

UNIVERSITATEA TEHNICĂ „GHEORGHE ASACHI” DIN IAȘI
FACULTATEA DE ELECTRONICĂ, TELECOMUNICAȚII SI
TEHNOLOGIA INFORMAȚIEI

**CONTRIBUȚII LA PRELUCRAREA
IMAGINILOR CU APLICAȚII ÎN
CLASIFICAREA ȘI RECUNOAȘTEREA
FORMELOR**

TEZĂ DE DOCTORAT

Conducător științific,
Prof. Dr. Ing. Liviu Goraș

Doctorand,
asist. ing. Paul Ungureanu

IAȘI, 2010

**UNIVERSITATEA TEHNICĂ "GHEORGHE ASACHI" DIN IAȘI
RECTORATUL**

NR. 17231 din 15 X 2010

Către

Vă facem cunoscut că în ziua de 30.10.2009, ora 10, în amfiteatrul P4 al Facultății de Electronică, Telecomunicații din Iași, Bd Carol I, nr. 11, va avea loc susținerea publică a tezei de doctorat cu titlul

**CONTRIBUȚII LA PRELUCRAREA IMAGINILOR CU APLICAȚII ÎN
CLASIFICAREA ȘI RECUNOAȘTEREA FORMELOR**

elaborată de d-nul ing. **Paul Ungureanu**, în vederea conferirii titlului științific de doctor inginer.

Comisia de doctorat este formată din:

- | | |
|---|-----------------------|
| - prof. dr. ing. Ion Bogdan
Universitatea Tehnică "Gheorghe Asachi" din Iași | președinte de comisie |
| - prof. dr. ing. Liviu Goraș
Universitatea Tehnică "Gheorghe Asachi" din Iași | conducător științific |
| - prof. dr. ing. Gavril Ioan Toderean
Universitatea Tehnică Cluj-Napoca | membru |
| - prof. dr. ing. Radu Dogaru
Universitatea Politehnica București | membru |
| - prof. dr. ing. Iulian Ciocoiu
Universitatea Tehnică "Gheorghe Asachi" din Iași | membru |

Vă trimitem rezumatul tezei de doctorat, cu rugămintea de a ne comunica în scris aprecierile și observațiile dumneavoastră.

Cu această ocazie vă invităm să participați la susținerea publică a tezei de doctorat.

Rector

prof. dr. ing. **Ion Giurmă**



Secretar universitate,
ing. **Cristina Nagi**

CUPRINS

Capitolul I. - FILTRE SPATIALE UTILIZATE CA EXTRACTORI DE TRASATURI IN DOMENIUL CLASIFICARII IMAGINILOR

I. 1. - Filtre spațiale; rolul filtrelor, tipuri de filtre utilizate.....1

I. 2. - Filtre Gabor; proprietăți2

I. 3. - Filtre circulare; proprietăți8

Capitolul II. - APROXIMAREA CARACTERISTICILOR FILTRELOR DE TIP GABOR

II. 1. - Aproximarea caracteristicilor de frecvență ale filtrelor Gabor folosind aproximarea Pade11

II. 2. - Aproximarea caracteristicilor de frecvență ale filtrelor Gabor folosind aproximarea Pade-Chebyshev15

Capitolul III. - IMPLEMENTĂRI ALE FILTRELOR DE TIP GABOR

III. 1. - Studiarea unor structuri RNN pentru implementarea filtrelor de tip Gabor.....18

III. 2. - Implementarea filtrelor de tip Gabor folosind filtre recursive.....23

Capitolul IV. - APLICATII ALE FILTRELOR SPATIALE DE TIP GABOR

IV.1 Recunoașterea texturilor utilizând trăsături extrase cu filtre Gabor.....46

IV.2 Detecția conturilor folosind bancuri de filtre Gabor implementate cu filtre de tip IIR52

Capitolul V. - FOLOSIREA RETELELOR NEURALE CELULARE CU DOUĂ STRATURI PENTRU EXTRAGEREA TRĂSĂTURILOR

<i>V. 1. - Noțiuni generale privind RNC de tip dublu strat.....</i>	36
<i>V. 2. - Filtrare neliniară folosind RNC de tip dublu strat.....</i>	40
<i>V. 3. - Filtrare liniară folosind RNC de tip dublu strat.....</i>	43
<i>V. 4. - Filtrare liniară a imaginilor folosind rețele neurale de tip dublu strat omogene</i>	46
<i>V.5 Filtrare liniară a imaginilor folosind rețele neurale de tip dublu strat neomogene</i>	52
CONCLUZII ȘI CONTRIBUȚII PERSONALE	55

PREFAȚĂ

Tematica tezei de doctorat se încadrează în domeniul prelucrării imaginilor în scopul extragerii de trăsături relevante care vor fi utilizate pentru clasificarea formelor. Sunt investigate în mod special posibilitățile de utilizare a unor extractori de trăsături care să poată fi utilizați în aplicații care necesită un volum de calcul mare, cum sunt aplicațiile din domeniul prelucrării imaginilor.

Sunt investigate posibilitățile de proiectare și implementare ale filtrelor Gabor care au fost utilizate în aplicații de recunoaștere a texturilor și detecție a conturilor. Filtrele au fost proiectate folosind aproximările Padé și Padé-Chebyshev rezultând aproximări ale caracteristicilor de frecvență mai bune decât cele raportate în literatura de specialitate.

Sunt investigate posibilitățile de implementare ale filtrelor Gabor folosind RNC și filtre recursive. Din punct de vedere al implementării, avantajul ar fi consumul redus și respectiv obținerea unor bancuri de filtre optime din punct de vedere al numărului de operații matematice.

Filtrele implementate au fost utilizate în domeniul recunoașterii texturilor și al detecției conturilor arătându-se că utilizarea filtrelor de tip Gabor oferă rezultate la fel de bune ca în cazul utilizării filtrelor ideale.

Sunt analizate performanțele RNC neurale de tip dublu strat liniare și neliniare în aplicații de recunoaștere a formelor. S-au analizat RNC omogene liniare, s-a determinat caracteristica de frecvență variabilă în timp a acestor filtre și s-au analizat performanțele RNC neomogene în aplicații de recunoaștere a texturilor.

Mulțumirile mele se îndreaptă către:

Domnul prof. dr. ing. Liviu Goraș pentru sprijinul și răbdarea care mi le-a oferit pe parcursul perioadei de doctorat și pentru atmosfera propice activității de cercetare care a creat-o în cadrul laboratorului de Semnale, Circuite și Sisteme.

Profesorii și colegii din cadrul laboratorului de Semnale, Circuite și Sisteme pentru sprijinul, încrederea acordate și mediul prietenos care au știut să îl întrețină.

Cadrele didactice din cadrul Facultății de Electronică, Telecomunicații și Tehnologia Informației care au contribuit la formarea mea ca inginer și cercetător.

Domnilor referenți științifici pentru că au acceptat să analizeze teza de doctorat, pentru observațiile dumnealor și pentru că au acceptat să participe la susținerea publică a tezei.

Nu în ultimul rând aș vrea să mulțumesc părinților și familiei pentru că m-au susținut și m-au îndrumat în anii școlii precum și pentru răbdarea și înțelegerea de care au dat dovadă pe perioada pregătirii tezei de doctorat.

Capitolul I. - FILTRE SPAZIALE UTILIZATE CA EXTRACTORI DE TRASATURI IN DOMENIUL CLASIFICARII IMAGINILOR

1.1 Filtre spațiale; rolul filtrelor, tipuri de filtre utilizate.

Detecția și analiza imaginilor sunt cele mai cunoscute aplicații în domeniul prelucrării imaginilor sau reprezintă o parte importantă a unui sistem de analiza a imaginilor. În prefața uneia dintre cele mai citate cărți din domeniul procesării imaginilor, [JAI89], se apreciază că un sistem suficient de performant de prelucrare a imaginilor ar trebui, ca pentru o imagine care cuprinde un drum pe lângă care trece o apă și peste ea o punte, să le identifice pe fiecare din cele trei elemente.

În literatura de specialitate [TUC93] metodele de analiza a imaginilor se împart în câteva categorii: statistice, geometrice, bazate pe un anumit model și bazate pe trăsături extrase folosind filtrări sau transformate din domeniul prelucrării semnalelor.

Metodele bazate pe prelucrarea semnalelor sunt dintre cele mai folosite metode din domeniul detecției și recunoașterii diferitelor categorii de imagini: detecția și segmentarea texturilor [RAN99a], [TUC93], detecția și recunoașterea fețelor [PHI06], [ADI97], [NAG03], [WIS97] detecția și recunoașterea obiectelor [MCK97].

Schema principală folosită în domeniul recunoașterii imaginilor este prezentată în Fig. 1.1. Fără a simplifica algoritmi folosiți în literatura de specialitate, o imagine este filtrată folosind un banc de N filtre, rezultând N imagini care conțin preponderent trăsături ce aparțin unei anumite benzi de frecvență.

Calculul energiei se realizează local (în aplicații ce țin mai mult de segmentarea imaginilor sau detecției unor anumite trăsături într-o imagine) sau se calculează energia fiecărei imagini filtrate. Pentru calculul energiei în literatură se folosesc norma $L1$ sau $L2$ [COG85], [LAI93], [TEU95], [UNS90]. Dintre toate blocurile unei scheme de clasificare, cel care influențează esențial rezultatul final este bancul de filtre [RAN99a].

În literatura de specialitate se folosesc filtre trece banda cu rolul de a selecta numai trăsăturile care fac parte dintr-o anumită bandă de frecvențe. Exemple de astfel de filtre sunt: bancuri de filtre Gabor diadice, filtre wavelet, filtre circulare, transformata cosinus discretă, filtre în cuadratură (quadrature mirror filters - QMF).

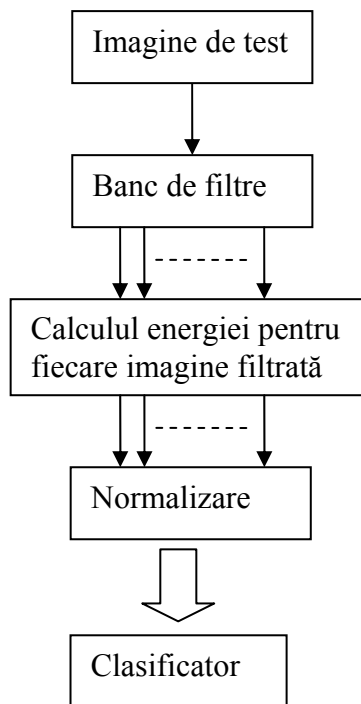


Fig. 1.1: Schema principială folosită în domeniul recunoașterii imaginilor

Dintre etapele algoritmului mai sus prezentat, în literatura de specialitate, cel mai mult s-a acordat atenție bancului de filtre.

În continuare se vor prezenta proprietățile a doi extractori de trăsături (bancurile de filtre Gabor și filtrele circulare) care sunt des utilizați în literatura de specialitate, în aplicații de recunoaștere a formelor.

1.2 Filtre Gabor; proprietăți

Filtrele Gabor au fost propuse în 1949 de Denis Gabor [GAB46] și sunt folosite în domeniul prelucrării imaginilor ca elemente de preprocesare și extragere de trăsături. Câteva aplicații ar fi: recunoașterea formelor, recunoașterea fețelor, detecția conturilor, analiza mișcării [WES95], [KOV99], [MAN00a], [WIS97].

Folosirea filtrelor Gabor a fost motivată de faptul că oferă maximul de rezoluție atât în domeniul spațiu cât și în domeniul frecvență [PAP77]. Utilizarea acestora în aplicațiile mai sus menționate este motivată și de anumite proprietăți ale acestora și anume, faptul că pot extrage informația din domeniile spațiu și frecvență cu minimă incertitudine. De asemenea, răspunsul la impuls al unui filtru Gabor permite analiza separată a caracteristicilor de amplitudine și de fază ale unui semnal în domeniul spațial. De asemenea, s-a descoperit că celulele

ganglionare ale retinei mamiferelor au răspunsul la impuls asemănător cu cel al filtrelor Gabor [COR00].

Filtre Gabor unidimensionale

Răspunsul la impuls al unui filtru Gabor este dat de o exponențială complexă modulată în amplitudine de o funcție gaussiană:

$$g(x) = \frac{1}{\sqrt{2 \cdot \pi \cdot \sigma}} \exp\left(-\frac{x^2}{2\sigma^2}\right) \cdot \exp(j\omega_0 \cdot x) \quad (1.1)$$

unde σ reprezintă deviația standard a gaussienei iar ω_0 reprezintă frecvența centrală a filtrului.

Transformata Fourier a unei funcții gaussiene este $\exp(-\omega^2 \cdot \sigma^2 / 2)$ iar a filtrului Gabor este:

$$G(\omega) = \exp\left(-\frac{(\omega - \omega_0)^2 \cdot \sigma^2}{2}\right) \quad (1.2)$$

În Fig. 1.2 s-a reprezentat modulul funcției Gabor, partea reală, partea imaginară și transformata Fourier ($G(\omega)$):

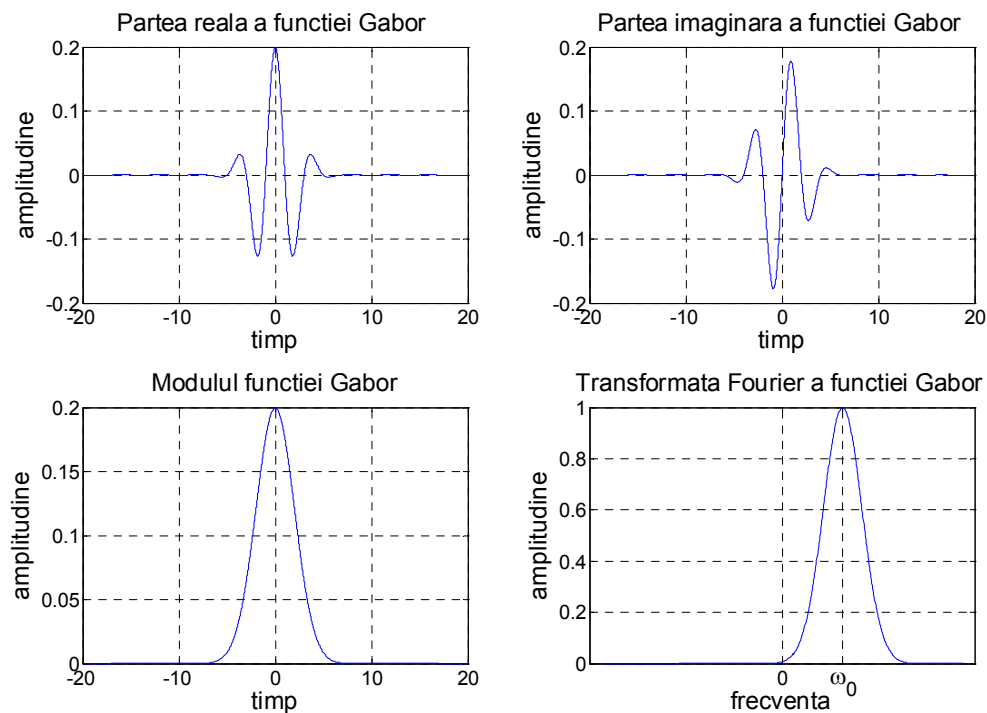


Fig. 1.2: Partea reală, imaginară și modulul funcției Gabor pentru $\sigma = 2$; transformata Fourier a funcției Gabor pentru $\omega_0 = \pi / \sigma$.

Pentru a extrage informațiile specifice diferitelor benzi de frecvență ale unui semnal, în aplicațiile de recunoaștere a formelor, se utilizează bancuri de filtre Gabor care au o proprietate de tip wavelet:

$$\sigma = a^i \text{ și } \omega_0 = k / \sigma \quad (1.3)$$

În felul acesta, se obține o acoperire a întregului domeniu de frecvențe [MAL99] și se pot obține vectori de trăsături care să caracterizeze cât mai bine imaginea respectivă.

Dacă $a=2$, atunci se spune că bancul de filtre Gabor respectiv are proprietatea de a fi diadic [MAL99]. Astfel definite, toate filtrele bancului au același factor de calitate. În Fig. 1.3 se prezintă un exemplu de astfel de banc de filtre format din 5 filtre cu parametrii $a=2$ și $k=\pi$. Bancul de filtre astfel definit ((1.1) și (1.3)) are proprietatea că norma L1 a filtrelor din care este constituit este 1 [HAL99], [YOU02].

$$\int_{-\infty}^{\infty} |g(x)| dx = 1 \quad (1.4)$$

În literatură s-au folosit și funcții Gabor care au proprietatea că energia este invariantă în raport cu σ [MOS98], [JIA00]:

$$\int_{-\infty}^{\infty} |g(x)|^2 dx = \frac{1}{2\sqrt{\pi}} \quad (1.5)$$

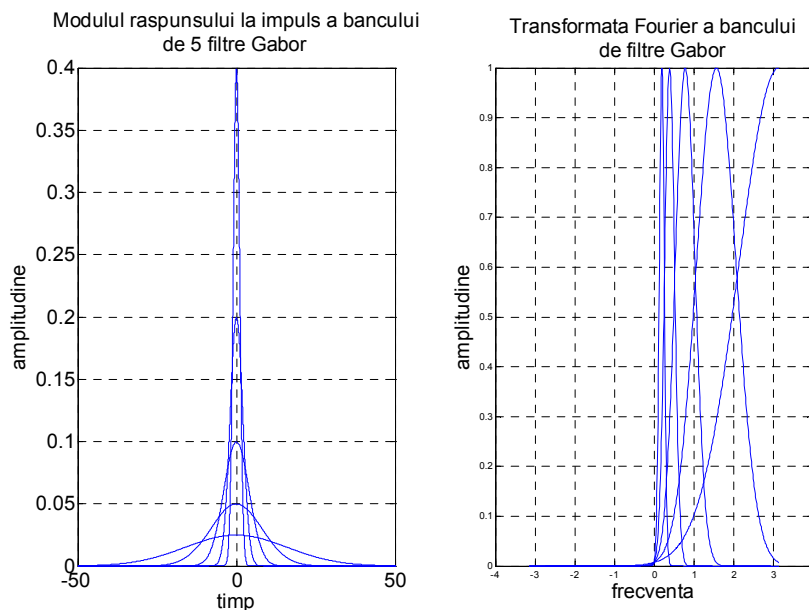


Fig. 1.3: Exemplu de banc de filtre Gabor format din 5 filtre (modulul răspunsului la impuls și respectiv transformata Fourier)

În acest caz, răspunsul la impuls al filtrului de tip Gabor este:

$$g(x) = \frac{1}{\sqrt{2 \cdot \pi \cdot \sigma}} \exp\left(-\frac{x^2}{2\sigma^2}\right) \cdot \exp(j\omega_0 \cdot x) \quad (1.6)$$

iar răspunsul în amplitudine al filtrului nu mai are valoare maximă egală cu unitatea ci, pentru diferite scale, este proporțională cu $\sqrt{\sigma}$ (Fig. 1.4).

$$G(\omega) = \sqrt{\sigma} \exp\left(-\frac{(\omega - \omega_0)^2 \cdot \sigma^2}{2}\right) \quad (1.7)$$

În alte aplicații se preferă o variantă a filtrelor Gabor numită în literatură filtre log Gabor [NEC06], [FDE98]. Dacă se consideră axa frecvențelor pe scara liniară, funcția Gabor este:

$$G(\omega) = \exp\left(\frac{(\log(\omega / \omega_0))^2}{2 \cdot (\log(k / \omega_0))^2}\right) \quad (1.8)$$

Parametrul k se alege astfel încât k / ω_0 sa fie constant. De exemplu dacă raportul este egal cu 0.75 rezultă un filtru cu banda aproximativ 1 octavă iar pentru 0.55 rezultă un filtru cu banda de aproximativ 2 octave. În Fig. 1.5 se prezintă caracteristicile de frecvență ale celor 2 bancuri de filtre (ω_0 variază ca și în cazul anterior conform formulei $\pi / 2^i$, $i = 0..4$).

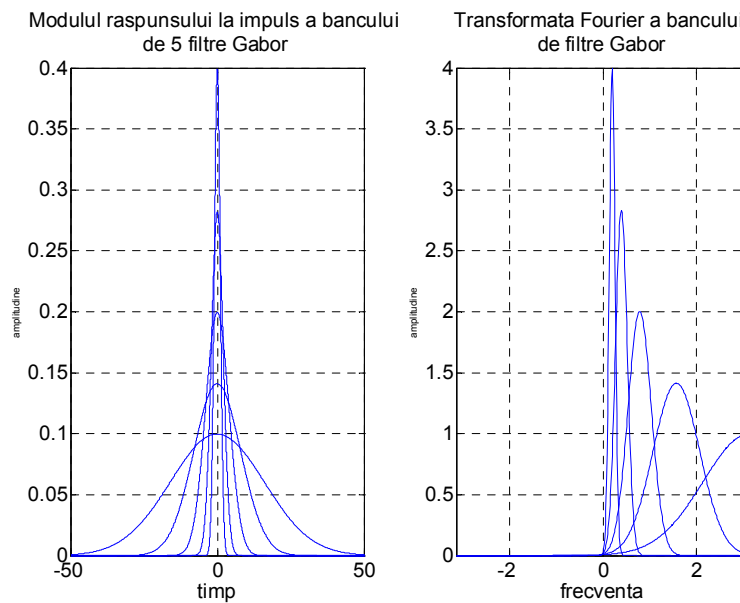


Figura 1.4 Exemplu de banc de filtre Gabor format din 5 filtre (modulul răspunsului la impuls și respectiv transformata Fourier).

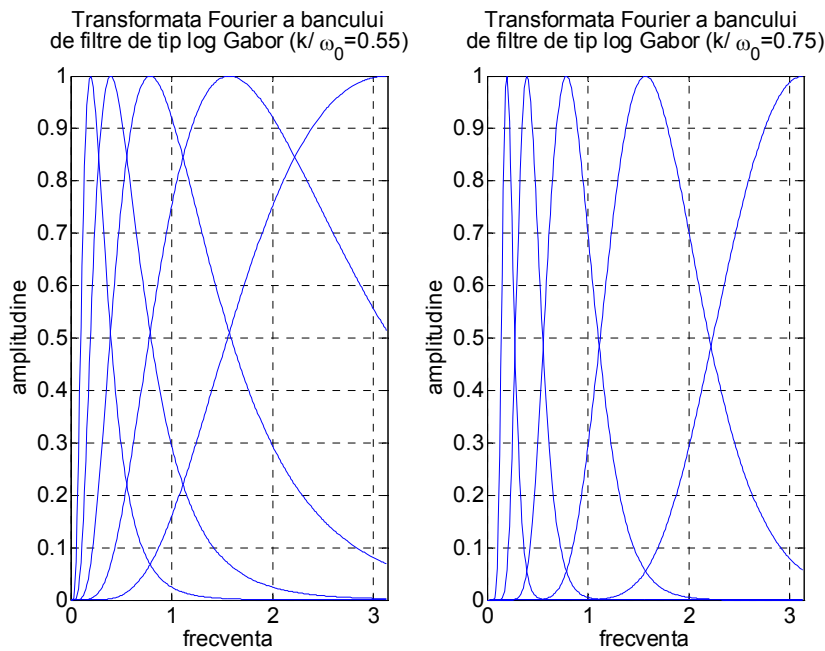


Figura 1.5: Exemplu de banc de filtre Gabor de tip *log Gabor* format din 5 filtre (modulul r spunsului la impuls  i respectiv transformata Fourier).

Pentru a fi un banc de filtre de tip wavelet, filtrele Gabor componente trebuie s  respecte urm toarele dou  propriet ti [MAL99]:

- Condi ia de admisibilitate:

$$0 < 2\pi \int_{-\infty}^{\infty} \frac{|G(\omega)|^2}{\omega} d\omega < \infty \quad (1.9)$$

- Componenta de curent continuu a r spunsului la impuls s  fie 0:

$$\int_{-\infty}^{\infty} g(x) dx = 0 \quad (1.10)$$

Condi ia (1.10) presupune $G(0) = 0$, condi ie care nu este respectat  de partea real  a r spunsului la impuls a filtrelor Gabor. De aceea  n literatura a fost propus  o versiune modificat  a rela iilor (1.1) sau (1.6) care respect  rela ia (1.10) [TAI96]:

$$g(x) = \frac{1}{\sqrt{2 \cdot \pi \cdot \sigma}} \exp\left(-\frac{x^2}{2\sigma^2}\right) \cdot \exp(j\omega_0 \cdot x) - \exp\left(-\frac{\omega_0^2 \sigma^2}{2}\right) \quad (1.11)$$

Filtre Gabor bidimensionale

Trecerea de la filtre 1D la filtre 2D conduce la filtre spa iale separabile sau neseparabile.  n cazul filtrelor separabile, r spunsul la impuls este dat de rela ia:

$$g_{xy}(x, y) = g(x)g(y) \quad (1.12)$$

 n acest caz, r spunsul la impuls al unui filtru Gabor 2D este:

$$g(x, y) = \frac{1}{2\pi\sigma_x\sigma_y} \exp\left(-\frac{x^2}{2\sigma_x^2} - \frac{y^2}{2\sigma_y^2}\right) \exp(j(\Omega_x x + \Omega_y y)) \quad (1.13)$$

iar transformata Fourier corespunzătoare este dată de relația (1.14):

$$G(\omega_x, \omega_y) = \exp\left(-\frac{(\omega_x - \Omega_x)^2 \sigma_x^2}{2} - \frac{(\omega_y - \Omega_y)^2 \sigma_y^2}{2}\right) \quad (1.14)$$

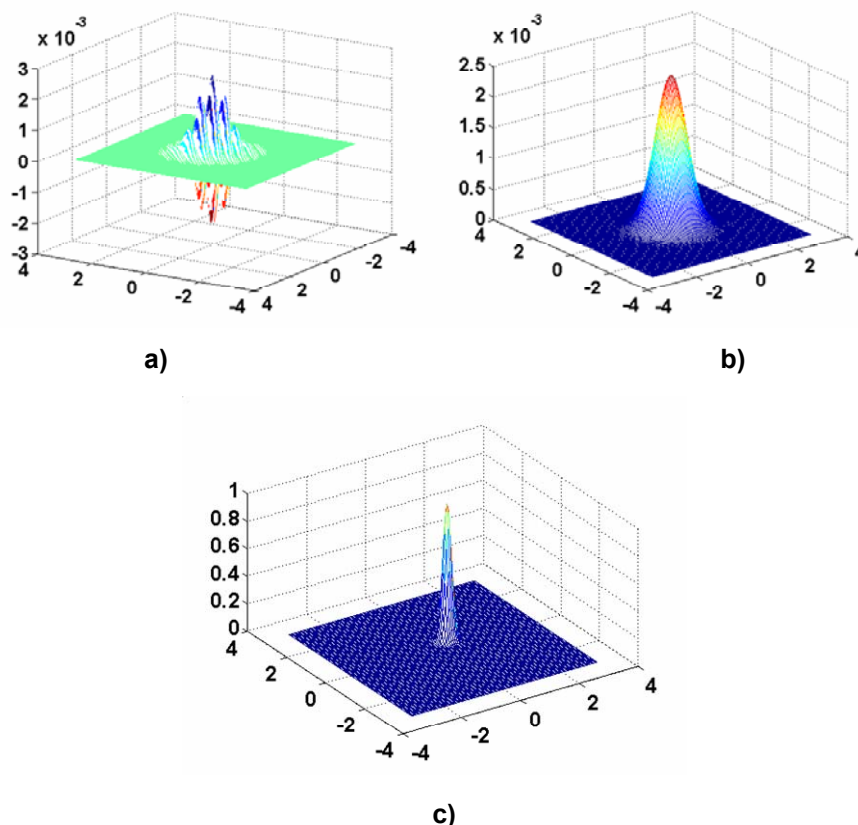


Fig 1.6: a) Partea reală, b) modulul și c) răspunsul în frecvență al unui filtru Gabor 2D.

Lățimea Gaussienei este dată de σ_x și σ_y în raport cu direcțiile x și respectiv y, iar frecvența purtătoare în raport cu cele două direcții ω_x și ω_y este dată de Ω_x și respectiv Ω_y . În domeniul prelucrării de imagini se folosesc filtre Gabor cu diferite valori pentru $\sigma_x, \sigma_y, \Omega_x$ și Ω_y . În cele mai multe aplicații se preferă următoarea relație între parametrii filtrului Gabor:

$$\begin{aligned} \sigma_x &= \sigma_y = \sigma_v \text{ și} \\ \Omega_x &= \Omega_v \cos \varphi_u, \Omega_y = \Omega_v \sin \varphi_u, \Omega_v = 2^{-\frac{v+2}{2}} \pi, \varphi_u = \frac{u\pi}{N} \end{aligned} \quad (1.15)$$

$$v = 1, \dots, M, u = 1, \dots, N$$

Deseori se folosește o relație wavelet de tipul: $\sigma_v \Omega_v = k$. În acest caz funcțiile Gabor sunt versiuni dilatate și scalate ale unei "funcții mama" (mother function).

1.3 Filtre circulare; proprietăți

De multe ori, imaginile analizate sunt similare cu replicile rotite ale imaginilor din bazele de date și, de aceea, este nevoie ca sistemele de recunoaștere să ia în considerare și această categorie de imagini. În Fig. 1.7 se prezintă o textură și replica ei rotită.



Fig. 1.7: Textura și același tip de textura rotită.

O rotație a unei imagini se traduce în planul XY, printr-o schimbare de coordonate dată de sistemul de ecuații:

$$\begin{cases} x' = x \cos(\varphi_0) + y \sin(\varphi_0) \\ y' = -x \sin(\varphi_0) + y \cos(\varphi_0) \end{cases} \quad (1.16)$$

În domeniul Fourier, are loc de asemenea o rotație a spectrului imaginii respective.

$$F\{f(x', y')\} = F(\omega'_x, \omega'_y) \quad (1.17)$$

unde

$$\begin{cases} \omega'_x = \omega_x \cos(\varphi_0) + \omega_y \sin(\varphi_0) \\ \omega'_y = -\omega_x \sin(\varphi_0) + \omega_y \cos(\varphi_0) \end{cases} \quad (1.18)$$



Modulul spectrului imaginii nerotite

Modulul spectrului imaginii rotite cu 45°

Fig. 1.8: Spectrele texturii și texturii rotite cu 45° din Fig. 1.7

Din punctul de vedere al unui sistem de recunoaștere al imaginilor, acesta se traduce printr-o modificare a vectorilor de trăsături caracteristici imaginii


respective. În literatura de specialitate sunt prezentați algoritmi care compensează rotirea imaginilor.

Există însă posibilitatea utilizării filtrelor circulare bidimensionale ca extractori de trăsături. Pentru a obține un astfel de filtru se poate utiliza un filtru Gabor unidimensional care este rotit în jurul axei utilizând schimbarea de variabilă:


$$\omega \rightarrow \sqrt{\omega_x^2 + \omega_y^2} :$$

$$G(\omega) = \exp\left(-\frac{(\sqrt{\omega_x^2 + \omega_y^2} - \omega_0)^2 \cdot \sigma^2}{2}\right) \quad (1.19)$$

În Fig. 1.11 se reprezintă răspunsul de impuls și caracteristica de frecvență a filtrului circular definit în relația (1.19).



Răspunsul la impuls al filtrului circular



Caracteristica de frecvență a filtrului circular

Fig. 1.9: Răspunsul de impuls și caracteristica de frecvență a filtrului circular

Sistemul de recunoaștere utilizează vectori de trăsături obținuți prin calcularea normei L1 sau L2 a imaginilor filtrate. Având în vedere forma circulară a caracteristicii de frecvență a filtrelor, norma este invariantă la rotirea spectrului imaginii.

Se obține astfel o metodă de a recunoaște a imaginilor rotite fără a mai fi necesară modificarea algoritmului de recunoaștere a imaginilor.

Pentru a avea o proprietate de tip wavelet ca și în cazul filtrelor Gabor, se poate proiecta bancul de filtre astfel încât produsul dintre frecvența centrală și deviația standard a Gaussienei să fie constantă: $\omega_0 \sigma = k$. În Fig. 1.12 se prezintă un astfel de banc de filtre, obținut pentru $\omega_0 = \pi / \sigma$ și $\sigma = 1,6^m$, unde m variază între 1 și 4.




Fig. 1.10: Caracteristica de frecvență a unui banc de filtre circulare

Concluzii

S-au prezentat două dintre cele mai utilizate filtre din domeniul prelucrării imaginilor, filtrele Gabor și filtrele circulare. S-a insistat în special pe utilizarea acestor filtre în domeniul recunoașterii imaginilor punându-se accent pe capacitatea acestor filtre de a extrage trăsături atât în domeniul spațiu cât și în domeniul frecvență cu minimum de incertitudine.

Capitolul II. - APROXIMAREA CARACTERISTICILOR FILTRELOR GABOR

Dezavantajul major al filtrelor Gabor este faptul că implementarea numerică folosind convoluția unui semnal cu răspunsul la impuls al acestor filtre necesită un număr mare de operații în cazul folosirii unor filtre selective. De aceea, în cazul unor aplicații ce necesită prelucrarea în timp real a semnalelor este necesară găsirea unor alternative mai rapide de implementare. Una dintre aceste alternative este folosirea filtrelor recursive (cu răspuns infinit la impuls, IIR) care să aproximeze cât mai bine caracteristicile filtrelor Gabor. S-au obținut rezultate încurajatoare în ceea ce privește proiectarea unor astfel de filtre [DAV03a], [DAV03b], [DAV05] folosind metode care permit proiectarea filtrelor de tip Gabor, și în ceea ce privește erorile de aproximare. De asemenea filtrele proiectate pot fi implementate folosind structuri paralele de calcul existând posibilitatea îmbunătățirii performanțelor ce privesc timpii de procesare în cadrul diverselor aplicații. În literatura de specialitate există o metodă de aproximare, care este însă limitată la filtre de ordinul 6 [YOU02] și care folosește mai întâi transformata Laplace a aproximării filtrului în domeniul timp al filtrului și apoi transformata Z corespunzătoare (s-a folosit metoda Euler pentru a se trece din planul s în z).

II.1 Aproximarea caracteristicilor de frecvență ale filtrelor Gabor

Așa cum rezultă din relația (2.1), pentru a aproxima o caracteristică a filtrului Gauss sau Gabor este suficient să se determine valorile lui A_k și B_0 . Pentru aceasta se încearcă aproximarea filtrului Gaussian prin relația:

$$G(\omega) = e^{-\frac{\omega^2 \sigma^2}{2}} \approx -\frac{P(\omega)}{Q(\omega)} = \frac{p_0}{q_0 + \sum_{k=1}^N 2q_k \cos(k\omega)}, \quad \omega \in [-\pi, \pi] \quad (2.1)$$

Pentru aceasta se utilizează următoarea schimbare de variabilă [DAV03a]:

$$x = \cos \omega \Leftrightarrow \omega = \arccos x$$

$$G(\omega) \rightarrow G(x) = e^{-\frac{(\arccos x)^2 \sigma^2}{2}}, \quad x \in [-1, 1]$$

Aproximarea caracteristicilor de frecvență ale filtrelor Gabor folosind aproximarea Padé

Aspecte teoretice privind aproximarea Padé pot fi găsite în [PRE02]. Aproximarea Padé aproximează o funcție $f(x)$ printr-un raport de două polinoame.

$$R(x) = \frac{P(x)}{Q(x)} = \frac{\sum_{k=0}^n p_k x^k}{\sum_{k=0}^m q_k x^k} \quad (2.2)$$

Pentru aceasta de pornește de la aproximarea Taylor a funcției $f(x)$, se consideră numai primii $m+n+1$ termeni ai dezvoltării și se egalează cu relația (2.2). Coeficienții aproximării Padé se determină rezolvând sistemul de ecuații:

$$\sum_{i=0}^k a_i q_{k-i} = p_i \quad k=0,1,2,\dots,N, q_0=1 \quad (2.3)$$

Se aproximează caracteristica de frecvență a filtrului de tip Gauss în jurul lui $\omega=0$ și de aceea se aproximează $G(x)$ în jurul lui $x=1$. În cazul nostru se va aproxima funcția $G(x)$ printr-un raport de tipul $p_0/Q(x)$, unde $Q(x)$ este un polinom de grad N unde N reprezintă dimensiunea matricei de conexiuni:

$$G(x) = e^{-\frac{(\arccos x)^2 \sigma^2}{2}} = \sum_{n=0}^{\infty} \frac{1}{n!} G^{(n)}(x) \Big|_{x=1} (x-1)^n \quad (2.4)$$

$$G(x) \approx \frac{P_0}{Q(x)} = \frac{P_0}{\sum_{k=0}^N q_k x^k}$$

Folosind substituția $x = \cos \omega$ în $G(x)$ și considerând relațiile trigonometrice dintre $\cos^n x$ și $\cos(n \cdot x)$ se obține o aproximare pentru $G(\omega)$ de tipul:

$$G(\omega) \approx \frac{P_0}{\sum_{k=0}^N q_k \cdot \cos(k \cdot \omega)} \quad (2.5)$$

Din motive tehnologice, se va limita valoarea lui N la $N=3$.

Considerând algoritmul de mai sus, funcțiile de transfer ale filtrului Gaussian pentru $N=1,2,3$ sunt [DAV03a], [DAV03b]:

$$\begin{aligned}
H_1(\omega) &= \frac{1}{1 + \sigma^2 - \sigma^2 \cos(\omega)} \\
H_2(\omega) &= \frac{12}{12 + 15\sigma^2 + 9\sigma^4 - (16\sigma^2 + 12\sigma^4) \cos(\omega) + (\sigma^2 + 3\sigma^4) \cos(2\omega)} \\
H_3(\omega) &= \frac{360}{360 + 490\sigma^2 + 420\sigma^4 + 150\sigma^6 - (540\sigma^2 + 585\sigma^4 + 225\sigma^6) \cos(\omega) + \dots} \\
&\dots + (54\sigma^2 + 180\sigma^4 + 90\sigma^6) \cos(2\omega) - (4\sigma^2 + 15\sigma^4 + 15\sigma^6) \cos(3\omega)
\end{aligned} \tag{2.6}$$

Eroarea de aproximare poate fi estimată calculând eroarea pătratică medie normalizată (NSE) și eroarea absolută maximă. (ε_{\max}):

$$\begin{aligned}
\varepsilon_{\max}(\sigma, N) &= \max |G(\omega_m, \sigma) - H_N(\omega_m, \sigma)| \\
NSE(\sigma, N) &= \frac{\sum_{m=-M/2}^{M/2} |G(\omega_m, \sigma) - H_N(\omega_m, \sigma)|^2}{\sum_{m=-M/2}^{M/2} |G(\omega_m, \sigma)|^2}
\end{aligned} \tag{2.7}$$

În figura de mai jos se prezintă erorile calculate considerând variația valorii lui σ [DAV05]:




Fig. 2.1: Eroarea pătratică maximă normalizată și eroarea absolută maximă

Realizând substituția $\omega \rightarrow \omega - \omega_0$, un filtru de tip Gabor se obține dintr-unul de tip Gauss printr-o translare de frecvență a caracteristicii filtrului în jurul frecvenței ω_0 . În acest caz se obține un filtru care are coeficienți complecși. În Fig. 2.2 se prezintă caracteristicile ideale și cele approximate ale filtrelor Gabor pentru σ egal cu 2,4 și 8 și considerând $k = \pi$ ($\omega_0 = \pi / \sigma$).

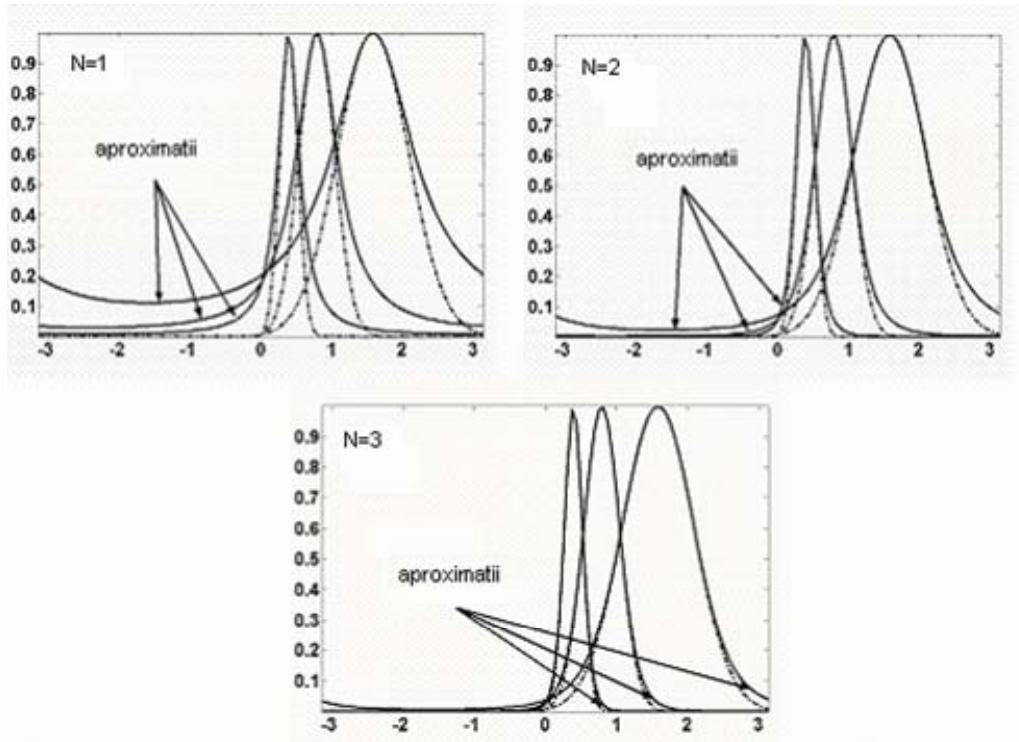
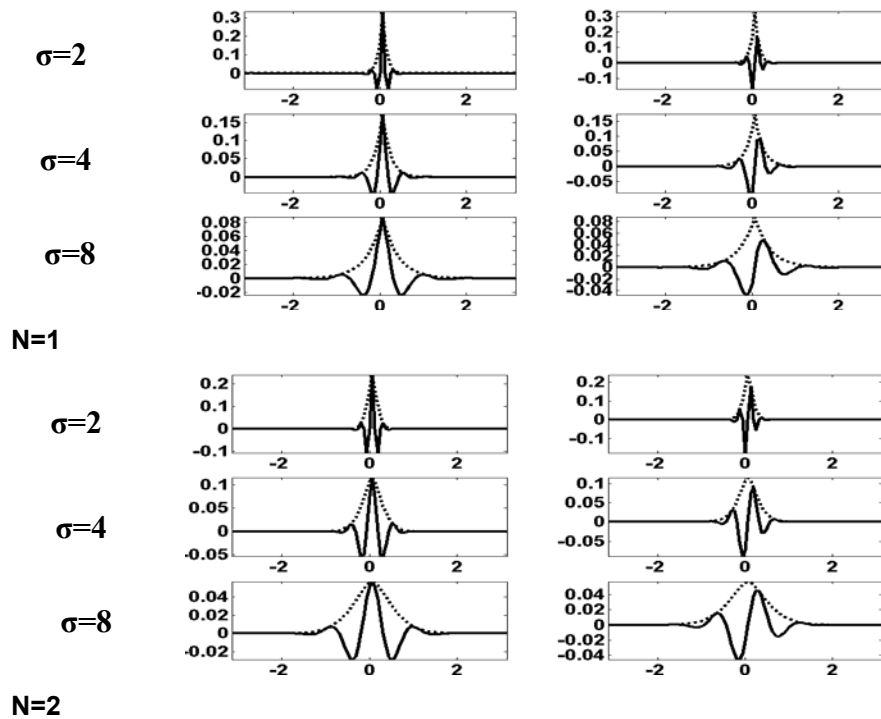


Fig 2.2: Caracteristici de frecvență ideale și aproximăte ale unui filtru Gabor, pentru cazul $N=1,2,3$ și $\sigma = 2,4,8$. (cu linii punctate se prezintă caracteristicile ideale ale filtrelor)






Fig. 2.3: Partea reală și partea imaginară a răspunsului la impuls al filtrelor de tip Gabor pentru $N=1,2,3$ și $\sigma = 2,4,8$

II.2 Aproximarea de tip Padé-Chebyshev

Aproximarea Padé-Chebyshev presupune aproximarea unei funcții printr-o funcție rațională folosind aproximarea Chebyshev [PRE02], [GED81].

$$G(x) = e^{-\frac{(\arccos x)^2 \sigma^2}{2}} = \sum_{k=0}^{\infty} c_k T(k, x) \approx \frac{q_0}{\sum_{k=0}^N p_k T(k, x)} = \frac{q_0}{\sum_{k=0}^N a_k x^k} \quad (2.8)$$

unde $T(k, x) = \cos(k \arccos(x))$.

Avantajul aproximării Chebyshev este că aproximarea se face pe un interval și nu într-un punct ca în cazul aproximării Padé, permițând obținerea de erori de aproximație mai mici pe întreg intervalul de aproximație [PRE02].

Pentru a găsi aproximarea rațională a gaussienei, s-a folosit metoda descrisă în [GED81].




Figura 2.4: Caracteristica de frecvență a unui filtru de tip Gauss și funcția corespunzătoare obținută prin transformarea $\omega = \arccos x$

În Fig. 2.4, se prezintă graficul funcției $G(x)$ pentru $\sigma = 4$. S-a observat că aproximarea rațională mai bună se obține dacă aproximarea Chebyshev nu se face pe intervalul $[-1, 1]$, ci pe intervalul $[a, 1]$ [DAV05].

Valoarea optimă a lui a se obține minimizând valoarea absolută maximă (2.9) a diferenței dintre $G(\omega)$ și caracteristica de frecvență aproximată.

În Figura 2.5 se prezintă valoarea optimă determinată a lui a calculată astfel încât să fie minimizată eroarea absolută maximă pentru $\sigma = 2..8$ și $N=1, 2, 3$. Valoarea optimă a lui a a fost determinată folosind metoda de optimizare „golden search” care permite determinarea valorii minime a unei funcții la variația unui parametru într-un interval considerat.

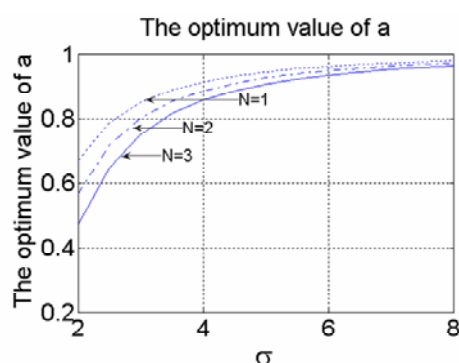


Figura 2.5: Valoarea optima a lui a

Considerând valorile optime ale lui a , în Fig. 2.6 se prezintă variațiile erorii pătratice medii (2.10) și ale erorii absolute maxime (2.9):

$$MAE(\omega) = \max \{ |G(\omega) - R(\omega)| \}, \quad \omega = -\pi.. \pi \quad (2.9)$$

$$RSE = \sqrt{\frac{1}{2\pi} \int_{-\pi}^{\pi} [G(\omega) - R(\omega)]^2 d\omega} \quad (2.10)$$

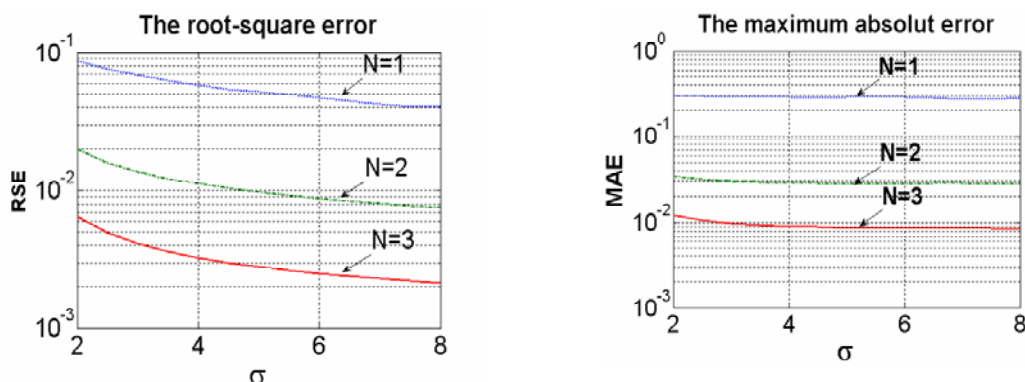


Fig. 2.6: Rădăcina erorii pătratice și eroarea absoluta maxima a filtrelor Gaussiene approximate pentru $\sigma = 2..8$ și $N=1, 2, 3$.

Raportat la rezultatele din literatura de specialitate, rezultatele obținute sunt comparabile cu cele din [YOU02] atunci când se folosește aproximarea Pade și mai bune decât cele din [YOU02] în cazul în care se folosește aproximarea Pade-Chebyshev. Dacă se utilizează aproximarea Pade-Chebyshev există posibilitatea implementării aceluiași filtru cu un ordin de mărime mai mic în condițiile aceluiași erori de aproximare.

II. 1. - Concluzii

S-a analizat posibilitatea utilizării aproximărilor Padé și Padé-Chebyshev în proiectarea filtrelor Gabor. Rezultatele obținute sunt comparabile cu cele din literatura de specialitate atunci când se folosește aproximarea Padé și mai bune pentru cazul în care se folosește aproximarea Padé-Chebyshev. Aproximarea Padé-Chebyshev oferă rezultate mai bune, fiind posibil să se implementeze același filtru cu un ordin de mărime mai mic în condițiile aceluiași erori de aproximare.

Capitolul III. - IMPLEMENTĂRI ALE FILTRELOR DE TIP GABOR

III.1 Studiarea unor structuri RNN pentru implementarea filtrelor de tip Gabor

Rețelele neurale celulare (RNC) sunt sisteme analogice de procesare paralelă a semnalului. Ele au fost introduse de Chua și Yang [CHU88a], [CHU88b] și și-au găsit aplicații mai ales în domeniul prelucrării imaginilor [CRO95].

RNC-ul tipic este alcătuit din celule identice interconectate indentic. De obicei celula este un sistem de ordinul I, care are o stare, o ieșire și o intrare conectată cu un număr mic de ieșiri ale celulelor vecine, așa numita matrice de conexiuni ("template").

Avantajele unei structuri de tipul senzor-RNC sunt: procesarea de mare viteză datorită structurii analogice a circuitului, interfața simplificată între senzor și procesor.

În ceea ce privește implementarea filtrelor Gabor folosind rețele neurale celulare, în literatura de specialitate sunt cunoscute arhitecturile de circuit propuse de B. Shi în [SHI98], iar în [SHI99] se prezintă prototipul unui astfel de circuit. Filtrul a fost realizat folosind RNC 1D cu matrice de conexiuni cu vecinătate 1. Astfel implementat, filtrul asigură un răspuns de faza 0 și de aceea a fost folosit în etapa de preprocesare a algoritmilor care folosesc faza răspunsului filtrelor de tip Gabor.

RNC-ul liniar este o rețea neurală celulară alcătuită dintr-un șir de neuroni identici, cuplați identic [DAV03a], [DAV03b], [DAV08]. Pentru prelucrarea unui semnal 1D pot fi folosite N celule ale unui RNC 1D. Starea $x(t,n)$ a fiecărei celule satisface ecuația diferențială:

$$\frac{dx(t,n)}{dt} = \sum_{k=-N}^N A_k x(t,n+k) + \sum_{k=-N}^N B_k u(t,n+k) \quad (3.1)$$

unde $A = [A_k]_{k=-N..N}$ și $B = [B_k]_{k=-N..N}$ reprezintă matricele de conexiune, iar N reprezintă raza vecinătății.

Modelul electric al unui RNC este prezentat în Fig 3.1. Considerând că ecuația (3.1) reprezintă teorema lui Kirchoff referitoare la curenții dintr-un nod, iar starea $x(t)$ reprezintă tensiunea de pe condensatoare, elementele matricei de conexiune devin surse de curent controlate în tensiune. În Fig. 3.1, t reprezintă variabila timp, iar n reprezintă numărul celulei ($n = 0..N - 1$).




Fig 3.1: Modelul electric al unei RNC liniare.

Pentru condiții la limită de tip periodic („ring”), folosind tehnicile de decuplare prezentate în [GOR95b], funcția de transfer spatio-temporală se definește ca fiind [DAV03a], [DAV03b]:

$$H(s, \omega_m) = \frac{X(s, \omega_m)}{U(s, \omega_m)} = \frac{B(\omega_m)}{s - A(\omega_m)}, \text{ where}$$

$$A(\omega_m) = \sum_{k=-N}^N A_k e^{j\omega_m k}, \quad B(\omega_m) = \sum_{k=-N}^N B_k e^{j\omega_m k} \quad (3.2)$$

$$\omega_m = \frac{2\pi}{M} m, \quad m=0 \dots M-1$$

Pentru $s=0$, caracteristica de frecvență a filtrului liniar devine:

$$H(\omega_m) = -\frac{B(\omega_m)}{A(\omega_m)} \quad (3.3)$$

Considerând relația (3.2), stabilitatea RNC-ului liniar este asigurată dacă:

$$\operatorname{Re}(A(\omega_m)) < 0 \quad \forall \omega_m \in [-\pi, \pi] \quad (3.4)$$

Presupunând că matricele $A = [A_k]_{k=-N..N}$ și $B = [B_k]_{k=-N..N}$, $B_k = 0$ pentru $k \neq 0$ au fost calculate astfel încât să aproximeze un filtru Gaussian, caracteristica de frecvență corespunzătoare filtrului de tip Gabor, se poate obține dacă se consideră schimbarea de variabilă $\omega \rightarrow \omega - \omega_{m_0}$. Se obțin astfel filtre Gabor a căror frecvență centrală devine ω_{m_0} .

$$H(\omega_m) \rightarrow H(\omega_m - \omega_{m_0}) = -\frac{B_0}{\sum_{k=-N}^N A_k e^{j(\omega_m - \omega_{m_0})k}} \quad (3.5)$$

Astfel elementele matricei de conexiuni A și variabilele de stare devin complexe:

$$A = [A_k e^{-jk\omega_{m_0}}]_{k=-N..N} \quad (3.6)$$

$$x(n, t) = x_r(n, t) + jx_i(n, t)$$

Dacă filtrul Gaussian este stabil, filtrul de tip Gabor rezultat este de asemenea stabil, deoarece deplasând caracteristica de frecvență a filtrului, partea reală a valorilor proprii va rămâne pozitivă, condițiile de stabilitate nemodificându-se.

În Fig 3.2 se prezintă modelul electric al rețelei neurale celulare care poate fi folosit la aproximarea filtrelor Gabor:




Fig.3.2 : Modelul electric al RNC-ului care aproximează filtrele de tip Gabor.

Câteva considerații privind structura rețele neurale celulare de tip Gabor 2D.

Până în prezent s-au prezentat posibilități de implementare ale rețelelor neurale celulare de tip Gabor numai pentru cazul 1D. Există însă posibilitatea implementării și de rețele neurale celulare 2D. Un dezavantaj al filtrării folosind structuri 2D este complexitatea crescută a circuitului, necesară în special dacă se dorește o aproximare cât mai bună a caracteristicii de frecvență a circuitului ceea ce presupune implementarea unor celule cu $N > 1$. Având în vedere proprietatea de separabilitate a filtrelor Gabor pe cele 2 direcții x și y, se poate evita folosirea rețelelor neurale celulare 2D prin filtrări succesive cu rețele neurale celulare 1D. Avantajul acestei implementări este complexitatea mai mică a celulei RNC-ului și numărul mai mic de conexiuni dintre celule, decât în cazul 2D.

Implementarea filtrării 2D se poate realiza prin filtrări 1D succesive: cu sau fără memorii digitale. Diferența dintre cele 2 metode constă în modul în care este făcută legătura între răspunsul filtrelor 1D aplicate pe liniile matricei de intrare și filtrele 1D care dau răspunsul pe coloane.

Structura cu memorii digitale este prezentată mai jos și este bazată pe filtre RNC 1D de tip Gabor:

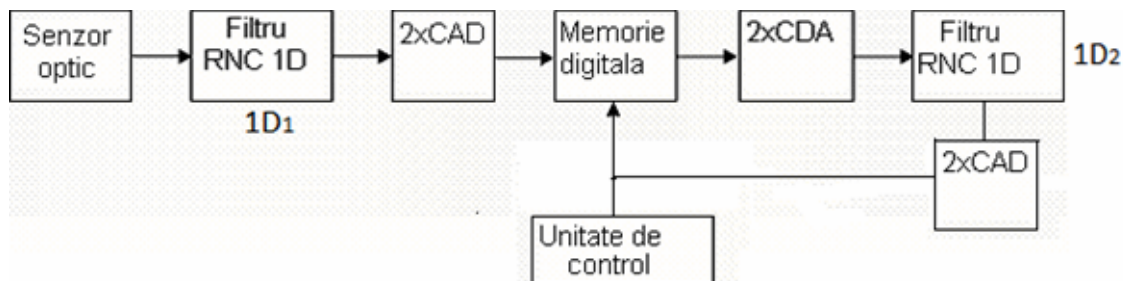


Fig 3.3: Structura cu memorii digitale a filtrului 2D de tip Gabor implementat prin filtrări succesive cu filtre 1D de tip Gabor.

Imaginea de intrare este aplicată linie cu linie primului filtru RNC 1D (1D1) Răspunsul de pe fiecare linie al filtrului 1D1 este convertită din analogic în digital

și stocată în memoria digitală. În Fig. 3.3 sunt necesare două convertoare CAD: unul pentru partea imaginară și unul pentru partea reală a răspunsului filtrului 1D1. După aceasta fază, fiecare coloană este citită din memorie, convertită de CDA și filtrată de cel de-al doilea filtru RNC 1D de tip Gabor (1D2). Valorile analogice astfel obținute sunt convertite în domeniul digital și stocate în memoria digitală pentru prelucrări ulterioare. Această operație este continuată coloană cu coloană.

Pentru implementarea convertoarelor analog-digitale și digital-analogice pot fi folosite soluțiile date în [TAN00]. De asemenea, pot fi folosite soluțiile de procesare paralelă prezentate.

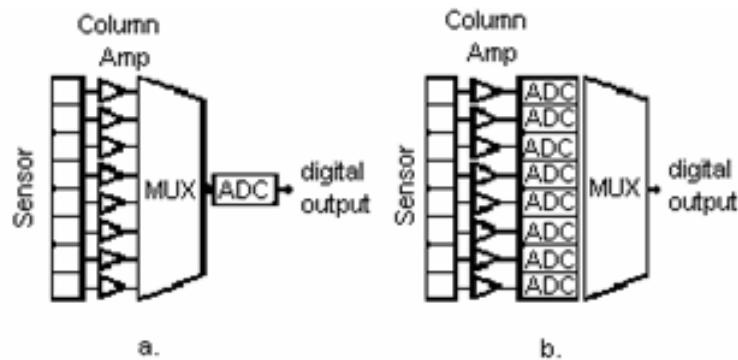


Fig 3.4: Structuri de procesare paralelă pentru conversia analog-digitală.

Convertorul digital analog va converti cuvintele digitale valoare cu valoare. În această situație se poate folosi un sir de capacități, amplificatoare și întrerupătoare analogice astfel încât valorile analogice să ajungă, la intrarea filtrului 1D₂ toate în același timp.

Structura filtrului 1D₁ poate fi la fel ca cea din Fig. 3.3. Structura celui de-al doilea filtru 1D₂, va fi puțin diferită față de 1D₁, deoarece va avea 2 intrări: una pentru partea reală și una pentru partea imaginară a răspunsului filtrului 1D₁.

Modelul electric al celulei 1D₂ este:




Fig 3.5: Modelul electric al filtrului 1D₂

Principalul dezavantaj al implementării cu memorii digitale este că trebuie să se utilizeze memorii digitale, convertoare analog-digitale și digital-analogice și unitatea de control. De asemenea, timpul de conversie nu este cel mai mic posibil.

Cea de-a doua metodă de implementare a filtrării 2D, prin filtrări succesive 1D, este structura fără memorii digitale. Principalul avantaj al acestei structuri este că filtrarea Gabor se realizează numai în domeniul analogic.

Structura unui astfel de circuit este schițată în Fig. 3.6 [DAV06].




Fig 3.6: Structura filtrului de tip Gabor 2D fără memorii digitale.

Leșirea senzorului optic este o matrice $N \times N$. Fiecare linie a acestei matrice este aplicată la intrarea a N filtre 1D de tip Gabor. Acestea alcătuiesc primul „plan” de filtre de tip Gabor. Leșirile acestui „plan” sunt o matrice de tipul $N \times N$ a cărei valori sunt numere complexe. Coloanele acestei matrice vor fi intrări pentru un al doilea plan de filtre 1D de tip Gabor. Aceste filtre vor avea 2 intrări: una pentru partea reală și una pentru partea imaginară.

Avantajul implementării filtrării 2D prin filtrări succesive 1D, este complexitatea mai mică a celulei RNC-ului 1D în comparație cu RNC-ul 2D. De asemenea, numărul de interconexiuni dintr-un punct este mult mai mic. Avantajul structurii cu memorii digitale este că numai 2 filtre 1D de tip Gabor trebuie integrate pe chip. Dezavantajul constă în necesitatea prezenței convertoarelor analog-digitale, digital-analogice, a memoriei digitale și a unității de control. Avantajul structurii fără memorii digitale este că toate calculele se fac în domeniul analogic, ceea ce conduce la un timp de calcul minim. Dezavantajul este legat de faptul că trebuie integrate pe chip $2 \times N$ filtre 1D.

III.2 Implementarea filtrelor Gabor folosind filtre digitale recursive.

Presupunând coeficienții filtrului Gaussian calculați folosind aproximarea Padé sau Padé-Chebyshev prezentate în capitolul II, caracteristicile de frecvență pot fi scrise astfel [DAV05]:

$$H_N(\omega) = \frac{1}{\sum_{k=-N}^N a_k e^{j\omega k}}, \quad e^{j\omega} = z, \quad a_k = a_{-k} \Rightarrow \quad (3.7)$$

$$H_N(z) = \frac{1}{\sum_{k=-N}^N a_k z^k} = \frac{z^N}{a_N z^{2N} + a_{N-1} z^{2N-1} + \dots + a_{N-1} z^1 + a_N}$$

Deoarece numitorul lui $H(z)$ este invariant la schimbarea de variabilă $z^k \rightarrow z^{-k}$ iar polii funcției de transfer sunt în perechi reciproce așa cum se prezintă Fig. 3.7.




Figura 3.7: Reprezentarea poli-zerouri a lui $H_N(z)$ pentru $N=3$ și $\sigma = 2, \dots, 8$.

Funcția de transfer a unui filtru de tip Gabor poate fi scrisă ca în relația (3.8) și în acest caz reprezentarea poli-zerouri din Figura 3.7 este rotită cu unghiul Ω_0 în jurul originii planului complex [DAV05].

$$H_N(z \cdot e^{-j\Omega_0}) = \frac{z^N e^{-jN\Omega_0}}{c \prod_{k=1}^N (z \cdot e^{-j\Omega_0} - \lambda_k)(z \cdot e^{-j\Omega_0} - 1/\lambda_k)} \quad (3.8)$$

Funcția de transfer a filtrului de tip Gabor poate fi exprimată ca o sumă (rezultând o implementare paralelă) sau ca un produs (rezultând o implementare serie) a două funcții de transfer: una cauzală și stabilă ($H_{s,p+}(z \cdot e^{-j\Omega_0})$), care are

polii în interiorul cercului unitate și una anti-cauzală și stabilă ($H_{s,p-}(z \cdot e^{-j\Omega_0})$) care are polii în exteriorul cercului unitate [DAV05].




Figura 3.8: Implementare serie și paralelă pentru un filtru de tip Gabor.

În cazul folosirii implementării serie, coeficienții funcției de transfer $H_{s+}(z \cdot e^{-j\Omega_0})$ și $H_{s-}(z^{-1} \cdot e^{-j\Omega_0})$ sunt complex conjugați, funcțiile de transfer cauzale și anti-cauzale putând fi scrise ca:

$$H_{s+}(z \cdot e^{-j\Omega_0})H_{s-}(z \cdot e^{-j\Omega_0}) = \frac{1}{\left(\sum_{k=0}^N b_k e^{jk\Omega_0} z^{-k}\right) \left(\sum_{k=0}^N b_k e^{-jk\Omega_0} z^k\right)} \quad (3.9)$$

Deoarece filtrele anti-cauzale nu pot fi implementate prin structuri recursive, a fost folosită metoda filtrării înainte-înapoi (forward-backward) ([11], [12], [6]). Semnalul de intrare, $in[n]$ este mai întâi filtrat de filtrul cauzal $H_{s+}(z \cdot e^{-j\Omega_0})$. Rezultatul, $w[n]$ este inversat în oglindă ($w[n] \rightarrow w[N-n]$), filtrat de $H_{s-}(z^{-1} \cdot e^{-j\Omega_0})$ iar semnalul rezultat este inversat din nou $out[N-n] \rightarrow out[n]$.

Ecuțiile cu diferențe ale implementării seriale a filtrului cauzal și anti-cauzal sunt (3.10) și respectiv (3.11):

$$w[n] = in[n] + \left(\sum_{k=1}^N b_k e^{-jk\omega_0} w[n-k]\right) / b_0 \quad (3.10)$$

$$out[n] = w[n] + \left(\sum_{k=1}^N b_k e^{-jk\omega_0} out[n+k]\right) / b_0 \quad (3.11)$$

Dacă este folosită implementarea paralelă, funcția de transfer $H(z \cdot e^{-j\Omega_0}) / z$ este despărțită în două fracții simple, corespunzătoare polilor $\lambda_k \cdot e^{-j\Omega_0}$ și $1 / \lambda_k \cdot e^{-j\Omega_0}$ (3.8). Funcțiile de transfer $H_{p+}(z \cdot e^{-j\Omega_0})$ și $H_{p-}(z \cdot e^{-j\Omega_0})$ au fost calculate prin sumarea fracțiilor simple care au polii $\lambda_k \cdot e^{-j\Omega_0}$ și respectiv $1 / \lambda_k \cdot e^{-j\Omega_0}$.

De asemenea, se folosește o metodă de tipul filtrării înainte-înapoi asemănătoare implementării serie: semnalul de intrare este inversat în oglindă ($in[n] \rightarrow in[N-n]$), filtrat de $H_{p-}(z^{-1} \cdot e^{-j\Omega_0})$ iar ieșirea este inversată din nou

($w_2[N-n] \rightarrow w_2[n]$). Ecuațiile cu diferențe, sunt asemănătoare cu relațiile (3.10) și (3.11) prezentate mai sus.

Pentru a compara rezultatele obținute cu cele din [YOU02], am calculat eroarea absolută maximă a răspunsului la impuls pentru $\sigma = 2..8$ și $N=1, 2, 3$. În Fig. 3.9 se prezintă variația erorii maxime absolute a răspunsului la impuls al unui filtru de tip Gabor.

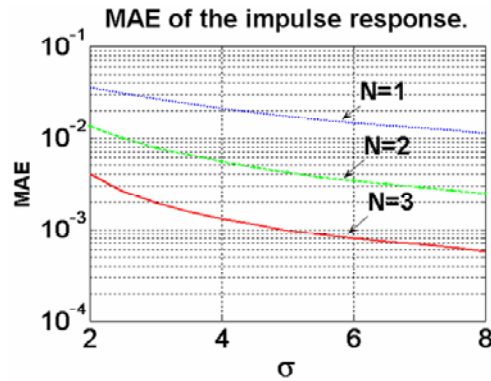



Figura 3.9: Eroarea absolută maximă a răspunsului la impuls al unui filtru implementat folosind aproximarea Padé-Chebyshev.

Comparativ cu rezultatele obținute în [YOU02], implementarea folosind aproximarea Pade-Chebyshev oferă performanțe mai bune, existând posibilitatea să se scadă ordinul filtrului cu o unitate în condițiile în care erorile de aproximare sunt aceleași.

În Fig. 3.10 se prezintă răspunsul la impuls (partea reală și partea imaginară) a unui filtru de tip Gabor și respectiv transformata Fourier corespunzătoare pentru $N=1,2,3$ și $\sigma = 8$:



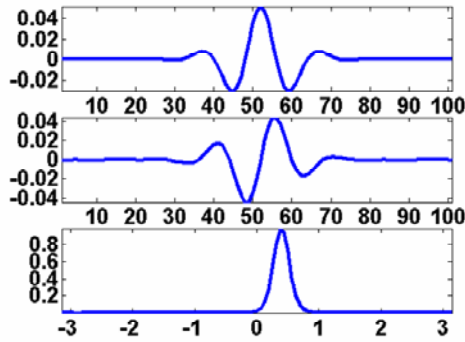


Fig 3.10: Răspunsul la impuls (partea reală și partea imaginară) și DFT corespunzătoare pentru $N=1,2,3$ și $\sigma = 8$

În Fig. 3.11 și Fig. 3.12 se prezintă răspunsurile la impuls și DFT corespunzătoare ale unui filtru de tip Gauss 2D (implementat prin filtrări succesive pe linii și apoi pe coloane) care are $\sigma = 8$ și implementat pentru $N=1, 2$ și 3 .




Fig. 3.11 Răspunsul la impuls al unui filtru de tip Gauss implementat recursiv obținut folosind o aproximare de tip Pade, pentru $N=1,2,3$, și $\sigma = 8$




Fig. 3.12: DFT a răspunsurilor la impuls prezentate în Fig. 3.11.

Complexitatea calculului este de $O(2*N+1)$ adunări și înmulțiri complexe pe pixel pentru o filtrare 1D și de două ori mai mare pentru o filtrare 2D. Pentru a filtra un semnal de M eșantioane, complexitatea algoritmului este: $O((2*N+1)*M)$. Principalul avantaj al metodei prezentate este numărul mic de operații în comparație cu algoritmul FFT care are complexitatea $O(M \log_2(M))$ mai ales pentru cazul imaginilor de înaltă rezoluție.

Concluzii

În acest capitol s-au prezentat posibilitățile de implementare ale filtrelor Gabor folosind RNC analogice și s-a analizat administrarea datelor în structuri analogice. De asemenea s-a analizat posibilitatea utilizării filtrelor digitale și a tehnicilor de filtrare înainte-înapoi pentru implementarea filtrelor Gabor, obținându-se rezultate mai bune decât cele raportate până în prezent în literatura de specialitate în cazul folosirii aproximării Pade-Chebyshev. De asemenea, având în vedere faptul că filtrele au fost implementate folosind filtre IIR, este probabil cea mai rapidă metodă de a implementa filtre Gabor. Numărul adunărilor și multiplicărilor nu depinde de rezoluția imaginii ca în cazul utilizării algoritmului FFT ci numai de ordinul filtrului.

Capitolul IV. - APLICAȚII ALE FILTRELOR SPAȚIALE DE TIP GABOR

În capitolele II și III au fost prezentate modalitățile de proiectare și implementare a filtrelor Gabor. Din analiza prezentată au rezultat performanțele filtrelor atât din punct de vedere al acurateții aproximării cât și din punct de vedere al timpului de calcul (pentru sistemele analogice) și al numărului de adunări și înmulțiri (pentru sistemele digitale). Din aceste puncte de vedere, metodele propuse au dat rezultate comparabile și chiar mai bune față de cele din literatura de specialitate. Cu toate că în literatura de specialitate s-au propus structuri de filtre rapide atât analogice cât și digitale, au fost puțin studiate performanțele acestor filtre în aplicații de prelucrare a imaginilor. De aceea, s-au studiat metodele care să ofere posibilitatea realizării unor filtrări rapide fără a compromite comportarea filtrelor în domeniul frecvență și în consecință a sistemului de recunoaștere a texturilor. În acest capitol se vor analiza performanțele filtrelor proiectate și implementate în capitolele II și III, comparativ cu filtrele Gabor ideale, în două dintre aplicațiile cele mai cunoscute din domeniul prelucrării imaginilor: recunoașterea texturilor și detecția conturilor. Rezultatele s-au comparat cu cele obținute în cazul utilizării filtrelor Gabor ideale.

IV.1 Recunoașterea texturilor utilizând trăsături extrase cu filtre Gabor

În literatura de specialitate texturile reprezintă imagini din natură care se definesc prin repetarea unor structuri de bază numite texteli. În funcție de tipul textelului rezultă un spectru al imaginii specific unui anumit tip de textură.

Având în vedere faptul că filtrele Gabor sunt capabile să filtreze numai o zonă din planul (ω_x, ω_y) al frecvențelor, atunci fiecare filtru Gabor va extrage informația specifică corespunzătoare spectrului texturii din zona respectivă.




Fig. 4.1 a) Partea reală a răspunsului la impuls a unui banc de filtre Gabor care are patru orientări și trei frecvențe; b) Conturul transformatei Fourier a bancului de filtre Gabor corespunzător jumătății din amplitudinea maximă

Pentru fiecare imagine filtrată se calculează momentele de ordin superior rezultând astfel un vector de trăsături. Partea reală a răspunsului la impuls, și conturul caracteristicii de frecvență a unui banc de filtre sunt reprezentate în Fig. 4.1.

Pentru extragerea trăsăturilor din imagini conținând texturi și utilizarea acestora în aplicații de recunoaștere se poate folosi o abordare similară cu cele prezentate în [MAN00a]. Astfel, o imagine $U^k[i, j]$ filtrată cu un banc de filtre Gabor va genera un număr de imagini complexe $X_{uv}^k[i, j]$ egal cu numărul de filtre. Pentru imaginea $U^k[i, j]$, imaginile complexe rezultate generează un vector de trăsături ale cărui componente reflectă conținutul energetic corespunzător benzii de frecvență a bancului de filtre.

$$\begin{aligned}
 m_{uv}^k &= \frac{1}{M_1 M_2} \sum_{i=1}^{M_1} \sum_{j=1}^{M_1} |X_{uv}^k[i, j]| \\
 \sigma_{uv}^k &= \sqrt{\frac{1}{M_1 M_2} \sum_{i=1}^{M_1} \sum_{j=1}^{M_1} (|X_{uv}^k[i, j]| - m_{uv}^k)^2} \\
 v &= 0, \dots, M-1, u = 0, \dots, N_o-1 \\
 \vec{f}^k &= [m_{00}^k, \sigma_{00}^k, \dots, m_{uv}^k, \sigma_{uv}^k, \dots, m_{M-1N_o-1}^k, \sigma_{M-1N_o-1}^k]^T
 \end{aligned} \tag{3.12}$$

În [MAN00a] s-a considerat că o măsură relevantă a unui anumit tip de textură este conținutul energetic al imaginii filtrate iar o măsură a nivelului energetic s-a considerat a fi media și deviația standard a imaginilor filtrate. Rezultă astfel un vector de trăsături \vec{f}_k dat de următoarele relații (3.12), unde M și N_o sunt numărul de scale și respectiv de orientări ale filtrelor.

Pentru clasificare se pot folosi metode simple bazate pe regula celui mai apropiat vecin din punct de vedere al unei distanțe $d_{kl} = \|\vec{f}^k - \vec{f}^l\|$ (Manhattan (D1) sau Euclidiană (D2)).

Imaginile folosite în experimente constau în 111 tipuri de texturi Brodatz [BRO66], fiecare fiind divizată în imagini nesuprapuse de 160x160 pixeli. Pentru a se analiza cât mai bine trăsăturile extrase cu bancurile de filtre, pentru toate tipurile de texturi, s-au calculat distanțele în spațiul trăsăturilor dintre toate imaginile. În funcție de fiecare distanță s-a luat în considerare ca metodă de clasificare regula celui mai apropiat vecin [DAV06], [DAV07]. S-au luat în considerare cei mai apropiați 15 vecini pentru fiecare imagine. Performanțele, considerate ca rate de recunoaștere, au fost evaluate ca procentul de imagini care au cel mai apropiat vecin aparținând claselor de textură corespunzătoare

(RR). Similar, s-a considerat și procentajul mediu al texturilor aparținând clasei corecte din 15 vecini pentru fiecare imagine (ARR15).

Performanțele de recunoaștere a texturilor folosind bancuri de filtre de tip Gabor implementate cu RNC

Pentru evaluarea și compararea ratelor de recunoaștere s-au folosit filtre de tip Gabor 2D separabile, implementate cu RNC [DAV03a], [DAV03b]. Filtrele au fost considerate ideale în sensul în care nu au fost luate în considerare variațiile inerente ale parametrilor ce caracterizează sistemele analogice. În Tabelul 4.1 sunt prezentate ratele de recunoaștere obținute folosind distanța Euclidiană pentru filtrele ideale împreună cu cele implementate cu RNC. Au fost considerate diverse ordine de aproximare ale funcțiilor ideale precum și bancuri de filtre cu diferite orientări și scale.


După cum se poate observa în Tabelul 4.1, ratele de recunoaștere nu cresc într-un mod semnificativ la creșterea numărului de scale și orientări, deși ARR15 este mai sensibilă [DAV06], [DAV08]. Motivul pentru care ARR15 are rezultate mai slabe este că anumite trăsături ale unor tipuri de texturi sunt mai aproape de trăsăturile altor clase decât cele ale texturilor proprii clase

<i>Tipul Filtrului</i>	M, N_o	<i>ARR</i> %	<i>ARR15</i> %
De tip Gabor Ideal	4,5	86,71	63,17
De tip Gabor N=1	4,5	86,31	57,27
De tip Gabor N=2	4,5	87,01	62,47
De tip Gabor N=3	4,5	87,01	63,07
Gabor Ideal	4,6	86,54	64,06
De tip Gabor N=1	4,6	85,64	58,16
De tip Gabor N=2	4,6	87,04	62,96
De tip Gabor N=3	4,6	86,74	63,16
Gabor Ideal	5,5	86,26	64,16
De tip Gabor N=1	5,5	84,46	59,36
De tip Gabor N=2	5,5	86,06	63,46
De tip Gabor N=3	5,5	85,76	63,76
Gabor Ideal	5,6	86,48	65,04
De tip Gabor N=1	5,6	85,08	59,94
De tip Gabor N=2	5,6	87,18	63,74
De tip Gabor N=3	5,6	86,88	64,54

Tabelul 4.1: Ratele de recunoaștere pentru diferite bancuri de filtre

Acest lucru se întâmplă în mod special în cazul texturilor care au o aparență neregulată. În general astfel de texturi dau rate de recunoaștere mai mici în cazul

marii majorității a sistemelor de recunoaștere a texturilor, unele dintre ele fiind dificil de clasificat chiar și de către om.



D21

D44

Fig. 4.2 Exemple de texturi pentru care se obțin ratele de recunoaștere cele mai bune și cele mai slabe

Pentru a ilustra acest aspect, în Fig. 4.2 sunt reprezentate două texturi pentru care s-au obținut ratele de recunoaștere cele mai bune $ARR_{15}=100\%$ (D21) și cele mai slabe $ARR_{15}<10\%$ (D44).

Performanțele de recunoaștere a texturilor folosind bancuri de filtre de tip Gabor implementate cu filtre numerice recursive

Pentru experimentele realizate s-au folosit filtre recursive 2D de tip Gabor proiectate folosind aproximarea Padé și implementate în ambele variante: serială și paralelă. Se consideră condiții inițiale nule [DAV05]. Pentru a vedea care sunt efectele distanței folosite asupra rezultatelor de recunoaștere, prezentate în Tabelul 4.2, s-au folosit distanța Euclidiană (D2) și distanța Manhattan (D1).

La fel ca în cazul filtrelor de tip Gabor implementate cu RNC, se poate observa că ratele de recunoaștere nu cresc în mod semnificativ cu numărul de orientări și scale.

De asemenea distanțele sau modalitatea de implementare a filtrelor (serială sau paralelă) nu influențează rezultatele [DAV07]. Cele mai bune rezultate se obțin în cazul utilizării distanței Manhattan și a implementării seriale. De asemenea, ratele de recunoaștere sunt mai mici pentru filtre de ordin $N=1$ și tind să fie egale cu cele obținute cu filtrele ideale la creșterea ordinului ($N=2, 3$).

Tipul filtrului	M, N_o	RR%		ARR15%	
		D1	D2	D1	D2
Gabor Ideal	4,5	87.33	86.71	65	63.17
Gabor Serial N=1	4,5	83.0	83.72	54.7	55.33
Gabor Serial N=2	4,5	87.27	86.76	63.1	62.1
Gabor Serial N=3	4,5	87.5	86.48	64.53	63.11
Gabor Paralel N=1	4,5	82.31	83.44	54.72	55.28
Gabor Paralel N=2	4,5	86.71	86.76	63.02	62.07
Gabor Paralel N=3	4,5	86.88	86.59	64.6	63.04

Gabor Ideal	4,6	86.71	86.54	65.75	64.06
Gabor Serial N=1	4,6	83.05	84.06	55.34	56.08
Gabor Serial N=2	4,6	86.71	86.88	63.87	63.01
Gabor Serial N=3	4,6	87.16	86.31	65.29	63.81
Gabor Paralel N=1	4,6	82.88	83.72	55.25	56.02
Gabor Paralel N=2	4,6	86.26	86.31	63.65	63.07
Gabor Paralel N=3	4,6	86.48	86.48	65.27	63.78
Gabor Ideal	5,5	87.21	86.26	66.14	64.16
Gabor Serial N=1	5,5	84.06	84.17	57	57.63
Gabor Serial N=2	5,5	86.59	86.88	64.56	63.18
Gabor Serial N=3	5,5	86.82	85.92	65.72	63.95
Gabor Paralel N=1	5,5	83.55	84.51	57.05	57.68
Gabor Paralel N=2	5,5	87.16	86.03	64.57	63.26
Gabor Paralel N=3	5,5	86.54	85.97	65.78	63.94
Gabor Ideal	5,6	86.88	86.48	66.86	65.04
Gabor Serial N=1	5,6	84.40	84.68	57.87	58.38
Gabor Serial N=2	5,6	87.04	86.88	65.35	64.14
Gabor Serial N=3	5,6	86.99	86.26	66.4	64.74
Gabor Paralel N=1	5,6	83.38	84.34	57.86	58.42
Gabor Paralel N=2	5,6	86.71	87.04	65.31	64.21
Gabor Paralel N=3	5,6	86.59	86.43	66.43	64.87

Tabelul 4.2: Ratele de recunoaștere pentru diferite bancuri de filtre și distanțe

Comparativ cu alte rezultate raportate în literatura de specialitate, rata de recunoaștere este cu 9% mai mică decât cele raportate în [MAN00a]. Acesta fapt poate avea două explicații. În primul rând, baza de date utilizată în [MAN00a] conține un număr suplimentar de texturi care nu fac parte din baza de date publică. De asemenea, s-a utilizat o altă metodă de proiectare a bancului de filtre de tip Gabor iar vectorii de trăsături nu au mai fost normalizați la deviația standard a fiecărui tip de trăsătură pe întreaga baza de date așa cum se exemplifică în relația (3.13). În experimentele noastre, normalizarea trăsăturilor ca în (3.13) duce la scăderea ratelor de recunoaștere cu aproximativ 5%.

$$\vec{f}^k = \left[\frac{m_{00}^k}{std(m_{00}^k)}, \frac{\sigma_{00}^k}{std(\sigma_{00}^k)}, \dots, \frac{m_{M-1, N_o-1}^k}{std(m_{M-1, N_o-1}^k)}, \frac{\sigma_{M-1, N_o-1}^k}{std(\sigma_{M-1, N_o-1}^k)} \right] \quad (3.13)$$

IV.2 Detecția conturilor folosind bancuri de tip Gabor implementate cu filtre de tip IIR.

Majoritatea algoritmilor de detectare a conturilor sunt bazați pe determinarea gradientului imaginii. Principalul dezavantaj al acestui tip de algoritm este că nu oferă cele mai bune rezultate, putând fi afectat de zgomot. O

altă metodă este bazată pe ideea că trăsăturile apar acolo unde componentele seriei Fourier sunt în faza (congruența fazei, “phase congruency”). Această metodă a fost dezvoltată de Morrone și Kovesi [KOV99]. De asemenea, Morrone și Burr au arătat că această metodă este asemănătoare cu modul în care sistemul vizual uman percepe imaginile.

Pentru a determina conținutul spectral din jurul unui anumit pixel, Kovesi a propus să se utilizeze un banc de filtre wavelet de tip log Gabor. Se cunoaște că răspunsul filtrelor Gabor este mai puțin afectat de zgomot. Dacă I_e și respectiv I_o reprezintă partea reală și respectiv imaginară a răspunsului filtrelor Gabor, se definește parametrul:

$$PC(i, j) = \frac{\sqrt{\left(\sum_{n,m} I_{e,n,m}(i, j)\right)^2 + \left(\sum_{n,m} I_{o,n,m}(i, j)\right)^2}}{\sum_{n,m} \sqrt{I_{e,n,m}(i, j)^2 + I_{o,n,m}(i, j)^2} + \varepsilon} \quad (3.14)$$

unde n reprezintă scala filtrelor iar m orientarea lor. Constanta ε are valoare mică (0.001) și are rolul de a evita posibilele împărțiri prin 0 în cazul în care răspunsul filtrelor are amplitudine mică.


Rezultate experimentale

Pentru simulări nu s-au utilizat filtre log Gabor, ci filtrele definite prin relația (3.14) implementate prin structuri de tip IIR:

$$G(\omega_x, \omega_y) = \exp\left(-\frac{(\omega_x - \pi \cdot a^{-n-1} \cdot \cos(\varphi_m))^2 (\mu \cdot a^{n+1})^2}{2} - \frac{(\omega_y - \pi \cdot a^{-n-1} \cdot \cos(\varphi_m))^2 (\mu \cdot a^{n+1})^2}{2}\right) \quad (3.15)$$

unde $n=0, \dots, 2$ reprezintă numărul scalelor iar $m=0, \dots, 5$ reprezintă numărul orientărilor. Pentru o mai bună acoperire a spațiului frecvențelor pentru parametrii a și μ s-au considerat valorile 1.6 și respective 1.7.

În Fig. 4.3 sunt prezentate imaginile procesate folosind: metoda propusă de Kovesi, același algoritm dar filtrele log Gabor au fost înlocuite cu filtre Gabor ideale și imaginile rezultate în urma folosirii filtrelor Gabor implementate cu structuri de tip IIR [DAV05].






Fig. 4.3: a) Imaginea originală, b) contururile detectate folosind filtre log Gabor ideale, c) contururile detectate folosind filtre Gabor ideale, d) contururile detectate folosind filtre implementate cu filtre IIR (N=1), e) contururile detectate folosind filtre implementate cu filtre IIR (N=2), f) contururile detectate folosind filtre implementate cu filtre IIR (N=3)

Concluzii

În acest capitol au fost prezentate rezultatele obținute cu filtrele de tip Gabor care au fost proiectate și implementate în capitolele II și respectiv capitolul III, în cadrul unei aplicații de recunoaștere a texturilor. Pentru simulări s-a folosit baza de date publică Brodatz. Rezultatele au arătat că atât filtrele implementate cu rețele neuronale celulare cât și cele implementate numeric cu filtre de tip IIR, dau rezultate aproximativ egale în cazul în care s-au folosit pentru preprocesare filtre Gabor ideale, chiar și pentru N=1. Astfel, s-au oferit soluții pentru situațiile în care numărul mare de operații afectează un sistem de recunoaștere al texturilor. De asemenea, rezultatele obținute sunt apropiate de cele din literatura de specialitate în care s-au folosit, pentru extragere de trăsături, filtre ideale.

În domeniul detecției contururilor, performanțele în cazul folosirii filtrelor de tip Gabor implementate cu structuri IIR sunt asemănătoare cu cazul folosirii filtrelor log Gabor sau Gabor ideale. De asemenea, din punctul de vedere al performanțelor, nu există deosebiri între filtrele separabile și cele neseperabile.

Capitolul V. - EXTRAGEREA TRĂSĂTURILOR FOLOSIND REȚELE NEURALE CELULARE DE TIP DUBLU STRAT

V.1 Noțiuni generale privind rețelele neurale de tip dublu strat

Un fenomen care s-a demonstrat că apare în rețelele neurale celulare este cel al formării patern-urilor (“pattern formation”). Pattern-ul reprezintă starea la care ajunge rețeaua neurală celulară (RNC) la echilibru. Există conexiuni și cu alte domenii cum ar fi biologia; un mecanism asemănător fiind descris de Turing ([TUR52],[MUR93]) pentru a explica morfogeneza ([MUR93]). Funcționarea RNC-ului de tip dublu strat a fost prezentată în ([GOR95a], [GOR95b]). În figura 5.1 se prezintă o RNC capabilă să producă forme de tip Turing ([GOR95b]). Aceasta este alcătuită din celule de ordin 2 cu două porți care se află între două straturi de rezistențe, fiecare strat conectând porți similare.




Figura 5.1: Arhitectura din două straturi de celule.

În figura 5.2 se prezintă o posibilă realizare a celulei RNC, alcătuită din patru elemente liniare (două condensatoare, o rezistența și o sursă de curent comandată în tensiune) și o rezistență neliniară. Analiza sistemului este simplificată dacă se analizează funcționarea celulelor în zona liniară a caracteristicii. Ecuațiile de funcționare ale celulei sunt:

$$\begin{aligned} i_1 &= f(u, v) = -Gu - f(u) + Gv \\ i_2 &= \tilde{g}(u, v)i_1 = (G - g)u - Gv \end{aligned} \tag{5.1}$$




Figura 5.2: Celulă cu două porturi și caracteristica curent/tensiune a rezistorului neliniar.

În relațiile (5.1), $f(u)$ reprezintă caracteristica rezistorului neliniar.

În cazul general, funcționarea unei RNC de tip dublu strat, compusă din MN celule poate fi descrisă de următorul sistem de $2MN$ ecuații diferențiale ordinare neliniare:

$$\begin{cases} \frac{du_{ij}(t)}{dt} = \gamma f(u_{ij}, v_{ij}) + D_u \nabla^2 u_{ij} \\ \frac{dv_{ij}(t)}{dt} = \gamma g(u_{ij}, v_{ij}) + D_v \nabla^2 v_{ij} \end{cases}, \quad i = 0, \dots, M-1, j = 0, \dots, N-1 \quad (5.2)$$

unde: $\nabla^2 x_{ij} = x_{(i+1)j} + x_{(i-1)j} + x_{i(j+1)} + x_{i(j-1)} - 4x_{ij}$ este Laplacianul. Pentru cazul RNC 1-D Laplacianul este: $\nabla^2 x_i = x_{i+1} + x_{i-1} - 2x_i$ [GOR95b]. Parametrii D_u și D_v se numesc parametri de difuzie și sunt definiți prin: $D_u = G_u / C_u$ și $D_v = G_v / C_v$.

Pentru analiza RNC, se linearizează sistemul de ecuații (5.2) în jurul punctului de echilibru (U_0, V_0) , a fiecărei celule, rezultând un sistem de ecuații diferențiale ordinare liniare:

$$\begin{cases} \frac{du_{ij}(t)}{dt} = \gamma(f_u u_{ij} + f_v v_{ij}) + D_u \nabla^2 u_{ij} \\ \frac{dv_{ij}(t)}{dt} = \gamma(g_u u_{ij} + g_v v_{ij}) + D_v \nabla^2 v_{ij} \end{cases} \quad (5.3)$$

unde f_u, f_v, g_u, g_v sunt elementele matricii Jacobiene ale funcțiilor $f(u, v)$ și $g(u, v)$ corespunzătoare punctului de echilibru (U_0, V_0) .

În cazul general, soluția unui astfel de sistem de $2MN$ ecuații diferențiale este:

$$X(t) = \sum_{i=0}^{2MN-1} \langle r_i, X(0) \rangle e^{\lambda_i t} Q_i \quad (5.4)$$

unde $X(t) = [u_0 \ u_1 \dots \ u_{N-1} \ v_0 \ v_1 \dots \ v_{N-1}]^T$ reprezintă vectorul de stare, λ_i și Q_i reprezintă valorile proprii simple și respectiv vectorii proprii ai matricii sistemului, r_i reprezintă baza reciprocă corespunzătoare matricii sistemului iar $X(0)$ reprezintă condițiile inițiale. Pentru ca RNC să fie stabilă ar trebui ca toate valorile proprii să fie negative. În cazul în care una dintre valorile proprii este pozitivă, sistemul devine instabil, evoluția sistemului limitându-se pe caracteristica neliniară a rezistorului.

În cazul în care toate celulele funcționează în regiunea liniară a caracteristicii analiza este simplificată datorită liniarității și simetriei. Analiza circuitului este valabilă în regiunea liniară a caracteristicii, înainte ca celulele să între în saturație. După ce amplitudinea formelor atinge neliniaritatea, determinarea evoluției nu mai este posibilă. În Fig. 5.3, se prezintă evoluția formelor de pe unul

din cele două straturi în raport cu timpul pentru cazul în care RNC 1D este stabil (a) și respectiv instabil (b).

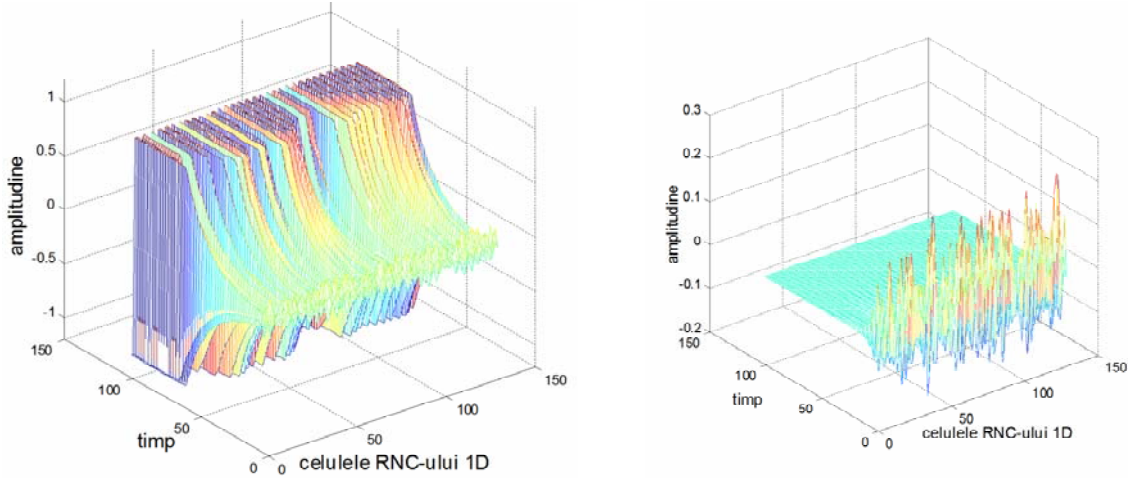


Fig. 5.3: a) RNC instabil și b) RNC stabil

Dinamica circuitului în regiunea liniară a fost studiată folosind tehnica decuplării [GOR95b] prin care sistemul de $2MN$ ecuații diferențiale cuplate s-a transformat în MN sisteme necuplate de ecuații diferențiale de ordinul I, de două variabile. Astfel soluția sistemului de ecuații (5.3) este alcătuită prin sumarea ponderată a M funcții $\Phi_M(m, i)$ care reprezintă funcțiile proprii ale Laplacian-ului discret.

Soluția sistemului de ecuații (5.3) are forma:

$$\begin{cases} u_i(t) = \sum_{m=0}^{M-1} \Phi_M(m, i) \cdot \hat{u}_m(t) \\ v_i(t) = \sum_{m=0}^{M-1} \Phi_M(m, i) \cdot \hat{v}_m(t) \end{cases}, i = 0..M - 1 \quad (5.5)$$

În sistemul de ecuații (5.5), $\hat{u}_m(t)$ și $\hat{v}_m(t)$ reprezintă spectrul semnalelor $u_i(t)$ și $v_i(t)$ în raport cu baza ortonormată dată de funcțiile proprii $\{\Phi_M(m, i), m = 0..M - 1, i = 0..M - 1\}$. Astfel, dinamica RNC 1D este descrisă de următorul set de ecuații [GOR95b]:

$$\begin{bmatrix} \dot{\hat{u}}_m \\ \dot{\hat{v}}_m \end{bmatrix} = \left(\gamma \begin{bmatrix} f_u & f_v \\ g_u & g_v \end{bmatrix} - k_m^2 \begin{bmatrix} D_u & 0 \\ 0 & D_v \end{bmatrix} \right) \begin{bmatrix} \hat{u}_m \\ \hat{v}_m \end{bmatrix}, m = 0..M - 1 \quad (5.6)$$

Soluția sistemului de ecuații (5.6) este de forma (5.7), unde constantele a_m, b_m, c_m, d_m depind de condițiile inițiale ($X(0)$):

$$\begin{cases} \hat{u}_m(t) = a_m e^{\lambda_{m_1} t} + b_m e^{\lambda_{m_2} t} \\ \hat{v}_m(t) = c_m e^{\lambda_{m_1} t} + d_m e^{\lambda_{m_2} t} \end{cases} \quad (5.7)$$

În sistemul de ecuații (5.7), λ_{m_1} și λ_{m_2} sunt soluțiile ecuației:

$$\det \left\{ \lambda_m \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} - \gamma \begin{bmatrix} f_u & f_v \\ g_u & g_v \end{bmatrix} + k_m^2 \begin{bmatrix} D_u & 0 \\ 0 & D_v \end{bmatrix} \right\} = 0 \quad (5.8)$$

Se obține astfel polinomul caracteristic al sistemului:

$$\begin{aligned} \lambda_m^2 + \lambda_m [k_m^2 (D_u + D_v) - \gamma (f_u + g_v)] + D_u D_v k_m^4 - \\ - \gamma (D_v f_u + D_u g_v) k_m^2 + (f_u g_v - f_v g_u) = 0 \end{aligned} \quad (5.9)$$

Dinamica unei RNC este determinată în principal de rădăcinile polinomului caracteristic, chiar dacă rezultatele analizei sunt valabile numai pentru zona liniară a caracteristicii rezistenței neliniare. Pentru ca forma sa nu se stingă, este necesar ca cel puțin una din rădăcinile polinomului caracteristic să aibă partea reală pozitivă. Astfel, amplitudinea modurilor spațiale corespunzătoare vor crește până când neliniaritatea le va limita evoluția.

Pentru RNC 2D, (5.7) se scriu înlocuind indicii m cu m, n unde $m = 0..M - 1$ și $n = 0..N - 1$. Astfel, răspunsul RNC 2D, este descris de următorul set de ecuații [GOR95b]:

$$\begin{cases} \hat{u}_{m,n}(t) = a_{m,n} e^{\lambda_{m,n_1} t} + b_{m,n} e^{\lambda_{m,n_2} t} \\ \hat{v}_{m,n}(t) = c_{m,n} e^{\lambda_{m,n_1} t} + d_{m,n} e^{\lambda_{m,n_2} t} \end{cases} \quad (5.10)$$

unde λ_{m,n_1} și λ_{m,n_2} sunt rădăcinile polinomului caracteristic:

$$\det \left\{ \lambda_{m,n} \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} - \gamma \begin{bmatrix} f_u & f_v \\ g_u & g_v \end{bmatrix} + k_{m,n}^2 \begin{bmatrix} D_u & 0 \\ 0 & D_v \end{bmatrix} \right\} = 0 \quad (5.11)$$


adică:

$$\begin{aligned} \lambda_{m,n}^2 + \lambda_{m,n} [k_{m,n}^2 (D_u + D_v) - \gamma (f_u + g_v)] + D_u D_v k_{m,n}^4 - \\ - \gamma (D_v f_u + D_u g_v) k_{m,n}^2 + (f_u g_v - f_v g_u) = 0 \end{aligned} \quad (5.12)$$

Dacă partea reală a valorilor proprii ale matricei sistemului este pozitivă, RNC va fi instabilă, iar în acest caz celulele vor avea la sfârșitul perioadei de tranziție valoarea pozitivă sau negativă de saturație. Condițiile necesare a fi îndeplinite pentru ca RNC să fie instabilă, ceea ce înseamnă că formele Turing apar, sunt:

$$\begin{cases} f_u + g_v < 0 \\ f_u g_v - f_v g_u > 0 \\ D_v f_u + D_u g_v > 0 \\ (D_v f_u - D_u g_v)^2 + 4 D_u D_v f_v g_u > 0 \end{cases} \quad (5.13)$$

În Fig. 5.4, se prezintă variația părții reale a valorilor proprii (λ_m) în raport cu m . Se observă că dacă există o bandă de moduri instabile, caz în care $\text{Re}\{\lambda_m\} > 0$, sistemul este instabil, așa cum se observă în Fig. 5.3a. De asemenea, dacă nu există o bandă de moduri instabile, sistemul este stabil așa cum se observă în Fig. 5.3b. Faptul că neliniaritatea are numai rolul de a limita evoluția modurilor spațiale instabile, a fost confirmat în [GOR95c] de simulările pe calculator. Pentru simulări s-a utilizat metoda Euler de rezolvare în domeniul discret al ecuațiilor diferențiale.



a) RNC instabil corespunzator Fig. 5.3a

b) RNC stabil corespunzator Fig. 5.3b

Fig. 5.4: Partea reala a valorilor proprii ale sistemului

V.2 Filtrarea neliniară a imaginilor folosind rețelele neurale de tip dublu strat

În [GOR03] s-a propus o metodă de preprocesare a imaginilor folosind RNC capabile să producă pattern-uri de tip Turing: fața originală va reprezenta starea inițială a sistemului, iar pattern-ul final va reprezenta versiunea filtrată neliniar a imaginii respective.

S-au utilizat pentru experimente baza de date de la Olivetti. Au fost investigate patru metode de analiză:

A) S-au obținut forme de tip Turing folosind RNC-uri cu diferite suprafețe de dispersie ale modurilor spațiale.

B) S-a realizat mai întâi o analiză multirezoluție bazată pe Transformata Wavelet Discreta (DWT).

C) se obțin imagini de rezoluție scăzută folosind DWT și se realizează o decompoziție de tip PCA.

D) se determină contururile imaginii originale iar imaginile rezultate se folosesc drept condiții inițiale ale RNC.

Rezultate experimentale.

În Fig. 5.5 se prezintă cele trei benzi de moduri instabile care au fost utilizate în simulări. Parametrii RNC-urilor sunt: $f_u = 0.1$, $f_v = -1$, $g_u = 0.1$, $g_v = -0.2$, $D_u = 1$ iar D_v, γ sunt folosiți astfel încât să fie selectate diferite moduri de benzi instabile.




Figura 5.5: Benzile de moduri instabile folosite în simulări.

În Fig. 5.6-5.9 se prezintă rezultatele obținute folosind drept condiții inițiale imaginile originale sau variante preprocesate ale imaginilor originale descrise la punctele A), B), C) și D) de mai sus.

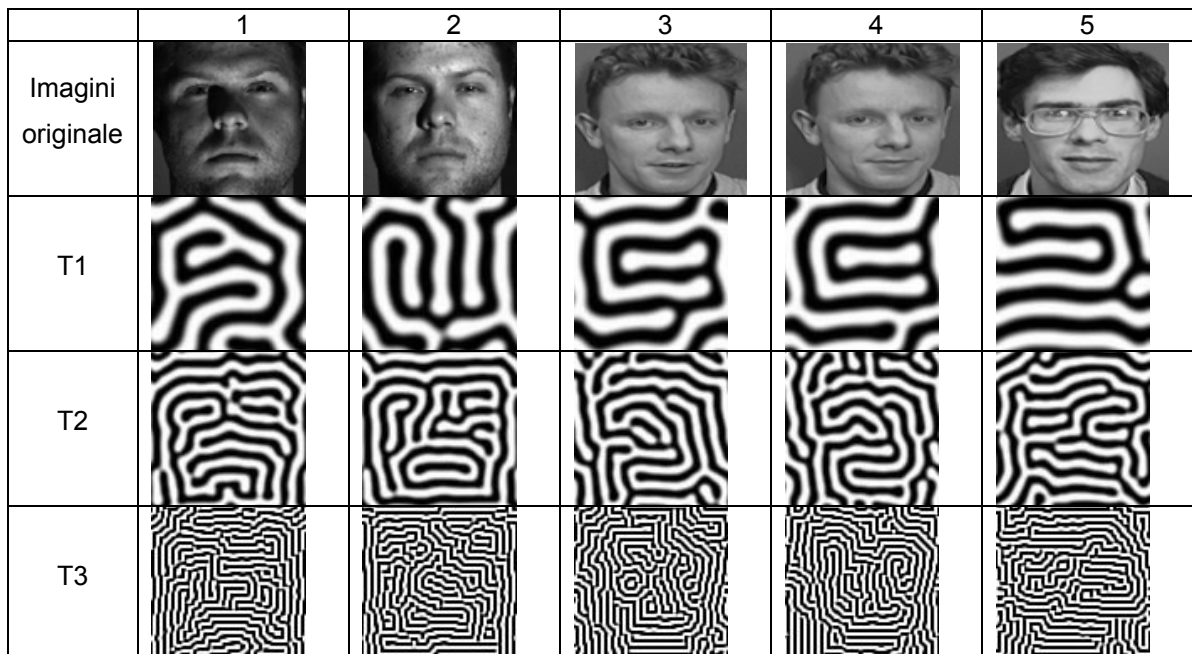


Fig. 5.6: Formele Turing corespunzătoare imaginilor de test utilizate.




Fig. 5.7: Imagini prelucrate cu DWT și subșantionate și formele Turing corespunzătoare.




Fig. 5.8: Imagini cărora li s-a aplicat decompoziția PCA și pattern-urile Turing corespunzătoare.




Fig. 5.9: Imagini în care s-au folosit drept condiții inițiale contururi și formele Turing corespunzătoare

În Fig. 5.6 se prezintă rezultatele obținute când s-au încărcat în RNC imaginile originale, neprocesate. În Fig. 5.7 se prezintă formele Turing obținute din componentele de joasă frecvență ale DWT ale imaginilor originale, iar în Fig. 5.8 condițiile inițiale se consideră a fi imaginile reconstruite prin decompoziția PCA și selecția celor mai semnificativi vectori proprii. În Fig. 5.9 se prezintă rezultatele obținute folosind drept condiții inițiale contururile imaginilor.

În cazul prelucrării fețelor s-a constatat ca cele mai bune rezultate se obțin dacă se filtrează o imagine folosind benzi de moduri instabile de joasă frecvență și poziția capului variază puțin (Fig. 5.6). Dacă variațiile poziției capului sunt mari atunci formele obținute variază semnificativ (Fig. 5.6). De asemenea rezultate nesatisfăcătoare se obțin în cazul în care imaginile sunt afectate de condițiile de iluminare, așa cum se observă în Fig. 5.6.

Rezultate nesatisfăcătoare se obțin și pentru cazul în care se folosesc benzi de frecvență înaltă atât pentru imaginile afectate de condiții de iluminare cât și pentru cele în care variază poziția capului. Acesta se observă din formele corespunzătoare benzilor de moduri instabile de înaltă frecvență din Fig. 5.6.

Cu toate că DWT și decompoziția PCA oferă o oarecare invarianță la diferite expresii ale fețelor, formele Turing corespunzătoare nu pot oferi o discriminare a claselor corespunzătoare diferitelor persoane. Aceasta se observă din Fig. 5.7 și 5.8.

V.3 Filtrare liniară folosind rețele neurale de tip dublu strat

O altă posibilitate de a extrage trăsături folosind rețele neurale este limitând evoluția formelor înainte ca circuitele să intre în neliniaritate. În această situație, RNC-ul se comportă ca un filtru liniar care are o caracteristică în frecvență dependentă de timp [GOR04], [UNG06], [GOR08]. Pentru a analiza filtrele implementate cu RNC de tip dublu strat ca filtru liniar, se consideră relația (5.7). Dacă se consideră condițiile la limita de tip periodic, atunci se observă că vectorii proprii sunt chiar exponențialele complexe ale transformatei Fourier Discrete. În consecință $\hat{u}_m(t)$ și $\hat{v}_m(t)$ reprezintă spectrul semnalelor $\hat{u}_i(t)$ și respectiv $\hat{v}_i(t)$ unde indicii i ($i = 0..M - 1$) reprezintă numărul celulei iar m ($m = 0..M - 1$) reprezintă valoarea modului.

Pentru cazul 2D, relațiile dintre $a_{mn}, b_{mn}, c_{mn}, d_{mn}$ au fost determinate în [GOR95b] din relațiile (5.6) și (5.7) considerând $\hat{u}_m(t)$, $\hat{v}_m(t)$, $\dot{\hat{u}}_m(t)$ și $\dot{\hat{v}}_m(t)$ la momentul $t = 0$:

$$\begin{cases} a_{mn}\lambda_{mn_1} + b_{mn}\lambda_{mn_2} = (a_{mn} + b_{mn})(\gamma f_u - D_u k_{mn}^2) + \gamma f_v(c_{mn} + d_{mn}) \\ c_{mn}\lambda_{mn_1} + d_{mn}\lambda_{mn_2} = (c_{mn} + d_{mn})(\gamma g_v - D_v k_{mn}^2) + \gamma g_u(a_{mn} + b_{mn}) \end{cases} \quad (5.14)$$

unde λ_{mn_1} și λ_{mn_2} trebuie să respecte ecuația caracteristică (5.12). Astfel se obține următoarea relație între parametrii $a_{mn}, b_{mn}, c_{mn}, d_{mn}$, obținuți considerând condițiile inițiale:

$$\begin{cases} a_{mn}(\lambda_{mn_1} - \gamma f_u + D_u k_{mn}^2) = \gamma f_v c_{mn} \\ b_{mn}(\lambda_{mn_2} - \gamma f_u + D_u k_{mn}^2) = \gamma f_v d_{mn} \end{cases} \quad (5.15)$$

Presupunând că rețeaua neurală celulară nu a intrat în zona neliniară a caracteristicii și considerând că cel de-al doilea start al rețelei se încarcă inițial cu 0 ($v_{mn}(0) = 0$ ceea ce înseamnă că $c_{mn} + d_{mn} = 0$), se poate defini caracteristica de frecvență variantă în timp, notată cu $H_{mn}(t_0)$:

$$H_{mn}(t_0) = \frac{\hat{u}_{mn}(t_0)}{\hat{u}_{mn}(0)} \quad (5.16)$$

Atunci relația (5.16) devine:

$$H_{mn}(t_0) = \frac{(\lambda_{mn_1} - \gamma f_u + D_u k_{mn}^2)e^{\lambda_{mn_1} t_0} - (\lambda_{mn_2} - \gamma f_u + D_u k_{mn}^2)e^{\lambda_{mn_2} t_0}}{\lambda_{mn_1} - \lambda_{mn_2}} \quad (5.17)$$

În relația de mai sus s-a determinat o caracteristică de frecvență variabilă în timp pentru care evoluția formei s-a oprit la un moment dat t_0 , înainte ca modurile care au partea imaginară pozitivă să le fie limitată evoluția de către liniaritatea celulei rețelei neurale celulare.

Pentru cazul rețelelor neurale celulare 1D, caracteristica de frecvență variabilă în timp corespunzătoare modului spațial m este:

$$H_m(t_0) = \frac{(\lambda_{m_1} - \gamma f_u + D_u k_m^2)e^{\lambda_{m_1} t_0} - (\lambda_{m_2} - \gamma f_u + D_u k_m^2)e^{\lambda_{m_2} t_0}}{\lambda_{m_1} - \lambda_{m_2}} \quad (5.18)$$

În Fig. 5.10 a) și Fig. 5. 10 b) se prezintă caracteristicile de frecvență ale unui filtru 2D și respectiv ale unui filtru 1D cu parametrii $f_u = 0.1, f_v = -1, g_u = 0.1, g_v = -0.2, D_u = 1, D_v = 50, \gamma = 14$ la momentele de timp $t_0 = \{1, 2, 3, 4, 5\}$. Se observă că se obțin filtre tip trece banda (filtre trece bandă circulare în cazul 2D) iar frecvența centrală a filtrului nu se modifică la variația timpului. În schimb, la variația timpului, variază banda filtrului trece bandă. De asemenea, odată cu creșterea timpului crește și valoarea maximă a


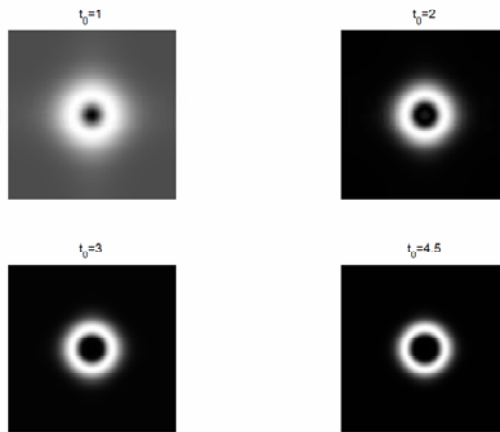


Fig. 5.10 a): Caracteristica de frecvență a filtrului trece banda 2D circular obținut pentru parametrii $f_u = 0.1, f_v = -1, g_u = 0.1, g_v = -0.2, D_u = 1, D_v = 50, \gamma = 14$ la momentele $t_0 = \{1, 2, 3, 4.5\}$




Fig. 5.10 b): Caracteristica de frecvență a filtrului trece bandă 2D obținut pentru parametrii $f_u = 0.1, f_v = -1, g_u = 0.1, g_v = -0.2, D_u = 1, D_v = 50, \gamma = 14$ la momentele $t_0 = \{1, 2, 3, 4.5\}$

caracteristicii de frecvență a filtrului corespunzătoare frecvenței centrale, ceea ce va determina intrarea la un moment dat în neliniaritate a circuitului.

V.4 Filtrarea liniară a imaginilor folosind rețele neurale de tip dublu strat omogene

Prelucrările de imagini sunt dintre cele mai mari consumatoare de resurse de calcul din domeniul prelucrărilor de semnal. De aceea soluțiile de prelucrare alternative pot fi interesante. În continuare se va analiza utilizarea rețelelor neurale celulare de tip dublu strat liniare pentru prelucrarea fețelor umane și a clasificării texturilor.

Caracteristicile de frecvență ale filtrelor circulare (Fig. 5.11) sunt asemănătoare caracteristicilor filtrelor implementate cu RNC de tip dublu strat liniare.




Figura 5.11: Caracteristicile de frecvență a trei filtre circulare

Un fapt interesant este că celulele de tip LGN ale sistemului vizual uman au caracteristici de frecvență asemănătoare cu ale unor filtre circulare așa cum se prezintă în Fig. 5.11 [COR00].

S-au investigat posibilitățile de a înlocui preprocesarea imaginilor folosind filtre circulare, cu filtre implementate prin RNC de tip dublu strat. Așa cum se observă în simulările de mai jos, s-a constatat că, dacă RNC-ul funcționează numai în zona liniară a caracteristicii, atunci această opțiune poate fi de interes.

Rezultatele simulărilor

Rezultatele simulărilor sunt prezentate în Tabelul 5.2 [GOR04]. Primul set de simulări pune în evidență asemănările dintre o procesare folosind un filtru circular bazat pe filtre Gabor cu orientări diferite și un filtru implementat cu un RNC de tip

dublu strat. S-au considerat trei benzi de frecvență (Fig. 5.11) și o unitate de procesare alcătuită dintr-un RNC de tip dublu strat cu diferite benzi de moduri instabile (Fig. 5.5). Imaginile cu persoane în diferite ipostaze, au fost folosite drept condiții inițiale pentru un strat al RNC, celălalt având condiții inițiale zero.

Rezultatele din Tabelul 5.2 prezintă pe rândurile notate cu FC1, FC2 și FC3 imaginile filtrate cu filtre circulare care au caracteristicile de frecvență corespunzătoare celor 3 valori ale lui σ care au fost utilizate în Fig. 5.11.

Rezultatele prezentate în rândurile CNN1, CNN2 și CNN3 reprezintă imaginile obținute prin oprirea la un moment dat a evoluției RNC-ului. Parametrii RNC s-au ales astfel încât să rezulte benzile de moduri instabile prezentate în Fig. 5.5. RNC vor avea astfel caracteristici de frecvență similare cu cele din Fig. 5.11. În toate cazurile regimul tranzitoriu a fost oprit înainte ca celulele să între în neliniaritate, la același moment pentru toate imaginile (pentru o anumită banda de moduri instabile). Se observă asemănările între imaginile corespunzătoare filtrării cu filtre circulare de tip Gabor și cele implementate cu RNC-uri. Se constată că un filtru circular poate fi înlocuit cu o RNC alcătuită din două straturi cuplate, care au fost proiectate cu anumite benzi de moduri instabile iar regimul tranzitoriu a fost oprit la un anumit moment de timp.

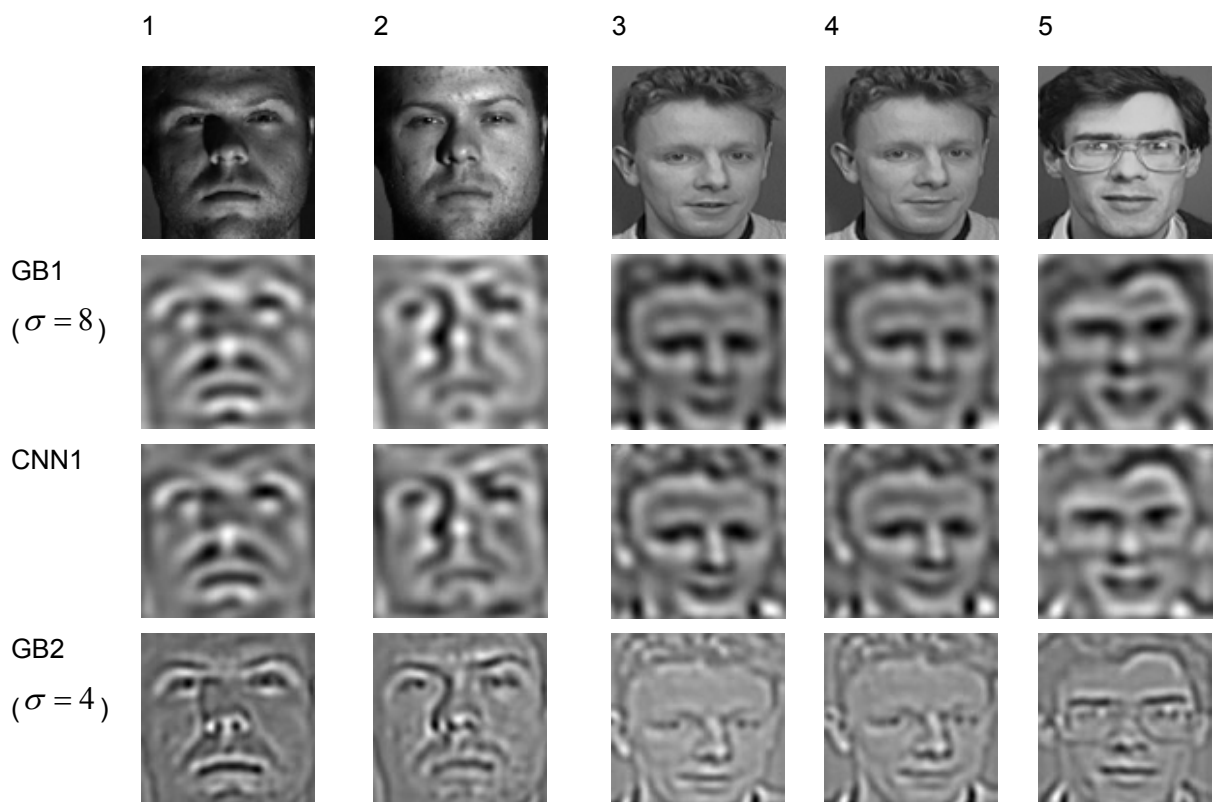




Table 5.2: Rezultatele simulărilor

S-a studiat, de asemenea, posibilitatea utilizării rețelele neurale celulare de tip dublu strat ca filtre liniare care aproximează caracteristica de frecvență a unor filtre circulare în aplicații de recunoaștere a texturilor [UNG06]. Principalul avantaj al acestui tip de filtre este că energia unei texturi filtrate este egală cu cea a texturii rotite și filtrate cu același filtru.

Un element important care va determina performanța sistemului este determinat de numărul de filtre (N) care vor fi folosite, frecvența centrală (π / σ) și selectivitatea filtrelor ($\mu\sigma$).

$$G(\omega) = \exp\left(-\frac{(\sqrt{\omega_x^2 + \omega_y^2} - \pi / \sigma)^2 \cdot (\mu\sigma)^2}{2}\right) \quad (5.19)$$

Deviația standard a filtrelor a fost aleasă conform relației: $\sigma = a^i$ unde $i = 1..N$. În Fig. 5.12 se prezintă caracteristica de frecvență a unui banc de filtre ($N=5$) precum și suma acestora (se dorește ca pentru cât mai bune performanțe de recunoaștere, cele N filtre considerate să acopere cât mai uniform planul frecvențelor).




Fig. 5.12: Filtrele circulare ideale ($a = 1.6$ și $\mu = 1.3$)

Metoda de clasificare a texturilor este clasică și este prezentă în Fig. 5.13. O textură este filtrată cu N filtre circulare. Fiecărei imagini rezultate i se calculează norma L1, iar rezultatul va forma un vector de dimensiune N. De asemenea vectorii vor fi normalizați în raport cu energia lor.

Pentru antrenare și testare s-au folosit 16 tipuri de texturi din baza de date Brodatz, fiecare având rezoluția 128x128. Fiecare tip de textură este reprezentată de 28 imagini diferite, fiecare fiind rotită cu 10 unghiuri diferite.

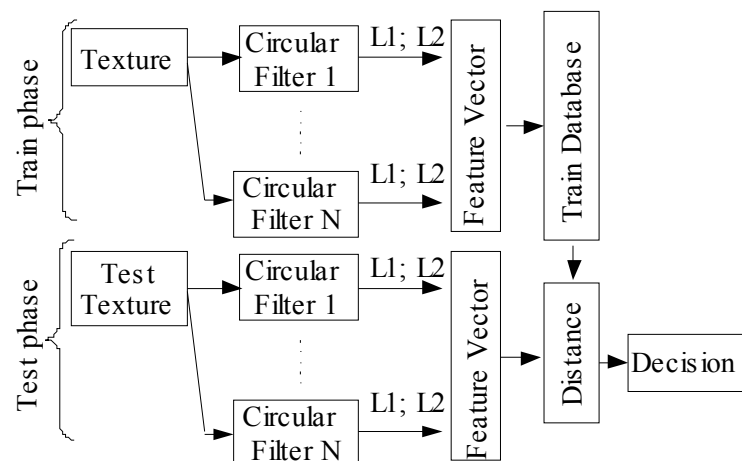


Fig. 5.13 Metoda de clasificare.

Din baza de date, 15% din fiecare tip de textură cu orientare 0^0 (5 texturi) au fost folosite pentru „antrenare” și vectorii corespunzători formează baza de date de „antrenare”. Fiecare imagine de test este filtrată cu cele 5 filtre. S-a format astfel vectorul de trăsături care a fost normalizat în raport cu energia sa și s-a calculat distanța L2 față de toți vectorii din baza de date de antrenare. Pentru a se verifica capacitatea sistemului de a recunoaște imagini rotite, din baza de date test nu fac parte texturile care au orientate 0^0 , precum și versiunile rotite ale celor 5 texturi cu orientare 0^0 care fac parte din baza de date de „antrenare”.

Numărul filtrelor	N=4	N=5	N=16
Parametrii filtrelor	$\mu = 1.3$ $a = 2$	$\mu = 1.3$ $a = 1.6$	$\mu = 1.3$ $a = 1.3$
Performanțele clasificării	96.6%	97.36%	99.34%

Tabelul 5.3: Performanțele clasificării

În [UNG06] s-a utilizat un sistem compus din 5 filtre circulare și o valoare a lui a egală cu 1.6. De asemenea, pentru baza de date considerată, s-a observat că rezultate mai bune s-au obținut dacă se utilizează $\mu = 1.3$. În Tabelul 5.3 se prezintă performanțele clasificării obținute pentru 4, 5, și 16 bancuri de filtre.

Nu s-au obținut performanțe puțin diferite pentru cazul în care s-a utilizat norma L1 și respectiv L2 în calculul vectorilor de trăsături.

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1	207															
2		207														
3			207													
4				183											2	
5				24	207										5	
6						199										
7						7	207								22	
8								207					1			
9									207							
10										199						
11											205					
12												206			15	
13						1							207			
14														207		
15															163	
16										8						207
(%)	100	100	100	88.4	100	96.1	100	100	100	96.1	99	99.5	100	100	78.7	100

Tabelul 5.4 Matricea de confuzie obtinuta pentru N=5 filtre circulare ideale

În Tabelul 5.4, se prezintă matricea de confuzie obținută pentru N=5. S-a utilizat următoarea numerotare a texturilor: 1-pânză, 2-stofă, 3-bumbac, 4-iarbă, 5-piele, 6-rogojină, 7-hârtie, 8-piele de porc, 9-rafie, 10-frunză, 11-piele de reptilă, 12-nisip, 13-paie, 14-șesătură, 15-lemn, 16-lână.

Pentru a se testa capacitatea RNC de tip dublu strat liniare de a putea fi utilizate în aplicații de clasificare a texturilor, s-au folosit 5 filtre care au parametrii specificați în Tabelul 5.5. Pentru a se varia frecvența centrală a filtrelor s-a modificat numai parametrul γ , iar pentru a se obține banda dorită s-a variat momentul la care s-a oprit evoluția formei (t_0).

filtrul 1	$f_u = 0.1, f_v = -1, g_u = 0.1, g_v = -0.2, D_u = 1, D_v = 50, \gamma = 69, t_0 = 2.3$
filtrul 2	$f_u = 0.1, f_v = -1, g_u = 0.1, g_v = -0.2, D_u = 1, D_v = 50, \gamma = 33, t_0 = 2.5$
filtrul 3	$f_u = 0.1, f_v = -1, g_u = 0.1, g_v = -0.2, D_u = 1, D_v = 50, \gamma = 14, t_0 = 4.5$
filtrul 4	$f_u = 0.1, f_v = -1, g_u = 0.1, g_v = -0.2, D_u = 1, D_v = 50, \gamma = 5.5, t_0 = 11$
filtrul 5	$f_u = 0.1, f_v = -1, g_u = 0.1, g_v = -0.2, D_u = 1, D_v = 50, \gamma = 2, t_0 = 30$

Tabelul 5.5: Valorile parametrilor RNC corespunzatoare celor 5 filtre considerate

În Fig. 5.14, se prezintă caracteristicile de frecvență ale filtrelor implementate cu RNC pentru cazul N=5.

În Tabelul 5.6 este prezentată matricea de confuzie obținută în urma clasificării. Performanța clasificării a scăzut cu 1.56% (95.8%) cel mai mic procent obținându-se ca și în cazul în care s-au utilizat filtre ideale, pentru lemn (73.9%). Cea mai mare scădere în performanță este pentru țesătura și bumbac (de la 100 % la 76.8%). Această scădere poate fi explicată prin faptul că ambele texturi au o bună parte din energie concentrată la frecvențe înalte, domeniu în care filtrele implementate cu RNC aproximează mai puțin bine filtrele ideale.




Fig. 5. 14: Caracteristicile de frecvență ale filtrelor circulare implementate cu RNC de tip dublu strat liniare, corespunzătoare celor cinci caracteristici de frecvență ale filtrelor circulare din Fig. 5.12

	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16
1	159															
2		207														
3	48		207													
4				186											1	
5				20	207										14	
6						200										
7						7	207				2					
8				1				207								
9									207							
10										207						
11											205					2
12												204			30	
13													207			
14														207		
15												2			162	
16												1				205
%	76.8	100	100	89.8	100	96.6	100	100	100	100	99	98.5	100	100	78.2	99

Tabelul 5.6 Matricea de confuzie obținută pentru N=5 filtre circulare implementate cu RNC tip dublu strat liniare

V.5 Filtrare liniară a imaginilor folosind rețele neuronale de tip dublu strat neomogene

S-au analizat de asemenea performanțele RNC de tip dublu strat pentru cazul în care parametrii rețelei variază de la o celulă la alta. Pentru analiza RNC, se poate liniariza sistemul de ecuații (5.2) în jurul punctului de echilibru (U_0, V_0) , a fiecărei celule, rezultând un sistem de ecuații diferențiale ordinare liniare, pentru care parametrii celulelor variază astfel:

$$\begin{cases} \frac{du_{ij}(t)}{dt} = \gamma_{ij}(f_{u_{ij}}u_{ij} + f_{v_{ij}}v_{ij}) + D_{u_{ij}}\nabla^2 u_{ij} \\ \frac{dv_{ij}(t)}{dt} = \gamma_{ij}(g_{u_{ij}}u_{ij} + g_{v_{ij}}v_{ij}) + D_{v_{ij}}\nabla^2 v_{ij} \end{cases} \quad (5.20)$$

unde $f_{u_{ij}}, f_{v_{ij}}, g_{u_{ij}}, g_{v_{ij}}$ sunt elementele matricei Jacobiene ale funcțiilor $f_{ij}(u, v)$ și $g_{ij}(u, v)$ corespunzătoare punctului de echilibru (U_0, V_0) al celulei (ij) .

Soluția unui astfel de sistem de $2MN$ ecuații diferențiale este aceeași ca și în cazul omogen:

$$X(t) = \sum_{i=0}^{2MN-1} \langle r_i, X(0) \rangle e^{\lambda_i t} Q_i \quad (5.21)$$

unde $X(t) = [u_0 \ u_1 \dots \ u_{N-1} \ v_0 \ v_1 \dots \ v_{N-1}]^T$ reprezintă vectorul de stare, λ_i și Q_i reprezintă valorile proprii simple și respectiv vectorii proprii ale matricei sistemului, r_i reprezintă baza reciprocă corespunzătoare matricei sistemului iar $X(0)$ reprezintă condițiile inițiale. Pentru ca RNC să fie stabilă, ca și în cazul RNC omogene, ar trebui ca toate valorile proprii să fie negative. În cazul în care una dintre valorile proprii este pozitivă, sistemul devine instabil, evoluția formelor limitându-se pe caracteristica neliniară a rezistorului specifică fiecărei celule a RNC de tip dublu strat.

Pentru ca RNC să poată fi considerat un filtru liniar, trebuie ca valorile proprii ale sistemului să își păstreze caracterul instabil în condițiile variației parametrilor rețelei. Având în vedere că s-a considerat o distribuție gaussiană a parametrilor rețelei, singura metodă de analiză a RNC cu parametri neomogeni este analiza statistică. Pentru aceasta s-au considerat 1000 de realizări ale RNC fiecare dintre rețele având o distribuție Gaussiană a parametrilor.

Analiza RNC neomogene, s-a realizat din punctul de vedere al capacității rețelelor de a recunoaște texturi în condițiile variației parametrilor [UNG08], [ALE08]. Pentru acesta s-a considerat o variație de 5%, 10%, 20% față de valorile nominale prezentate în Tabelul 5.5. S-au considerat 1000 de realizări ale RNC de tip dublu strat neomogen și s-a arătat că pentru filtrele alese, valoarea

proprie maximă a sistemului este pozitivă, ceea ce confirmă cerința necesară pentru ca sistemul să aibă caracter instabil.

În Fig. 5.15, se prezintă caracteristicile de frecvență obținute pentru o variație 10% pentru o singura realizare a RNC.

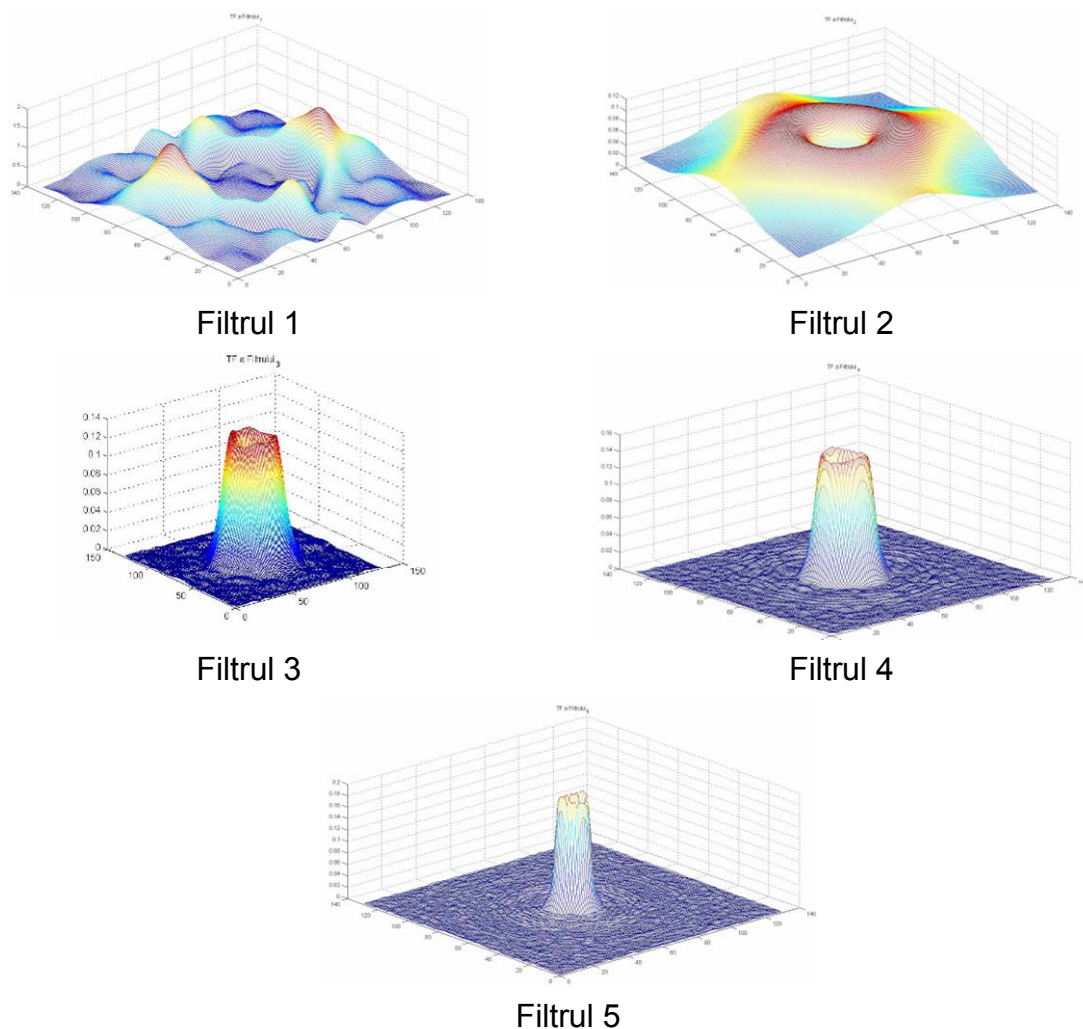


Fig. 5.15: Caracteristicile de frecvență obținute pentru o variație 10% parametrilor RNC neomogene

Performanțele sistemului din punctul de vedere al recunoașterii texturilor pentru 10 realizări ale sistemului și o variație Gaussiană a parametrilor RNC neomogene sunt prezentate în Fig. 5.16. Se observă că, pentru o variație a parametrilor rețelei de 5% și 10%, performanțele sistemului sunt asemănătoare cu cele obținute în cazul utilizării RNC omogene. De asemenea, nu s-au obținut variații mari între procentul de recunoaștere maxim și minim pentru diferite realizări ale RNC (0.8% pentru o variație a parametrilor de 10% și respectiv 1% pentru o variație a parametrilor de 5%). La o variație a parametrilor RNC de 20%, performanțele sistemului au scăzut semnificativ iar variația între procentul de recunoaștere maximă și minimă este de 3.08%




Fig. 5.16: Procentul de recunoaștere obținut pentru 10 realizari ale RNC

Concluzii

Au fost analizate, de asemenea, posibilitățile de utilizare a rețelelor neurale celulare de tip dublu strat liniare și neliniare în aplicații de recunoaștere a fețelor umane și a texturilor. Cele mai bune rezultate obținute de RNC neliniare s-au obținut în cazul în care s-au utilizat benzi de moduri instabile corespunzătoare frecvențelor joase. S-a constatat o sensibilitate mare a formei finale la modificări mici ale poziției capului sau la condițiile de iluminare.

S-a determinat caracteristica de frecvență temporală valabilă pentru cazul în care evoluția formei nu atinge neliniaritatea celulei. S-a folosit un banc de 5 filtre implementate cu RNC liniare care au fost folosite în aplicații de recunoaștere a texturilor. Rezultatele simulărilor au arătat că pentru cazul omogen performanțele sistemului implementat cu filtre digitale sunt asemănătoare cu cele ale sistemului implementat cu RNC liniare. În cazul implementării bancului de filtre cu RNC liniare neomogene, pentru o variație de 5% și 10% a parametrilor rețelei față de valorile nominale se obțin rezultate comparabile cu cele obținute pentru cazul omogen, iar diferența dintre procente de recunoaștere minimă și maximă obținute pentru 10 realizări ale RNC este mai mică de 1%. La o variație de 20% a parametrilor RNC, performanțele de recunoaștere scad cu aproximativ 5% iar diferența dintre procente de recunoaștere minimă și maximă obținute pentru 10 realizări ale RNC crește la 3%.

CONCLUZII ȘI CONTRIBUȚII PERSONALE

În ceea ce urmează vor fi prezentate concluziile tezei și contribuțiile personale ale autorului cu referire la publicațiile în care au fost prezentate.

Obiectivul principal al tezei de doctorat îl reprezintă analiza filtrelor Gabor și a filtrelor circulare implementate folosind circuite numerice sau analogice și posibilitatea utilizării acestora în aplicații care sunt cunoscute pentru volumul mare de calcule necesare, cum este domeniul recunoașterii formelor.

În primul capitol s-au prezentat două dintre cele mai utilizate filtre din domeniul prelucrării imaginilor, filtrele Gabor și filtrele circulare. S-a insistat în special pe utilizarea acestor filtre în domeniul recunoașterii imaginilor, punându-se accent pe capacitatea acestor filtre de a extrage trăsături atât în domeniul spațiu cât și în domeniul frecvență cu minimum de incertitudine.

În capitolul al II-lea s-a analizat posibilitatea utilizării aproximărilor Padé și Padé-Chebyshev în proiectarea filtrelor Gabor. Rezultatele obținute sunt comparabile cu cele din literatura de specialitate atunci când se folosește aproximarea Padé și mai bune pentru cazul în care se folosește aproximarea Padé-Chebyshev. Aproximarea Padé-Chebyshev oferă rezultate mai bune, fiind posibil să se implementeze același filtru cu un ordin de mărime mai mic în condițiile acelorași erori de aproximare.

În capitolul al III-lea s-au prezentat posibilitățile de implementare a filtrelor Gabor folosind RNC analogice. S-a analizat posibilitatea utilizării filtrelor digitale și a tehnicii de filtrare înainte-înapoi pentru implementarea filtrelor Gabor, obținându-se rezultate mai bune decât cele raportate până în prezent în literatura de specialitate în cazul folosirii aproximării Padé-Chebyshev. De asemenea, având în vedere faptul ca filtrele au fost implementate folosind filtre IIR, este probabil cea mai rapidă metodă de a implementa filtre Gabor. Numărul adunărilor și multiplicărilor nu depinde de rezoluția imaginii ca în cazul utilizării algoritmului FFT, ci numai de ordinul filtrului.

În capitolul al IV-lea au fost prezentate rezultatele obținute cu filtrele de tip Gabor care au fost proiectate și implementate în capitolele II și respectiv capitolul III, în cadrul unei aplicații de recunoaștere a texturilor. Pentru simulări s-a folosit baza de date publică Brodatz. Rezultatele au arătat că atât filtrele implementate cu rețele neurale celulare cât și cele implementate numeric cu filtre de tip IIR, dau rezultate aproximativ egale cu cazul în care s-au folosit pentru preprocesare filtre Gabor ideale, chiar și pentru $N=1$. S-au oferit astfel soluții pentru situațiile în care numărul mare de operații afectează un sistem de recunoaștere a texturilor.

Rezultatele obținute sunt apropiate de cele din literatura de specialitate în care s-au folosit filtre ideale pentru extragere de trăsături. În domeniul detecției contururilor, performanțele în cazul folosirii filtrelor de tip Gabor implementate cu structuri IIR sunt asemănătoare cu cazul folosirii filtrelor log Gabor sau Gabor ideale. De asemenea din punctul de vedere al performanțelor nu există deosebiri între filtrele separabile și cele neseperabile.

În capitolul al V-lea au fost analizate posibilitățile de utilizare a rețelelor neurale celulare de tip dublu strat liniare și neliniare în aplicații de recunoaștere a fețelor umane și a texturilor. Cele mai bune rezultate obținute de RNC neliniare s-au obținut în cazul în care s-au utilizat benzi de moduri instabile corespunzătoare frecvențelor joase. S-a constatat de asemenea o sensibilitate mare a formei finale la modificări mici ale poziției capului sau la condițiile de iluminare. S-a determinat caracteristica de frecvență variabilă în timp, valabilă pentru cazul în care evoluția formei nu atinge neliniaritatea celulei. S-a folosit un banc de 5 filtre implementate cu RNC liniare care au fost folosite în aplicații de recunoaștere a texturilor. Rezultatele simulărilor au arătat că pentru cazul omogen performanțele sistemului implementat cu filtre digitale sunt asemănătoare cu cele ale sistemului implementat cu RNC liniare. În cazul implementării bancului de filtre cu RNC liniare neomogene, pentru o variație de 5% și 10% a parametrilor rețelei față de valorile nominale se obțin rezultate comparabile cu cele obținute pentru cazul omogen, iar diferența dintre procente de recunoaștere minimă și maximă obținute pentru 10 realizări ale RNC este mai mică de 1%. La o variație de 20% a parametrilor RNC, performanțele de recunoaștere scad cu aproximativ 5% iar diferența dintre procente de recunoaștere minimă și maximă obținute pentru 10 realizări ale RNC crește la 3%.

Lucrarea elaborată conține un număr semnificativ de contribuții originale referitoare la studiul și dezvoltarea unor soluții eficiente pentru prelucrarea imaginilor, din punctul de vedere al timpului de calcul. Principalele contribuții sunt:

1. dezvoltarea unor metode bazate pe aproximarea rațională Padé-Chebyshev pentru proiectarea de filtre de tip Gauss și Gabor numerice ca filtre recursive. Din punctul de vedere al aproximării caracteristicilor de frecvență, filtrele astfel proiectate oferă cele mai bune dintre rezultatele raportate în literatura de specialitate.

2. analiza și implementarea numerică a filtrelor de tip Gabor ca filtre recursive și a particularităților structurilor de filtre propuse rezultând soluții mai eficiente din punctul de vedere al complexității computaționale.
3. analiza comparativă a performanțelor filtrelor Gabor și a celor *de tip Gabor* din punctul de vedere al capacității de extragere a trăsăturilor în aplicații de recunoaștere a formelor, arătându-se că filtrele neideale nu influențează semnificativ ratele de recunoaștere.
4. analiza comportării rețelelor neurale de tip dublu strat ca filtre circulare liniare rezultând o caracteristică de frecvență de filtru circular variabilă în timp.
5. analiza capacității rețelelor neurale de tip dublu strat omogene neliniare și liniare de a extrage trăsături în aplicații de recunoaștere a formelor și în particular a texturilor rotite. S-a arătat capacitatea RNC omogene liniare de a înlocui filtrele circulare ideale în aplicații de recunoaștere a texturilor rotite.
6. analiza capacității rețelelor neurale de tip dublu strat neomogene de a extrage trăsături în aplicații de recunoaștere a texturilor, analizându-se efectul variației parametrilor RNC asupra performanțelor sistemelor de recunoaștere a texturilor rotite.

Rezultatele prezentate în această teză au fost publicate astfel: un capitol de carte, un articol publicat în o revistă din țară, în 13 articole publicate în volumele ale unor conferințe internaționale, în cadrul unui contract de cercetare și a unei burse de cercetare de tip CNCSIS-BD.

Capitole de cărți:

- [1']. L. Goras, T. D. Teodorescu, R. Ghinea, E. David, P. Ungureanu. Chapter 4 "On the Dynamics of Some Classes of Cellular Neural Networks", published in A. Slavova, V. Mladenov, "Cellular Neural Networks: Theory and Applications" Nova Science Publishers, New York 2004, pp. 77-96, ISBN: 1-59454-040-3.

Lucrări publicate în reviste din țara

- [2']. [GOR08] L. Goras, P. Ungureanu, I. Alecsandrescu, "Asupra formării pattern-urilor în arhitecturi analogice paralele", Zilele Academice ale ASTR, București, 12-13 nov. 2008;

Lucrări publicate în volumele unor conferințe internaționale

- [3']. Radu Matei, Paul Ungureanu, „Image Processing Using Elliptically-Shaped Filters”, International Symposium on Signal, Circuits and Systems, ISSCS 2009, July 9–10, 2009, Iasi, Romania, pp. 337-340, ISBN 978-1-4244-3784-9;
- [4']. Paul Ungureanu, Iolanda Alecsandrescu, Liviu Goras, „Texture Classification using Cellular Neural Network Based Nonideal Circular Filters”, Proceedings of 5th European Conference on Intelligent Systems and Technologies, ECIT 2008, 10-12 iulie 2008, Iasi, Romania, CD Proceedings;
- [5']. Iolanda Alecsandrescu, Paul Ungureanu, Liviu Goras, „Nonhomogeneous CNN's And Their Use For Texture Classification”, 9th Symposium on Neural Network Applications in Electrical Engineering, NEUREL 2008, September 25–27, 2008, Belgrade, Serbia, pp. 153-156, ISBN 978-1-4244-2903-5;
- [6']. L. Goras, I. Alecsandrescu, P. Ungureanu, "Pattern Generation Using Feedback in CNN Architectures", Experimental Chaos Conference, June 3-6, 2008, Universita'degli Studi di Catania, Italy;
- [7']. E. David, P. Ungureanu, “On the Features Extraction Performances of Recursive Gabor-Type Filters in Texture Recognition Applications”, Proc. of International Symposium on Signals, Circuits and Systems, ISSCS 2007, 12-13 iulie 2007, Iasi
- [8']. L. Goras, I. Alecsandrescu, P. Ungureanu, “On Pattern Formation in Inertial CNN's”, Proceedings of International Symposium on Signals, Circuits and Systems, ISSCS 2007, 12-13 iulie 2007, Iasi, Romania, pp. 275-278, ISBN 1-4244-0968-3;
- [9']. P. Ungureanu, E. David, L. Goras, “On Rotation Invariant Texture Classification Using Two-Grid Coupled CNNs”, 8th Seminar on Neural Network Applications in Electrical Engineering, NEUREL-2006 Belgrade, September 25-27, 2006
- [10']. E. David, P. Ungureanu, L. Goras „On the Feature Extraction Performances of CNN Gabor-Type Filters in Texture Recognition Applications”, The 10th IEEE International Workshop on Cellular Neural Networks and their Applications, CNNA 2006, Istanbul, Turkey, August 28 – 30, 2006, pp. 153-158
- [11']. E. David, P. Ungureanu, M. Ansoorge, “A Fast Recursive Implementation of Gabor Filters”, Proceedings of International Symposium on Signals, Circuits

- and Systems, ISSCS 2005, Iasi, Romania, vol II, pp. 581-584, 14-15 iulie 2005
- [12']. L. Goras, P. Ungureanu, "On the Possibilities of Using Two-Grid Coupled CNN's for Face Feature Extraction", IEEE Symposium on Cellular Neural Networks and Applications, CNNA 2004, Budapesta, Ungaria, 2004, pp. 381-386, 22-24 iulie 2004
- [13']. E. David, P. Ungureanu, M. Ansorge, L. Goraş - "On the CNN Template Design for Gabor-Type Filters Based on Padé Approximation", SCS 2003, Iasi, Romania, pp. 193-196, 10-11 Iulie 2003
- [14']. E. David, P. Ungureanu, L. Goraş, "On CNN Template Design for Gabor-Type Filters Based on Rational Approximations", Proceedings of the European Conference on Circuit Theory and Design, ECCTD 2003, Krakow, Poland, vol II pp.333-336, 1-4 Sept.2003
- [15']. L. Goraş, I. Ciocoiu, E. David, P. Ungureanu, "On Nonlinear Filtering Using Two-Grid Coupled Cellular Neural Networks", , Proceedings of the European Conference on Circuit Theory and Design, ECCTD 2003, Krakow, Poland, vol II pp. 448-451, 1-4 Sept.2003

Contracte de cercetare:

Grant tip CNCSIS-TD tip TD – PNCDI II, programul Resurse umane, "Cercetari privind prelucrarea imaginilor cu aplicatii in recunoasterea formelor" , valoare: 36600 lei – director de proiect

Direcții viitoare de cercetare

Pentru viitor se va continua analiza filtrelor numerice de tip Gabor implementate pe un număr finit de biți. Se va avea în vedere, în special analiza în raport cu performanțele algoritmilor de recunoaștere a formelor. De asemenea se va analiza posibilitatea proiectării și implementării filtrelor 2D neseperabile folosind structuri recursive. În domeniul RNC liniare neomogene, se are în vedere ca împreună cu colegii care își desfășoara activitatea în domeniul circuitelor integrate analogice să se analizeze măsura în care variațiile tehnologice inerente o au asupra parametrilor RNC liniare neomogene și măsura în care sunt influențate performanțele algoritmilor de prelucrare a formelor.

REFERINTE

- [ADI97] Y. Adini, Y. Moses, S. Ullman, "Face recognition: The problem of Compensating for changes in illumination direction.", IEEE Trans. On Pattern Analysis and Machine Intelligence, vol. 19, no. 7, July 1997;
- [ALE08] Iolanda Alecsandrescu, Paul Ungureanu, Liviu Goras, „Nonhomogeneous CNN's And Their Use For Texture Classification", 9th Symposium on Neural Network Applications in Electrical Engineering, NEUREL 2008, September 25–27, 2008, Belgrade, Serbia, pp. 153-156, ISBN 978-1-4244-2903-5;
- [BRO66] P. Brodatz, "Textures: A photographic album for artists and designers", Dover: New York, 1966
- [CHU88a] L.O. Chua, L. Yang, "Cellular neural networks: Theory", IEEE Trans. Circuits Syst., Vol. 35, No. 10, pp. 1257-1272, October 1988
- [CHU88b] L.O. Chua, L. Yang, "Cellular neural networks: Applications", IEEE Trans. Circuits Syst., Vol. 35, No. 10, pp. 1273-1290, October 1988
- [COG85] J.M. Coggins and A.K. Jain, "A Spatial Filtering Approach to Texture Analysis," Pattern Recognition Letters, vol. 3, no. 3, pp. 195–203, 1985;
- [COR00] L. K. Cormack, "Computational Models of Early Human Vision", Handbook of Image and Video Processing, Academic Press, 2000;
- [CRO95] K.R.Crouse, L.O.Chua, "Methods for Image Processing and Pattern Formation in Cellular Neural Networks: A Tutorial", IEEE Trans. on Circ. and Syst.-I, vol.42, no.10, pp. 583-601, 1995
- [DAV03a] E. David, P. Ungureanu, M. Ansorge, L. Goraş - "On the CNN Template Design for Gabor-Type Filters Based on Padé Approximation", SCS 2003, Iasi, Romania, pp. 193-196, 10-11 Iulie 2003
- [DAV03b] E. David, P. Ungureanu, L. Goraş, "On CNN Template Design for Gabor-Type Filters Based on Rational Approximations", Proceedings of the European Conference on Circuit Theory and Design, ECCTD 2003, Krakow, Poland, vol II pp.333-336, 1-4 Sept.2003
- [DAV05] E. David, P. Ungureanu, M. Ansorge, "A Fast Recursive Implementation of Gabor Filters", Proceedings of International Symposium on Signals, Circuits and Systems, ISSCS 2005, Iasi, Romania, vol II, pp. 581-584, 14-15 Iulie 2005
- [DAV06] E. David, P. Ungureanu, L. Goras „On the Feature Extraction Performances of CNN Gabor-Type Filters in Texture Recognition Applications", The 10th IEEE International Workshop on Cellular Neural Networks and their Applications, CNNA 2006, Istanbul, Turkey, August 28 – 30, 2006, pp. 153-158

- [DAV07] E. David, P. Ungureanu, "On the Features Extraction Performances of Recursive Gabor-Type Filters in Texture Recognition Applications", Proc. of International Symposium on Signals, Circuits and Systems, ISSCS 2007, 12-13 iulie 2007, Iasi
- [DAV08] Emilian David, „Contribuții privind Prelucrarea Imaginilor cu Aplicații în Recunoașterea Formelor”, Teză de doctorat, Iași, 2008;
- [FDE98] J. Fdez-Valdivia, Member, J.A. Garcia, Member, J. Martinez-Baena, and Xose R. Fdez-Vidal, "The Selection of Natural Scales in 2D Images Using Adaptive Gabor Filtering", IEEE Transactions on Pattern Analysis And Machine Intelligence, vol. 20, no. 5, mai 1998
- [GAB46] D. Gabor, "Theory of communication," J. Inst. Elec. Eng., London, U.K., Vol. 93, pp. 429-457, 1946;
- [GED81] K. O. Geddes, "Block Structure in the Chebyshev-Padé Table ", SIAM J. Numer. Anal., 18(5), Oct. 1981, pp. 844-861.
- [GEO01] A. S. Georghiadis, P.N. Belhumeur, D.J. Kriegman, "From few to many: illumination cone models for face recognition under variable lighting and pose", IEEE Trans. Pattern Anal. Mach. Intelligence, pp. 643-660, June 2001.
- [GOR95b] L. Goraș, L. O. Chua, "Turing Patterns in CNN's - Part II: Equations and Behaviors", IEEE Trans. Circuits Syst, vol.42, pp. 612-626, October 1995
- [GOR95c] L. Goraș, L. O. Chua, "Turing Patterns in CNN's - Part II: Equations and Behaviors", IEEE Trans. Circuits Syst, vol.42, pp. 627-637, October 1995
- [GOR03] L. Goraș, I. Ciocoiu, E. David, P. Ungureanu, "On Nonlinear Filtering Using Two-Grid Coupled Cellular Neural Networks", , Proceedings of the European Conference on Circuit Theory and Design, ECCTD 2003, Krakow, Poland, vol II pp. 448-451, 1-4 Sept.2003
- [GOR04] L. Goras, P. Ungureanu, "On the Possibilities of Using Two-Grid Coupled CNN's for Face Feature Extraction", IEEE Symposium on Cellular Neural Networks and Applications, CNNA 2004, Budapest, 2004, pp.381-387.
- [GOR08] L. Goras, P. Ungureanu, I. Alecsandrescu, "Asupra formării pattern-urilor în arhitecturi analogice paralele", Zilele Academice ale ASTR, Bucuresti, 12-13 nov. 2008;
- [GUS96] F. Gustafsson, "Determining the initial states in forward-backward filtering", IEEE Trans. on Signal Processing, Vol. 40, No. 4, April 1996, pp. 988-992.
- [HAL99] G. M. Haley and B. S. Manjunath, "Rotation invariant texture classification using a complete space-frequency model," IEEE Trans. Image Process. 8,256-269 (1999);
- [JAI89] Anil K. Jain, "Fundamentals of Digital Image Processing", Prentice-Hall, 1989;
- [JIA00] Jian Chen, Yoshinobu Sato, Shinichi Tamura, "Orientation Space Filtering for Multiple Orientation Line Segmentation", IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 22, no. 5, may 2000;
- [KOV99] P. Kovesi, "Image features from phase congruency", Journal of Computer Vision Research, 1999 , Vol. 1, No. 3, The MITT Press;

- [LAI93] A. Laine and J. Fan, "Texture Classification by Wavelet Packet Signatures," IEEE Trans. Pattern Analysis and Machine Intelligence, vol. 15, pp. 1,186–1,190, Nov. 1993;
- [MAN00a] B.S. Manjunath, G. M. Haley, W. Y. Ma, "Multiband techniques for texture classification and segmentation", Handbook of image and video processing, Academic press, 2000, pp 367-381;
- [MAN00b] G. Manganaro, J.P. Gyvez, "One-dimensional discret-time CNN with multiplexed template-hardware", IEEE Trans. On Circ. And Systems, vol. 47, no.2, may 2000.
- [MAL99] Stephane Mallat, "A wavelet tour of signal processing - second edition", Academic Press, 1999;
- [MCK97] Stefan J. McKenna, Shaogang Gong, Rolf P. Würtz, Jonathan Tanner, Daniel Banin, "Tracking Facial Feature Points with Gabor Wavelets and Shape Models", Proceedings 1st International Conference on Audio and Video based Biometric Person Authentication, 1997;
- [MOS98] Moshe Porat, Yehoshua Y. Zeevi, "The Generalized Gabor Scheme of Image Representation in Biological and Machine Vision", IEEE Transactions on Pattern Analysis and Machine Intelligence", vol. 10, no. 4, july 1998;
- [MUR93] J. D. Murray, Mathematical Biology, Springer-Verlag, Berlin Heidelb, 1993
- [NAG03] J.-L. Nagel, P. Stadelman, M. Ansorge, F. Pelladini, "Comparison of features extraction techniques for face verification using elastic graph matching on low-power mobile techniques", EUROCON'2003, Ljubljana, Slovenia;
- [NEC06] Nectarios Rose, "Facial Expression Classification using Gabor and Log-Gabor Filters," fg, pp.346-350, Seventh IEEE International Conference on Automatic Face and Gesture Recognition (FG'06), 2006;
- [PAP77] Athanasios Papoulis "Signal Analysis", McGraw-Hill, 1977;
- [PHI06] P. Jonathon Phillips, W. Todd Scruggs, Alice J. O'Toole, Patrick J. Flynn Kevin W. Bowyer, Cathy L. Schott, Matthew Sharpe, "FRVT 2006 and ICE 2006 Large-Scale Results", 2006, <http://www.frvt.org/FRVT2006/docs/FRVT2006andICE2006LargeScaleReport.pdf>
- [RAN99a] T. Randen, John Hakon Hudoy "Filtering for Texture Classification:A Comparative Study", IEEE Transactions on Pattern Analysis And Machine Intelligence, VOL. 21, NO. 4, APRIL 1999;
- [SHI98] B. E. Shi, "Gabor-Type Filtering in Space and Time with Cellular Neural Networks", IEEE Trans. On Circ. And Systems, vol. 45, no.2, may 1998.
- [SHI99] B. E. Shi, "A One-Dimensional CMOS Focal Plane Array for Gabor-Type Image Filtering", IEEE Trans. On Circ. And Systems, vol. 46, no.2, may 1999.
- [TAI96] Tai Sing Lee, "Image representation using 2D Gabor wavelets", IEEE Transactions on pattern analysis and machine intelligence" vol. 18, no. 10, oct. 1996
- [TAN00] Tanner S, "Low-power architectures for single-chip digital image sensors", Institute de Microtechnique, Université de Neuchâtel, nov. 2000.

- [TUC93] M. Tuceryan and A.K. Jain, "Texture Analysis" Handbook Pattern Recognition and Computer Vision, C.H. Chen, L.F. Pau, and P.S.P. Wang, eds., ch. 2, pp. 235–276. Singapore: World Scientific, 1993;
- [TEU95] A. Teuner, O. Pichler, and B.J. Hosticka, "Unsupervised Texture Segmentation of Images Using Tuned Matched Gabor Filters," IEEE Trans. Image Processing, vol. 4, pp. 863–870, June 1995;
- [TUR52] A. M. Turing, "The Chemical Basis of Morphogenesis", Phil. Trans. Of Royal Society, London. October 1952, B 237, pp.37-72.
- [UNS90] M. Unser and M. Eden, "Nonlinear Operators for Improving Texture Segmentation Based on Features Extracted by Spatial Filtering," IEEE Trans. Systems, Man, Cybernetics, vol. 20, pp. 804–815, 1990;
- [WIS97] L. Wiscott, J.-M. Fellous, N. Krüger, C. von der Malsburg, "Face recognition by elastic bunch graph matching", IEEE Trans. on pattern analysis and machine intelligence, Vol 19, No. 7, July 1997;
- [WES95] C.-J. Westelius, "Focus on attention and gaze control or robot vision", Linköping University, Sweden, 1995;
- [WIS97] L. Wiscott, J.-M. Fellous, N. Krüger, C. von der Malsburg, "Face recognition by elastic bunch graph matching", IEEE Trans. on pattern analysis and machine intelligence, Vol 19, No. 7, July 1997, pp. 775-779;
- [YOU02] Ian T. Young, Lucas J. van Vliet, and Michael van Ginkel, "Recursive Gabor Filtering", IEEE TRANSACTIONS ON SIGNAL PROCESSING, VOL. 50, NO. 11, NOVEMBER 2002;
- [UNG06] P. Ungureanu, E. David, L. Goras, "On Rotation Invariant Texture Classification Using Two-Grid Coupled CNNs", 8th Seminar on Neural Network Applications in Electrical Engineering, NEUREL-2006 Belgrade, September 25-27, 2006
- [UNG08] Paul Ungureanu, Iolanda Alecsandrescu, Liviu Goras, „Texture Classification using Cellular Neural Network Based Nonideal Circular Filters”, Proceedings of 5th European Conference on Intelligent Systems and Technologies, ECIT 2008, 10-12 iulie 2008, Iasi, Romania, CD Proceedings;