

UNIVERSITATEA “BABEŞ-BOLYAI”
FACULTATEA DE MATEMATICĂ ŞI INFORMATICĂ

Transformări spectrale ale imaginilor

Referat de doctorat

Doctorand
Radu-Lucian Lupşa

Conducător științific
Prof. dr. Leon Tâmbulea

2003

Cuprins

| | | |
|----------|---|-----------|
| 1 | Introducere | 2 |
| 2 | Transformări spectrale clasice | 3 |
| 2.1 | Transformata Fourier | 3 |
| 2.1.1 | Transformata Fourier discretă | 4 |
| 2.1.2 | Proprietăți ale transformatei Fourier | 4 |
| 2.2 | Alte transformate spectrale globale | 5 |
| 2.2.1 | Transformatele sinus și cosinus | 6 |
| 2.2.2 | Transformatele Walsh și Hadamard | 7 |
| 2.3 | Algoritmi de calcul | 8 |
| 2.3.1 | Transformata Fourier rapidă | 8 |
| 2.3.2 | Transformări bidimensionale | 9 |
| 2.3.3 | Transformata cosinus | 10 |
| 2.4 | Aplicații | 10 |
| 2.4.1 | Analiza spectrală | 10 |
| 2.4.2 | Translații și rotații | 10 |
| 2.4.3 | Corectarea și îmbunătățirea imaginilor | 12 |
| 2.4.4 | Compresia imaginilor | 12 |
| 3 | Transformata Wavelets | 14 |
| 3.1 | Transformate wavelet ortogonale | 14 |
| 3.2 | Transformate wavelets liniare și analiza multirezoluție | 15 |
| 3.3 | Transformate wavelets biortogonale | 18 |
| 3.4 | Construcția prin pași de netezire (lifting) | 19 |
| 3.5 | Aplicații | 21 |
| 3.5.1 | Compresia imaginilor | 21 |
| 3.5.2 | Recunoașterea texturilor | 21 |

Capitolul 1

Introducere

Denumirea de *spectru* (fantomă, arătare scheletică) provine de la aspectul *spectrului optic* vizibil prin descompunerea luminii prin intermediul unei prisme optice. Lumina este, în general, compunerea unor radiații electromagnetice cu diferite lungimi de undă. *Distribuția spectrală* este funcția care dă puterea radiată pe fiecare lungime de undă, ca funcție de lungimea de undă. *Spectrul* este mulțimea lungimilor de undă pentru care puterea este nenulă.

Un semnal electric periodic, privit ca o funcție intensitate/timp, se poate scrie ca o sumă de semnale sinusoidale, cu diverse amplitudini și cu frecvențele multiplii ai frecvenței principale a semnalului. Această scriere este săzumita *serie Fourier*. Amplitudinile sinusoidelor, ca funcție de frecvență, alcătuiesc, prin analogie cu cazul luminii, *distribuția spectrală* (*spectrul*) semnalului.

Noțiunile de *spectru* și de *distribuție spectrală* au fost extinse la alte domenii în care un obiect supus studiului este alcătuit prin însumarea unor obiecte elementare, parametrizate. Ponderea obiectelor elementare, ca funcție de parametrii ce le descriu, alcătuiește *distribuția spectrală* a obiectului supus studiului.

În prelucrările imaginilor, obiectele supuse studiului sunt *imaginile*, care sunt în general funcții, definite pe \mathbb{R}^2 sau pe o submulțime a sa, și cu valori reale. Transformările spectrale sunt operațiile prin care se obține o distribuție spectrală pornind de la imaginea inițială și reciproc.

Capitolul 2 este consacrat transformărilor clasice (Fourier, cosinus, Walsh-Hadamard), în care funcțiile elementare sunt “distribuite uniform” pe domeniul imaginii. Capitolul 3 studiază transformările multirezoluție (wavelets), în care funcțiile elementare sunt mai mult sau mai puțin localizate.

Capitolul 2

Transformări spectrale clasice

2.1 Transformata Fourier

Fiind dată o funcție $f : \mathbb{R} \rightarrow \mathbb{R}$, *transformata Fourier (directă)* a lui f este funcția:

$$F(u) = \int_{-\infty}^{\infty} f(x)e^{-2\pi i ux}dx$$

Fiind dată transformata Fourier F a unei funcții, funcția originală se poate regăsi prin relația:

$$f(x) = \int_{-\infty}^{\infty} F(u)e^{2\pi i ux}du$$

numită *transformarea Fourier inversă*.

Transformarea Fourier este utilizată foarte adesea în studiul semnalelor analogice. În acest context, semnalul este privit ca o funcție $f = f(t)$, iar variabila u a transformatei Fourier reprezintă frecvența. Transformarea Fourier inversă reprezintă de fapt scrierea semnalului ca o sumă de semnale sinusoidale.

De remarcat că transformata Fourier a unei funcții reale este, în general, o funcție complexă (de variabilă reală), având însă proprietatea că $F(-u) = \overline{F(u)}$ (bara reprezentând conjugata complexă).

Transformata Fourier se poate extinde la funcții reale de variabilă vectorială, în modul următor: fiind dată funcția $f : \mathbb{R}^2 \rightarrow \mathbb{R}$, transformata Fourier directă este

$$\begin{aligned} F(u, v) &= \int \int_{(x,y) \in \mathbb{R}^2} f(x, y) e^{-2\pi i xu} e^{-2\pi iyv} dx dy = \\ &= \int \int_{(x,y) \in \mathbb{R}^2} f(x, y) e^{-2\pi i(xu+yv)} dx dy \end{aligned}$$

cu inversa

$$f(x, y) = \int \int_{(u,v) \in \mathbb{R}^2} F(u, v) e^{2\pi i(xu+yv)} du dv$$

2.1.1 Transformata Fourier discretă

Pentru cazul discret, al unei funcții $f : \{0, 1, 2, \dots, N-1\} \rightarrow \mathbb{R}$, transformata Fourier se definește prin

$$F(u) = \frac{1}{\sqrt{N}} \sum_{x=0}^{N-1} f(x) e^{-\frac{2\pi i ux}{N}}$$

pentru $u = \overline{0, N-1}$. Funcția f se poate reconstitui din F prin

$$f(x) = \frac{1}{\sqrt{N}} \sum_{u=0}^{N-1} F(u) e^{\frac{2\pi i ux}{N}}$$

Generalizarea în mai multe dimensiuni se face astfel:

Transformata Fourier directă a lui $f : \{0, 1, \dots, M-1\} \times \{0, 1, \dots, N-1\}$ este funcția

$$F(u, v) = \frac{1}{\sqrt{MN}} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) e^{-2\pi i(\frac{ux}{M} + \frac{vy}{N})}$$

pentru $u = \overline{0, M-1}$ și $v = \overline{0, N-1}$.

Reciproc, f se poate regăsi din transformata Fourier prin

$$f(x, y) = \frac{1}{\sqrt{MN}} \sum_{u=0}^{M-1} \sum_{v=0}^{N-1} F(u, v) e^{-2\pi i(\frac{ux}{M} + \frac{vy}{N})}$$

2.1.2 Proprietăți ale transformatei Fourier

Linearitatea Transformarea Fourier este liniară, adică dacă $h = \alpha f + \beta g$ atunci transformata Fourier a lui h este $H = \alpha F + \beta G$.

Separabilitatea Transformata Fourier (discretă) în mai multe dimensiuni are următoare proprietate de separabilitate:

$$F(u, v) = \frac{1}{\sqrt{MN}} \sum_{x=0}^{M-1} e^{-\frac{2\pi i ux}{M}} \sum_{y=0}^{N-1} e^{-\frac{2\pi i vy}{N}} f(x, y)$$

Translația Dacă $g(x, y) = f(x + x_0, y + y_0)$, atunci transformata Fourier a lui g este

$$G(u, v) = F(u, v)e^{-2\pi i(\frac{ux_0}{N} + \frac{vy_0}{M})}$$

Convoluția Dacă $h = f * g$, adică

$$h(x, y) = \int \int f(t, w)g(x - t, y - w) dt dw$$

atunci transformata Fourier a lui h este $H(u, v) = F(u, v)G(u, v)$.

În cazul discret, avem exact aceeași proprietate (aici convoluția se scrie $h(x, y) = \sum_{t=0}^{M-1} \sum_{w=0}^{N-1} f(t, w)g(x - t, y - w)$).

2.2 Alte transformate spectrale globale

Transformata Fourier face parte dintr-o familie mai largă a transformărilor de forma:

$$T(u) = \sum_{x=0}^{N-1} f(x)g(x, u)$$

unde $g(x, u)$ este *nucleul transformării directe*. Inversa este de forma

$$f(x) = \sum_{u=0}^{N-1} T(u)h(x, u).$$

În cazul transformantei Fourier, nucleul este, după cum am văzut, $g(x, u) = \frac{1}{\sqrt{N}}e^{-2\pi i xu}$, iar nucleul invers este $h(x, u) = \frac{1}{\sqrt{N}}e^{2\pi i xu}$.

Să observăm că transformata T este de fapt produsul lui f văzut ca un vector (linie) de dimensiune N cu g văzută ca o matrice $N \times N$. Putem inversa o astfel de transformare dacă și numai dacă matricea corespunzătoare lui g este nesingulară. Nucleul invers h va corespunde atunci inversei matricii corespunzătoare nucleului direct.

Un caz particular favorabil apare atunci când coloanele nucleului formează un sistem ortonormat, adică:

$$\sum_{k=0}^{N-1} g(k, u) \overline{g(k, v)} = \delta_{uv}, \quad \forall u, v \in \{0, 1, \dots, N-1\}$$

unde

$$\delta_{uv} = \begin{cases} 1, & u = v \\ 0, & u \neq v \end{cases}$$

În cazul în care nucleul direct este ortonormat, se poate demonstra imediat că nucleul invers este conjugatul nucleului direct: $h(x, u) = \overline{g(x, u)}$.

Pentru funcții de variabilă vectorială (în n dimensiuni), nucleul va avea $2n$ variabile, transformata scriindu-se în 2 dimensiuni în modul următor:

$$T(u, v) = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) g(x, u, y, v)$$

O asemenea transformare este *separabilă* dacă nucleul g este de forma $g(x, u, y, v) = g_1(x, u)g_2(y, v)$ și în plus este simetrică dacă $g_1 = g_2$.

Să observăm că dacă g este nucleul unei transformări inversabile și h este nucleul invers, atunci $g_2(x, u, y, v) = g(x, u)g(y, v)$ este nucleul unei transformări bidimensionale al cărei nucleu invers este $h_2(x, u, y, v) = h(x, u)h(y, v)$.

2.2.1 Transformatele sinus și cosinus

În timp ce transformata Fourier folosește perechea (sinus, cosinus) (sub forma exponențialei complexe), transformatele sinus și cosinus folosesc doar câte una dintre acestea. Aă cum arată numele, transformata sinus folosește numai funcția sinus, iar transformata cosinus folosește doar funcția cosinus.

Transformatele sinus și cosinus au ca nucleu un sinus sau cosinus de un argument în care apar variabilele nucleului:

$$g(x, u) = \sin(E(x, u))$$

respectiv

$$g(x, u) = \cos(E(x, u)).$$

În [2] sunt citate 16 transformări trigonometrice, 8 sinus și 8 cosinus,

având nucleele date mai jos:

$$\begin{array}{ll}
 g(x, u) = c(x, u) \cos \frac{\pi x u}{N} & g(x, u) = c(x, u) \sin \frac{\pi(x+1)(u+1)}{N+1} \\
 g(x, u) = c(x, u) \sin \frac{\pi x(2u+1)}{2N} & g(x, u) = c(x, u) \sin \frac{\pi(x+1)(2u+1)}{2N} \\
 g(x, u) = c(x, u) \cos \frac{\pi(2x+1)u}{2N} & g(x, u) = c(x, u) \sin \frac{\pi(2x+1)(u+1)}{2N} \\
 g(x, u) = c(x, u) \cos \frac{\pi(2x+1)(2u+1)}{4N} & g(x, u) = c(x, u) \sin \frac{\pi(2x+1)(2u+1)}{4N} \\
 g(x, u) = c(x, u) \cos \frac{2\pi x u}{2N-1} & g(x, u) = c(x, u) \sin \frac{2\pi(x+1)(u+1)}{2N+1} \\
 g(x, u) = c(x, u) \cos \frac{\pi x(2u+1)}{2N-1} & g(x, u) = c(x, u) \sin \frac{\pi(x+1)(2u+1)}{2N+1} \\
 g(x, u) = c(x, u) \cos \frac{\pi(2x+1)u}{2N-1} & g(x, u) = c(x, u) \sin \frac{\pi(2x+1)(u+1)}{2N+1} \\
 g(x, u) = c(x, u) \cos \frac{\pi(2x+1)(2u+1)}{4N+2} & g(x, u) = c(x, u) \sin \frac{\pi(2x+1)(2u+1)}{4N-2}
 \end{array}$$

coeficientul $c(x, u)$ servește asigurării ortonormalității matricei, și este constant cu excepția primei sau ultimei coloane sau rând, după caz.

Transformata cosinus discretă unidimensională, folosită cel mai adesea în practică, în special pentru compresia *JPEG*, este:

$$C(u) = \alpha(u) \sum_{x=0}^{N-1} f(x) \cos \left(\frac{\pi(2x+1)u}{2N} \right)$$

având inversa

$$f(x) = \sum_{u=0}^{N-1} \alpha(u) C(u) \cos \left(\frac{\pi(2x+1)u}{2N} \right)$$

unde

$$\alpha(u) = \begin{cases} \frac{1}{\sqrt{N}} & , u = 0 \\ \frac{2}{\sqrt{N}} & , u \neq 0 \end{cases}$$

2.2.2 Transformatele Walsh și Hadamard

Transformatele Walsh și Hadamard sunt definite pentru funcții în care cardinalul domeniului este o putere a lui 2, adică $N = 2^n$. Ambele transformate au nucleul format din valori 1 și -1, și ortogonal, ceea ce face ca nucleul invers să coincidă cu nucleul direct până la un factor constant.

Transformata *Walsh* directă are nucleul

$$g(x, u) = (-1)^{\sum_{i=0}^{n-1} b_i(x) b_{n-1-i}(u)}$$

unde $b_i(x)$ reprezintă bitul i al reprezentării binare a lui x .

Nucleul invers este $h(x, u) = \frac{1}{N} g(x, u)$.

Transformata *Hadamard* directă are nucleul

$$g(x, u) = (-1)^{\sum_{i=0}^{n-1} b_i(x) b_i(u)}$$

Nucleul invers este, din nou, $h(x, u) = \frac{1}{N} g(x, u)$.

Să observăm că nucleul transformatelor Hadamard și Walsh diferă doar prin ordinea coloanelor matricei corespunzătoare. Într-adevăr, dacă înlocuim u cu răsturnatul său, considerând reprezentarea lui u în baza 2, obținem transformata Walsh din transformata Hadamard și reciproc. Acest fapt justifică adoptarea denumirii comune de *transformata Walsh-Hadamard* pentru orice transformare de acest tip.

O altă transformată Walsh-Hadamard notabilă este aceea în care coloanele sunt permutează în aşa fel încât numărul de schimbări de semn de pe o coloană să crească o dată cu numărul u al coloanei. În acest fel, variabila u are rolul unei frecvențe, similar cu cazul transformatelor Fourier și cosinus.

Această transformare este *transformata Hadamard ordonată* și are nucleul direct

$$g(x, u) = (-1)^{\sum_{i=0}^{n-1} b_i(x) p_i(u)}$$

unde $p_0(u) = b_n(u)$ și $p_k(u) = b_{n-k}(u) + b_{n-k-1}(u)$, $k = \overline{1, n-1}$.

2.3 Algoritmi de calcul

2.3.1 Transformata Fourier rapidă

Calculul transformatei Fourier discrete prin implementarea directă a definiției conduce, în cazul unidimensional, la $\Theta(N^2)$ operații pentru o funcție definită pe N puncte. În aplicații practice, $\Theta(N^2)$ reprezintă o complexitate prea mare.

Metoda clasică pentru a calcula eficient transformata Fourier este aşa-numita *transformata Fourier rapidă (FFT — Fast Fourier Transform)*. Este aplicabilă pentru funcții definite pe un număr de puncte egal cu o putere a lui 2 ($N = 2^n$) și se bazează pe faptul că nucleul transformatei Fourier $g_N(x, u) = e^{-\frac{2\pi i x u}{N}}$ are pentru $\forall x, u \in \{0, 1, \dots, N-1\}$, proprietățile:

$$g_{2N}(2x, u) = g_N(x, u)$$

$$\begin{aligned} g_{2N}(2x+1, u) &= c_N(u)g_N(x, u) \\ g_{2N}(2x, u+N) &= -g_N(x, u) \\ g_{2N}(2x+1, u+N) &= -c_N(u)g_N(x, u) \end{aligned}$$

unde $c_N(u)$ nu depinde de x .

Atunci, notând $2M = N$,

$$F(u) = \sum_{x=0}^{M-1} g_M(x, u)f(2x) + c_M(u) \sum_{x=0}^{M-1} g_M(x, u)f(2x+1)$$

și

$$F(u+N) = \sum_{x=0}^{M-1} g_M(x, u)f(2x) - c_M(u) \sum_{x=0}^{M-1} g_M(x, u)f(2x+1)$$

de unde rezultă că transformata Fourier pentru N puncte se reduce la a calcula două transformate Fourier în $N/2$ puncte plus $2N$ operații (adunări, scăderi și înmulțiri; considerăm că valorile $c_N(u)$ pot fi precalculate). Rezultă pentru complexitate recurență $T(N) = 2N + 2T(N/2)$ și de aici $T(N) = \Theta(N\log N)$.

Algoritmul FFT este aplicabil pentru toate transformările ce au proprietățile enunțate mai sus. În particular, se poate aplica transformatei Walsh.

2.3.2 Transformări bidimensionale

Transformările bidimensionale (separabile simetrice) de forma

$$T(u, v) = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y)g(x, u)g(y, v)$$

se pot calcula după schema

$$T(u, v) = \sum_{x=0}^{M-1} \left[\sum_{y=0}^{N-1} f(x, y)g(y, v) \right] g(x, u)$$

efectuând separat transformările pe cele două axe. Complexitatea este $\Theta(MN^2 + M^2N) = \Theta(MN(M+N))$, în cazul în care algoritmul FFT nu este aplicabil, și $\Theta(MN\log N + NM\log M) = \Theta(MN\log(MN))$ în cazul aplicării FFT.

2.3.3 Transformata cosinus

Algoritmul FFT nu este aplicabil în forma prezentată pentru a calcula transformata cosinus. Există o transformată cosinus rapidă, bazată pe o altă grupare a coeficienților. De asemenea, transformata cosinus se poate calcula pornind de la transformatele Fourier a funcției inițiale f și a funcției $f_1(x) = f(x)e^{-\frac{\pi(2x+1)}{2N}}$.

2.4 Aplicații

2.4.1 Analiza spectrală

Transformata Fourier se folosește intens în electronică, teoria semnalelor și teoria informației datorită următorului fapt:

Un semnal se poate scrie ca suma unor sinusoide. Dacă semnalul este trecut numai prin componenete liniare, semnalul de la ieșire poate fi văzut ca suma ieșirilor produse pentru fiecare componentă sinusoidală în parte (un circuit în care ieșirea este funcție liniară de intrare are proprietarea că funcția aplicată sumei este suma rezultatelor aplicării funcției fiecărei componente în parte). Deoarece comportamentul circuitelor electronice se studiază mult mai ușor pentru semnale sinusoidale, este avantajos să studiem acțiunea circuitului asupra transformatei Fourier a semnalului decât asupra semnalului original.

În această ipostază, analiza spectrală este un instrument util în studiul sistemelor optice și electronice (analogice) care contribuie la achiziționarea imaginii. Aceste studii servesc la corectarea digitală a defectelor sistemului analogic de achiziție.

2.4.2 Translații și rotații

Translația unei imagini cu un număr întreg de pixeli este o simplă permutare (circulară) a pixelilor. Translația cu un număr neîntreg de pixeli este în schimb o operație mult mai delicată. S-ar putea defini spre exemplu translația cu $1/2$ pixeli ca făcând o medie aritmetică între pixelii vecini. Ca orice mediere, are dezavantajul de-a micșora rezoluția imaginii. Transtația pe această cale nu este reversibilă.

O metodă mai bună pentru translația cu număr fracțional de pixeli se poate defini cu ajutorul transformatei Fourier. Anume, translația cu un deplasament (x_0, y_0) se poate defini ca fiind funcția care are transformata Fourier

$$G(u, v) = F(u, v)e^{-2\pi i(\frac{ux_0}{N} + \frac{vy_0}{M})}$$

unde F este transformata Fourier a imaginii originale. Translația definită în acest mod este reversibilă, fară pierderea calității (în măsura în care valorile pixelilor sunt reprezentate ca numere reale și erorile de rotunjire sunt suficient de mici). Imaginea rezultată este însă, în general, o funcție complexă.

Rotarea unei imagini se poate realiza prin translații ale liniilor și coloanelor imaginii, în modul următor:

Dacă într-o imagine translatăm fiecare linie cu o cantitate $\Delta x = ay$ rezultă o imagine înclinată. Operația constă în translație linie cu linie, care se poate realiza exact prin procedeul sus amintit. Matricea transformării este

$$\begin{pmatrix} 1 & a \\ 0 & 1 \end{pmatrix}$$

Înclinarea similară pentru coloane are matricea

$$\begin{pmatrix} 1 & 0 \\ b & 1 \end{pmatrix}$$

Realizând o succesiune formată dintr-o înclinare după linii urmată de o înclinare după coloane, urmată de o nouă înclinare după linii folosind același coeficient ca și prima înclinare după linii, obținem o transformare a cărei matrice are forma:

$$\begin{pmatrix} 1 & a \\ 0 & 1 \end{pmatrix} \begin{pmatrix} 1 & 0 \\ b & 1 \end{pmatrix} \begin{pmatrix} 1 & a \\ 0 & 1 \end{pmatrix} = \begin{pmatrix} 1+ab & 2a+a^2b \\ b & 1+ab \end{pmatrix}$$

Punând acum

$$a = \frac{\cos \alpha - 1}{\sin \alpha}$$

și

$$b = \sin \alpha$$

avem

$$\begin{pmatrix} 1+ab & 2a+a^2b \\ b & 1+ab \end{pmatrix} = \begin{pmatrix} \cos \alpha & -\sin \alpha \\ \sin \alpha & \cos \alpha \end{pmatrix}$$

adică am realizat o rotație de unghi α .

2.4.3 Corectarea și îmbunătățirea imaginilor

Adesea, procesul de achiziție a imaginii introduce erori. O parte din aceste erori sunt *zgomot*, adică un semnal mai mult sau mai puțin aleator suprapus peste imagine. O altă parte o constituie *aberațiile* sau focalizarea incorectă a sistemului de achiziție. Acestea din urmă duc la faptul că imaginea unui punct din scena analizată este o pată mai mare sau mai mică pe imaginea rezultată.

Pentru micșorarea efectelor zgomotului, una dintre primele și cele mai simple metode utilizabile este medierea fiecărui pixel cu valorile pixelilor vecini. Această operație reprezintă de fapt o convoluție a imaginii cu o anumită funcție. Faptul că o convoluție echivalează cu o înmulțire punct cu punct a transformatorilor Fourier oferă o metodă eficientă pentru realizarea convoluției și în final filtrarea imaginii.

Corectarea aberațiilor se bazează pe faptul că imaginea formată de un sistem cu aberații este de fapt rezultatul aplicării asupra imaginii inițiale a unei convoluții. Cazul cel mai simplu este al imaginii focalizate greșit, dacă eroarea de focalizare este aceeași în toată imaginea. Aici funcția cu care s-a făcut convoluția imaginii inițiale este o constantă în interiorul unui cerc centrat în zero și cu o rază dependentă de defocalizarea sistemului de achiziție, și zero în afara acestui cerc. Luând transformata Fourier a imaginii achiziționate și împărțind-o punct cu punct la transformata Fourier a funcției cu care s-a produs convoluția obținem transformata Fourier a imaginii corecte.

Reducerea zgomotului constă în reducerea componentelor corespunzătoare frecvențelor ridicate din transformata Fourier. Corectarea aberațiilor presupune de obicei dimpotrivă creșterea componentelor corespunzătoare frecvențelor ridicate. Rezultă că metodele de corectare a aberațiilor sunt sensibile la zgomot (și au tendința de-a amplifica zgomotul), iar reducerea zgomotului duce la imagini mai puțin nete.

2.4.4 Compresia imaginilor

Reprezentarea pe pixeli a imaginilor necesită cantități mari de memorie. Aceasta a stimulat cercetări intense în domeniul compresiei imaginilor.

S-a observat că, în transformata Fourier a unei imagini, majoritatea valorilor care apar sunt apropiate de zero, iar neglijarea lor nu conduce, în general, la diferențe vizibile față de imaginea originală. Aceasta este ideea care stă în spatele formatului *JPEG* pentru reprezentarea imaginilor [1], [10].

În locul transformării Fourier se folosește însă transformata cosinus, având proprietăți similare dar este reală și nu complexă.

Compresia *JPEG* constă din următoarea secvență de pași:

1. imaginea se împarte în blocuri de 8×8 pixeli;
2. se calculează transformata cosinus a fiecărui bloc;
3. se cuantifică valorile coeficienților. Acesta este pasul la care intervine pierderea de informație. Precizia cuantificării depinde de poziția coeficientului, precizia maximă fiind pentru frecvența zero;
4. valorile obținute la pasul anterior se iau într-o anumită ordine “în zigzag”, se aplică o compresie Run-Length Encoding (adică o secvență de mai multe valori egale se reprezintă prin valoare și lungimea secvenței), și rezultatul se scrie în fișier.

Capitolul 3

Transformata Wavelets

Transformările spectrale clasice sunt *globale* în sensul că valoarea transformării în fiecare punct depinde de valoarea tuturor punctelor imaginii. În multe domenii în care sunt folosite transformările spectrale ar fi utilă un fel de “transformată spectrală locală”. O asemenea transformare ar putea arata aspecte legate de oscilații locale în cadrul unei imagini, spre deosebire de transformările spectrale “globale” capabile doar să sumeze oscilațiile locale în cadrul întregii imagini.

O asemenea transformare este *transformata wavelets*.

Primele cercetări legate de transformata wavelets au fost facute de Haar în 1909 și de Levy în anii 1930; însă studierea intensivă a transformatelor wavelets a început abia la sfârșitul anilor 1980.

Este greu să dăm în momentul de față o definiție a transformatelor wavelets [14]. Aceasta deoarece, pronind de la ideea localizării oscilațiilor din transformatele de tip Fourier, s-au făcut numeroase generalizări, inclusiv transformate wavelets în care funcțiile de bază nu sunt ortogonale, transformate pentru puncte de eșantionare neuniform spațiate, transformate pentru funcții definite pe varietăți non-afine (de exemplu pe sfere), și transformate wavelets neliniare.

3.1 Transformate wavelet ortogonale

Ideea de plecare a transformatelor wavelets a fost să se reprezinte funcțiile prin dezvoltare în serie Fourier după un sistem ortonormat complet generat prin scalarea și translația unei singure funcții de bază, sau eventual a unei familii finite de funcții de bază.

Aceasta înseamnă, presupunând că lucrăm în $L^2(\mathbb{R})$, că se va alege o

funcție de bază, $\psi : \mathbb{R} \rightarrow \mathbb{R}$, de la care se va genera familia $(\psi_{jk})_{j,k \in \mathbb{Z}}$:

$$\psi_{jk}(x) = 2^{k/2}\psi(2^kx - j) \quad (3.1)$$

Funcția de bază ψ trebuie aleasă în aşa fel încât familia $(\psi_{jk})_{j,k \in \mathbb{Z}}$ să formeze un sistem ortonormat complet pentru $L^2(\mathbb{R})$.

Condiția anterioară este echivalentă cu faptul că orice funcție $f \in L^2(\mathbb{R})$ se poate dezvolta în serie Fourier:

$$f = \sum_{j,k \in \mathbb{Z}} c_{jk} \psi_{jk} \quad (3.2)$$

unde

$$c_{jk} = (f, \psi_{jk}) = \int_{\mathbb{R}} f(t) \psi_{jk}(t) dt \quad (3.3)$$

Familia coeficienților wavelets c_{jk} se va numi atunci transformata wavelets a funcției f .

Cel mai simplu exemplu de trasnformată wavelets are ca funcție de bază funcția lui Haar:

$$H(x) = \begin{cases} 0 & , x < 0 \\ 1 & , 0 \leq x < 1/2 \\ -1 & , 1/2 \leq x < 1 \\ 0 & , x \geq 1 \end{cases} \quad (3.4)$$

Construcția prezentată se poate extinde și la alte spații de funcții, cum ar fi $L^2(I)$, unde I este un interval real, sau pentru funcții definite pe mulțimi discrete (\mathbb{Z} , \mathbb{N} sau $\{0, 1, \dots, N-1\}$, $N \in \mathbb{N}$).

Coefficienții wavelets caracterizează oscilațiile, în diferite zone spațiale (intervale din domeniul de definiție) a oscilațiilor funcției f .

3.2 Transformate wavelets liniare și analiza multirezoluție

Un alt unghi din care se poate privi transformata wavelets este următorul:

Fie X spațiul Hilbert al funcțiilor pe care le analizăm (de exemplu, $X = L^2(\mathbb{R})$). A privi o funcție f la un anumit nivel de rezoluție înseamnă a găsi și studia cea mai bună aproximare (proiecția) funcției $f \in X$ pe un subspațiu $S \subseteq X$ închis. Spre exemplu, dacă f reprezintă un semnal pe care îl eșantionăm la momente de timp exprimate prin numere întregi, vom

aproxima f printr-o funcție care pe fiecare interval delimitat de două numere întregi consecutive este constantă. Atunci

$$S = \{f(x) = x_{\lfloor x \rfloor} : (x_j)_{j \in \mathbb{Z}} \in l_2\}$$

și funcția f va fi aproximată prin

$$\text{pr}_S(f)(x) = \int_{\lfloor x \rfloor}^{\lfloor x \rfloor + 1} f(t) dt$$

Dacă vom dori însă să obținem o aproximare mai bună a lui f vom putea aproxima f într-un spațiu cu rezoluție mai fină. Putem construi atunci o familie de spații

$$S_k = \{f(x) = x_{\lfloor kx \rfloor} : (x_j)_{j \in \mathbb{Z}} \in l_2\}, \quad k \in \mathbb{Z}$$

de funcții cu rezoluție din ce în ce mai fină.

Conceptul intuitiv că $(S_k)_{k \in \mathbb{Z}}$ alcătuiesc spații de funcții de rezoluții din ce în ce mai fine se definește prin proprietățile:

- (i) $\forall j < k, S_j \subseteq S_k$
- (ii) $\bigcap_{k \in \mathbb{Z}} S_k = \{0\}$ și $\overline{\bigcup_{k \in \mathbb{Z}} S_k} = X$
- (iii) dacă $f \in S_0$, atunci $\forall k \in \mathbb{Z}, f(\cdot - k) \in S_0$ (altfel spus, S_0 este invariant la translații cu cantități întregi)
- (iv) $\forall k \in \mathbb{Z}, f \in S_k$ dacă și numai dacă $f(2 \cdot) \in S_{k+1}$ (adică spațiul S_{k+1} are rezoluție dublă față de S_k).

Spațiile S_k se numesc *spații de scară*.

Conform teoremei de descompunere ortogonală a lui Riesz, fiecare $S_k \subseteq S_{k+1}$ are un complement ortogonal în S_{k+1} , $W_k = S_k^\perp$ astfel încât orice funcție $f_{k+1} \in S_{k+1}$ se scrie în mod unic sub forma $f_{k+1} = f_k + w_k$, cu $f_k \in S_k$ și $w_k \in W_k$.

Spațiile W_k se numesc *spatiile wavelets* asociate spațiilor de scară S_k . Proprietățile spațiilor de scară determină pentru spațiile wavelets următoarele proprietăți:

- (i) $\forall j \neq k, W_j \perp W_k$
- (ii) dacă $w \in W_0$, atunci $\forall k \in \mathbb{Z}, w(\cdot - k) \in W_0$ (W_0 este invariant la translații cu cantități întregi)

(iii) $\forall k \in \mathbb{Z}$, $w \in W_k$ dacă și numai dacă $w(2 \cdot) \in W_{k+1}$ (spațiul W_{k+1} este spațiul oscilațiilor de frecvență dublă față de W_k).

(iv) $X = \sum_{k \in \mathbb{Z}} W_k$, adică orice funcție $f \in X$ se descompune unic sub forma $f = \sum_{k \in \mathbb{Z}} w_k$ cu $w_k \in W_k$.

Demonstrație

Primele trei proprietăți fiind imediate, vom demonstra doar ultima.

Fie $f \in X$. Notăm $f_n = \text{pr}_{S_n}(f)$, $r_n = f - f_n$ și fie $w_n = f_{n+1} - f_n$. Vom arăta că $f = \sum_{k \in \mathbb{Z}} w_k$. Pentru început, să arătăm că $f = f_0 + \sum_{k=0}^{\infty} w_k$. Deoarece

$\overline{\bigcup_{k \in \mathbb{Z}} S_k} = X$, deducem că există un sir $(g_k)_{k \in \mathbb{Z}}$ cu $g_k \in S_k$, convergent către f . Din definiția proiecției rezultă $\|f - f_k\| \leq \|f - g_k\|$ și deci $\|f - f_k\| \rightarrow 0$ când $k \rightarrow \infty$. Dar, pe de altă parte, $f_n = f_0 + \sum_{k=0}^{n-1} w_k$, $\forall n > 0$, de unde $f_0 + \sum_{k=0}^{\infty} w_k = f$.

Să demonstrăm acum că $f_0 = \sum_{k=1}^{\infty} w_{-k}$. Pentru aceasta să notăm $c_k = \|w_k\|^2$ și să observăm că ortogonalitatea spațiilor S_{-k} , W_{-k} , \dots , W_{-1} implică

$$\|f_{-n}\|^2 = \|f_0\|^2 - \sum_{k=1}^n c_{-k}$$

de unde rezultă că seria cu termeni pozitivi $\sum_{k=1}^{\infty} c_k$ este mărginită și prin urmare convergentă. Acum, presupunând $m < n$, $\|f_{-m} - f_{-n}\|^2 = \sum_{k=m}^n c_k$ și de aici rezultă că sirul $(f_{-m})_{m \in \mathbb{N}}$ este fundamental. Rezultă că (f_{-n}) este convergent în X și fie $f_{-\infty}$ limita sa. Considerând subșirul $(f_{-k})_{k \geq n}$, pentru un $n \in \mathbb{N}^*$ arbitrar, remarcăm $(f_{-k})_{k \geq n} \subseteq S_n$, de unde, întrucât S_n este închis, $f_{-\infty} \in S_n$. Prin urmare $f_{-\infty} \in \bigcap_{k \in \mathbb{Z}} S_k = \{0\}$ deci $f_{-\infty} = 0$. Din

$$f_{-n} = f_0 - \sum_{k=1}^n w_k \text{ rezultă acum } f_0 - \sum_{k=1}^{\infty} w_k = 0.$$

Avem acum că $f = \sum_{k \in \mathbb{Z}} w_k$.

Pentru unicitate, să presupunem că există $(g_k)_{k \in \mathbb{Z}}$ cu $g_k \in W_k$ și $\sum_{k \in \mathbb{Z}} g_k = f$.

Fie $n \in \mathbb{Z}$ arbitrar. Din închiderea lui S_n rezultă $\sum_{k=-\infty}^{n-1} g_k \in S_n$ și din $W_k \perp$

S_n , $\forall k \geq n$ rezultă $\sum_{k=n}^{\infty} g_k \in S_n^\perp$. Mai departe, din unicitatea descompunerii ortogonale după S_k rezultă că $\sum_{k=-\infty}^{n-1} g_k = f_n$ și $\sum_{k=n}^{\infty} g_k = r_n$, de unde reiese $\forall n \in \mathbb{Z}$, $g_n = w_n$. \diamond

În analiza multirezoluție se pune o condiție suplimentară, și anume ca mulțimea de scară S_0 să admită o bază ortonormată de forma $\phi_{j,0}(x) = \phi(x - j)$, $j \in \mathbb{Z}$, pentru o anumită funcție ϕ .

Condiția de ortonormalitate este adesea prea restrictivă. O relaxare acceptabilă este să se ceară doar ca funcțiile $\phi_{j,0}$ să alcătuiască o bază Riesz a lui S_0 , adică orice $f \in S_0$ să se poată scrie în mod unic sub forma $f = \sum_{j \in \mathbb{Z}} c_j \phi_{j,0}$ și încă plus să existe $c_1, c_2 > 0$, independente de f , astfel încât

$$c_1 \|f\|^2 \leq \sum_{j \in \mathbb{Z}} |c_j|^2 \leq c_2 \|f\|^2.$$

Dacă $\phi_{j,0}$ formează o bază ortonormală (respectiv Riesz) pentru S_0 , atunci se vede imediat că $\phi_{j,k}(x) = 2^{k/2} \phi(kx - j)$ formează o bază ortonormată (respectiv Riesz) pentru S_k .

Se poate arăta că relaxarea condiției de ortonormalitate asupra bazei $\phi_{j,0}$ nu este esențială, o bază ortonormală putând fi construită pornind de la o bază Riesz. De asemenea, se arată existența unei baze similare $\psi_{j,0}$ pentru W_0 .

Dacă ψ este o funcție astfel încât translațiile cu cantități întregi $\psi_{j,0}$ să formeze o bază ortonormată pentru W_0 , atunci funcția ψ poate fi funcția de bază a unei transformări wavelets definite în secțiunea precedentă.

În exemplul din secțiunea precedentă, ψ era funcția lui Haar. Spațiul de scară S_0 este mulțimea funcțiilor din $L^2(\mathbb{R})$ care sunt constante pe fiecare interval $[k, k+1]$ cu $k \in \mathbb{Z}$. O posibilă bază ortonormată se poate construi prin translațiile cu cantități întregi ale funcției $\psi = \chi_{[0,1]}$ (funcția caracteristică a intervalului $[0, 1]$).

3.3 Transformate wavelets biortogonale

Condiția de ortonormalitate asupra bazelor $(\phi_{j,0})_{j \in \mathbb{Z}}$ și $(\psi_{j,0})_{j \in \mathbb{Z}}$ este adesea greu de îndeplinit. Deși s-a demonstrat că plecând de la o bază Riesz se poate construi o bază ortonormată, totuși construcția duce la pierderea unor proprietăți dezirabile, cum ar fi compactitatea suportului.

În aceste condiții, se iau funcțiile ϕ și ψ astfel încât $(\phi_{j,0})_{j \in \mathbb{Z}}$ să alcătuiască o bază Riesz pentru S_0 și $(\psi_{j,0})_{j \in \mathbb{Z}}$ să alcătuiască o bază Riesz pentru W_0 .

Fie acum $f \in S_0$, $f = \sum_{j \in \mathbb{Z}} f_j \phi_{j,0}$. Pentru a determina coeficienții $(f_j)_{j \in \mathbb{Z}}$

într-o bază ortonormată, aveam relația simplă $f_j = \langle f, \phi_{j,0} \rangle$. În cazul unei baze Riesz, întrucât $f \mapsto f_n$ este o funcțională liniară și lipschitziană, rezultă (conform teoremei de reprezentare) că există $\tilde{\phi}_{j,0}$ astfel încât $f_j = \langle f, \tilde{\phi}_{j,0} \rangle$. Mai mult, se arată imediat că $\tilde{\phi}_{j,0}(x) = \tilde{\phi}_{0,0}(x-j)$ și că dacă definim $\phi_{j,k}(x) = 2^{k/2} \tilde{\phi}_{0,0}(kx-j)$ atunci, în general, $(\phi_{j,k})_{j \in \mathbb{Z}}$ este baza Riesz pentru S_k duală lui $(\phi_{j,k})_{j \in \mathbb{Z}}$. Adică, $\forall k \in \mathbb{Z}$ și $\forall f \in S_k$:

$$f = \sum_{j \in \mathbb{Z}} \langle f, \tilde{\phi}_{j,k} \rangle \phi_{j,k}$$

și

$$f = \sum_{j \in \mathbb{Z}} \langle f, \phi_{j,k} \rangle \tilde{\phi}_{j,k}$$

Aceeași construcție duce la construcția funcțiilor $\tilde{\psi}_{j,k}(x) = 2^{k/2} \tilde{\psi}(kx-j)$ astfel încât $(\tilde{\psi}_{j,k})_{j \in \mathbb{Z}}$ să constituie baza Riesz pentru W_k duală lui $(\psi_{j,k})_{j \in \mathbb{Z}}$.

Să remarcăm două lucruri importante:

1. Alegerea perechii de baze $(\phi, \tilde{\phi})$ pentru S_0 este independentă de alegerea perechii de baze $(\psi, \tilde{\psi})$ pentru W_0 .
2. Chiar dacă funcțiile wavelet de pe același nivel $(\psi_{j,k})_{j \in \mathbb{Z}}$ nu sunt ortogonale, oricare două funcții wavelet de nivele diferite rămân ortogonale: $\langle \psi_{j_1, k_1}, \psi_{j_2, k_2} \rangle = 0$, $\forall j_1, k_1, j_2, k_2 \in \mathbb{Z}$ cu $k_1 \neq k_2$.

3.4 Construcția prin pași de netezire (lifting)

Metoda netezirii (lifting) ([14], [13]) conduce la transformarea unei funcții de variabilă discretă într-o secvență de coeficienți care, se speră, sunt mai puțin intercorelați decât valorile funcției inițiale. Construcția, în anumite cazuri particulare, este echivalentă cu o transformată wavelets clasica.

Metoda netezirii decurge în modul următor:

Fie $\lambda_{0,k} = f(k)$ valorile funcției inițiale. Setul de valori λ_0 se împarte în două subseturi, λ'_{-1} și γ'_{-1} într-un mod care să permită reconstituirea lui λ_0 din λ'_{-1} și γ'_{-1} . Este preferabil ca seturile λ'_{-1} și γ'_{-1} să fie puternic corelate, pentru ca din λ'_{-1} să se poată construi o estimare bună pentru γ'_{-1} . Exemplul

cel mai simplu este $\lambda'_{-1,k} = \lambda_{0,2k}$ și $\gamma'_{-1,k} = \lambda_{0,2k+1}$, presupunând că valorile din punctele impare ale funcției nu vor fi de departe de valorile ce se pot estima din valorile punctelor pare.

În continuare, se construiește diferența $\gamma_{-1} = \gamma'_{-1} - \mathcal{P}(\lambda'_{-1})$ între valorile reale γ'_{-1} și valorile estimate pe baza valorilor λ'_{-1} . Continuând exemplul, putem estima valorile din punctele impare ca fiind media aritmetică a valorilor din punctele vecine: $\mathcal{P}_{2k+1}(\lambda'_{-1}) = \frac{1}{2}(\lambda_{-1,k} + \lambda_{-1,k+1}) = \frac{1}{2}(\lambda_{0,2k} + \lambda_{0,2k+2})$.

A treia etapă a “pasului de netezire” este actualizarea setului $\lambda_{-1} = \lambda'_{-1} + \mathcal{U}(\gamma_{-1})$. Această din urmă operație are ca scop păstrarea anumitor proprietăți ale setului inițial. De exemplu, dacă cerem ca setul λ_{-1} să aibă aceeași medie aritmetică cu λ_0 putem pune, în exemplul de mai sus, $\mathcal{U}_k(\gamma_{-1}) = \frac{1}{2}(\gamma_{-1,k-1} + \gamma_{-1,k})$.

Aplicarea pașilor de netezire duce la înlocuirea treptată a valorilor λ ale funcției inițiale cu valorile coeficienților γ .

Etapele a doua (estimarea și calculul diferenței) și a treia (actualizarea) se pot omite dacă decorelarea datelor se face din prima etapă (de diviziune). Spre exemplu, pentru a implementa transformata Haar prin pași de netezire vom efectua diviziunea $\lambda'_{j,-1} = \frac{\lambda_{2j,0} + \lambda_{2j+1,0}}{2}$ și $\gamma'_{j,-1} = \frac{\lambda_{2j,0} - \lambda_{2j+1,0}}{2}$, după care estimarea este $\mathcal{P} = 0$ ceea ce conduce la $\lambda_{j,-1} = \lambda'_{j,-1}$ și actualizarea este din nou $\mathcal{U} = 0$ adică $\gamma_{j,-1} = \gamma'_{j,-1}$.

Desigur, trebuie să ne asigurăm asupra posibilității de-a reface $(\lambda_{j,0})_{j \in \mathbb{Z}}$ din $(\lambda'_{j,-1})_{j \in \mathbb{Z}}$ și $(\gamma'_{j,-1})_{j \in \mathbb{Z}}$. Aceasta se face punând $\lambda_{2j,0} = \lambda'_{j,-1} + \gamma'_{j,-1}$ și $\lambda_{2j+1,0} = \lambda_{j,-1} - \gamma'_{j,-1}$.

Este în general mai ușor să construim o transformată wavelets corectă (inversabilă) prin netezire (lifting) decât prin construcția bazelor duale.

Dacă operațiile din pașii de netezire sunt liniare, rezultatul este o transformată wavelets (liniară). Prin urmare mecanismul pașilor de netezire permite o mai mare generalitate.

Pentru a face transformata wavelets prin lifting, să presupunem că avem o funcție f . Deoarece ne găsim în discret, nu vom putea avea reprezentarea exactă a lui f ci doar reprezentarea proiecției ei pe un spațiu de scară S_n :

$$\text{pr}_{S_n}(f) = \sum_{j \in \mathbb{Z}} \lambda_{j,n} \phi_{j,n} \text{ unde } \lambda_{j,n} = \langle f, \tilde{\phi}_{j,n} \rangle.$$

Atunci

$$\lambda_{m,n-1} = \langle f, \tilde{\phi}_{m,n-1} \rangle = \left\langle \sum_{j \in \mathbb{Z}} \lambda_{j,n} \phi_{j,n}, \tilde{\phi}_{m,n-1} \right\rangle = \sum_{j \in \mathbb{Z}} \lambda_{j,n} \langle \phi_{j,n}, \tilde{\phi}_{m,n-1} \rangle$$

și analog

$$\gamma_{m,n-1} = \sum_{j \in \mathbb{Z}} \lambda_{j,n} \langle \phi_{j,n}, \tilde{\psi}_{m,n-1} \rangle$$

3.5 Aplicații

3.5.1 Compresia imaginilor

Probabil cea mai bine fructificată aplicație a transformării wavelet în domeniul procesării imaginilor este compresia imaginilor. Formatul *JPEG-2000* ([11], [12]) este rezultatul cercetărilor din anii 1990 cu privire la folosirea transformatei wavelets în locul “clasicei” transformate cosinus (folosită de formatul *JPEG* clasic).

Ca și compresia *JPEG* clasică, compresia *JPEG-2000* împarte mai întâi imaginea în blocuri; însă, spre deosebire de *JPEG*, în *JPEG-2000* dimensiunea blocurilor nu este impusă de standard ci este lăsată la latitudinea programului de compresie. Blocurile mici din *JPEG*-ul clasic erau impuse de faptul că transformata cosinus este globală. *JPEG-2000* profită de caracterul multirezoluție a transformatei wavelets.

Fiecare bloc este apoi supus transformatei wavelets. Coeficientii rezultați sunt ulterior cuantificați și secvența lor comprimată asemănător cu cazul compresiei *JPEG* clasice.

Se estimează că ratele de compresie posibile la *JPEG-2000* sunt de până la 10 ori mai mari decât în cazul *JPEG*, la aceeași calitate. Desigur, calitatea rezultatului compresiei nu poate fi apreciat decât subiectiv, iar factorul de compresie obținut depinde mult de imaginea supusă compresiei.

Standardul *JPEG-2000* prevede de asemenea posibilitatea de a realiza compresia fără pierdere de informație. În acest scop se folosește o transformată wavelet întreagă [15].

3.5.2 Recunoașterea texturilor

Recunoașterea texturilor este o altă aplicație majoră a transformatei wavelets. Descompunerea wavelets oferă coeficienți care caracterizează oscilațiile locale în cadrul unei imagini. Prin urmare, este natural să fie considerată un bun punct de plecare în caracterizarea texturilor, adică a unor modele repetitive.

Principalele informații oferite de descompunerea wavelets sunt distribuția energiei după frecvență și după orientare și dispersia coeficienților wavelets ([17], [18]).

Bibliografie

- [1] ANDREW B. WATSON, *Image Compression Using the Discrete Cosine Transform*, Mathematica Journal, 4(1), 1994, p 81–88
- [2] MARKUS PÜSKEL, JOSÉ M. F. MOURA, *The Discrete Trigonometric Transforms and their Fast Algorithms: An Algebraic Symmetry Perspective*, <http://www.ece.cmu.edu/pueschel/papers/dtt.ps>
- [3] R. C. GONZALEZ, R. E. WOODS, *Digital Image Processing*, Addison-Wesley Publishing Company, 1993
- [4] V. GUI, D. LACRĂMĂ, D. PESCARU, *Prelucrarea imaginilor*, Editura politehnica Timișoara, 1999
- [5] J. MOREL, F. GUICHARD, *Traitements d'Images*, curs, ENS-Ulm, Paris, 1998
- [6] IOAN MUNTEAN, *Analiză funcțională*, curs, Univ. Babes-Bolyai Cluj-Napoca, 1993
- [7] OCTAVIAN AGRATINI, IOANA CHIOREAN, GHEORGHE COMAN, RADU TRÂMBITĂŞ, *Analiză numerică și teoria aproximării*, Presa Universitară Clujeană, 2002, cap. 21 — Elemente de analiză Fourier și wavelets
- [8] RONALD A. DEVORE, BRADLEY J. LUCIER, *Wavelets Acta Numerica*, A. Iserles, ed., Cambridge University Press, v. 1 (1992), p. 1–56.
- [9] AMARA GRAPS, *An Introduction to Wavelets* IEEE Computational Science and Engineering, vol. 2, nr. 2, 1995
- [10] <http://www.ece.purdue.edu/ace/jpeg-tut/jpegtut1.html>
- [11] <http://www.jpeg.org>
- [12] MICHAEL W. MARCELLIN, MICHAEL J. GORMISH, ALI BILGIN, MARTIN P. BOLIEK, *An Overview of JPEG-2000* Proc. of the IEEE Data Compression Conference, p. 523–541, 2000

- [13] INGRID DAUBECHIES, WIM SWELDENS, *Factoring Wavelets Transforms into Lifting Steps*, 1997
<http://cm.bell-labs.com/who/wim/papers/factor/factor.pdf>
- [14] WIM SWELDENS, *The Lifting Scheme: A New Philosophy in Biorthogonal Wavelet Constructions*, Journal of Appl. and Comput. Harmonic Analisys, vol. 3, p. 186–200, 1996
- [15] ROBERT CALDENBANK, INGRID DAUBECHIES, WIM SWELDENS, BOON-LOCK YEO, *Wavelet transforms that map integers to integers*, Applied and Computational Harmonics Analysis 5 (no. 3), pp. 332–369, 1998.
- [16] A. R. CALDERBANK, INGRID DAUBECHIES, WIM SWELDENS, BOON-LOCK YEO, Lossless Image Compression using Integer to Integer Wavelet Transform
- [17] G. VAN DE WOUWER, P. SCHEUNDERS, D. VAN DYCK, *Statistical texture characterization from discrete wavelet representations* IEEE Transactions on Image Processing, Vol. 8, Nr. 4, p. 592-598, (1999)
- [18] G. VAN DE WOUWER, P. SCHEUNDERS, S. LIVENS, D. VAN DYCK, *Wavelet Correlation Signatures for Color Texture Characterization* Pattern Recognition, Vol. 32, Nr. 3, p. 443-451, (1999)