genetic programming: An application to epileptic eeg classification," *Expert Systems with Applications*, vol. 38, no. 8, pp. 425–436, Aug. 2011.

- [234] J. Seshadrinath, B. Singh, and B. Panigrahi, „Incipient interturn fault diagnosis in induction machines using an analytic wavelet-based optimized bayesian inference,” *IEEE Transactions on Neural Networks and Learning Systems*, vol. 25, no. 5, pp. 990–1001, May 2014.
- [235] H. Bafroui, A. Ohadi et al., „Application of wavelet energy and shannon entropy for feature extraction in gearbox fault detection under varying speed conditions,” *Neurocomputing*, vol.133, no. 1, pp. 437–445, June 2014.
- [236] G. Xian and B. Zeng, „An intelligent fault diagnosis method based on wavelet packer analysis and hybrid support vector machines,” *Expert Systems with Applications*, vol. 36, no. 10, pp. 12131–12136, Dec. 2009.74
- [237] L. Lin and J. Hongbing, „Signal feature extraction based on an improved emd method,” *Measurement*, vol. 42, no. 5, pp. 796–803, June 2009.
- [238] J. Huang, X. You et al., „Rotation invariant iris feature extraction using gaussian markov random fields with non-separable wavelet,” *Neurocomputing*, vol. 73, no. 4-6, pp. 883–894, Jan. 2010.
- [239] R. Khushaba, S. Kodagoda et al., „Driver drowsiness classification using fuzzy wavelet-packetbased feature-extraction algorithm,” *IEEE Transactions on Biomedical Engineering*, vol. 58, no. 1, pp. 121–131, Sept. 2010.
- [240] D. Wang, D. Miao, and C. Xie, „Best basis-based wavelet packet entropy feature extraction and hierarchical eeg classification for epileptic detection,” *Expert Systems with Applications*, vol. 38, no. 11, pp. 14314–14320, Oct. 2011.
- [241] G. Bin, J. Gao et al., „Early fault diagnosis of rotating machinery based on wavelet packets empirical mode decomposition feature extraction and neural network,” *Mechanical Systems and Signal Processing*, vol. 27, no. 1, pp. 696–711, Feb. 2012.
- [242] S. Li, W. Zu et al., „Feature extraction and recognition of ictal eeg using emd and svm,” *Computers in Biology and Medicine*, vol. 43, no. 7, pp. 807–816, Aug. 2013.
- [243] G. Deepa and R. Keerthi et al., „Face recognition using spectrum-based feature extraction,” *Applied Soft Computing*, vol. 12, no. 9, pp. 2913–2923, Sept. 2012.
- [244] B. Chen, Z. Zhang et al., „Fault feature extraction of gearbox by using overcomplete rational dilation discrete wavelet transform on signals measured from vibration sensors,” *Mechanical Systems and Signal Processing*, vol. 33, no. 1, pp. 275–298, Nov. 2012.
- [245] L. Han, C. Li et al., „Feature extraction method of bearing AE signal based on improved fast-ica and wavelet packet energy,” *Mechanical Systems and Signal Processing*, vol. 62-63, no. 1, pp. 91–99, Oct. 2015.
- [246] H. Wang, J. Chen et al., „Feature extraction of rolling bearings early weak fault based on eemd and tunable q-factor wavelet transform,” *Mechanical Systems and Signal Processing*, vol. 48, no. 1-2, pp. 103–119, Oct. 2014.
- [247] K. Poornima, A. Danti et al., „Novel feature extraction for face recognition using multiscale principal component analysis,” *International Journal of Computer Science and Engineering Communications*, vol. 2, no. 1, pp. 121–128, Feb. 2014.
- [248] N. Lu, Z. Xiao et al., „Feature extraction using adaptive multiwavelets and synthetic detection index for rotor fault diagnosis of rotating machinery,” *Mechanical Systems and Signal Processing*, vol. 52-53, no. 1, pp. 393–415, Feb. 2015.

- [249] J. Bennet, C. Ganaprakasam, and K. Arputharaj, „A discrete wavelet based feature extraction and hybrid classification technique for microarray data analysis,” *The Scientific World Journal*, vol. 2014, no. 1, pp. 1–9, July 2014.
- [250] Z. Wang, S. Bian et al., „Feature extraction and classification of load dynamic characteristics based on lifting wavelet packet transform in power system load modeling,” *International Journal of Electrical Power and Energy Systems*, vol. 62, no. 1, pp. 353–363, Nov. 2014.
- [251] S. Zhang, Y. Zhang, and J. Zhu, „Rolling element-bearing feature extraction based on combined wavelets and quantum-behaved particle swarm optimization,” *Journal of Mechanical Science and Technology*, vol. 29, no. 2, pp. 605–610, Feb. 2015.
- [252] M. Yuwono, Y. Qin, J. Zhou, Y. Guo, B. Celler, and S. Su, „Automatic bearing fault diagnosis using particle swarm clustering and hidden markov model,” *Engineering Applications of Artificial Intelligence*, Mar. 2015.
- [253] C. Nafornta, A. Isar, „Estimating Directional Smoothness of Images with the aid of the Hyperanalytic Wavelet Packet Transform,” *Proc. Internat. Conf. Signals Circuits and System*, Iasi, 2013.
- [254] I. Adam, C. Nafornta, J.M. Boucher and A. Isar, „A Bayesian Approach of Hyperanalytic Wavelet Transform Based Denoising”, *Proc. IEEE Int. Conf. WISP'07*, Alcalá de Henares, Spain.
- [255] O. Rioul, „Ondelettes régulières: application à la compression d'images fixes”, PhD thesis, ENST, Télécom Paris, Mar. 1993.
- [256] J. D. B. Nelson, N. G. Kingsbury, „Dual-Tree Wavelets for Estimation of Locally Varying and Anisotropic Fractal Dimension”, *Proc. IEEE Conf. on Image Processing ICIP 2010*, Hong Kong, 26-29 September 2010, 341-344.
- [257] C. -L. Stolojescu, Ph. D. thesis: A Wavelets Based Approach for Time-series Mining, Scientific Advisors: Professor Alexandru Isar, POLITEHNICA University of Timisoara, Professor Philippe Lenca, TELECOM Bretagne, January 2012.
- [258] B. Vidakovic, O. Nicolis, C. Garutti, „2-d Wavelet-based Spectra with Applications in Analysis of Geophysical Images”, *ASA Joint Statistical Meetings*, 2007.
- [259] P. Gajitzki, A. Isar, **G. Magu**, „A New Algorithm for Fractional Brownian Motion Processes Generation”, *Acta Technica Napocensis* 59 (1), 6-9.
- [260] M. A. Richards, J. A. Scheer, William A. Holm, „Principles of Modern Radar: Basic Principles”, *SciTech Publishing*, Edison, NJ, 2010.
- [261] H. Rohling, „Radar CFAR Thresholding in Clutter and Multiple Target Situations,” in *IEEE Transactions on Aerospace and Electronic Systems*, Vol. AES-19, Issue: 4, July 1983, 608-621.
- [262] E. Guizzo, „How Google’s self-driving car works,” *IEEE Spectr. Online*, vol. 18, Oct. 2011, <https://spectrum.ieee.org/how-google-self-driving-car-works>. [Accesat: 16.09.2021]
- [263] H. H. Meinel, „Evolving automotive radar: From the very beginnings into the future,” in *Proc. European Conf. Antennas and Propagation*, Hague, The Netherlands, 2014, pp. 3107–3114.
- [264] S. Kobashi, et al., „3D-Scan radar for automotive application,” in *Proc. ITS World Congr.*, Vienna, Austria, 2012, vol. 38, pp. 3–7.
- [265] I. Gresham, N. Jain, T. Budka, A. Alexanian, N. Kinayman, B. Ziegner, S. Brown, and P. Staecker, „A compact manufacturable 76-77-GHz radar module for commercial ACC applications,” *IEEE Trans. Microwave Theory Tech.*, vol. 49, no.1, pp. 44–58, Jan. 2001.

- [266] D. M. Grimes and T. O. Jones, „Automotive radar: A brief review,” *Proc. IEEE*, vol. 62, no. 6, pp. 804–822, June 1974.
- [267] J. Wenger, „Automotive radar: Status and perspectives,” in *Proc. IEEE Compound Semiconductor Integrated Circuit Symp.*, Palm Springs, CA, 2005, pp. 21–25.
- [268] F. Fölster and H. Rohling, „Signal processing structure for automotive radar,” *Frequenz*, vol. 60, no. 1/2, pp. 1–4, 2006.
- [269] J. Li and P. Stoica, „MIMO radar with colocated antennas,” *IEEE Signal Process. Mag.*, vol. 24, no. 5, pp. 106–114, Sept. 2007.
- [270] A. Isar, C. Nafornta, A. Macaveiu, **G. Magu**, „Wavelet Based Adaptive Detection of Automotive Radar Single Target with Low SNR,” in *Proceedings of 2020 International Symposium on Electronics and Telecommunications (ISETC)*, 5-6 Nov. 2020, Timisoara, Romania.
- [271] A. Macaveiu, C. Nafornta, A. Isar, A. Campeanu, I. Nafornta, „A Method for Building the Range-Doppler Map for Multiple Automotive Radar Targets”, *Proc. 11th International Symposium on Electronics and Telecommunications (ISETC)*, Timisoara, Romania, 2014, 151-156.
- [272] L. I. Perlovsky, R.W. Deming, „Maximum Likelihood Joint Tracking and Association in Strong Clutter”. *Int. J. Adv. Robot. Syst.* 2013, 10, 1–9.
- [273] K. Granström, M. Baum, S. Reuter, „Extended Object Tracking: Introduction, Overview and Applications,” *J. Adv. Inf. Fusion* 2017, 12, 139–174.
- [274] A. Tchamova, T. Semerdjiev, P. Konstantinova, J. Dezert, „Generalized Data Association for Multitarget Tracking in Clutter,” In *Advances and Applications of DSMT for Information Fusion (Collected works)*; Smarandache, F., Dezert, J., Eds.; American Research Press: Rehoboth, MA, USA, 2004; Volume 1, Chapter XIV; pp. 302–324.
- [275] **G. Magu**, R. Lucaciu, „Multiple Radar Targets Tracking and Trajectories Fitting,” *In Proceedings of the International Symposium on Electronics and Telecommunications (ISETc)*, Timisoara, Romania, 5–6 November 2020.
- [276] A. Macaveiu, A. Câmpeanu, I. Nafornta, „Kalman-Based Tracker for Multiple Radar Targets,” *In Proceedings of the 10th International Conference on Communications (COMM)*, Bucharest, Romania, 29–31 May 2014; pp.12–23.
- [277] **G. Magu**, R. Lucaciu and A. Isar, „Improving the Targets’ Trajectories Estimated by an Automotive RADAR Sensor Using Polynomial Fitting,” *Appl. Sci.* 2021, 11, 361.
- [278] H. W. Kuhn, „The Hungarian method for the assignment problem,” *Nav. Res. Logist. Q.* 2005, 52, 7–21.
- [279] B. R. Mahafza, „Radar Systems Analysis and Design Using Matlab”, Chapman & Hall/CRC, 2000.
- [280] A. Macaveiu, A. Câmpeanu, „Automotive Radar Target Tracking by Kalman Filtering”, *International Conference TELSIKS 2013*, Nis, Serbia, October 16-19, 2013.
- [281] **G. Magu**, R. Lucaciu and A. Isar, „Polynomial Based Kalman Filter Result Fitting to Data”, *Proceedings of 43rd International Conference on Telecommunications and Signal Processing (TSP)*, 7-9 July 2020, Milan, Italy
- [282] V. Katkovnik, K. Egiazarian, J. Astola, „Local Approximation Techniques in Signal and Image Processing”, *SPIE Press*, 2006.
- [283] <https://www.oceandatalab.com/ov/>. [Accesat:09.10.2021]