



Universitatea Politehnica Timișoara

Teză de Abilitare
Habilitation Thesis

*Rețele neuronale/neliniare celulare cu aplicații în prelucrări de
imagini și pentru navigația roboților mobili*

*Cellular neural/nonlinear networks with image processing
and mobile robot navigation applications*

Prof.dr.ing. GACSÁDI Alexandru

2017

Cuprins

A. Rezumatul tezei de abilitare	3
Rezumat (Ro).....	3
Abstract (En)	5
B.	
1. Realizări științifice, profesionale și academice în perioada 2001–2016	7
2. Descrierea tehnică a contribuțiilor științifice	11
2.1. Prelucrări de imagini bazate pe calcul variațional și utilizarea	
rețelelor neuronale/neliniare celulare	11
2.1.1. Rețele neuronale/neliniare celulare	11
2.1.2. Proiectarea bazată pe calcul variațional a unui template CNN	19
2.1.3. Metode CNN utilizate pentru reconstrucția unei imagini.....	25
2.1.4. Algoritm CNN omogen de estimare și compensare a mișcării	32
2.2. Prelucrarea unor imagini medicale.....	45
2.2.1. Îmbunătățire adaptivă a imaginilor utilizând rețele	
neuronale/neliniare celulare.....	46
2.2.2. Filtrarea zgomotului din imagini, bazată pe calcul variațional	
utilizând rețele neuronale/neliniare celulare.....	53
2.2.3. Segmentarea CNN a imaginilor.....	59
2.2.4. Clasificarea automată a tumorilor din imagini mamografice,	
bazată pe caracteristici direcționale.....	72
2.3. Utilizarea tehnologiei rețelelor neuronale celulare pentru	
navigația roboților mobili autonomi	76
2.3.1. Planificarea traiectoriei unui robot mobil în medii cu obstacole.....	76
2.3.2. Algoritm CNN de planificare simultană a traiectoriilor pentru doi	
roboți mobili	90
2.3.3. Coordonarea deplasării unei colectivități de roboți mobili	93
2.3.4. Mediu integrat pentru navigația unui robotul mobil.....	100
2.4. Sistem integrat pentru asistarea persoanelor cu deficiențe de	
vedere	106
2.4.1. Medii integrate pentru deplasarea persoanelor cu deficiențe de	
vedere.....	107
2.4.2. Algoritm CNN pentru calcularea corelației între două imagini	112
2.4.3. Implementarea FPGA a algoritmului CNN pentru corelația	
imaginilor	118
3. Planuri de evoluție și dezvoltare a carierei academice, științifice și	
profesionale	122
C. Bibliografie.....	125

Rețele neuronale/nelineare celulare cu aplicații în prelucrări de imagini și la navigația roboților mobili

Rezumat

În cadrul prezentei teze de abilitare sunt prezentate principalele realizări personale obținute în cercetarea științifică, activitatea didactică și academică, după susținerea publică a tezei și obținerea titlului de doctor al Universității Politehnica din Timișoara (2001).

Teza de abilitare este structurată pe trei părți:

- rezumatul, ce cuprinde sinteza tezei de abilitare redactat atât în limba română cât și în limba engleză;
- partea a doua, care se referă la realizările științifice, profesionale și academice, respectiv la planuri de evoluție și dezvoltare a carierei de cercetare și didactice;
- referințele bibliografice.

În cele de mai jos se descrie cea de a doua parte, care la rândul ei include trei capitole.

În primul capitol sunt prezentate succint principalele rezultate obținute în activitatea de cercetare științifică, didactică și academică: cursuri predate, discipline noi introduse în planul de învățământ și contribuțiile la dezvoltarea planurilor de învățământ, activitatea de îndrumare a proiectelor de diplomă și disertație, lista de lucrări și granturi/proiecte, dotare laboratoare, profesor invitat, inițierea de colaborări academice internaționale, activități de management, etc. În perioada 2001-2016 am publicat 79 de articole în reviste și la manifestări științifice naționale și internaționale, dintre care 27 de lucrări sunt indexate ISI și alte 22 de lucrări sunt indexate BDI, am elaborat 6 cărți și 4 îndrumătoare de laborator în domenii conexe prezentei teze, am participat în cadrul a 13 granturi/proiecte de cercetare câștigate prin competiție (la 6 dintre ele fiind și director de proiect) și la 4 contracte de cercetare cu mediul socio-economic.

Capitolul doi se referă la descrierea tehnică a contribuțiilor științifice rezultate în cele patru direcții de cercetare care au fost abordate de autor în perioada mai sus amintită:

- *Prelucrări de imagini bazate pe calcul variațional și utilizarea rețelelor neuronale/nelineare celulare.* Alături de alte procedee clasice, ca structuri de calcul paralel, rețelele neuronale/nelineare celulare (CNN - Cellular Neural/Nonlinear Networks) oferă soluții complementare de realizare în timp real a unor aplicații în domeniul prelucrării semnalelor. Este prezentată o modalitate originală de proiectare a unor template-uri, bazată pe calcul variațional, cu ajutorul cărora se pot efectua anumite procesări spațio-temporale ale imaginilor. Folosind template-uri dimensionate în acest mod, s-a analizat eficiența unor metode CNN în reconstrucția unei imagini deteriorate sau cunoscută parțial și s-a elaborat un algoritm CNN omogen de estimare și compensare a mișcării.
- *Prelucrarea unor imagini medicale.* Implementarea CNN a unor metode de prelucrare a imaginilor medicale nu este un scop în sine, astfel rezultă soluții pentru integrarea acestora într-un sistem de asistare în timp real a diagnozei medicale și/sau la urmărirea tratamentului. Sunt prezentate metode CNN originale de îmbunătățire adaptivă a contrastului, de filtrare a zgomotului, de segmentare a imaginilor medicale, în particular imagini computer tomografice (CT), care oferă creșterea vizibilității componentelor

imaginii în scopul interpretării acesteia cât mai ușoare de către expert. De asemenea, sunt descrise rezultatele studiului utilizării filtrelor de tip Gabor în clasificarea automată a țesuturilor mamare de tip normal, benign și malign. Pentru reducerea dimensiunii datelor s-a utilizat descompunerea în componente principale (*PCA - Principal Component Analysis*), iar ca și clasificator s-a folosit metoda vectorilor suport de tip proximal (*Proximal Support Vector Machines*).

▫ *Utilizarea tehnologiei rețelelor neuronale celulare pentru navigația roboților mobili autonomi.* Prin utilizarea tehnologiei CNN la comanda unui robot mobil, cu reacție vizuală bazată pe imagini, se asigură reducerea timpului de procesare a semnalelor și astfel, se poate obține o creștere a vitezei de deplasare. Algoritmul CNN pentru planificarea traiectoriei unui robot mobil furnizează acestuia, într-un mediu de lucru cu obstacole, traiectoria optimă din punct de vedere al lungimii și a numărului de viraje, între poziția de start și poziția țintei. Metoda propusă poate fi extinsă și pentru cazul navigației simultane a doi roboți mobili dar și la coordonarea deplasării unei colectivități de roboți mobili. Astfel, fiecare robot ocolește obstacolele întâlnite în cale precum și pe celălalt robot, dacă este necesar. În final, se prezintă un sistem integrat pentru deplasarea autonomă efectivă a unui robot mobil, într-un mediu real nestructurat. Pentru navigația robotului se propune o metodă hibridă care are în vedere combinarea optimă a celor două tipuri de navigații complementare, metoda globală și metoda locală.

▫ *Sistem integrat pentru asistarea persoanelor cu deficiențe de vedere.* Bazată pe evoluția spectaculoasă a tehnologiei electronice, prin dezvoltarea unui nou sistem integrat pentru asistarea persoanelor cu deficiențe de vedere se urmărește extinderea și îmbunătățirea performanțelor simultan cu creșterea preciziei și scăderea timpului de procesare. Pentru creșterea eficienței acestui sistem, se propune un algoritm CNN de calcul al corelației dintre două imagini. Acest algoritm a fost implementat, într-o variantă semi-paralelă, pe o platformă FPGA de emulare digitală a CNN-UM (*CNN Universal Machine*). Varianta propusă, de implementare semi-paralelă, conduce la obținerea unui raport optim între viteza de procesare și resursele hardware necesare.

De menționat că majoritatea subiectelor, grupate în cele patru direcții de cercetare, au fost abordate în cadrul unor granturi/proiecte de cercetare, naționale sau internaționale, la care am participat, în calitate de director sau membru. Principalele rezultate obținute, în legătură cu aceste direcții de cercetare, au fost publicate în peste 60 de articole, dintre care 25 de lucrări sunt indexate ISI și alte 20 de lucrări sunt indexate BDI.

În ultima secțiune se prezintă planurile de evoluție și dezvoltare în ceea ce privește cariera profesională, științifică și academică, precum și modalitățile avute în vedere pentru atingerea efectivă a acestor obiective. Sub deviza "sisteme electronice aplicate", direcția principală de cercetare se referă la elaborarea unor metode de analiză și prelucrare a semnalelor biomedicale și implementarea lor efectivă într-un sistem de asistare în timp real a diagnozei medicale și/sau la urmărirea tratamentului. Se va continua investigarea unor imagini CT și imagini mamografice, studiind, alături de *cellular wave computing*, și alte soluții noi de implementare.

Cellular neural/nonlinear networks with image processing and mobile robot navigation applications

Abstract

This habilitation thesis presents the main personal achievements obtained in scientific research, teaching and academic activity after getting the PhD degree at University Politehnica Timisoara (2001).

The habilitation thesis is structured as follows:

- the abstract, which includes the synthesis of the habilitation thesis, written both in Romanian and English;
- the second part, which covers the scientific professional and academic achievements, and future research and teaching career development plans;
- references.

The second part includes three chapters.

The first chapter briefly presents the main achievements in scientific research, teaching and academic work: courses taught, new subjects introduced in the curriculum and contributions to the development of curricula, mentoring diploma and dissertation projects, published papers list and grants / projects, equipped laboratories, visiting professor, initiating international academic collaboration, management activities, etc. Between 2001-2016 I have published 79 papers in scientific journals and at national and international workshops of which 27 are ISI indexed and other 22 are BDI indexed, I have written 6 books and 4 laboratory guides in fields related to the present thesis, I collaborated in 13 grants / research projects won by competition (in 6 of them being the project manager) and 4 research contracts with the socio-economic environment.

Chapter two covers the technical description of the scientific contributions obtained in the four research directions that were addressed by the author during the above-mentioned period of time:

- *Image processing based on variational computing and using of cellular neural/nonlinear networks.* Along with other classical methods, such as parallel computing structures, *Cellular Neural/Nonlinear Networks (CNN)* provides complementary solutions to achieve real-time signal processing applications. An original template design method based on variational computing is presented, which can be used to perform certain spatio-temporal processing of images. Using templates designed in this manner, the effectiveness of these CNN methods was analyzed in reconstruction a damaged or partially known image and a homogeneous CNN algorithm was developed for motion estimation and compensation.
- *Medical image processing.* CNN implementation of methods for medical image processing is not an aim by itself, but obtaining solutions to their integration into a real-time medical diagnosis support system and/or follow-up treatment. Original CNN methods are presented for adaptive contrast enhancement, noise filtering, segmentation of medical images, particularly computer tomography (CT) images, offering increased visibility of

image components in order to help the expert make the best possible interpretation of the image. Also the results of the study regarding the use of Gabor filters in the classification of normal, benign and malignant mammary tissue are presented. To reduce the size of the data *Principal Component Analysis (PCA)* was implemented, and as classifier the *Proximal Support Vector Machines* method was used.

▫ *Cellular neural networks technology using for autonomous navigation of mobile robots.* Using the CNN technology to mobile robot control, with on images based visual feedback, a reduction in processing time can be achieved and thus a movement speed increase can be obtained. The CNN path planning algorithm for a mobile robot in an environment with obstacles to find an optimal trajectory in terms of length and number of turns between the start and target positions. The proposed method can be extended to the case of simultaneous navigation of two of mobile robots and also to coordinate the movement of a collective of mobile robots. Thus, each robot avoids obstacles in its path as well as the other robot. Finally, an integrated system for effective self-propelled mobile robot in a real unstructured environment is presented. A hybrid method for robot navigation is proposed that takes into account the optimal combination of the two complementary types of navigations, e.g the global and local method.

▫ *Integrated system for assisting visually impaired people.* Based on the spectacular evolution of electronic technology, the development of a new integrated system for assisting visually impaired people in some typical every-day tasks. To increase the efficiency of this system, a CNN algorithm is proposed for calculating the correlation between two images. This algorithm has been implemented, in a semi-parallel version, on an emulated digital *FPGA* based platform of a *CNN-UM (CNN Universal Machine)*. The proposed semi-parallel implementation variant yields an optimal ratio between processing speed and required hardware resources.

It has to be noted that most topics, grouped into four directions of research were addressed in national or international grants/research projects, where my role was a principal investigator or member of a research team. The main obtained results in connection with these directions of research have been published in 60 articles, of which 25 are ISI indexed papers and 20 papers are BDI indexed.

The last section presents scientific, academic and professional career development plans, and methods envisaged to effective achievement of these objectives. Under the "applied electronic systems" head line, the main direction of research refers to the development of biomedical signal analysis and processing methods and their effective implementation in a real-time medical diagnosis helping follow-up treatment. The investigation of CT and mammographic images will be continued, alongside *cellular wave computing* and other new implementations.

1. Realizări științifice, profesionale și academice în perioada 2001-2016

Teza de doctorat, cu titlul ”*Contribuții la conducerea adaptivă a roboților prin prelucrarea informației vizuale utilizând rețele neuronale celulare*”, am susținut-o la data de 18.05.2001, la Facultatea de Electronică și Telecomunicații din cadrul Universității ”Politehnica” din Timișoara.

După obținerea titlului științific de doctor, magna cum laude, în domeniul ”Inginerie Electronică și Telecomunicații” (în baza Ordinului MEN 4202/27.07.2001), am devenit conferențiar universitar (din octombrie 2002), respectiv profesor universitar (din octombrie 2005), la Universitatea din Oradea, Facultatea de Inginerie Electrică și Tehnologia Informației, Departamentul de Electronică și Telecomunicații.

Activitatea didactică și profesională

Pe parcursul carierei mele academice am susținut activități didactice de curs și de laborator la mai multe discipline din domeniu. Actualmente desfășor activități didactice la următoarele discipline: *Bazele sistemelor de achiziție a datelor, Televiziune, Sisteme electronice în robotică, Electronică de putere*, (licență), respectiv *Aplicații ale rețelelor neuronale celulare* (masterat). La toate aceste discipline sunt asigurate materiale didactice adecvate (cărți, îndrumătoare de laborator, note de curs, prezentări, etc.) accesibile și în format electronic pe pagina web personală. Pentru cursuri folosesc și metode moderne de predare (prezentări și discuții interactive), iar la activitatea de laborator utilizăm deopotrivă experimente practice și metode de analiză bazate pe simulare. Fișele disciplinelor sunt elaborate, adaptate și actualizate periodic în conformitate cu standardele actuale și cerințele companiilor angajatoare.

Am elaborat și publicat ca autor unic sau ca și co-autor 6 cărți de specialitate: ”*Sisteme de achiziții de date*”, ”*Bazele televiziunii*”, ”*Rețele neuronale celulare. Aplicații*”, ”*Roboți mobili autonomi - Conducere cu rețele neuronale artificiale*”, ”*Structura și dinamica rețelelor dinamice complexe. Rețele neliniare celulare*”, ”*Informatică aplicată în electronică: teorie și aplicații*”. Acestea sunt utile atât studenților, ca suport de curs pentru disciplinele susținute la licență și master, cât specialiștilor din domeniile respective.

În colaborare cu alți colegi am elaborat 4 îndrumătoare de laborator: ”*Sisteme de achiziție a datelor*”, ”*Bazele televiziunii*”, ”*Bazele roboticii*”, ”*Electronică industrială*” și am realizat lucrări practice de laborator funcționale (circuite electronice și aplicații program) care sunt utilizate atât în activitatea didactică cât și în cea de cercetare.

Prin achizițiile de echipamente și tehnică de calcul, realizate în cadrul unor granturi/proiecte de cercetare naționale și internaționale în care am activat, s-a contribuit la îmbunătățirea nivelului de dotare al laboratorului (*Sisteme Electronice Aplicate*), unde se desfășoară activități didactice și de cercetare menționate anterior.

Am contribuit la dezvoltarea continuă a programelor de studii de licență: *Electronică Aplicată și Rețele și Software de Telecomunicații*. Am participat la introducerea și susținerea unor noi programe de studii de masterat: *Tehnologii audio-video și telecomunicații și Sisteme electronice avansate*. La toate aceste programe de studii, tutelate de Departamentul de Electronică și Telecomunicații, am participat la întocmirea rapoartelor de autoevaluare în vederea acreditării și reacreditării acestora. De asemenea, am contribuit activ la dezvoltarea, planurilor de învățământ pentru aceste programe de studii de licență și de master și la introducerea unor noi discipline, cum ar fi: *Aplicații ale rețelelor neuronale celulare*.

În fiecare an am condus lucrări de diplomă și de disertație, majoritatea dintre ele cu finalizare practică, unele dintre acestea fiind folosite în activitatea didactică de laborator. Am încurajat studenții să participe în echipe de cercetare și la sesiuni de comunicări științifice studentești. La pregătirea profesională a unor studenți a contribuit cooptarea lor în activitățile colectivului de cercetare *Sisteme Electronice Aplicate*.

În perioada 2011-2015 am predat cursuri la disciplinele: *Electronică și Senzori și actuatori*, la Facultatea de Inginerie, Universitatea din Debrecen, Ungaria.

Activitatea de cercetare

Am participat la înființarea *Centrului de Cercetare în Tehnologia Informației, Electronică și Automatică*, fiind primul director al acestuia (februarie 2008). În cadrul *Colectivului de Cercetare în Inginerie Electronică și Telecomunicații* am participat la introducerea și susținerea unor noi direcții de cercetare sub deviza ”*Sisteme Electronice Aplicate*” (*Aplicații utilizând rețele neuronale celulare, Comanda adaptivă a roboților*).

În perioada 2001-2016 am activat în cadrul a 13 granturi/proiecte de cercetare câștigate prin competiție (la 6 dintre ele fiind și director de proiect) și la 4 contracte de cercetare cu mediul socio-economic. De fapt, cele patru direcții de cercetare, care sunt prezentate în această teză de abilitare, au rezultat în urma abordării unor subiecte, în cadrul unor granturi/proiecte de cercetare naționale sau internaționale, de către echipele de cercetare din care am făcut parte în calitate de director sau membru.

Aceste direcții de cercetare se referă la:

- *Prelucrări de imagini bazate pe calcul variațional și utilizarea rețelelor neuronale/nelineare celulare*. Acest subiect a fost abordat în cadrul următoarelor granturi/proiecte de cercetare: Contract de cercetare Nr. 1120/2005, Institutul programelor de Cercetare al Fundației Sapientia, Cluj-Napoca, *Implementarea unor metode de îmbunătățire a imaginilor pe chip CNN-UM emulat digital*; Contract de cercetare Nr. 1446/2004, Institutul programelor de Cercetare al Fundației Sapientia, Cluj-Napoca, *Proiectarea unor metode de prelucrare a imaginilor utilizând rețele neuronale celulare și aplicații ale acestora*; Domus Hungarica Scientiarum et Artium, Hungarian Academy of Sciences, *Adaptive image enhancement by using cellular neural networks*, Research report, Image Processing and Neurocomputing Department, University of Veszprém, 2002.
- *Prelucrarea unor imagini medicale*. Această temă a fost investigată în cadrul proiectului de cercetare: PNCDI PN II, 2009-2010-2011, Idei 668/2008, Contract Nr. 645/19.01.2009,

Dezvoltarea unor metode de prelucrare și analiză a imaginilor computer tomografice utilizând rețele neuronale celulare și integrarea acestora într-un sistem de asistare a diagnozei medicale.

- *Utilizarea tehnologiei rețelelor neuronale celulare pentru navigația roboților mobili autonomi.* Acest subiect a fost studiat în cadrul proiectului de cercetare: Grant CNCSIS A 473/2006-2007, *Utilizarea tehnologiei rețelelor neuronale celulare pentru navigația roboților mobili autonomi.*

- *Sistem integrat pentru asistarea persoanelor cu deficiențe de vedere.* Această temă a fost abordată în cadrul proiectului de cercetare: Grant CNCSIS A 639/2005-2006-2007, *Mediu integrat pentru deplasarea asistată a persoanelor cu handicap vizual.*

Sintezele acestor proiecte de cercetare evidențiază caracterul interdisciplinar și capacitatea participanților, deopotrivă cadre didactice și studenți, de a gestiona în echipe de cercetare capacități și competențe diverse. Principalele rezultate obținute în investigarea acestor subiecte de cercetare au fost publicate în:

- cărți de specialitate publicate în edituri recunoscute: *”Rețele neuronale celulare. Aplicații”*, *”Roboți mobili autonomi - Conducere cu rețele neuronale artificiale”*, *”Structura și dinamica rețelelor dinamice complexe. Rețele neliniare celulare”*.

- reviste de specialitate recunoscute sau în volumele unor manifestări științifice internaționale din țară și străinătate, în peste 60 de articole, dintre care 25 de lucrări sunt indexate ISI și alte 20 de lucrări sunt indexate BDI.

De asemenea, o parte din rezultatele științifice obținute în cadrul acestor proiecte de cercetare au contribuit și la finalizarea tezelor de doctorat ale colegilor mei:

Gavriliuț Ioan, *”Contribuții la navigația roboților mobili autonomi utilizând rețele neuronale celulare”* Universitatea Politehnica Timișoara, 2007.

Țepelea Laviniu, *”Noi metode pentru deplasarea asistată în medii cu obstacole a persoanelor cu deficiențe de vedere”*, Universitatea Politehnica Timișoara, 2014.

Recunoașterea și impactul activității

Unele dintre lucrările pe care le-am publicat, ca autor unic sau ca și co-autor, au fost citate până în prezent în peste 129 de lucrări în reviste, cărți și volume ale unor manifestări științifice. Dintre acestea 38 de lucrări sunt indexate ISI și alte 91 de lucrări sunt indexate BDI.

În calitate de profesor invitat, am participat la:

- Programul *„Enhancing scientific research at the Pázmány Péter Catholic University”*, Ref.No.:TÁMOP-4.2.1.B-11/2/KMR-2011-0002, “Social Mobility Operative Programme” - ITK-BIONIKA, Budapest, October 25, 2013, prezentare invitată.

- *11th WSEAS International Conference on Recent Advances Automation & Information*, (ICAI '10), Iasi, Romania, June 13-15, 2010, prezentare invitată.

- Stagiul de cercetare, în domeniul rețelelor neuronale celulare, la *Departamentul de Prelucrări de imagini și calcul neuronal, din cadrul Universității Veszprém - Ungaria (2002).*

- Stagii Erasmus de predare la *Facultatea de Tehnologia Informației și Bionică, Universitatea Catolică "Pázmány Péter" Budapesta, Ungaria* (2009-2016) și la *Centrul de Cercetare și Aplicații în Prelucrarea Imaginii și Semnalului (CREATIS), la Institutul Național de Științe Aplicate din Lyon, Franța* (2010 și 2005).

În ceea ce privește activitatea de management al activităților didactice și de cercetare:

- Între anii 2001-2016, în diferite perioade, am fost membru în Consiliul Facultății de Inginerie Electrică și Tehnologia Informației, respectiv membru în Consiliul Departamentul de Electronică și Telecomunicații.
- Sunt: evaluator PNCDI, membru în Registrul Național al Evaluatorilor ARACIS, evaluator CEEPUS, auditor intern ARACIS la Universitatea din Oradea.
- Începând din anul 2009, sunt coordonatorul programului Erasmus+ între Universitatea din Oradea și Universitatea Catolică "Pázmány Péter", Facultatea de Tehnologia Informației și Bionică, Budapesta, Ungaria. În cadrul acestui program, au beneficiat de mobilități atât studenți cât și cadre didactice.
- Am făcut parte din comisii de evaluare a tezei de abilitare și a tezei de doctorat.
- În anul 2011 am primit Diplomă de Merit, pentru activitatea didactică și de cercetare științifică din partea Universității din Oradea.

Actualmente sunt membru în colectivele de redacție ale revistelor: *Journal of Electrical and Electronics Engineering, indexat Scopus, Journal International Review of Applied Sciences and Engineering, Publisher Akadémiai Kiadó* și fac parte din comitetul de organizare al conferințelor bianuale: *International Conference on Engineering of Modern Electric Systems*, anterior *International Conference on Advances in Electro-Technologies* și *International Conference on Renewable Sources and Environmental Electro-Technologies*.

Dintre participările mele, ca membru în comitete științifice/recenzor la conferințe internaționale respectiv reviste, din perioada 2010-2016, se pot aminti: *International Workshop on Cellular Nanoscale Networks and their Applications* (2016, 2014, 2012, 2010); *International Symposium of Circuits and Systems* (2016, 2015); *International Symposium on Electronics and Telecommunications, Timisoara, 2014*; *International Journal of Circuit Theory and Applications* (2013, 2012); *International Symposium on Signals Circuits and Systems* (2013, 2011); *European Conference on Circuit Theory and Design* (2013); *European Signal Processing Conference* (2012); *International Symposium on Nonlinear Theory and its Applications* (2011); *Journal of Circuits, Systems and Computers* (2011).

În prezent sunt membru al următoarelor asociații profesionale:

- Asociația Română de Robotică.
- Asociația Inginerilor Electricieni și Electroniști din România.
- Societatea Maghiară Tehnico-Științifică din Transilvania.

Doresc să subliniez că rezultatele obținute, pe parcursul anilor, în activitatea mea didactică, profesională și de cercetare științifică, sunt rodul muncii efectuate în veritabile echipe, din țară și străinătate. Printre membri acestor echipe s-au aflat unii dintre foștii mei profesori, colegi, studenți, în prezent unii dintre ei fiind colegi în Departamentul de Electronică și Telecomunicații din Oradea.

Cu deosebit respect, tuturor le mulțumesc pentru colaborare.

2. Descrierea tehnică a contribuțiilor științifice

2.1. Prelucrări de imagini bazate pe calcul variațional și utilizarea rețelelor neuronale/nelineare celulare

2.1.1. Rețele neuronale/nelineare celulare

Rețelele neuronale/nelineare celulare (*CNN - Cellular Neural/Nonlinear Networks*) (Chua and Yang 1988)¹, ca și structuri de calcul paralel, oferă soluții de realizare în timp real a unor aplicații în domeniul prelucrării semnalelor. Astfel, poate rezulta optimizarea performanțelor în ansamblu, a timpului de procesare și a preciziei prelucrării. În această secțiune se face o succintă prezentare generală a principalelor noțiuni legate de rețeaua neuronală/nelineară celulară și implementarea CNN a unei aplicații.

Rețeaua neuronală/nelineară celulară de bază

Rețeaua neuronală celulară/nelineară de bază are o structură bidimensională rectangulară, fiind formată din circuite analogice identice, nelineare, dispuse regulat, numite celule, care interacționează local între ele. În figura 2.1.1 se prezintă structura unei rețele neuronale/nelineare celulare de bază monostrat, cu M linii și N coloane, de dimensiune $M \times N$. Prin vecinătatea sau sfera de influență de rangul r a unei celule $C(i,j)$ se înțelege mulțimea:

$$N_r(i,j) = \{C(k,l) \mid \max\{|k-i|, |l-j|\} \leq r\}, \quad (2.1.1)$$

unde (i,j) reprezintă coordonatele spațiale carteziene ale celulei $C(i,j)$, $1 \leq i \leq M$; $1 \leq j \leq N$, r este un număr întreg pozitiv. Pentru o celulă $C(i,j)$ dimensiunea sferei de influență N_r de rază r este $(2r+1) \times (2r+1)$. În figura 2.1.1 este prezentată sfera de influență a unei celule $C(i,j)$ de rază $r=1$ (vecinătate 3×3).

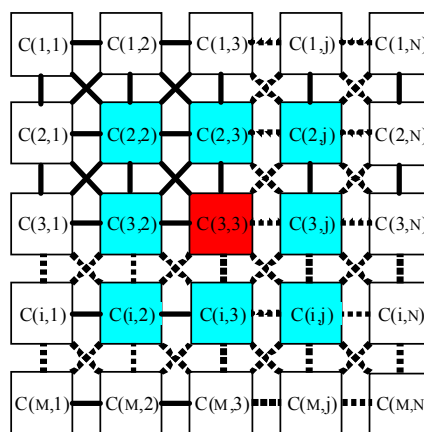


Figura 2.1.1: Structura de bază a unei rețele neuronale celulare monostrat cu M linii și N coloane.

¹ În limba română, pentru acest tip de rețea se folosește și denumirea de rețea celular nelineară (Dogaru et al. 2013).

Sistemul de vecinătăți prezintă proprietatea de simetrie, adică, presupunând că $C(i,j) \in N_r(k,l)$ atunci și $C(k,l) \in N_r(i,j)$, pentru oricare $C(i,j)$ și $C(k,l)$ din rețeaua neuronală celulară. Fiecare celulă a rețelei este conectată în mod direct numai cu acele celule din rețea care se află în sfera ei de influență. De remarcat faptul că, și celulele neconectate în mod direct pot comunica datorită efectului de propagare a interacțiunilor locale dintre celule, pe durata regimului tranzitoriu din rețea. Astfel, cu toate că interconectările dintre celule sunt numai locale, se constată că prin procesarea CNN a semnalelor pot fi extrase și proprietăți regionale și globale (Roska and Chua 1993). De asemenea, se poate observa că pentru $r=N-1$ și $M=N$ se obține rețeaua neuronală celulară complet conectată, în care fiecare celulă este conectată cu fiecare celulă, adică sfera de influență pentru o celulă este toată rețeaua. O celulă $C(i,j)$ se consideră a fi celulă internă a unei rețele dacă toate celulele $C(k,l) \in N_r(i,j)$ din vecinătatea acesteia sunt incluse în acea rețea. În caz contrar, celulele sunt de margine sau extreme.

Din punctul de vedere al implementării fizice a rețelei neuronale celulare, este important de semnalat că fiecărei celule $C(i,j)$ interne îi corespunde un circuit electric real, figura 2.1.2. În acest circuit electric neliniar se constată prezența a trei noduri caracterizate fiecare de câte o tensiune: tensiunea de intrare v_{uij} , tensiunea de stare v_{xij} și tensiunea de ieșire v_{yij} .

De asemenea, circuitul analogic include următoarele elemente:

- sursa de tensiune independentă E_{ij} , care constituie mărimea de intrare a celulei;
- o sursă de curent continuu independentă I , reprezentând polarizarea;
- sursele liniare de curent comandate în tensiune, I_{xu} , I_{xy} , și I_{yx} ;
- rezistențele R_x , R_y și o capacitate C . Valorile elementelor de circuit I , C , R_x , R_y sunt identici pentru fiecare celulă.




Figura 2.1.2: Structura circuitului electric pentru o celulă $C(i,j)$.

Sursele de curent I_{xu} , I_{xy} sunt comandate cu tensiunile de intrare v_{ukl} (reacție directă) respectiv cu tensiunile de ieșire v_{ykl} (reacția inversă) ale celulelor $C(k,l) \in N_r(i,j)$ din vecinătatea de rază r a celulei $C(i,j)$.

Valoarea curentului furnizat de sursele comandate este dată de relațiile:

$$I_{xu}(i,j;k,l) = B(i,j;k,l)v_{ukl}, \quad (2.1.2)$$

$$I_{xy}(i,j;k,l) = A(i,j;k,l)v_{ykl}. \quad (2.1.3)$$

A și B sunt operatori sinaptici. $A(i,j;k,l)$ se numește operatorul de comandă al ieșirii prin reacție inversă, denumit pe scurt operator de reacție, iar $B(i,j;k,l)$ este operator de comandă al intrării prin reacție directă, sau operator de comandă. Este limpede că operațiile de procesare pe care le realizează o rețea CNN sunt determinate de operatorii $A(i,j;k,l)$, $B(i,j;k,l)$ și respectiv curentul I .

În cazul implementării VLSI (*Very Large-Scale Integration*) a unor astfel de rețele neuronale/nelineare celulare se utilizează frecvent forma normalizată, în care elementele R_x , R_y și C din circuitul electric asociat unei celule au valori unitare, de asemenea și constanta de timp a regimului tranzitoriu: $\tau_{\text{CNN}}=C \cdot R_x=1$.

În scopul simplificării descrierii, în figura 2.1.3. este prezentată structura unei celule $C(i,j)$ din rețeaua neuronală/nelineară celulară standard, invariantă în spațiu care rezultă pe baza circuitului electric real.

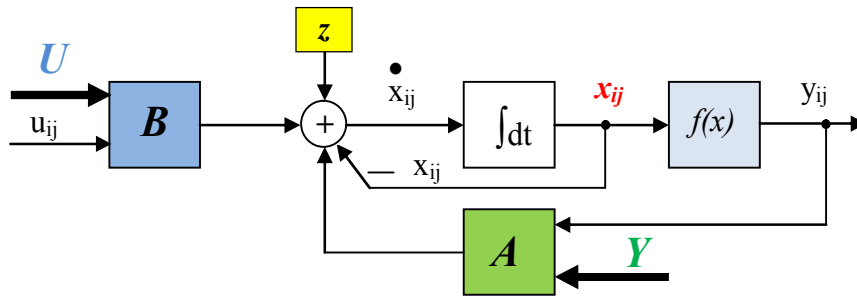


Figura 2.1.3: Structura unei celule C_{ij} .

Pentru această celulă x sau x_{ij} reprezintă starea, y_{ij} ieșirea și u_{ij} intrarea, $1 \leq i \leq M$; $1 \leq j \leq N$; $f(x)$ reprezintă funcția de transfer de la stare la ieșire:

$$f(x) = \frac{1}{2} [|x + 1| - |x - 1|]. \quad (2.1.4)$$

Reprezentarea grafică a funcției $f(x)$ de tip sigmoid, aproximată liniar pe porțiuni, este redată în figura 2.1.4.




Figura 2.1.4: Caracteristica de transfer $f(x)$.

Rețeaua neuronală celulară standard, invariantă în spațiu, este caracterizată prin ecuația diferențială de stare, atașată unei celule:

$$\dot{x} = -x_{ij} + A \otimes Y + B \otimes U + z, \quad (2.1.5)$$

unde s-a notat cu “ \otimes ” operația de convoluție spațială. Ansamblul format din operatorul de reacție, A , operatorul de control, B și polarizarea, z , formează așa numitul “template” CNN, având semnificația unor matrice de pondere sau de conexiune².

² Termenul „template” a fost preluat în limba română direct din literatura de limbă engleză. Frecvent, mărimile A , B , etc. sunt apelate tot prin termenul „template”. În acord cu semnificația reală și pentru a evita confuziile, în lucrarea de față aceste mărimi vor fi desemnate prin termenul de „operatori” (Gacsádi and Tiponut 2002).

O rețea neuronală celulară este invariantă în spațiu sau izotropică dacă operatorii A , B și z nu depind de indicii (i,j) . Un template CNN este liniar dacă A , B și z au toate elementele constante³.

Structura bidimensională a unei rețele neuronale de bază sugerează ideea asocierii acesteia cu o imagine, fiecare celulă corespunzând unui pixel. Mai mult decât atât, pot fi asociate imagini corespunzătoare stării rețelei ($STATE$), intrării ($INPUT$) și respectiv ieșirii ($OUTPUT$). În continuare se va utiliza pentru modelul unei rețele neuronale celulare această asociere cu imagini. În figura 2.1.5 este prezentată, circulația informației într-o rețea neuronală celulară standard, invariantă în spațiu, cu operatori de dimensiune 3×3 .

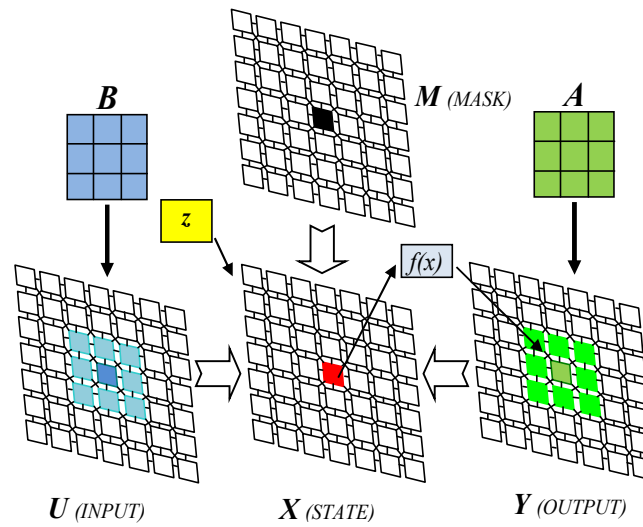


Figura 2.1.5: Circulația informației într-o rețea neuronală celulară standard, invariantă în spațiu, cu operatori de dimensiune 3×3 .

Operația pe care o realizează o rețea neuronală celulară asupra unei imagini de intrare $U(t_0)$, pentru obținerea unei imagini de ieșire stabilă Y , este complet definită de operatorii A , B , z , precizați la rândul lor prin cei 19 parametri. Aceste elemente alcătuiesc o instrucțiune elementară CNN. În modelul unei rețele neuronale celulare starea inițială a rețelei este asociată cu imaginea de stare la momentul inițial t_0 , adică cu $X(t_0)$, sau dacă se consideră $t_0=0$, $X(0)$.

Pentru o rețea neuronală celulară, ecuațiile de stare ale celulelor formează un sistem de ecuații diferențiale. Starea finală la ieșirea rețelei, rezultă prin rezolvarea acestui sistem. Rezolvarea ecuațiilor diferențiale ordinare și neliniare este posibilă numai dacă sunt cunoscute condițiile inițiale și de limită sau de frontieră (*boundary conditions*). Condițiile de frontieră se pot realiza prin conectarea unor celule virtuale la marginile rețelei, atât pentru imaginea de intrare, imaginea de stare cât și pentru imaginea de ieșire.

Celulele C_{kl} se numesc celule virtuale dacă $|k-i| \leq r$, $|l-j| \leq r$, dar $k \notin \{1,2,\dots,M\}$ și/sau $l \notin \{1,2,\dots,N\}$. Acelor celule li se asociază intrări virtuale u_{kl} , stări virtuale x_{kl} , ieșiri virtuale y_{kl} și polarizări virtuale z_{kl} , pentru ca sistemul de ecuații diferențiale

³ Pentru rețeaua celulară neuronală (RCN), având celulele identice, se poate folosi termenul „genă” pentru a descrie totalitatea parametrilor care definesc structura rețelei invariante în spațiu (Dogaru et al. 2013).

să devină compatibil. În cazul unei rețele neuronale celulare de dimensiune $M \times N$, includerea de celule virtuale presupune adăugarea a două linii și a două coloane virtuale. Cele două linii virtuale, una sus și una jos, vor avea indicele asociat pentru linii de 0 respectiv $M+1$. Cele două coloane virtuale, una în stânga și una în dreapta rețelei, vor avea indicele asociat pentru coloane de 0 respectiv $N+1$. Pentru a impune anumite condiții de frontieră, celulele virtuale vor fi forțate să aibă anumite valori, fapt ce se realizează prin conectarea lor la surse de tensiune. Sunt utilizate frecvent următoarele condiții de frontieră:

- condiții de frontieră în care celulele virtuale au valori constante (Dirichlet);
- condiția de frontieră zero-flux în care celulele virtuale repetă valorile din imediata lor vecinătate (Neuman).

Pentru respectarea condițiilor inițiale impuse unei rețele neuronale celulare, valorile elementelor de imagine se normalizează după cum urmează:

- în cazul unei imagini binare se asociază pentru nivelul alb valoarea -1 și valoarea $+1$ pentru nivelul negru al unui pixel;
- la o imagine cu niveluri de gri (*gray-scale*) se asociază pentru nivelul pixelilor de la alb la negru domeniul de valori $[-1, +1]$ (domeniul valorilor standard CNN).

Un template se consideră neliniar dacă oricare dintre elementele operatorului A este dependent de combinațiile valorilor de ieșire a celulelor respective și/sau dacă oricare dintre elementele operatorului B este funcție de combinațiile valorilor de intrare a celulelor. Practic unele elemente ale template-ului neliniar depind de indicii (i, j) ⁴.

Uneori se utilizează operatorul cel mai general, de tip $D_{ij,kl}$, care este de forma:

$$D_{ij,kl} = d(u_{ij}, x_{ij}, y_{ij}, u_{kl}, x_{kl}, y_{kl}).$$

În argumentul funcției d , între valorile de intrare, de stare și de ieșire a celulelor pot exista operațiile de adunare, scădere sau de produs.

Având în vedere tipurile de operatori prezentați mai sus, forma generală a ecuației diferențială de stare pentru rețeaua neuronală/neliniară celulară standard devine: (2.1.6)

$$\dot{x} = -x_{ijl} + \sum_{C_{kl} \in N_r} A_{ij,kl} * y_{kl} + \sum_{C_{kl} \in N_r} B_{ij,kl} * u_{kl} + z_{ij} + \sum_{C_{kl} \in N_r} C_{ij,kl} * x_{kl} + \sum_{C_{kl} \in N_r} D_{ij,kl}(u_{kl}, x_{kl}, y_{kl})$$

pentru $1 \leq i \leq M$; $1 \leq j \leq N$, i și j sunt coordonatele spațiale; M și N dimensiunile rețelei.

Evident, operatorul neliniar de reacție respectiv operatorul neliniar de comandă include operatorul liniar de reacție respectiv operatorul liniar de comandă.

De asemenea, operatorul neliniar generalizat $D_{ij,kl}$ include toți operatorii liniari și neliniari. Funcțiile a , b , c și d , care determină interacțiunile neliniare dintre celule, pot fi exprimate prin aproximare pe porțiuni, cu valori constante (*piecewise-constant* - pwc) respectiv variații liniare (*piecewise-liniar* - pwl).

⁴ În cazul rețelei celular neuronale (RCN) variante în spațiu, pentru multitudinea de gene și localizarea lor în spațiu se poate utiliza termenul „genom” (Dogaru et al. 2013).

Rețele neuronale/nelineare celulare particulare

Pornind de la caracteristicile rețelei neuronale/nelineare celulare de bază, au fost elaborate și alte variante de rețele neuronale/nelineare celulare particulare, care au dovedit o eficiență deosebită la procesarea spațio-temporală, în timp real, a semnalelor bidimensionale. Astfel, se îmbogățește și se extinde domeniul procesării CNN al semnalelor atât din punct de vedere teoretic cât și aplicativ, proces care continuă și în prezent.

Astfel, în cazul cel mai general, operatorii A , B , z , pot fi variabile în spațiu (valorile lor depind de coordonatele (i,j)) respectiv, se pot modifica și în funcție de variabila timp.

De exemplu, dacă mărimea de polarizare z_{ij} (*threshold*, *bias* sau *current*) este dependentă de poziția celulei în rețea, rezultă o posibilitate suplimentară pentru a comanda rețeaua neuronală celulară. Imaginea de polarizare asociată B_s (*BIAS*) influențează regimul tranzitoriu al rețelei și prin urmare determină, alături de imaginile de intrare respectiv de stare, comportamentul rețelei.

În cazul unei rețele neuronale celulare de dimensiune $M \times N$, se asociază imaginii de stare, o imagine mască M (*MASK*), având aceeași dimensiune. Pentru anumite valori ale pixelilor din imaginea mască, nu se permite modificarea în timpul procesului de prelucrare a valorilor elementelor de imagine în pozițiile identice ale imaginii de stare (celule inactive).

De exemplu, considerând cazul unei imagini mască binare, pixelii din imaginea de stare își pot modifica valoarea în timpul procesului tranzitoriu (celule active), dacă în imaginea mască le corespunde în aceeași poziție un element cu valoare $+1$. Dacă în imaginea mască un pixel este de valoare -1 , elementul identic ca poziție din imaginea de stare nu-și va putea schimba valoarea. Valorile implicite pentru pixelii imaginii mască permit ca toate elementele din imaginea de stare să fie active.

Utilizarea celor două imagini, de mască și de polarizare, permite încorporarea în algoritmi CNN a unei adaptabilități spațiale, liniare în cazul imaginii B_s și nelineare în cazul imaginii M (Gacsádi and Tîponuț 2002).

Prin discretizare temporală, ecuația diferențială de stare a unei celule $C(i,j)$ poate fi aproximată cu o ecuație cu diferențe finite:

$$\frac{1}{h} [x_{ij}((n+1)h) - x_{ij}(nh)] = -x_{ij}(nh) + \sum_{C_{kl} \in N_r} A_{ij,kl} y_{kl}(nh) + \sum_{C_{kl} \in N_r} B_{ij,kl} u_{kl}(nh) + z_{ij} \quad (2.1.7)$$

În relația de mai sus, $t=nh$ este variabila discretă de timp, h este pasul de eșantionare iar n este un număr natural. Totodată, funcția de transfer de la ieșire $f(x)$, dată de relația (2.1.4), se modifică în consecință, astfel că mărimea la ieșire va rezulta conform relației:

$$y_{ij}(nh) = 0.5(|x_{ij}(nh) + 1| - |x_{ij}(nh) - 1|) \equiv f[x_{ij}(nh)] \quad (2.1.8)$$

pentru $1 \leq i \leq M; 1 \leq j \leq N$.

Pe baza acestor ecuații, operația realizată de rețea poate fi interpretată ca fiind similară unui filtru nelinear bidimensional, care transformă o imagine de stare $x(nh)$ într-o altă imagine $x[(n+1)h]$. Dacă operatorii (A, B, z) sunt invariанți în spațiu, filtrul este de asemenea invariant în spațiu. Deoarece filtrarea realizată între două momente discrete succesive se poate folosi doar la detecția de proprietăți locale, pentru extragerea de proprietăți regionale, respectiv globale, sunt necesare mai multe iterații.

Vecinătatea N_{nr} este de n ori mai mare decât vecinătatea N_r astfel încât pentru un număr n de iterații suficient de mare, vecinătatea N_{nr} , va cuprinde toată imaginea, indiferent de valorile coordonatelor (i,j) și a sferei de influență de rang r . Așadar, proprietatea de propagare oferă posibilitatea extragerii și a unor caracteristici regionale, respectiv globale ale imaginilor, cu păstrarea proprietăților locale, vecinii apropiați având efecte mai puternice comparativ cu vecinii mai îndepărtați.

Pentru funcțiile de transfer de la stare către ieșire, pot fi folosite în afară de funcția sigmoid, aproximată liniar pe porțiuni, și alte funcții, cum ar fi: funcția sigmoid, funcția Gauss, funcția signum.

Noțiunile definite în cazul rețelelor bidimensionale pot fi generalizate cu ușurință pentru cazul cu mai multe dimensiuni, rezultând astfel rețelele neliniare/neuronale celulare multistrat sau multidimensionale, având caracteristici similare cu cele ale rețelelor monostrat, cum ar fi spre exemplu, condițiile de atingere a stabilității. De asemenea, în majoritatea cazurilor, în toate straturile rețelei se utilizează valori identice pentru elementele R_x , R_y și C din circuitul electric asociat unei celule. Se poate observa cu ușurință că, dacă nu există operatori de reacție între straturi, funcția realizată de rețeaua CNN multistrat se poate implementa prin prelucrare secvențială cu o rețea CNN monostrat.

Implementarea CNN a unei aplicații

Rețelele neuronale/neliniare celulare sunt utilizate pentru soluționarea unor probleme în aplicații din cele mai diverse domenii din știință (*cellular wave computing - "calcul ondulatoriu"*) (Baatar et al. 2010).

Soluționarea cu metode CNN a unei probleme concrete se poate realiza numai după ce aceasta a fost transpusă în mediul CNN. Aceasta înseamnă că pentru fiecare operație de procesare dorită, trebuie elaborat template-ul potrivit. Prin urmare, proiectarea în domeniul rețelelor neuronale celulare înseamnă în primul rând dimensionarea de template-uri, adică determinarea setului de operatori corespunzător unei aplicații concrete (Gacsádi and Tîponuț 2002), (Tîponuț et al. 2010), (Dogaru et al. 2013).

Prin intermediul parametrilor unui template, dinamica rețelei neuronale/neliniare celulare trebuie astfel „acordată” încât pe baza ecuației diferențiale de stare asociată rețelei să realizeze tocmai prelucrarea dorită asupra imaginii de intrare și de stare. Pentru a ilustra dificultatea acestei probleme, trebuie avut în vedere că și în cazul cel mai simplu al unui template liniar de dimensiuni $3*3$, trebuie determinați, nu mai puțin de 19 parametri reali ($2*9+1$). De exemplu, metoda empirică de dimensionare a unui template se bazează în mod esențial pe intuiția proiectantului și se poate aplica cu succes numai în cazuri simple, existând însă și situații când nu se poate garanta găsirea soluției potrivite. Proiectantul trebuie să aibă experiență mare în procesarea imaginilor și în domeniul CNN, pentru a „specula” soluția optimă.

Pentru anumite aplicații complexe, nu este posibilă determinarea unui template care să asigure prelucrarea dorită într-o singură etapă și care să furnizeze un rezultat convenabil. În astfel de cazuri, un set de operatori nu este altceva decât o singură instrucțiune elementară iar

proiectarea CNN se transformă, de fapt, în programare CNN cu ajutorul mai multor instrucțiuni elementare sau subrutine, având la bază operatori existenți (**1999b), (** 2010). Programarea în mediul CNN, este facilitată de existența unei biblioteci software de template-uri și algoritmi care se dezvoltă și se revizuieste periodic, pe baza rezultatelor cercetărilor CNN din întreaga lume (** 2010).

Practic, în orice aplicație care se poate prezenta sub formă de algoritm este posibilă și utilizarea rețelelor neuronale/nelineare celulare. Însă, este evident că, deși procesarea CNN este aplicabilă în orice problemă, utilizarea acesteia nu este eficientă, față de prelucrarea numerică serială, decât într-o clasă restrânsă de probleme. În anumite situații este posibil ca vitezele de prelucrare a celor două metode să fie comparabile. Dacă problema de soluționat reprezintă o parte a unui algoritm complex, atunci alegerea unei variante dintre ele, procesarea CNN sau prelucrarea numerică serială, se face pe baza performanțelor în ansamblu ale celor două procedee, preferându-se o structură de prelucrare cât mai omogenă.

Procesarea CNN a semnalelor se poate efectua cu ajutorul unui simulator care rulează pe un PC; acest simulator poate fi de sine-stătător ca parte componentă a unui sistem de dezvoltare pentru aplicații CNN (“*CadetWin - CNN application development environment and toolkit under Windows*”) (**1999a), sau ca modul (*MATCNN - Analogic Simulation Toolbox for Matlab*) (Rekeczky 1997) al unui program de procesare dedicat, cum este mediul Matlab (*Matlab Tools and Development Environment*) (** Matlab). Pe de altă parte, interesul deosebit acordat pe plan mondial cercetării în domeniul rețelelor neuronale celulare are la bază mai ales posibilitatea implementării directe, complet paralele, a unei aplicații pe un chip CNN analogic în tehnologia VLSI (Linan et al. 1999) (Cembrano et al. 2003).

Evident, procesarea CNN a semnalelor cu ajutorul unui simulator este cea mai lentă soluție, în timp cea de a doua, implementarea directă, complet paralelă, pe un chip CNN analogic în tehnologia VLSI este cea mai rapidă. În același timp, chip-urile CNN analogice implementate VLSI sunt caracterizate prin dezavantaje majore legate de precizia relativ scăzută (7-8 biți) și sensibilitatea ridicată chiar și la cele mai mici variații de temperatură și tensiuni de alimentare.

Prin utilizarea mediului de dezvoltare CadetWin se pot realiza programe CNN cu ajutorul unui editor și interpretor în limbaj de nivel inferior (limbaj de asamblare specific AMC) (*AMC - Extended analogic macro code and interpreter*) (**1999b). Este important de semnalat faptul că aceste programe sunt unitare și compatibile sub aspectul rulării în mediul CadetWin, atât pe mijloacele de simulare software cât și pe chipul CNN analogic.

Actualmente, între cele două posibilități de implementare a unei aplicații CNN, amintite mai sus, există o alta intermediară, adică cea a realizării emulatorului digital CNN implementat FPGA (*Field Programmable Gate Array*) (Nagy et al. 2006), (** 2007). Prin această soluție se realizează un compromis între viteză și precizie, dar se asigură repetabilitate, reproductibilitate, flexibilitate, posibilitate de implementare CNN chiar a unor procedee complexe de prelucrare, dar și interfațare ușoară cu sistemele digitale. De asemenea, implementarea FPGA permite, nu numai utilizarea template-urilor nelineare, inclusiv de tip D, dar și realizarea unor structuri cu mai multe straturi. În acest sens, emulatorul digital CNN implementat cu FPGA optimizează performanțele procesării CNN în ansamblu.

2.1.2. Proiectarea bazată pe calcul variațional a unui template CNN

În domeniul cercetărilor privind prelucrarea și analiza imaginilor este cunoscută eficiența utilizării ecuațiilor diferențiale parțiale (*PDE - partial differential equation*), (Casellas et al. 1998), (Chan et al. 2003), (Angenent et al. 2006). Spre exemplu, astfel de prelucrări pot avea ca obiectiv: reducerea zgomotului din imagini (Mumford and Shah 1989), (Rudin et al. 1992), (Chan and Esedoglu 2005); interpolarea imaginilor și reconstrucția imaginilor deteriorate; îmbunătățirea adaptivă a imaginilor; operații bazate pe morfologie matematică; detecția și estimarea mișcării; segmentarea imaginilor, etc.

Prin utilizarea modelelor bazate pe ecuații diferențiale parțiale pot rezulta beneficii semnificative atât din punct de vedere teoretic cât și al preciziei prelucrării semnalelor. Astfel, rezultă o mai mare flexibilitate în modelarea unor fenomene dar și o mai ușoară implementare numerică.

Oricare ar fi însă prelucrarea semnalului, modelată prin PDE sau calcul variațional, rezultă inevitabil necesitatea unei puteri de calcul considerabile. În acest sens, ca structură paralelă de calcul, rețelele neuronale/nelineare celulare pot reprezenta o soluție alternativă, complementară, pentru realizarea unor aplicații în timp real în domeniul prelucrării semnalelor (Rekeczky et al. 1998), (Rekeczky 2002), (Gacsádi and Szolgay 2005), (Gacsádi et al. 2005), (Hillier et al. 2006), (Grava et al. 2010), (Gacsádi and Szolgay 2010). Reducerea semnificativă a timpului de calcul, datorat evident procesării paralele, se obține numai dacă algoritmul de prelucrare poate fi implementat pe o structură hardware paralelă, pe un CNN-UC (*CNN Universal Chip*) (Cembrano et al. 2003), care are la bază arhitectura unei CNN-UM (*CNN Universal Machine*) (Roska and Chua 1993).

Prelucrarea imaginilor bazată pe utilizarea ecuațiilor diferențiale parțiale

Se consideră o imagine cu niveluri de gri (*gray-scale*) $\Phi_0(x,y)$, $\Phi_0: \mathbf{R}^2 \rightarrow \mathbf{R}$,

$\Omega = \{(x,y): x \in [1,M], y \in [1,N], M \text{ și } N \in \mathbf{R}^+\}$ (Casellas et al. 1998).

Prelucrarea acestei imagini conform unui algoritm bazat pe un operator poate fi descrisă prin ecuația diferențială parțială:

$$\frac{\partial \Phi}{\partial t} = F [\Phi(x, y, t)], \quad (2.1.9)$$

unde s-a introdus un parametru artificial t , F fiind operatorul care caracterizează algoritmul de prelucrare dorit ($F: \mathbf{R}^2 \rightarrow \mathbf{R}$). În general funcția F depinde de imaginea inițială, de prima și a doua derivată spațială a acesteia. Imaginea finală, obținută după procesare, rezultă ca soluție a acestei ecuații diferențiale parțiale.

Prin formularea procesărilor de imagini cu ajutorul PDE există posibilitatea combinării ponderate a acestora. De exemplu, dacă două procesări distincte sunt descrise de ecuațiile:

$$\frac{\partial \Phi}{\partial t} = F_1 [\Phi(x, y, t)] \text{ și} \quad (2.1.10)$$

$$\frac{\partial \Phi}{\partial t} = F_2 [\Phi(x, y, t)], \quad (2.1.11)$$

rezultă o prelucrare complexă de imagini prin combinarea acestor ecuații sub forma:

$$\frac{\partial \Phi}{\partial t} = F_1 + \lambda F_2, \text{ unde } \lambda \in \mathbf{R}^+, \text{ reprezintă un parametru scalar.} \quad (2.1.12)$$

Ecuția diferențială parțială care realizează o anumită prelucrare asupra imaginii poate fi obținută în urma formulării variaționale echivalente ca rezultat al minimizării unei energii (funcții de cost):

$$\arg\{\text{Min}_{\Phi} E(\Phi)\}, \quad (2.1.13)$$

unde E este energie dată, iar F fiind derivata întâia a lui E . Pentru minimizarea lui E , Φ rezultă din condiția: $F(\Phi)=0$, ceea ce reprezintă soluția stabilă a ecuației:

$$\frac{\partial \Phi}{\partial t} = F(\Phi), \quad (2.1.14)$$

unde t este tot un parametru artificial introdus.

Un astfel de exemplu este integrala Dirichlet:

$$E(\Phi) = \int |\nabla \Phi|^2(x) dx, \quad (2.1.15)$$

care este asociată cu ecuația căldurii:

$$\frac{\partial \Phi}{\partial t}(x, t) = \nabla^2 \Phi(x). \quad (2.1.16)$$

Pe de altă parte, dacă F_1 și F_2 rezultă ca derivate de ordinul întâi ale funcțiilor de cost E_1 și E_2 o prelucrare complexă a unei imagini ca cea descrisă de ecuația (2.1.12) poate fi reformulată prin metodă variațională în urma minimizării energiei $\alpha E_1 + \lambda E_2$, cu ajutorul parametrilor scalari α și λ (α și $\lambda \in \mathbf{R}^+$) (Jähne 2002).

Prin ponderarea termenilor E_1 și E_2 , rezultă o prelucrare complexă între limitele descrise de rezultatele inițiale ale fiecărei prelucrări în parte. Evident, în general, este de dorit ca procesarea imaginii să se bazeze pe un număr cât mai mic de parametri impuși la începutul procesării și să fie dominante elementele deduse chiar din conținutul imaginii procesate.

Avantajul major al prelucrării imaginilor, bazată pe utilizarea ecuațiilor diferențiale parțiale PDE sau bazată pe calcul variațional, îl reprezintă posibilitatea realizării unor prelucrări complexe, obținute prin combinarea concomitentă a două sau mai multe procesări care au efecte diferite. În multe situații însă, implementarea efectivă a acestor metode de prelucrare a imaginilor este greoaie, mai ales datorită dificultății determinării parametrilor scalari. De asemenea, dacă crește numărul de termeni care sunt ponderați, crește și posibilitatea apariției unor erori grosolane, de aceea, eficiența acestor metode depinde de aplicația concretă, de natura imaginilor procesate, modelul PDE utilizat pentru prelucrare și de numărul parametrilor scalari de ponderare.

Dimensionarea bazată pe calcul variațional a unui template CNN

În general, includerea în aplicații a prelucrării semnalelor bazată pe utilizarea rețelelor neuronale/nelineare celulare este caracterizată printr-o puternică interdependență între dezvoltarea aspectelor teoretice și a modului efectiv de implementare a acestora, care este condiționat direct de nivelul de performanță al tehnologiei electronice actuale. Aceste două aspecte reprezintă două direcții de cercetare care se află nu numai într-o competiție continuă,

dar și într-o susținere reciprocă. Desigur, o a treia direcție de cercetare este chiar identificarea unor aplicații în care procedeele bazate pe utilizarea rețelelor neuronale/nelineare pot fi utilizate cu maximă eficiență, sub aspectul preciziei și procesării în timp real a semnalelor, ca urmare a unei optimizări globale care ține cont atât de aspectele teoretice dar și de modul efectiv de implementare.

Trebuie semnalat că, în comparație cu programarea unor procesoare numerice, într-o aplicație bazată pe utilizarea rețelelor neuronale/nelineare celulare este mult mai dificilă determinarea unui template CNN adecvat care să asigure tocmai o anumită prelucrare dorită. Față de procesarea CNN a imaginilor binare, un grad sporit de dificultate îl prezintă proiectarea unor template-uri cu care se pot prelucra imagini cu niveluri de gri. Pe de altă parte, în cazul unor aplicații complexe este dificil sau chiar imposibil de determinat un singur template, care să ofere soluția optimă dorită printr-un singur pas de prelucrare, chiar dacă s-ar utiliza și variante nelineare de template-uri ori rețele având structură multistrat. În astfel de situații, aplicația complexă se va descompune în obiective parțiale, care pot fi soluționate cu câte un singur template elementar, rezultând astfel un algoritm secvențial dar care include procesări paralele (Vilariño and Rekeczky 2005), (Tiponut et al. 2010). În acest sens, prezintă o importanță deosebită dezvoltarea continuă a bibliotecii software pentru aplicații care utilizează rețele neuronale/nelineare celulare la prelucrarea semnalelor (***) 2010).

În general, există diverse soluții pentru minimizarea unor funcții de cost prin care se pot modela diferite fenomene, procese, prelucrări de imagini. Adesea aceste soluții conduc la realizarea unor circuite electrice specifice care sunt dedicate unei aplicații particulare. Aceste structuri speciale de implementare VLSI sau hardware pot avea la bază elemente din teoria rețelelor nelineare celulare, (Vilariño and Rekeczky 2005), (Arena et al. 2005), (Dudek and Vilariño 2006). Dezavantajul unor astfel de abordări este că prin particularizarea soluției de implementare nu rezultă un template, care ulterior ar putea fi utilizat în cadrul unui algoritm analogic complex, implementat pe structura standard a rețelei neuronale/nelineare celulare.

În această secțiune se va prezenta o modalitate originală pentru dimensionarea unor template-uri, bazată pe calcul variațional, cu care se pot efectua anumite procesări elementare asupra imaginilor (Gacsádi and Szolgay 2001), (Gacsádi and Szolgay 2003), (Gacsádi and Szolgay 2005), (Gacsádi et al. 2009), (Gacsádi and Szolgay 2009). Pentru aceasta se va utiliza modelul standard general al unei celule din structura rețelei neuronale/nelineare celulare. Avantajul acestei metode analitice de proiectare este că poate ușura modul de implementare pe chip CNN și template-ul rezultat poate fi utilizat ulterior și în cadrul altor aplicații, devenind o nouă instrucțiune elementară CNN, inclusă în biblioteca software. De asemenea, se consideră că pentru implementarea hardware al template-urilor obținute sunt disponibile structuri de rețele nelineare celulare de tip emulator digital implementate FPGA. Această modalitate de implementare a procesării CNN permite, nu numai utilizarea template-urilor nelineare, inclusiv de tip D, dar și realizarea unor structuri cu mai multe straturi. De menționat, că metoda de proiectare propusă se poate extinde și în cazul unor circuite specifice care sunt dedicate unei aplicații particulare de prelucrare a imaginilor.

Proiectarea template-urilor CNN bazată pe calcul variațional permite diversificarea metodelor CNN de prelucrare a imaginilor și extinde domeniile de aplicabilitate ale acestora

rezultând posibilitatea de a verifica experimental, în timp real, a diverselor modele matematice pentru prelucrarea imaginilor.

Proiectarea template-urilor CNN bazată pe calcul variațional are la bază următoarele considerente și etape:

- Se va utiliza forma generală a ecuației diferențiale de stare pentru rețeaua neuronală/nelinară celulară standard:

$$\begin{aligned} \dot{x} = & -x_{ijl} + \sum_{C_{kl} \in N_r} A_{ij,kl} * y_{kl} + \sum_{C_{kl} \in N_r} B_{ij,kl} * u_{kl} + z_{ij} + \\ & + \sum_{C_{kl} \in N_r} C_{ij,kl} * x_{kl} + \sum_{C_{kl} \in N_r} D_{ij,kl}(u_{kl}, x_{kl}, y_{kl}) \end{aligned} \quad (2.1.17)$$

pentru $1 \leq i \leq M$; $1 \leq j \leq N$, i și j sunt coordonatele spațiale; M și N sunt dimensiunile rețelei; u_{ij} reprezintă intrarea, x_{ij} reprezintă starea, iar y_{ij} reprezintă ieșirea.

C_{kl} este vecinătatea pentru celula C_{ij} , cu $C_{kl} \in N_r$, unde N_r vecinătatea sau sfera de influență de rangul r :

$$N_r(i, j) = \{C(k, l) | \max\{|k - i|, |l - j|\} \leq r\} \quad (2.1.18)$$

Operatorul de reacție s-a notat cu $A_{ij,kl}$, $B_{ij,kl}$ reprezintă operatorul de comandă, iar z_{ij} semnifică polarizarea.

- Pentru asigurarea stabilității rețelei și menținerea în orice situație, atât a valorilor imaginii de stare x_{ij} cât și a valorilor imaginii de ieșire, în domeniul liniar $[-1, 1]$, condiția necesară și suficientă este:

$$\sum_{C_{kl} \in N_r} A_{ij,kl} y_{kl} + \sum_{C_{kl} \in N_r} B_{ij,kl} u_{kl} + z_{ij} + \sum_{C_{kl} \in N_r} C_{ij,kl} x_{kl} + \sum_{C_{kl} \in N_r} D_{ij,kl}(u_{kl}, x_{kl}, y_{kl}) \leq 1 \quad (2.1.19)$$

- Îndeplinindu-se condiția de mai sus, prin utilizarea doar a porțiunii liniare a funcției de transfer de la stare la ieșire, se asigură ca imaginea de ieșire să fie identică cu imaginea de stare, adică:

$$y_{ij} \equiv x_{ij} \quad (2.1.20)$$

- Obținerea în final a unei valori stabile pentru imaginea x_{ij}^* este echivalentă cu condiția:

$$\sum_{C_{kl} \in N_r} A_{ij,kl} y_{kl} + \sum_{C_{kl} \in N_r} B_{ij,kl} u_{kl} + z_{ij} + \sum_{C_{kl} \in N_r} C_{ij,kl} x_{kl} + \sum_{C_{kl} \in N_r} D_{ij,kl}(u_{kl}, x_{kl}, y_{kl}) \equiv x_{ij}^*, \quad (2.1.21)$$

unde $\lim_{t \rightarrow \infty} x_{ij}(t) = x_{ij}^*$ și $\left. \frac{dx_{ij}}{dt} \right|_{x_{ij}=x_{ij}^*} = 0$.

- La determinarea pe cale analitică a template-lui CNN se vor utiliza funcții de cost sau energii potrivite, pornind de la cele cunoscute deja din literatura de specialitate, dar pot rezulta și altele noi, mai eficiente, în urma combinării acestora. De asemenea, pot fi folosite și alte relații, cunoscute apriori, pentru a determina cât mai ușor elementele template-lui și atingerea minimului global al acestor energii.
- Asocierea termenilor din funcția de cost cu operatorii A , B , C sau D . În această etapă se au în vedere constrângerile tehnologice actuale ale template-urilor privind implementarea aplicațiilor CNN. Pentru a putea implementa cât mai ușor, în urma proiectării se preferă utilizarea unei structurii CNN monostrat și obținerea unor

template-uri liniare, eventual neliniare, dar cu dimensiuni 3*3; sunt mai puțin agreate template-urile cu dimensiuni 5*5, chiar dacă sunt liniare, respectiv acele template-uri care se pot implementa numai pe structuri CNN multistrat. De remarcat faptul că, prin utilizarea template-urilor neliniare de reacție, în decursul procesării imaginilor se pot extrage unele proprietăți locale și regionale ca urmare a propagării efectelor între vecini. De asemenea, se are în vedere că:

- Pentru satisfacerea condiției de stabilitate, parametrii scalari din funcțiile de cost trebuie să fie ponderați între 0 și 1.
- Prin utilizarea condiției de frontieră zero-flux pentru rețeaua CNN, practic nu mai sunt necesare cunoașterea condițiilor de frontieră.
- Uneori poate fi utilă utilizarea și a unei imagini mască.
- Ca modalitate efectivă de implementare a template-ului proiectat, deseori de tip neliniar, actualmente se poate opta doar pentru varianta emulatorului digital CNN implementat FPGA.

Procedura de proiectare a unui template implementat pe o structură CNN standard se poate extinde ușor și pentru alte structuri particulare de procesare paralelă de implementare, dar numai în urma identificării tuturor condițiilor inițiale specifice circuitelor respective.

Exemplu de proiectare al unui template CNN

Se consideră funcția de cost care asigură interpolarea spline cubică (Gacsádi and Szolgay 2001):

$$E_3(\Phi(p,q)) = \iint_{p,q \in \Omega} \left[\left(\frac{\partial^2 \Phi}{\partial p^2} \right)^2 + 2 \left(\frac{\partial^2 \Phi}{\partial p \partial q} \right)^2 + \left(\frac{\partial^2 \Phi}{\partial q^2} \right)^2 \right] dpdq, \quad (2.1.22)$$

$\Phi(p,q)$ este imaginea *gray-scale*, cu $\Phi: \mathbb{R}^2 \rightarrow \mathbb{R}$, și

$\Omega = \{(p,q): p \in [1,M], q \in [1,N], M \text{ și } N \in \mathbb{R}^+\}$.

Folosind abordarea cu diferențe finite, după discretizare spațială cu un pas de eșantionare h , identică pe linii și coloane, rezultă imaginea discretizată în spațiu, $\Phi(i,j)$:

unde, $\Phi: \mathbb{R}^2 \rightarrow \mathbb{R}$, pt. $1 \leq i \leq M$; $1 \leq j \leq N$, $\Delta i = h$ și $\Delta j = h$.

Pentru o celulă Φ , de coordonate (i,j) rezultă: (2.1.23)

$$\begin{aligned} \frac{\Delta^2 \Phi_{i,j}}{\Delta i^2} &= \frac{\Phi_{i+1,j} - \Phi_{i,j} - \Phi_{i,j} + \Phi_{i-1,j}}{h^2}, & \frac{\Delta^2 \Phi_{i,j}}{\Delta j^2} &= \frac{\Phi_{i,j+1} - \Phi_{i,j} - \Phi_{i,j} + \Phi_{i,j-1}}{h^2}, \\ \frac{\Delta^2 \Phi_{i,j}}{\Delta i \Delta j} &= \frac{\Phi_{i+1,j+1} - \Phi_{i+1,j} - \Phi_{i,j+1} + \Phi_{i,j}}{h^2}, & \frac{\Delta^2 \Phi_{i,j}}{\Delta i \Delta j} &= \frac{\Phi_{i,j} - \Phi_{i,j-1} - \Phi_{i-1,j} + \Phi_{i-1,j-1}}{h^2}; \\ \frac{\Delta^2 \Phi_{i,j}}{\Delta i \Delta j} &= \frac{\Phi_{i,j+1} - \Phi_{i-1,j+1} - \Phi_{i,j} + \Phi_{i-1,j}}{h^2}, & \frac{\Delta^2 \Phi_{i,j}}{\Delta i \Delta j} &= \frac{\Phi_{i+1,j} - \Phi_{i,j} - \Phi_{i+1,j-1} + \Phi_{i,j-1}}{h^2}. \end{aligned}$$

Prin discretizare, integrala se transformă în sumă și rezultă funcția de cost al cărui minim global se va determina pentru realizarea prelucrării dorite a unei imagini:

$$E_3(\Phi(i, j)) = \sum_{i=1}^M \sum_{j=1}^N \left[\left(\frac{\Delta^2 \Phi_{i,j}}{\Delta i^2} \right)^2 + 2 \frac{\Delta^2 \Phi_{i,j}}{\Delta i \Delta j} + \left(\frac{\Delta^2 \Phi_{i,j}}{\Delta j^2} \right)^2 \right]. \quad (2.1.24)$$

Folosind o altă formă a relației de mai sus: (2.1.25)

$$E_3(\Phi_{i,j}) = \sum_{i=1}^M \sum_{j=1}^N \frac{1}{h^2} \left[(\Phi_{i-1,j} - 2\Phi_{i,j} + \Phi_{i+1,j})^2 (\Phi_{i,j-1} - 2\Phi_{i,j} + \Phi_{i,j+1})^2 - \right. \\ \left. - (\Phi_{i+1,j+1} - \Phi_{i+1,j} - \Phi_{i,j+1} + \Phi_{i,j})(\Phi_{i,j} - \Phi_{i,j-1} - \Phi_{i-1,j} + \Phi_{i-1,j-1}) + \right. \\ \left. (-1)(\Phi_{i-1,j+1} + \Phi_{i,j} - \Phi_{i,j+1} - \Phi_{i-1,j})(-1)(\Phi_{i,j} + \Phi_{i+1,j-1} - \Phi_{i,j-1} - \Phi_{i+1,j}) \right]$$

valoarea variabilei Φ pentru care E_3 este minimă, rezultă din condiția:

$$\frac{\partial E_3(\Phi)}{\partial \Phi} = 0; \quad (2.1.26)$$

$$\frac{\Delta E_3}{\Delta \Phi_{i,j}} = \sum_{i=1}^M \sum_{j=1}^N \frac{1}{h^2} \left[-4(\Phi_{i-1,j} - 2\Phi_{i,j} + \Phi_{i+1,j}) - 4(\Phi_{i,j-1} - 2\Phi_{i,j} + \Phi_{i,j+1}) + \right. \\ \left. + \Phi_{i+1,j+1} - \Phi_{i+1,j} - \Phi_{i,j+1} + \Phi_{i,j} + \Phi_{i,j} - \Phi_{i,j-1} - \Phi_{i-1,j} + \Phi_{i-1,j-1} + \right. \\ \left. + \Phi_{i-1,j+1} + \Phi_{i,j} - \Phi_{i,j+1} - \Phi_{i-1,j} + \Phi_{i,j} + \Phi_{i+1,j-1} - \Phi_{i,j-1} - \Phi_{i+1,j} \right] = 0 \quad (2.1.27)$$

astfel:

$$\frac{\partial E_3}{\partial \Phi_{i,j}} = \sum_{i=1}^M \sum_{j=1}^N \frac{1}{h^2} (20\Phi_{i,j} - 6\Phi_{i-1,j} - 6\Phi_{i+1,j} - 6\Phi_{i,j} - 6\Phi_{i,j+1} + \\ + \Phi_{i+1,j+1} + \Phi_{i-1,j-1} + \Phi_{i-1,j+1} + \Phi_{i+1,j-1}) = 0 \quad (2.1.28)$$

respectiv: (2.1.29)

$$-\Phi_{i,j} + \frac{6\Phi_{i-1,j} + 6\Phi_{i+1,j} + 6\Phi_{i,j} + 6\Phi_{i,j+1} - (\Phi_{i+1,j+1} + \Phi_{i-1,j-1} + \Phi_{i-1,j+1} + \Phi_{i+1,j-1})}{20} = 0$$

Dar: $\Phi_{i,j} = y_{i,j}$, rezultă: (2.1.30)

$$-y_{i,j} + \frac{6y_{i-1,j} + 6y_{i+1,j} + 6y_{i,j-1} + 6y_{i,j+1} - (y_{i+1,j+1} + y_{i-1,j-1} + y_{i-1,j+1} + y_{i+1,j-1})}{20} = 0$$

Se observă că, în cazul utilizării acestei funcții de cost, în imaginea procesată de ieșire valoarea unui pixel, $\Phi_{i,j}$, depinde doar de valorile pixelilor din imediata lor vecinătate.

Astfel, în raport cu relația (2.1.21), în acest caz particular:

$$\sum_{C_{kl} \in N_r} B_{ij,kl} * u_{kl} = 0, \quad (2.1.31)$$

$$z_{ij} = 0, \quad (2.1.32)$$

$$\sum_{C_{kl} \in N_r} C_{ij,kl} * x_{kl} = 0, \quad (2.1.33)$$

$$\sum_{C_{kl} \in N_r} D_{ij,kl}(u_{kl}, x_{kl}, y_{kl}) = 0. \quad (2.1.34)$$

Pentru structura unui template A având dimensiunile 3*3, se va utiliza convenția de notare de forma:

$$A = \begin{pmatrix} a_{-1,-1} & a_{-1,0} & a_{-1,+1} \\ a_{0,-1} & a_{0,0} & a_{0,+1} \\ a_{+1,-1} & a_{+1,0} & a_{+1,+1} \end{pmatrix}. \quad (2.1.35)$$

Rezultă:

$$-x_{ij} + \sum_{C_{kl} \in N_r} A_{ij,kl} y_{kl} = -y_{ij} + \sum_{C_{kl} \in N_r} A_{ij,kl} y_{kl} = 0, \quad (2.1.36)$$

respectiv: (2.1.37)

$$\begin{aligned} -y_{ij} + \sum_{C_{kl} \in N_r} A_{ij,kl} y_{kl} = & -y_{i,j} + a_{-1,-1} y_{i-1,j-1} + a_{-1,+1} y_{i-1,j+1} + a_{+1,+1} y_{i+1,j+1} + a_{+1,-1} y_{i+1,j-1} + \\ & + a_{-1,0} y_{i-1,j} + a_{+1,0} y_{i+1,j} + a_{0,-1} y_{i,j-1} + a_{0,+1} y_{i,j+1} + a_{0,0} y_{i,j} = 0 \end{aligned}$$

Elementele necunoscute ale operatorului A rezultă prin identificarea coeficienților dintre expresiile de mai sus, descrise de relațiile (2.1.30) și (2.1.37): (2.1.38)

$$a_{-1,-1} = a_{-1,+1} = a_{+1,+1} = a_{+1,-1} = -0.05; \quad a_{-1,0} = a_{+1,0} = a_{0,-1} = a_{0,+1} = 0.3, \quad a_{0,0} = 0.$$

Rezultă template-ul denumit AINTPOL3:

$$A = \begin{pmatrix} -0.05 & 0.3 & -0.05 \\ 0.3 & 0 & 0.3 \\ -0.05 & 0.3 & -0.05 \end{pmatrix}. \quad (2.1.39)$$

AINTPOL3

2.1.3. Metode CNN utilizate pentru reconstrucția unei imagini

Reconstrucția unei imagini deteriorate ori cunoscute parțial

Reconstrucția sau restaurarea unei imagini deteriorate oarecare (*image inpainting*) este o problemă de interpolare în cazul în care se cunosc valorile doar la o parte din elementele imaginii care, de cele mai multe ori, sunt dispuse neregulat, și este necesară obținerea prin calcul a elementelor lipsă. Practic, unui observator care nu este familiarizat cu imaginea originală, nici nu observă că imaginea a fost restaurată. Imaginea de ieșire are aceleași dimensiuni și rezoluție ca și imaginea de intrare. Cele mai întâlnite aplicații pentru restaurare sunt folosite în cazul pozelor și filmelor deteriorate parțial. În același timp, prin reconstrucția unor imagini este posibil să se obțină și efecte speciale, eliminarea unor părți nedorite, texte sau obiecte (Bertalmio et al. 2000) (Oliveira et al. 2001), (Ballester et al. 2001).

Într-un prim pas, utilizatorul va selecta manual porțiunile imaginii care urmează a fi reconstituite. Apoi reconstrucția imaginii se va face automat, prin completarea acestor regiuni necunoscute pe baza informațiilor care rezultă din porțiunile cunoscute ale imaginii. Imaginea de ieșire are aceleași dimensiuni și rezoluție ca și imaginea de intrare (Bertalmio et al. 2001), (Chan and Shen 2001), (Shen 2003).

În domeniul reconstrucției digitale a imaginilor deteriorate sunt disponibile modele matematice complexe deosebit de performante bazate pe utilizarea ecuațiilor diferențiale parțiale (PDE) sau pe calcul variațional (Casellas et al. 1998), (Chan et al. 2003). Reconstrucția imaginilor deteriorate, prin procesare serială, este uneori greu de efectuat în

timp real, chiar dacă, și în acest mod, se dispune de putere de calcul din ce în ce mai semnificativă.

În principiu, pot exista similitudini în ceea ce privește modul de procesare a unei imagini în cazul reconstrucției și filtrarea acesteia. Totuși, aceste două procesări se diferențiază prin faptul că în cazul restaurării imaginii porțiunile necunoscute pot fi de dimensiuni mai mari care, în general, nu conțin nici o informație, în timp ce în cazul reducerii zgomotului, pixelii imaginii conțin informații dar care includ și zgomot aditiv (Rudin et al. 1992), (Chan and Shen 2001).

În această secțiune sunt prezentate metode CNN care se pot utiliza la reconstrucția unor imagini deteriorate ori cunoscute parțial (Gacsádi and Szolgay 2005), (Gacsádi 2010). Metodele prezentate au în vedere în primul rând posibilitatea implementării directe pe un chip CNN analogic, printr-un singur pas, cu template-uri liniare cu reacție, de dimensiuni 3*3 (Linan et al. 1999), (Cembrano et al. 2003). Astfel, în urma procesării complet paralele, se asigură reducerea timpului de calcul, indiferent de dimensiunile imaginilor.

Pentru creșterea eficienței reconstrucției CNN a unei imagini deteriorate este necesară și utilizarea unui template neliniar, care asigură creșterea ariei de propagare a proprietăților locale și a celor regionale, și astfel, se pot prelucra și imagini cu porțiuni necunoscute de dimensiuni mai mari. Procesările CNN prezentate, bazate pe utilizarea calculului variațional, permit combinarea lor ușoară, rezultând metode noi, originale. Implementarea acestor metode chiar și pe un chip CNN analogic este totuși posibilă prin realizarea unor algoritmi analogici CNN complecși (Rekeczky et al. 1998) sau se poate opta pentru varianta emulatorului digital CNN implementat FPGA (Nagy et al. 2006), (** 2007).

Metode CNN pentru reconstrucția unei imagini

Utilizând metoda descrisă la subcap.2.1.2, în cazul proiectării unei metode CNN pentru reconstrucția unei imagini deteriorate au rezultat următoarele constrângeri particulare:

- Pentru eliminarea necesității cunoașterii condițiilor de frontieră se utilizează condiția de frontieră de tipul zero-flux.
- Pentru a nu se permite modificarea valorilor elementelor de imagine care se cunosc la începutul procesării, dar care să permită calcularea valorilor elementelor de imagine necunoscute din porțiunea deteriorată, este necesară utilizarea unei imagini mască (figura 2.1.7b). De fapt, existența unei imagini mască presupune cunoașterea (sau identificarea) pozițiilor elementelor de imagine care trebuie calculate. Elemente corespunzătoare porțiunilor deteriorate au valoarea inițială zero. Imaginea care urmează a se prelucra, Φ_{IN} , se aplică pe starea rețelei, la momentul $t=0$ (figura 2.1.7c).

Reconstrucția unor imagini deteriorate se bazează pe un proces de netezire prin mediere (*smoothing*). În principiu oricare dintre metodele CNN de interpolare a semnalelor bidimensionale se pot utiliza la reconstrucția unor imagini deteriorate ori cunoscute parțial (Gacsádi and Szolgay 2001). Pentru interpolarea semnalelor bidimensionale se pot utiliza una din următoarele energii (funcții de cost) (Gacsádi and Szolgay 2005), (Gacsádi 2010):

$$E_1 = \iint_{p,q \in \Omega} [(\Phi - \Phi_{N_r})^2] dpdq \quad (2.1.40)$$

unde Φ_{N_r} reprezintă valoarea pixelilor în vecinătatea de rază r ;

$$E_2(\Phi(p,q)) = \iint_{p,q \in \Omega} \left[\left(\frac{\partial \Phi}{\partial p} \right)^2 + \left(\frac{\partial \Phi}{\partial q} \right)^2 \right] dpdq \quad (2.1.41)$$

$$E_3(\Phi(p,q)) = \iint_{p,q \in \Omega} \left[\left(\frac{\partial^2 \Phi}{\partial p^2} \right)^2 + 2 \left(\frac{\partial^2 \Phi}{\partial p \partial q} \right)^2 + \left(\frac{\partial^2 \Phi}{\partial q^2} \right)^2 \right] dpdq \quad (2.1.42)$$

Termenul de energie utilizat pentru netezire poate fi și integrala de variație totală (*TV - the total variation integrals*) din modelul de extragere a zgomotului din imagini, Rudin-Osher-Fatemi (Rudin et al. 1992):

$$E_4 = \beta E_\beta = \beta \iint_{p,q \in \Omega} |\nabla \Phi_0| dpdq = TV \quad (2.1.43)$$

unde β este un parametru scalar.

Pe baza minimizării acestor funcții de cost au rezultat template-urile care conțin numai termenul A de reacție, celelalte fiind nule ($B=0, z=0$). Cu ajutorul acestora prelucrarea CNN realizează o interpolare liniară, interpolare pătratică, interpolare spline cubică, respectiv extragere a zgomotului din imagini: (2.1.44)

$$A_1 = \begin{pmatrix} 0.125 & 0.125 & 0.125 \\ 0.125 & 0 & 0.125 \\ 0.125 & 0.125 & 0.125 \end{pmatrix}; \quad A_2 = \begin{pmatrix} 0 & 0.25 & 0 \\ 0.25 & 0 & 0.25 \\ 0 & 0.25 & 0 \end{pmatrix};$$

AINTPOL1 AINTPOL2

$$A_3 = \begin{pmatrix} -0.05 & 0.3 & -0.05 \\ 0.3 & 0 & 0.3 \\ -0.05 & 0.3 & -0.05 \end{pmatrix}; \quad A_{TV} = \begin{pmatrix} 0 & a & 0 \\ a & 0 & a \\ 0 & a & 0 \end{pmatrix}$$

AINTPOL3 OSRUFATV

unde $a = \beta \operatorname{sgn}(y_{ij} - y_{kl})$, $\beta \in [0, 1]$; ($B=0, z=0, C=0, D=0$)

Testarea reconstrucției CNN a unei imagini

Pentru testarea reconstrucției CNN a unei imagini deteriorate ori cunoscute parțial s-a folosit mediul de dezvoltare Matlab, sistemul de dezvoltare pentru aplicații CNN *CadetWin* (**1999a), inclusiv chip-ul CNN de 64*64 pixeli (Linan et al. 1999).

Oricare ar fi metoda aleasă de reconstituire a unei imagini deteriorate se dorește ca precizia reconstituirii să fie cât mai bună, dar în același timp să se poată reconstitui porțiuni necunoscute de dimensiuni cât mai mari din imaginea deteriorată (zone lipsă sau goluri), adică raza (distanța) de propagare prin interpolare să fie mare. Aceste două deziderate stau la baza evaluării metodelor propuse de reconstrucție a unei imagini deteriorate, de aceea s-au analizat doi parametri:

- Eroarea ER (criteriul preciziei) care rezultă prin comparația între imaginea reconstituită, Φ , și imaginea originală Φ_0 , (eventual obținută după o interpolare ideală). Pentru aceasta în experimentele prezentate în continuare, imaginile deteriorate utilizate Φ_{IN} , s-au obținut din imagini reale originale, Φ_0 , la care s-au anulat valorile corespunzătoare unei părți din elementele imaginii. În acest fel, erorile care rezultă în urma utilizării diferitelor metode se pot evalua cantitativ cu o măsură de tip:

$$ER = \sqrt{\frac{\sum_{\Omega} (\Phi_0(i, j) - \Phi(i, j))^2}{M * N}}, \quad 1 \leq i \leq M; \quad 1 \leq j \leq N \quad (2.1.45)$$

- Raza (distanța) de propagare, se poate analiza calitativ cu ajutorul imaginilor de eroare obținute cu relații de tip:

$$\Phi_{ER} = \Phi_0(i, j) - \Phi(i, j), \quad 1 \leq i \leq M; \quad 1 \leq j \leq N. \quad (2.1.46)$$

Pentru a analiza eficacitatea template-urilor propuse în reconstrucția unor imagini deteriorate care au goluri mari s-a folosit o imagine artificială (figura 2.1.6). Cele două goluri (zone lipsă) sunt situate în regiuni uniforme lipsite de zgomot, una de valoare pozitivă (0.70) și alta de valoare negativă (-0.70), pixelii din imagine având valori în domeniul standard CNN [-1, +1]. De fapt, se dorește ca unda CNN, prin care reconstruiește imaginea, să aibă raza de acțiune cât mai mare.

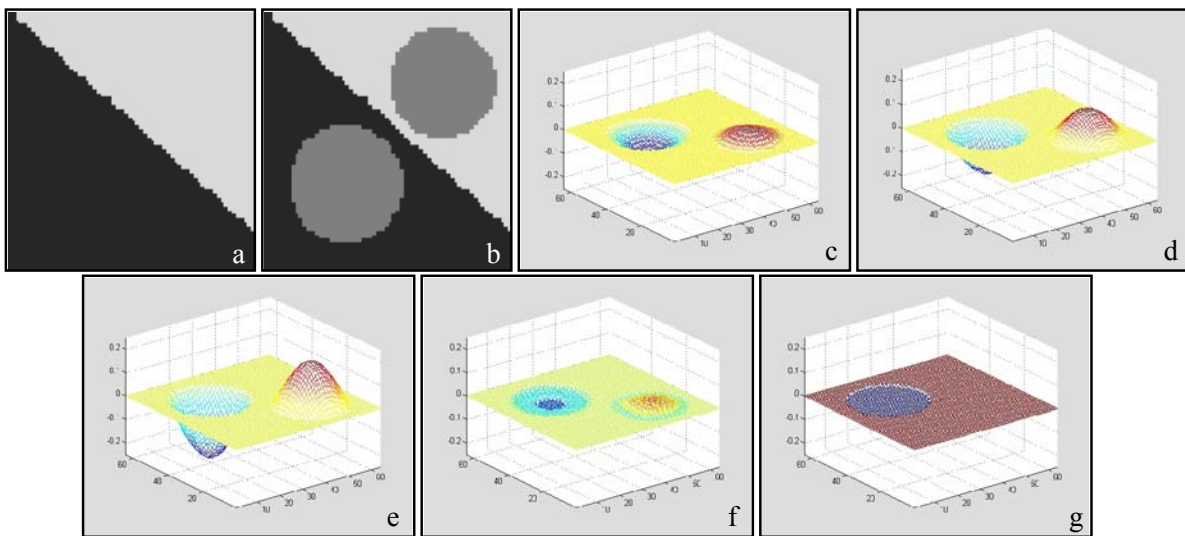


Figura 2.1.6: a) imaginea originală Φ_0 ; b) imaginea de reconstruit Φ_{IN} ; c) imaginea de eroare Φ_{ER1} pentru AINPOL1; d) imaginea de eroare Φ_{ER2} pentru AINPOL2; e) imaginea de eroare Φ_{ER3} pentru AINPOL3; f) imaginea de eroare Φ_{ER4} pentru OSRUFATV; g) imaginea de eroare Φ_{ER5} pentru NEL_AINTPOL3.

Tabelul 2.1.1. Erori ale unor metode CNN de reconstrucție a imaginilor deteriorate

<i>Template</i>	<i>Erori (ER)</i>	
	<i>Imagine cu porțiuni mari necunoscute</i>	<i>Imagine cu porțiuni mici necunoscute</i>
AINTPOL1	0.0219	0.0230
AINTPOL2	0.0558	0.0204
AINTPOL3	0.0823	0.0198
OSRUFATV	0.0092	0.0304
NEL_AINPOL3	0.0041	0.0200

Analizând imaginile și valorile erorilor ER (tabelul 2.1.1), dintre cele 4 template-uri descrise de rel. (2.1.44), se constată că la reconstrucția golurilor dintr-o imagine deteriorată cel mai bun comportament îl are template-ul OSRUFATV, cele mai mari erori rezultând cu AINTPOL3.

În figura 2.1.7 sunt prezentate rezultatele obținute cu metodele CNN propuse de autor la reconstrucția unei imagini la care elementele cu valori necunoscute sunt dispuse regulat pe linii și coloane (zonele necunoscute au dimensiuni mici).




Figura 2.1.7: a) imaginea originală Φ_0 ; b) imaginea mască; c) imaginea de reconstruit, Φ_{IN} ; d) imaginea de ieșire, Φ_{OUT} , pentru AINPOL1; e) imaginea de ieșire, Φ_{OUT} , pentru AINPOL2; f) imaginea de ieșire, Φ_{OUT} , pentru AINPOL3; g) imaginea de ieșire, Φ_{OUT} , pentru OSRUFATV; h) imaginea de ieșire, Φ_{OUT} , pentru NEL_AINPOL3; i) imaginea de ieșire, Φ_{OUT} , rezultată prin procesare pe chip CNN cu 64*64 pixeli utilizând AINTPOL3.

Evident, în cazul unei astfel de imagini, când zonele necunoscute au dimensiuni mici, se va analiza numai precizia reconstrucției, deoarece nu apare problema unei propagări insuficiente, spre deosebire de cazul imaginilor deteriorate cu goluri mari. Analizând imaginile din figura 2.1.7 și valorile erorilor ER, se constată că la reconstrucția imaginii deteriorată, de această dată, situația este chiar inversă față de cea anterioară, prezentată în figura 2.1.6. Astfel, cel mai bun comportament îl asigură template-ul AINTPOL3, cele mai mari erori realizându-se cu OSRUFATV. Pe de altă parte, utilizând AINTPOL3, AINTPOL2, AINTPOL1, erorile rezultate nu diferă esențial. Practic fiecare procedeu poate fi util, dar numai dacă se cunoaște caracterul imaginii deteriorate, deoarece nici o metodă nu este satisfăcătoare pentru orice situație.

Creșterea eficienței reconstrucției unei imagini deteriorate se poate obține prin combinarea și optimizarea celor două procedee care au avut comportamentul cel mai bun în cele două situații limite avute în vedere. Această metodă CNN pentru reconstrucția unei imagini poate fi formulată prin metoda variațională în urma minimizării energiei pe baza relației următoare:

$$E_s = \alpha E_\alpha + \beta E_\beta \quad (2.1.47)$$

Prelucrarea complexă, între limitele descrise de rezultatele inițiale ale fiecărei prelucrări în parte, rezultă tocmai din ponderarea termenilor, E_α și E_β , cu ajutorul parametrilor scalari subunitari α și β (α și $\beta \in \mathbb{R}^+$). Evident, este de dorit ca și reconstrucția unei imagini să se bazeze pe un număr cât mai mic de parametri impuși la începutul procesării și să fie dominante elementele deduse chiar din conținutul imaginii procesate. Ponderarea funcțiilor de cost cu ajutorul unor parametri scalari subunitari este necesară pentru respectarea condiției descrise de relația (2.1.19).

În cele din urmă, se poate constata că, cele două metode alese (AINTPOL3 și OSRUFATV) se completează reciproc, rezultând un comportament eficient pentru orice imagine, chiar și în oricare din situațiile limită (tabelul 2.1.1). Astfel, rezultă template-ul:

$$A = \begin{pmatrix} -0.05 & 0.3 & -0.05 \\ 0.3 & 0 & 0.3 \\ -0.05 & 0.3 & -0.05 \end{pmatrix} \quad D = \begin{pmatrix} 0 & a & 0 \\ a & 0 & a \\ 0 & a & 0 \end{pmatrix} \quad (2.1.48)$$

NEL_AINTPOL3

unde $a = \beta \text{sgn}(y_{ij} - y_{kl})$, $\beta \in [0, 1]$; ($\alpha=1$; $B=0$; $z=0$)

Rezultatele reconstrucției CNN a unor imagini deteriorate prin utilizarea template-ului NEL_AINTPOL3 sunt prezentate în figura 2.1.6g (eroarea) și figura 2.1.7h (imaginea reconstruită).

În figura 2.1.7i se poate observa imaginea de ieșire reconstituită prin interpolare pe chip CNN 64*64 cu pixeli (Linan et al. 1999) utilizând AINTPOL3. Timpul mediu complet de procesare include, alături de timpul efectiv de procesare la interpolare și timpii necesari pentru citirea imaginii din memorie respectiv pentru încărcarea și descărcarea imaginii pe chip precum și timpul necesar pentru afișarea imaginii. Din timpul total de procesare o parte semnificativă este utilizată pentru încărcarea și descărcarea imaginii pe chip. Dacă în cazul

unui chip CNN se consideră numai timpul efectiv de procesare la interpolare, pentru o constantă τ_{CNN} , ce caracterizează o celulă, de 250 ns (Linan et al. 1999), rezultă că prelucrarea analogică propriu-zisă pe chip a unei imagini cu dimensiunile identice cu al chip-ului durează cel mult $6,25\mu\text{s}$ (25 iterații* 250 ns) (Gacsádi and Szolgay 2001).

Imaginile deteriorate, din figurile 2.1.8b și 2.1.9a, au rezultat prin suprapunerea artificială a unor texte peste imaginile reale. După reconstituirea CNN, utilizând template-ul NEL_AINTPOL3, au rezultat imaginile prezentate în figura 2.1.8c și figura 2.1.9c.



Figura 2.1.8: a) imaginea originală Φ_0 ; b) imaginea care se va reconstitui Φ_{IN} ; c) imaginea de ieșire, Φ_{OUT} , reconstituită utilizând NEL_AINTPOL3.

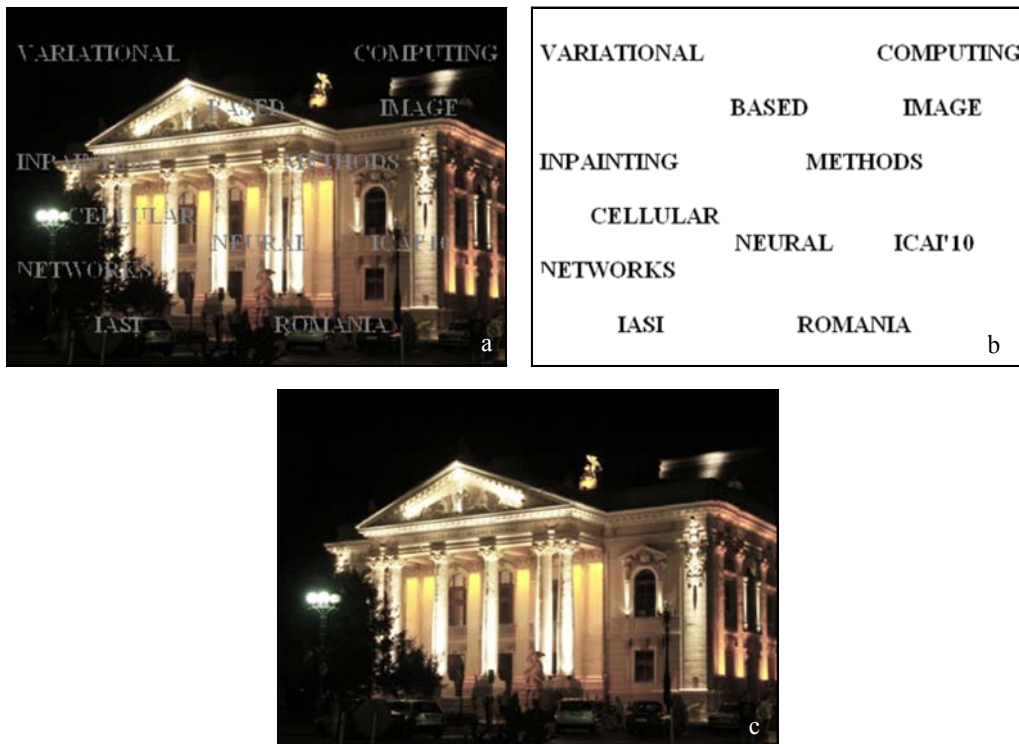


Figura 2.1.9: a) imaginea de intrare care se va reconstitui Φ_{IN} ; b) imaginea mască; c) imaginea de ieșire, Φ_{OUT} , reconstituită utilizând NEL_AINTPOL3.

2.1.4. Algoritm CNN omogen de estimare și compensare a mișcării

Implementarea CNN a metodei lui Horn & Schunck de estimare a mișcării

În această secțiune este prezentată implementarea paralelă a metodei Horn & Schunck de estimare a mișcării în secvențe de imagini, prin utilizarea rețelelor neuronale/nelineare celulare (CNN) (Gacsádi et al. 2006a). Pentru cazul implementării seriale, timpul de calcul mare reprezintă unul dintre dezavantajele algoritmilor clasici de estimare a mișcării, inclusiv pentru binecunoscuta metodă Horn & Schunck (Horn and Schunck 1981). Pe de o parte, obiectivul implementării CNN este obținerea unor timpi de procesare mai mici, pe de altă parte, de a realiza algoritmi omogeni pentru compensarea mișcării sau interpolarea spațio-temporală în secvențe de imagini, cu aplicații în vederea artificială sau imagistică medicală. Astfel, și prin administrarea mai eficientă a resursele de calcul se poate contribui la prelucrarea imaginilor în timp real (Gacsádi et al. 2004), (Grava et al. 2010).

Informația vizuală joacă un rol din ce în ce mai important în multe din aplicațiile cotidiene care au fost dezvoltate în ultimii ani pe baza progresului tehnologic din diverse domenii. Câteva exemple de astfel de domenii sunt: imagistica medicală, televiziunea digitală și de înaltă definiție, video-conferințele, tehnicile de realitate virtuală și multimedia. În toate aceste domenii este necesară prelucrarea informației obținute dintr-o secvență de imagini, cu scopul de a obține informația de mișcare.

Fluxul de date care trebuie prelucrat în cazul unei secvențe de imagini 2D este mare datorită unei a treia dimensiuni și anume cea temporală. Tehnicile de estimare a mișcării estimează traiectoriile pixelilor (câmpul de mișcare) între imagini succesive, cu scopul de a exprima intensitatea luminoasă din imaginea curentă pe baza informației din imaginea anterioară sau următoare. Algoritmii de estimare a mișcării din secvențe de imagini au fost dezvoltați pentru diverse aplicații, cum ar fi: analiza secvențelor de imagini, vederea artificială sau compresia informației video.

În estimarea mișcării trebuie avut în vedere faptul că informația de mișcare este obținută pe baza variației de intensitate luminoasă observată într-o secvență de imagini, informația rezultată numindu-se „flux optic”. Este de remarcat faptul că fluxul optic observat poate fi diferit de mișcarea reală. Pentru a obține un flux optic care să reprezinte o bună aproximare a câmpului real de mișcare trebuie făcute unele ipoteze, constrângeri (Aggarwall and Nandhakumar 1988).

Metodele de estimare a mișcării se pot clasifica în două mari clase: metode de tip determinist și metode de tip probabilist. În cadrul metodelor de tip probabilist mișcarea este modelată ca o variabilă aleatoare (Konrad 2000), (Murat 1997). Astfel, ansamblul vectorilor de mișcare formează un câmp aleator care este modelat, în general, printr-un câmp aleator de tip Markov (*MRF-Markov Random Field*). Pe baza acestei presupuneri, s-a arătat că funcția de distribuție asociată, care caracterizează câmpul aleator, este o distribuție Gibbs, iar această distribuție este estimată pe baza unor estimatori de tip MAP (*maximum a posteriori*). Metodele de tip probabilist necesită un timp de calcul foarte mare, dar permit modelarea

discontinuităților în câmpul de mișcare și nu sunt limitate la anumite tipuri de modele de mișcare.

În practică sunt folosite metode de tip determinist, care necesită un timp de calcul mult mai mic. Dintre metodele deterministe, cele mai utilizate sunt (Aggarwall and Nandhakumar 1988), (Barron et al. 1994), (Murat 1997):

- metodele diferențiale (sau de tip gradient), în cadrul cărora mișcarea este estimată pe baza gradientilor spațio-temporali ai imaginii (Horn and Schunck 1981), (Bruhn et al. 2003);
- metodele de tip bloc (numite și metode corelative). Acestea se pot clasifica la rândul lor în metode de corelație a fazei și în metode de potrivire a blocurilor (*block-matching*). În cazul metodelor de corelație a fazei, mișcarea este estimată pe baza diferenței de fază Fourier a două blocuri, între două imagini succesive. Aceste metode sunt mai puțin utilizate în practică datorită sensibilității ridicate la zgomot. În cazul metodelor de potrivire a blocurilor se caută locația blocului care se potrivește cel mai bine în imaginile următoare sau anterioare cu blocul de referință din imaginea curentă, potrivirea efectuându-se pe baza unui anumit criteriu de potrivire sau diferență. Ambele metode pot fi aplicate doar în cazul unei mișcări de translație, însă pot fi încorporate și alte transformări spațiale ale mișcării (Zhu and Thall 2002), (Wei et al. 2005a).

În aproape toate metodele de estimare a mișcării, principiul fundamental este că intensitatea luminoasă a fiecărui pixel este constantă de-a lungul traiectoriei mișcării sau se modifică într-un mod predictibil. Ipoteza conservării intensității luminoase a fiecărui pixel (x,y,t) de-a lungul traiectoriei mișcării poate fi exprimată prin ecuația de diferență între imaginile deplasate (DFD - *Displaced Frame Difference*) între imaginile de la momentele t și $t'=t+\Delta t$ (Barron et al. 1994) (Konrad 2000):

$$DFD = \Phi(x + d_x, y + d_y, t + \Delta t) - \Phi(x, y, t), \quad (2.1.49)$$

unde $\Phi(x,y,t)$ reprezintă distribuția de intensitate a imaginii la momentul t ,

iar $\mathbf{d}=[d_x, d_y]^T$ este vectorul de deplasare între momentele t și t' (d_x, d_y fiind vectorii de deplasare în direcțiile x și respective y). Metodele bazate pe minimizarea directă a acestei ecuații se numesc și metode de potrivire a blocurilor.

Se observă că în cazul în care se presupune conservarea intensității luminoase:

$$DFD = \Phi(x + d_x, y + d_y, t + \Delta t) - \Phi(x, y, t) = 0 \quad (2.1.50)$$

Metodele diferențiale de estimare a mișcării se bazează pe gradientii spațio-temporali ai imaginilor unei secvențe de imagini. Dacă intensitatea luminoasă a unui punct nu variază în timp, atunci (Horn and Schunck 1981):

$$\frac{d\Phi}{dt} = 0. \quad (2.1.51).$$

Dezvoltarea în serie Taylor de ordinul 1 a acestei ultime relații, are ca rezultat ecuația de constrângere a mișcării (ECM, numită și ecuația fluxului optic EFO) care leagă gradientii spațiali și temporali ai intensității luminoase:

$$\frac{\partial\Phi}{\partial x} \frac{dx}{dt} + \frac{\partial\Phi}{\partial y} \frac{dy}{dt} + \frac{\partial\Phi}{\partial t} = 0. \quad (2.1.52)$$

Această ecuație se poate rescrie ca:

$$\Phi_x \cdot v_x + \Phi_y \cdot v_y + \Phi_t = 0, \quad (2.1.53)$$

unde Φ_x și Φ_y sunt gradientii spațiali, Φ_t este gradientul temporal al intensității luminoase și $v_x = \frac{dx}{dt}$, $v_y = \frac{dy}{dt}$ sunt vitezele pe direcțiile x și y (Konrad 2000).

Ecuția de constrângere a mișcării (2.1.52) descrie o dreaptă în spațiul vitezelor (v_x , v_y). Distanța care separă această dreaptă (dreapta de constrângere) de origine, depinde de raportul modulelor gradientilor temporali și spațiali, în timp ce orientarea acestei drepte este determinată de orientarea gradientului spațial al punctului de interes (figura 2.1.10).




Figura 2.1.10: Ecuția de constrângere a mișcării și dreapta de constrângere.

După cum se observă din relația (2.1.53), ecuația de constrângere a mișcării ECM (sau ecuația fluxului optic EFO) are două necunoscute (v_x , v_y), deci sistemul este sub-determinat.

Aceasta pune în evidență faptul că ecuația de constrângere nu permite determinarea decât a uneia dintre necunoscute și anume a proiecției vectorului viteză pe gradientul spațial al intensității luminoase. Pentru a obține informația de mișcare adică ambele componente ale mișcării, (v_x , v_y), trebuie introdusă o a doua constrângere, astfel, rezultând un sistem complet determinat (două ecuații cu două necunoscute).

Una din constrângerile posibile presupune că toate punctele vecine au mișcări asemănătoare, considerându-se câmpul de vectori viteză uniform (Horn and Schunck 1981). Rezultă că trebuie minimizată o energie de tipul:

$$E^2 = E_{flux}^2 + \gamma \cdot E_{uniformitate}^2. \quad (2.1.54)$$

Primul termen corespunde diferenței în raport cu proiecțiile vectorilor viteză pe gradientul spațial (conform ECM), iar cel de-al doilea termen corespunde diferenței în raport cu un câmp uniform, coeficientul γ fiind factorul de ponderare între cei doi termeni.

Constrângerea de uniformitate se exprimă prin ecuația:

$$E_{uniformitate}^2 = \left(\frac{\partial v_x}{\partial x} \right)^2 + \left(\frac{\partial v_x}{\partial y} \right)^2 + \left(\frac{\partial v_y}{\partial x} \right)^2 + \left(\frac{\partial v_y}{\partial y} \right)^2, \quad (2.1.55)$$

iar ecuația fluxului optic:

$$E_{flux}^2 = (\Phi_x \cdot v_x + \Phi_y \cdot v_y + \Phi_t)^2 \quad (2.1.56)$$

Soluția ecuației (2.1.53) se poate obține după o minimizare de tip Gauss-Seidel, rezultând ecuațiile iterative (Horn and Schunck 1981). Ecuația va fi astfel minimizată atunci când eroarea (adică diferența între două valori succesive ale lui v_x , și v_y) va fi considerată ca fiind minimă sau când se va atinge numărul de iterații ales. Această metodă nu este limitată la translații, cum este cazul metodei de potrivire a blocurilor, iar calculele sunt mult mai scurte. În schimb, mișcarea trebuie să fie de mică amplitudine, mai mici de trei pixeli, din considerente de validitate ale dezvoltării în serie Taylor. Pentru a elimina dezavantajele legate de limitarea la mișcări de amplitudine mică, soluția este de a utiliza tehnici de tip multirezoluție.

În scopul implementării CNN a metodei lui Horn & Schunck de estimare a mișcării se vor lua în considerare constrângerile de proiectare prezentate deja în subcap. 2.1.2.

O etapă foarte importantă o reprezintă, și de această dată, asocierea termenilor din funcția de cost cu operatorii A, B, C sau D. În general, ar fi de preferat utilizarea unei structuri CNN monostrat și obținerea unor template-uri liniare, eventual neliniare, dar numai cu dimensiuni 3*3. Se va apela la template-urile care se pot implementa numai pe structuri CNN multistrat doar dacă nu există nici o altă modalitate mai simplă pentru implementarea CNN a unei aplicații. Parametrii scalari din funcțiile de cost (2.1.54) trebuie să fie ponderați între 0 și 1 pentru satisfacerea condiției de stabilitate precum și a menține valorile stărilor straturilor CNN în zona liniară a caracteristicii de transfer de la stare la ieșire.

Luând în considerare notațiile CNN uzuale, în continuare se vor utiliza și următoarele notații:

$$\frac{\partial \Phi}{\partial x} = \Phi_x \rightarrow \Phi_i; \quad \frac{\partial \Phi}{\partial y} = \Phi_y \rightarrow \Phi_j; \quad \frac{\partial \Phi}{\partial t} = \Phi_t \rightarrow \Phi_i; \quad \frac{dx}{dt} = v_x \rightarrow v_i; \quad \frac{dy}{dt} = v_y \rightarrow v_j;$$

$$\frac{\partial v_x}{\partial x} = v_x^x \rightarrow v_i^i; \quad \frac{\partial v_x}{\partial y} = v_x^y \rightarrow v_i^j; \quad \frac{\partial v_y}{\partial x} = v_y^x \rightarrow v_j^i; \quad \frac{\partial v_y}{\partial y} = v_y^y \rightarrow v_j^j. \quad (2.1.57)$$

unde v_i și v_j reprezintă vitezele după direcțiile i și j , care urmează a fi determinate.

Pe baza considerentelor de mai sus, pentru estimarea CNN a mișcării se vor folosi cele două imagini, imaginea inițială $\Phi_1(i,j,t)$ și imaginea finală $\Phi_2(i,j,t+\Delta t)$, rezultând o structură CNN având două straturi și template-ul HOSCH (figura 2.1.11). Variabilele discrete spațiale sunt i și j .




Figura 2.1.11: Structura CN cu două straturi pentru implementarea metodei Horn & Schunck de estimare a mișcării.

După minimizarea energiei din relația (2.1.54), rezultă template-ul HOSCH având următoarele componente: (2.1.58)

- Imaginile de polarizare Z_1 și Z_2 :

$$Z_1 = \Phi_i \Phi_t; \quad Z_2 = \Phi_j \Phi_t.$$

- Operatorii liniari de reacție inversă, A_1 și A_2 :

$$A = \begin{pmatrix} 0 & a & 0 \\ a & 1-4a & a \\ 0 & a & 0 \end{pmatrix},$$

unde parametrul constant a include și parametrul γ din ecuația (2.1.54), în mod evident, ponderate și cu constantele care rezultă în procesul de minimizare a energiei.

- Operatorul neliniar de tip D rezultă de forma:

$$D_{kl} = \begin{pmatrix} 0 & 0 & 0 \\ 0 & d_{kl} & 0 \\ 0 & 0 & 0 \end{pmatrix}, \text{ unde perechea } kl \text{ poate fi: } 11;21;22;12.$$

Astfel:

- pentru D_{11} corespunde $d_{11}(v_i) = \Phi_i^2 v_i$; pentru D_{21} corespunde $d_{21}(v_j) = \Phi_i \Phi_j v_j$;
- pentru D_{22} corespunde $d_{22}(v_j) = \Phi_j^2 v_j$; pentru D_{12} corespunde $d_{12}(v_i) = \Phi_i \Phi_j v_i$;

Folosind sistemul de dezvoltare pentru aplicații CNN *CadetWin* (**1999a) și mediul Matlab, rezultate experimentale obținute în urma utilizării metodei de estimare a mișcării a lui Horn & Schunck sunt prezentate în figura 2.1.13. Pentru ilustrarea modului în care implementarea CNN propusă realizează estimarea de mișcare, s-au construit imaginile artificiale, imaginea inițială $\Phi_1(i,j,t)$ și imaginea finală $\Phi_2(i,j,t+\Delta t)$ (figura 2.1.12a,b). Rezultatele obținute pentru imaginile vitezelor sunt prezentate în figura 2.1.12c,d.




Figura 2.1.12: Estimarea mișcării: a) imaginea $\Phi_1(t)$; b) imaginea $\Phi_2(t+\Delta t)$; c) imaginea viteză, v_i ; d) imaginea viteză, v_j .

Pentru o vizualizare mai bună, imaginile vitezelor, v_i și v_j , nu sunt calibrate în domeniul CNN. În cazul în care dorim să utilizăm aceste imagini, de exemplu, în compensarea imaginii, trebuie să fie calibrate în domeniul standard CNN $[-1,+1]$. Astfel, în imaginile calibrate pentru v_i și v_j , o deplasare de un pixel corespunde unei variații de valoarea 0,1.

Rezultatele obținute utilizând implementarea CNN a metodei de estimare a mișcării a lui Horn & Schunck sunt ilustrate în figura 2.1.13, pentru cazul unei secvențe reale de imagini

binecunoscute în literatura de specialitate, dedicată estimării de mișcare și anume secvența „taxi”.




Figura 2.1.13: Estimarea mișcării: a) imaginea $\Phi_1(t)$; b) imaginea $\Phi_2(t+\Delta t)$; c) imaginea viteză, v_i ; d) imaginea viteză, v_j .

După cum se observă și din rezultatele prezentate, implementarea CNN a metodei lui Horn & Schunck asigură rezultate bune pentru mișcări de amplitudine mică, în timp ce metoda poate eșua în cazul mișcărilor de amplitudine mai mare de 3 pixeli.

Deși procesarea CNN paralelă asigură reducerea timpului de calcul, unele metode sofisticate de procesare a semnalelor sunt dificil sau chiar imposibil de implementat pe un chip CNN cu un singur strat, care utilizează numai template-uri invariante în spațiu, liniare, de dimensiuni 3×3 . Astfel, implementarea CNN propusă a metodei lui Horn & Schunck de estimarea mișcării necesită o structură cu două straturi și template-uri neliniare. Implementarea paralelă efectivă poate fi realizabilă pe un chip CNN-UC existent (Cembrano et al. 2003) numai prin proiectarea unui algoritm CNN analogic complex sau utilizând emulatorul digital CNN implementat FPGA (Nagy et al. 2006), (***) 2007).

Algoritmul CNN de compensare a mișcării

Informația de mișcare obținută în urma estimării, indiferent de modalitatea prin care aceasta rezultă, va putea fi utilizată la compensarea mișcării: într-un lanț de analiză a unei secvențe video, în compresia temporală a imaginilor, la interpolarea spațială sau temporală a imaginilor (Grava et al. 2003), (Gacsádi et al. 2004), (Grava et al. 2010). Astfel, utilizând două imagini consecutive, imaginea inițială $\Phi_1(x,y,t_1)$ și imaginea finală $\Phi_2(x,y,t_2)$ dintr-o secvență (figura 2.1.14), în urma aplicării unei metode de estimare de mișcare, pentru fiecare pixel rezultă o estimare a mișcării după cele două direcții ale sistemului de coordonate atașat planului de imagine.

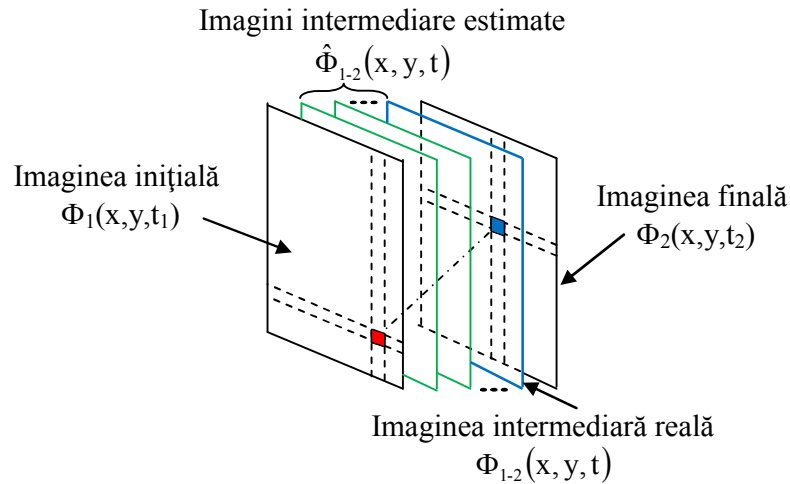


Figura 2.1.14: Compensarea mișcării.

Algoritmul CNN de compensare a mișcării utilizează informația de mișcare obținută cu algoritmul de estimare a mișcării descris mai sus astfel încât, pornind de la imaginea inițială Φ_1 , utilizată în procesul de estimare, și de la această informație de mișcare, să fie reconstruite (sau prezise) imagini intermediare, imaginea compensată a mișcării, $\hat{\Phi}_{1-2}$. În acest scop, este propusă o clasificare a pixelilor din imaginile ce conțin informația de mișcare, iar procesul de compensare a mișcării este descompus în pași elementari (al căror număr este egal cu deplasarea maximă estimată), la fiecare pas fiind creată câte o imagine intermediară prin deplasarea pixelilor din imaginea inițială, în conformitate cu informația de mișcare estimată (figura 2.1.14). La final se obține imaginea compensată precisă, care teoretic ar trebui să fie identică cu imaginea reală, Φ_{1-2} , care nu a fost utilizată în procesul de estimare a mișcării între imaginea inițială Φ_1 și imaginea finală Φ_2 . Diferența între cele două exprimă eroarea cumulată a compensării de mișcare și implicit a estimării de mișcare, dar și a interpolărilor efectuate.

Astfel, un pixel își poate modifica poziția după una din cele 8 direcții: N, N-E, E, S-E, S, S-V, V, N-V, sau rămâne pe loc. În urma estimării acestor mișcări, în imaginea inițială sau într-o imagine intermediară pixelii se pot clasifica în cinci categorii:

- Pixeli de tip “a”, care au poziții identice în cele două imagini Φ_1 și Φ_2 . Aceste elemente de imagine nu-și schimbă nici pozițiile și nici valorile niciodată în cursul prelucrărilor CNN ulterioare.
- Pixeli de tip “b”, care urmează să se miște, ca urmare a faptului că în imaginile care conțin informația de mișcare pixelii corespunzători în poziții au valori mai mari decât o cantă curentă. Valorile acestor elemente de imagine nu se modifică, dar prin intercalarea unor cadre de imagine între imaginea Φ_1 și imaginea Φ_2 , pozițiile lor se modifică succesiv cu câte o cantă corespunzătoare discretizării spațiale a imaginilor. Numărul maxim de cadre de imagine care se pot intercala este egal cu numărul maxim de cuante de mișcare care se pot identifica.
- Pixelii de tip “c” sunt aceia ai căror valori se vor schimba datorită faptului că în locul respectiv sosește un alt pixel suprapunându-se peste cel inițial din acea poziție:

$$c(t) = \text{shift}(b(t)) \quad (2.1.59)$$

- Pixeli de “d”, care în decursul prelucrărilor au suferit modificări, prin sosirea și plecarea unor pixeli aflați în mișcare, dar la un moment dat, poate chiar în final, vor avea chiar valoarea inițială din imaginea Φ_1 . De aceea, valorile acestor pixeli se refac prin reconstituire:

$$d(t) = [d(t-1) \cdot \bar{c}(t) + b(t) \cdot \bar{c}(t)] \cdot b(1) \quad (2.1.60)$$

- Pixeli de tip “e”, cu valori necunoscute care iau naștere prin eliberarea pozițiilor de către pixelii de tip b, dar în acel loc nu sosește niciodată alt pixel. Corespunzător fiecărui pas de mișcare, valorile acestor elemente de imagine, a căror poziții sunt cunoscute, se pot determina prin interpolare CNN:

$$e(t) = c(t-1) \cdot b(t) \cdot \bar{c}(t) \cdot \bar{d}(t) \quad (2.1.61)$$

Pentru fiecare imagine intermediară valoarea unui pixel din imaginea respectivă rezultă după determinarea tipului de pixel. Într-o poziție oarecare a imaginilor intermediare, cu excepția pixelilor de tip a, statutul pixelilor de tip b, c, d, e se poate modifica pe parcursul prelucrării. Organigrama care prezintă principiul interpolării CNN cu compensarea mișcării este redată în figura 2.1.15.

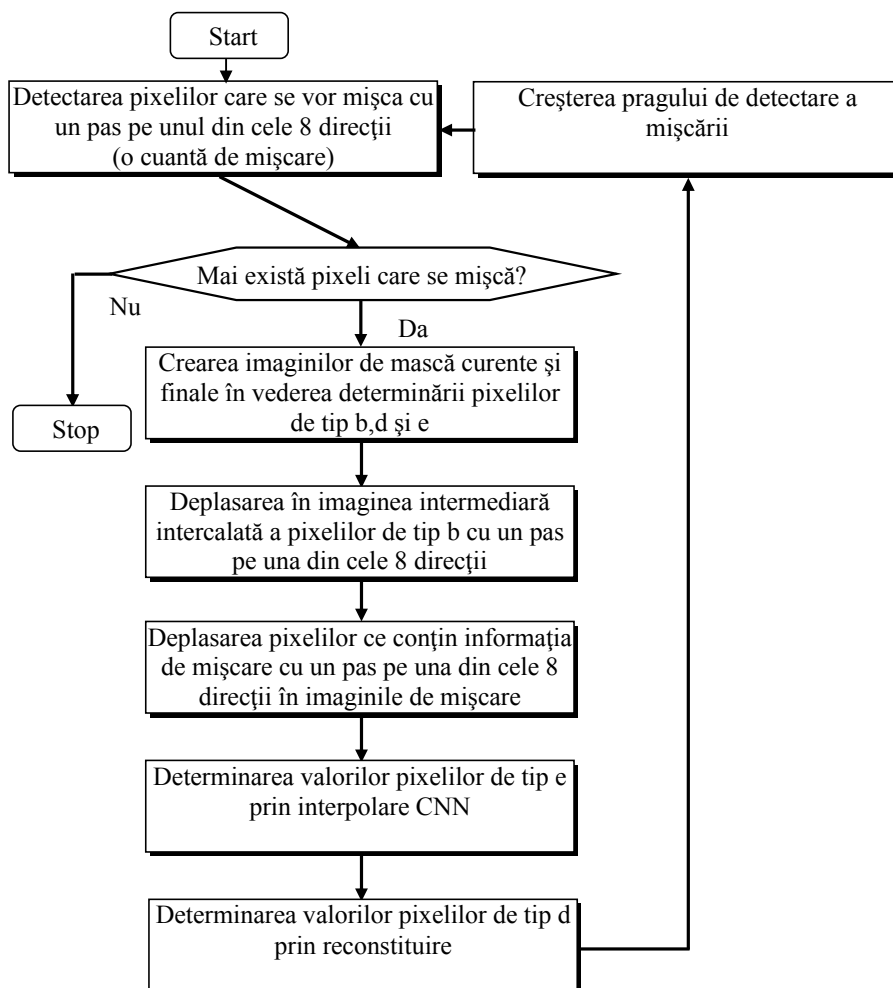


Figura 2.1.15: Algoritmul CNN de compensare a mișcării.

Imaginile Φ_1 și Φ_2 precum și imaginile care conțin informațiile de mișcare au dimensiuni identice. De asemenea, toate aceste imagini sunt convertite în imagini cu niveluri

de gri, cu valori în domeniul standard CNN (de la -1 până la $+1$) (figura 2.1.16). Unui pixel care nu-și modifică poziția între imaginile Φ_1 și Φ_2 , în aceeași poziție din imaginile care conțin informația de mișcare îi corespunde valori nule sau sub pragul minim detectabil al mișcării. Pixelii cu valori negative codifică o mișcare spre stânga (figura 2.1.16a) respectiv sus (figura 2.1.16b), iar pixelii cu valori pozitive codifică mișcări către dreapta (figura 2.1.16a) respectiv jos (figura 2.1.16b).




Figura 2.1.16: Imaginile care conțin informațiile de mișcare.

Valorile pixelilor care codifică mișcări sunt multipli ai valorii minime detectabile de mișcare. Pentru a ușura procesarea CNN de compensare a mișcării, valorile maxime din imaginile ce conțin informația de mișcare se pot norma astfel încât valorilor maxime estimate să le corespundă chiar valorile -1 și $+1$ (valori extreme în domeniul mediului CNN). Se are în vedere faptul că, în general, reprezentarea valorilor elementelor de imagine în domeniul CNN, atât la simulare cât și la implementare pe chip, este realizată pe 8 biți. Astfel, în urma normării devin mai ușor detectabile și mișcările de amplitudine redusă.

Pentru detectarea pixelilor care urmează a-și modifica pozițiile, la procesarea imaginilor de mișcare se utilizează template-ul TRESHOLD cu valorile de prag p alese în concordanță cu nivelurile pragurilor de detecție a mișcării (** 2010):

$$A = \begin{pmatrix} 0 & 0 & 0 \\ 0 & 2 & 0 \\ 0 & 0 & 0 \end{pmatrix} \quad B = \begin{pmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{pmatrix} \quad z = -p, \quad (2.1.62)$$

TRESHOLD

unde p este un număr real care aparține intervalului $[-1, +1]$.

În vederea deplasării pixelilor cu o poziție se utilizează familia de template-uri SHIFT (** 2010) pentru imagini cu niveluri de gri corespunzătoare celor opt direcții. Spre exemplu, deplasarea cu o poziție spre est este realizată utilizând SHIFTE:

$$A = \begin{pmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{pmatrix} \quad B = \begin{pmatrix} 0 & 0 & 0 \\ 1 & 0 & 0 \\ 0 & 0 & 0 \end{pmatrix} \quad z = 0, \quad (2.1.63)$$

SHIFTE

Modificarea pozițiilor pixelilor trebuie să se facă nu numai în imaginile intercalate dar și în imaginile de mișcare. Pentru determinarea valorilor pixelilor care au luat naștere în urma modificării pozițiilor unor elemente de imagine, se utilizează template-ul AINTPOL3, care

asigură o interpolare spline cubică. Determinarea valorilor pixelilor de tip e prin interpolare se poate realiza atât pentru imaginile intermediare intercalate cât și pentru imaginea finală.

Pentru ca în decursul prelucrării să nu se modifice pixelii de tip a, respectiv pentru reconstituirea valorilor pixelilor de tip d, sunt create succesiv imagini mască adecvate.

Timpul de prelucrare este dependent de numărul de interpolări, respectiv de numărul cuantelor de mișcare rezultate în urma discretizării spațiale, adică de numărul total de imagini intercalate între cele două imagini originale Φ_1 și Φ_2 . În cazul procesării paralele, acest timp total de prelucrare este însă independent de dimensiunile imaginilor originale și de numărul de pixeli care se vor mișca.

În figura 2.1.17 sunt prezentate rezultatele obținute în urma simulării interpolării CNN cu compensare de mișcare utilizând informațiile de mișcare redată în imaginile din figura 2.1.16. Fiecare pixel negru (figura 2.1.17a) se deplasează după una din cele 8 direcții posibile: N, N-E, E, S-E, S, S-V, V, N-V, având cuantele corespunzătoare de mișcare cuprinse de la 1 la 8.




Figura 2.1.17: Interpolare CNN cu compensarea mișcării: a) imaginea inițială Φ_1 ; b) și c) imagini intermediare; d) imaginea finală rezultată din imaginea Φ_1 și informațiile de mișcare.

În exemplul prezentat în figura 2.1.18, toți pixelii obiectului efectuează o mișcare identică spre direcția N-E.




Figura 2.1.18: Interpolare CNN cu compensarea mișcării: a) imaginea inițială Φ_1 ; b) și c) imagini intermediare; d) imaginea finală rezultată din imaginea Φ_1 și informațiile de mișcare.

Algoritmii dezvoltați au fost ilustrați în cazul unei secvențe cunoscute în literatura de specialitate („Tabla de tenis”), iar rezultatele confirmă validitatea algoritmului omogen de estimare și compensare a mișcării (figura 2.1.19) (Grava et al. 2010). După cum se poate observa, cele mai mari erori între imaginea reală, Φ_{1-2} , și imaginea compensată de mișcare, $\hat{\Phi}_{1-2}$, sunt situate în regiunea cu un gradient ridicat de intensitate, care de obicei corespunde

regiunilor cu mișcări diferite. De asemenea, o altă cauză a acestor erori ar putea fi caracterul spațial discret al imaginii și interpolării efectuate.

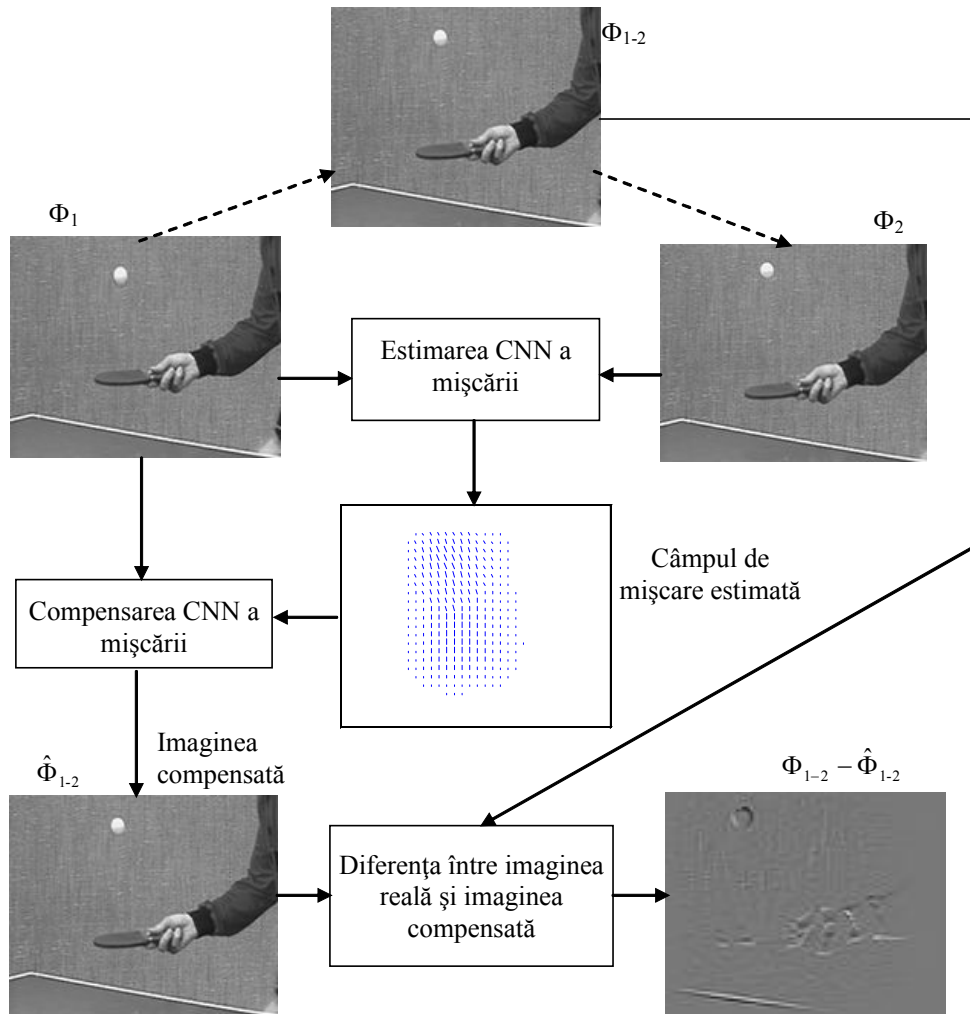


Figura 2.1.19: Algoritmul CNN de compensare a mișcării.

Pentru ilustrarea algoritmului dezvoltat de estimarea și compensare a mișcării s-a utilizat mediul de simulare *CadetWin* (**1999a) și programul Matlab, rezultatele confirmând validitatea algoritmului omogen propus pentru estimarea și compensarea mișcării.

În cazul implementării seriale a algoritmului de estimare și compensare a mișcării, timpul de calcul depinde de dimensiunile imaginilor. Prin utilizarea rețelelor neuronale/nelineare celulare și implementarea CNN a algoritmului (pe chip CNN și/sau pe structură FPGA, (Cembrano et al. 2003), (Nagy et al. 2006)) procesarea imaginilor devine paralelă și se poate reduce considerabil timpul de calcul. Astfel, timpul de calcul depinde doar de constanta de timp a structurii hardware și de numărul maxim de pași al algoritmului (egal cu deplasarea maximă), fiind independent de dimensiunile imaginilor prelucrate. Timpul de calcul astfel estimat poate fi cu câteva ordine de mărime mai mic decât în cazul implementării seriale.

Interpolarea CNN a secțiunilor de imagini CT și imagini RM

Algoritmul CNN de compensare a mișcării, prezentat mai sus, poate fi utilizat și pentru creșterea rezoluției spațiale în a treia dimensiune a unui volum de secțiuni 2D de imagini computer tomografice (CT) sau imagini de rezonanță magnetică (RM) (Goshtasby et al. 1992) (Gacsádi et al. 2004). Secțiunile intermediare de imagini sunt create utilizând o metodă de interpolare CNN (de exemplu, spline-cubică), pe baza corespondenței stabilite, printr-un proces de potrivire a imaginilor între cele două secțiuni reale consecutive, imaginea inițială Φ_1 , și imaginea finală Φ_2 , (figura 2.1.14).

Informația de corespondență, care poate rezulta, de exemplu, prin metoda de potrivire a blocurilor, permite clasificarea pixelilor, atât în imaginea inițială sau într-o imagine intermediară, în cele cinci tipuri, de la “a” la “e”.

În figura 2.1.20 sunt prezentate rezultatele simulării interpolării CNN a secțiunilor în cazul imaginilor sintetice CT. Imaginea Φ_2 rezultă ca deformația sintetică a imaginii inițiale, Φ_1 , prin utilizarea principiului FFD (*Free Form Deformation*). Sunt prezentate imaginea inițială (figura 2.1.20a și 2.1.20e), imaginea finală (figura 2.1.20c), precum și o imagine intermediară (figura 2f) și câmpul de mișcare între imaginea inițială și imaginea finală (figura 2.1.20b). În figura 2.1.20g se poate vedea imaginea finală estimată, $\hat{\Phi}_2$, care rezultă după ultima iterație a algoritmului. În figura 2.1.20d s-a prezentat imaginea diferență între imaginea finală reală și imaginea inițială, $\Phi_2 - \Phi_1$, iar în figura 2.1.20h s-a prezentat imaginea diferență între imaginea finală estimată și cea inițială, $\hat{\Phi}_2 - \Phi_1$.

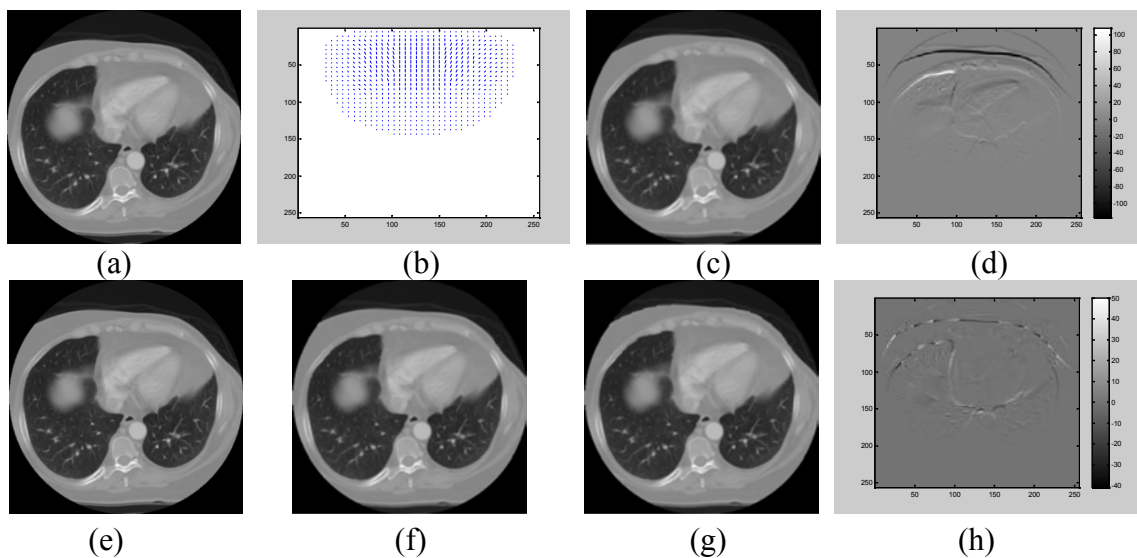


Figura 2.1.20: Interpolarea CNN a secțiunilor în cazul imaginilor sintetice CT: (a) și (e) imaginea inițială, Φ_1 ; (b) câmpul de mișcare între imaginea inițială și imaginea finală; (c) imaginea finală, Φ_2 ; (d) imaginea diferență între imaginea finală reală și imaginea inițială, $\Phi_2 - \Phi_1$; (f) imaginea intermediară; (g) imaginea finală estimată, $\hat{\Phi}_2$; (h) imaginea diferență între imaginea finală estimată și cea inițială, $\hat{\Phi}_2 - \Phi_1$.

În figura 2.1.21 sunt prezentate rezultatele simulării interpolării CNN a secțiunilor în cazul imaginilor reale RM. Se poate vizualiza imaginea inițială, Φ_1 , (figura 2.1.21a și 2.1.21e), imaginea finală, Φ_2 , (figura 2.1.21c), o imagine intermediară (figura 2.1.21f) și câmpul de mișcare între imaginea inițială și imaginea finală (figura 2.1.21b). În figura 2.1.21g se poate observa imaginea finală estimată, $\hat{\Phi}_2$, care rezultă după ultima iterație a algoritmului. În figura 2.1.21d s-a prezentat imaginea diferență între imaginea finală reală și imaginea inițială, $\Phi_2 - \Phi_1$, iar în figura 2.1.21h s-a prezentat imaginea diferență între imaginea finală estimată și cea inițială, $\hat{\Phi}_2 - \Phi_1$.




Figura 2.1.21: Interpolarea CNN a secțiunilor în cazul imaginilor reale RM:
 (a) și (e) imaginea inițială, Φ_1 ; (b) câmpul de mișcare între imaginea inițială și imaginea finală; (c) imaginea finală, Φ_2 ; (d) imaginea diferență între imaginea finală reală și imaginea inițială, $\Phi_2 - \Phi_1$; (f) imaginea intermediară; (g) imaginea finală estimată, $\hat{\Phi}_2$; (h) imaginea diferență între imaginea finală estimată și cea inițială, $\hat{\Phi}_2 - \Phi_1$.

Timpul de procesare al algoritmului propus pentru creșterea rezoluției 3D depinde de numărul de interpolări, adică de numărul total de imagini inserate între imaginea inițială, Φ_1 , și imaginea finală, Φ_2 . Prin implementarea CNN a algoritmului (pe chip CNN și/sau pe structură FPGA, (Cembrano et al. 2003), (Nagy et al. 2006)) procesarea imaginilor devine paralelă și se poate reduce considerabil timpul de calcul. Astfel, timpul total de prelucrare rezultă independent de dimensiunile imaginilor originale și de numărul de pixeli în mișcare.

2.2. Prelucrarea unor imagini medicale

În prezent, tehnicile de investigare, cum ar fi imagistica prin rezonanță magnetică (IRM), tomografia computerizată (CT) sau tomografia cu emisie de pozitroni (PET), joacă un rol deosebit de important în medicină. Pentru a extrage cât mai multe informații posibile, aceste tehnici folosesc metode avansate de procesare a imaginii. Astfel, îmbunătățirea calității imaginilor și tehnicile 3D pot fi folosite pentru a obține o mai bună vizualizare, extragerea de trăsături poate fi folosită la diagnosticare asistată, segmentarea poate fi utilă pentru a separa diferite țesuturi și organe.

Dezvoltarea unor echipamente tot mai performante de imagistică medicală, este o necesitate continuă. Aproape indiferent de natura imaginii medicale achiziționate sau de principiul de funcționare a aparatului utilizat, aceasta trebuie adusă sub o formă cât mai ușor de interpretat de către medicii specialiști. În acest scop imaginea este supusă unui lanț de prelucrări și analiză. Toate aceste operații de prelucrare și analiză a imaginilor medicale trebuie să fie efectuate în timp real.

Un aspect deosebit de important îl reprezintă evaluarea metodelor de procesare a imaginilor medicale din punctul de vedere al posibilității integrării acestora în sisteme semiautomate sau automate de diagnostic medical. În acest sens, o metodă poate fi benefică, chiar și atunci când este mai puțin performantă din punct de vedere teoretic, dar care oferă rezultate în timp real și poate fi utilizată în interesul pacientului în practica medicală de zi cu zi. Datorită diversității și dificultății problemelor existente la ora actuală, atât din punct de vedere teoretic cât și cel al modului de implementare, dezvoltarea unor noi metode de imagistică medicală continuă să rămână un subiect de certă actualitate.

În cele din urmă, este important de remarcat faptul că indiferent de algoritmul matematic utilizat pentru procesarea imaginilor medicale și modul lui de implementare, aprecierea eficienței și utilității acestora, adică validarea lor în practica medicală rezultă în urma unui procedeu iterativ în buclă, care are ca principal „arbitri” medici experți în imagistică medicală (Angenent et al. 2006).

Alături de celelalte procedee clasice, ca structuri de calcul paralel, rețelele neuronale/nelineare celulare (*CNN - wave computing*) oferă soluții complementare de realizare a unor aplicații în timp real în domeniul imagisticii medicale.

În general, implementarea CNN a unor metode de prelucrare a imaginilor medicale nu este un scop în sine (Chua and Yang 1988), (Roska and Chua 1993). Astfel, se poate reduce timpul de calcul datorită procesării complet paralele (Cembrano et al. 2003), (Nagy et al. 2006), (Hillier et al. 2006), (Dudek and Vilariño 2006). În scopul extragerii zgomotului, segmentării imaginilor, determinării conturului, în literatura de specialitate au fost analizate și propuse diferite modele matematice privind posibilitatea implementării pe structuri hardware bazate pe utilizarea rețelelor neuronale/nelineare celulare. Din păcate, compararea eficienței implementării CNN a acestor metode este practic imposibilă deoarece unele dintre acestea utilizează structuri hardware optimizate și dedicate pentru aplicația concretă și acestea sunt accesibile limitat. Totuși, pentru comparația metodelor ca și parametru cantitativ obiectiv,

rezultă timpul de calcul, în timp ce precizia prelucrării, în majoritatea cazurilor, se poate aprecia numai calitativ pe baza opiniei medicilor experți în imagistică medicală.

Următoarele secțiuni, se referă la dezvoltarea unor metode de analiză și prelucrare a imaginilor computer tomografice (CT), bazată pe tehnologia rețelelor neuronale celulare (CNN) și abordarea lor în ansamblu pentru a le implementa într-un sistem de asistare în timp real a diagnozei medicale (Gacsádi et al. 2009-2011).

Obiectivul general al studiului vizează îmbunătățirea actului medical, prin creșterea eficienței imagisticii CT la stabilirea diagnozei medicale și/sau la urmărirea tratamentului, utilizând în acest scop un sistem de asistare. Acest obiectiv, în centrul căreia se află îmbunătățirea calității vieții *Omului*, este realizabil numai în condițiile existenței dialogului și colaborării interdisciplinare eficiente și permanente a specialiștilor din toate domeniile de știință implicate.

2.2.1. Îmbunătățire adaptivă a imaginilor utilizând rețele neuronale/nelineare celulare

Îmbunătățire CNN a imaginilor

În general, în domeniul prelucrărilor de imagini un pas important de preprocesare este îmbunătățirea calității imaginii care are drept scop obținerea vizibilității superioare a componentelor imaginii în vederea interpretării cât mai ușoare de către observatorul uman (Gonzalez and Woods 1993). Prin preprocesarea imaginilor, pe de o parte, trebuie să se realizeze reducerea zgomotului prin filtrare, fără însă a deteriora sau a pierde informații utile incluse în detalii, pe de altă parte, trebuie uneori chiar accentuate detalii, de exemplu cele care se referă la contururi și care pot fi indispensabile în continuare, fără însă a introduce elemente artificiale perturbatoare. Cele două deziderate sunt evident contradictorii, deoarece filtrarea zgomotului din imagini acționează în sens negativ și asupra muchiilor (conturilor), în timp ce accentuarea detaliilor poate provoca chiar și descompunerea falsă a unei regiuni omogene, compacte.

În scopul reducerii zgomotului din imagine simultan cu îmbunătățirea contrastului și a conturilor sunt disponibile modele matematice complexe deosebit de performante. Deocamdată, unele dintre aceste prelucrări de imagini sunt greu de realizat în timp real, chiar dacă se dispune de putere de calcul serial din ce în ce mai mare.

Unele tehnici de îmbunătățire a imaginilor sunt realizabile și cu metode de calcul CNN, cum ar fi: extinderea contrastului (*contrast stretching*), detecția muchiilor, reducerea zgomotului.

Csapodi și Roska descrie o metoda CNN de scalare globală a unei imagini cu contrast scăzut având valorile inițiale ale pixelilor cuprinse între Φ_{\min} și Φ_{\max} (Csapodi and Roska 1996). Obiectivul urmărit este utilizarea întregului domeniu de valori CNN standard al imaginilor cu niveluri de gri, cuprins în intervalul $[-1, 1]$. În acest scop se utilizează funcția de transfer $g(\Phi)$, reprezentată în figura 2.2.1:

$$g(\Phi) = -1 + 2 \cdot \frac{\Phi - \Phi_{\min}}{\Phi_{\max} - \Phi_{\min}} \quad (2.2.1)$$




Figura 2.2.1: Funcția de transfer g .

Actualmente o parte însemnată a calculelor din relația (2.2.1), mai puțin împărțirea, se pot efectua într-un mediu CNN, chiar și direct pe chip-ul CNN, în mod complet paralel.

Îmbunătățirea adaptivă a imaginilor presupune ca funcția de transfer atașată prelucrării să depindă de nivelul de intensitate și de contrastul local, sau uneori regional.

Calitatea unei imagini se poate aprecia prin relația (Brendel and Roska 2002):

$$Q(x, y) = c_1 D(I^2(x, y)) + c_2 D(C^2(x, y)) \quad (2.2.2)$$

unde I reprezintă intensitate medie, C reprezintă contrastul mediu, D reprezintă operatorul de difuzie, iar c_1 și c_2 sunt parametri constanți. Metoda propusă în această lucrare se poate implementa pe o structură de rețele neuronale celulare cu 3 straturi, sau pe baza unui algoritm secvențial (Rekeczky et al. 2000). Evaluarea cantitativă a calității imaginii poate fi utilă la aprecierea prin comparare a metodelor de îmbunătățire a imaginilor, având în vedere că prin adaptarea ochiului uman imaginea prelucrată poate fi apreciată uneori ca fiind mult mai bună decât este ea în realitate.

Rekeczky și Roska propune o altă metodă complexă de îmbunătățire a contrastului imaginii simultan cu reducerea zgomotului (Rekeczky and Roska 2001). Procesarea imaginii este obținută pe baza unui algoritm iterativ care include parțial și procesări paralele realizate cu metode CNN.

Îmbunătățire adaptivă CNN a imaginilor bazată pe calcul variațional

Metoda originală de îmbunătățire adaptivă a imaginilor utilizând rețele neuronale/nelineare celulare, prezentată în această secțiune, are în vedere deopotrivă reducerea zgomotului, accentuarea muchiilor, creșterea contrastului, dar și posibilitatea implementării directe pe un chip analogic CNN existent, într-o singură etapă, utilizând numai template liniar, de dimensiuni 3×3 (Gacsádi and Szolgay 2003), (Gacsádi et al. 2005). Astfel, se asigură reducerea timpului de calcul în urma procesării complet paralele. Dimensionarea analitică a template-ului, propus pentru îmbunătățirea adaptivă CNN a imaginilor, este bazată pe calcul variațional (subcap.2.1.2).

Se consideră o imagine cu niveluri de gri (*gray-scale*) $\Phi(x, y)$, $\Phi_0: \mathbf{R}^2 \rightarrow \mathbf{R}$,

$\Omega = \{(x, y): x \in [1, M], y \in [1, N], M \text{ și } N \in \mathbf{R}^+\}$ (Casellas et al. 1998).

Energia utilizată, având ca obiectiv îmbunătățirea adaptivă a imaginii, este de forma (Mumford and Shah 1985), (Perona and Tartagni 1994):

$$E(\Phi, G) = \underbrace{\iint \|\nabla\Phi\|^2 dx dy}_{\text{Mediere}} + \underbrace{\lambda|G|}_{\text{Muchii și Fidelitate}}. \quad (2.2.3)$$

Minimizarea acestei funcții de cost presupune efectuarea a două procese: filtrarea continuă a imaginii $\Phi(x,y)$ prin mediere și, un proces de detecție a muchiilor, descris de funcția G și un parametru scalar λ . Astfel, în urma prelucrării imaginii bazate pe energia E , se realizează un compromis între reducerea zgomotului (*denoising*) și extragerea muchiilor (*deblurring*).

Pentru a putea implementa procedura pe o structură CNN cu un singur strat, într-o primă aproximare, în relația (2.2.3) considerăm că funcția G asigură și păstrarea asemănării (fidelității) imaginii prelucrate cu imaginea inițială.

În condițiile inițiale de proiectare prezentate în subcap. 2.1.2, prin minimizarea termenului de mediere din energia E , rezultă template-ul AINTPOL1, care include numai operatorul A (Gacsádi and Szolgay 2001):

$$A = \begin{pmatrix} 0 & 0.25 & 0 \\ 0.25 & 0 & 0.25 \\ 0 & 0.25 & 0 \end{pmatrix}. \quad (2.2.4)$$

În principiu, funcția de cost corespunzătoare termenului de penalitate (de accentuare) a muchiilor poate avea o formă similară ca și termenul de mediere, evident cu semn schimbat. În aceleași condiții de proiectare, prin minimizarea acestei componente rezultă template-ul care include numai operatorul B diferit de zero ($A=0$ și $z=0$):

$$B = \begin{pmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{pmatrix}. \quad (2.2.5)$$

În consecință, pentru îmbunătățirea CNN adaptivă a imaginilor bazată pe calcul variațional rezultă template-ul ENHAN de forma:

$$A = \begin{pmatrix} 0 & 0.25 & 0 \\ 0.25 & 0 & 0.25 \\ 0 & 0.25 & 0 \end{pmatrix} \quad B = \begin{pmatrix} 0 & -\lambda & 0 \\ -\lambda & 4 \cdot \lambda & -\lambda \\ 0 & -\lambda & 0 \end{pmatrix} \quad z = 0, \quad (2.2.6)$$

unde λ este un parametru care definește raportul, balansul dintre mediere și accentuarea contrastului și muchiilor. Pentru valori subunitare ale lui λ predomină efectul de mediere (reducere a zgomotului), iar pentru valori supraunitare ale lui λ predomină efectul de accentuare a contrastului (extragerea muchiilor).

Testarea metodelor CNN de îmbunătățire a imaginilor

În continuare, sunt prezentate rezultatele experimentale obținute, cu ajutorul mediului de dezvoltare CadetWin (**1999a) și a mediului Matlab, pentru îmbunătățirea adaptivă CNN a imaginilor (Gacsádi and Szolgay 2003).

Se consideră o imagine cu contrast redus și cu zgomot (figura 2.2.2a). Această imagine este procesată CNN utilizând template-uri care rezultă din relația (2.2.6) pentru diferite valori ale parametrului scalar λ .

Dacă $\lambda=0$ se produce doar medierea imaginii (figura 2.2.2b), ceea ce duce practic la pierderea muchiilor. Dacă $\lambda=2$, practic accentuarea locală a contrastului conduce la situația în care doi pixeli vecini pot avea numai valori extreme, $+1$ sau -1 (2.2.2c). În figura 2.2.2d,e,f sunt prezentate rezultatele procesării imaginii inițiale pentru: $\lambda=0.05$; $\lambda=0.4$ și respectiv $\lambda=1.5$.




Figura 2.2.2: Îmbunătățirea imaginii utilizând ENHAN: a) imaginea inițială; b) imaginea de ieșire pentru $\lambda=0$; c) imaginea de ieșire pentru $\lambda=2$; d) imaginea de ieșire pentru $\lambda=0.05$; e) imaginea de ieșire pentru $\lambda=0.4$; f) imaginea de ieșire pentru $\lambda=1.5$.

Efectul preprocesării unei imaginii prin aplicarea metodei descrise mai sus se poate evidenția prin evaluarea histogramelor globale și din aceeași zone de interes ale imaginii inițiale (figura 2.2.3), din imaginea care rezultă în urma efectuării scalării globale, (figura 2.2.4), realizate pe baza relației (2.2.1), respectiv din imaginea obținută prin utilizarea template-ului ENHAN pentru $\lambda=1$ (figura 2.2.5). Scalarea globală poate conduce la saturări locale, în schimb procesarea CNN bazată pe ENHAN realizează o echilibrare locală a nivelului de intensitate.

Metoda CNN de îmbunătățire adaptivă a imaginilor, utilizând ENHAN, realizează îmbunătățirea contrastului imaginilor prin egalizarea și modificarea adaptivă a histogramei.

De asemenea, aprecierea performanței procedurii de procesare prezentat mai sus se poate face dacă se evaluează imaginea care rezultă după detecția muchiilor, pentru o imagine

inițială fără zgomot dar cu contrast redus, imaginea obținută prin scalarea globală și, imaginea obținută după preprocesare cu ENHAN (figura 2.2.6). Pentru detecția muchiilor s-a utilizat același template EDGEGRAY (***) 2010). Astfel, se constată că detecția muchiilor este corectă și robustă numai în imaginea obținută prin scalarea globală și în imaginea obținută după preprocesare cu ENHAN.




Figura 2.2.3: Imaginea inițială: a), b), c) histograme locale; d) histograma globală.




Figura 2.2.4: Imaginea obținută prin scalarea globală: a), b), c) histograme locale; d) histograma globală.




Figura 2.2.5: Imaginea obținută utilizând ENHAN: a), b), c) histograme locale pentru $\lambda=1$; d) histograma globală.




Figura 2.2.6: a) imaginea inițială, fără zgomot dar cu contrast redus; b) imaginea obținută prin scalarea globală; c) imaginea obținută utilizând ENHAN pentru $\lambda=1$; d) detecția muchiilor în imaginea inițială; (e) detecția muchiilor în imaginea obținută prin scalarea globală; (f) detecția muchiilor procesată cu ENHAN pentru $\lambda=1$.

În figura 2.2.7 sunt prezentate rezultatele procesării unei imagini cu zgomot dar cu contrast ridicat. Reducerea zgomotului din imaginea inițială, în urma procesării cu ENHAN se poate observa din evaluarea imaginii care rezultă după detecția muchiilor.




Figura 2.2.7: a) imagine cu zgomot și cu contrast ridicat; b) imaginea obținută utilizând ENHAN pentru $\lambda=0.05$; c) detecția muchiilor în imaginea inițială; d) detecția muchiilor procesată cu ENHAN.

Tehnicile de îmbunătățire a imaginilor sunt deosebit de utile mai ales la interpretarea imaginilor biomedicale (Szabó et al. 2002). Îmbunătățirea calității imaginilor tomografice are drept scop obținerea unei vizibilități superioare a componentelor imaginii, creșterea adaptivă a contrastului, în vederea interpretării cât mai ușoare de către medicul specialist.

În cazul imaginilor CT, atunci când contrastul este satisfăcător rezultă necesitatea unei preprocesări a imaginii prin utilizarea lui AINTPOL1 ($\lambda=0$) respectiv, ENHAN cu $\lambda=0.05$ (figura 2.2.8). Astfel, analiza imaginii după detecția mușchilor din imaginile preprocesate poate deveni mai ușoară.




Figura 2.2.8: a) imagine CT cu zgomot și cu contrast ridicat; b) imaginea obținută utilizând ENHAN ($\lambda=0.05$); c) detecția mușchilor procesată cu ENHAN ($\lambda=0.05$).

Îmbunătățirea imaginilor CT cu contrast redus se poate obține utilizând ENHAN, având valori ale parametrului scalar λ mai mari decât 1 (figura 2.2.9).




Figura 2.2.9: a) imagine CT cu contrast scăzut; b) imaginea obținută utilizând ENHAN ($\lambda=1$); c) imaginea obținută prin scalarea globală.

În figura 2.2.10 sunt prezentate rezultatele îmbunătățirii unor imagini de cord cu contrast redus utilizând ENHAN (Gacsádi et al. 2005).




Figura 2.2.10: a) și c) imagini de cord cu contrast scăzut; b) și d) imagini obținute utilizând ENHAN.

Pe baza rezultatelor prezentate se poate constata validitatea metodei propuse pentru îmbunătățirea adaptivă CNN a imaginilor, în principal cu aplicații concrete pentru imagini medicale.

2.2.2. Filtrarea zgomotului din imagini, bazată pe calcul variațional utilizând rețele neuronale/nelineare celulare

Reducerea zgomotului din imagini

Pentru reducerea zgomotului din imagini sunt cunoscute din literatura de specialitate modele matematice complexe și eficiente, inclusiv modele bazate pe utilizarea ecuațiilor cu derivate parțiale (*PDE*) (Casellas et al. 1998), (Budaes et al. 2005), (Chan et al. 2003), (Angenent et al. 2006). Majoritatea acestor metode au performanțe remarcabile atunci când imaginea procesată corespunde modelului algoritmului, dar în caz contrar eșuează sau produc artefacte semnificative. În același timp, cu cât metoda este mai performantă cu atât necesită timp de calcul mai mare. De aceea, prelucrarea imaginii în timp real devine dificilă.

În analiza și prelucrarea imaginilor o problemă importantă este reconstrucția unei imaginii originale Φ_0 , din imaginea degradată achiziționată Φ . La deteriorarea unei imagini pot contribui două fenomene: unul este legat de metoda de achiziție (de exemplu, achiziționarea prin proiecții a unei imagini CT sau înceteșarea (*blurring*) cauzată de mișcare); celălalt este chiar zgomotul aleatoriu, inerent, care este asociat oricărui semnal util.

Cel mai simplu model care ține seama deopotrivă de neclaritate și de zgomot este modelul degradării liniare (Budaes et al. 2005):

$$\Phi = H\Phi_0 + \eta, \quad (2.2.7)$$

unde Φ_0 este imaginea originală, Φ este imaginea observată și degradată, η reprezintă zgomotul aditiv. Matricea H reprezintă operatorul liniar de degradare (*blur operator, linear distorsion*), care poate fi invariant sau variant în spațiu.

Adesea se poate presupune că zgomotul este alb, Gaussian și aditiv. Reconstrucția imaginii poate fi interpretată în acest fel ca o problemă inversă. Astfel, filtrarea zgomotului reprezintă recuperarea unei imagini originale Φ_0 , dintr-o imagine de intrare cu zgomot Φ . Imaginea recuperată conține regiuni omogene separate de muchii evidente.

Filtrarea CNN a zgomotului din imagini

În scopul reducerii zgomotului din imagini, utilizând modele matematice bazate pe ecuații cu derivate parțiale, metoda de regularizare reprezintă o alternativă interesantă în raport cu metoda de difuzie neliniară (Mumford and Shah 1989), (Rudin et al. 1992), (Perona and Malik 1990), (Rekeczky et al. 1998), (Chan et al. 2003), (Chan and Esedoglu 2005). Unele tehnici de filtrare a imaginilor sunt realizabile și cu metode de calcul CNN.

În cazul filtrării zgomotului din imagini bazată pe calcul variațional, în principiu, energia minimizată trebuie să conțină doi termeni, unul care stimulează netezirea și al doilea care ține cont de asemănarea cu imaginea originală (termen de fidelitate și conservare a muchiiilor) (Mumford and Shah 1989):

$$E_\Phi(\Phi_0) = \underbrace{\alpha E_1}_{\text{Fidelitate}} + \underbrace{\lambda E_2}_{\text{Mediere}}. \quad (2.2.8)$$

Pe baza relației (2.2.8), pentru diferite perechi de energii (E_1, E_2), în literatura de specialitate există diferite metode de filtrare a zgomotului din imagini. În prezenta secțiune sunt analizate comparativ eficiențele unora dintre aceste metode. De menționat că, prin implementare CNN există posibilitatea analizei eficienței filtrării imaginilor și pentru alte perechi de energii (E_1, E_2) prin care se poate optimiza în ansamblu precizia procesării și timpul de calcul. Astfel, am dimensionat template-urile originale DN_AINTPOL2 și VSGN.

Aplicând metoda de proiectare pentru template-uri descrisă în subcap. 2.1.2, în continuare, sunt analizate performanțele filtrării zgomotului bazate pe calcul variațional pentru diferite funcții de cost:

- Utilizând funcția de energie care rezultă din combinația termenului de fidelitate din funcția de energie propusă de Rudin, Osher și Fatemi (Rudin et al. 1992) și termenul de energie pentru mediere care este integrala Dirichlet (Gacsádi et al. 2009):

$$E_{DN_AINTPOL2} = \frac{\alpha}{2} \iint_{x,y \in \Omega} (\Phi - \Phi_0)^2 dx dy + \lambda \iint_{x,y \in \Omega} |\nabla \Phi_0|^2 dx dy \quad (2.2.9)$$

rezultă template-ul DN_AINTPOL2:

$$A = \begin{pmatrix} 0 & 0.25 & 0 \\ 0.25 & 0 & 0.25 \\ 0 & 0.25 & 0 \end{pmatrix} \quad D = \begin{pmatrix} 0 & 0 & 0 \\ 0 & d & 0 \\ 0 & 0 & 0 \end{pmatrix} \quad (2.2.10)$$

unde: $d = \alpha(x_{ij} - u_{ij})$; $\alpha \in [0, 1]$ și ($B=0, z=0$).

- Utilizând funcția de energie propusă de Rudin, Osher și Fatemi (Rudin et al. 1992):

$$E_{OSRUFA} = \frac{\alpha}{2} \iint_{x,y \in \Omega} (\Phi - \Phi_0)^2 dx dy + \lambda \iint_{x,y \in \Omega} |\nabla \Phi_0| dx dy, \quad (2.2.11)$$

rezultă template-ul neliniar OSRUFA (Gacsádi et al. 2009):

$$A = \begin{pmatrix} 0 & a & 0 \\ a & 1 & a \\ 0 & a & 0 \end{pmatrix} \quad D = \begin{pmatrix} 0 & 0 & 0 \\ 0 & d & 0 \\ 0 & 0 & 0 \end{pmatrix}, \quad (2.2.12)$$

unde: $a = \lambda \operatorname{sgn}(y_{ij} - y_{kl})$, $\lambda \in [0, 1]$, $d = \alpha(x_{ij} - u_{ij})$, $\alpha \in [0, 1]$ și ($B=0$, $z=0$).

- Utilizând funcția de energie propusă de Chan și Esedoglu (Chan and Esedoglu 2005):

$$E_{CHES} = \alpha \iint_{x,y \in \Omega} |\Phi - \Phi_0| dx dy + \lambda \iint_{x,y \in \Omega} |\nabla \Phi_0| dx dy \quad (2.2.13)$$

rezultă template-ul CHES (Gacsádi et al. 2009):

$$A = \begin{pmatrix} 0 & a & 0 \\ a & 1 & a \\ 0 & a & 0 \end{pmatrix} \quad D = \begin{pmatrix} 0 & 0 & 0 \\ 0 & d & 0 \\ 0 & 0 & 0 \end{pmatrix}, \quad (2.2.14)$$

unde: $a = \lambda \operatorname{sgn}(y_{ij} - y_{kl})$, $\lambda \in [0, 1]$ și $d = \alpha \operatorname{sgn}(x_{ij} - u_{ij})$, $\alpha \in [0, 1]$ și ($B=0$, $z=0$).

- Utilizând funcția de energie (Gacsádi and Szolgyay 2009):

$$E_{VSGN} = \alpha \iint_{x,y \in \Omega} |\nabla(\Phi - \Phi_0)| dx dy + \lambda \iint_{x,y \in \Omega} |\nabla \Phi_0| dx dy \quad (2.2.15)$$

rezultă template-ul VSGN:

$$A = \begin{pmatrix} 0 & a & 0 \\ a & 1 & a \\ 0 & a & 0 \end{pmatrix} \quad D = \begin{pmatrix} 0 & d & 0 \\ d & 0 & d \\ 0 & d & 0 \end{pmatrix} \quad (2.2.16)$$

unde: $a = \lambda \operatorname{sgn}(y_{ij} - y_{kl})$, $\lambda \in [0, 1]$, $d = \alpha \operatorname{sgn}(x_{ij} - u_{kl})$, $\alpha \in [0, 1]$ și ($B=0$, $z=0$).

Testarea metodelor de filtrare CNN

Performanțele tehnicilor de reducere a zgomotului sunt greu de evaluat, în absența cunoașterii imaginii originale fără zgomot. În anumite situații, dacă se cunoaște imaginea originală fără zgomot, rezultatele obținute în urma prelucrărilor pot fi comparate pe baza unor mărimi cantitative deduse experimental. Adesea, mai ales în aplicații de imagistică medicală, nu există altă metodă de evaluare a performanței procesării decât cea calitativă în urma vizualizării directe de către experți. În domeniul imagisticii medicale, zgomot alb Gaussian aditiv reprezintă o pondere semnificativă și, prin urmare, vom trata procesarea unor imagini care includ acest tip de zgomot (Budaes et al. 2005).

La testarea metodelor de filtrare CNN s-au utilizat mediul de dezvoltare CadetWin (**1999a) și mediul Matlab.

În următoarele exemple, pentru aprecierea eficacității metodelor de extragere a zgomotului se va evalua, pe de o parte, măsura în care metoda afectează o imagine cu zgomot,

adică, care sunt „beneficiile” procesării respective în reducerea zgomotului (figura 2.2.11, figura 2.2.12). Pentru această etapă, de fapt, imaginea cu zgomot rezultă chiar prin adăugarea la imaginea inițială ideală fără zgomot, Φ_0 , a unui zgomot alb, Gaussian, cu valori cunoscute. Pe de altă parte, se va evalua în ce măsură metoda de prelucrare conservă muchiile, adică care sunt „costurile” procedurii. În acest scop, pentru o mai ușoară interpretare a rezultatelor se va analiza măsura în care procedura de extragere a zgomotului afectează o imagine considerată ideală adică fără zgomot, Φ_0 (figura 2.2.13, figura 2.2.14). Evident, în ambele situații, este de dorit ca erorile rezultate să fie cât mai mici.

Ponderarea funcțiilor de cost s-a realizat cu parametrii scalari care satisfac condițiile impuse pentru dimensionarea template-ului CNN, bazată pe calcul variațional, α și λ având valori între 0 și 1. În experimentele prezentate mai jos, α și λ au fost stabilite la valoarea 0.01, pentru toate template-urile determinate.

Pentru a evalua global eficiența filtrării zgomotului din imagini, se calculează erorile care rezultă din compararea imaginii originale ideale, Φ_0 , considerată neafectată de zgomot, cu imaginile obținute după prelucrare, Φ , utilizând funcția de eroare:

$$ER = \sqrt{\frac{\sum_{\Omega} (\Phi_0(i, j) - \Phi(i, j))^2}{M * N}}, \quad 1 \leq i \leq M; \quad 1 \leq j \leq N, \quad (2.2.17)$$




Figura 2.2.11: Filtrarea zgomotului din imagini: a) imaginea A cu zgomot alb Gaussian, cu media zero și varianța 0.04; b) filtrarea cu DN_AINTPOL2; c) filtrarea cu OSRUFA; d) filtrarea cu CHES.

În tabelul 2.1 sunt prezentate valorile erorilor, ERA, care rezultă prin procesarea CNN a imaginii A de intrare cu zgomot (figura 2.2.11a) și a imaginii A originale fără zgomot (figura 2.2.13a), utilizând template-urile DN_AINTPOL2, OSRUFA și CHES.

În tabelul 2.2 sunt prezentate valorile erorilor, ERB, care rezultă prin procesarea CNN a imaginii B de intrare cu zgomot (figura 2.2.12a) și a imaginii B originale fără zgomot (figura 2.2.14a), utilizând template-urile OSRUFA, CHES și VSGN.




Figura 2.2.12: Filtrarea zgomotului din imagini: a) imaginea B cu zgomot alb Gaussian, cu media zero și varianța 0.04; b) filtrarea cu OSRUFA; c) filtrarea cu CHES; d) filtrarea cu VSGN.

Tabelul 2.1. Erori ale unor metode CNN de filtrare a imaginii A.

<i>Template</i>	<i>Erori - ERA</i>	
	<i>Imaginea A fără zgomot</i>	<i>Imagine A cu zgomot</i>
DN_AINTPOL2	12.54	12.59
OSRUFA	4.38	12.74
CHES	2.27	8.31

Tabelul 2.2. Erori ale unor metode CNN de filtrare a imaginii B.

<i>Template</i>	<i>Erori - ERB</i>	
	<i>Imaginea B fără zgomot</i>	<i>Imagine B cu zgomot</i>
OSRUFA	2.17	13.01
CHES	0.51	8.25
VSGN	0.20	4.84

Pentru aprecierea comportamentului privind conservarea muchiilor se vor vizualiza imaginile de eroare Φ_{ER} , (figura 2.2.11), care rezultă pe baza relației:

$$\Phi_{ER} = \Phi_0(i, j) - \Phi(i, j), \quad 1 \leq i \leq M; \quad 1 \leq j \leq N. \quad (2.2.18)$$

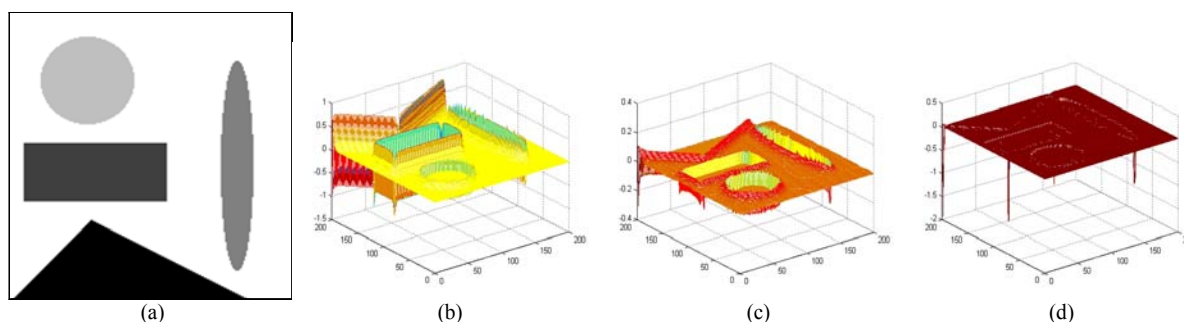


Figura 2.2.13: Filtrarea zgomotului din imaginea A, evaluarea conservării muchiilor, utilizând imaginea eroare Φ_{ER} : a) imagine fără zgomot de referință; b) filtrarea cu DN_AINTPOL2 c) filtrarea cu OSRUFA; d) filtrarea cu CHES.

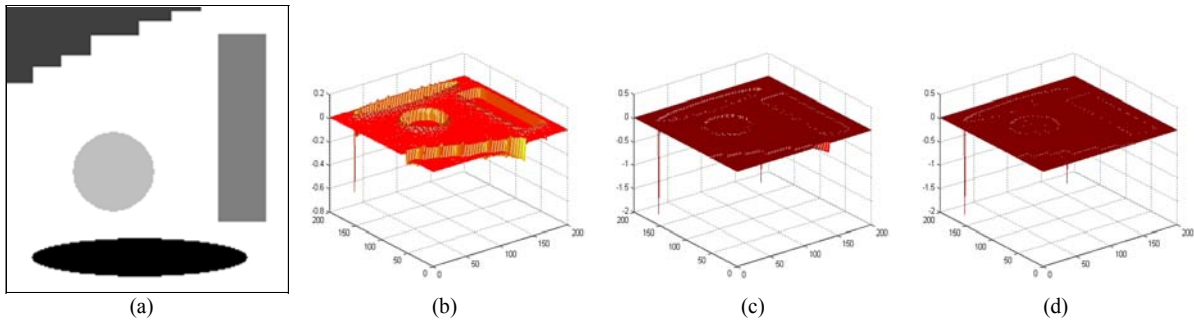


Figura 2.2.14: Filtrarea zgomotului din imaginea B, evaluarea conservării muchiilor, utilizând imaginea eroare Φ_{ER} : a) imagine fără zgomot de referință; b) filtrarea cu OSRUFA; c) filtrarea cu CHES; d) filtrarea cu VSGN.

Analizând rezultatele obținute, din punctul de vedere al extragerii zgomotului prin mediere, DN_AINTPOL2 și OSRUFA au cele mai slabe comportamente și se remarcă eficiența globală mai ridicată pentru VSGN. De asemenea, în privința conservării muchiilor, se observă că DN_AINTPOL2 introduce cele mai mari erori, în timp ce CHES și VSGN au cele mai bune performanțe.

Utilizând aceleași procedee CNN la extragerea zgomotului din imagini ca în exemplele de mai sus, în figura 2.2.15 sunt redată rezultatele obținute pentru o imagine naturală. În cazul acestor imagini, și pentru nespecialiști este posibilă interpretarea eficienței procesării efectuate prin observarea directă a unor parametri: nivelul de zgomot, claritatea și contrastul.




Figura 2.2.15: Filtrarea zgomotului din imagini: a) imagine inițială considerată fără zgomot b) imagine cu zgomot alb Gaussian; c) filtrarea cu OSRUFA; d) filtrarea cu CHES; e) filtrarea cu VSGN.

Mai ales în domeniul prelucrării imaginilor biomedicale fiecare etapă de procesare trebuie să fie efectuată, fără modificări sau pierderi de informații utile. Filtrarea imaginilor computer tomografice are drept scop reducerea zgomotului pentru obținerea unei vizibilități

superioare a componentelor imaginii, în vederea interpretării cât mai ușoare de către medicul specialist. În figura 2.2.16 sunt prezentate rezultatele obținute, în urma prelucrării cu metodele CNN descrise anterior, asupra unei imagini CT reale cu zgomot (Gacsádi and Szolgay 2009).




Figura 2.2.16: Filtrarea zgomotului din imagini CT reale: a) imagine cu zgomot; b) filtrarea cu OSRUFA; c) filtrarea cu CHES; d) filtrarea cu VSGN.

2.2.3. Segmentarea CNN a imaginilor

Metode de segmentare a imaginilor

Segmentarea imaginilor prin delimitarea structurilor anatomice și a regiunilor de interes are un rol crucial în majoritatea aplicațiilor de imagistică medicală, atât în faza de stabilire a diagnozei prin localizarea patologiei, cât și în planificarea și efectuarea tratamentului adecvat, cum ar fi de exemplu, biopsia, radioterapia sau chirurgia minim invazivă. În acest sens, segmentarea automată reprezintă un set de metode care creează prin imagini relevante modelul anatomic specific al pacientului. O situație tipică pentru un sistem de asistare a diagnozei medicale este aceea când în urma segmentării imaginii rezultă diferite regiuni etichetate ca fiind țesut sănătos sau o tumoare (Pham et al. 2000).

Au fost elaborate numeroase metode pentru a rezolva problema segmentării de imagini aceasta fiind o etapă importantă de procesare într-un sistem de asistare a diagnozei medicale. În primul rând, pentru imagini cu niveluri de gri, segmentarea poate fi bazată pe detecția muchiilor sau pe tehnici bazate pe regiuni. Metoda bazată pe regiuni poate fi mai puțin sensibilă la zgomot decât metodele morfologice sau cele bazate pe extragerea muchiilor, dar ele pot necesita o mare putere de calcul chiar și în cazuri simple. Pe de altă parte, în acest domeniu, și alte abordări au devenit populare, cum ar fi metodele bazate pe: evoluția curbei, suprafețe active, abordări statistice și calcul variațional.

Performanțele unei tehnici de segmentare sunt greu de evaluat. În prezent nu există o metodă anume, generală, de segmentare, care să producă rezultate acceptabile pentru orice tip de imagini medicale. Fiecare dintre aceste metode își au avantajele și dezavantajele lor, după cum un anumit algoritm optimizat pentru procesarea pe o anumită structură hardware poate să nu mai funcționeze la fel de bine pe o altă structură.

Procedeele utilizate pentru efectuarea segmentării imaginilor variază foarte mult în funcție de specificul aplicației, modalitatea de formare a imaginii, precum și de alți factori. Dar chiar și în imagistica medicală, pentru a atinge același obiectiv, metoda optimă de prelucrare poate fi diferită în cazul în care imaginea este CT sau IRM. Mai mult decât atât, în cazul imaginilor CT segmentarea țesutului creierului are cerințe diferite față de cerințele pentru segmentarea ficatului.

Pentru segmentarea imaginilor cele mai recente abordări utilizează metoda conturilor active, care poate fi bazată pe energie sau bazată pe set de nivele, dar și pe variantele acestora. Aceste tehnici se caracterizează prin performanțe mult mai bune privind precizia, dar în același timp și prin timp ridicat de prelucrare chiar și în condițiile utilizării unei puteri de calcul deosebit de ridicate.

Astfel, prin utilizarea rețelelor neuronale/neliniare celulare în cazul tehnicii conturilor active convenționale a rezultat metoda celulară a conturilor active (*CAC-Cellular Active Contours*). Actualmente pentru această metodă există două abordări. O abordare bazată pe utilizarea PDE (Rekeczky and Chua 1999), (Rekeczky 2002), care implementează contururi active prin tehnică non-iterativă de propagare pe regiuni, unde conturile sunt definite de frontul undelor care se propagă. Deși metoda asigură viteză de calcul ridicată, slăbiciunea acestei metode provine din dificultatea de a controla evoluția conturului și de a nu permite expansiunea și contracția simultană a diferitelor părți ale regiunilor active. În aplicații reale pentru eliminarea acestor deficiențe inevitabil crește și complexitatea algoritmului.

Cealaltă metodă este iterativă și are la bază tehnica PLS (*Pixel-Level Snakes*) (Vilariño and Rekeczky 2005). Această procedură se bazează pe existența unor contururi deformabile care evoluează pixel cu pixel de la formele lor inițiale până la delimitarea obiectelor de interes. Schimbarea conturului este ghidată de informații locale din imagine, luând în considerare atât forțe externe, care întind conturul spre margini, cât și de forțele interne (termeni de regularizare), care încearcă să mențină netezimea curbei conturului.

Rețelele neuronale discrete în timp (*DTCNN-Discrete Time Cellular Neural Networks*) se pot utiliza pentru segmentarea imaginii bazate pe tehnici de contur active (Vilariño et al. 2003). Utilizând astfel de rețele se realizează doar parțial procesarea paralelă ale unor etape din algoritmul implementat. Prin utilizarea unei rețele neuronale/neliniare speciale bazate pe folosirea unor praguri multiple și a unor neuroni binari universali (*UBN-Universal Binary Neurons*), se poate reduce timpul necesar calculelor deoarece acestea necesită numai operații booleene (Aizenberg et al. 2001).

Vilariño și Rekeczky, propune un alt algoritm pentru metoda celulară a conturilor active, care are în vedere, o mai mare eficiență și flexibilitate în evoluția conturului în raport cu limitele de interes urmărite (Vilariño and Rekeczky 2005). Pe de altă parte, acest algoritm este implementat efectiv pe cel mai performant chip CNN analogic existent la momentul

respectiv. Rezultatele obținute au fost evaluate din punctul de vedere al flexibilității, vitezei de procesare, preciziei, convergenței și robusteții.

Pentru localizarea și urmărirea conturului unui obiect dintr-o imagine sunt propuse și alte abordări de calcule celulare topografice (Hillier et al. 2006). Autorii compară performanțele a trei metode de segmentare (*Pixel Level Snakes*, *Constrained Wave*, *Computing and Moving and Patch Method*) pe aceeași platformă hardware și software. Pe baza rezultatelor obținute pentru segmentarea imaginilor se recomandă elaborarea unor algoritmi care din structura unui sistem de calcul dedicat pentru prelucrări de imagini de calcul (*High-performance Visual Computer*) exploatează optim și complementar deopotrivă platforma cu chip-ul analogic CNN respectiv, procesoarele numerice de semnal (*DSP-Digital Signal Processor*).

Din cele prezentate mai sus rezultă că tehnica PLS permite controlul riguros al evoluției conturului dar poate fi de complexitate mai ridicată și mare consumatoare de timp față de tehnica bazată pe propagarea undei. Prin urmare, un algoritm nou este propus de Dudek și Vilariño pentru a aplica metoda celulară a conturilor active bazate pe PLS (Dudek and Vilariño 2006). Această nouă abordare optimizează performanțele de calcul, prin implementarea pe un procesor cu structura dedicată pentru această aplicație (*SIMD-Single Instruction Multiple Data processor arrays*).

În prezenta secțiune sunt sintetizate concluziile privind analiza și selectarea unor metode pentru segmentarea CNN a imaginilor medicale, în particular a imaginilor CT, având atenția focusată, în primul rând, pe izolarea și evaluarea în timp real a metastazelor hepatice. În acest scop, s-au propus metode CNN optimizate pentru segmentarea imaginilor medicale, bazate pe calcul variațional, având în permanență în vedere posibilitatea implementării algoritmului într-un sistem semiautomat de diagnoză medicală, supravegheată de expertul în imagistică medicală (Gacsádi and Szolgay 2010), (Gacsádi et al. 2011), (Țepelea et al. 2010). Metodele alese de segmentare trebuie să asigure reproductibilitate, programabilitate, robustețe, sensibilitate și selectivitate ridicată, dar în același timp, imunitate mare la zgomot și reducerea timpului de procesare. Actualmente, aceste cerințe pot fi asigurate pentru metodele propuse doar prin utilizarea unor platforme hardware cum ar fi, de exemplu, de tip emulator digital CNN implementat FPGA (Nagy et al. 2006). Desigur, în urma abordării acestei tematici, datorită complexității, diversității și dificultății întrebărilor fundamentale ridicate și existente la ora actuală în imagistică medicală, rezultatele obținute oferă soluții doar la un număr foarte restrâns de probleme.

Rezultatele experimentale pentru testarea metodelor CNN de segmentare a imaginilor, prezentate în continuare, au fost obținute cu ajutorul mediului de dezvoltare CadetWin (**1999a) și a mediului Matlab.

Segmentarea CNN bazată pe detecția muchiilor

În vederea segmentării CNN bazată pe contur, imaginea achiziționată de intrare trebuie să fie anterior preprocesată în scopul îmbunătățirii ei, astfel încât în urma segmentării să rezulte descompunerea corectă a imaginii în elementele constitutive.

Prin aplicarea succesivă a filtrării CNN a imaginii cu ajutorul OSRUFA (subcap. 2.2.2) urmată de îmbunătățirea adaptivă a contrastului imaginii cu ENHAN (subcap. 2.2.1), se pot echilibra aceste procesări. Un exemplu al efectuării acestor procesări succesive pentru o imagine CT este prezentat în figura 2.2.17 (Gacsádi et al. 2011). Pentru detecția muchiilor s-a utilizat același template EDGEGRAY(*** 2010).




Figura 2.2.17: a) imagine cu zgomot și cu contrast ridicat; b) imaginea obținută cu filtrarea OSRUFA; c) imaginea obținută după filtrarea cu OSRUFA și procesarea cu ENHAN; d) detecția muchiilor în imaginea inițială; e) detecția muchiilor din imaginea filtrată cu OSRUFA; f) detecția muchiilor din imaginea filtrată cu OSRUFA și procesarea cu ENHAN.

Rezultatele obținute confirmă eficiența metodei propuse și se poate observa că extragerea conturilor din imaginea cu zgomot este practic imposibilă, dar extragerea conturilor chiar și din imaginea filtrată se produce cu pierdere de informație.

Pe de altă parte, în vederea eficientizării segmentării imaginilor CT cu zgomot, se propune optimizarea template-ului AVERGRAD (Țepelea et al. 2010). Valorile parametrilor b și z care conduc cu acest template la segmentare optimă, rămân valabile dacă imaginile prelucrate sunt caracterizate prin conținut asemănător de zgomot, adică sunt achiziționate în condiții similare. Oricum, înaintea detecției muchiilor este necesară filtrarea prealabilă a zgomotului din imagini.

Detecția muchiilor este unul dintre cei mai importanți pași în procesarea imaginilor medicale. Obținerea unor muchii de calitate într-o imagine depinde foarte mult de alegerea operatorilor potriviți pentru tipul de imagine analizat și mai ales ca operatorii să fie adaptați pentru de tipul de zgomot prezent în imaginile originale.

Pentru detecția muchiilor, în cazul imaginilor cu nivele de gri, este utilizat frecvent template-ul EDGEGRAY (***) 2010).

$$A = \begin{pmatrix} 0 & 0 & 0 \\ 0 & 2 & 0 \\ 0 & 0 & 0 \end{pmatrix} B = \begin{pmatrix} -1 & -1 & -1 \\ -1 & 8 & -1 \\ -1 & -1 & -1 \end{pmatrix} z = -0.5 \quad (2.2.19)$$

Aplicarea acestui template are dezavantajul că amplifică și zgomotul din imagini. Din acest motiv, în cazul imaginilor cu niveluri de gri, afectate de zgomot, este mai potrivit template-ul AVERGRAD (***) 2010). Acest template este mai eficient deoarece realizează și un proces de mediere concomitent cu detecția muchiilor.

$$A = \begin{pmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{pmatrix} B = \begin{pmatrix} b & b & b \\ b & 0 & b \\ b & b & b \end{pmatrix} z = 0 \quad (2.2.20)$$

unde $b = \rho(u_{ij} - u_{kl})$, $\rho \in [0, 1]$, (figura 2.2.18).




Figura 2.2.18: Caracteristica de transfer b .

Zgomotele care afectează cel mai mult imaginile medicale de tip CT, sunt zgomotul de tip Gaussian și cel de tip sare și piper. Pornind de la această ipoteză a fost aplicat template-ul EDGEGRAY pe o imagine sintetică, fără zgomot (figura 2.2.19).




Figura 2.2.19: Detecția muchiilor cu EDGEGRAY și AVERGRAD: a) imaginea inițială; b) detecția muchiilor cu EDGEGRAY, imaginea Φ_6 ; c) imaginea cu zgomot sare și piper; d) imaginea cu zgomot Gaussian; e), f) detecția muchiilor cu AVERGRAD; g), h) imaginea binară a muchiilor de la e) (imaginea Φ_6) și f) (imaginea Φ_7).

După aceea, aceiași template a fost aplicat pe aceeași imagine sintetică, dar asupra căruia a fost suprapus zgomot de tip Gaussian și zgomot de tip sare și piper.

Având imaginile muchiilor în cele două cazuri, se poate calcula eroarea pătratică medie dintre imaginea originală a muchiilor și imaginile muchiilor în cazul imaginii afectate de zgomotele mai sus menționate:

$$\text{MSE} = \frac{1}{N \cdot M} \sum_{p=1}^N \sum_{q=1}^M (\Phi_1(p, q) - \Phi_{6(7)}(p, q))^2 \quad (2.2.21)$$

În continuare sunt ajustate valorile componentelor template-ului AVERGRAD pentru a obține valoarea optimizată a lui MSE, ținând cont de ambele tipuri de zgomot analizate (figura 2.2.20).

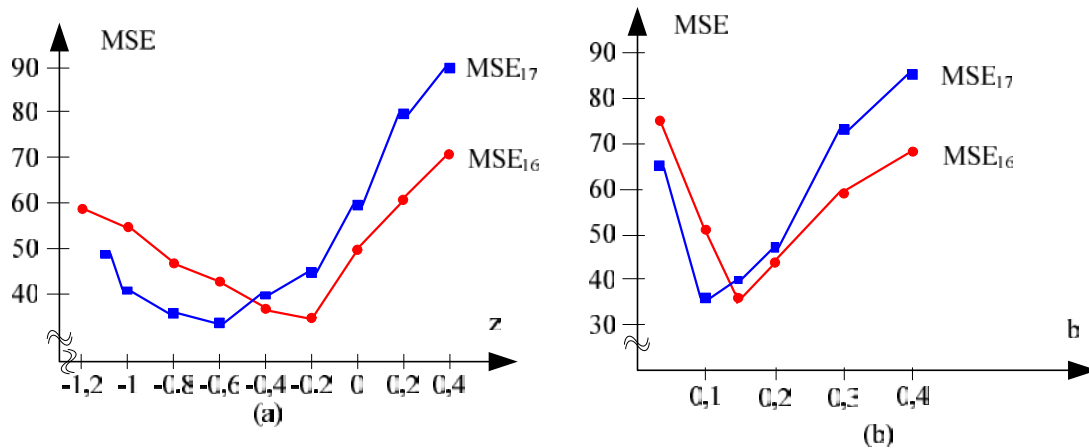


Figura 2.2.20: Valorile MSE în funcție de componentele lui AVERGRAD:
a) în funcție de z ; b) în funcție de b .

În final, se obțin noile valori pentru template-ul AVERGRADM care sunt optimizate pentru detecția muchiilor în anumite imagini medicale afectate de zgomot.

$$A = \begin{pmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{pmatrix} B = \begin{pmatrix} b & b & b \\ b & 0 & b \\ b & b & b \end{pmatrix} z = -0.2 \quad (2.2.22)$$




Figura 2.2.21: Caracteristica de transfer a lui b .

Segmentare CNN a imaginilor bazată pe calcul variațional

Reprezentând punctul de pornire pentru multe metode de segmentare a imaginilor bazată pe calcul variațional, o importanță deosebită în acest domeniu îl reprezintă funcția de energie introdusă în lucrarea (Mumford and Shah 1985) și (Morel and Solimini 1995):

$$E_{MS}(\Phi, \Gamma) = \alpha \iint_{R \setminus \Gamma} |\nabla \Phi|^2 dx dy + \beta \iint_R (\Phi - \Phi_0)^2 dx dy + |\Gamma|, \quad (2.2.23)$$

unde R este o submulțime din \mathbf{R}^2 , Φ_0 este imaginea originală, Γ reprezintă conturul rezultat prin segmentare, Φ este imaginea filtrată sau mediată (obținută printr-un proces de netezire) prelucrată $\subset \mathbf{R}^2 \setminus \Gamma$, $|\Gamma|$ este lungimea Γ , iar α și β sunt parametri scalari (α și $\beta \in \mathbf{R}^+$). Minimizarea acestei funcții de energie clasice impune estimarea a două procese, segmentarea continuă a imaginii, Φ , și detecția binară de muchii, Γ .

De fapt, se poate demonstra că majoritatea metodelor de segmentare sunt subseturi ale problemei mai generale de minimizare a funcției de cost descrisă mai sus (segmentarea bazată pe muchii, segmentarea bazată pe regiuni, segmentarea bazată pe contururi active).

Datorită dificultății determinării conturului Γ , în relația (2.2.23), acesta a fost înlocuit prin variabila continuă K de Ambrosio și Tortorelli (Shah 1996) rezultând:

$$E_{AT}(\Phi, K) = \iint_R \left\{ \alpha(1-K)^2 |\nabla \Phi|^2 + \beta(\Phi - \Phi_0)^2 + \frac{\rho}{2} |\nabla K|^2 + \frac{K^2}{2\rho} \right\} dx dy. \quad (2.2.24)$$

Avantajul major al acestei reprezentări este că, minimizarea energiei este echivalentă cu minimizarea simultană a două funcții de cost, care produc simultan o segmentare, rezultând imaginea estimată $\tilde{\Phi}$ și, un proces de detecție de muchii, rezultând imaginea estimată \tilde{K} . De aceea, minimizarea energiei din ecuația (2.2.24) a fost folosită de către mulți cercetători pentru segmentarea imaginilor, chiar dacă rezultatele obținute s-au dovedit a fi mai modeste decât cele rezultate prin folosirea altor modele matematice.

Astfel, dacă K este constant în relația (2.2.24), rezultă energia:

$$E_K(\Phi) = \iint_R \left\{ \alpha(1-K)^2 |\nabla \Phi|^2 + \beta(\Phi - \Phi_0)^2 \right\} dx dy. \quad (2.2.25)$$

Respectiv, dacă Φ este constant, rezultă energia:

$$E_\Phi(K) = \iint_R \left\{ |\nabla K|^2 + \frac{1+\Psi}{2\rho^2} \left(K - \frac{\Psi}{1+\Psi} \right)^2 \right\} dx dy, \quad (2.2.26)$$

unde $\Psi(\Phi) = 2\alpha\rho|\nabla\Phi|^2$ și ρ este un alt parametru scalar ($\rho \in \mathbf{R}^+$).

Corespunzător celor două energii de mai sus rezultă sistemul de ecuații diferențiale parțiale:

$$\frac{\partial \Phi}{\partial t} = -2\nabla K \cdot \nabla \Phi + (1-K)\nabla^2 \Phi - \frac{\beta}{\alpha(1-K)}(\Phi - K) \quad (2.2.27)$$

$$\frac{\partial K}{\partial t} = \nabla^2 K - \frac{K}{\rho^2} + \frac{2\alpha}{\rho}(1-K)|\nabla \Phi|^2 \quad (2.2.28)$$

$$\frac{\partial \Phi}{\partial n} \Big|_{\partial R} = 0; \quad \frac{\partial K}{\partial n} \Big|_{\partial R} = 0; \quad (2.2.29)$$

unde ∂R reprezintă conturul lui R iar n este normala la ∂R .

În vederea implementării segmentării imaginilor pe structuri CNN, analizând relațiile (2.2.27) și (2.2.28) se evidențiază următoarele caracteristici (Gacsádi and Szolgay 2010):

- Pentru efectuarea procesării CNN este nevoie de o structură cu mai multe straturi. Astfel, două straturi principale sunt necesare pentru obținerea imaginii estimate $\tilde{\Phi}$

respectiv, imaginii estimate \tilde{K} . Celelalte straturi sunt necesare pentru calcularea unor componente intermediare care sunt utilizate de straturile principale.

- Funcțiile de energie descrise de relațiile (2.2.25) și (2.2.26) conțin termeni ponderați de netezire, $|\nabla\Phi|^2$ respectiv $|\nabla K|^2$, termen ponderat pentru menținerea fidelității imaginii (sau termeni de conservare al muchiilor), $(\Phi - \Phi_0)^2$, respectiv termen pentru detecția muchiilor, $\left(K - \frac{\Psi}{1 + \Psi}\right)^2$.
- Rezolvarea sistemului de ecuații diferențiale parțiale, descrise de relațiile (2.2.27) și (2.2.28) include o seamă de operații care se pot soluționa eficient prin structuri paralele de procesare, inclusiv prin metode CNN.
- Includerea în aceste ecuații a unui număr însemnat de parametri scalari, care pot depinde chiar de conținutul imaginilor și care trebuie precizați apriori, înaintea efectuării procesării, determină ca sarcina optimizării soluțiilor obținute să devină deosebit de dificilă.
- Chiar și în condițiile implementării riguroase prin metode numerice a acestui model, precizia de calcul rezultată este modestă. Acest fapt este consecința mai ales a imperfecțiunilor netezirii realizate printr-o funcție de forma $|\nabla(\cdot)|^2$.
- Mai mult decât atât, prin implementarea CNN a procesării imaginilor pe structuri numerice de 8 biți, soluționarea unor astfel de ecuații sigur vor introduce aproximări și erori suplimentare.

Pe baza acestor caracteristici, într-o primă aproximație, ca soluție de compromis, actualmente se justifică evaluarea unor algoritmi în care, se elimină interacțiunea dintre cele două straturi principale, astfel încât practic cele două ecuații diferențiale parțiale se pot rezolva succesiv. În consecință, dimensionarea unor template-uri care să asigure tocmai procesarea dorită a unei imagini cu niveluri de gri este o problemă dificilă, chiar dacă sunt utilizate metode bazate pe calcul variațional.

În vederea segmentării imaginilor cu niveluri de gri, la dimensionarea bazată pe calcul variațional a template-urilor CNN se consideră că sunt respectate toate considerentele și etapele de proiectare menționate în subcap. 2.1.2.

Pentru efectuarea segmentării CNN a imaginilor bazată pe calcul variațional, în cele ce urmează se vor analiza caracteristicile rezultate prin utilizarea unor funcții de energie pentru determinarea celor două imagini, imaginea filtrată Φ și imaginea cu muchii K . Imaginea segmentată estimată, $\tilde{\Phi}$, va rezulta prin fuziunea acestor două imagini, Φ și K .

Pentru determinarea imaginii filtrate de zgomot, Φ , se vor utiliza următoarele funcții pentru energie:

$$- E_L(\Phi) = \iint_R \left\{ \alpha |\nabla\Phi|^2 + \beta (\Phi - \Phi_0)^2 \right\} dx dy. \quad (2.2.30)$$

După cum se poate observa, de fapt, această funcție de energie, E_L (Laplace), reprezintă o variantă simplificată a funcției de energie descrisă prin relația (2.2.25).

Prin minimizarea acestei energii rezultă template-ul DN_LAPLACE:

$$A = \begin{pmatrix} 0 & a & 0 \\ a & 1-4a & a \\ 0 & a & 0 \end{pmatrix} \quad D = \begin{pmatrix} 0 & 0 & 0 \\ 0 & d & 0 \\ 0 & 0 & 0 \end{pmatrix}, \quad (2.2.31)$$

unde $a = \alpha \cdot 0.25$; $\alpha \in [0, 1]$ și $d = 2\beta(x_{ij} - u_{ij})$; $2\beta \in [0, 1]$ respectiv, ($B=0, z=0$).

$$- E_{OSRUFA} = \beta \iint_R (\Phi - \Phi_0)^2 dx dy + \alpha \iint_R |\nabla \Phi_0| dx dy, \quad (\text{Rudin et al. 1992}) \quad (2.2.32)$$

Se obține template-ul OSRUFA:

$$A = \begin{pmatrix} 0 & a & 0 \\ a & 1 & a \\ 0 & a & 0 \end{pmatrix} \quad D = \begin{pmatrix} 0 & 0 & 0 \\ 0 & d & 0 \\ 0 & 0 & 0 \end{pmatrix}, \quad (2.2.33)$$

unde: $a = \alpha \operatorname{sgn}(y_{ij} - y_{kl})$; $\alpha \in [0, 1]$, $d = 2\beta(x_{ij} - u_{ij})$; $2\beta \in [0, 1]$ și ($B=0, z=0$).

$$- E_{CHES} = \alpha \iint_R |\nabla \Phi_0| dx dy + \beta \iint_R |\Phi - \Phi_0| dx dy \quad (\text{Chan and Esedoglu 2005}) \quad (2.2.34)$$

rezultând template-ul CHES:

$$A = \begin{pmatrix} 0 & a & 0 \\ a & 1 & a \\ 0 & a & 0 \end{pmatrix} \quad D = \begin{pmatrix} 0 & 0 & 0 \\ 0 & d & 0 \\ 0 & 0 & 0 \end{pmatrix}, \quad (2.2.35)$$

unde: $a = \alpha \operatorname{sgn}(y_{ij} - y_{kl})$; $\alpha \in [0, 1]$ și $d = \beta \operatorname{sgn}(x_{ij} - u_{ij})$; $\beta \in [0, 1]$ și ($B=0, z=0$).

$$- E_{VSGN}(\Phi) = \iint_R \alpha |\nabla \Phi| + \beta |\nabla(\Phi - \Phi_0)| dx dy \quad (2.2.36)$$

Prin minimizarea acestei energii rezultă template-ul VSGN:

$$A = \begin{pmatrix} 0 & a & 0 \\ a & 1 & a \\ 0 & a & 0 \end{pmatrix} \quad D = \begin{pmatrix} 0 & d & 0 \\ d & 0 & d \\ 0 & d & 0 \end{pmatrix} \quad (2.2.37)$$

unde: $a = \alpha \operatorname{sgn}(y_{ij} - y_{kl})$; $\alpha \in [0, 1]$ și $d = \beta \operatorname{sgn}(x_{ij} - u_{kl})$; $\beta \in [0, 1]$, respectiv ($B=0, z=0$).

Această funcție de energie prezentată deja, E_{VSGN} , a fost propusă pentru îmbunătățirea comportamentului privind conservarea muchiilor în cazul filtrării CNN a imaginilor. De asemenea, se observă că pentru netezirea imaginii se utilizează integrala de variație totală TV (Rudin et al. 1992).

Pentru determinarea imaginii muchiilor se justifică o funcție de energie dependentă de $|\nabla \Phi|^2$, cum ar fi de exemplu:

$$- E(K) = \iint_R \rho |\nabla \Phi|^2 dx dy. \quad (2.2.38)$$

Prin minimizarea acestei energii rezultă template-ul neliniar GRAD (***) 2010):

$$B = \begin{pmatrix} 0 & b & 0 \\ b & 0 & b \\ 0 & b & 0 \end{pmatrix}, \quad (2.2.39)$$

unde: $b = \rho(u_{ij} - u_{kl})$; $\rho \in [0, 1]$, respectiv ($A=0$, $z=0$).

După analiza comportamentului acestui template privind producerea de contururi false, în final, s-a optat pentru template-ul AVERGRAD (eventual chiar varianta optimizată AVERGRADM) la detecția muchiilor, acesta având un comportament mai eficient în prezența zgomotului, prin faptul că realizează și o mediere asupra imaginii concomitent cu detecția muchiilor (***) 2010):

$$B = \begin{pmatrix} b & b & b \\ b & 0 & b \\ b & b & b \end{pmatrix}, \quad (2.2.40)$$

unde $b = \rho(u_{ij} - u_{kl})$; $\rho \in [0, 1]$ și ($A=0$, $z=0$).

Testarea metodelor bazate pe calcul variațional de segmentare CNN a imaginilor

Pentru exemplificarea modului în care algoritmi propuși, bazați pe calcul variațional, realizează segmentarea CNN, s-au construit imagini sintetice, fără zgomot și imagini la care s-au adăugat în mod artificial zgomot alb Gaussian (Gacsádi and Szolgay 2010). Rezultatele obținute sunt prezentate în figura 2.2.22.




Figura 2.2.22: Segmentarea CNN bazată pe calcul variațional: a) imaginea ideală fără zgomot; b) imaginea de ieșire după detecția muchiilor; c) rezultatul segmentării imaginii fără zgomot; d) imaginea de intrare cu zgomot; e) imaginea de ieșire filtrată, Φ , utilizând DN_LAPLACE; f) imaginea de ieșire după detecția muchiilor, K , utilizând AVEGRAD; g) rezultatul segmentării imaginii cu zgomot utilizând DN_LAPLACE; h) imaginea de ieșire filtrată, Φ , utilizând VSGN; i) imaginea de ieșire după detecția muchiilor, K , utilizând AVEGRAD; j) rezultatul segmentării imaginii cu zgomot utilizând VSGN.

În figura 2.2.23 și în figura 2.2.24 sunt prezentate exemple de segmentare a unor imagini CT reale. Evaluarea vizuală a rezultatelor a fost efectuată de experți în imagistică medicală (Gacsádi and Szolgay 2010), (Gacsádi et al. 2011).




Figura 2.2.23: Segmentarea CNN bazată pe calcul variațional a unei imagini CT reale: a) imaginea de intrare cu zgomot; b) imaginea de ieșire filtrată, Φ , utilizând VSGN; c) imaginea de ieșire după detecția mușchilor, K , utilizând AVEGRAD; d) rezultatul segmentării imaginii cu zgomot utilizând VSGN.




Figura 2.2.24: Segmentarea CNN bazată pe calcul variațional a unei imagini CT reale: a) imaginea de intrare cu zgomot; b) imaginea de ieșire filtrată, Φ , utilizând OSRUFA; c) imaginea de ieșire după detecția muchiilor, K , utilizând AVEGRAD; d) rezultatul segmentării imaginii cu zgomot utilizând OSRUFA; e) imaginea de ieșire filtrată, Φ , utilizând CHES; f) imaginea de ieșire după detecția muchiilor, K , utilizând AVEGRAD; g) rezultatul segmentării imaginii cu zgomot utilizând CHES.

2.2.4. Clasificarea automată a tumorilor din imagini mamografice, bazată pe caracteristici direcționale

Imaginile mamografice sunt imagini de tip radiografic (raze X), ale zonelor din regiunea pieptului. O metodă de diagnosticare a tumorilor de sân este dată de inspecția vizuală a acestor regiuni din imaginile radiografice mamare. Identificarea unei astfel de tumori în stadii incipiente este crucială deoarece poate conduce la un tratament adecvat și eficient în tratarea acestei afecțiuni. Aceste zone suspecte pot fi identificate relativ ușor de către personalul medical calificat prin inspecție vizuală deoarece ele apar ca zone cu densitate mărită în imaginile radiografice. O problemă mai dificilă este însă punerea unui diagnostic, tumoare benignă sau malignă, doar pe baza mamografiei. Statistica arată că între 65-90 % dintre tumorile identificate astfel ca fiind maligne s-au dovedit a fi în final de tip benign în urma unei biopsii. Folosirea unei metode complete de identificare automată, cu ajutorul unui sistem computerizat de asistare a diagnozei medicale, ar ajuta personalul medical în luarea unei decizii mai exacte, eliminând alarmele false. În principal cei doi pași, localizare urmată de o clasificare, sunt separați.

Pentru a analiza, a detecta sau a extrage caracteristici din imagini mamografie au fost propuse mai multe tehnici în literatura de specialitate. Strickland și Hahn au propus o metodă, bazată pe undișoare, pentru detectarea și segmentarea unor microcalcificații (Strickland and Hahn 1996). Pentru extragerea caracteristicilor și clasificarea acestora Swiniarski și colab. au propus undișoare Haar și descompunerea datelor în componente principale (PCA - *Principal Component Analysis*) (Swiniarski et al. 2001). Pentru clasificarea imaginilor mamografice se propune metoda vectorilor suport (SVMs - *Support Vector Machines*) (Wei et al. 2005b). Mai multe tehnici privind prelucrarea imaginilor mamografice, incluzând atât segmentarea cât și clasificarea, sunt prezentate de Bozek și colab. (Bozek et al. 2009).


În procesul de achiziție a imaginilor pot apărea diferite tipuri de zgomot care afectează calitatea imaginilor și performanțele clasificării (Analoui 2001). În principiu, poate să apară în mod normal zgomot Gaussian, dar și un zgomot specific pentru imagini cu raze X cu distribuție Poisson, zgomot cuantic (*quantum*) (Webb 1988), (Goebel et al. 2005).

Actualmente există deja softuri comerciale specializate pentru localizarea automată, mai mult sau mai puțin precisă, a zonelor suspecte dar deocamdată nu există nici o aplicație comercială care să identifice tipul tumorii, benignă sau malignă.

În secțiunea următoare sunt descrise rezultatele utilizării filtrelor de tip Gabor în clasificarea automată a țesuturilor mamare de tip normal, benign și malign (Buciu and Gacsádi 2011) și (Buciu and Gacsádi 2009). Proprietatea deosebit de importantă a acestor filtre este sensibilitatea lor direcțională astfel încât patern-urile (*pattern* – tipar) de forma radială, orientate pe diverse direcții spațiale, asociate țesuturilor maligne sau benigne pot fi modelate folosind astfel de filtre. De asemenea, modelarea în frecvență a acestor filtre ajută la asocierea acestor țesuturi, reprezentând zone dense, cu diverse frecvențe ale filtrelor Gabor.

Baza de date cu care s-a lucrat este o bază publică cunoscută și disponibilă prin societatea MIAS (*MIAS-Mammographic Image Analysis Society*), (** MIAS). Setul de date conține 322 eșantioane din care 208 reprezintă țesut normal sau sănătos, 63 eșantioane

reprezintă țesut benign și 51 eșantioane reprezintă țesut malign. Țesuturile, formațiunile, suspecte au fost împărțite în 6 clase: a) microcalcificație; b) masă circumscrișă; c) masă de tip spic; d) masă cu forma nedefinită; e) distorsiune arhitecturală; f) masă asimetrică. Analiza a avut ca obiectiv doar clasificarea țesuturilor în cele 3 clase de bază: sănătos, benign și malign. Fiecare imagine este de dimensiune 1024*1024 pixeli. Zonele suspecte au fost identificate și extrase manual. Pentru o delimitare cât mai exactă, pentru fiecare imagine sunt disponibile atât coordonatele centrului zonei suspecte cât și raza cercului care cuprinde această zonă. Zona malignă sau benignă cea mai extinsă are raza de 197 de pixeli, iar cea mai redusă de doar 3 pixeli. Exemple de astfel de țesuturi sunt ilustrate în figura 2.2.25.



*Figura 2.2.25: Zone suspecte de dimensiune 140*140 pixeli extrase din imaginile mamografice. Rândul de sus reprezintă 5 eșantioane de țesut normal, rândul de mijloc reprezintă 5 eșantioane de țesut benign, iar ultimul rând 5 eșantioane de țesut malign.*

Pentru fiecare imagine de dimensiuni 1024*1024 de pixeli, s-a extras o regiune de interes de dimensiuni 140*140 de pixeli, în jurul formațiunii anormale. Prin dimensiuni de 140 de pixeli se asigură includerea în analiza imaginii și a unei părți din exteriorul formațiunii. În acest fel se păstrează informații și despre forma formațiunii. În cazul imaginilor cu țesuturi sănătoase, zonele s-au extras din regiuni aleatorii din imagine. Pentru reducerea dimensiunii datelor, fiecare astfel de imagine a fost redusă la 30*30 și 60*60 pixeli după care s-a trecut la aplicarea filtrelor Gabor pentru fiecare imagine.

Filtrele Gabor se bazează pe undișoarele cu același nume ale căror funcție de implementare este similară cu procesele biologice de formare a imaginilor în sistemul vizual uman (Lee 1996). Funcția matematică de tip Gabor este descrisă printr-un produs între un kernel Gaussian și o funcție sinusoidă complexă. Spre deosebire de alte metode care folosesc transformate undișoare, filtrele Gabor au proprietatea de a scoate în evidență direcția și frecvența formelor de țesut analizate (Turner 1986). O direcție sau frecvență specifică este evidențiată, filtrată, prin modificarea parametrilor filtrelor Gabor (Grigorescu et al. 2002), (Han and Ma 2007). Obiectivul general urmărit al acestui studiu a fost analiza performanțelor de clasificare ale sistemului în funcție de direcțiile și frecvențele filtrate.

În cazul nostru, au fost aplicate un set de 40 de filtre Gabor (definite de 8 orientări și 5 frecvențe). Setul de antrenare, cu clasa cunoscută, a fost formată din 80 % din totalul datelor, restul de 20 % au format setul de testare, cu clasa necunoscută. Pentru determinarea clasei

fiecărui eșantion din setul de test s-a folosit ca și clasificator metoda vectorilor suport de tip proximal (*Proximal Support Vector Machines*). Înainte de aplicarea clasificatorului s-a folosit o reducere a dimensiunii datelor prin descompunerea în componente principale (PCA - *Principal Component Analysis*). Mai exact, fiecare produs de convoluție dintre imaginea de 30*30 pixeli (sau 60*60 pixeli) și un filtru Gabor a fost redimensionat pe un vector de dimensiunea 900*1 (sau 3600*1) valori. Pentru fiecare filtru acest vector s-a concatenat într-un singur vector de dimensiune 144000*1 (144000=3600 *40). Forma finală a setului a fost o matrice de dimensiune 144000*N, unde N este numărul de imagini folosite la antrenare. Descompunerea în componente principale are ca efect păstrarea informației relevante, din setul de imagini și eliminarea celei redundante sau care are o contribuție nesemnificativă. Contribuția este dată de matricea de covarianță a setului de date de imagini, în așa fel încât doar acele componente de imagine vor fi păstrate care au o valoare numerică semnificativă.

Studiul efectuat a avut ca scop și testarea robusteții la zgomot a filtrelor Gabor. Deoarece baza de date MIAS conține imagini fără zgomot, s-a aplicat artificial zgomotul de tip cuantic (*quantum*), cu distribuție Poisson și parametru λ diferit, frecvent întâlnit în cazul imaginilor radiografice. Figura 2.2.26 prezintă două eșantioane fără zgomot, urmate de aceleași două eșantioane peste care s-a suprapus zgomot de tip quantum cu două intensități diferite. Figura 2.2.27 ilustrează rezultatul convoluției dintre o imagine eșantion și cele 40 de filtre Gabor pentru o imagine fără zgomot și, respectiv pentru o imagine cu zgomot.




Figura 2.2.26: Imagini mamografice:câte două eșantioane(coloane) fără zgomot, urmate de aceleași două eșantioane peste care s-a suprapus zgomot de tip quantum cu două intensități diferite. Pe rânduri sunt eșantioane de țesut: normal, benign și malign.




Figura 2.2.27: Rezultatul convoluției dintre o imagine eșantion și cele 40 de filtre Gabor pentru o imagine fără zgomot și, respectiv pentru o imagine cu zgomot.

Rezultatele obținute în urma testelor privind: rata de recunoaștere (RR), sensibilitatea (Sn), specificitatea (Sp) și aria caracteristicii de recunoaștere (AUC), sunt prezentate în tabelele 2.2.3 și 2.2.4.

Tabel 2.2.3. Rata de recunoaștere, sensibilitatea, specificitatea și aria caracteristicii de recunoaștere în cazul clasificării de tip țesut normal versus țesut tumoral.

Dim. imag.	Tip imag.	Metoda	RR	Sn	Sp	AUC
30×30	fără zgomot	GabPCA	84.37 (10)	97.56	60.86	0.79
		PCA	73.43 (120)	97.56	30.43	0.77
	$\lambda = 0.1$	GabPCA	73.43 (90)	75.60	69.56	0.77
		PCA	66.75 (80)	70.48	43.47	0.69
	$\lambda = 1$	GabPCA	76.56 (130)	75.60	78.26	0.78
		PCA	71.87 (5)	60.97	39.13	0.51
60×60	fără zgomot	GabPCA	75 (90)	92.68	40	0.70
		PCA	75 (150)	97.56	34.78	0.78
	$\lambda = 0.1$	GabPCA	67.18 (10)	88.05	70.23	0.69
		PCA	73.43 (140)	78.04	65.21	0.77
	$\lambda = 1$	GabPCA	67.18 (10)	78.04	65.21	0.77
		PCA	75.00 (100)	80.48	65.21	0.77

Tabel 2.2.4. Rata de recunoaștere, sensibilitatea, specificitatea și aria caracteristicii de recunoaștere în cazul clasificării de tip țesut benign versus țesut malign.

Dim. imag.	Tip imag.	Metoda	RR	Sn	Sp	AUC
30×30	fără zgomot	GabPCA	78.26 (80)	84.61	80	0.78
		PCA	56.52 (80)	76.92	30	0.57
	$\lambda = 0.1$	GabPCA	69.56 (30)	46.15	70	0.60
		PCA	65.21 (50)	76.92	50	0.64
	$\lambda = 1$	GabPCA	69.56 (20)	76.92	50	0.67
		PCA	65.21 (40)	76.92	50	0.63
60×60	fără zgomot	GabPCA	69.56 (10)	30.07	80	0.70
		PCA	56.52 (40)	74.22	10	0.55
	$\lambda = 0.1$	GabPCA	69.56 (10)	54.61	40	0.66
		PCA	60.86 (70)	53.84	70	0.63
	$\lambda = 1$	GabPCA	69.56 (10)	75.92	40	0.68
		PCA	69.56 (50)	69.23	70	0.65

În urma experimentelor efectuate de noi, rezultatele obținute sunt promițătoare, chiar dacă față de acestea, privind rata de recunoaștere, au fost raportate deja rezultate superioare (Verma et al. 2010), (Islam et al. 2010). Pe de altă parte, trebuie precizat că este dificilă realizarea unei comparații echitabile între rezultatele obținute dacă configurarea experimentelor diferă, chiar dacă se utilizează aceeași bază de date.

Putem concluziona că rezultatele de clasificare în cazul filtrării Gabor sunt net superioare rezultatelor corespunzătoare cazului în care PCA este aplicată direct datelor, fără filtrare. Rezultatele obținute indică o robustețe crescută la precizia de clasificare a tumorilor în cazul suprapunerii de zgomot de tip distribuție Poisson peste imaginile fără zgomot. Cu alte cuvinte, s-a remarcat o sensibilitate relativă a ratei de recunoaștere în raport cu nivelul zgomotului mult mai mică decât în cazul altor metode standard de extragere a paternurilor.

2.3. Utilizarea tehnologiei rețelelor neuronale celulare pentru navigația roboților mobili autonomi

2.3.1. Planificarea traiectoriei unui robot mobil în medii cu obstacole

În general, în cazul comenzii unui robot, senzorul vizual este inclus într-o buclă cu reacție negativă, realizându-se așa-zisa comanda vizuală (*visual servoing* sau *visual servo*) (Hutchinson et al. 1996). Astfel, unul din avantajele principale ale comenzii bazate pe imagini, față de comanda bazată pe poziții, este că precizia poziționării sistemului este mai puțin sensibilă la erorile de calibrare ale camerei video. Un alt avantaj îl reprezintă posibilitatea reducerii timpului de procesare și creșterea vitezei de deplasare. Pentru comanda vizuală a unui robot se folosește una din următoarele configurații de amplasare a camerei video: camera video este fixată de robotul mobil sau de efectorul final, sau este situată în spațiul de lucru (Hutchinson et al. 1996). Există și combinații ale celor două structuri prezentate mai sus, de exemplu, cazul în care se urmărește poziția efectorului final al unui robot cu o camera video montată pe efectorul final al unui alt robot.

Rețelele neuronale/nelineare celulare (Chua and Yang 1988) (Roska and Chua 1993) s-au dovedit eficiente și la prelucrarea semnalelor care provin de la diferiți senzori precum și în alte probleme specifice de prelucrare a imaginilor care se pot utiliza la comanda vizuală a robotului, începând de la extracția unui obiect dintr-o imagine, detecția poziției, mișcării și vitezei, navigarea robotului într-un mediu cu obstacole, până la conducerea propriu-zisă. Alegerea acestor rețele în soluționarea unor probleme din domeniul roboticii se bazează, în primul rând, pe posibilitatea implementării lor pe un singur chip, în tehnologia VLSI (Cembrano et al. 2003) (***) sau pe un emulator digital CNN (Nagy et al. 2006).

Comanda vizuală a unui robot presupune, întâi de toate, preprocesarea imaginilor achiziționate (îmbunătățirea adaptivă, extracția zgomotului din imagini, binarizarea imaginii, interpolarea imaginii etc.). Pentru exemplificarea și testarea unor metode CNN de prelucrare a imaginilor achiziționate de la camera video se poate utiliza un algoritm CNN bazat pe imagini de urmărire a unui obiect în mișcare, cu ajutorul unei camere video montate pe brațul unui robot cu două grade de libertate (Gacsádi et al. 2006b). Între două imagini de intrare achiziționate consecutiv, prin prelucrarea complet paralelă cu rețele neuronale celulare a semnalelor bidimensionale, se asigură efectuarea tuturor procesărilor necesare în vederea funcționării în timp real a sistemului (figura 2.3.1). Comanda vizuală implementată poate fi dezvoltată prin includerea unor algoritmi de estimare a mișcării, realizabile tot în timp real (Gacsádi et al. 2006a) (Grava et al. 2007).

În domeniul roboților mobili, un subiect de cercetare de actualitate continuă o constituie proiectarea sistemului de planificare a traiectoriei. Un astfel de sistem trebuie să-i furnizeze robotului traiectoria optimă posibilă pentru deplasarea lui de la o poziție inițială la o poziție țintă, evitând obstacolele care sunt localizate între aceste două poziții. Este evident că, o asemenea sarcină nu este ușor de rezolvat, mai ales, dacă se iau în calcul că atât obstacolele cât și ținta pot fi în mișcare, obstacolele pot avea diverse forme, etc. (Adamatzky et al. 2004).

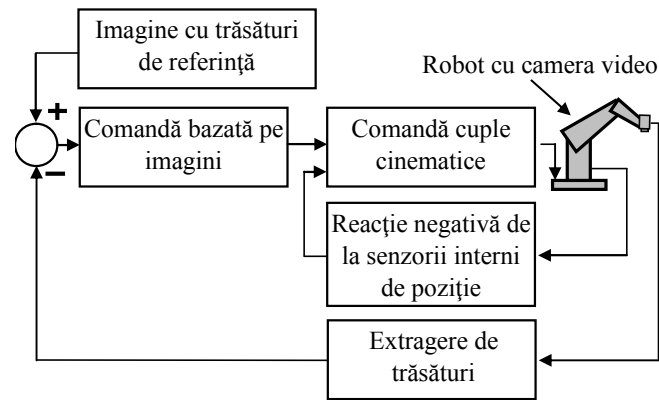


Figura 2.3.1: Structură dinamică “privește și mută” bazată pe imagini.

Planificarea traiectoriei sau navigarea robotului prin metoda globală este asociată cu nivelul ierarhic superior din sistemul de conducere al unui robot. Cu această metodă se determină o traiectorie optimă, ocolindu-se obstacolele statice sau mobile cunoscute din mediu. De cele mai multe ori metodele globale au la bază crearea de “hărți” și abordează problema numai din punct de vedere geometric.

Planificarea traiectoriei sau navigarea robotului prin metoda locală se asociază cu nivelul ierarhic inferior din sistemul de conducere al unui robot și de aceea realizează conducerea robotului pe o traiectorie prescrisă de nivelul de planificare globală. Folosind metoda locală de navigare pentru un robot, se pot evita obstacolele necunoscute, statice sau în mișcare, compensând incertitudinea datelor furnizate de nivelul global. Navigarea locală poate lua în considerare atât cinematica cât și dinamica robotului, deoarece se bazează pe informații obținute din semnale, care se pot prelucra în timp real. Însă prin folosirea numai a informațiilor locale nu se garantează găsirea soluției optime pentru traiectoria planificată a robotului și nu se semnalează dacă poziția țintă nu este accesibilă.

Prin urmare, deseori se combină cele două strategii, adică planificarea globală pentru asigurarea traiectoriei accesibile și navigația locală pentru optimizarea locală a traiectoriei și evitarea obstacolelor neașteptate.

Prin utilizarea rețelelor neuronale/nelineare celulare se asigură reducerea timpului de procesare a semnalelor și astfel, se poate obține o creștere a vitezei de deplasare pentru roboții mobili. Din acest motiv, tehnologia CNN reprezintă o alternativă pentru procesarea imaginilor în scopul ghidării roboților mobili autonomi (Gacsádi et al. 2002) (Adamatzky et al. 2004) (Arena et al. 2005)

Pentru planificarea CNN a traiectoriei roboților mobili în literatura de specialitate au fost propuse o multitudine de soluții, (Siemiatkowska 1994), (Vilarino and Rekeczky 2004), (Gacsádi and Tîponuț 2002), (Tîponuț et al. 2010), care în general, au la bază prelucrări de imagini și una sau ambele metode cunoscute pentru planificarea traiectoriei: metoda locală și/sau globală. Siemiatkowska propune ca planificarea traiectoriei să se realizeze cu ajutorul unei rețele neuronale celulare cu două straturi pe care este implementat un algoritm bazat pe generarea unei unde a cărui front avansează în planul rețelei (Siemiatkowska 1994). Corespondența între mediul de lucru al robotului și starea fiecărei celule (ocupată, liberă sau

necunoscută) este obținută pe baza informațiilor furnizate de senzorii ultrasonici ai robotului. Actualizarea stării celulelor se face prin metoda probabilistică bayesiană.

În continuare, se vor prezenta algoritmi de comandă ai unui robot mobil cu reacție vizuală bazată pe imagini folosind rețele neuronale/nelineare celulare. Anumite aspecte ale acestui subiect au fost abordate de colective cercetare din care a făcut parte și autorul prezentei teze (Gacsádi et al. 2007). Testarea acestor algoritmi s-a efectuat cu ajutorul sistemului de dezvoltare pentru aplicații CNN *CadetWin* (**1999a) și mediul de dezvoltare Matlab.

Algoritmul CNN de comandă a unui robot mobil cu reacție vizuală bazată pe imagini

În aplicația de față, se consideră un robot mobil care se găsește într-un mediu plan cu obstacole statice (figura 2.3.2), supravegherea lui fiind realizată cu o singură cameră video, (Gacsádi et al. 2002), (Gacsádi and Tîponuț 2002). Imaginile reale ale mediului sunt achiziționate la momente discrete de timp (t_0+kT), începând de la momentul inițial t_0 , cu pasul de eșantionare T , k fiind un număr natural, $k \in \mathbb{N}$.




Figura 2.3.2: Mediul de lucru al unui robot mobil cu comandă vizuală bazată pe imagini.

Comanda vizuală a robotului se realizează pe baza algoritmului global prezentat în figura 2.3.3. Între două eșantioane de imagini succesiv achiziționate, trebuie să se realizeze toate prelucrările necesare din algoritm pentru imaginea de intrare curentă. De aceea, achiziția unei noi imagini a mediului este posibilă numai după efectuarea tuturor pașilor de procesare din algoritm. Dacă în mediul de lucru nu sunt numai obiecte statice ci și obiecte în mișcare, adică structura mediului se modifică în timp, este cu atât mai important ca procesarea imaginilor să se facă în timp real. Astfel, dacă comanda vizuală a robotului se efectuează ciclic, pe baza algoritmului global, poziția țintă se poate considera fixă iar poziția de start este chiar poziția actuală a robotului din ultima imagine achiziționată. Se poate accepta și situația

în care și poziția țintei se modifică de la un cadru la altul al imaginii achiziționate, dar numai dacă viteza de prelucrare a imaginilor este suficient de mare încât să fie posibilă obținerea în timp real a mărimii de comandă a robotului.

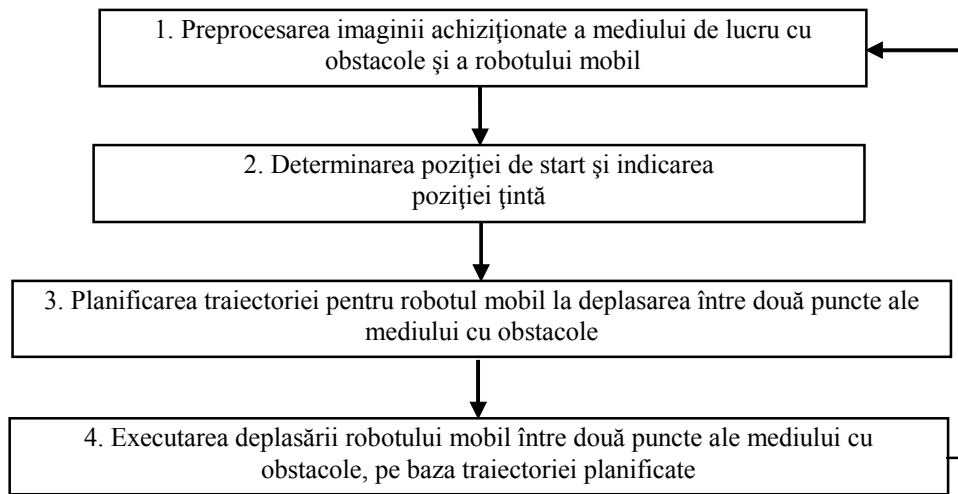


Figura 2.3.3: Organigrama algoritmului global de comandă vizuală a robotului mobil pentru deplasarea între două puncte ale unui mediu de lucru cu obstacole.

Pentru a putea fi prelucrate cu rețele neuronale celulare, imaginile mediului cu obstacole sunt divizate în imagini discrete având $M*N$ pixeli, fiind posibil în acest fel, reprezentarea imaginii mediului printr-o rețea neuronală standard având $M*N$ celule, figura 2.3.4.

Imaginea de intrare binară a mediului de lucru se obține în urma unor procesări elementare CNN asupra imaginii reale cu niveluri de gri (*gray-scale*), achiziționate. În imaginile cu niveluri de gri valorile pixelilor sunt în domeniul standard CNN, adică $[-1, +1]$, de la alb către negru, iar pentru imaginile binare, valorile pixelilor sunt $+1$ pentru negru și -1 pentru alb. În imaginea binară rezultată în urma procesării, pixelilor cu valori de $+1$ li se asociază pozițiile interzise, care nu sunt accesibile robotului în mediul de lucru, iar pixelii cu valoarea -1 semnifică poziții libere, accesibile pentru robot.

În urma discretizării spațiale a imaginii, discretizare care corespunde cu rezoluția CNN, se presupune că fiecare obstacol este reprezentat de cel puțin un pixel negru iar robotul și ținta sunt identificați fiecare prin câte un pixel negru.




Figura 2.3.4: Imaginea binară a mediului de lucru.

Organigrama algoritmului de planificare a traiectoriei robotului mobil, pe baza imaginilor, este prezentată în figura 2.3.5. Algoritmul detectează și semnalează chiar de la început situațiile posibile în care ținta nu este accesibilă robotului, adică faptul că ținta este “înconjurată” de obstacole.

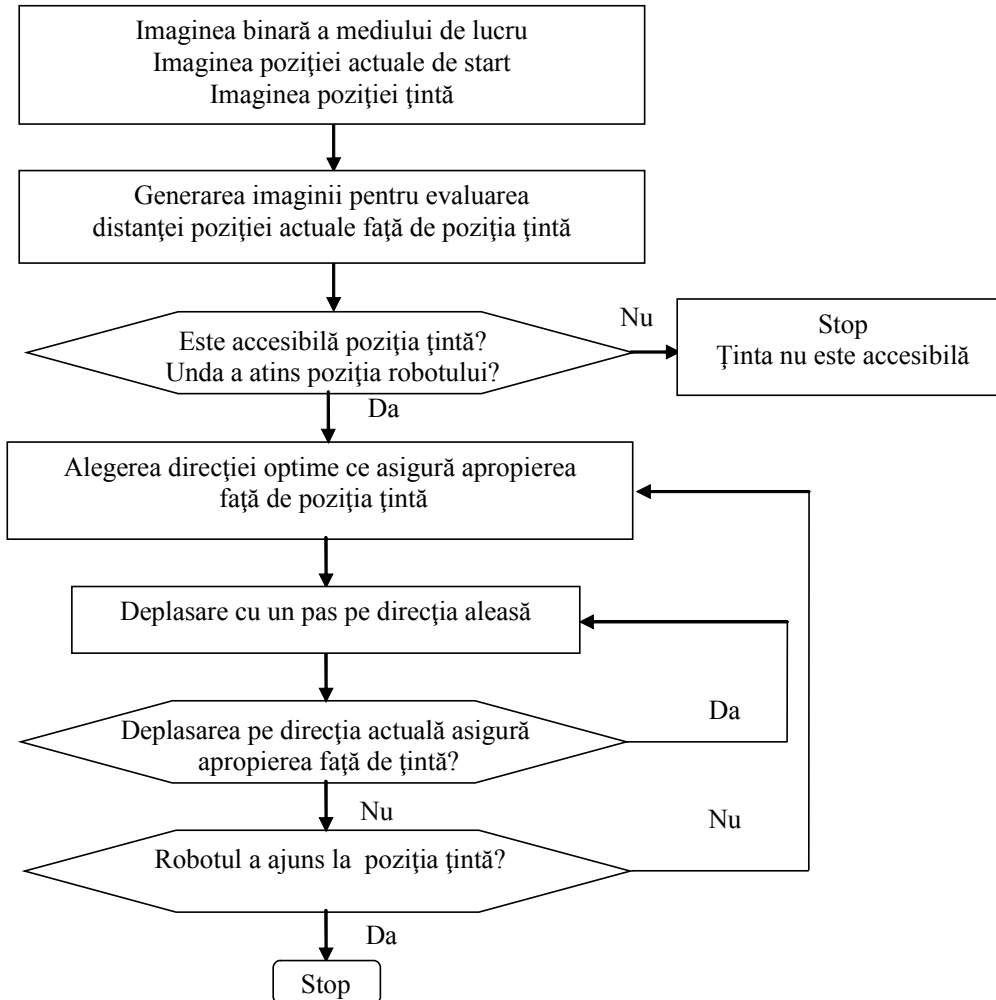


Figura 2.3.5: Organigrama algoritmului pentru planificarea traiectoriei robotului mobil la deplasarea între două puncte într-un mediu de lucru cu obstacole.

Evaluarea distanțelor punctelor din mediul de lucru față de punctul țintă

Pentru stabilirea unei traiectorii optime, între poziția de start și țintă, trebuie evaluate pozițiile punctelor (pixelilor) din spațiul liber al mediului de lucru față de punctul țintă. În acest scop se generează o undă în planul imaginii, având centrul sursei situat chiar în punctul țintă, (Gacsádi et al. 2002), (Gavriliuț et al. 2006a). Pentru obținerea acestei imagini se utilizează template-ul EXPLORE (** 2010), definit de relațiile 2.3.1. În domeniul aplicațiilor CNN, generarea controlată a unei unde în imagini este o metodă eficientă, care se poate utiliza la detectarea conturilor sau la clasificarea binară.

$$A = \begin{pmatrix} 0 & a & 0 \\ a & 1 & a \\ 0 & a & 0 \end{pmatrix} \quad B = \begin{pmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{pmatrix} \quad z = 0 \quad (2.3.1)$$

Template-ul de mai sus este neliniar deoarece funcția a depinde de diferența dintre valoarea mărimii de ieșire a celulei C_{ij} și valoarea mărimii de ieșire a celulei C_{kl} , situată în vecinătatea sa, $(y_{ij}-y_{kl})$. În figura 2.3.6 este reprezentată grafic funcția a . Parametrul β are semnificația de unitate de măsură a distanței.




Figura 2.3.6: Caracteristica de transfer a funcției a .

Prin propagarea ei, unda explorează toate căile accesibile din mediul de lucru, începând din punctul țintă (Figura 2.3.7). Pe starea inițială a rețelei $x(t_0)$ (*STATE*) se aplică o imagine în care toate elementele de imagine au valoarea +1, cu excepția pixelului corespunzător punctului țintă, care are valoarea -1. Această imagine este, de fapt, inversa imaginii prin care se indică poziția țintei. Imaginea binară a mediului se va folosi ca imagine mască (*MASK*). Pixelii de la marginea imaginii mediului de lucru, respectiv frontierei rețelei neuronale celulare, vor fi considerați poziții interzise.

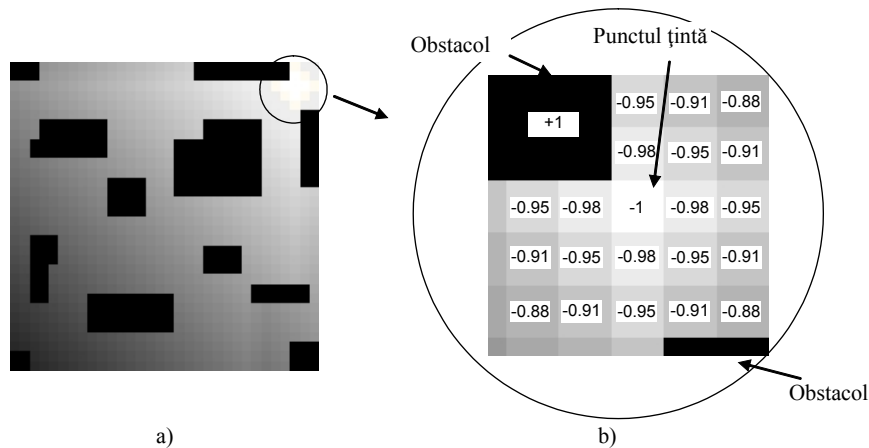


Figura 2.3.7: Principiul propagării circulare a unei unde din punctul țintă:
a) imaginea undei; b) valorile pixelilor din jurul poziției țintei.

În urma acestei prelucrări, pixelul corespunzător poziției țintă din imaginea de ieșire a rețelei, va rămâne la valoarea inițială -1, iar elementele de imagine care vor avea valoarea +1 vor constitui poziții interzise sau inaccesibile robotului. Toți ceilalți pixeli vor avea valori proporționale cu distanțele dintre pozițiile lor și poziția țintei. Astfel, în imaginea rezultată, pornind din centrul sursei undei, valorile pixelilor cresc aproximativ cu câte o unitate de măsură a distanței β , la creșterea cu o unitate a razei undei cu propagare circulară.

Obținerea unei unde care să atingă poziția de start se face prin aplicarea repetată a template-ului EXPLORE. Numărul de aplicări a template-ului va crește treptat de la valoarea 1 până la o valoare care va determina ca în imaginea de ieșire să se obțină o modificare a pixelului ce indică poziția de start. Dacă acest număr atinge o valoare maximă N_{\max} , dat de relația 2.3.2, și valoarea luminanței pixelului ce indică poziția de start nu se modifică, înseamnă că ținta nu este accesibilă. Aceasta se poate întâmpla fie din cauza poziției obstacolelor, fie din cauză că ținta este situată la o distanță mult prea mare față de robot (Gavriliuț et al. 2006a).

$$N_{\max} = \frac{+1 - (-1)}{p}, \text{ unde} \quad (2.3.2)$$

valoarea lui p reprezintă pasul minim de discretizare în niveluri de gri, tipic $p = 0.03$, rezultând valoarea $N_{\max} = 67$.

Alegerea direcției optime de deplasare pentru robot

Alegerea direcției optime, care să asigure lungimea minimă pentru traiectoria robotului, precum și un număr minim de viraje, se realizează prin extragerea valorii unui pixel cu niveluri de gri. Poziția robotului este reprezentată de o imagine având toți pixelii de valoare -1 cu excepția unui singur pixel de valoare $+1$. Această imagine care indică poziția curentă a robotului, va fi suprapusă la fiecare pas al algoritmului cu imaginea reprezentând evaluarea distanțelor dintre punctele din mediul de lucru accesibile robotului și punctul țintă (figura 2.3.7a).

Pentru obținerea traiectoriei optime, trebuie să fie ales, la fiecare pas, pixelul cu cea mai mică valoare din vecinătatea de rază $r = 1$ a pixelului ce indică poziția curentă a robotului. Acest pixel va indica direcția optimă de deplasare și va reprezenta apoi poziția actuală a robotului.

Determinarea acestui pixel s-a făcut în două moduri:

- explorarea tuturor pixelilor vecini și apoi determinarea sa prin comparații succesive (Gacsádi et al. 2002);
- prin aplicarea template-ului PATH (Gavriliuț et al. 2006a).

În primul caz, prin inversarea imaginii, care indică inițial poziția punctului de start a robotului, apoi poziția actualizată în care se va alege o nouă direcție de deplasare, se obține o imagine binară cu aceleași dimensiuni care va fi folosită în continuare ca imagine mască.

În această etapă de prelucrare sunt necesare: imaginea mască menționată mai sus și imaginea cu niveluri de gri care conține estimarea distanțelor pozițiilor libere din mediu față de poziția țintei (figura 2.3.7a).

Dintre cei opt pixeli vecini care corespund direcțiilor date de punctele cardinale (N, S, E, V, SE, NE, NV, SV), după care se poate efectua deplasarea, se evaluează și se alege cu o metodă locală celula vecină cu valoarea cea mai mică. Practic, sunt comparate valorile pixelilor din jurul pixelului ce indică poziția robotului în imaginea cu niveluri de gri din figura 2.3.7a și este ales pixelul cu luminanța cea mai mare. Pentru aceasta, se utilizează

procesări AMC asupra imaginilor, având la bază familia de template-uri SHIFT, (***) 2010), care corespund celor opt direcții posibile de deplasare (relația 2.3.3).

$$A = \begin{pmatrix} 0 & 0 & 0 \\ 0 & 2 & 0 \\ 0 & 0 & 0 \end{pmatrix} \quad B = \begin{pmatrix} se & s & sv \\ e & 0 & v \\ ne & n & nv \end{pmatrix} \quad z = 0 \quad (2.3.3)$$

În cazul unuia dintre template-urile familiei SHIFT doar unul din elementele operatorului B sunt egale cu 1 restul fiind 0, astfel: SHIFTE ($e = 1$), SHIFTSE ($se = 1$), SHIFTS ($s = 1$), SHIFTSV ($sv = 1$), SHIFTV ($v = 1$), SHIFTNV ($nv = 1$), SHIFTN ($n = 1$), SHIFTNE ($ne = 1$).

În cazul alegerii direcției optime prin aplicare de template, având indicată poziția robotului printr-un pixel negru, delimitarea vecinătății robotului de rază $r = 1$, poate fi obținută cu template-ul DILATION (***) 2010), dat de relația 2.3.4.

$$A = \begin{pmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{pmatrix} \quad B = \begin{pmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{pmatrix} \quad z = 8 \quad (2.3.4)$$

Dacă pe starea și pe intrarea rețelei se aplică imaginea ce reprezintă poziția curentă a robotului, după aplicarea template-ului de mai sus, pe ieșire se obține imaginea vecinătății robotului (figura 2.3.8).




Figura 2.3.8: Delimitarea vecinătății de rază $r=1$ a robotului: a) imagine reprezentând poziția robotului; b) imagine reprezentând vecinătatea robotului.

După realizarea unor operații logice asupra imaginii vecinătății robotului, se va obține o imagine mască (figura 2.3.9a), care suprapusă peste imaginea undei din figura 2.3.6a, sau zona selectată din figura 2.3.9b, va rezulta o imagine care reprezintă unda obținută prin procesarea cu EXPLORE a imaginii mediului cu obstacole, doar în zona ce corespunde vecinătății robotului, restul pixelilor din imagine având valoarea +1 (figura 2.3.9c).

Dintre toți pixelii vecini va fi ales pixelul având valoarea cea mai mică, astfel pixelul ce trebuie ales din imaginea prezentată în figura 2.3.9c va fi cel cu valoarea 0.63. Pentru ca algoritmul să determine acest pixel, se poate proiecta un template care aplicat asupra acestei imagini, dată ca exemplu, să rezulte o imagine în care toți pixelii au valoarea -1 cu excepția pixelului ce indică poziția viitoare a robotului, care va avea valoarea +1. Din păcate, aplicarea acestui template nu va indica poziția viitoare pentru robot în alte situații, adică atunci când va fi o altă configurație a valorilor pixelilor din vecinătatea robotului. Ar trebui, spre exemplu, ca valoarea de prag z a template-ului să se modifice la fiecare altă configurație în care se află robotul.

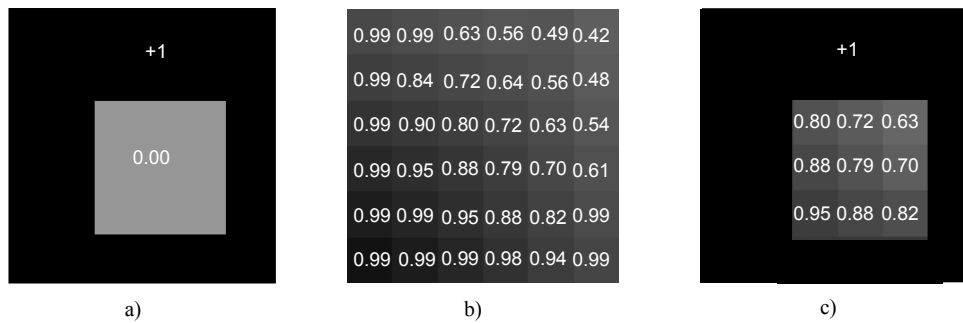


Figura 2.3.9: Delimitarea zonei corespunzătoare vecinătății robotului cu valorile pixelilor obținute după propagarea undei; a) imagine mască obținută din imaginea vecinătății robotului, b) imagine reprezentând valorile pixelilor în jurul poziției actuale după procesarea cu EXPLORE, c) imagine cu valorile pixelilor din vecinătatea de rază $r=1$ a robotului, după propagarea undei.

Din acest motiv, în algoritm se vor efectua procesări asupra imaginilor de forma celei din figura 2.3.9c, astfel încât prin aplicarea aceluiași template, asupra acestor tipuri de imagini, să se obțină de fiecare dată o imagine ce indică poziția viitoare ce trebuie ocupată de robot. Prin urmare, se va memora valoarea minimă din imagine și apoi se va crea o imagine având toți pixelii cu această valoare (figura 2.3.10a). Dacă această imagine va fi scăzută din imaginea de tipul celei din figura 2.3.9b, se obține o imagine care are valorile pixelilor din vecinătatea robotului, prezentată în figura 2.3.10b. Imaginea obținută în final (figura 2.3.10c) va constitui imaginea asupra căreia se va opera cu un template pentru determinarea poziției viitoare a robotului. Imaginea astfel rezultată, are aproximativ aceleași valori ale pixelilor în jurul poziției curente a robotului, indiferent de poziția în care este situat robotul în drumul lui către țintă. Având un template potrivit, ce se va aplica prin intermediul unei imagini mască, asupra imaginii de tipul celei din figura 2.3.10c se va obține, de fiecare dată, o imagine ce va indica, printr-un pixel negru, poziția viitoare ce trebuie ocupată de către robot.

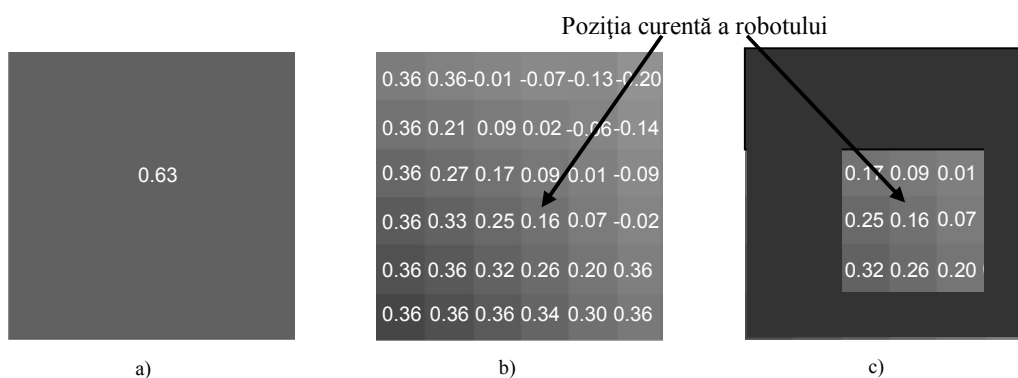


Figura 2.3.10: Exemplu de actualizare a pixelilor în funcție de poziția curentă a robotului; a) imagine având valoarea tuturor pixelilor egală cu valoarea minimă a undei în vecinătatea poziției robotului (0.63), b) valoarea actualizată a pixelilor în jurul poziției curente a robotului, c) valoarea actualizată a pixelilor în vecinătatea poziției robotului.

Template-ul determinat în acest scop, denumit PATH, este de forma dată de relația 2.3.5.

$$A = \begin{pmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{pmatrix} \quad B = \begin{pmatrix} 0 & -0.1 & 0 \\ -0.1 & -8 & -0.1 \\ 0 & -0.1 & 0 \end{pmatrix} \quad z = 0.3. \quad (2.3.5)$$

În figura 2.3.11 este prezentat modul de determinare a poziției viitoare pentru robotul mobil prin utilizarea acestui template.

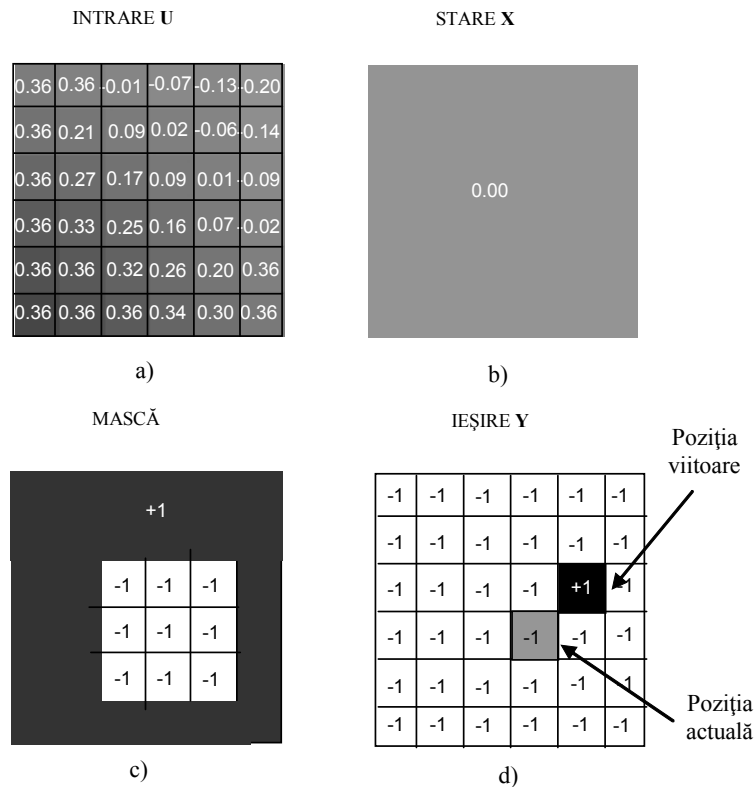


Figura 2.3.11: Modul de determinare a poziției viitoare pentru robotul mobil:
 a) imaginea mediului cu obstacole peste care e suprapusă unda actualizată;
 b) imagine având toți pixelii de valoare 0; c) imaginea mască; d) imagine în care toți pixelii au valoarea -1 cu excepția pixelului ce indică poziția viitoare ce urmează a fi ocupată de către robot.

Deplasarea robotului spre țintă

După determinarea pixelului care indică poziția viitoare, ce trebuie ocupată de către robot, acest pixel va deveni poziție curentă. În această poziție poate fi aleasă o nouă direcție de deplasare, sau este posibil ca robotul să se deplaseze în continuare pe direcția aleasă anterior, atâta timp cât prin această mișcare se apropie de țintă. În primul caz lungimea traiectoriei măsurată în număr de pixeli va fi minimă iar în cazul al doilea numărul de viraje va fi minim, (Gacsádi et al. 2002).

În continuare sunt prezentate cele două modalități de obținere a traiectoriei pentru robot și anume:

- deplasarea robotului pe direcția pixelului cu valoare minimă atâta timp cât se asigură apropierea de țintă;
- deplasarea pixel cu pixel a robotului alegând de fiecare dată pixelul cu valoare minimă.

În cazul deplasării continue a robotului pe direcția pixelului cu valoare minimă atâta timp cât se asigură apropierea de țintă, direcția de deplasare rămâne neschimbată dacă aceasta asigură apropierea robotului de poziția țintei. Aceasta înseamnă că, de pe poziția curentă se va păși pe următoarea poziție de pe aceeași direcție numai dacă valoarea pixelului corespunzător pentru poziția respectivă este mai mică decât valoarea pixelului din poziția curentă. Spre exemplu, în figura 2.3.12, din punctul A robotul se va deplasa succesiv în punctele B, C, D, E, și F unde se va opri deoarece pe aceeași direcție urmează un pixel ce are valoarea mai mare decât cel al poziției curente. În punctul F se va alege o nouă direcție de deplasare și anume direcția dată de punctul G respectiv H.

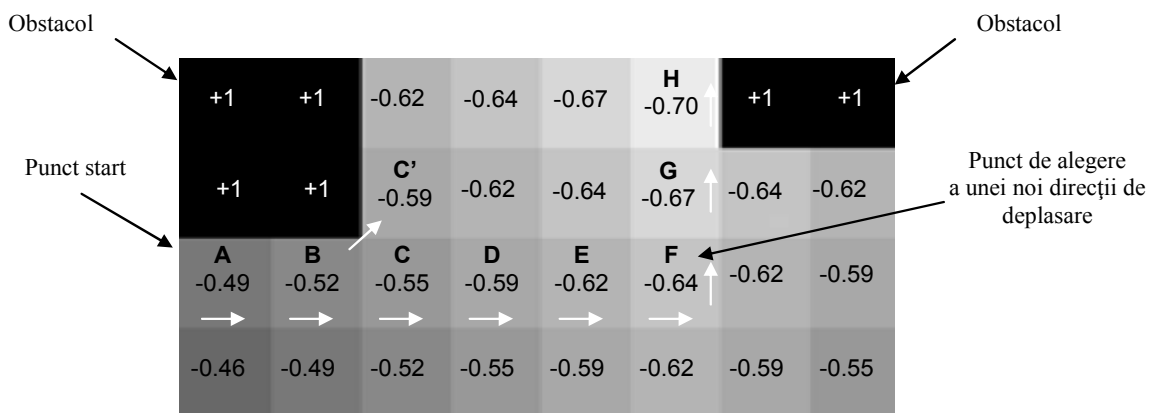


Figura 2.3.12: Alegerea direcției optime prin menținerea direcției atâta timp cât se asigură apropierea de țintă.

După alegerea direcției optime, într-un punct de viraj, obținerea imaginii traiectoriei pe direcția respectivă, care să indice în acel moment drumul spre țintă, se obține prin utilizarea familiei de template-uri SELECT, extinsă pe una din cele opt direcții (***) 2010), definită de relațiile 2.3.6:

$$A = \begin{pmatrix} se & s & sv \\ e & 4 & v \\ ne & n & nv \end{pmatrix} \quad B = \begin{pmatrix} se & s & sv \\ e & 0 & v \\ ne & n & nv \end{pmatrix} \quad z = 0 \quad (2.3.6)$$

În cazul unuia din template-urile din familia SELECT, elementele operatorilor A și B din relația 2.6.6 vor avea valorile astfel:

SELECTE

$$A(e = 1, se = s = sv = v = nv = n = ne = 0); \quad B(e = b, se = s = sv = v = nv = n = ne = 0);$$

SELECTSE

$$A(se = 1, e = s = sv = v = nv = n = ne = 0); \quad B(se = b, e = s = sv = v = nv = n = ne = 0);$$

SELECTS

$$A(s = 1, e = se = sv = v = nv = n = ne = 0); \quad B(s = b, e = se = sv = v = nv = n = ne = 0);$$

SELECTSV

 $A(sv = 1, e = se = s = v = nv = n = ne = 0); B(sv = b, e = se = s = v = nv = n = ne = 0);$

SELECTV

 $A(v = 1, e = se = s = sv = nv = n = ne = 0); B(v = b, e = se = s = sv = nv = n = ne = 0);$

SELECTNV

 $A(nv = 1, e = se = s = sv = v = n = ne = 0); B(nv = b, e = se = s = sv = v = n = ne = 0);$

SELECTN

 $A(n = 1, e = se = s = sv = v = nv = ne = 0); B(n = b, e = se = s = sv = v = nv = ne = 0);$

SELECTNE

 $A(ne = 1, e = se = s = sv = v = nv = n = 0); B(ne = b, e = se = s = sv = v = nv = n = 0).$

Funcția neliniară b este prezentată în figura 2.3.13, în care β are semnificația de unitate de măsură a distanței în imagine.




Figura 2.3.13: Caracteristica de transfer a funcției b .

Pentru obținerea traiectoriei robotului între două puncte de viraj, se aplică pe intrarea rețelei neuronale celulare imaginea cu estimarea distanțelor punctelor din spațiul liber al mediului față de poziția țintei iar pe starea rețelei se aplică o imagine având un sigur pixel de valoare +1 ce indică poziția de start pentru porțiunea curentă din traiectoria planificată, restul pixelilor având valoarea -1. În același timp se aplică unul din template-urile din familia SELECT ce corespunde direcției ce a fost aleasă în prealabil.

Traectoria totală între poziția inițială de start și poziția țintei se obține prin însumarea traiectoriilor dintre două puncte de viraj. Așadar, după “selectarea” traiectoriei pe direcția respectivă aceasta va fi însumată cu traiectoriile precedente și tot așa până la țintă. Fiecare punct de viraj, în care trebuie aleasă o nouă direcție, trebuie să fie reprezentat printr-o imagine ce are activ doar acel pixel, astfel că, asupra imaginii ce conține ultima porțiune de traiectorie trebuie aplicat de fiecare dată unul din template-urile din familia DEL (***) 2010), extinsă pe cele opt direcții de deplasare. Template-urile DEL sunt date de relațiile 2.3.7:

$$A = \begin{pmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{pmatrix} \quad B = \begin{pmatrix} se & s & sv \\ e & 0 & v \\ ne & n & nv \end{pmatrix} \quad z = 0 \quad (2.3.7)$$

În cazul unuia din template-urile din familia DEL, elementele operatorului B din relația 2.3.7 vor avea valorile, după cum urmează:

DELE $e = 1, v = -1, se = s = sv = nv = n = ne = 0;$

DELSE $se = 1, nv = -1, e = s = sv = v = n = ne = 0;$

$DELS \quad s = 1, n = -1, e = se = sv = v = nv = ne = 0;$
 $DELSV \quad sv = 1, ne = -1, e = se = s = v = nv = n = 0;$
 $DELV \quad v = 1, e = -1, se = s = sv = nv = n = ne = 0;$
 $DELNV \quad nv = 1, se = -1, e = s = sv = v = n = ne = 0;$
 $DELN \quad n = 1, s = -1, e = se = sv = v = nv = ne = 0;$
 $DELNE \quad ne = 1, sv = -1, e = se = s = v = nv = n = 0.$

Prin aplicarea acestor operatori asupra unei imagini binare ce conține porțiunea de traiectorie reprezentată de pixeli de valoare +1, se va realiza ștergerea după direcția specificată, a unui pixel. Ștergerea mai multor pixeli pe aceeași direcție se realizează prin aplicarea repetată a operatorului respectiv.

Aplicând algoritmul CNN de planificare a traiectoriei, prin această metodă de deplasare a robotului, se obține în final traiectoria prezentată în figura 2.3.14c. După cum s-a menționat și anterior, avantajul acestei metode constă în faptul că numărul de viraje realizat de către robot este minimizat.




Figura 2.3.14: Obținerea traiectoriei robotului mobil la deplasarea acestuia într-un mediu cu obstacole statice prin metoda deplasării pe direcția pixelului cu valoare minimă atâta timp cât se asigură apropierea de țintă: a) imaginea inițială binară a mediului cu obstacole; b) imaginea undei ce se propagă prin mediul de lucru din punctul în care este situată ținta; c) imaginea traiectoriei rezultate.

Deplasarea robotului poate fi realizată pixel cu pixel cu alegerea direcției optime la fiecare pas, deoarece dezavantajul metodei prezentate mai sus este dat de faptul că lungimea traiectoriei măsurată în număr de pixeli, nu este cea minimă. În exemplul prezentat în figura 2.3.12 între punctele de schimbare a direcției A și F există punctul B care dacă ar fi punct de alegere a unei noi direcții, deplasarea ar fi spre punctul C' și nu spre C. Dacă robotul s-ar deplasa pixel cu pixel alegând după fiecare pas direcția optimă, atunci lungimea traiectoriei măsurată în număr de pixeli ar fi minimă în schimb timpul total necesar algoritmului de planificare a traiectoriei este mai mare. În figura 2.3.15 se prezintă forma traiectoriei în cazul deplasării pixel cu pixel a robotului mobil cu determinarea direcției optime la fiecare pas (pixel). Pentru fiecare porțiune din traiectorie, poziția viitoare, pe care o va ocupa robotul

robotul va deveni poziție curentă și tot așa până când va fi atinsă ținta. Traiectoria planificată, între poziția de start și poziția țintă, se compune din segmente de traiectorii între două puncte consecutive în care este schimbată direcția de deplasare. Astfel, la traiectoria parcursă până într-un anumit punct (poziție curentă) se va adăuga de fiecare dată poziția viitoare (la deplasarea pixel cu pixel) sau porțiuni din traiectorie (la deplasarea pe o direcție atâta timp cât se asigură apropierea de țintă). Această operație se poate realiza chiar și în domeniul CNN prin aplicarea operației logice ȘI între două imagini, pixel cu pixel.

Algoritmul de planificare a traiectoriei se va încheia atunci când robotul, reprezentat printr-un pixel, se va suprapune cu pixelul corespunzător poziției în care este situată ținta. După fiecare deplasare a robotului, fie că aceasta se face continuu pe o direcție descrescătoare a valorilor pixelilor, fie că se face pixel cu pixel, se va verifica dacă robotul a atins ținta.




Figura 2.3.15: Determinarea traiectoriei robotului mobil la deplasarea pixel cu pixel și alegerea direcției optime la fiecare pas: a) imaginea inițială binară a mediului cu obstacole; b) imaginea undei ce se propagă prin mediul de lucru din punctul în care este situată ținta; c) imaginea traiectoriei obținute pentru deplasarea robotului mobil.

Timpul total minim de prelucrare necesar algoritmului se obține însumând timpii minimi necesari de prelucrare pentru fiecare etapă în parte. În cazul etapei de evaluare a distanțelor dintre punctele spațiului de lucru și poziția țintei, timpul minim de prelucrare depinde de distanța dintre poziția de start și poziția țintei, deoarece este necesar ca unda, cu originea în țintă, să se propage până în poziția de start a robotului. O condiție necesară pentru buna funcționare a algoritmului prezentat este ca în imaginile achiziționate să se poată identifica atât punctul de start cât și punctul țintă. Din aceste considerente rezultă dimensiunile imaginii și pasul de eșantionare minim pentru discretizarea spațială a imaginii achiziționate.

Algoritmul CNN de planificare a traiectoriei a fost realizat în ambele variante de alegere a direcției de deplasare a robotului prezentate mai sus și simulat în aceleași condiții, urmărind diferențele dintre rezultatele obținute, mai ales în ceea ce privește timpul total de procesare. Timpii au fost măsurați în cazul simulării pe un calculator cu procesor Pentium II având viteza de 500Mhz. pentru prelucrare și lungimea traiectoriei obținute, exprimată în număr de pixeli, în cele două variante ale algoritmului. În figura 2.3.16 se prezintă dependența dintre

timpul necesar pentru prelucrare și lungimea traiectoriei obținute, exprimată în număr de pixeli, în cele două variante ale algoritmului.

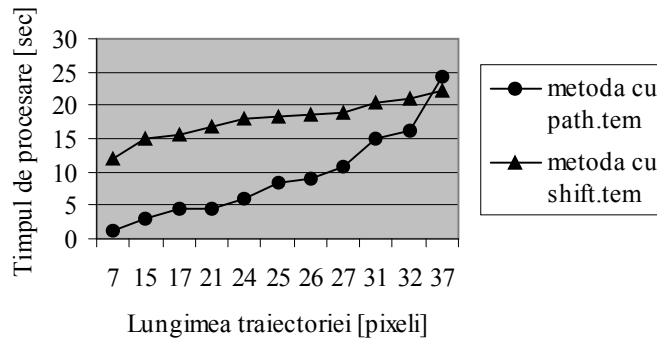


Figura 2.3.16: Dependența dintre lungimea traiectoriei parcurse de robot și timpul de procesare necesar în cazul celor două metode pentru determinarea direcției optime.

Se observă că în cazul metodei de determinare a pixelului cu valoare minimă prin aplicarea template-ului PATH, timpul de procesare este foarte mic în situațiile în care robotul se află aproape de țintă și este mai mare decât în cazul celeilalte metode doar în cazul în care robotul s-ar afla la o distanță relativ mare de țintă.

2.3.2. Algoritm CNN de planificare simultană a traiectoriilor pentru doi roboți mobili

În continuare, se prezintă un algoritm de planificare simultană a traiectoriilor pentru doi roboți mobili, care trebuie să ajungă la o țintă comună, într-un mediu cu obstacole, pe baza imaginilor captate cu o cameră video (Gavriliuț et al. 2005). Pentru prelucrarea imaginilor și planificarea traiectoriei se utilizează rețele neuronale/nelineare celulare invariante în spațiu, cu operatori de dimensiune 3*3. Algoritmul furnizează roboților traiectoria optimă din punct de vedere al lungimii și a numărului de viraje, între pozițiile de start ale roboților și poziția țintei. Pe baza acestor traiectorii, fiecare robot ocolește obstacolele întâlnite în cale precum și pe celălalt robot, dacă este necesar.

Se consideră doi roboți mobili care se găsesc într-un mediu plan cu obstacole statice, care trebuie să ajungă la aceeași țintă ocolind obstacolele și de asemenea unul pe celălalt (figura 2.3.17). Supravegherea este realizată cu o cameră video, iar imaginile captate de aceasta sunt prelucrate conform algoritmului global din figura 2.3.18.

Deplasarea roboților se va face alternativ spre țintă, pe baza traiectoriei furnizate de algoritm, care ține cont în cazul fiecărui robot de poziția celui alt și totodată de poziția obstacolelor din mediu. Astfel, se vor obține traiectorii fără coliziune pentru ambii roboți. Deplasarea unui robot, în cadrul unui pas al algoritmului, se va realiza atâta timp cât acesta se apropie de țintă fără a schimba direcția de mers, urmând apoi deplasarea în același mod a celui alt robot. Astfel, înaintea începerii deplasării, fiecare robot va schimba mai întâi direcția de deplasare avută anterior.




Figura 2.3.17: Mediul de lucru al roboților.

Etapele principale ale algoritmului sunt prezentate în organigrama din figura 2.3.18.

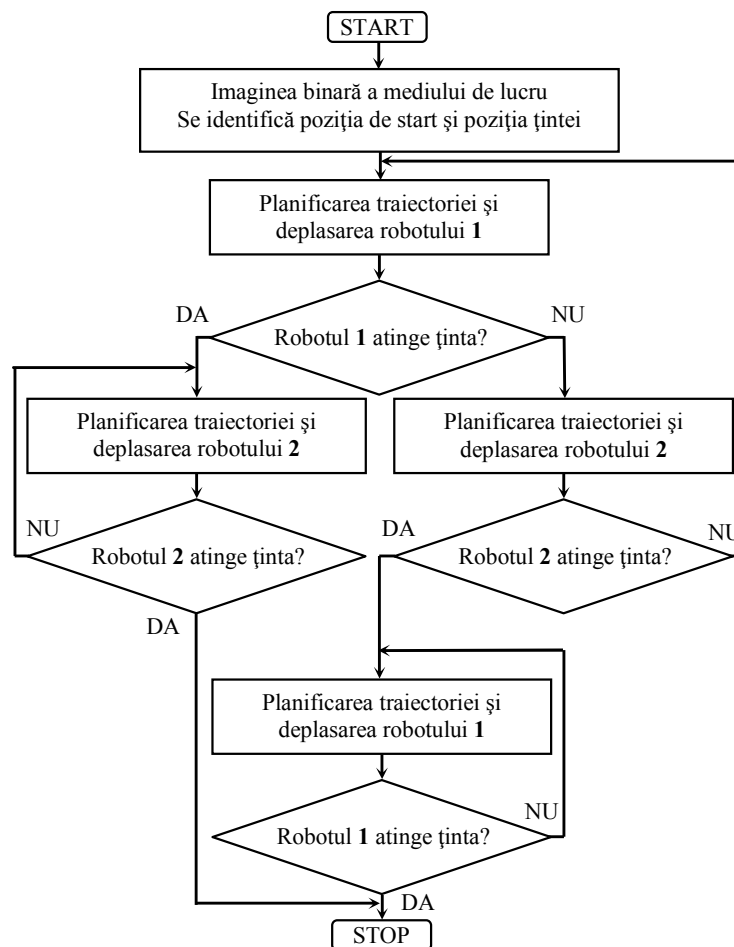


Figura 2.3.18: Organigrama algoritmului global de planificare a traiectoriilor pentru doi roboți mobili, pentru deplasarea lor spre o țintă comună într-un mediu de lucru cu obstacole.

Pentru testarea algoritmului de planificare a traiectoriilor celor doi roboți, într-un mediu de lucru cu obstacole, s-a utilizat mediul de simulare CadetWin (**1999a). Rezultatele au fost obținute pe baza unor programe scrise în limbaj de asamblare AMC (**1999b). Vecinătatea robotului și a țintei au fost alese de rază $r = 1$, iar imaginile au dimensiuni de 32×32 pixeli. În figura 2.3.19 sunt prezentate rezultatele simulării pentru o situație concretă.

Imaginea binară a mediului de lucru cu obstacole se obține în urma unor procesări elementare CNN asupra imaginii achiziționate de cameră. Pentru obținerea acestei imagini s-a utilizat template-ul TRESHOLD (** 2010). Fiecare obstacol din mediu este reprezentat de cel puțin un pixel negru iar roboții sunt identificați fiecare prin câte un pixel negru. Astfel, în imaginea binară rezultată în urma procesării, pixelilor cu valori +1 li se asociază pozițiile interzise, care trebuie evitate de către roboți, iar pixelii cu valoarea -1 semnifică poziții libere, accesibile roboților.




Figura 2.3.19: Rezultatele simulării algoritmului CNN de planificare a traiectoriilor pentru doi roboți mobili la deplasarea lor spre o țintă comună dintr-un mediu cu obstacole.

După identificarea pozițiilor de start ale roboților în imaginea binară, se va trece la pasul următor care constă în planificarea traiectoriei și deplasarea cu un pas a robotului 1 spre țintă.

Se verifică apoi dacă acesta a ajuns la țintă și dacă da, algoritmul va continua doar pentru robotul **2**. Dacă nu, pasul următor va consta în planificarea traiectoriei și deplasarea cu un pas a robotului **2**. Se verifică dacă acesta din urmă a ajuns la țintă, apoi se va reveni la robotul **1** și tot așa până când ambii roboți vor atinge ținta.

Estimarea distanțelor față de țintă s-a realizat prin generarea unei unde în planul imaginii cu ajutorul template-ului EXPLORE (***) 2010), așa cum s-a prezentat deja în cadrul secțiunii precedente. Pentru alegerea direcției optime se utilizează procesări elementare asupra imaginilor obținute anterior, având la bază familia de template-uri SHIFT (***) 2010), care corespund celor opt direcții de deplasare. Deplasarea pe direcția aleasă se va face continuu, atâta timp cât această direcție asigură apropierea robotului de țintă. Practic, înainte ca roboții să se deplaseze pe direcția aleasă, conform celor arătate mai sus, se vor opri și vor schimba direcția de mers avută anterior.

Pentru o mai ușoară înțelegere a algoritmului, sunt prezentate imaginile obținute după fiecare pas (momentele de timp $t_0 \dots t_{11}$). Se observă că la momentul t_6 robotul **1** (R1) întâlnește robotul **2** (R2) și conform algoritmului se va opri la o distanță de un pixel de acesta. Deoarece robotul **2** a ajuns primul la “punctul de întâlnire”, o va lua înainte, iar robotul **1** se va deplasa în urma sa. Când robotul **2** ajunge în vecinătatea țintei se va opri pentru moment, urmând ca în pasul următor să treacă de partea cealaltă a țintei pentru a-i face loc celuilalt robot. Timpul total de procesare necesar pentru derularea algoritmului variază puțin în funcție de lungimea traiectoriilor celor doi roboți, dar s-a observat că depinde aproape liniar de numărul de viraje cumulat al roboților.

2.3.3. Coordonarea deplasării unei colectivități de roboți mobili

Prin întrebuintarea senzorilor și actuatorilor avansați și a algoritmilor de comandă inteligenți, performanțele roboților mobili cresc continuu, ca urmare a necesității realizării unor sarcini tot mai complexe. Cu toate acestea, unele operațiuni fie nu pot fi realizate de către un singur robot, fie timpul de execuție devine inacceptabil de mare.

Se poate observa, în ultimii ani, un interes crescând privind teoria și implementarea colectivităților (coloniilor) de roboți, alcătuite din indivizi care cooperează între ei în vederea realizării unor sarcini specifice. Aproape fără excepție, cercetările vizează coloniile de roboți mobili, probabil datorită faptului că modelul biologic care a inspirat aceste cercetări, insectele sociale se caracterizează, în general, prin mobilitate.

Societățile de roboți prezintă interes pentru aplicațiile tehnice datorită gradului ridicat de toleranță la defecte. Conceptul de societate presupune implicit o înaltă redundanță, în sensul că atribuțiile unui individ, devenit nefuncțional, pot fi preluate cu ușurință de către alți membri ai societății, fără a fi necesară o reconfigurare a întregii societăți. Pe de altă parte, numărul mare de membri impune o structură de comunicație în societate, de la individ la individ. Această caracteristică permite mărirea sau micșorarea cu ușurință a numărului de indivizi dintr-o societate, fără nici o redefinire a structurii de comunicație.

Descompunerea unei sarcini în mai multe subsarcini ce pot fi executate în paralel, de obicei, mărește viteza de execuție. Această descompunere poate rezulta ca urmare a

“divizării” unui robot complex în mai mulți roboți, fiecare din aceștia fiind specializat pentru o anumită operație. Astfel, au apărut multe aplicații în care colectivitățile de roboți mobili sunt utilizate cu succes. Cele mai cunoscute dintre acestea sunt: operații de căutare, salvare și recuperare (*collective foraging*) (Kube and Zhang 1997) (*formation-marching*) (Fredslund and Mataric 2002), îndepărtarea materialelor radioactive, explorarea unor domenii necunoscute (Vainio et al. 1995), operații de supraveghere, în minerit, (David et al. 1997) (Balch and Arkin 1998), manipularea unor obiecte grele, sau voluminoase (Mondada et al. 2003).

Aplicația următoare descrie situația în care un set de roboți mobili omogeni sunt dispersați pe o anumită arie și se dorește ca roboții care au poziții extreme, să se deplaseze spre roboții cu poziții centrale astfel încât această operație să se facă printr-o deplasare cumulată minimă a roboților. Algoritmul propus pentru coordonarea deplasării unei colectivități de roboți mobili se bazează pe procesarea CNN a imaginilor obținute cu o cameră video, în care pot fi identificate pozițiile roboților (Gacsádi et al. 2006b), (Gavriliuț et al. 2007a).

Estimarea distanțelor dintre roboți

Estimarea distanțelor dintre doi roboți s-a făcut prin determinarea vecinătății cu rază minimă, a pixelului ce indică poziția unui robot, care include pixelul corespunzător poziției celuilalt robot. Dacă se presupune o colectivitate de n roboți mobili, având fiecare coordonatele poziției în imagine, date de perechea (i, j) , $(R1(i_1, j_1), R2(i_2, j_2) \dots Rn(i_n, j_n))$, vecinătatea de rază r pentru robotul Rn este dată de relația următoare:

$$V_{Rn,r}(i_n, j_n) = \{C(k_n, l_n) \mid \max\{|k_n - i_n|, |l_n - j_n|\} \leq r\} \quad (2.3.8)$$

Distanța măsurată, în număr de pixeli, r_{1m} dintre robotul $R1$ și un robot Rm este:

$$\text{dacă } (i_m, j_m) \in V_{R1,r}(i_1, j_1) \text{ și } (i_m, j_m) \notin V_{R1,r-1}(i_1, j_1) \text{ atunci } r_{1m} = r \quad (2.3.9)$$

$$\forall \text{ ar fi } m \in [1, n], m \neq 1 \text{ și } r \in [1, r_1]$$

În mod similar vor fi determinate distanțele, măsurate în număr de pixeli, dintre robotul $R1$ și toți ceilalți roboți din grup: $r_{1m} \forall \text{ ar fi } m \in [1, n], m \neq 1$.

Pentru simplificare, se va lua în considerare proprietatea de reciprocitate și anume:

$$r_{pm} = r_{mp} \quad \forall \text{ ar fi } p \in [1, n] \text{ și } m \in [1, n], p \neq m. \quad (2.3.10)$$

Imaginea vecinătății unui robot se poate obține cu ajutorul rețelelor neuronale celulare prin aplicarea template-ului DILATION (***) (2010). Astfel, aplicând acest template, asupra imaginii cu un singur pixel negru, ce reprezintă poziția robotului, se va obține imaginea vecinătății de rază $r=1$, iar prin aplicarea repetată a acestuia, se vor obține vecinătăți cu raze din ce în ce mai mari.

Pentru o situație concretă, cu patru roboți, în figura 2.3.20, se prezintă modalitatea de obținere succesivă a vecinătăților robotului $R1$, până când acestea acoperă treptat pixelii corespunzători poziției roboților $R2, R3$ și $R4$. În mod similar vor fi generate vecinătățile pentru ceilalți roboți din grup: $R2, R3$ și $R4$. Ordinea estimării distanțelor dintre roboți s-a

făcut în două moduri și anume: într-o ordine prestabilită și în ordinea crescătoare a distanțelor.




Figura 2.3.20: Generarea vecinătăților corespunzătoare robotului R1:
 a) pozițiile roboților R1..R4; b) vecinătatea de rază $r=1$; c) $r=2$; d) $r=3$;
 e) $r=4$ (acoperirea pixelului corespunzător robotului R3); f) $r=5$ (acoperirea și a pixelului corespunzător robotului R2); g) $r=6$; h) $r=7$ (acoperirea și a pixelului corespunzător robotului R4).

Organigrama pentru estimarea distanțelor dintre robotul R1 și ceilalți trei roboți, într-o ordine prestabilită, se prezintă în figura 2.3.1.

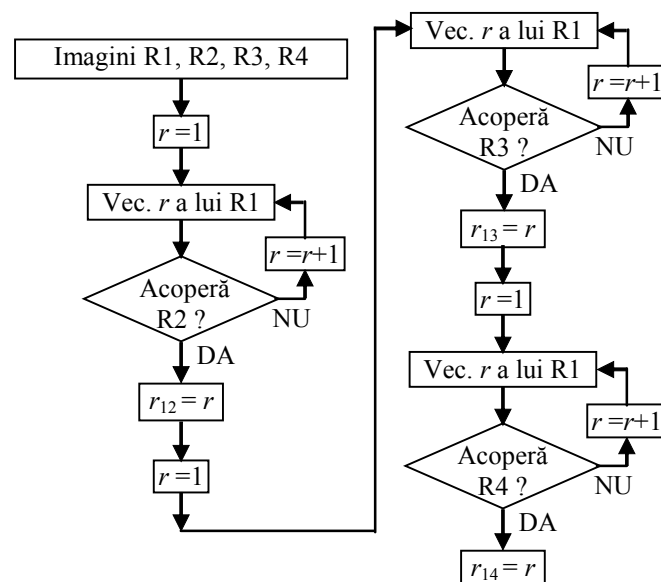


Figura 2.3.21: Organigrama pentru estimarea distanțelor dintre R1 și ceilalți trei roboți într-o ordine prestabilită.

În cazul metodei de estimare a distanțelor, în ordinea lor crescătoare, va fi determinată mai întâi distanța până la robotul cel mai apropiat apoi până la următorul robot situat cel mai aproape și tot așa până când sunt determinate distanțele până la toți roboții din colectivitate. În

figura 2.3.22 se prezintă modul de estimare a distanțelor dintre robotul R1 și ceilalți roboți, în ordinea lor crescătoare.

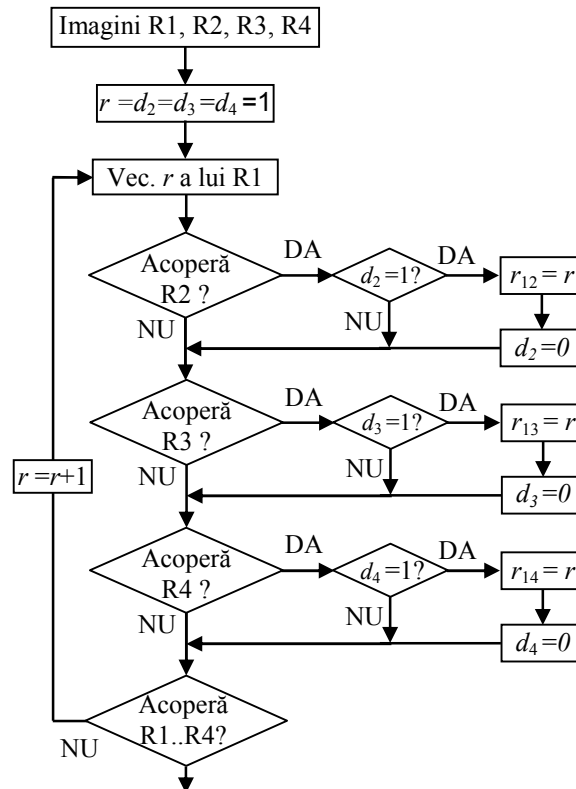


Figura 2.3.22: Organigrama pentru estimarea distanțelor în ordine crescătoare, dintre robotul R1 și ceilalți roboți (R2, R3 și R4).

Gruparea roboților în jurul celor care au poziții centrale

Pentru fiecare robot, valorile obținute prin estimarea distanțelor față de ceilalți roboți vor fi cumulate și astfel vor fi obținute valorile N_1 , N_2 , N_3 și N_4 . Pe baza acestor valori se poate aprecia cât de aproape este situat un robot față de ceilalți roboți. Valorile acestor indicatori sunt date de relațiile următoare:

$$\begin{aligned}
 N_1 &= r_{12} + r_{13} + r_{14}; \\
 N_2 &= r_{21} + r_{23} + r_{24}; \\
 N_3 &= r_{31} + r_{32} + r_{34}; \\
 N_4 &= r_{41} + r_{42} + r_{43}.
 \end{aligned}
 \tag{2.3.11}$$

Prin compararea acestor valori se poate determina care robot sau roboți au poziții centrale comparativ cu pozițiile celorlalți roboți. Astfel pot exista mai multe situații și anume:

- nu există nici un robot cu poziție centrală ($N_1 = N_2 = N_3 = N_4$);
- un singur robot (ex. R1) are poziție centrală ($N_1 < \min(N_2, N_3, N_4)$);
- doi roboți (ex. R1, R2) au poziții centrale ($N_1 = N_2 < \min(N_3, N_4)$);
- trei roboți (ex. R1, R2, R3) au poziții centrale ($N_1 = N_2 = N_3 < N_4$).

Adunarea roboților în jurul roboților cu poziții centrale (roboți central), astfel încât să fie minimizată lungimea deplasărilor cumulate ale roboților mobili, $tr_{totală}$, dată de relația 2.3.12, se poate obține prin deplasarea roboților din pozițiile extremă (roboți extremă) spre roboții mobili având poziții centrale.

$$tr_{totală} = tr_{R1} + tr_{R2} + tr_{R3} + tr_{R4} \quad (2.3.12)$$

În situația cu un robot central și un robot extremă, robotul din poziția extremă se va deplasa pas cu pas până va intra în vecinătatea de rază $r=1$ a robotului situat în poziția centrală. Dacă se presupune că robotul R1 este robotul cu poziție centrală în cadrul grupului, iar R2 este robotul având o poziție extremă, organigrama algoritmului de grupare pentru această situație este prezentată în figura 2.3.23.

Dacă doi roboți au poziții centrale și un singur robot are poziție extremă, acesta din urmă va trebui să se deplaseze spre robotul central cel mai apropiat de el. Astfel, dacă se presupune că roboții R1 și R2 sunt roboți centrali iar R3 este robotul extremă care trebuie grupat, acesta va alege să se deplaseze spre unul din aceștia prin compararea valorilor r_{31} și r_{32} . Astfel, pot exista situațiile:

- dacă $r_{31} < r_{32}$ robotul R3 se va deplasa spre R1;
- dacă $r_{31} > r_{32}$ robotul R3 se va deplasa spre R2;
- dacă $r_{31} = r_{32}$ robotul R3 se va deplasa spre oricare din roboții R1 sau R2.

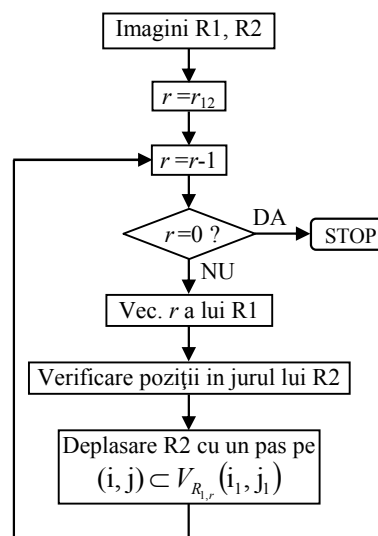


Figura 2.3.23: Organigrama pentru gruparea roboților în cazul existenței unui robot extremă (R2) și a unui robot central (R1).

Odată ales robotul spre care trebuie să se deplaseze R3, algoritmul va continua conform organigramei din figura 2.3.23.

Dacă se consideră, spre exemplu, situația concretă cu R1 robot central și R2, R3 roboți extreme atunci deplasarea acestora din urmă spre robotul central se va face conform organigramei din figura 2.3.24.

Algoritmii de grupare a roboților mobili prezentați mai sus au fost testați utilizând mediul de simulare Cadetwin (**1999a). Rezultatele simulărilor au fost obținute pe baza unor programe scrise în limbaj de asamblare (**1999b). Imaginile utilizate pentru testare au dimensiuni de 32*32 pixeli.

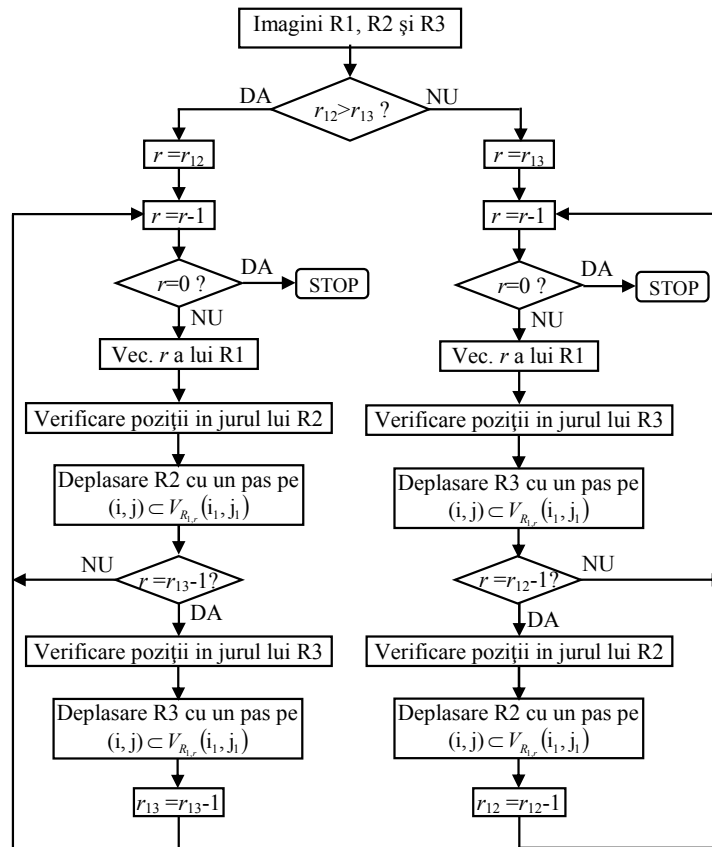


Figura 2.3.24: Organigrama algoritmului pentru gruparea roboților în cazul existenței unui robot central (R1) și a doi roboți extremă (R2) și (R3).

În figura 2.3.25 se prezintă un exemplu de determinare a roboților centrali și a roboților extremă utilizând algoritmul prezentat anterior. Se presupune că o colectivitate de patru roboți mobili R1...R4 are dispunerea geometrică ca în figura 2.3.25a. În figura 2.3.25b se arată vecinătățile pixelului care indică poziția robotului R1, astfel încât acestea să acopere pixelii ce indică poziția roboților R2, R3 și R4. În figura 2.3.25c se arată vecinătățile pixelului care indică poziția robotului R2, astfel încât să acopere pixelii ce indică poziția roboților R3 și R4. În figura 2.3.25d se arată vecinătățile pixelului care indică poziția robotului R3, astfel încât să acopere pixelul ce indică poziția robotului R4. După determinarea razelor pentru vecinătățile prezentate mai sus, se obține în final imaginea pixelilor ce reprezintă roboții cu poziții centrale (figura 2.3.25e) și respectiv cu poziții extreme (figura 2.3.25f).

În figura 2.3.26 se prezintă un exemplu de grupare a doi roboți extremă în jurul unui robot cu poziție centrală. În figura 2.3.26a sunt reprezentate prin câte un pixel negru pozițiile inițiale ale celor trei roboți, R1 fiind robotul cu poziție centrală iar roboții R2 și R3 cu poziții extreme. Într-o primă fază se va deplasa robotul R2 spre robotul R1 atâta timp cât el este cel mai îndepărtat de R1 (figura 2.3.26b). Deoarece robotul R3 va deveni robotul cu poziția cea mai îndepărtată de robotul central se va deplasa în mod similar ca și robotul R2. În continuare

roboții R2 și R3 vor face alternativ câte un pas (pixel) până când ambii vor ajunge în vecinătatea de rază $r=1$ a robotului central R1 (figura 2.3.26c).

Timpul total necesar pentru rularea algoritmului de grupare a roboților, depinde de varianta de estimare a distanțelor dintre roboți. Cel mai scurt timp s-a obținut în cazul în care estimarea distanțelor dintre roboți s-a făcut în ordinea crescătoare a lor. Astfel, în această variantă, acest timp a fost redus cu aproximativ 25%, față de varianta cu estimarea distanțelor într-o ordine prestabilită. De asemenea, ținându-se cont de relația 2.3.10, s-a obținut și o reducere a timpului de procesare cu 40%.

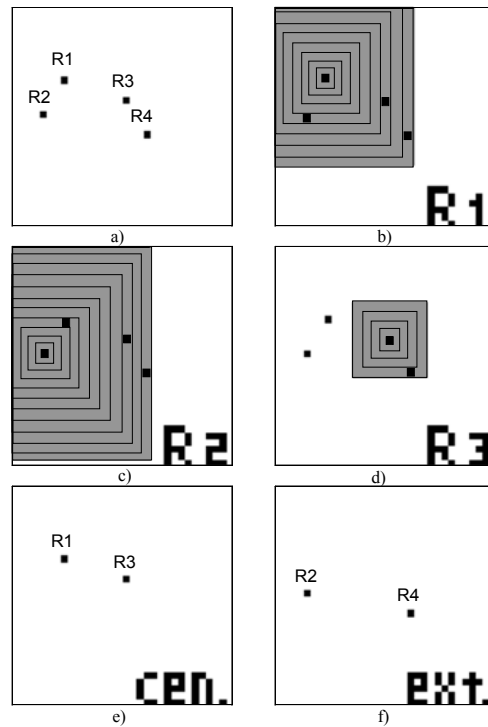


Figura 2.3.25: Exemplu de determinare a roboților cu poziție centrală și poziție extremă dintr-un grup: a) pozițiile roboților; b) vecinătățile lui R1; c) vecinătățile lui R2; d) vecinătățile lui R3; e) roboții cu poziție centrală; f) roboții cu poziție extremă.




Figura 2.3.26: Exemplu de grupare a doi roboți mobili în jurul unui robot cu poziție centrală: a) pozițiile inițiale ale roboților; b) deplasarea lui R2, c) deplasarea alternativă a lui R2 și R3.

2.3.4. Mediu integrat pentru navigația unui robot mobil

Deplasarea autonomă efectivă a unui robot mobil, într-un mediu real nestructurat, este una dintre cele mai dificile sarcini din domeniul roboticii. Navigația autonomă a unui robot mobil într-un mediu cu obstacole, presupune existența unui sistem complex care trebuie să perceapă mediul de lucru, să stabilească traiectoria optimă și apoi să elaboreze semnale de comandă pentru sistemul de acționare al robotului.

Perceperea structurii mediului de lucru cu obstacole se poate face pe baza unor hărți cunoscute apriori sau realizate în timpul deplasării robotului pe baza informațiilor senzoriale. Cei mai utilizați senzori în acest sens sunt: senzorii vizuali (camerele video) și senzorii de proximitate (senzorii: laser, în infraroșu și ultrasonici). Senzorii vizuali constituie o sursă bogată de informații, dar utilizarea lor pentru navigarea roboților mobili presupune procesarea unei cantități mari de informație, care consumă timp și poate conduce în final la o viteză de navigare scăzută. Prin utilizarea rețelelor neuronale/nelineare celulare se poate reduce substanțial, timpul de procesare a imaginilor.

În continuare se prezintă un mediu integrat pentru comanda deplasării unui robot mobil pe baza imaginilor achiziționate cu o cameră video (Gavriliuț et al. 2007b), (Gavriliuț et al. 2009). Procesarea imaginilor mediului cu obstacole se realizează cu rețele neuronale/nelineare celulare, prin utilizarea toolbox-ului MatCNN (Rekeczky 1997), din mediul de simulare Matlab. În figura 2.3.27 este prezentată schema bloc de principiu a mediului integrat considerat pentru efectuarea experimentelor.

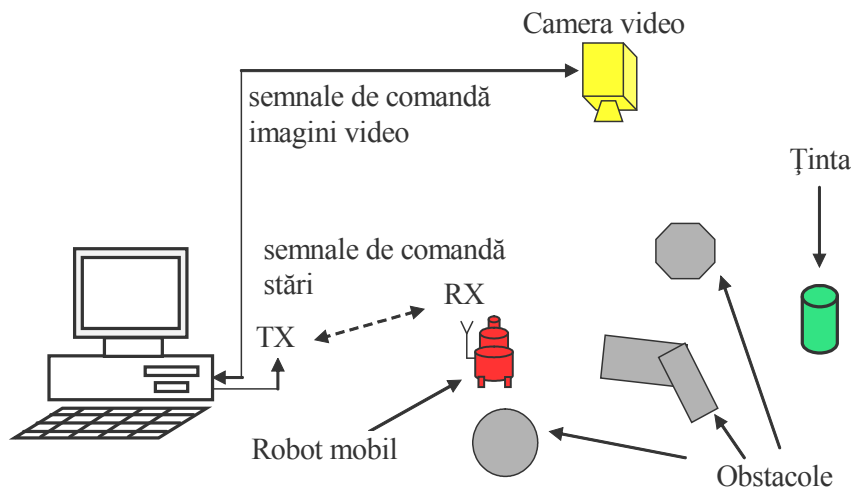


Figura 2.3.27: Structura sistemului integrat pentru navigația unui robot mobil într-un mediu cu obstacole.

Robotul trebuie să se deplaseze spre țintă pe o traiectorie cât mai scurtă, ocolind obstacolele. Camera video supraveghează întreg mediul de lucru și captează imagini la momente discrete de timp. De fiecare dată, după procesarea acestora, va fi planificată traiectoria ce trebuie urmată în continuare de către robot și vor fi elaborate și transmise comenzi către sistemul de acționare al robotului pentru realizarea deplasării pe direcția specificată. Pentru navigarea robotului în mediul de lucru se propune o metodă hibridă, alcătuită dintr-o planificare globală bazată pe imagini, care ghidează robotul spre țintă pe o

traietorie optimă, respectiv o metodă locală, bazată pe utilizarea senzorilor în infraroșu, care asigură ca robotul să evite obstacolele în mișcare, ce pot apărea în calea sa în cursul deplasării. Organigrama pe baza căreia se derulează întreg procesul de navigare, începând cu achiziția imaginilor, apoi procesarea acestora, planificarea globală a traiectoriei și în final realizarea deplasării robotului se prezintă în figura 2.3.28.

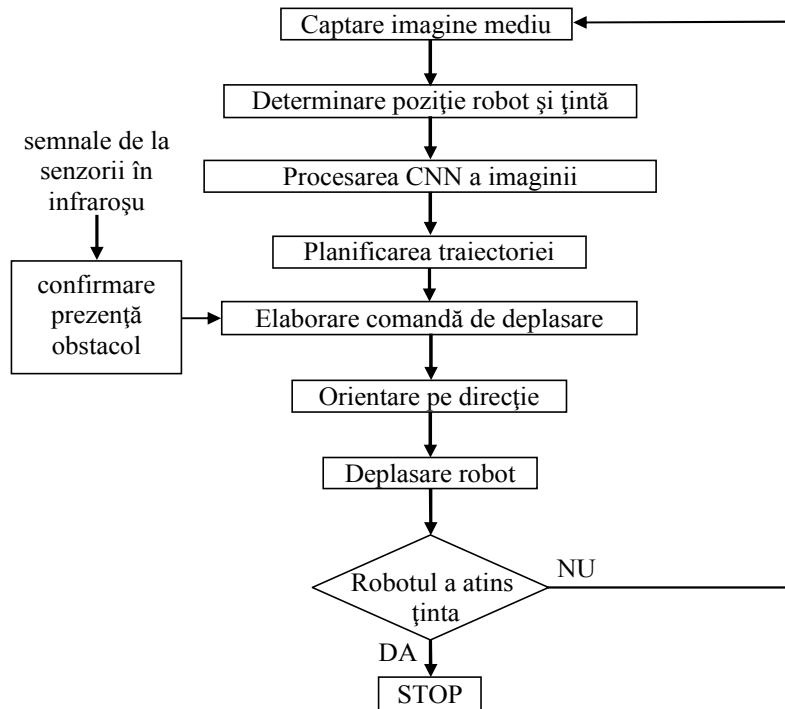


Figura 2.3.28: Organigrama procesului de planificare și comandă a navigării robotului mobil.

Procesarea CNN a imaginilor mediului de lucru

Într-o primă variantă, achiziția imaginii mediului s-a făcut cu o cameră Web de tipul *USB PC Camera 305* montată pe portul USB al unui calculator Pentium IV. Comanda camerei video, respectiv stabilirea momentelor de achiziție a imaginilor și setarea parametrilor este realizată din mediul Matlab pe baza unui program denumit VFM (*Vision For Matlab*), (Soinio 2003). Înainte de captarea imaginii pot fi realizate reglajele necesare asupra camerei video (rezoluția imaginilor, luminozitate, contrast, etc.). În aceste imagini vor fi identificate de fiecare dată, pe baza matricelor rezultate, poziția robotului mobil precum și poziția țintei. Poziția acestora va fi identificată prin câte un pixel chiar dacă dimensiunea reală a acestora este mai mare, se va reprezenta practic centrul de simetrie al imaginii celor două elemente. Poziția robotului și poziția țintei pot fi determinate și pe baza imaginii cu niveluri de gri a mediului prin utilizarea unor algoritmi de recunoaștere a formelor și apoi de detecție a punctului central al acestor forme. În cazul robotului, pe lângă poziția acestuia trebuie determinată și orientarea sa în raport cu ținta sau cu un sistem de referință fix (Gacsádi and Tiponuç 2002).

Imaginea reală a mediului poate fi achiziționată o singură dată și apoi prin procesarea acestei imagini se planifică în întregime traiectoria robotului sau pot fi achiziționate periodic

mai multe imagini ale mediului la momente discrete de timp $(t_0 + kT)$, începând de la momentul inițial t_0 , cu pasul de eșantionare T , k fiind un număr natural, $k \in \mathbb{N}$. Fiecare imagine achiziționată va fi procesată, rezultând comanda (direcția și timpul de deplasare) ce trebuie transmisă robotului. În acest fel, procesul **achiziție imagine** \rightarrow **planificare traiectorie** \rightarrow **comandă deplasare**, se va repeta până când robotul atinge ținta. Această din urmă metodă are avantajul că ține cont de eventualele modificări ale structurii mediului cu obstacole survenite în momentul deplasării robotului.

Pe baza celor trei matrice de culoare se obține imaginea cu niveluri de gri a mediului care va fi utilizată pentru identificarea pozițiilor din mediu în care sunt situate obstacolele. Pentru a putea fi procesată cu ajutorul unei rețele neuronale celulare, imaginea trebuie transferată în domeniul standard CNN cu niveluri de gri, adică $[-1, +1]$ de la alb către negru.

Se consideră că obstacolele au luminanța mai mică decât cea a spațiilor libere, astfel că, pentru identificarea acestora se poate folosi template-ul TRESHOLD (** 2010):

$$A = \begin{pmatrix} 0 & 0 & 0 \\ 0 & 2 & 0 \\ 0 & 0 & 0 \end{pmatrix} \quad B = \begin{pmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{pmatrix} \quad z = 0. \quad (2.3.13)$$

Pe intrarea și pe starea inițială a rețelei neuronale celulare se aplică imaginea cu niveluri de gri a mediului cu obstacole. După aplicarea template-ului prezentat mai sus, pe ieșirea rețelei se obține imaginea binară a mediului, în care obstacolele sunt reprezentate de către pixelii negri (valoarea +1) iar spațiile libere de pixelii albi (valoarea -1).

În funcție de condițiile de iluminare existente în mediul de lucru precum și de variația luminanței zonelor libere, imaginea achiziționată poate conține unele "zgomote", astfel că, unele porțiuni mici din spațiul liber pot fi interpretate ca fiind obstacole. Apare astfel necesitatea eliminării acestora din imagine, lucru ce poate fi realizat prin aplicarea template-ului EROSION (** 2010):

$$A = \begin{pmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{pmatrix} \quad B = \begin{pmatrix} 0 & 1 & 0 \\ 1 & 1 & 1 \\ 0 & 1 & 0 \end{pmatrix} \quad z = -4. \quad (2.3.14)$$

Datorită faptului că prin această acțiune sunt afectate și dimensiunile obstacolelor din imagine, se aplică în continuare template-ul DILATION (** 2010). În acest fel, este posibilă refacerea dimensiunilor formelor care semnifică obstacolele.

În figura 2.3.29 se prezintă un exemplu de aplicare a template-urilor prezentate mai sus asupra unei imagini gray-scale a mediului cu obstacole achiziționate cu camera video (figura 2.3.29a). Prin aplicarea template-ului TRESHOLD, valorile pixelilor care au luminanța peste un anumit prag devin albi iar ceilalți pixeli vor fi de culoare neagră, obținându-se astfel o imagine binară a mediului (figura 2.3.29b). Eliminarea unor eventuale "zgomote" sub forma unor dungă subțiri de culoare neagră, ce pot fi interpretate ca fiind obstacole se realizează prin aplicarea template-ului EROSION (figura 2.3.29c), iar refacerea dimensiunilor obstacolelor este posibilă prin aplicarea template-ului DILATION (figura 2.3.29d).




Figura 2.3.29: Exemplu de procesări CNN a imaginii reale ale unui mediu cu obstacole: a) imaginea gray-scale a mediului; b) imaginea rezultată după aplicarea TRESHOLD; c) imaginea rezultată după aplicarea EROSION; d) imaginea rezultată după aplicarea DILATION.

Planificarea traiectoriei

Pentru estimarea poziției robotului față de țintă și planificarea apoi a traiectoriei acestuia s-a utilizat metoda câmpului potențial artificial (Schneider and Wildermuth 2003). Această metodă presupune realizarea, pe baza imaginii mediului cu obstacole, a unui câmp potențial de atracție și a unui câmp potențial de repulsie.

Câmpul potențial de atracție se realizează pe baza unei funcții potențiale de atracție, denumită și potențial atractiv, calculată pentru fiecare punct din mediul de lucru, și care este dată de relația următoare:

$$U_{\text{atr}}(i, j) = \frac{1}{2} \cdot k \cdot d(i, j) \quad \text{pentru } \forall \text{ ar fi } i = 1 \dots m, j = 1 \dots n, \quad (2.3.15)$$

unde k reprezintă un număr întreg pozitiv, iar funcția d reprezintă distanța euclidiană dintre pixelii i și j .

Dacă se notează cu (z, c) perechile de coordonate ce reprezintă pozițiile ocupate de către obstacole, atunci valorile funcției potențiale de repulsie pe baza căreia se realizează câmpul potențial de repulsie sunt date de relația:

$$U_{\text{rep}}(i, j) = \begin{cases} U_{\text{max}} & \text{dacă } i = z \text{ și } j = c \\ n \cdot \left(\frac{1}{d((z, c), (i, j))} \right)^2 & \text{dacă } i \in [z - q, z + q] \text{ sau } j \in [c - q, c + q] \end{cases} \quad (2.3.16)$$

unde n reprezintă un număr întreg pozitiv, q reprezintă raza de acțiune, măsurată în număr de pixeli, a câmpului în jurul obstacolelor și $d((z, c), (i, j))$ reprezintă distanța euclidiană dintre pixelii pe care sunt situate obstacolele și pixelii din vecinătatea obstacolelor care sunt situați în raza de acțiune a câmpului.

Prin însumarea celor două câmpuri potențiale, pe întreg mediul de lucru al robotului, se obține câmpul potențial artificial total, $U_{\text{total}}(i, j)$:

$$U_{\text{total}}(i, j) = U_{\text{atr}}(i, j) + U_{\text{rep}}(i, j), \quad \text{pentru } \forall \text{ ar fi } i = 1 \dots m, j = 1 \dots n. \quad (2.3.17)$$

În figura 2.3.30 se prezintă un exemplu de realizare a unui câmp potențial artificial pentru un mediu cu obstacole având imaginea cu rezoluția 160*120 pixeli (figura 2.3.30a). Câmpul potențial de atracție are forma prezentată în figura 2.3.30b. Având cunoscute pozițiile pe care sunt situate obstacolele, se realizează câmpul potențial de repulsie figura 2.3.30c. Prin însumarea celor două câmpuri potențiale se obține câmpul potențial artificial total (figura 2.3.30d).




Figura 2.3.30: Realizarea câmpului potențial artificial; a) imaginea gray-scale a unui mediu cu obstacole, b) potențialul de atracție, c) potențialul de repulsie, d) potențialul total.

Planificarea traiectoriei este realizată pixel cu pixel, începând de la pixelul care reprezintă poziția inițială a robotului (iR, jR), prin determinarea de fiecare dată a celui pixel ce are valoarea cea mai mică dintre cei opt pixeli vecini, situați în jurul pixelului care reprezintă poziția curentă a robotului. În figura 2.3.31 se poate observa forma traiectoriei planificate în cazul imaginilor prezentate mai sus, în care poziția țintei este dată de pixelul având coordonatele $i = 130$ și $j = 20$, iar poziția robotului este dată de pixelul de coordonate $i = 20$ și $j = 100$.




Figura 2.3.31: Traiectoria planificată.

Inițial, pentru testarea practică a algoritmului de navigare, s-a utilizat robotul mobil miniatură Robby RP5 (figura 2.3.32) (** c-robotics). Sistemul locomotor al acestui robot se compune din două șenile angrenate de două motoare de curent continuu. Turația motoarelor poate fi controlată prin modulația în durată a impulsurilor de tensiune, care le alimentează (*PWM*). La comanda robotului RP5 s-a utilizat microcontrolerul M68HC05, iar programele aplicații au fost realizate în limbajul BASIC, în mediul de proiectare integrat (*IDE - Integrated Design Environment*) (** c-robotics). Pentru planificarea locală a traiectoriei, respectiv evitarea coliziunii cu obstacole neașteptate ce pot să apară în calea robotului, acesta este echipat și cu doi senzori în infraroșu. Ulterior, comanda robotului s-a realizat cu placa de dezvoltare Arduino Uno care are la bază un microcontroler ATmega328, iar navigația locală utilizează senzori ultrasonici. În prezent robotul miniatură, utilizat și în activitatea didactică, se poate comanda și cu ajutorul unui telefon (*smartphone*) prin comunicare *Bluetooth* (figura 2.3.32).




Figura 2.3.32: Robotul mobil Robby RP 5, modificat.

2.4. Sistem integrat pentru asistarea persoanelor cu deficiențe de vedere

Persoanele cu deficiențe de vedere reprezintă o categorie importantă din populația globului, actualmente numărul lor fiind estimat la zeci de milioane. Este cunoscut faptul că, dintre cele cinci simțuri pe care le are un om, sistemul vizual este cel mai important, furnizând cea mai mare cantitate de informație dinspre mediul înconjurător. Orientarea și mobilitatea persoanei sunt afectate drastic de către deficiența vizuală, chiar dacă, în mod natural, există din partea organismului o tendință de compensare a ei prin celelalte simțuri. Indiferent de cauza care produce și etapa vieții în care se instalează deficiența de vedere, (la naștere, accident, boală dobândită, procesul natural de îmbătrânire), asigurarea calității vieții acestor persoane și integrarea lor în societate reprezintă un obiectiv important și de actualitate permanentă.

În decursul timpului s-au abordat diverse metode de ajutorare a persoanelor cu deficiențe de vedere, începând cu ajutorul dat de o altă persoană umană, utilizarea bastonului alb, utilizarea câinilor dresați și până la diferite sisteme tehnice senzoriale (Dowling et al. 2003), (Shoval et al. 2003). Problema principală a utilizării bastonului alb, o soluție ieftină dar și cu beneficii limitate, îl reprezintă necesitatea efectuării multor ore de antrenament. Pentru dresarea unui câine sunt necesare, de asemenea, multe ore de antrenament dar și cheltuieli financiare ridicate. De aceea, utilizarea lor este posibilă într-un număr redus de cazuri. Rezultă în mod evident necesitatea construirii unor mijloace tehnice care să asiste deplasarea unei persoane cu deficiențe de vedere. De asemenea, se remarcă câteva caracteristici principale pe care trebuie să le îndeplinească un astfel de sistem: să dispună de funcții de asistare cât mai multe și eficiente, să aibă greutate cât mai mică, să fie portabil, să asigure o comunicație (interfață) eficientă om-mașină, și nu în ultimul rând, un preț de cost accesibil pentru orice persoană cu deficiențe de vedere.

În ultimele decenii au fost elaborate numeroase sisteme tehnice, bazate pe senzori, care sunt destinate pentru asistarea în deplasare a persoanelor cu deficiențe de vedere. Deseori, aceste sisteme sunt optimizate numai pentru anumite funcții limitate, totuși pot contribui substanțial la îmbunătățirea mobilității nevăzătorilor prin creșterea siguranței și a vitezei de deplasare. Dintre acestea se pot aminti: sistemul *LaserCane* (Shoval et al. 2003), sistemul *Teletact*, sistemul *Sonicguide K.A.S.P.A.*, sistemul *NavBelt*, sistemul *Guide Cane* (Ulrich et al. 2001), sistemul *Intelligent Glasses* (Velázquez et al. 2003), sisteme bazate pe detecția obiectelor în imagini (Van der Heijden et al. 2005), sisteme de asistare bazate pe navigație globală *DRISHTI* (Helal et al. 2001).

Sistemul *Bionic Eyeglass* (Roska et al. 2006), (Karacs et al. 2008), elaborat pe baza recomandărilor persoanelor cu deficiențe de vedere, ia în considerare existența a trei tipuri de medii în care oferă asistență: acasă, la locul de muncă și la deplasarea între cele două locații. Sistemul propus asigură următoarele caracteristici: recunoașterea hainelor bazată pe detecția texturii și a culorii, recunoașterea trecerilor de pietoni, recunoașterea bancnotelor, recunoașterea semnelor de transport public și a numărului rutei de transport, recunoașterea semnelor unui ascensor și recunoașterea direcției de deplasare a scârilor rulante. Pentru realizarea acestor funcții, mediul integrat propus folosește tehnologia CNN pentru procesarea

semnalelor: arhitectura vizuală duală Bi-i (***) (2007) și emulatorul digital CNN-UM implementat pe FPGA (Nagy et al. 2006).

Refacerea parțială a vederii persoanelor nevăzătoare constituie o abordare cu rezultate parțiale deosebit de promițătoare, de aceea, actualmente este obiectul de cercetare al mai multor echipe din întreaga lume. Refacerea parțială a vederii poate fi obținută prin utilizarea unei camere de luat vederi care furnizează imagini, la anumite intervale de timp, unui bloc de procesare a informației, pentru ca în final informațiile să fie transformate în semnale electrice ce sunt trimise la creier printr-un implant ce face legătura cu calea vizuală umană (Dowling et al. 2003). Deși deocamdată, nu se poate realiza, o restaurare totală a vederii persoanelor nevăzătoare, totuși printr-o bună procesare a informației vizuale, se poate obține o detecție a scenei din imagine, și în final o bună percepție a realității de către persoanele în cauză.

În urma analizei sistemelor tehnice elaborate pentru îmbunătățirea abilităților persoanelor cu deficiențe de vedere se evidențiază complexitatea și multitudinea problemelor pe care le implică asistarea acestor persoane, insuficiențele și limitele soluțiilor actuale și accesibile. Acest domeniu multidisciplinar este într-un proces de dezvoltare continuă, ca rezultat al implicării mai multor colective de cercetare din întreaga lume. Pe de altă parte, se poate observa că, persoanele cu deficiențe de vedere și roboții mobili întâmpină probleme similare la deplasarea în medii nestructurate. Prin urmare, tehnicile specifice roboților mobili, precum metodele de planificare a traiectoriei și metodele de evitare a obstacolelor, pot reprezenta soluții pentru sistemele electronice de asistare a deplasării persoanelor cu handicap vizual.

În acest capitol sunt prezentate unele subiecte, abordate de colective de cercetare din care a făcut parte și autorul prezentei lucrări, în domeniul sistemelor electronice de asistare la deplasare a persoanelor cu deficiențe de vedere: structuri și module ale unui sistem integrat (Tiponuț et al. 2006b), (Tiponuț et al. 2005-2007), evoluția acestora ținând cont de dinamica tehnologiei electronice (Țepelea et al. 2014); procesarea paralelă a imaginilor cu rețele neuronale/nelineare celulare (*wave computing* – „calcul ondulatoriu”), exemplificată printr-un algoritm CNN de corelație (Țepelea et al. 2011) și implementarea acestuia pe o platformă FPGA (Kincses et al. 2012).

2.4.1. Medii integrate pentru deplasarea persoanelor cu deficiențe de vedere

Prin dezvoltarea unor noi structuri de medii integrate de asistare a persoanelor cu deficiențe de vedere se urmărește extinderea și îmbunătățirea performanțelor simultan cu creșterea preciziei și scăderea timpului de procesare.

În figura 2.4.1 este prezentat mediul integrat pentru asistarea în deplasare a persoanelor cu deficiențe de vedere, propus de Tiponuț și colab. (Tiponuț et al. 2006b). Pentru creșterea eficienței sistemului, s-a avut în vedere combinarea optimă a celor două tipuri de navigații complementare, metoda de navigație globală și metoda de navigație locală, utilizate și în cazul conducerii robotului mobil. Metodele de navigație globală servesc la proiectarea unei traiectorii optime de urmat prin evitarea obstacolelor statice, fac posibilă monitorizarea

deplasării pe traseul dorit și asigură atingerea țintei dacă aceasta este posibilă. Metodele de navigație locală asigură detecția și evitarea obstacolelor dinamice de pe traseul de navigare.

De asemenea, prin integrarea eficientă a diferitelor tipuri de senzori, inclusiv fuzionarea datelor senzoriale, pot rezulta beneficii sporite. Evident, odată cu creșterea cantității de informație achiziționată, prelucrarea acesteia poate deveni greoaie și dificil de realizat în timp real, reducând viteza de deplasare a persoanei cu deficiențe de vedere. Astfel, rezultă și necesitatea utilizării unor sisteme de procesare paralelă a semnalelor cum ar fi, spre exemplu, circuitele integrate cu rețele neuronale/nelineare celulare.

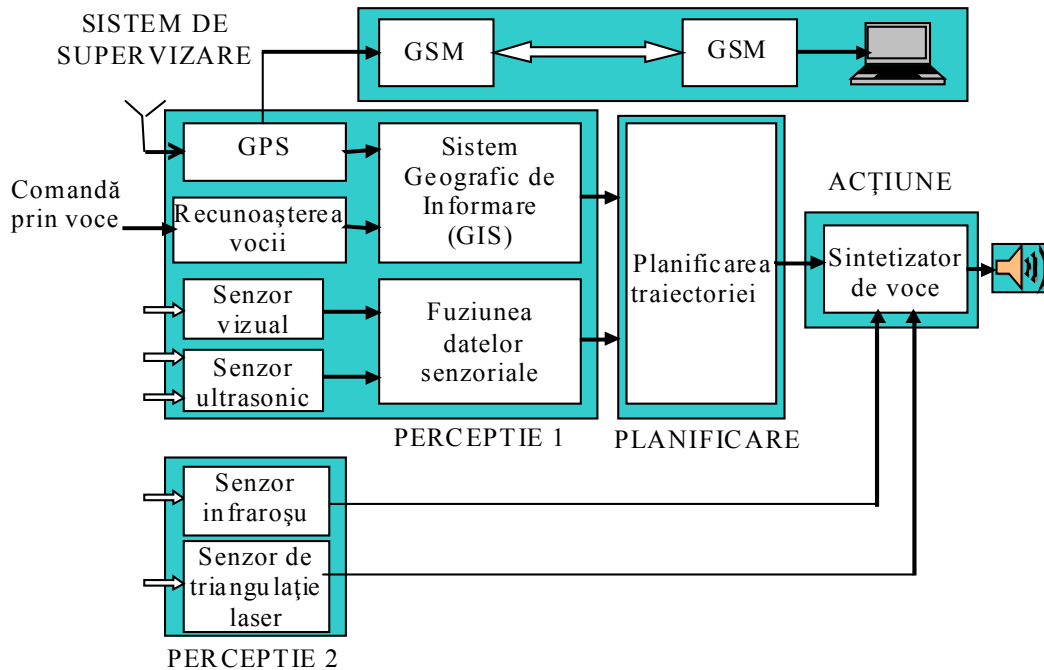


Figura 2.4.1: Arhitectura sistemului integrat pentru asistarea deplasării.

Mediul integrat, prezentat în figura 2.4.1, include blocurile PERCEPTIE 1,2, PLANIFICARE și ACȚIUNE, necesare pentru asistarea persoanelor cu deficiențe de vedere, la deplasarea spre țintă cu evitarea obstacolelor. Aceste blocuri includ: module senzoriale de detecție a obstacolelor; modulul de fuziune a datelor senzoriale; modulul de detecție a poziției prin GPS (*GPS - Global Positioning System - Sistemul de poziționare globală*); modulul de planificare a traiectoriei pe baza datelor primite de la senzori și pe baza poziției actuale; modulul de sinteză vocală prin care se comunică persoanei nevăzătoare direcția de urmat. De asemenea, structura mediului integrat înglobează și un subsistem de supraveghere a persoanelor asistate care se află în aria supervizată (module de comunicație la distanță prin GSM (*GSM - Global System for Mobile Communications - Sistem Global pentru Comunicații Mobile*)) și calculatorul personal cu aplicația program aferentă). Sistemul de supervizare asigură persoanei asistate deplasarea pe traseul planificat și detectarea poziției actuale pentru a-l putea ajuta în cazul în care apar modificări dinamice în mediu sau în cazul apariției unor evenimente deosebite și neprevăzute. În completare la poziția detectată prin GPS, este inclus și sistemul informațional geografic GIS (*GIS - Geographic Information System*).

Procedura de monitorizare a sistemului de supervizare este prezentată în figura 2.4.2.

Calculatorul (centrul de servicii) se află în permanență în schimb de informații cu persoana nevătătoare. Periodic, calculatorul interoghează echipamentul mobil prin intermediul unor mesaje de tip SMS (*Short Message Service*). Ca rezultat al acestei interogări echipamentul portabil furnizează coordonatele carteziene sistemului informațional geografic. Pe baza acestor coordonate, respectiv având o bază de date spațiale aflată pe calculatorul central, o aplicație software este capabilă să furnizeze coordonatele traiectoriei pentru fiecare persoană nevătătoare care circulă în zona supervizată.




Figura 2.4.2: Procedura de monitorizare a persoanei nevătătoare.

În figura 2.4.3 este prezentată structura internă a sistemului de supervizare din dispozitivul portabil.

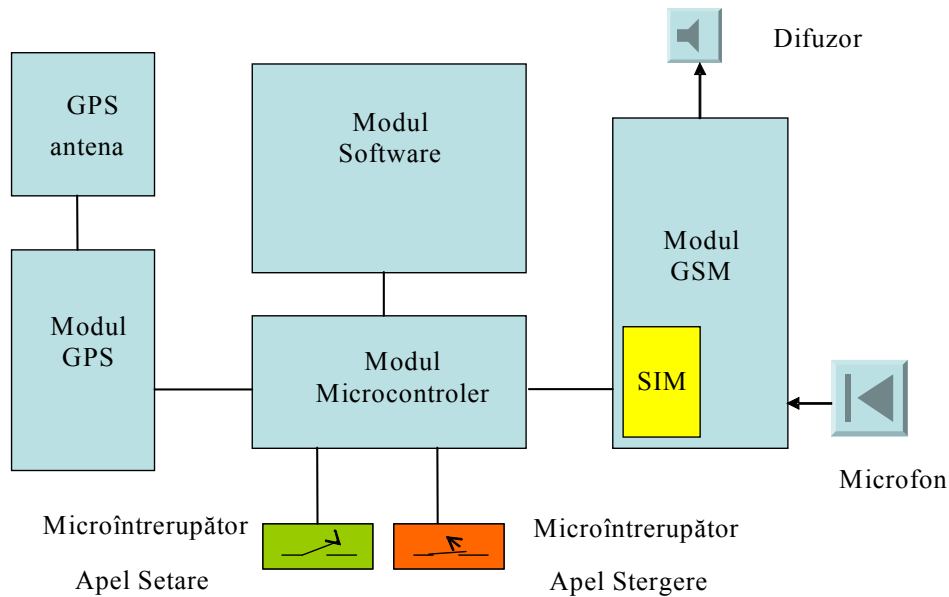


Figura 2.4.3: Structura sistemului de supervizare.

Modulul GSM recepționează un SMS și retransmite acest SMS modulului microcontroler.

Aplicația software rulată pe microcontroler analizează mesajele primite și le convertește în comenzi pentru modulul GPS. Modulul GPS execută comanda primită și furnizează răspunsul sosit către microcontrolerul care deservește modulul software. Acest modul extrage din răspuns coordonatele X, Y și realizează un mesaj de tip SMS cu aceste date. Practic mesajul este transmis apoi de GSM. Sistemul este capabil să realizeze și apel manual. Această posibilitate este foarte utilă în cazul apariției unor evenimente neprevăzute. Atât centrul de

servicii cât și persoana în cauză pot iniția un apel de ieșire sau de intrare utilizând microîntrerupătoarele Apel Setare sau Apel Ștergere.

Prin evoluția spectaculoasă a tehnologiei electronice din ultimul deceniu (procesoare tot mai performante, memorii de mare capacitate, dimensiuni tot mai reduse a componentelor și plăcilor de circuit), prin apariția unor dispozitive portabile, gen telefon (*smartphone*) sau tabletă, s-au deschis noi perspective pentru realizarea unor sisteme integrate eficiente de asistare în deplasare a persoanelor cu deficiențe de vedere.

Pornind de la conceptul de mediu integrat de asistare, prezentat anterior, s-a elaborat o altă structură de sistem integrat de asistare în deplasare a persoanelor cu deficiențe de vedere, (Țepelea et al. 2014). La acest sistem integrat de asistare, platforma principală de calcul utilizează un dispozitiv mobil gen *smartphone* sau tabletă, având putere de calcul apreciabilă. În figura 2.4.4 este prezentată arhitectura acestui mediu integrat de asistare bazat pe Android.

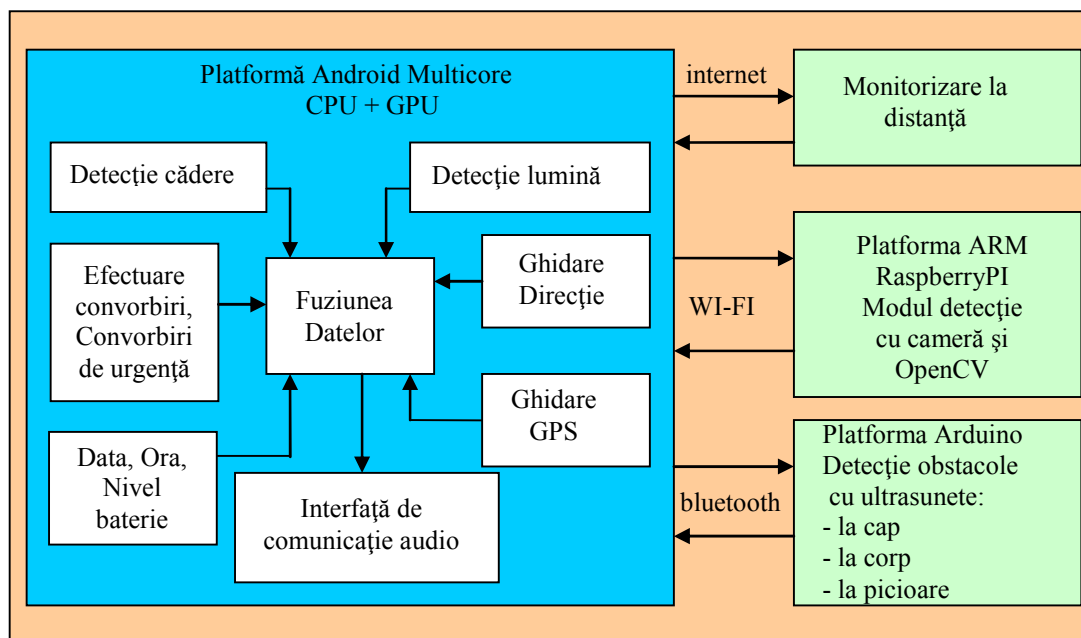


Figura 2.4.4: Mediul integrat de asistare bazat pe Android.

Alături de platforma Android Multicore, cu unitatea centrală de prelucrare și unitate de procesare grafică (*CPU - Central processing unit; GPU - Graphics processing unit*), acest sistem integrat mai include și alte două platforme: Platforma Arduino și Platforma RaspberryPI.

Platforma Arduino (Arduino Nano), are sarcina de a detecta obstacolele la trei niveluri ale persoanei asistate: la nivelul capului, la nivelul corpului și la nivelul picioarelor. Semnalele electrice, care provin de la senzorii de detecție ultrasonici, sunt prelucrate cu ajutorul aplicației software implementate pe microcontroler. Acești senzori pot detecta cu precizie obstacole de la 4 cm la 4 metri. Informațiile relevante se comunică către telefon folosind standardul Bluetooth.

Platforma RaspberryPI, utilizată tot pentru detecția obstacolelor, este bazată pe un procesor ARM (*Advanced RISC Machine; RISC - Reduced instruction set computing*) cu procesor grafic integrat și cu memorie RAM de 256 MB. Detecția obstacolelor se realizează

cu ajutorul unei camere video, de mici dimensiuni, dedicată pentru această platformă. Aplicația de detecție a obstacolelor este bazată pe mediul software *open source OpenCV (Open Source Computer Vision Library)*, frecvent utilizat și în domeniul roboticii pentru procesări de imagini în timp real. O altă opțiune pentru detectarea obiectelor cu camera video, în timp real, poate fi prelucrarea CNN a imaginilor, implementată pe o platformă FPGA.

În general, telefonul se află în mâna persoanei asistate, deci poziția lui se poate modifica în permanență, deseori fiind înclinată mai mult spre orizontală. Prin urmare, camera video inclusă în telefon nu se va putea utiliza la detectarea obstacolelor apărute în deplasare.

Camera video inclusă în telefon, având rezoluție mare, poate fi totuși utilizată pentru a detecta și recunoaște unele obiecte din imagini, spre exemplu pentru detecția bancnotelor, a indicatoarele rutiere, trecerea de pietoni, numerele de tramvai și autobuz. Cu ajutorul funcției de recunoaștere optică a caracterelor, camera poate fi folosită și la citirea unor afișe, articole din presă, etc., prin traducerea lor acustică.

Platforma hardware a telefonului include mai mulți senzori, iar datele furnizate de aceștia sunt aduse la blocul de Fuziune a Datelor. Acest bloc, analizează datele primite de la senzori, în funcție de prioritatea lor, și ia decizia adecvată privind asistarea persoanei. Deciziile sunt comunicate imediat, prin sintetizare vocală.

Pentru supervizarea persoanei nevătătoare se utilizează blocul de Detecție Cădere. Senzorul de accelerație poate detecta modificarea, peste o anumită valoare de prag prestabilită a accelerației, specifică unei căderi sau loviri puternice. Evenimentul se comunică imediat la distanță pe serverul folosit pentru supravegherea persoanei asistate și opțional se poate apela un număr de telefon prestabilit.

Blocul Detecție Lumină este utilizat pentru a detecta când sunt persoanele în interiorul clădirilor sau în afara lor. Atunci când persoana asistată ajunge într-un spațiu mai întunecos, care poate fi o cameră închisă, ieșirea poate fi mai dificilă și se impune o încetinire a deplasării pe traiectoria planificată. De asemenea, blocul Detecție Lumină poate furniza informații complementare despre perioada zilei, ziua sau noaptea.

Un rol deosebit în monitorizarea persoanei monitorizate îl are blocul de efectuare a convorbirilor telefonice și de avertizare în situații de urgență. Astfel, se poate efectua un apel telefonic de contact, un apel taxi, sau un apel de urgență chiar către serviciul 112.

Sursă de energie pentru sistemul de asistare portabil este, pe de o parte, bateria telefonului, pe de altă parte, pentru platformele anexe se mai folosește o altă sursă de energie sub forma unei baterii, cu încărcare solară. Capacitatea acestor surse de energie fiind limitate, este necesară avertizarea persoanei asistate asupra necesității încărcării bateriei. De asemenea, acest bloc oferă informații, asupra nivelului de încărcare a bateriei și asupra datei și orei.

Pentru asistarea în deplasare a persoanei cu deficiențe de vedere, un bloc funcțional detectează poziția geografică prin GPS și pe baza unei cereri de asistare până la un anumit punct geografic, se oferă asistare pas cu pas prin planificare globală asupra traiectoriei de urmat până la punctul final țintă, folosindu-se serviciile Google. Blocul de Ghidare Direcție este cel care oferă la nevoie direcția de urmat în asistare față de punctele cardinale.

Toate informațiile obținute cu ajutorul senzorilor sunt trimise pe internet la un anumit server dedicat pentru această aplicație, în scopul supravegherii persoanei asistate de la

distanță. La acest centru de asistare monitorizarea se poate face permanent sau, după caz, se pot face avertizări automate asupra unei necesități cu privire la asistarea unei anumite persoane.

În cadrul sistemului integrat de asistare a persoanelor cu deficiențe de vedere, un rol foarte important este îndeplinit de blocul de interfață audio. La elaborarea acestui bloc s-a ținut cont de faptul că interfața trebuie să permită comunicarea persoanelor cu handicap vizual, folosind telefoane ce au ecran tactil și nu au butoane. Prin urmare, toate aplicațiile Android, inclusiv această interfață, sunt special concepute pentru aceste persoane. O atingere a unui buton de pe interfața oferă utilizatorului selectarea butonului și dublu clic pe un buton comandă o aplicație. Cel mai simplu mod de a comunica cu persoana asistată este prin intermediul telefonului utilizând căștile audio și microfonul. Astfel, utilizatorul nu deranjează alte persoane din jurul lui, comunicarea este foarte clară, în același timp, având o ureche liberă, poate auzi și alte sunete din mediul înconjurător.

Sistemul folosește tehnologia TTS (*Text-To-Speech*) pentru a se adresa audio utilizatorului. De asemenea, comenzile audio ale utilizatorului, prin telefon, sunt recunoscute pentru sistem prin tehnologia de recunoaștere a vocii de la Google.

Sistemul de asistare a persoanelor cu deficiențe de vedere, descris mai sus, a fost conceput, construit și validat experimental, în urma unui proces iterativ de optimizare, sub deviza „totul într-un sistem eficient utilizând componente performante, disponibile în comerț și foarte ieftine” care să se poată utiliza efectiv în viața de zi cu zi. Evident, creșterea performanțelor componentelor utilizate va conduce inevitabil și la creșterea eficienței sistemului de asistare în ansamblu.

2.4.2. Algoritm CNN pentru calcularea corelației între două imagini

Analiza gradului de asemănare dintre două imagini

Dezvoltarea unor echipamente tot mai performante pentru asistarea persoanelor cu deficiențe de vedere, este strâns legată de rezultatele cercetărilor din domeniul prelucrării și analizei imaginilor, sau mai general a semnalelor multidimensionale. Astfel, pentru a putea fi utilizate informațiile conținute în imaginea achiziționată, aceasta trebuie adusă sub o formă cât mai ușor de interpretat, fiind supusă în acest scop unui lanț de prelucrări și analiză. Toate aceste operații de prelucrare și analiză a imaginilor trebuie să fie efectuate în timp real, deoarece viteza de achiziție și de interpretare a informațiilor poate fi vitală (Tiponuț et al. 2009). Alături de celelalte procedee clasice, tehnologia CNN, ca structură de calcul paralelă, oferă o soluție complementară de realizare a unor aplicații în timp real în domeniul procesării imaginilor.

Se consideră o imagine șablon (*template image sau correlation kernel*) și o imagine sursă (imagine test) care poate conține obiecte similare cu un obiect conținut de imaginea șablon. Corelația imaginilor, sau potrivirea unor șabloane din imagini (*template matching*), are ca obiectiv principal detectarea și localizarea în imaginea sursă a unor obiecte similare cu un obiect conținut de o imagine șablon, prin determinarea măsurii în care o porțiune din imagine sursă se aseamănă sau diferă de imaginea șablon (figura 2.4.5).

Pentru evitarea unor confuzii, în prezenta lucrare, termenul „template” se utilizează în cazul procesării CNN, așa cum s-a precizat în capitolul 2.1, iar în cazul corelației de imagini se va folosi denumirea de imagine șablon. Algoritmii de analiză a conținutului prin corelația imaginilor se folosesc adesea pentru a identifica obiecte simple (numere, litere, figuri simple).

Într-o imagine binară curentă de intrare achiziționată, rezultată după procesări elementare, se poate detecta obiectul din șablonul binar. Utilizând metrice adecvate, se poate obține un răspuns concret, dacă există sau nu în imaginea curentă obiectul căutat din imaginea șablon, fără a se preciza și poziția exactă a obiectului în imagine. Prin comparația pixel cu pixel a două imagini binare, rezultatul obținut este univoc, există sau nu există potrivire între doi pixeli corespunzători din cele două imagini.

În cazul realizării corelației imaginilor color și imaginilor gray-scale, mai întâi acestea sunt prelucrate succesiv (inclusiv binarizare) pentru a extrage cât mai multe informații relevante din imaginea originală, urmând evaluarea simultană a tuturor acestor informații primare. Este evident, că prin comparația directă a imaginilor gray-scale practic este imposibilă o potrivire perfectă a nivelelor de gri, de aceea, pentru mărimea care indică gradul de potrivire a imaginilor comparate se va folosi diferența nivelurilor de gri.

Pentru analiza gradului de asemănare sau de potrivire, dintre două imagini, se pot utiliza diferite metrice, (procedee sau funcții) cum ar fi: distanța Euclideană, suma diferențelor absolute (SDA) (relația 2.4.1), media diferențelor absolute (MDA) (relația 2.4.2), respectiv, coeficientul de corelație normalizat (CCN) (relația 2.4.3) (Jähne 2002) (Gonzalez 2004):

$$SDA(i,j) = \sum_{p=1}^P \sum_{q=1}^Q |K(p,q) - \Lambda(p,q)| \quad (2.4.1)$$

$$MDA(i,j) = \frac{\sum_{p=1}^P \sum_{q=1}^Q |K(p,q) - \Lambda(p,q)|}{PQ} \quad (2.4.2)$$

unde, $K(p,q)$ reprezintă imaginea șablon sau nucleul corelației, $K: \mathbb{R}^2 \rightarrow \mathbb{R}$, și

$$\Omega_K = \{(p,q): p \in [1,P], q \in [1,Q], P \text{ și } Q \in \mathbb{R}^+\}$$

respectiv, $\Lambda(p,q)$ reprezintă imaginea curentă comparată cu imaginea șablon,

$$\Lambda: \mathbb{R}^2 \rightarrow \mathbb{R}, \text{ și } \Omega_\Lambda = \{(p,q): p \in [1,P], q \in [1,Q], P \text{ și } Q \in \mathbb{R}^+\}.$$

Corespunzător fiecărei astfel de metrice, pentru fiecare imagine se va determina coeficientul maxim în raport cu imaginea șablon (ori coeficientul de diferență minimă în raport cu imaginea șablon), sau coeficienții mai mari ca o valoare de prag prestabilită. În funcție de valorile acestor coeficienți se poate aprecia dacă obiectul căutat există în imagine și în ce poziție.

Procedeele pentru analiza gradului de potrivire a șabloanelor, menționate mai sus, sunt relativ ușor de implementat utilizând structuri hardware clasice, dar necesită timp de procesare ridicat. Metricele SDA și MDA sunt preferate în locul calculării coeficientului de corelație normalizat tocmai cu scopul reducerii timpului de calcul. Desigur, uneori reducerea timpului de calcul poate rezulta numai în detrimentul preciziei.

Pe de altă parte, tehnologia CNN s-a dovedit a fi foarte utilă în procesarea imaginilor în timp real (Chua and Yang 1988) (Roska and Chua 1993). Reducerea efectivă a timpului de

calcul rezultă numai în cazul în care algoritmul CNN de prelucrare a semnalelor este implementat efectiv pe o structură paralelă de procesare (Cembrano et al. 2003) (**2007).

Pentru metricile SDA și MDA s-au elaborat algoritmi și s-au implementat pe structuri CNN, atât în varianta analogică utilizând chip CNN, cât și pe emulatorul digital CNN-UM implementat pe FPGA. În general, alegerea variantei celei mai potrivite de implementare depinde de aplicația concretă: natura imaginilor procesate (imagini binare, gray-scale sau color), dimensiunile imaginilor, etc.

Kincses și colab. utilizează metrica SDA pentru analiza gradului de potrivire al unor imagini, luând în considerare limitările dispozitivelor FPGA și parametrizarea specială pentru propagarea undei (Kincses et al. 2011).

Coeficientul de corelație dintre două imagini

Se consideră imaginea $\Phi(m,n)$, unde $\Phi: \mathbb{R}^2 \rightarrow \mathbb{R}$, și $\Omega_\Phi = \{(m,n): m \in [1,M], n \in [1,N], M \text{ și } N \in \mathbb{R}^+\}$, reprezentând o imagine sursă (imaginea test), respectiv $K(p,q)$, o imagine șablon, unde $K: \mathbb{R}^2 \rightarrow \mathbb{R}$, și $\Omega_K = \{(p,q): p \in [1,P], q \in [1,Q], P \text{ și } Q \in \mathbb{R}^+\}$. Imaginea sursă se baleiază pixel cu pixel astfel încât imaginea șablon să se suprapună complet pe imaginea sursă și se calculează gradul de potrivire în fiecare pixel. Gradul de potrivire cu șablonul $K(p,q)$, a unei regiuni $\Lambda(p,q)$ din imaginea sursă, se obține prin calcularea unui coeficient de corelație (index numeric) care indică valoric cât de mult se potrivește șablonul cu conținutul acelei regiuni (imagine comparată). Rezultă astfel imaginea de corelație $\text{Corr}(i,j)$ sau imaginea țintă, figura 2.4.5, (Jähne 2002) (Gonzalez 2004).

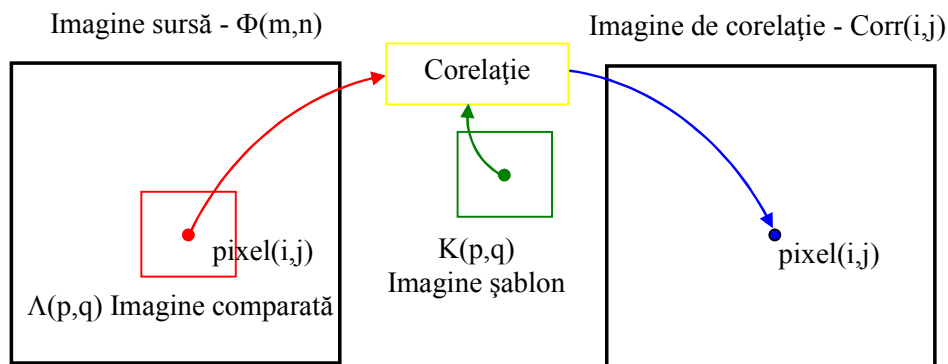


Figura 2.4.5: Principiile corelației imaginilor.

Coeficientul de corelație este o metrică care exprimă nivelul de potrivire dintre două imagini, adică între imaginea șablon și o regiune din imaginea sursă.

Pentru compararea imaginilor, este utilizat pe scară largă coeficientul de corelație normalizat (CCN) definit prin relația:

$$\text{Corr}(i,j) = \frac{\sum_{p=1}^P \sum_{q=1}^Q (K(p,q) - \bar{K}) \cdot (\Lambda(p,q) - \bar{\Lambda})}{\sqrt{\sum_{p=1}^P \sum_{q=1}^Q (K(p,q) - \bar{K})^2} \cdot \sqrt{\sum_{p=1}^P \sum_{q=1}^Q (\Lambda(p,q) - \bar{\Lambda})^2}}, \quad (2.4.3)$$

unde, $K(p,q)$ reprezintă imaginea șablon,

$\Lambda(p,q)$ reprezintă imaginea curentă, având coordonatele centrale (i,j) , comparată cu imaginea șablon,

\bar{K} este media nivelelor de gri din imaginea șablon, $\bar{\Lambda}$ este media nivelelor de gri din regiunea imaginii curente, având coordonatele centrale (i,j) .

În figura 2.4.6. este exemplificată determinarea imaginii de corelație prin utilizarea unor imagini sintetice, fără zgomot.




Figura 2.4.6: Exemplificarea determinării imaginii de corelație.

Coeficientul de corelație are valoarea $\text{Corr}(i,j)=1$ dacă cele două imagini comparate sunt absolut identice. Dacă imaginile comparate sunt complet necorelate, coeficientul de corelație are valoarea $\text{Corr}(i,j)=0$. Coeficientul de corelație are valoarea $\text{Corr}(i,j)=-1$ dacă imaginile comparate sunt complet anti-corelate, de exemplu, când o imagine este negativul celei de a doua.

Algoritm CNN de calcul al corelației dintre două imagini

În cazul procesării seriale, timpul de calcul pentru determinarea unui coeficient de corelație de coordonate (i,j) este dependent de dimensiunile imaginii șablon, crescând proporțional odată cu acesta. Pe de altă parte, este de dorit ca dimensiunile imaginii șablon să fie suficient de mari pentru a conține cât mai multe informații relevante. Prin utilizarea algoritmului CNN de procesare paralelă pentru calculul coeficientului de corelație între două imagini se poate reduce acest timp de calcul, respectiv acesta nu va crește proporțional odată cu creșterea dimensiunilor imaginii șablon (Tepelea et al. 2011).

În vederea elaborării algoritmului CNN de procesare paralelă pentru calcularea coeficienților de corelație între două imagini, relația 2.4.3 este rescrisă ca:

$$\text{Corr}(i,j) = \frac{(\bar{K}(p,q) - \bar{K}) \cdot (\bar{\Lambda}(p,q) - \bar{\Lambda})}{\sqrt{(\bar{K}(p,q) - \bar{K})^2} \cdot \sqrt{(\bar{\Lambda}(p,q) - \bar{\Lambda})^2}} \quad (2.4.4)$$

Se constată că la calcularea coeficienților de corelație dintre două imagini de aceeași mărime rezultă următoarele operații: mediere, adunare, scădere și înmulțire. În domeniul CNN, aceste operații sunt realizate prin procesare paralelă fără ca timpul de calcul să depindă de dimensiunile imaginilor. Singurele două operații care nu pot fi realizate în mod paralel, direct în domeniul CNN, sunt împărțirea și extragerea rădăcinii pătratice. Pentru efectuarea și a acestor operații în mod cvasi-paralel, în anumite medii de dezvoltare au fost deja elaborate

macroinstrucțiuni (algoritmi CNN), utilizând procesoare numerice de semnal (*DSP - Digital Signal Processor*).

Pentru anumite clase de aplicații, dacă se cunoaște domeniul de valori al coeficienților de corelație rezultați, relația 2.4.4 poate fi rescrisă în forma:

$$\text{Corr}^2(i,j) = \frac{\left[\overline{(\mathbf{K}(p,q) - \overline{\mathbf{K}}) \cdot (\Lambda(p,q) - \overline{\Lambda})} \right]^2}{\left(\overline{(\mathbf{K}(p,q) - \overline{\mathbf{K}})^2} \cdot \overline{(\Lambda(p,q) - \overline{\Lambda})^2} \right)} \quad (2.4.5)$$

Prin această transformare, operația de extragere a rădăcinii poate fi înlocuită cu înmulțirea a două imagini, procesare CNN care poate fi realizată în mod paralel. În acest caz trebuie avut în considerare că, vor rezulta valori pozitive mari ale coeficienților de corelație chiar și în situația în care cele două imagini sunt complet anti-corelate.

Analizând în continuare relația 2.4.5, algoritmul CNN propus pentru calcularea coeficienților de corelație trebuie să fie bazat pe următoarele observații:

- în domeniul CNN, calculul valorii medii a unei imagini poate fi realizat în mod paralel prin calcul ondulatoriu (*wave computing*) și rezultă o imagine având pixelii de valoare constantă, reprezentând chiar valoarea medie a imaginii inițiale; Pentru acest scop, există template-uri CNN care au același efect de netezire pe imaginile procesate. Pentru a testa algoritmul CNN propus în această lucrare, s-a utilizat template-ul *AINTPOL2* (Gacsádi and Szolgay 2001), caracterizat printr-o bună viteză de propagare a undei de mediere.
- pentru reducerea timpului de calcul necesar pentru obținerea coeficienților de corelație, în general, se are în vedere că, valoarea medie a imaginii șablon, $(\overline{\mathbf{K}})$, respectiv imaginea, $(\mathbf{K}(p,q) - \overline{\mathbf{K}})$, trebuie calculată doar o singură dată, fiind considerată deci o constantă cunoscută; în mod similar se poate calcula pentru fiecare poziție (i,j) , valoarea medie a imaginii comparate din imaginea sursă, $\overline{\Lambda}$, respectiv se poate calcula paralel imaginea diferență, $(\Lambda(p,q) - \overline{\Lambda})$. Se menționează că, în domeniul CNN, la adunarea respectiv, scăderea a două imagini, trebuie avut în vedere ca rezultatul acestor operații să nu conducă la suprasaturare, adică valorile de ieșire să rămână în domeniul standard CNN. De aceea, întotdeauna, înaintea unor astfel de operații imaginile de intrare sunt ponderate cu $\frac{1}{2}$. Ținând cont de această ponderare, nu se alterează nici valoarea coeficientului de corelație rezultat.
- înmulțirea a două imagini în domeniul CNN poate fi realizată efectiv paralel (de exemplu $(\mathbf{K}(p,q) - \overline{\mathbf{K}}) \cdot (\Lambda(p,q) - \overline{\Lambda})$); astfel, timpul de procesare este același indiferent de dimensiunile imaginilor; desigur că imaginile care sunt înmulțite pixel cu pixel trebuie să aibă aceleași dimensiuni. Utilizând template-ul *AINTPOL2*, calculul valorii medii a unei imagini este similar cu cazul $\overline{\mathbf{K}}$ sau $\overline{\Lambda}$, de exemplu, astfel se poate calcula $\overline{(\mathbf{K}(p,q) - \overline{\mathbf{K}}) \cdot (\Lambda(p,q) - \overline{\Lambda})}$ și $\overline{(\mathbf{K}(p,q) - \overline{\mathbf{K}})^2}$ și $\overline{(\Lambda(p,q) - \overline{\Lambda})^2}$.
- pentru ca în ansamblu algoritmul propus să fie implementat omogen în mediul CNN, există posibilitatea ca și operația de împărțire a imaginilor să fie realizată cvasi-paralel

CNN (având în vedere restricțiile menționate deja) și, astfel nu se va consuma timp cu trecerea dintr-un domeniu în altul.

Tot prin procesări paralele CNN efective se pot determina din imaginea de corelație valoarea maximă a coeficientul de corelație, sau coeficienții de corelație mai mari în raport cu o valoare de prag prestabilită.

Testarea algoritmului CNN pentru corelația imaginilor

Algoritmul CNN propus pentru obținerea coeficienților de corelație dintre două imagini a fost testat prin simulare software utilizând următoarele medii de simulare: *CadetWin* (**1999a), *InstantVision Integrated Software Environment* (** 2007) și *Matlab* (** Matlab).

Tipic, coeficientul de corelație este utilizat pentru a compara două imagini cu aceleași obiecte, scene sau cadre de imagine la momente diferite de timp (Țepelea et al. 2011).

Valorile ridicate ale coeficienților de corelație reprezintă o potrivire mai bună între cele două imagini (imaginea șablon și regiunile comparate din imaginea sursă). Pentru fiecare imagine se vor determina coeficientul cu valoarea maximă (sau coeficienții cu valori mai mari în raport cu o valoare de prag). Alegerea valorii de prag utilizată pentru comparație este dependentă de aplicație. În cazul aplicațiilor analizate, aceste valori sunt cuprinse adesea între 0,3 și 0,8. Pentru calcularea coeficienților de corelație este utilizată relația 2.4.5.

În continuare sunt prezentate rezultatele obținute prin simulare, utilizând imagini reale, care pot exista în cazul în care algoritmul CNN propus este inclus într-un sistem de asistare a persoanelor cu deficiențe de vedere (Tiponuț et al. 2006), (Țepelea et al. 2014). În exemplele următoare (figurile 2.4.7-2.4.9), pentru fiecare pereche de imagini sursă (a1, a2), s-a utilizat aceeași imagine șablon.




Figura 2.4.7: *Detecția indicatorului trecere de pietoni: (a1, a2) imagini sursă; (b) imagine șablon; (c1,c2) imagini de corelație.*

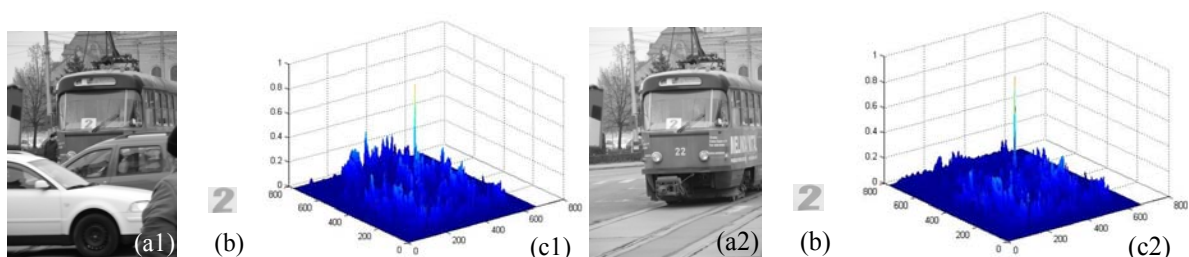


Figura 2.4.8: *Detecția numărului de tramvai: (a1, a2) imagini sursă; (b) imagine șablon; (c1,c2) imagini de corelație.*




Figura 2.4.9: *Deteția trecerii de pietoni: (a1, a2) imagini sursă; (b) imagine șablon; (c1,c2) imagini de corelație.*

În continuare, dacă în imaginea de corelație sunt câteva regiuni de interes caracterizate prin coeficienți de corelație care trec de pragul de sensibilitate, coeficienții de corelație pot fi recalculați în fiecare din aceste regiuni, printr-o procedură care să asigure o mai mare acuratețe. De asemenea, dezvoltarea unor algoritmi cu multiple praguri de condiționare poate ajuta la recunoașterea anumitor forme. Acuratețea recunoașterii unui șablon poate fi crescută numai după reducerea satisfăcătoare a timpului de procesare pentru o etapă.

Complexitatea situațiilor întâlnite în realitate, justifică dezvoltarea diversilor algoritmi existenți precum și elaborarea unor soluții noi. Creșterea eficienței unui algoritm, respectiv alegerea celui mai potrivit pentru o problemă concretă este o sarcină deosebit de dificilă.

2.4.3. Implementarea FPGA a algoritmului CNN pentru corelația imaginilor

Algoritmul CNN pentru calcularea coeficienților de corelație, prezentat mai sus, a fost implementat pe o platformă hardware de emulare digitală a CNN-UM utilizând FPGA (Kincses et al. 2012). Rezultatele obținute s-au analizat în scopul integrării acestui algoritm într-un sistem de asistare a persoanelor cu deficiențe de vedere. Astfel, au fost investigate și discutate aspectele esențiale ale aplicației privind viteza de procesare și aria suprafeței structurii FPGA utilizate.

În principiu, pentru implementarea efectivă FPGA a aplicației de determinare a coeficienților de corelație dintre două imagini există trei moduri de abordare: secvențială, semi-paralelă și complet paralelă (Bailey 2011).

În primul caz, coeficienții de corelație sunt calculați secvențial prin utilizarea unui element de procesare. Această metodă reprezintă cea mai lentă soluție, de aceea, nu poate fi folosită în cazul unei aplicații în timp real, deși are cea mai mică cerință privind suprafața FPGA.

În cazul metodei complet paralele, coeficienții de corelație sunt calculați cu un procesor paralel de tip matrice, bidimensională (Almudena 2007). Astfel, această soluție oferă cea mai mare viteză de procesare, dar aria suprafeței utilizate crește cu pătratul dimensiunii imaginii șablon. Prin urmare, această variantă poate fi aplicată numai în cazurile în care dimensiunile imaginii șablon sunt suficient de mici (de exemplu: între 12×12 pixeli și 20×20 pixeli). Principala limitare în acest mod de abordare este legată de numărul de blocuri DSP dedicate pentru multiplicare și acumulare (*MAC - Multiply-Accumulate*). Imaginile șablon cu

dimensiuni mari, precum 32×32 pixeli, trebuie să fie partiționate, rezultând astfel dezavantajul înmulțirii timpului de procesare cu numărul de partiții.

Pentru calculul coeficienților de corelație, pe baza relației 2.4.5, s-a propus și implementat cea de a treia variantă, respectiv soluția semi-paralelă (Kincses et al 2012), ca rezultat al unui bun compromis (optimizări) între abordarea secvențială și cea complet paralelă. Astfel, mai multe unități de prelucrare MAC, împreună cu elemente logice suplimentare, sunt aranjate liniar și ele pot calcula paralel coeficienții de corelație succesiv pe rânduri, linie după linie. Deși prin această metodă aria suprafeței structurii FPGA crește direct proporțional cu dimensiunile imaginii șablon, totuși pot fi procesate în timp real imagini șablon cu dimensiuni relativ mari (de exemplu: cu dimensiuni de 64×64 pixeli, 128×128 pixeli). Arhitectura generală a acestei soluții, prezentată în figura 2.4.10, include patru componente principale: unitatea de comandă a memoriei (*Memory Controller Unit*), unitatea nucleu de memorie (*Kernel Memory Unit*), unitatea de calcul a mediei (*Mean Calculator Unit*) și unitatea nucleu pentru corelație (*CCU - Correlator Core Unit*).

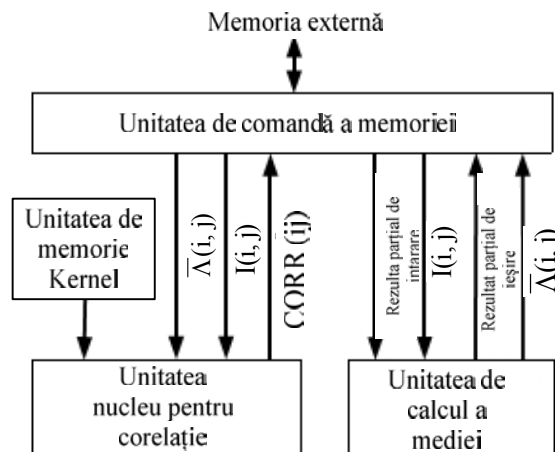


Figura 2.4.10: Arhitectura generală a sistemului.

Unitatea de comandă a memoriei reprezintă de fapt o interfață de transfer de date între memoria externă și unitatea de calcul a mediei și unitatea nucleu pentru corelație.

Unitatea nucleu pentru corelație este realizată din patru componente principale:

- unitatea registru bidimensional;
- unitatea scăzător și unitatea MAC;
- unitatea registru de deplasare;
- unitatea pentru rezultatul final.

Caracteristicile unității nucleu pentru corelație a fost investigată sub două aspecte principale: aria suprafeței necesare, atât pentru elementele dedicate cât și pentru elementele logice, precum și performanțele realizabile privind capacitatea de calcul.

În scopul implementării și verificării procedurii, a fost utilizat mediul de programare *Xilinx ISE Design Suite version 13.4* (***) (2012). Aria suprafeței necesare și performanțele arhitecturii propuse au fost analizate în mediul de dezvoltare integrat software ISE (*Integrated Software Environment*). Pentru structura din familia *FPGA Xilinx Seria-7* (***) (2012), au fost stabilite condițiile inițiale privind cerințele de suprafață, în cazul în care este utilizată o

imagine sursă de intrare gray-scale pe 8biți, având dimensiunile de 511×511 pixeli, respectiv imaginea șablon având dimensiunile cuprinse între 4×4 și 128×128 pixeli.

Trebuie semnalat că toate unitățile MAC pot fi utilizate eficient pentru efectuarea calculelor numai dacă dimensiunile imaginii sursă sunt în concordanță cu dimensiunile imaginii șablon. De asemenea, dimensiunile imaginii șablon sunt setate la valori de puteri a lui doi, și astfel operația de împărțire pentru calculul valorii medii poate fi înlocuită cu o simplă operație de translație. Cerințele privind resursele generale din unitatea nucleu pentru corelație (de exemplu, *Logic Slices*, *Flip-flops* and *6-input Look-Up-Tables*) cresc direct proporțional cu dimensiunile imaginii șablon, figura 2.4.11.




Figura 2.4.11: Cerințele privind resursele generale din unitatea nucleu pentru corelație.

Au fost evaluate și cerințele privind unele resurse dedicate ale unității nucleu pentru corelație (CCU). Numărul secțiunilor dedicate DSP48E1 crește direct proporțional cu dimensiunile imaginii șablon, după cum se poate observa în figura 2.4.12.

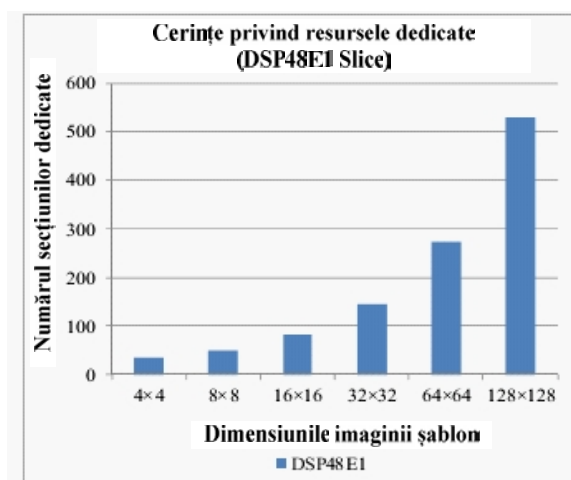


Figura 2.4.12: Cerințele privind resursele dedicate din unitatea nucleu pentru corelație.

O operație de tip MAC pentru o imagine șablon de dimensiuni 4×4 pixeli necesită cel puțin 8 multiplicatori din unitatea MAC. De asemenea, independent de dimensiunile imaginii șablon, pentru a calcula în final rezultatul corelației sunt necesari minim 18 multiplicatori DSP. În timpul testelor de sinteză au fost investigate nu numai cerințele resurselor totale privind întreaga unitate nucleu pentru corelație, dar au fost verificate și submodulele sale interne.

Unitatea nucleu pentru corelație, construită din patru componente principale, are o structură modulară, în funcție de modul descrierii VHDL (*VHDL - Very High Speed Integrated Circuit Hardware Description Language*). Cerințele privind resursele generale și specifice ale unității pentru rezultatul final sunt în esență independente de dimensiunile imaginii șablon. În consecință, sunt prezentate numai cerințele privind resursele celorlalte trei părți rămase, de mai mare interes: unitatea registru bidimensional, unitatea scăzător și unitatea MAC, respectiv, unitatea registru de deplasare, figura 2.4.13.




Figura 2.4.13: Cerințele privind resursele unor unități din CCU: a) resursele necesare pentru scăzător și MAC; b) resursele necesare pentru registrul bidimensional; c) resursele necesare pentru registrul de deplasare.

Analizând cerințele suprafețelor solicitate de aceste unități în raport cu imaginile șablon de diferite dimensiuni, rezultă dependențe direct proporționale pentru fiecare unitate în parte, similar cu cerințele privind resursele globale. Unitatea registru de deplasare are cea mai mare cerință de resurse din cauza lungimii datelor, figura 2.4.13c.

După analizarea cerințelor privind resursele necesare pentru CCU, au fost investigate performanțele sale maxime privind capacitatea de calcul. Rezultatele obținute au arătat că frecvența de tact a unității este doar ușor dependentă de dimensiunile imaginii șablon. În consecință, în orice situație, practic poate fi atinsă frecvența de tact de 300 MHz.

Aceste rezultate obținute (Kincses et al. 2012) au fost apoi comparate cu o implementare complet paralelă (Almudena et al. 2007). Comparația s-a făcut pentru o imagine sursă având dimensiunile de 511×511 pixeli și o imagine șablon având dimensiunile 64×64 pixeli. În cazul implementării semi-paralele propuse de (Kincses et al. 2012), timpul de procesare necesar este de aproximativ 57 ms, în timp ce în cazul arhitecturii complet paralele (Almudena 2007) timpul de procesare este de 0.652 ms. Pe de altă parte, soluția semi-paralelă consumă doar 274 secțiuni DSP MAC, în timp ce în cazul implementării complet paralele sunt necesare de 14 ori mai multe blocuri MAC dedicate.

3. Planuri de evoluție și dezvoltare a carierei academice, științifice și profesionale

Este binecunoscut faptul că activitățile științifice, profesionale și academice ale cadrelor didactice universitare sunt într-o susținere reciprocă. În același timp fiecare dintre aceste activități au specificitatea lor, de aceea consider că este foarte importantă creșterea eficienței, îmbunătățirea simultană și echilibrată a fiecăreia dintre ele.

Activitatea didactică și profesională

Pentru toate disciplinele la care desfășor activități didactice sunt asigurate suporturile de studiu adecvate (cărți, îndrumătoare de laborator, note de curs, prezentări, etc.) accesibile și în format electronic de pe pagina web personală. Aceste materiale didactice vor fi adaptate și actualizate periodic și în viitor, în conformitate cu standardele actuale și cerințele companiilor angajatoare. În concordanță cu conceptul de ”învățământ centrat pe student”, în continuare voi utiliza și metode moderne de predare și evaluare a cunoștințelor (prezentări și discuții interactive, teste grilă), iar la activitatea de laborator vom utiliza deopotrivă metode de analiză bazate pe simulare și experimente practice respectiv, cu extinderea acestora și în varianta *e-laboratory* (realizată deja într-o variantă prototip în cadrul unui proiect).

În vederea îndeplinirii acestor obiective este nevoie de studiu continuu, de actualizarea cunoștințelor de specialitate și didactice. În acest sens contribuții însemnate au și participările la conferințe, workshop-uri, schimburi de experiențe la universități partenere din țară și din străinătate, prin mobilități Erasmus+. La îmbunătățirea nivelului de dotare al laboratorului, unde se desfășoară activități de cercetare și mai multe activități didactice, avem în vedere și posibile achiziții de echipamente și tehnică de calcul prin participări la competiții și obținerea de finanțări prin granturi/proiecte de cercetare naționale și internaționale.

După 24 de ani de activitate didactică și de cercetare, în care am coordonat numeroase lucrări de diplomă și de disertație, în care am atras studenți în activitățile de proiectare și cercetare, obiectivul meu personal este de a coordona și activități de doctorat. An de an, unii dintre cei mai buni absolvenți de masterat și-au manifestat dorința de a continua studiile prin doctorat în domeniul electronică, telecomunicații și tehnologii informaționale. Astfel, există posibilitatea închiderii unui ciclu complet al studiilor de la licență, masterat și până la doctorat.

Asigurarea studiilor de doctorat și în alte domenii, față de cele existente în prezent în cadrul Universității din Oradea, poate contribui la extinderea domeniilor de activitate ale unor companii străine cu filiale locale, de la nivelul de producție la nivelul de proiectare și cercetare, beneficiind de personal înalt calificat. În acest sens, consider că dacă în tezele de doctorat vom aborda subiecte prin care se vor soluționa și probleme concrete ale acestor firme colaborarea poate deveni mai avantajoasă pentru ambele părți.

În vederea creșterii eficienței, activității de proiectare și cercetare, temele proiectelor de diplomă, de disertație și de doctorat pot fi corelate, în același timp, vor rezulta și alte beneficii ale activităților în echipe de studenți din mai multe generații.

Activitatea de cercetare

Temele și subiectele de cercetare alese a fi abordate în viitor vor fi corelate, armonizate cu provocările științifice, cu cerințele ”pieței”, competențele existente și capacitățile tehnice disponibile.

Fără a exclude cercetarea fundamentală, în viitor, îmi propun ca activitățile de cercetare să se desfășoare sub deviza ”sisteme electronice aplicate” și acolo unde este posibil să se finalizeze cu prototip.

Direcția principală de cercetare va constitui elaborarea unor metode de analiză și prelucrare a semnalelor biomedicale și implementarea lor efectivă într-un sistem de asistare în timp real a diagnozei medicale și/sau la urmărirea tratamentului. Obiectivul general al acestei direcții de cercetare, care vizează îmbunătățirea actului medical, este realizabil numai în condițiile existenței dialogului și colaborării interdisciplinare eficiente și permanente a specialiștilor din toate domeniile de știință implicate.

Datorită diversității și dificultății problemelor existente la ora actuală, atât din punct de vedere teoretic cât și cel al modului de implementare, dezvoltarea unor echipamente tot mai performante de imagistică medicală, este o necesitate continuă. În acest sens, o metodă poate fi benefică, chiar și atunci când este mai puțin performantă din punct de vedere teoretic, dar care oferă rezultate în timp real și poate fi utilizată în interesul pacientului în practica medicală de zi cu zi. Vom continua investigarea unor imagini CT (cu atenția focalizată pe metastaze hepatice) și imagini mamografice.

Este binecunoscut faptul că, în orice aplicație, modalitatea de procesare a semnalelor este rezultatul unei optimizări, care ține cont de cel puțin două aspecte, precizia prelucrării și timpul de prelucrare. Pe baza experienței dobândite în acest domeniu, vom aborda și soluțiile oferite de utilizarea rețelele neuronale/nelineare celulare pentru realizarea în timp real a unor aplicații în domeniul prelucrării semnalelor, pentru care se justifică acesta. Pentru creșterea eficienței implementării CNN a acestor metode vom avea în vedere structuri hardware optimizate și dedicate pentru aplicația concretă, bazată pe arhitectura emulatorului digital CNN-UM implementat pe o platformă FPGA. Alături de alte variante de prelucrare a semnalelor, *cellular wave computing* poate reprezenta o soluție complementară.

O altă direcție de cercetare către care ne vom menține atenția este domeniul inteligenței artificiale. Ca mijloc eficient de validare practică, rezultatele obținute vor fi implementate în conducerea adaptivă a roboților, respectiv în sisteme pentru asistarea persoanelor cu deficiențe de vedere.

Având în vedere dificultățile existente în finanțarea cercetării, participarea la competiții pentru granturi/proiecte naționale și internaționale reprezintă o importanță deosebită pentru obținerea de fonduri necesare la continuarea cercetărilor. În acest sens, prezintă o provocare

serioasă a identifica cea mai potrivită modalitate de colaborare și cu filialele locale ale unor companii de profil.

În scopul atingerii acestor obiective, am în vedere inițierea de noi colaborări și dezvoltarea în continuare a celor existente, cu colective de cercetare din cadrul unor universități din țară (Timișoara, Cluj-Napoca, București, Iași, etc.) și străinătate (Budapesta, Debrecen, Lyon, Kosice, etc.). Astfel, se va putea asigura concentrarea resurselor și a competențelor existente în diferite universități și centre de cercetare în vederea obținerii rezultatelor dorite.

Pentru creșterea eficienței diseminării rezultatelor obținute în urma activităților de cercetare, va trebui să acord o atenție sporită pentru publicarea de articole, în primul rând, în reviste ISI, dar și în volumele unor conferințe internaționale de prestigiu. Tot pentru creșterea vizibilității activităților de cercetare și didactice îmi propun să mă implic mai activ în cadrul colectivelor de redacție/comitete științifice ale unor reviste și conferințe internaționale, inclusiv în revistele facultății noastre.

În cele de mai sus, am formulat succint, planul meu personal de evoluție și dezvoltare a carierei academice, științifice și profesionale, pe termen scurt și mediu.

În final, aș menționa că doresc să-mi mențin deschiderea, libertatea de a aborda și alte subiecte de cercetare provocatoare, care în prezent nu le-am avut în vedere. În privința asigurării depline a finanțării cercetării și a condițiilor materiale pot avea cel mult un optimism limitat, dar sunt convins că vom putea recruta echipă potrivită pentru fiecare dintre aceste provocări.

Bibliografie

(Adamatzky et al. 2004) A. Adamatzky, P. Arena, A. Basile, R. Carmona-Galan, B. De Lacy Costello, L. Fortuna, M. Frasca and A. Rodriguez-Vazquez, *Reaction-Diffusion Navigation Robot Control: From Chemical to VLSI Analogic Processors*, IEEE Transaction on Circuits and Systems – I: Regular Papers, Vol. 51, No. 5, pp. 926-938, May, 2004.

(Aggarwall and Nandhakumar 1988) J.K. Aggarwall, N. Nandhakumar, *On the Computation of Motion from Sequences of Images - A review*, Proceedings of IEEE, Vol.76, No.8, pp. 917-935, 1988.

(Aizenberg et al. 2001) I. Aizenberg, N. Aizenberg, J. Hiltner, C. Moraga, E. Meyer zu Bexten, *Cellular Neural Networks and Computational Intelligence in Medical Image Processing*, Image and Vision Computing 19, pp.177–183, 2001.

(Almudena et al. 2007) L. Almudena, E. Luis, *High performance FPGA-based image correlation*, Journal Real-Time Image Proc., Vol. 2, Special Issue, Springer, pp. 223-233, 2007.

(Analoui 2001) M. Analoui, *Radiographic digital image enhancement. Part II: transform domain techniques*, Dentomax. Radiol. 30, pp.65–77, 2001.

(Angenent et al. 2006) S. Angenent, E. Pichon, A.Tannenbaum, *Mathematical Methods in Medical Image Processing*, Bulletin of the American Mathematical Society, Vol. 43, pp.365-396, 2006.

(Arena et al. 2005) P. Arena, L. Fortuna, M. Frasca, G. Vagliasindi, M. E. Yalcin, A. Basile, J.A.K. Suykens, *CNN Wave Based Computation for Robot Navigation on ACE16k*, IEEE International Symposium on Circuits and Systems, pp. 5818-5821, 2005.

(Baatar et al. 2010) C. Baatar, W. Porod, T. Roska, (Eds.), *Cellular Nanoscale Sensory Wave Computing*, Publisher Springer US, 2010.

(Bailey 2011) D. G. Bailey, *Design for Embedded Image Processing on FPGAs*, John Wiley & Sons (Asia) Pte Ltd, Singapore, 2011.

(Balch and Arkin 1998) T. Balch, R. C. Arkin, *Behavior-Based Formation Control for Multirobot Teams*, IEEE Transactions on Robotics and Automation, Vol. 14, No. 6, pp.926-939, 1998.

(Ballester et al. 2001) C. Ballester, M. Bertalmio, V. Caselles, G. Sapiro, and J.Verdera, *Filling-in by joint interpolation of vector fields and gray levels*, IEEE Transaction on Image Processing, 10(1), pp. 1200-1211, 2001.

(Barron et al. 1994) J.L. Barron, D.J. Fleet, S. Beauchemin, *Performance of Optical Flow Techniques*, International Journal of Computer Vision, 12:1, pp. 43-77, 1994.

(Bertalmio et al. 2000) M. Bertalmio, G. Sapiro, V. Caselles, and C. Ballester, *Image inpainting*, Computer Graphics, pp. 417–424, 2000.

(Bertalmio et al. 2001) M. Bertalmio, A. Bertozzi, G. Sapiro, Navier–Stokes, *Fluid Dynamics, and Image and Video Inpainting*, Proceedings of the 2001 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, pp. 1355-1362, Hawaii, 2001.

(Bozek et al. 2009) J. Bozek, M. Mustra, K. Delac, M. Grgic, in: M. Grgic, K. Delac, M. Ghanbari (Eds.), *A Survey of Image Processing Algorithms in Digital Mammography Recent Advances in Multimedia Signal Processing and Communications*, Springer- Verlag, Heidelberg, pp. 631-657, 2009.

(Brendel and Roska 2002) M. Brendel and T. Roska, *Adaptive image sensing and enhancement using the cellular neural network universal machine*, International Journal of Circuit Theory and Applications, Vol. 30, Issue 2-3, pp.287–312, 2002.

(Bruhn et al. 2003) Bruhn A., Weickert J., Feddern C., Kohlberger T., Schnorr C., *Real-time optic flow computation with variational methods*, Computer Analysis of Images and Patterns, pp.222-229, 2003.

(Buciu and Gacsádi 2009) I. Buciu, A. Gacsádi, *Gabor Wavelet Based Features for Medical Image Analysis and Classification*, IEEE International Symposium on Applied Sciences in Biomedical and Communication Technologies, Bratislava, Slovakia, pp. 8-11, 2009.

(Buciu and Gacsádi 2011) I. Buciu, A. Gacsádi, *Directional features for automatic tumor classification of mammogram images*, Biomedical Signal Processing and Control Volume 6, Issue 4, pp.370-378, 2011.

(Budaes et al. 2005), A. Budaes, B. Coll and J.M. Morel, *A Review of Image Denoising Algorithms, With a New One*, Multiscale Model. Simul. Society for Industrial and Applied Mathematics, Vol. 4, No. 2, pp. 490–530, 2005.

(Casellas et al. 1998) V. Casellas, J.M. Morel, G. Sapiro, A. Tannenbaum, *Introduction to the special issue on partial differential equations and geometry-driven diffusion in image processing and analysis*, IEEE Trans. on Image Processing, Vol. 7, pp. 269-273, 1998.

(Cembrano et al. 2003) G. L. Cembrano, A. Rodríguez-Vázquez, S. Espejo-Meana, R. Domínguez-Castro, *ACE16k: A 128x128 Focal Plane Analog Processor with Digital I/O*, International Journal Neural Systems, 13(6), pp.427-434, 2003.

(Chan and Shen 2001) T. Chan, J. Shen, *Mathematical Models for Local Nontexture Inpaintings*, SIAM Journal of Applied Mathematics, 62(3), pages 1019–1043, 2001.

(Chan et al. 2003) T.F. Chan, J. Shen and L. Vese, *Variational PDE Models in Image Processing*, Notices of the Amer. Math. Soc. Vol. 50, No. 1, pp.14-26, 2003.

(Chan and Esedoglu 2005) T.F. Chan and S. Esedoglu, *Aspects of total variation regularized L1 function approximation*, SIAM Journal of Applied Mathematics, 65(5), pp.1817–1837, 2005.

(Chua and Yang 1988) L.O. Chua, L. Yang, *Cellular Neural Networks: Theory and Applications*, IEEE Trans. on Circuits and Systems Vol.35, pp.1257-1290, 1988.

(Csapodi and Roska 1996) M. Csapodi, T. Roska, *Adaptive histogram equalization with cellular neural network*, Proceedings of IEEE International Workshop on Cellular Neural Networks and their Applications, pp.81-86, 1996.

(David et al. 1997) David C. Brogan, Jessica K. Hodgins, *Group Behaviors for Systems with Significant Dynamics*, Kluwer Academic Publishers, Autonomous Robots, Nr. 4, pp.137-153, 1997.

(Dogaru et al. 2013) R. Dogaru, I. Dogaru, A. Gacsádi, I. Gavriluț, *Structura și dinamica rețelelor dinamice complexe. Rețele neliniare celulare*, Editura Matrixrom, 174pag., 2013.

(Dowling et al. 2003) J. Dowling, A. Maeder, W. Boles, *Intelligent Image Processing Constraints for Blind Mobility Facilitated through Artificial Vision*, The Eight Australian and New Zealand Intelligent Information Systems Conference, pp. 109-114, 2003.

(Dudek and Vilariño 2006) P. Dudek, D.L. Vilariño, *A Cellular Active Contours Algorithm Based on Region Evolution*, Proceedings of the International Workshop on Cellular Neural Networks and Their Applications, Istanbul, Turkey, pp.1-6, 2006.

(Fredslund and Mataric 2002) J. Fredslund, M. J. Mataric, *A General Algorithm for Robot Formations Using Local Sensing and Minimal Communication*, IEEE Transaction on Robotics and Automation, Vol. 18, No. 5, pp. 837-846, 2002.

(Gacsádi and Szolgay 2001) A. Gacsádi, P. Szolgay, *Interpolation of 2D signals using CNN*, Proceedings of the European Conference on Circuit Theory and Design, pp. I 349-352, Espoo, 2001.

(Gacsádi and Típonuț 2002) A. Gacsádi, V. Típonuț, *Rețele neuronale celulare. Aplicații*, Editura Universitatii din Oradea, 189 pag., 2002.

(Gacsádi et al. 2002) A. Gacsádi, T. Maghiar, V. Típonuț, *Path planning for a mobile robot in an environment with obstacles*, Proceedings of the International Workshop on Cellular Neural Networks and their Applications, Frankfurt/Main, Germany, pp. 188-194, 2002.

(Gacsádi and Szolgay 2003) A. Gacsádi, P. Szolgay, *Adaptive image enhancement by using cellular neural networks*, Proceedings of the European Conference on Circuit Theory and Design, Cracow, Poland, Vol. I, pp. 233-236, 2003.

(Gacsádi et al. 2004) A. Gacsádi, C. Grava, C. Gordan, T. Maghiar, A. Grava, R. Reiz, *Inter-Slice Interpolation based on Matching Information using Cellular Neural Networks*, Proceedings of the IEEE International Workshop on Cellular Neural Networks and their Applications, pp. 417-422, Budapest, Hungary; 2004.

(Gacsádi and Szolgay 2005) A. Gacsádi, P. Szolgay, *Image mage inpainting methods by using cellular neural networks*, Proceedings of the IEEE International Workshop on Cellular Neural Networks and their Applications pp. 198-201, Hsinchu, Taiwan, 2005.

(Gacsádi et al. 2005) A. Gacsádi, C. Grava, A. Grava, *Medical image enhancement by using cellular neural networks*, Proceedings of the IEEE International. Workshop on Computing in Cardiology, pp.821-824, Lyon, France, 2005.

(Gacsádi et al. 2006a) Gacsádi A., Grava C., Tiponuş V., Szolgay P., *A CNN implementation of the Horn & Schunck motion estimation method*, Proceedings of the 10th International Workshop on Cellular Neural Networks and Their Applications, pp. 381-385, Istanbul, Turkey, 2006.

(Gacsádi et al. 2006b) A. Gacsádi, V. Tiponuş, P. Szolgay, *Image-Based Visual Servo Control of a Robotic Arm by Using Cellular Neural Networks*, Proceedings of the International Workshop on Robotics in Alpe-Adria-Danube Region, Balatonfüred, Hungary, 2006.

(Gacsádi et al. 2007), *Utilizarea tehnologiei reţelelor neuronale celulare pentru navigaţia roboţilor mobili autonomi*, Raport de Cercetare, Grant CNCISIS A/ 473, 2006-2007.

(Gacsádi and Szolgay 2009) A. Gacsádi, P. Szolgay, *Variational Computing Based Images Denoising Methods by using Cellular Neural Networks*, Proceedings of the European Conf. on Circuit Theory and Design, Antalya, Turkey, pp.85-88, 2009.

(Gacsádi et al. 2009) A. Gacsádi, C. Grava, O. Straciuc, I. Gavriluş, *PDE-Based Medical Images Denoising Using Cellular Neural Networks*, IEEE Proceedings of the International Symposium on Signals Circuits and Systems, Vol. 2, Iaşi, România, pp.397-400, 2009.

(Gacsádi and Szolgay 2010) A. Gacsádi, P. Szolgay, *Variational Computing Based Segmentation Methods for Medical Imaging by using CNN*, Proceedings of the IEEE CNNA International Workshop on Cellular Neural Nanoscale and their Applications, pp.418-423, Berkeley, California, USA, 2010.

(Gacsádi et al. 2009-2011), *Dezvoltarea unor metode de prelucrare şi analiză a imaginilor computer tomografice utilizând reţele neuronale celulare şi integrarea acestora într-un sistem de asistare a diagnozei medicale*, PN II - IDEI - Proiect de Cercetare Exploratorie, ID- 668/2008, Raport de Cercetare, 2009-2011.

(Gacsádi 2010) A. Gacsádi, *Variational Computing Based Image Inpainting Methods by Using Cellular Neural Networks*, Proceedings of the WSEAS International Conference on Automation & Information pp.104-109, Iaşi, Romania, 2010.

(Gacsádi et al. 2011) A. Gacsádi, L. Ţepelea, I. Gavriluş, O. Straciuc, *Energy Based Medical Imaging Segmentation Methods by using Cellular Neural Networks*, Proceedings of the WSEAS International Conference on Systems, Recent Researches in System Science, Corfu Island, Greece, pp.190-195, 2011.

(Gavriluş et al. 2005) I. Gavriluş, A. Gacsádi, L. Ţepelea, V. Tiponuş, *Motion planning for two mobile robots in an environment with obstacles by using cellular neural networks*, Proceedings of the IEEE International Symposium on Signals, Circuits and Systems, Iaşi, Romania, pp. 801-804, 2005.

(Gavriluş et al. 2006a) I. Gavriluş, A. Gacsádi, C. Grava, V. Tiponuş, *Vision based algorithm for path planning of a mobile robot by using cellular neural networks*, Proceedings of the International Conference on Automation, Quality&Testing, Robotics, Cluj-Napoca, Romania, pp. 306-311, 2006.

(Gavriliuț et al. 2006b) I. Gavriliuț, V. Tiponuț, A. Gacsádi, *Path Planning of Mobile Robots by Using Cellular Neural Networks*, Proceedings of the International Workshop on Cellular Neural Networks and Their Applications, Istanbul, Turkey, pp. 108-113, 2006.

(Gavriliuț et al. 2007a) I. Gavriliuț, V. Tiponuț, A. Gacsádi, C. Grava, *CNN Processing Techniques for Multi-robot Coordination*, Proceedings of International Symposium on Signals, Circuits and Systems, Vol. 1, Iași, Romania, pp.269-272, 2007.

(Gavriliuț et al. 2007b) I. Gavriliuț, V. Tiponuț, A. Gacsádi, *An Integrated Environment for Mobile Robot Navigation based on CNN Images Processing*, Proceedings of the WSEAS International Conference on Systems, Agios Nikolaos, Crete Island, Greece, pp. 81-86, 2007.

(Gavriliuț et al. 2009) I. Gavriliuț, V. Tiponuț, A. Gacsádi, *Mobile Robot Navigation based on CNN Images Processing – An Experimental Setup*, Proceedings of the WSEAS International Conference on Systems, Rodos Island, Greece, pp. 220-225, 2009.

(Goebel et al. 2005) P.M. Goebel, A.N. Belbachir, M. Truppe, *Noise estimation in panoramic x-rays images: an application analysis approach*, Proceedings of the 13th IEEE Workshop on Statistical Signal Processing, pp. 996-1001, 2005.

(Gonzalez and Woods 1993) R.C. Gonzalez, R.E. Woods, *Digital image processing*, Addison-Wesley Publishing Company, 1993.

(Gonzalez 2004) R. C. Gonzalez, R. E. Woods and S. L. Eddins, *Digital Image Processing using MATLAB*, Pearson Education, 2004.

(Goshtasby et al. 1992) A. Goshtasby, D.A. Turner, L.V. Ackerman, *Matching of Tomographic Slices for Interpolation*, IEEE Transaction on Medical Imaging, Vol.11, No 4, pp.507-516, 1992.

(Grava et al. 2003) Grava C., Gacsádi A., Gordan C., Maghiar T., Bondor K., *Motion Compensation using Cellular Neural Networks*, Proceedings of the European Conference on Circuit Theory and Design, Volume I, pp. I-397-I-400, Krakow, Poland, 2003.

(Grava et al. 2007) C. Grava, A. Gacsádi, C. Gordan, A. M. Grava, I. Gavriliuț, *Applications of the Iterated Conditional Modes Algorithm for Motion Estimation in Medical Image Sequences*, Proceedings of the IEEE International Symposium on Signals, Circuits and Systems, Iași, Romania, Vol. 1, pp. 373-376, 2007.

(Grava et al. 2010) C. Grava, A. Gacsádi, I. Buciu, *A Homogeneous Algorithm for Motion Estimation and Compensation by Using Cellular Neural Networks*, Intern. Journal. of Computers, Communications & Control, Vol. V, No. 5, pp.719-726, 2010.

(Grigorescu et al. 2002) S.E. Grigorescu, N. Petkov, P. Kruizinga, *Comparison of Texture Features Based on Gabor Filters*, IEEE Trans. on Image Processing 11 (10) pp.1160-1167, 2002.

(Helal et al. 2001) A. Helal, S. Moore, B. Ramachandran, *Drishti: An Integrated Navigation System for Visually Impaired and Disabled*, International Symposium on Wearable Computers, pp. 149-156, 2001.

(Han and Ma 2007) J. Han, K.-K. Ma, *Rotation-invariant and Scale-invariant Gabor Features for Texture Image Retrieval*, Image and Vision Computing 25 (9), pp.1474–1481 2007.

(Hillier et al. 2006) D. Hillier, V. Binzberger, D. L. Vilariño, Cs. Rekeczky, *Topographic cellular active contour techniques: theory, implementations and comparisons*, Intern. Journal of Circuit Theory and Applications, Vol. 34, Issue 2, pp.183-216, 2006.

(Horn and Schunck 1981) B.K.P. Horn, B.G. Schunck, *Determining Optical Flow*, Artificial Intelligence 17, pp. 185-203, 1981.

(Hutchinson et al. 1996) S. Hutchinson, G.D. Hager, P.I. Corke, *A tutorial on visual servo control*, IEEE Transactions on Robotics and Automation, Vol. 12, pp. 651-670, 1996.

(Islam et al. 2010) M.J. Islam, M. Ahmadi, M.A. Sid-Ahmed, *An Efficient Automatic Mass Classification Method In Digitized Mammograms Using Artificial Neural Network*, International Journal of Artificial Intelligence & Applications 1 (3) pp.1–13, 2010.

(Jähne 2002) B. Jähne, *Digital image processing*, Heidelberg, Springer-Verlag, Berlin, 2002.

(Karacs et al. 2008) K. Karacs, A. Lazar, R. Wagner, B. Balint, T. Roska, M. Szuhaj, *Bionic eyeglass: The first prototype A personal navigation device for visually impaired - A review*, International Symposium on Applied Sciences on Biomedical and Communication Technologies, Aalborg, pp. 1-5, 2008.

(Kincses et al. 2011) Z. Kincses, L.Orzó, Z. Nagy, G. Mező and P. Szolgay, *High-Speed, SAD Based Wavefront Sensor Architecture Implementation on FPGA*, Journal of Signal Processing Systems, Springer, New York, Vol. 64, Issue 3, pp. 279-290, 2011.

(Kincses et al. 2012) Z. Kincses, Zs. Vörösházi, Z. Nagy, P. Szolgay, T. Laviniu, A. Gacsádi, *Investigation of area and speed trade-offs in FPGA implementation of an image correlation algorithm*, Proceedings of the International Workshop on Cellular Nanoscale Networks and their Applications, Turin, Italy, pp.1-5, 2012.

(Konrad 2000) J. Konrad, *Motion detection and estimation*, Image Processing HandBook, Networking and Multimedia, pp. 207-227, 2000.

(Kube and Zhang 1997) C. R. Kube, H. Zhang, *Task modelling in collective robotics*, Kluwer Academic Publishers, Autonomous Robots, No. 4, pp. 53-72, Manufactured in The Netherlands, 1997.

(Lee 1996) T. Lee, *Image Representation using 2d Gabor Wavelets*, IEEE Trans. Pattern Analysis and Machine Intelligence, Vol.18 (10), pp.959–971, 1996.

(Linan et al. 1999) G. Linan, S. Espejo, R. Dominguez-Castro, E. Roca, A. Rodriguez-Vazquez, *CNNUM3: A mixed-signal 64×64 CNN Universal Chip*, Proceedings of International Conference on Microelectronics for Neural, Fuzzy and Bio-inspired Systems, pp.61-68, 1999.

(Mondada et al. 2003) F. Mondada, A. Guignard, M. Bonani, D. Floreano D. Bär, M. Lauria, *SWARM-BOT: From Concept to Implementation*, IEEE/RSJ International Conference on Intelligent Robot and Systems, pp.1626-1631, 2003.

(Morel and Solimini 1995) J. Morel and S. Solimini, *Variational Methods in Image Segmentation*, Vol. 14 of Progress in Nonlinear Differential Equations and their Applications, Birkhauser, 1995.

(Mumford and Shah 1985) D. Mumford, J. Shah, *Boundary detection by minimizing functionals*, Proceedings of IEEE Conference on Computer Vision and Pattern Recognition pp.22-26, 1985.

(Mumford and Shah 1989) D. Mumford, J. Shah, *Optimal approximations by piecewise smooth functions and associated variational problems*, Comm. Pure Applied. Math., Vol. 17, pp.577–685, 1989.

(Murat 1997) T.A. Murat, *Digital Video Processing*, Prentice Hall PTR, Upper Saddle River, NJ 07458, Prentice Hall Signal Processing series, 1997.

(Nagy et al. 2006) Z. Nagy, Zs. Vörösházi, P. Szolgay, *Emulated Digital CNN-UM Solution of Partial Differential Equations*, Intern. Journal of Circuit Theory and Applications Vol. 34, Issue 4, pp.445-470, 2006.

(Oliveira et al. 2001) M.M. Oliveira, B. Bowen, R. McKenna, Y.S. Chang, *Fast Digital image inpainting*, Proceedings of the International Conference on Visualization, Imaging and Image Processing, pp. 261-266, Marbella, 2001.

(Perona and Malik 1990), P. Perona and J. Malik, *Scale Space and Edge Detection Using Anisotropic Diffusion*, IEEE Trans. Pattern Analysis and Machine Intelligence, Vol. 12, pp.629-639, 1990.

(Perona and Tartagni 1994) P. Perona, T. Tartagni, *Diffusion networks for on-chip image contrast normalization*, Proceedings of IEEE International Conference on Image Processing, pp.1-5, 1994.

(Pham et al. 2000) D. L. Pham, C. Xu, J. L. Prince, *A Survey of Current Methods in Medical Image Segmentation*, Annual Review of Biomedical Engineering, Vol. 2, pp.315-338, 2000.

(Rekeczky 1997) C. Rekeczky, *MATCNN - Analogic Simulation Toolbox for Matlab*, Version 1.0, Analogical and Neural Computing Laboratory, Computer and Automation Institute of the Hungarian Academy of Sciences, Budapest, 1997.

(Rekeczky et al. 1998) Cs. Rekeczky, T. Roska, A. Ushida: *CNN-based difference-controlled adaptive on non-linear image filters*, Int. Journal of Circuit Theory and Applications, Vol. 26, pp.375-423, 1998.

(Rekeczky and Chua 1999) Cs. Rekeczky and L.O. Chua, *Computing with Front Propagation: Active Contour and Skeleton Models in Continuous-Time CNN*, Journal of VLSI Signal Processing Systems, 23(2/3), pp.373-402, 1999.

(Rekeczky et al. 2000) Cs. Rekecyky, T. Serrano-Gotarredona, T. Roska, Á. Rodríguez-Vázquez, *A stored program 2nd order/ 3-layer complex cell CNN-UM*, Proceedings of IEEE International Workshop on Cellular Neural Networks and their Applications, pp.213-217, Catania, 2000.

(Rekeczky and Roska 2001) Cs. Rekeczky, T. Roska, *Calculating local and global PDEs by analogic diffusion and wave algorithms*, Proceedings of the European Conference on Circuit Theory and Design II: pp.17-20, 2001.

(Rekeczky 2002) Cs. Rekeczky, *CNN Architectures for Constrained Diffusion Based Locally Adaptive Image Processing: Research Articles*, International Journal of Circuit Theory and Applications Vol. 30, pp.313-348, 2002.

(Roska and Chua 1993) T. Roska, L. O. Chua, *The CNN universal machine: an analogic array computer*, IEEE Trans. on Circuits and Systems II: Analog and Digital Signal Processing, Vol. 40, pp.163-173, 1993.

(Roska et al. 2006) T. Roska, D. Balya, A. Lazar, K. Karacs, and R. Wagner, *System aspects of a bionic eyeglass*, Proceedings IEEE International Symposium on Circuits and Systems, pp. 161-164, 2006.

(Rudin et al. 1992) L. Rudin, S. Osher, E. Fatemi, *Nonlinear total variational based noise removal algorithms*, Physica D, Vol. 60, pp.259–268, 1992.

(Schneider and Wildermuth 2003) F.E. Schneider, D. Wildermuth, *A potential field based approach to multi robot formation navigation*, Proceedings of the IEEE International Conference on Robotics, Intelligent Systems and Signal Processing, pp. 680-685, 2003.

(Shah 1996) J. Shah, *A Common Framework for Curve Evolution, Segmentation and Anisotropic Diffusion*, Proceedings IEEE on Computer Vision and Pattern Recognition, pp.136-142, 1996.

(Shen 2003) J. Shen, *Inpainting and the fundamental problem of image processing*, SIAM News, 36(5), 2003.

(Shoval et al. 2003) S. Shoval, I. Ulrich, J. Borenstein, *Robotics-based obstacle avoidance systems for the blind and visually impaired*, IEEE Robotics and Automation Magazine, Vol. 10, No. 1, pp. 9-20, 2003.

(Siemiatkowska 1994) B. Siemiatkowska, *Cellular neural network for mobile robot navigation*, Proceedings of the IEEE International Workshop on Cellular Neural Networks and their Applications, Rome, pp. 285-290, 1994.

(Soinio 2003) A. Soinio, *A Lego-robot with camera controlled by Matlab*, LEGO Group Company, <http://www.abo.fi/fak/tkf/rt/robot>, 2003.

(Strickland and Hahn 1996) R.N. Strickland, H. Hahn, *Wavelet Transforms for Detecting Microcalcifications in Mammograms* IEEE Trans. on Medical Imaging, 15, pp.218-229, 1996.

(Szabó et al. 2002) T. Szabó, P. Barsi, P. Szolgay, *Application of analogic CNN algorithms in telemedical neuroradiology*, Proceedings of IEEE International Workshop on Cellular Neural Networks and their Applications, pp.579-586, Frankfurt Main, 2002.

(Swiniarski et al. 2001) R. Swiniarski, T. Luu, A. Swiniarska, H. Tanto, *Data Mining and On-line Recognition of Mammographic Images Based on Haar Wavelets, Principal Component Analysis and Rough Sets Methods*, International SPIE Symposium Medical Imaging pp.17-23, 2001.

(Tiponuş et al. 2005-2007) V. Tiponuş, A. Gacsádi, C. Lar, I. Gavriluş, Ş. Oniga, C. Gavrincea, L. Ţepelea, R. Caciora, *Mediu integrat pentru deplasarea asistată a persoanelor cu handicap vizual*, Grant CNCSIS A 639/2005, Raport de Cercetare, 2005-2007.

(Tiponuş et al. 2006b) V. Tiponuş, A. Gacsádi, L. Ţepelea, C. Lar, I. Gavriluş, *Integrated Environment for Assisted Movement of Visually Impaired*, Proc. Intern. Workshop on Robotics in Alpe-Adria-Danube Region, Balatonfüred, Hungary, pp. 234-239, 2006.

(Tiponuş et al. 2009) 129 V. Tiponuş, D. Ianchis, Z. Haraszy, *Assisted Movement of Visually Impaired in Outdoor Environments*, Proceedings of the WSEAS International Conference on Systems, Rodos, Greece, pp.386-391, 2009.

(Tiponuş et al. 2010) V. Tiponuş, I. Gavriluş, A. Gacsádi, *Roboţi mobili autonomi - Conducere cu reţele neuronale artificiale*, Editura Politehnica din Timişoara, 286 pag., 2010.

(Turner 1986) M.R. Turner, *Texture Discrimination by Gabor functions*, Biological Cybernetics, Vol.55, pp.71-82, 1986.

(Ţepelea et al. 2010) L. Ţepelea, I. Gavriluş, A. Gacsádi, *Edge Based CNN Image Segmentation Methods for Medical Imaging*, Journal of Computer Science and Control Systems, University of Oradea Publisher, Vol. 3, Issue 2, pp.95-98, 2010.

(Ţepelea et al. 2011) L. Ţepelea, A. Gacsádi, I. Gavriluş, V. Tiponuş, *A CNN Based Correlation Algorithm to Assist Visually Impaired Persons*, IEEE Proceedings of the International Symposium on Signals Circuits and Systems, Iaşi, Romania, pp.169-172, 2011.

(Ţepelea et al. 2014) L. Ţepelea, V. Tiponuş, P. Szolgay, A. Gacsádi, *Multicore Portable System for Assisting Visually Impaired People*, International Workshop on Cellular Nanoscale Networks and their Applications, July 29-31, University of Notre Dame, USA, pp.1-2, 2014.

(Ulrich et al. 2001) I. Ulrich, J. Borenstein, *The GuideCane - Applying Mobile Robot Technologies to Assist the Visually Impaired*, IEEE Transactions on Systems, Man, and Cybernetics, Part A: Systems and Humans, Vol. 31, No. 2, pp. 131-136, 2001.

(Vainio et al. 1995) M. Vainio, T. Schönberg, A. Halme, P. Jakubik, *Optimizing the Performance of a Robot Society in Structured Environment through Genetic Algorithms*, Robotics and Emulation of Animal Behavior, Advances in Artificial Life, Vol. 929 of the series Lecture Notes in Computer Science, pp 733-746, 2005.

(Van der Heijden et al. 2005) 18 F. Van der Heijden, P.P.L. Regtien, *Wearable navigation assistance – a tool for the blind*, Measurement Science Review, Vol. 5, Section 2, 2005.

(Velázquez et al. 2003) R. Velázquez, F. Maingreud, E. Piscaloux, *Intelligent Glasses: A New Man-Machine Interface Concept Integrating Computer Vision and Human Tactile Perception*, EuroHaptics, Dublin, pp. 456-460, 2003.

(Verma et al. 2010) B. Verma, P. McLeod, A. Klevansy, *Classification of benign and malignant patterns in digital mammograms for the diagnosis of breast cancer*, Expert Systems with Applications 37 (4), pp.3344-3351, 2010.

(Vilariño et al. 2003) D.L. Vilariño, D. Cabello, X.M. Pardo, V.M. Brea, *Cellular Neural Networks and Active Contours: a Tool for Image Segmentation*, Image and Vision Computing, 21, pp.189-204, 2003.

(Vilariño and Rekeczky 2004) D. L. Vilarino, Cs. Rekeczky, *Shortest path problem with pixels level snakes: Application to robot path planning*, Proceedings of the IEEE International Workshop on Cellular Neural Networks and their Applications, pp. 135-140, Budapest, 2004.

(Vilariño and Rekeczky 2005) D.L. Vilariño and Cs. Rekeczky, *Pixel Level Snakes on the CNNUM: Algorithm Design, On-chip Implementation and Applications*, International Journal of Circuit Theory and Applications, Vol. 33, Issue 1, pp.17-51, 2005.

(Webb 1988) S. Webb, *The Physics of Medical Imaging*, Adam Hilger, Bristol, U.K, 1988.

(Wei et al. 2005a) Wei W., Hou Z.-X., Guo Y.-C., *A displacement search algorithm for deformable block matching motion estimation*, Proceedings of IEEE International Symposium on Communications and Information Technology, pp. 457-460, 2005.

(Wei et al. 2005b) L. Wei, Y. Yang, RM Nishikawa, Y. Jiang, *A Study on Several Machine-Learning Methods for Classification of Malignant and Benign Clustered Microcalcification*, IEEE Trans. on Medical Imaging, 24 (3), pp.371-380, 2005.

(Zhu and Thall 2002) Zhu Y., Thall T. J., *A modified block matching method for real-time freehand strain imaging*, Ultrasonic Imaging, Vol. 24, pp. 161-176, 2002.

(***1999a) *** “*CadetWin-99, CNN application development environment and toolkit under Windows*” Version 3.0, Analogical and Neural Computing Laboratory, Computer and Automation Institute, Hungarian Academy of Science, Budapest, 1999.

(***1999b) *** “*CadetwWin-99, Extended analogic macro code (AMC) and interpreter*”, Reference Manual, Version 3.0, Analogical and Neural Computing Laboratory, Computer and Automation Institute, Hungarian Academy of Sciences, Budapest, 1999.

(*** 2007) *** “*Bi-i V301F-Vision System*”, *InstantVision Integrated Software Environment*, Version 3.1, User's Manual, AnaLogic Computers Ltd., 2007.

(*** 2010) *** *Software Library for Cellular Wave Computing Engines in an era of kilo-processor chips*, Version 3.1, Cellular Sensory and Wave Computing Laboratory of the Computer and Automation Research Inst., Hungarian Academy of Sciences and the Jedlik Laboratories of the Pázmány Péter Catholic University Budapest, 2010.

(*** Matlab) *** Matlab Tools and Development Environment.

(***MIAS) Mammographic Image Analysis Society,
<http://www.wiau.man.ac.uk/services/MIAS/MIASweb.html>.

(*** 2012) ***, Xilinx Inc, 2012: www.xilinx.com.

(*** c-robotics) www.c-robotics.com.