

UNIVERSITATEA "POLITEHNICA" DIN TIMIȘOARA  
FACULTATEA DE ELECTRONICĂ ȘI TELECOMUNICAȚII  
DEPARTAMENTUL DE MASURĂRI ȘI ELECTRONICĂ OPTICĂ

10/11/2017

METODE ȘI ALGORITMI DE CUANTIZARE VECTORIALĂ

Teză de doctorat

BIBLIOTECA CENTRALĂ  
UNIVERSITATEA "POLITEHNICA"  
TIMIȘOARA

Conducător științific:  
prof. dr. ing. Sever Crișan

Autor:  
ing. Septimiu Mischie

1998

## PREFATĂ

2007. 7. 4  
E.P. I

Prelucrarea numerică a semnalelor constituie o preocupare tradițională în cadrul colectivului Departamentului de Măsurări și Electronică Optică al Facultății de Electronică și Telecomunicații din Timișoara, în acest domeniu susținându-se mai multe teze de doctorat.

Prelucrarea numerică se aplică în prezent pentru foarte multe categorii de semnale dintre care se amintesc: semnalul vocal, semnalul de imagine și semnalele biomedicale.

Prelucrarea semnalului vocal este o preocupare mai veche a autorului. Astfel, tema proiectului de diplomă cu care autorul a obținut titlul de inginer s-a numit "Sistem pentru recunoașterea cuvintelor izolate".

Cuantizarea vectorială este o tehnică utilizată astăzi în majoritatea domeniilor de prelucrare numerică, datorită structurii sale și modului relativ simplu de implementare, având ca scop compresia datelor. Unul dintre domeniile în care cuantizarea vectorială este utilizată frecvent este cel al semnalului vocal.

După conversia analog-numerică realizată cu ajutorul circuitelor specializate, fiecărui eșantion  $i$  se atribuie un cod numeric, cu un anumit număr de biți. În scopul micșorării debitului de informație transmis, prin intermediul metodelor de prelucrare numerică trebuie efectuată o compresie, adică trebuie redus numărul de biți alocat fiecărui eșantion, păstrând însă eroarea obținută după reconstituirea semnalului original la valori acceptabile. Mai întâi s-a folosit în acest scop cuantizarea scalară, iar în prezent se folosește aproape exclusiv cuantizarea vectorială. Astfel, prin acest procedeu, se atribuie un cod unui grup de eșantioane sau unui vector. În acest fel se reduce numărul echivalent de biți alocat fiecărui eșantion, realizându-se compresia.

În practică se cuantizează vectorial diferite forme ale parametrilor modelului liniar predictiv al semnalului vocal, între care liniile spectrale de

frecvență (parametrii LSF) dau cele mai bune rezultate. Astfel, autorul abordează cuantizarea vectorială a parametrilor LSF, obținând rezultate deosebite în acest sens.

Teza este structurată în cinci capitole și două anexe conținând o listă cu 50 de titluri bibliografice.

Autorul aduce cele mai respectuase mulțumiri domnului profesor dr. ing. Sever Crișan pentru îndrumarea competentă dată în decursul stagiului pentru doctorat, începând cu referatele și continuând cu teza propriuzisă.

De asemenea, autorul aduce mulțumiri domnului profesor dr. ing. Eugen Pop, pentru importante indicații și sugestii date în timpul elaborării tezei.

Autorul aduce mulțumiri domnului profesor dr. ing. Liviu Toma, atât pentru sprijinul dat în elaborarea tezei precum și pentru îndrumarea competentă a întregii activități a autorului atât ca student cât și în calitate de cadru didactic.

Autorul mulțumește de asemenea colegului as. ing. Alexandru Iacovliev, pentru ajutorul dat la elaborarea programelor.

În final, autorul mulțumește doamnei Magdalena Ciobanu și domnișoarei Mihaela Șerban, care au avut o contribuție esențială la redactarea în această formă a tezei.

Timișoara, 24 septembrie 1998

Autorul

*Nănaș*

## CUPRINS

<b>Cap. 1.</b> Noțiuni introductive despre cuantizarea vectorială	5
<b>Cap. 2.</b> Cuantizarea vectorială a parametrilor LSF	21
2.1 Obținerea parametrilor LSF. Proprietăți ale parametrilor LSF	21
2.2 Metode de cuantizare vectorială a parametrilor LSF	34
<b>Cap. 3.</b> Proiectarea cărții de cod a unui cuantizor vectorial	48
3.1 Generalități	48
3.2 Utilizarea algoritmului PNN pentru cuantizarea vectorială a parametrilor LSF	49
3.2.1 Împărțirea secvenței de antrenament în buchete	50
3.2.2 Algoritmul PNN rapid. Obținerea vectorilor de reproducere	56
3.3 Analiza calității unui cuantizor vectorial în funcție de diferite forme ale erorii pătratice ponderate	65
<b>Cap. 4.</b> Cuantizarea vectorială a parametrilor LSF prin metoda combinată arbore-căutare totală	71
4.1 Cuantizarea vectorială de tip arbore	71
4.2 Principiul cuantizării vectoriale prin metoda combinată arbore-căutare totală	74
4.3 Structurarea cărții de cod a unui cuantizor vectorial în vederea aplicării metodei combinate arbore-căutare totală	77
4.3.1 Descrierea generală a procesului de structurare	77
4.3.2 Determinarea parametrilor $n_s$ și $n_d$ prin metoda intersecțiilor	82
4.3.3 Aplicarea metodei intersecțiilor pentru structurarea unei cărți de cod la un cuantizor vectorial pentru parametri LSF	88
4.4 Algoritmul de codare al cuantizării vectoriale prin metoda combinată arbore-căutare totală	102
4.5 Realizarea structurării cărții de cod și a codării pentru cazul erorii pătratice ponderate	107
<b>Cap. 5.</b> Concluzii și contribuții personale	113
<b>Anexa 1</b>	119

<b>Anexa 2</b>	121
<b>Bibliografie</b>	139

121

139

## 1. NOȚIUNI INTRODUCATIVE DESPRE CUANTIZAREA VECTORIALĂ

Cuantizarea vectorială, VQ, (vector quantization, în limba engleză) numită de Shanon "cuantizare bloc" [1] a apărut ca urmare a ideii potrivit căreia, sistemele de cuantizare pot obține rezultate mai bune dacă operează asupra unor grupuri de simboluri sau *vectori*, în locul simbolurilor individuale.

Denumirea de cuantizare vectorială s-a impus la începutul anilor 1980, când de fapt s-a trecut de la studiile teoretice, la implementarea unor algoritmi care operează asupra unor semnale reale [1].

Cuantizarea vectorială este o generalizare a cuantizării scalare. Dacă cuantizarea scalară are în general la intrare mărimi analogice, în cazul cuantizării vectoriale se acționează asupra unor semnale sub formă numerică. Scopul principal al utilizării cuantizării vectoriale este compresia datelor.

Un cuantizor vectorial este un sistem care alocă unui vector  $k$ -dimensional,  $\mathbf{x}=(x_1, x_2, \dots, x_k)$ ,  $\mathbf{x} \in \mathfrak{R}^k$ , un alt vector de aceeași dimensiune,  $\hat{\mathbf{x}}=(\hat{x}_1, \hat{x}_2, \dots, \hat{x}_k)$ ,  $\hat{\mathbf{x}} \in \mathcal{L}$ . Mulțimea  $\mathcal{L}$  conține un număr finit de vectori,  $\mathcal{L}=\{y_1, y_2, \dots, y_N\}$  și se numește *carte de cod*<sup>1</sup> sau *alfabet*, iar vectorii  $y_i$ ,  $i=1, \dots, N$ , se numesc *vectori de reproducere* sau *cuvinte de cod*.

Funcția îndeplinită de un cuantizor vectorial este  $Q: \mathfrak{R}^k \rightarrow \mathcal{L}$ ,  $\hat{\mathbf{x}}=Q(\mathbf{x})$ .




Figura 1.1: Structura unui cuantizor vectorial.

<sup>1</sup>Principalele denumiri legate de cuantizarea vectorială, scrise înclinat, au fost preluate de autor din literatură și traduse.

Un cuantizor vectorial poate fi descompus în două structuri distincte: codorul și decodorul (figura 1.1). Codorul, reprezentat prin funcția de codare  $\alpha$ , alocă unui vector  $\mathbf{x}$  un *cod* sau *simbol de canal*,  $i \in I = \{1, 2, \dots, N\}$ . Decodorul, reprezentat prin funcția de decodare  $\beta$ , alocă codului  $i$ , vectorul de reproducere  $\hat{\mathbf{x}} = \mathbf{y}_i$ . Astfel,

$$\alpha: \mathfrak{R}^k \rightarrow I; \beta: I \rightarrow \mathcal{L}. \quad (1.1)$$

De multe ori se consideră și codul  $i$  ca ieșire a cuantizorului vectorial. Acest cod este de fapt indicele vectorului de reproducere  $\mathbf{y}_i$  și se reprezintă sub formă binară. Numărul de biți necesar pentru reprezentarea codului este astfel  $\log_2 N$ . Pentru o utilizare a tuturor combinațiilor binare posibile,  $N$  se ia o putere a lui 2. Mărimea  $r = \log_2 N$  se numește *rata* unui cuantizor vectorial și se exprimă în biți pe vector. Se observă că această mărime nu depinde de numărul de biți prin care se memorează fiecare componentă a vectorilor de reproducere, ci doar de numărul acestora,  $N$ . De asemenea, uneori se folosește și rata, în biți pe componentă,  $r' = r/k$ .

Oricărui cuantizor vectorial îi este caracteristică o *partiție* a spațiului  $\mathfrak{R}^k$  în  $N$  regiuni de cuantizare,  $R_i$ ,  $i=1, \dots, N$ . O regiune de cuantizare  $R_i$  conține mulțimea vectorilor  $\mathbf{x}$  care se cuantizează prin vectorul de reproducere  $\mathbf{y}_i$ ,

$$R_i = \{\mathbf{x} \in \mathfrak{R}^k: Q(\mathbf{x}) = \mathbf{y}_i\} \quad (1.2)$$

În principiu, codorul trebuie să determine regiunea de cuantizare în care "intră" vectorul de cuantizat, deci trebuie să cunoască partiția. Decodorul conține o tabelă care are la  $N$  adrese succesive cei  $N$  vectori de reproducere  $\mathbf{y}_i$ . Deci, în momentul primirii codului  $i$ , decodorul citește vectorul aflat la adresa  $i$  în tabela respectivă.

Regiunile de cuantizare  $R_i$  sunt distincte, iar prin reuniunea lor se obține spațiul  $\mathfrak{R}^k$ ,  $R_i \cap R_j = \emptyset$  pentru  $i \neq j$ ;  $\cup R_i = \mathfrak{R}^k$ .

Procesului de cuantizare vectorială al unui vector  $\mathbf{x}$  prin  $\hat{\mathbf{x}} = Q(\mathbf{x})$  i se asociază o măsură a erorii de cuantizare,  $d(\mathbf{x}, \hat{\mathbf{x}})$ , care este o distanță între 2 vectori. Performanțele unui cuantizor vectorial se apreciază prin valoarea

medie a erorii de cuantizare,  $D=E[d(X, \hat{X})]$ , unde  $X$  reprezintă un vector aleator uniform distribuit în  $\mathfrak{R}^k$ .

Cu cât eroarea medie este mai mică, cu atât calitatea cuantizorului vectorial este mai bună. În practică, performanțele cuantizorului se apreciază prin media în timp,

$$\bar{d} = \frac{1}{n} \sum_{i=1}^n d(x_i, \hat{x}_i), \quad (1.3)$$

unde  $n$  reprezintă numărul de vectori care se cuantizează.

Cea mai folosită măsură a erorii de cuantizare este eroarea pătratică sau distanța euclidiană,

$$d(x, \hat{x}) = \|x - \hat{x}\|^2 = \sum_{i=1}^k (x_i - \hat{x}_i)^2. \quad (1.4)$$

O altă măsură a erorii de cuantizare este eroarea pătratică ponderată,

$$d(x, \hat{x}) = \sum_{i=1}^k w_i (x_i - \hat{x}_i)^2, \quad (1.5)$$

unde  $w_i$  reprezintă ponderea alocată fiecărei componente  $i$ , în acest fel putându-se accentua anumite componente ale vectorilor, considerate mai importante.

Un cuantizor vectorial se numește *mărginit*, dacă este definit pe un domeniu mărginit,  $B \subset \mathfrak{R}^k$ .


Un cuantizor vectorial se numește *regular*, dacă regiunile de cuantizare sunt convexe și, pentru fiecare cod  $i$ , vectorul de reproducere  $y_i \in \mathcal{R}_i$ . În plus, dacă regiunile de cuantizare sunt mărginite de segmente și sunt obținute prin intersecția unui număr finit de semispații de forma

$$\{x \in \mathfrak{R}^k : \langle u_v, x \rangle + v_v \geq 0\}, \quad (1.6)$$

cuantizorul vectorial se numește *politop* [1].  $u_v$  (care este un vector  $k$  - dimensional) și  $v_v$  (scalar) sunt parametrii semispațiului, iar  $\langle u_v, x \rangle$  reprezintă un produs scalar. În general, frontierele regiunilor de cuantizare sunt alcătuite din segmente care aparțin unui spațiu de dimensiune mai mică decât  $k$ , de obicei  $k - 1$ . În figura 1.2 se prezintă regiunile de cuantizare ale



unui cuantizor vectorial mărginit, pentru  $k=2$ . Punctele din interiorul regiunilor reprezintă vectorii de reproducere. Acest cuantizor este regulat pentru că regiunile sunt convexe și politop pentru că sunt mărginite de segmente de dreaptă (din spațiul  $k = 1$ ).



**Figura 1.2:** Regiunile de cuantizare și vectorii de reproducere pentru un cuantizor vectorial.

La un cuantizor vectorial regulat și politop din spațiul  $k = 3$ , regiunile de cuantizare sunt poliedre, și sunt mărginite de poligoane (din spațiul  $k = 2$ ).

Așa cum s-a mai spus, codorul trebuie să găsească regiunea de cuantizare în care intră vectorul de cuantizat. Pentru aceasta, trebuie cunoscută structura geometrică a partiției. Pentru un cuantizor vectorial regulat și politop, regiunile de cuantizare se obțin prin intersecția unui număr de semispații egal cu numărul fețelor fiecărei regiuni. Dacă se notează cu  $H_\nu$  un semispațiu,

$$H_\nu = \{\mathbf{x} \in \mathbb{R}^k : \langle \mathbf{u}_\nu, \mathbf{x} \rangle + v_\nu \geq 0\}, \quad (1.7)$$


atunci o regiune de cuantizare  $R_i$  se poate exprima ca

$$R_i = \bigcap_{\nu=1}^{L_i} H_\nu, \quad (1.8)$$

unde  $L_i$  reprezintă numărul fețelor regiunii de cuantizare  $R_i$ . Frontiera care mărginește semispațiul  $H_\nu$  se exprimă prin

$$F_\nu = \{x \in \mathfrak{R}^k : \langle u_\nu, x \rangle + v_\nu = 0\}, \quad (1.9)$$

iar fețele regiunilor de cuantizare sunt porțiuni din frontiere de tipul  $F_\nu$ .



**Figura 1.3:** Regiunea de cuantizare a unui cuantizor vectorial obținută ca intersecție de semiplane.

În figura 1.3 se prezintă o regiune de cuantizare pentru un cuantizor vectorial cu  $k = 2$ , care are 3 fețe. Ea se obține prin intersecția a 3 semiplane,  $H_1$ ,  $H_2$  și  $H_3$ , mărginite de frontierele  $F_1$ ,  $F_2$ ,  $F_3$ . Pentru a determina dacă un vector  $x \in \mathfrak{R}^2$  intră în regiunea de cuantizare din figura 1.3, codorul trebuie să verifice dacă  $\langle u_\nu, x \rangle + v_\nu \geq 0$  pentru  $\nu = 1, 2, 3$ , adică dacă  $x$  aparține fiecăruia din semiplanele  $H_\nu$ ,  $\nu = 1, 2, 3$ . Deci, codorul trebuie să cunoască ecuațiile tuturor semiplanelor prin intersecția cărora se obține regiunea de cuantizare, iar acest procedeu trebuie repetat pentru toate regiunile de cuantizare. Rezultă un număr mare de operații, ținând cont că numărul de semispații care mărginesc regiunile de cuantizare crește odată cu creșterea dimensiunii  $k$ .

Acest mod de tratare a codorului unui cuantizor vectorial are mai mult o valoare teoretică, deoarece în cele mai multe cazuri practice, există un alt mod de realizare a funcției de codare, în care partiția este complet determinată de vectorii de reproducere componenți ai cărții de cod și de măsura erorii de cuantizare.

Un cuantizor vectorial la care orice vector se cuantizează prin cel mai apropiat vector de reproducere, în sensul unei distanțe date, se numește de tip Voronoi și se spune că respectă condiția celei mai apropiate vecinătăți. În acest caz regiunile de cuantizare se pot exprima prin

$$R_i = \{x : d(x, y_i) \leq d(x, y_j), \text{ pentru orice } j \in I\} \quad (1.10)$$

adică, o regiune de cuantizare  $R_i$  conține toți vectorii  $x$  care, dacă sunt cuantizați prin vectorul de reproducere  $y_i$ , produc o eroare de cuantizare mai mică decât dacă s-ar cuantiza prin oricare alt vector de reproducere. Dacă un vector este egal depărtat de doi vectori de reproducere, atunci, convențional, codul este dat de cel mai mic dintre indicii vectorilor egal depărtați.

Codorul acestui tip de cuantizor determină codul vectorului de cuantizat în felul următor: calculează eroarea de cuantizare dintre vectorul respectiv și fiecare din cei  $N$  vectori de reproducere, după care determină cea mai mică dintre cele  $N$  erori; indicele vectorului de reproducere în raport cu care s-a obținut eroarea minimă reprezintă codul. Un astfel de proces de codare, în care vectorul de cuantizat se compară cu toți vectorii de reproducere se numește codare prin căutare totală.

În cele ce urmează se va arăta că un cuantizor vectorial care respectă condiția celei mai apropiate vecinătăți în sensul distanței euclidiene este regulat și politop.

Se definește mulțimea

$$H_{ij} = \left\{ x : \|x - y_i\|^2 \leq \|x - y_j\|^2 \right\}, \quad (1.11)$$

care conține toți vectorii  $x$  mai apropiați de vectorul de reproducere  $y_i$  decât de vectorul de reproducere  $y_j$ . Rezultă că o regiune de cuantizare  $R_i$  se poate exprima ca,

$$R_i = H_{i1} \cap H_{i2} \cap \dots \cap H_{i,i-1} \cap H_{i,i+1} \cap \dots \cap H_{iN}, \quad (1.12)$$

adică conține toți vectorii  $x$  mai apropiați de  $y_i$  decât de oricare alt vector de reproducere.

Înlocuind expresia distanței euclidiene (1.4) în (1.11), după reduceri se obține

$$H_{ij} = \left\{ x : 2 \langle (y_i - y_j) x \rangle + \|y_j\|^2 - \|y_i\|^2 \geq 0 \right\}. \quad (1.13)$$

Dacă se notează

$$\mathbf{u}_{ij} = 2(\mathbf{y}_i - \mathbf{y}_j), \quad (1.14)$$

și

$$v_{ij} = \|\mathbf{y}_j\|^2 - \|\mathbf{y}_i\|^2, \quad (1.15)$$

rezultă că

$$H_{ij} = \{\mathbf{x} : \langle \mathbf{u}_{ij}, \mathbf{x} \rangle + v_{ij} \geq 0\}$$

și ținând cont de (1.12) se poate spune că regiunile de cuantizare au aceeași formă ca și la un cuantizor vectorial regular și politop, iar structura lor depinde de vectorii de reproducere, adică de cartea de cod.

În cazul în care măsura erorii de cuantizare este eroarea pătratică ponderată, relația (1.5), concluziile de mai sus nu mai sunt valabile în totalitate. Considerând mulțimea  $H_{ij}$  de forma

$$H_{ij} = \{\mathbf{x} : d(\mathbf{x}, \mathbf{y}_i) \leq d(\mathbf{x}, \mathbf{y}_j)\} \quad (1.16)$$

unde pentru distanța  $d$  se folosește eroarea pătratică ponderată, după efectuarea calculelor se obține


$$H_{ij} = \left\{ \mathbf{x} : 2 \sum_{l=1}^k w_l x_l (y_{il} - y_{jl}) + \sum_{l=1}^k w_l (y_{jl}^2 - y_{il}^2) \geq 0 \right\} \quad (1.17)$$

Pentru cazul  $k=2$  se obține

$$\begin{aligned} H_{ij} = \{ \mathbf{x} : & 2w_1 x_1 (y_{i1} - y_{j1}) + 2w_2 x_2 (y_{i2} - y_{j2}) + w_1 (y_{j1}^2 - y_{i1}^2) + \\ & + w_2 (y_{j2}^2 - y_{i2}^2) \geq 0 \} \end{aligned} \quad (1.18)$$

În practică ponderile  $w_1$  și  $w_2$  depind de componentele vectorului de cuantizat, adică  $w_1 = w_1(x_1, x_2)$  și  $w_2 = w_2(x_1, x_2)$ . Aceasta înseamnă, conform (1.18), că ecuațiile frontierelor regiunilor de cuantizare nu conțin numai termeni în  $x_1$  și  $x_2$ , ci pot să conțină și termeni de forma  $(x_1 x_2)^2$ ,  $x_1^2$  sau  $x_2^2$  în funcție de forma funcțiilor  $w_1$  și  $w_2$ . **Adică, regiunile de cuantizare nu mai sunt mărginite de drepte, ci de curbe mai complicate (pentru  $k \geq 3$  de suprafețe mai complicate).** De aici rezultă că un astfel de cuantizor nu mai este regular și politop. Acest fapt nu afectează însă aplicabilitatea metodelor de cuantizare vectorială folosite de autor. De asemenea, tot din (1.18) rezultă că structura regiunilor de cuantizare este impusă de vectorii de reproducere la fel ca și în cazul erorii pătratice.

În figura 1.4 se prezintă structura regiunilor de cuantizare pentru un cuantizor de tip Voronoi, cu  $N=4$  vectori de reproducere,  $k=2$ , și distanța euclidiană ca măsură a erorii de cuantizare. Sunt figurate și semiplanele de tip  $H_{ij}$  prin intersectarea cărora se obțin regiunile de cuantizare. Se observă că pentru fiecare segment de dreaptă (față) care delimitează două regiuni de cuantizare există câte 2 vectori de reproducere echidistanți.



**Figura 1.4:** Structura regiunilor de cuantizare pentru un cuantizor vectorial cu  $N=4$ .

Se introduce noțiunea de *centroid* al unei regiuni  $R_i \in \mathbb{R}^k$ : acel vector,  $y^*$ , în raport cu care se minimizează eroarea medie de cuantizare a vectorilor  $X$  care aparțin acelei regiuni  $R_i$ ,

$$y^* = \text{cent}(R_i) \text{ dacă } E[d(X, y^*) | X \in R_i] < E[d(X, y) | X \in R_i], \quad (1.19)$$

pentru orice  $y \in \mathbb{R}^k$ . Dacă măsura erorii de cuantizare este eroarea pătratică, se arată, [1], că centroidul reprezintă chiar media vectorilor din regiunea respectivă,

$$\text{cent}(R_i) = E(X | X \in R_i) \quad (1.20)$$

Pentru cazul când regiunea  $R_i$  conține un număr finit de vectori relația (1.20) se poate aplica fiind necesară funcția de probabilitate discretă  $p_x(x)$ . În practică însă, adesea se consideră că fiecare vector din  $R_i$  are aceeași probabilitate, egală cu  $1/\|R_i\|$ , unde  $\|R_i\|$  reprezintă numărul de vectori din  $R_i$ . În această situație centroidul regiunii  $R_i$  este media aritmetică a vectorilor din  $R_i$ , adică

$$\text{cent}(R_i) = \frac{1}{\|R_i\|} \sum_{j=1}^{|R_i|} \mathbf{x}_j, \quad (1.21)$$

Un cuantizor vectorial pentru care vectorul de reproducere din fiecare regiune de cuantizare este reprezentat de centroidul acelei regiuni, adică

$$\mathbf{y}_i = \text{cent}(R_i), \quad i=1, \dots, N, \quad (1.22)$$

se spune că respectă condiția centroidului.

În continuare se prezintă câteva noțiuni referitoare la condițiile pe care trebuie să le îndeplinească un cuantizor vectorial pentru a fi *optim*, precum și, ca o consecință, modul cum se proiectează un cuantizor vectorial.

Un cuantizor vectorial este optim dacă cartea de cod (decodorul) și partiția sau regula de codare (codorul) conduc împreună la minimizarea erorii medii de cuantizare  $D$ , reprezentată prin media statistică  $E[d(X, Q(X))]$ . În cazul în care vectorul de intrare, reprezentat de variabila aleatoare  $X$ , are o distribuție discretă, eroarea medie de cuantizare se specifică cu ajutorul funcției de probabilitate discretă  $p_x(\mathbf{x})$ ,

$$D = E[d(X, Q(X))] = \sum_i d(\mathbf{x}_i, Q(\mathbf{x}_i)) p_x(\mathbf{x}_i), \quad (1.23)$$

unde  $\{\mathbf{x}_i\}$  sunt valorile variabilei aleatoare  $X$  care au probabilitatea diferită de 0.

Un cuantizor vectorial se numește *local* optimal dacă o mică modificare a vectorilor de reproducere nu poate produce scăderea erorii medii de cuantizare  $D$ , și, respectiv *global* optimal, dacă nu există o altă carte de cod care să producă scăderea erorii medii de cuantizare  $D$ . Așa cum se arată în [1], un cuantizor vectorial care satisface condiția celei mai apropiate vecinătăți și condiția centroidului, este cel puțin local optimal.

Pe baza celor două condiții necesare pentru un optim local se realizează proiectarea iterativă a unui cuantizor vectorial.

Pentru aceasta, trebuie să se considere o carte de cod inițială (în capitolul 3 vor fi date câteva metode de obținere a unei astfel de cărți de

cod), o măsură a erorii de cuantizare  $d(\cdot, \cdot)$ , precum și o secvență de vectori numită de *antrenament*,

$$T = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}, \quad (1.24)$$

în care fiecare vector are probabilitatea egală cu  $1/n$ .

Algoritmul generalizat al lui Lloyd [1], care va fi descris în continuare, va preciza de câte ori sau până când se va aplica procesul iterativ de optimizare a codorului pentru decodorul dat (adică aplicarea condiției celei mai apropiate vecinătăți) și invers, a decodorului pentru codorul dat (aplicarea condiției centroidului). În acest scop se definește o iterație Lloyd care cuprinde două etape:

a) partiționarea secvenței de antrenament în regiuni de cuantizare, conform condiției celei mai apropiate vecinătăți, în funcție de o carte de cod  $\mathcal{L}_m$ , pe baza măsurii erorii de cuantizare,  $d(\cdot, \cdot)$ .

b) aplicarea condiției centroidului pentru regiunile de cuantizare obținute la punctul a), în acest fel obținându-se cartea de cod

$$\mathcal{L}_{m+1} = \{\text{cent}(R_i)\}, \quad i=1, \dots, N.$$

Se definește funcția selector, caracteristică unui cuantizor vectorial,

$$S_i(\mathbf{x}) = \begin{cases} 1, & \text{daca } \mathbf{x} \in R_i \\ 0, & \text{in rest} \end{cases} \quad (1.25)$$

În acest caz centroidul unei regiuni  $R_i$  este [1]

$$\text{cent}(R_i) = \frac{\sum_{i=1}^n \mathbf{x}_i S_i(\mathbf{x}_i)}{\sum_{i=1}^n S_i(\mathbf{x}_i)}, \quad (1.26)$$

iar eroarea medie de cuantizare se poate exprima prin

$$D = \frac{1}{n} \sum_{i=1}^n \sum_{j=1}^N d(\mathbf{x}_i, \mathbf{y}_j) S_j(\mathbf{x}_i), \quad (1.27)$$

unde  $i$  reprezintă indicii vectorilor de antrenament, iar  $j$  reprezintă indicii vectorilor de reproducere.

Având în vedere că pasul a) al iterației Lloyd îmbunătățește sau lasă neschimbat codorul față de decodorul dat, iar pasul b) îmbunătățește sau lasă neschimbat decodorul față de codorul rezultat la pasul a), rezultă că în urma unei iterații Lloyd, eroarea medie de cuantizare scade sau rămâne neschimbată.

În aceste condiții se prezintă structura algoritmului generalizat al lui Lloyd pentru proiectarea unui cuantizor vectorial optim.

1. Se consideră o carte de cod inițială;  $m=1$ .
2. Dându-se cartea de cod  $\mathcal{C}_m$ , se aplică o iterație Lloyd pentru a obține o variantă îmbunătățită a cărții de cod, notată  $\mathcal{C}_{m+1}$ .
3. Se calculează eroarea medie  $D_{m+1}$  a secvenței de antrenament față de cartea de cod  $\mathcal{C}_{m+1}$ .
4. Test de ieșire. Dacă raportul  $\frac{D_m - D_{m+1}}{D_m}$  este mai mic decât o valoare de prag aleasă convenabil (cât mai mică, de exemplu 0,001), algoritmul se încheie. Dacă raportul este mai mare decât valoarea de prag, parametrul  $m$  ia valoarea  $m+1$ , și se sare la pasul 2.

Testul de ieșire verifică care este scăderea relativă a erorii la iterația curentă,  $D_{m+1}$ , față de cea de la iterația precedentă,  $D_m$ .


Algoritmul Lloyd, prin iterația Lloyd, nu modifică foarte mult cartea de cod. Acest fapt sugerează că odată aleasă cartea de cod inițială, algoritmul converge spre cel mai apropiat minim local față de cartea inițială, din spațiul tuturor cărților de cod posibile. Deoarece eroarea medie de cuantizare este o funcție complexă, care are în general mai multe minime locale, rezultă concluzia că algoritmul generalizat Lloyd nu găsește un optim global, ci un optim local.

În continuare se prezintă câteva dintre avantajele utilizării cuantizării vectoriale în raport cu cuantizarea scalară.

Considerând cazul vectorilor bidimensionali, de forma  $\mathbf{x}=(x_1, x_2)$ , prin cuantizarea scalară a celor două componente, cu câte 4 niveluri de reproducere, se obține un cuantizor vectorial echivalent cu 16 regiuni de cuantizare, ca în figura 1.5. Indiferent cum s-ar alege nivelurile de reproducere, forma regiunilor cuantizorului vectorial obținut este totdeauna dreptunghiulară. Prin aplicarea directă a cuantizării vectoriale, regiunile de



cuantizare pot să aibe forme mai complicate, adaptându-se la distribuția secvenței de antrenament, rezultând erori mai mici sau compresie.



**Figura 1.5:** *Cuantizor vectorial obținut prin cuantizarea scalară a componentelor.*

**Tabelul 1.1:** *Regula de cuantizare scalară.*

Eșantioane de cuantizat posibile	Nivelul de reproducere asociat	Codul (în zecimal)
1,2	1	0
3,4	3	1
5,6	5	2
7,8	7	3
9,10	9	4
11,12	11	5
13,14	13	6
15,16	15	7

Alt avantaj al cuantizării vectoriale rezultă când între componentele vectorilor există o dependență. De exemplu, dacă componentele vectorilor sunt eșantioanele unei forme de undă, între eșantioanele alăturate există o corelație în sensul că diferența între două eșantioane consecutive nu poate fi foarte mare, fiind în general mult mai mică decât gama dinamică a semnalului. Pentru a ilustra avantajul utilizării cuantizării vectoriale într-un astfel de caz, se consideră un semnal ale cărui eșantioane, în urma conversiei analog-numerice, iau valori între 1 și 16, iar între două

eșantioane consecutive nu poate fi o diferență mai mare decât 6 (corelația de ordinul 1, între 2 eșantioane consecutive). Aceste eșantioane se pot cuantiza scalar, alocând de exemplu, 8 niveluri de reproducere echidistante: 1,3,5,...,15. Rata cuantizării este deci  $\log_2 8 = 3$  biți/eșantion. Cuantizarea se face după regula celei mai apropiate vecinătăți, ca în tabelul 1.1.

Un eșantion egal depărtat de două niveluri se cuantizează prin cel cu indicele mai mic (de exemplu, 2 se cuantizează prin 1, nu prin 3). Grupând eșantioanele în vectori cu dimensiunea 2, se obțin vectorii de reproducere din tabelul 1.2, astfel încât diferența între componente să nu fie mai mare de 6.

Componentele vectorilor sunt aceleași cu nivelurile de reproducere de la cuantizarea scalară, dar datorită faptului că nu sunt posibile toate combinațiile de câte două, se obține un total de 44 vectori de reproducere. Rata cuantizării va fi în acest caz  $\log_2 44 = 5,46$  biți/vector, sau  $5,46/2 = 2,73$  biți/eșantion, adică mai mică decât la cuantizarea scalară, deci rezultă o compresie.

**Tabelul 1.2:** Vectorii de reproducere  $(x_1, x_2)$ .

1	1	3	1	5	1	7	1	9	3	11	5	13	7	15	9
1	3	3	3	5	3	7	3	9	5	11	7	13	9	15	11
1	5	3	5	5	5	7	5	9	7	11	9	13	11	15	13
1	7	3	7	5	7	7	7	9	9	11	11	13	13	15	15
		3	9	5	9	7	9	9	11	11	13	13	15		
				5	11	7	11	9	13	11	15				
						7	13	9	15						

Datorită faptului că vectorii de reproducere conțin aceleași componente ca și nivelurile de reproducere de la cuantizarea scalară, eroarea medie și cea maximă sunt egale în cele două cazuri (se folosește eroarea pătratică).

Dacă eșantioanele se grupează în vectori cu dimensiunea 3, impunând în plus restricția ca între componentele 1 și 3 să nu fie o diferență mai mare ca 10 (corelația de ordinul 2), se obțin vectorii de reproducere din tabelul 1.3 (doar cei care au prima componentă 1).

Se obțin în total 21 vectori de reproducere. Determinând și ceilalți vectori de reproducere posibili, adică cei cu prima componentă 3,5,...,15 se obțin 248 vectori, iar rata este  $\log_2 248 = 7,95$  biți/vector sau  $7,95/3 = 2,65$  biți/eșantion, deci compresia este mai mare decât în cazul  $k=2$ . Dimensiunea vectorilor,  $k$ , poate fi crescută până când corelația de ordinul  $k-1$  mai este suficient de puternică între componente.

**Tabelul 13:** Vectorii de reproducere ( $x_1 x_2 x_3$ ).

1 1 1	1 3 1	1 5 1	1 7 1
1 1 3	1 3 3	1 5 3	1 7 3
1 1 5	1 3 5	1 5 5	1 7 5
1 1 7	1 3 7	1 5 7	1 7 7
	1 3 9	1 5 9	1 7 9
		1 5 11	1 7 11


Desigur că în aceste exemple s-au considerat situații simple, pur teoretice, dar totuși sugestive. În practică, pentru semnale reale, se obțin compresii mai puternice.

În concluzie, se poate spune că, datorită faptului că nu toate combinațiile de 2, 3 sau mai multe componente sunt posibile, cartea de cod le "învață", pe baza secvenței de antrenament, doar pe cele mai plauzibile, în acest fel rezultând un număr echivalent de biți pe eșantion mai mic.

**Pe baza exemplelor prezentate, autorul a demonstrat proprietatea de compresie a cuantizării vectoriale.**

**O altă situație în care autorul arată avantajul cuantizării vectoriale în raport cu cuantizarea scalară este cea în care vectorii au componentele astfel încât  $x_1 < x_2 < \dots < x_k$ .** Pentru simplitate se consideră cazul  $k = 2$ . În figura 1.6 a) se prezintă regiunea în care acești vectori sunt uniform distribuiți. Utilizând cuantizarea scalară pentru componentele  $x_1$  și  $x_2$  cu câte 4 niveluri (2 biți/componentă), se obține un cuantizor vectorial cu 16 regiuni de cuantizare, figura 1.6 b). Se observă că 6 dintre regiuni, cele notate cu puncte în interior, nu sunt în zona în care sunt distribuiți vectorii. Deci cuantizarea vectorială poate folosi doar 10 regiuni, adică  $\log_2 10 = 3,32$

biți/vector sau  $3,32/2=1,66$  biți/componentă, adică se obține o compresie. O altă îmbunătățire s-ar putea face dacă cele 16 regiuni de cuantizare ale cuantizorului vectorial s-ar dispune numai în zona unde sunt distribuiți vectorii. În acest fel, regiunile de cuantizare ar avea o suprafață mai mică, permițând scăderea erorii de cuantizare, la o rată egală cu cea de la cuantizarea scalară.



**Figura 1.6:** Cuantizor vectorial pentru  $k=2$ ,  $x_1 < x_2$ .

În finalul acestui capitol se prezintă și alte caracteristici importante ale unui cuantizor vectorial, pe lângă cele prezentate anterior, adică rata și eroarea medie de cuantizare.

*Complexitatea* unui cuantizor vectorial este o mărime care reprezintă numărul de operații aritmetice care se fac pentru cuantizarea unui vector. Desigur că operația de codare necesită cele mai multe operații, decodarea fiind o operație de citire de la o adresă. De aceea, în cele mai multe cazuri, complexitatea se referă în exclusivitate la operațiile de codare. Operațiile aritmetice care se fac pot fi înmulțiri, adunări, comparații. De obicei se consideră numai operațiile de înmulțire, deoarece acestea consumă mai mult timp. Dar, deoarece actualele procesoare de semnal pot să facă înmulțirile foarte rapid, este mai corect să se considere și celelalte operații.

Astfel, în cazul general în care codarea se face prin căutare totală, în care se codează vectori  $k$ -dimensionali, cartea de cod are  $N$  elemente, iar măsura erorii de cuantizare este eroarea pătratică, pentru codarea unui vector

se fac  $Nk$  înmulțiri (ridicările la pătrat),  $Nk$  scăderi (diferențele între componentele omoloage ale vectorilor) și  $N(k-1)$  adunări (însurarea celor  $k$  diferențe). În plus mai intervin și comparațiile necesare pentru determinarea erorii minime.

*Memoria* unui cuantizor vectorial reprezintă memoria folosită în procesul de cuantizare a unui vector și este dată în cazul unei codări prin căutare totală de numărul de locații de memorie necesare pentru memorarea vectorilor de reproducere, adică  $2Nk$  octeți, dacă fiecare componentă se memorează prin 2 octeți.

Când se analizează performanțele unui cuantizor vectorial se iau în considerare aceste caracteristici adică: rata, eroarea medie, complexitatea și memoria. Desigur că ideal ar fi ca toate aceste caracteristici să aibe valori cât mai mici, dar ele depind una de alta și de aceea se caută un compromis. De exemplu, se impune o rată și se dorește minimizarea erorii, sau se impune o eroare și se încearcă minimizarea complexității sau alte variante. În acest fel se obțin cuantizoare vectoriale numite *suboptimale*. Cartea de cod pentru un astfel de cuantizor are o structură care nu respectă cele două condiții de optim, permițând o căutare mai rapidă în vederea determinării codului vectorului de cuantizat. Datorită acestor cauze, vectorul de reproducere găsit nu este cel care produce eroarea de cuantizare minimă posibilă. Avantajul obținut este însă reducerea complexității și (sau) a memoriei, eroarea crescând însă mai puțin, astfel că, pe ansamblu, analizând toate mărimile caracteristice ale cuantizorului vectorial se poate aprecia că s-a obținut o îmbunătățire.

În capitolul 1 autorul a prezentat sub o formă sistematizată principalele noțiuni și principii utilizate la cuantizarea vectorială, precum și unele contribuții originale.

## 2. CUANTIZAREA VECTORIALĂ A PARAMETRILOR LSF

### 2.1 Obținerea parametrilor LSF. Proprietăți ale parametrilor LSF

Cuantizarea vectorială se aplică în prezent la semnalul vocal și la cel de imagine. În cazul prelucrării semnalului vocal, domeniu studiat de către autor, cuantizarea vectorială s-a aplicat la început pentru vectori formați din eșantioane consecutive prelevate din semnalul vocal, iar apoi pentru vectori formați din diferite forme ale parametrilor obținuți prin predicție liniară (se numesc parametri LPC-linear predicativ coding). De obicei, predicția liniară se face pentru porțiuni de semnal vocal care conțin 20-25 ms, numite cadre, [10], [11]. În ultimul timp [4], [5], [6] s-a arătat că reprezentarea sub formă de linii spectrale de frecvență (LSF) a parametrilor LPC, dă rezultate foarte bune la cuantizarea vectorială.

Parametrii LSF se obțin din parametrii LPC printr-o transformare 1 la 1, adică dintr-un număr de parametri LPC (sub formă de coeficienți de predicție) se obține același număr de parametri LSF, [43]. Astfel, dacă se face o analiză prin predicție liniară de ordinul  $p$ , se obțin  $p$  coeficienți de predicție  $a_1, a_2, \dots, a_p$ .  $A(z)$  este polinomul construit cu acești coeficienți,

$$A(z) = 1 - a_1 z^{-1} - a_2 z^{-2} - \dots - a_p z^{-p}, \quad (2.1)$$

iar apoi cu  $A(z)$  se formează polinoamele

$$P(z) = A(z) + z^{-(p+1)} A(z^{-1}) \quad (2.2)$$

și

$$Q(z) = A(z) - z^{-(p+1)} A(z^{-1}) \quad (2.3)$$

Pe baza rădăcinilor polinoamelor  $P(z)$  și  $Q(z)$  se obțin parametrii LSF. În cazul  $p=10$  (folosit în marea majoritate a cazurilor practice), polinoamele  $P(z)$  și  $Q(z)$  au gradul 11. Datorită faptului că au coeficienți reali, pe lângă rădăcinile reale,  $-1$  pentru  $P(z)$  și  $+1$  pentru  $Q(z)$ , aceste polinoame au

rădăcini complex conjugate. Rădăcinile complex conjugate ale acestor polinoame au următoarele proprietăți [4]:

1° Se găsesc pe cercul unitar, deci au modulul egal cu 1.

2° Dacă argumentele, în valoare absolută, ale acestor rădăcini se aranjează în ordine crescătoare, vor fi intercalate.

Dacă rădăcinile lui  $P(z)$  se notează:  $e^{\pm j\omega_1}, e^{\pm j\omega_3}, \dots, e^{\pm j\omega_9}$ , iar cele ale lui  $Q(z)$ :  $e^{\pm j\omega_2}, e^{\pm j\omega_4}, \dots, e^{\pm j\omega_{10}}$ , proprietatea 2° se poate reprezenta sub forma:

$$\omega_1 < \omega_2 < \omega_3 < \dots < \omega_{10}. \quad (2.4)$$

Parametrii LSF se obțin prin relația:

$$f_i = \frac{\omega_i}{2\pi} f_e, \quad i = 1, 2, \dots, 10, \quad (2.5)$$

unde  $f_e$  reprezintă frecvența de eșantionare. Dacă de exemplu,  $f_e = 8\text{kHz}$ , parametrii LSF vor avea valori în intervalul (0, 4000) Hz. Uneori, parametrii LSF se consideră sub formă normalizată  $\omega_i$ , având valori în intervalul (0,  $\pi$ ).

Pentru cuantizarea vectorială, vectorii se formează din cei 10 parametri LSF corespunzători cadrelor, care, fiind în ordine crescătoare, prezintă un avantaj așa cum s-a arătat în capitolul 1. Dacă în urma cuantizării, parametrii LSF își păstrează proprietatea 2°, polinomul  $A(z)$  își păstrează proprietatea de fază minimă, filtrul de reconstituire al semnalului vocal  $H(z) = 1/A(z)$  fiind stabil [4]. Polinomul  $A(z)$  se reconstituie ușor din parametrii LSF cuantizați, deoarece se știe că pe baza parametrilor cu indice impar se formează  $P(z)$ , iar din cei cu indice impar  $Q(z)$ , iar apoi


$$A(z) = (P(z) + Q(z)) / 2. \quad (2.6)$$

Coefficienții polinomului  $A(z)$  astfel obținut reprezintă coeficienții de predicție  $a_i$ .

Pentru a determina legătura dintre liniile spectrale de frecvență și densitatea spectrală de putere normalizată,  $S(f)$ , calculată pe baza coeficienților de predicție (pe scurt, spectrul LPC)

$$S(f) = \frac{1}{\left| A(e^{j2\pi f/f_e}) \right|^2}, \quad (2.7)$$

în figura 2.1 se arată forma de variație a spectrului LPC pentru un cadru de semnal vocal achiziționat de autor și liniile spectrale de frecvență aferente, reprezentate prin liniile verticale, acestea având următoarele valori, în Hz: 204, 329, 789, 899, 1488, 1671, 2030, 2604, 2925, 3475.



**Figura 2.1:** *Spectrul LPC și parametrii LSF aferenți.*

Din figura 2.1 se observă că grupuri de 2 sau 3 parametri LSF caracterizează un vârf din spectru (un formant în cazul unui semnal vocal), iar lățimea vârfului este proporțională cu intervalul de frecvență acoperit de parametrii LSF respectivi.

În continuare, autorul dezvoltă, pe baza unor experimente ale căror rezultate se vor justifica teoretic, legătura dintre spectrul LPC și parametrii LSF, în scopul de a determina o reprezentare simplificată a spectrului LPC, în funcție de parametrii LSF.

În cazul în care  $|z|=1$ , valabil pentru rădăcinile polinoamelor  $P(z)$  și  $Q(z)$ , rezultă:



$$z = \cos \omega + j \sin \omega = e^{j\omega} \quad (2.8 \text{ a})$$

și

$$z^* = \cos \omega - j \sin \omega = e^{-j\omega} = \frac{1}{z} = z^{-1}. \quad (2.8 \text{ b})$$

Știind că

$$|A(z)|^2 = A(z) \cdot A(z^*),$$

se obține

$$|A(z)|^2 = A(z) \cdot A(z^{-1}) = \frac{P(z) + Q(z)}{2} \cdot \frac{P(z^{-1}) + Q(z^{-1})}{2}$$

Deoarece, pe baza relațiilor de definiție ale polinoamelor  $P(z)$  și  $Q(z)$ , (2.2) și (2.3), se poate demonstra că

$$P(z)Q(z^{-1}) + P(z^{-1})Q(z) = 0,$$

rezultă că

$$|A(z)|^2 = \frac{|P(z)|^2 + |Q(z)|^2}{4} \quad (2.9)$$

Apoi, pe baza relației (2.7) se obține:

$$S(f) = \frac{4}{|P(z)|^2 + |Q(z)|^2}, \quad (2.10)$$

unde  $z = e^{j\omega} = e^{j \frac{2\pi f}{f_e}}$ . Pe de altă parte, ținând cont de rădăcinile pe care le au, polinoamele  $P(z)$  și  $Q(z)$  se pot exprima ca

$$P(z) = z^{-11}(z+1)(z-e^{j\omega_1})(z-e^{-j\omega_1})(z-e^{j\omega_3}) \cdot (z-e^{-j\omega_3}) \dots (z-e^{j\omega_9})(z-e^{-j\omega_9}) \quad (2.11)$$

și

$$Q(z) = z^{-11}(z-1)(z-e^{j\omega_2})(z-e^{-j\omega_2})(z-e^{j\omega_4}) \cdot (z-e^{-j\omega_4}) \dots (z-e^{j\omega_{10}})(z-e^{-j\omega_{10}}) \quad (2.12)$$

Știind că  $\omega_i = 2\pi f_i / f_e$ , înlocuind  $P(z)$  și  $Q(z)$  date de relațiile (2.11) și (2.12) în (2.10) se obține o expresie a spectrului LPC,  $S(f)$ , în funcție de parametrii LSF,  $f_i$ .

Pentru calculul valorilor  $S(f)$  pentru valorile  $f_1, f_3, \dots, f_9$  se observă că, în oricare din aceste puncte, polinomul  $P(z)$  se anulează, iar pentru oricare

din valorile  $f_2, f_4, \dots, f_{10}$  se anulează polinomul  $Q(z)$ . În concluzie, se poate spune că în punctele  $f_1, f_3, \dots, f_9$  spectrul depinde numai de rădăcinile lui  $Q(z)$  adică  $f_2, f_4, \dots, f_{10}$ , iar în punctele  $f_2, f_4, \dots, f_{10}$ , spectrul depinde de rădăcinile lui  $P(z)$ , adică  $f_1, f_3, \dots, f_9$ ,

$$S(f_k) = \begin{cases} \frac{4}{|Q(e^{j2\pi f_k / f_e})|^2}, & \text{pentru } k = 1, 3, \dots, 9 \\ \frac{4}{|P(e^{j2\pi f_k / f_e})|^2}, & \text{pentru } k = 2, 4, \dots, 10 \end{cases} \quad (2.13)$$


Înlocuind în relația (2.13) expresiile lui  $P(z)$  și  $Q(z)$  date de relațiile (2.11) și (2.12), se obține pentru spectrul  $S(\omega_k)$  relația:

$$S(\omega_k) = \begin{cases} \frac{4}{|z^{11}(z - e^{j0})(z - e^{j\omega_2})(z - e^{-j\omega_2}) \dots (z - e^{j\omega_{10}})(z - e^{-j\omega_{10}})|^2} \\ \text{pentru } k = 1, 3, \dots, 9 \\ \frac{4}{|z^{11}(z - e^{j\pi})(z - e^{j\omega_1})(z - e^{-j\omega_1}) \dots (z - e^{j\omega_9})(z - e^{-j\omega_9})|^2} \\ \text{pentru } k = 2, 4, \dots, 10 \end{cases} \quad (2.14)$$


unde  $z = e^{j\omega_k}$ . Deoarece  $f_k = \frac{\omega_k}{2\pi} f_e$ ,  $S(f_k)$  și  $S(\omega_k)$  sunt echivalente.

Numitorul lui  $S(\omega_k)$  exprimat prin (2.14) conține un produs de 11 factori, deoarece  $|z^{11}| = 1$ .

Pentru un caz oarecare, de exemplu  $f = f_3$  sau  $z = e^{j\omega_3} = e^{j2\pi f_3 / f_e}$ , în figura 2.2 se arată cum se obțin cei 11 factori cu ajutorul cercului trigonometric. Pe cerc sunt figurate punctele de argument  $\omega = \pm\omega_2$ ,  $\omega = \pm\omega_4$ ,  $\omega = \pm\omega_6$ ,  $\omega = \pm\omega_8$ ,  $\omega = \pm\omega_{10}$  precum și punctul de argument 0. Se obțin 11 segmente care unesc punctul  $\omega = \omega_3$  cu cele 11 puncte amintite anterior. Ridicând la pătrat fiecare din măsurile celor 11 segmente, se obțin cei 11 factori care constituie numitorul expresiei din (2.14).



**Figura 2.2:** Ilustrativă pentru obținerea celor 11 factori din expresia spectrului în punctul  $f=f_3$ .



**Figura 2.3:** Spectrul inițial (cu linie continuă) și spectrul modificat obținut prin schimbarea valorii parametrului  $f_4$ .

În figura 2.3 se prezintă modificarea produsă în spectrul LPC datorită modificării valorii unui singur parametru LSF. Astfel, graficul desenat cu

linie continuă s-a obținut pentru următoarele valori ale parametrilor LSF, în Hz (obținute experimental): 307, 646, 940, 1425, 1558, 1788, 2220, 2515, 3065, 3234. Graficul desenat cu linie întreruptă s-a obținut pentru cazul când  $f_4=1395$  Hz, ceilalți 9 parametri nemodificându-se.

Așa cum s-a arătat anterior din punct de vedere teoretic, din figură se observă că, în punctele  $f=f_2$ ,  $f=f_6$ ,  $f=f_8$ , și  $f=f_{10}$ , spectrul nu este afectat de modificarea parametrului  $f_4$ . Cele mai mari modificări se produc în punctele  $f=f_3$  și  $f=f_5$ . În punctul  $f=f_3$ , modificarea spectrului are loc, așa cum rezultă din analiza figurii 2.2, datorită modificării segmentelor care unesc punctul de argument  $\omega_3$  cu punctele de argumente  $\omega_4$  și  $-\omega_4$ . Este evident că modificarea segmentului  $\omega_3$ ;  $\omega_4$  este mult mai mare decât cea a segmentului  $\omega_3$ ;  $-\omega_4$ . În mod asemănător se poate explica modificarea spectrului în punctul  $f=f_5$ , care este de asemenea învecinat cu  $f_4$ , parametrul modificat.

Tot din figura 2.3 se observă că în punctele  $f=f_1$  și  $f=f_7$ , modificările spectrului sunt mai mici decât în  $f=f_3$  și  $f=f_5$ . Deoarece punctele  $f=f_1$  și  $f=f_7$  sunt mai depărtate de  $f_4$ , modificarea lui  $f_4$  produce o modificare mai mică a segmentelor  $\omega_1$ ;  $\omega_4$  și  $\omega_7$ ;  $\omega_4$  față de segmentele  $\omega_3$ ;  $\omega_4$  și  $\omega_5$ ;  $\omega_4$ . Și în acest caz, modificarea segmentelor  $\omega_1$ ;  $-\omega_4$  și  $\omega_7$ ;  $-\omega_4$  este mică.

În fine, în punctul  $f=f_9$  nu se observă o modificare a spectrului, deoarece acest punct este cel mai îndepărtat de  $f_4$ , segmentele  $\omega_3$ ;  $\omega_4$  și  $\omega_5$ ;  $-\omega_4$  având variații foarte mici.

În continuare se dorește obținerea unei expresii mai simple pentru  $S(f_k)$ . Pentru aceasta se consideră cazul unui semnal vocal pentru care parametrii LSF sunt egali depărtați în intervalul (0,...,4000)Hz, adică:

$$f_k = k \cdot \frac{4000}{p+1} = k \cdot \frac{4000}{11}, k = 1, 2, \dots, 10, \quad (2.15)$$

sau

$$\omega_k = k \cdot \frac{\pi}{p+1} = k \cdot \frac{\pi}{11}. \quad (2.16)$$

Se notează

$$\alpha = \omega_{k+1} - \omega_k = \frac{\pi}{p+1} = \frac{\pi}{11}, \quad (2.17)$$

reprezentând diferența dintre 2 parametri LSF consecutivi.

În cele ce urmează se va demonstra că, în acest caz, densitatea spectrală de putere are valoarea 1 la oricare dintre valorile parametrilor LSF, [47]. Mai întâi se găsește o altă exprimare pentru termenii de forma  $\left| (z - e^{\pm j\omega_i}) \right|^2$  situați la numitorul expresiilor din relația (2.14).

$$\begin{aligned} \left| z - e^{j\omega_i} \right|^2 &= \left| e^{j\omega} - e^{j\omega_i} \right|^2 = \left| \cos\omega + j\sin\omega - \cos\omega_i - j\sin\omega_i \right|^2 = \\ &= \left| -2\sin\frac{\omega + \omega_i}{2} \sin\frac{\omega - \omega_i}{2} + 2j\sin\frac{\omega - \omega_i}{2} \cos\frac{\omega + \omega_i}{2} \right|^2 = \\ &= 4\sin^2\frac{\omega - \omega_i}{2} \end{aligned} \quad (2.18)$$

Înlocuind relația (2.18) în relația (2.14) se obține următoarea exprimare pentru  $S(\omega_k)$

$$S(\omega_k) = \begin{cases} \frac{1}{2^{20} \sin^2 \frac{\omega_k}{2} \prod_{i=1}^5 \pi \sin^2 \frac{\omega_k - \omega_{2i}}{2} \sin^2 \frac{\omega_k + \omega_{2i}}{2}}, & \text{pentru } k = 1, 3, \dots, 9 \\ \frac{1}{2^{20} \cos^2 \frac{\omega_k}{2} \prod_{i=1}^5 \pi \sin^2 \frac{\omega_k - \omega_{2i-1}}{2} \sin^2 \frac{\omega_k + \omega_{2i-1}}{2}}, & \text{pentru } k = 2, 4, \dots, 10. \end{cases} \quad (2.19)$$

În continuare, pe baza relației (2.17),  $S(\omega_k)$  poate fi exprimată sub forma:

$$S(\omega_k) = \frac{1}{\left(2^5 \sin \frac{\alpha}{2} \sin \frac{3\alpha}{2} \sin \frac{5\alpha}{2} \sin \frac{7\alpha}{2} \sin \frac{9\alpha}{2}\right)^4}$$

pentru  $k = 1, 2, \dots, 10$  (2.20)

adică, din cele 11 segmente reprezentate în figura 2.2, unul are valoarea 2, iar celelalte 10 sunt egale două câte două.

Prin transformări trigonometrice elementare se obține succesiv:

$$\begin{aligned} S(\omega_k) &= \frac{1}{\left(2^5 \sin \frac{\alpha}{2} \sin \frac{3\alpha}{2} \sin \frac{5\alpha}{2} \cos 2\alpha \cdot \cos \alpha\right)^4} = \\ &= \frac{1}{\left(2^5 \sin \frac{\alpha}{2} \cos 4\alpha \cos 3\alpha \cos 2\alpha \cos \alpha\right)^4} = \\ &= \left(\frac{\cos \frac{\alpha}{2}}{2^4 \sin \alpha \cos \alpha \cos 2\alpha \cos 4\alpha \cos 3\alpha}\right)^4 = \\ &= \left(\frac{\cos \frac{\alpha}{2}}{2 \sin 8\alpha \cos 3\alpha}\right)^4 = \left(\frac{\cos \frac{\alpha}{2}}{2 \sin 3\alpha \cos 3\alpha}\right)^4 = \left(\frac{\cos \frac{\alpha}{2}}{\sin 6\alpha}\right)^4 = 1 \end{aligned}$$

(2.21)

adică

$$S(\omega_k) = 1, \text{ pentru } \omega = \omega_k, k = 1, 2, \dots, 10 \quad (2.22)$$

Pentru obținerea unei formule aproximative pentru  $S(\omega_k)$ , valabilă pentru orice valori  $\omega_k$ , se fac niște aproximări în relația (2.21) astfel:

-funcțiile sinus se înlocuiesc cu argumentul, ceea ce înseamnă, referitor la cercul trigonometric din figura 2.2, că cele mai mici 6 segmente se înlocuiesc cu arcele corespunzătoare.

-funcțiile cosinus se înlocuiesc cu valoarea 1, adică cele mai mari 4 segmente, din cercul trigonometric, se înlocuiesc cu valoarea 2.

În acest fel, se obține:

$$S(\omega_k) = K \cdot \frac{1}{\alpha^{12}}, \quad (2.23)$$

în care  $\alpha$  se stabilește ținând cont de următoarele:

1.  $S(\omega_k)$  pentru  $k=2,4,\dots,10$  depinde numai de valorile  $\omega_k$ ,  $k=1,3,\dots,9$  iar pentru  $k=1,3,\dots,9$  depinde de valorile  $\omega_k$ ,  $k=2,4,\dots,10$ .
2.  $S(\omega_k)$  pentru  $k=1,2,\dots,10$  depinde în special de valorile  $\omega_k$  mai apropiate, așa cum autorul a demonstrat anterior.

Constanta  $K$  se stabilește astfel încât pentru repartiția uniformă a parametrilor LSF, să se obțină  $S(\omega_k) = 1$ , pentru  $k=1,2,\dots,10$ .

Astfel, pentru a se obține cea mai simplă formă de exprimare a  $S(\omega_k)$ ,  $\alpha$  se exprimă ca diferență față de cei 2 parametri LSF învecinați, adică:

$$S(f_k) = K \cdot \frac{1}{(f_{k+1} - f_k)^6 (f_k - f_{k-1})^6} \quad (2.24)$$

unde  $K = \left[ \frac{f_e}{2(p+1)} \right]^{12}$ , și  $K=5,35 \times 10^{30}$  pentru  $f_e=8000\text{Hz}$  și  $p=10$ .

Făcându-se din nou referire la cercul trigonometric din figura 2.2, expresia lui  $S(f_k)$  dată prin relația (2.24) calculează cele mai mici 2 segmente care au punctul comun în punctul de argument  $\omega_k$ . Celelalte 4 segmente care au fost înlocuite cu arcele corespunzătoare pentru obținerea relației (2.23), se consideră că au valori proporționale cu cele 2 segmente mai mici, constantele de proporționalitate fiind incluse în constanta  $K$ .

O altă relație pentru  $S(f_k)$  care permite aproximarea cu erori (medii) mai mici, se obține dacă se utilizează pentru calculul lui  $\alpha$  nu numai frecvențele  $f_{k-1}$  și  $f_{k+1}$  ci și  $f_{k-3}$  și  $f_{k+3}$ . În acest fel sunt necesare pentru calculul lui  $S(f_k)$ ,  $k=1,2,\dots,10$ , frecvențele  $f_k$ ,  $k=-2,-1,0,1,\dots,12,13$ , așa cum rezultă din tabelul 2.1.

**Tabelul 2.1:** Valorile lui  $f_k$ ,  $k=-2,-1,0,1,\dots,12,13$ .

$k$	-2	-1	0	1	2	3	4	5	6	7	8	9	10	11	12	13
$f_k$	$-f_2$	$-f_1$	0	$f_1$	$f_2$	$f_3$	$f_4$	$f_5$	$f_6$	$f_7$	$f_8$	$f_9$	$f_{10}$	$f_e/2$	$f_e - f_{10}$	$f_e - f_9$

Pentru mărimea  $\alpha$  din relația (2.23), se consideră o valoare care depinde de valorile mai mari decât  $f_k$ ,

$$\alpha = \frac{3(f_{k+1} - f_k) + (f_{k+3} - f_k)}{6} = \frac{f_{k+3} + 3f_{k+1} - 4f_k}{6} \quad (2.25)$$

pentru  $k=1,2,\dots,10$ ,

respectiv o valoare care depinde de valorile mai mici decât  $f_k$ ,

$$\alpha = \frac{3(f_k - f_{k-1}) + (f_k - f_{k-3})}{6} = \frac{4f_k - 3f_{k-1} - f_{k-3}}{6} \quad (2.26)$$

pentru  $k=1,2,\dots,10$ .

Utilizarea acestor valori pentru  $\alpha$  conduce pe baza relației (2.23) la:

$$S(f_k) = K_1 \cdot \frac{1}{(f_{k+3} + 3f_{k+1} - 4f_k)^6 (4f_k - 3f_{k-1} - f_{k-3})^6} \quad (2.27)$$

pentru  $k=1,2,\dots,10$ .

unde  $K_1 = 6^{12} K = \left(\frac{3f_e}{p+1}\right)^{12}$  și  $K_1 = 1,16 \cdot 10^{40}$ , pentru  $p=10$  și  $f_e=8000$  Hz.

Adoptarea relațiilor (2.25) și (2.26) pentru  $\alpha$ , se justifică prin aceea că trebuie ținut cont cumva că parametrii LSF nu sunt uniform distribuiți. În acest sens,  $\alpha$  ia o valoare medie în care intervine și următorul parametru de care depinde  $S(f_k)$ , adică  $f_{k+3}$  și, respectiv  $f_{k-3}$ . Dacă se consideră că intervalul  $f_{k+3} - f_k$  este egal cu de 3 ori intervalul  $f_{k+1} - f_k$ , atunci se face o împărțire la 6, pentru a se obține o valoare medie a lui  $\alpha$ .

**În acest fel autorul a obținut două relații aproximative și simplificate, 2.24 și 2.27, pentru calculul densității spectrale de putere. Aceste relații vor fi folosite așa cum se va vedea în capitolul 3, la calculul erorii pătratic ponderate, folosită la cuantizarea vectorială a parametrilor LSF.** Pentru o primă evaluare a acestor relații, în tabelul 2.2 se arată, pentru 2 cadre diferite obținute experimental, cu câte 10 parametri LSF,  $f_{k1}$  și  $f_{k2}$ , valorile densității spectrale de putere calculate cu cele 2 relații propuse, comparativ cu valoarea exactă calculată cu relația 2.19.

Privind rezultatele din tabelul 2.2, se poate observa, așa cum se anticipa, o diferență mai mică, în raport cu valoarea exactă calculată cu




relația (2.19), a valorilor  $S(f_k)$  calculate cu relația (2.27), și respectiv o diferență mai mare a valorilor calculate cu relația (2.24). Trebuie însă subliniat că, la eroarea pătratică ponderată, unde se vor folosi aceste valori, este necesară puterea 1/6 din  $S(f_k)$ , ceea ce are ca efect apropierea acestor valori. De asemenea interesează variația relativă a valorilor  $S(f_k)$  alăturate, necontând așa de mult valoarea lor absolută.


**Tabelul 2.2:** Valorile lui  $S(f_k)$  pentru 2 cadre de semnal vocal.

$k$	1	2	3	4	5	6	7	8	9	10
$f_{k1}$ [Hz]	257	456	716	998	1538	1668	2230	2506	2972	3526
$S(f_{k1})$ cu rel.(2.24)	298	278	34	0,42	44	35	0,38	1,17	0,01	0,01
$S(f_{k1})$ cu rel.(2.27)	189	55	30	1,35	4,75	2,78	0,20	0,59	0,02	0,02
$S(f_{k1})$ cu rel.(2.19)	198	59	49	4,27	8,39	5,33	0,36	0,51	0,04	0,04
$f_{k2}$ [Hz]	190	435	817	988	1567	1815	2214	2591	2910	3418
$S(f_{k2})$ cu rel.(2.24)	524	7,94	68	5,66	0,60	5,68	0,46	1,76	0,29	0,01
$S(f_{k2})$ cu rel.(2.27)	307	13	17	3,38	0,68	2,86	0,35	0,66	0,14	0,01
$S(f_{k2})$ cu rel.(2.19)	205	20	33	9,4	1,67	2,51	0,43	0,53	0,15	0,03

În figura 2.4 se prezintă grafic valorile  $S(f_k)$  în punctele corespunzătoare parametrilor LSF, calculate cu (2.24) (cu linie întreruptă) comparativ cu cele calculate cu relația exactă (2.19) (cu linie continuă), iar în figura 2.5 se prezintă grafic valorile  $S(f_k)$  calculate cu (2.27) (cu linie întreruptă) comparativ cu cele calculate cu relația exactă (2.19). Din aceste grafice se observă că valorile  $S(f_k)$  calculate cu (2.24) au variații mai mari



**Figura 2.4:** Densitatea spectrală de putere calculată cu relațiile (2.24), (cu linie întreruptă) și (2.19).



**Figura 2.5:** Densitatea spectrală de putere calculată cu relațiile (2.27) (cu linie întreruptă) și (2.19).

decât cele calculate cu (2.27). Explicația este că, dacă cel puțin unul din intervalele  $f_{k+1} - f_k$  sau  $f_k - f_{k-1}$  sunt mici, aproximarea făcută consideră că și celelalte intervale sunt la fel de mici, (în realitate acestea sunt mai mari) rezultând valori mai mari pentru  $S(f_k)$ . Justificarea este similară când cel puțin unul din intervalele menționate anterior sunt mari.

**În concluzie, avantajul principal obținut prin utilizarea celor două relații propuse de autor este reducerea cantității de calcul.**

## 2.2 Metode de cuantizare vectorială ale parametrilor LSF

În deschiderea acestui subcapitol se prezintă modul în care se apreciază calitatea unui cuantizor vectorial pentru parametri LSF. Cerința primordială în cazul cuantizării unor parametri care caracterizează semnalul vocal este ca, semnalul reconstituit pe baza parametrilor cuantizați să nu producă erori sesizabile de către un ascultător oarecare, în raport cu semnalul original. În acest scop s-a introdus *eroarea spectrală*, care este o măsură a pătratului diferenței ariilor dintre cele două spectre, cel al semnalului original și cel al semnalului reconstituit din parametrii cuantizați, având expresia [4]

$$SD_i^2 = \frac{2}{f_e} \int_0^{f_e/2} \left[ 10 \log_{10}(S_i(f)) - 10 \log_{10}(\hat{S}_i(f)) \right]^2 df \quad (2.28)$$

unde  $i$  reprezintă indicele cadrului de semnal vocal pentru care s-a făcut analiza prin predicție liniară, iar  $S_i(f)$  și  $\hat{S}_i(f)$  sunt spectrele LPC obținute din parametrii LPC necuantizați, respectiv cuantizați. Luându-se în considerare eroarea spectrală pentru toate cadrele, se consideră că se obține o cuantizare "transparentă", adică nu se introduc erori sesizabile, dacă [4],

1. Eroarea spectrală medie este în jurul valorii de 1 dB.
2. Nu există cadre cu erori spectrale mai mari decât 4 dB.
3. Numărul cadrelor cu erori spectrale în gama 2÷4 dB este mai mic decât 2% din totalul cadrelor.

Pentru a se calcula valoarea medie a erorii spectrale, se cuantizează vectorial un grup de vectori LSF, diferiți de vectorii de antrenament, numiți vectori de test.

Parametrii LSF au fost cuantizați la început scalar, adică fiecare componentă din cele 10 s-a cuantizat individual. S-a constatat că sunt necesari între 32 și 36 de biți [7] pentru realizarea unei cuantizări transparente. Adică, fiecare parametru LSF necesită 3÷4 biți sau 8÷16 niveluri de cuantizare în cartea de cod.

Cuantizarea vectorială a fost aplicată la început pentru parametrii LPC sub formă de coeficienți de predicție, și, utilizându-se 10 biți pentru un cadru s-au obținut performanțe comparabile cu cele ale cuantizării scalare la 24 biți/cadru [7]. Eroarea spectrală medie obținută era însă inacceptabilă (3,35 dB), ceea ce a implicat creșterea în continuare a numărului de biți alocat. Dar acest lucru era practic imposibil deoarece atât complexitatea cât și memoria cresc exponențial cu numărul de biți alocat cărții de cod (vezi capitolul 1 al acestei lucrări). În aceste condiții soluția adoptată în literatură a fost folosirea cuantizatoarelor vectoriale suboptimale, care permit reducerea complexității și a memoriei, crescând însă eroarea.

O primă metodă de cuantizare vectorială suboptimală folosită pentru parametrii LSF, care face parte din categoria mai mare a metodelor de tip cod produs, este cuantizarea vectorială prin desplicare sau partiționare [4],[43]. Conform acestei metode, vectorul de cuantizat se desplică într-un număr de subvectori (de regulă 2 sau 3). De exemplu, în cazul desplicării în 2 subvectori, primul subvector conține primele  $n_1$  componente (parametri LSF), iar al doilea următoarele  $n_2=k-n_1$  componente. Pentru fiecare subvector se proiectează separat câte o carte de cod, iar fiecare subvector se cuantizează separat cu ajutorul cărții de cod aferente. Versiunea cuantizată a vectorului inițial se obține alăturând versiunile cuantizate ale celor 2 subvectori. Această metodă este suboptimală deoarece împărțind vectorii în subvectori, se pierde avantajul datorat dependenței între cei 10 parametri LSF.

Folosindu-se eroarea pătratică ca măsură a erorii de cuantizare, în [4] se obține o cuantizare transparentă pentru o rată de 26 biți/vector (13 biți

pentru primul subvector având  $n_1=4$  componente și 13 biți pentru al doilea subvector, cu  $n_2=6$  componente).

Tot în [4] se folosește apoi eroarea pătratică ponderată ca măsură a erorii de cuantizare. Așa cum s-a arătat în capitolul 1, o eroare pătratică ponderată dă o mai mare importanță unor componente ale vectorilor în raport cu altele, în sensul că cele  $k$  diferențe la pătrat între componentele similare ale celor 2 vectori între care se calculează distanța, sunt înmulțite cu coeficienți diferiți. În acest fel, componentele cu ponderi mari vor introduce termeni mai mari în eroarea totală. De aceea, pentru vectorul de cuantizat, trebuie să se găsească un vector de reproducere, care are componentele cu pondere mare mult mai apropiate față de cele similare ale vectorului de cuantizat, astfel micșorându-se termenii respectivi în eroarea totală. Rezultatul este că, componentele cu pondere mare vor fi cuantizate mai precis decât cele cu pondere mai mică. În cazul cuantizării vectoriale a parametrilor LSF, ponderile trebuie alese astfel încât eroarea spectrală  $SD$  să fie cât mai mică. Asta înseamnă că porțiunile din spectru corespunzătoare vârfurilor sau zonelor cu amplitudine mare trebuie reproduse mai exact în urma cuantizării. De aici a rezultat ideea ca ponderea fiecăreia din cele 10 componente să fie proporțională cu valoarea spectrului la frecvența corespunzătoare parametrului LSF respectiv,

$$w_i = [S(f_i)]^r, \quad (2.29)$$

iar

$$d(f, \hat{f}) = \sum_{i=1}^{10} [w_i (f_i - \hat{f}_i)]^2, \quad (2.30)$$

unde  $r$  este o constantă determinată experimental, având valori în intervalul  $[0,15; 0,2]$ . Ponderile  $w_i$ ,  $i=1, \dots, 10$  au valori variabile de la un cadru la altul, în funcție de forma spectrului pentru cadrul respectiv. În plus, pentru a accentua și mai mult parametrii LSF corespunzători frecvențelor joase se mai introduce o pondere suplimentară care are aceeași valoare indiferent de cadru,

$$c_i = \begin{cases} 1 & \text{pentru } 1 \leq i \leq 8 \\ 0,8 & \text{pentru } i = 9 \\ 0,4 & \text{pentru } i = 10 \end{cases}, \quad (2.31)$$

astfel încât distanța devine,

$$d(f, \hat{f}) = \sum_{i=1}^{10} [c_i w_i (f_i - \hat{f}_i)]^2, \quad (2.32)$$

constantele  $c_i$  fiind determinate de asemenea experimental.

Prin utilizarea erorii pătratice ponderate, se obține o cuantizare transparentă la 24 biți/vector, sau cu alte cuvinte, la aceeași rată de cuantizare, scade eroarea spectrală medie, precum și numărul cadrelor cu eroare spectrală mai mare decât 2 dB.

Utilizarea ponderii dată de relația (2.29) presupune o mare cantitate de calcul. Pentru a calcula  $S(f_i)$  cu relația (2.19), de exemplu, sunt necesare 11 înmulțiri între numere obținute după aplicarea funcției sinus. În plus mai există ridicarea la puterea  $r$  (0,15 ... 0,2) și înmulțirea cu  $c_i$ . Însă aceste ponderi se calculează o singură dată la cuantizarea unui vector, și așa cum se va vedea în continuare necesită un număr relativ mic de operații față de celelalte operații necesare pentru cuantizarea unui vector.

Considerând că termenii  $(c_i w_i)^2$ ,  $i=1, \dots, 10$  se calculează anterior procesului de calcul al distanțelor față de vectorii de reproducere, expresia complexității este

$$C = \sum_{i=1}^s 2n_i N_i, \quad (2.33)$$

unde  $s$  este numărul de subvectori în care se împarte un vector,  $n_1 + n_2 + \dots + n_s = 10$ , iar  $N_i$  este numărul de vectori de reproducere pentru fiecare subvector. Factorul 2 apare datorită modului în care se calculează termenii din expresia (2.32):  $(c_i w_i)^2 \cdot (f_i - \hat{f}_i) \cdot (f_i - \hat{f}_i)$ , care necesită 2 înmulțiri. De exemplu, pentru  $n_1=4$ ,  $n_2=6$ ,  $N_1=N_2=2^{12}=4096$  (rata este  $12+12=24$  biți/vector), complexitatea are valoarea

$$C = 2(4 \times 4096 + 6 \times 4096) = 81920 \text{ înmulțiri.}$$

În cazul în care s-ar fi făcut o căutare totală în cartea de cod de 24 biți, complexitatea ar fi avut valoarea

$$C' = 2 \times 10 \times 2^{24} = 3,355 \times 10^8 \text{ înmulțiri,}$$

deci se obține o reducere foarte mare a numărului de operații.

Memoria necesară memorării vectorilor de reproducere este

$$Mem = \sum_{i=1}^s 2n_i N_i, \quad (2.34)$$

unde factorul 2 semnifică faptul că fiecare componentă a vectorilor se memorează prin 2 octeți. Pentru cazul de mai sus, se obține

$$Mem = 2(4 \times 4096 + 6 \times 4096) = 81920 \text{ octeți.}$$

În cazul unei codări prin căutare totală, memoria necesară are valoarea

$$Mem' = 2 \times 10 \times 2^{24} = 3,355 \times 10^8 \text{ octeți,}$$

deci în cazul cuantizării prin despicare se obține și o reducere a memoriei.

În [15] se propune o nouă pondere, de forma

$$w_i = \frac{1}{f_i - f_{i-1}} + \frac{1}{f_{i+1} - f_i}, i = 1, \dots, 10, \quad (2.35)$$

unde  $f_0 = 0$  și  $f_{11} = 4000 \text{ Hz}$ , iar distanța între doi vectori se calculează prin

$$d(f, \hat{f}) = \sum_{i=1}^{10} w_i (f_i - \hat{f}_i)^2. \quad (2.36)$$


Expresia (2.35), fără a fi demonstrată, se justifică prin faptul că ponderea la frecvența  $f_i$  trebuie să fie proporțională cu spectrul la frecvența  $f_i$ , și așa cum s-a arătat în capitolul 2.1, spectrul la frecvența  $f_i$  este invers proporțional cu diferența între  $f_i$  și  $f_{i-1}$ , respectiv,  $f_{i+1}$  și  $f_i$ . Expresia lui  $w_i$  dată prin (2.35) este mai simplă decât cea dată prin (2.29), dar se pare că duce la rezultate ceva mai slabe (în literatură nu se compară performanțele obținute cu cele două ponderi, pentru aceeași bază de date).

O altă metodă de cuantizare vectorială a parametrilor LSF, de asemenea suboptimală și făcând parte din categoria metodelor de tip cod produs, este cuantizarea vectorială în mai multe stadii (multi stage VQ, MSVQ), [4], [5]. Conform acestei metode, în primul stadiu se face o cuantizare mai "brută" a vectorului de cuantizat (adică se folosește o carte de cod cu un număr relativ mic de vectori de reproducere). În fiecare din următoarele stadii se cuantizează vectorul eroare de cuantizare al stadiului precedent, considerat ca diferență între  $x$  și  $Q(x)$ . Versiunea cuantizată a

vectorului de intrare se obține însumând ieșirile cuantizoarelor din fiecare stadiu.

În figura 2.6 se prezintă structura unui cuantizor vectorial în 3 stadii.  $VQ_1$  reprezintă cuantizorul vectorial al primului stadiu.  $Q(x)=y_{1i}$  reprezintă ieșirea lui  $VQ_1$ ,  $y_{1i}$  fiind unul din cei  $N_1$  vectori de reproducere corespunzători stadiului 1. Vectorul de intrare în stadiul 2 este  $x-y_{1i}$ , iar  $Q(x-y_{1i})=y_{2j}$ . În fine, vectorul de intrare în stadiul 3 este  $x-y_{1i}-y_{2j}$  și  $Q(x-y_{1i}-y_{2j})=y_{3l}$ . Cărțile de cod pentru stadiile 2 și 3 au  $N_2$  și respectiv  $N_3$  vectori de reproducere. În acest caz, după cele 3 stadii, cuantizatul vectorului de intrare,  $\hat{x}$ , este dat prin

$$\hat{x} = y_{1i} + y_{2j} + y_{3l}. \quad (2.37)$$




**Figura 2.6:** *Cuantizor vectorial în 3 stadii.*

Bineînțeles că în practică numărul de stadii poate să fie mai mare decât 3. În faza de proiectare, pentru fiecare stadiu se proiectează separat câte o carte de cod, având ca secvență de antrenament secvența vectorilor eroare de cuantizare ai stadiului precedent. Acest procedeu este suboptimal pentru că nu ține cont de stadiile următoare. Și procedura de codare (căutare) numită secvențială, (adică codarea se face gășind vectorul de reproducere în primul stadiu, în al doilea ș.a.m.d.) este suboptimală, deoarece nu se face o comparație a vectorului de intrare cu toți cei  $N_1 \times N_2 \times \dots \times N_K$  vectori de reproducere posibili, unde  $K$  reprezintă numărul stadiilor.

Trebuie remarcat că numărul total de biți prin care se codează un vector,  $\log_2 N_1 + \log_2 N_2 + \dots + \log_2 N_K$ , are o valoare apropiată de numărul de biți care s-ar obține în cazul proiectării unei singure cărți de cod [4], [5], iar în toate stadiile vectorii utilizați au aceeași dimensiune ca și vectorii inițiali, adică  $k$ .



O modalitate de a optimiza procesul de căutare la MSVQ, folosește un algoritm de căutare mai vechi [1], numit algoritmul M, care se combină cu procesul de căutare secvențială specific MSVQ [5]. Acest algoritm numit și MSVQ-M decurge în modul următor: în urma calculării celor  $N_1$  distanțe între vectorul de cuantizat și vectorii de reproducere ai stadiului 1, se rețin  $M$  vectori de reproducere față de care se realizează cele mai mici distanțe; în stadiul 2 se calculează distanțele dintre cei  $M$  vectori eroare de cuantizare ai stadiului 1, calculați ca diferență între vectorul de intrare  $x$  și cei  $M$  vectori de reproducere care au produs cele mai mici distanțe, și fiecare din cei  $N_2$  vectori de reproducere ai stadiului 2; din cele  $MN_2$  distanțe, se rețin din nou cele mai mici  $M$ . În acest fel se crează  $M$  "căi" de parcurgere a cuantizorului, de la stadiul 1 spre stadiul 2. Procesul continuă în acest mod, în fiecare stadiu se rețin  $M$  vectori de reproducere care dau cele mai mici distanțe.



**Figura 2.7:** Explicativă pentru algoritmul MSVQ-M.

În figura 2.7 se arată un caz simplu de MSVQ-M, cu  $K=3$  stadii,  $M=2$  și  $N_1=N_2=N_3=4$ . În stadiul 1, vectorii de reproducere  $y_{11}$  și  $y_{14}$  dau cele mai mici 2 distanțe față de vectorul de cuantizat  $x$ . În stadiul 2, din cele 8 distanțe posibile, 4 între  $x-y_{11}$  și  $y_{21}, \dots, y_{24}$  și 4 între  $x-y_{14}$  și  $y_{21}, \dots, y_{24}$ , cele mai mici 2 distanțe se obțin între  $x-y_{11}$  și  $y_{22}$ , respectiv între  $x-y_{14}$  și  $y_{23}$ . În stadiul 3, dintre cele 8 distanțe posibile, 4 între  $x-y_{11}-y_{22}$  și  $y_{31}, \dots, y_{34}$  și 4 între  $x-y_{14}-y_{23}$  și  $y_{31}, \dots, y_{34}$ , cele mai mici 2 se obțin între  $x-y_{11}-y_{22}$  și  $y_{31}$ , respectiv între  $x-y_{14}-y_{23}$  și  $y_{34}$ . Astfel, în acest caz, cele 2 căi care străbat cuantizorul sunt (1,2,1) și (4,3,4), reprezentând indicii vectorilor de reproducere din cărțile de cod ale stadiilor 1, 2 și 3. În final, din cele  $M$  (2 în cazul de față) căi minime se alege calea în raport cu care vectorul de

cuantizat  $x$  produce eroarea minimă. Vectorul cuantizat  $\hat{x}$  se obține însumând vectorii de reproducere corespunzători căii minime.

Pe lângă algoritmul MSVQ-M care asigură o optimizare a procesului de căutare, tot în [5], se prezintă o metodă îmbunătățită de proiectare a cărților de cod pentru cele  $K$  stadii. Astfel, se proiectează iterativ, cartea de cod pentru fiecare stadiu, începând cu stadiul 1. Pentru a proiecta cartea de cod pentru un stadiu  $i$ ,  $i=1, \dots, K$ , se consideră ca secvență de antrenament diferența între vectorul  $x$  și vectorii de reproducere corespunzători tuturor stadiilor, inclusiv cele care urmează după stadiul  $i$ ; vectorii de reproducere ai stadiilor diferite de  $i$  se consideră stabiliți, iar vectorii de reproducere ai stadiului  $i$  se optimizează iterativ prin algoritmul Lloyd.

Cumulat, cele două îmbunătățiri aduse algoritmului MSVQ, adică utilizarea algoritmului M în procesul de căutare și proiectarea îmbunătățită a cărților de cod pentru cele  $K$  stadii, conduc la scăderea erorii spectrale medii,  $SD$ . În tabelul 2.3 se prezintă (din [5]), comparativ, valorile erorii spectrale pentru diferite valori ale parametrului  $M$ , ale numărului de stadii  $K$ , și ale numărului de vectori de reproducere pentru fiecare stadiu  $N_1, N_2, \dots, N_K$ . În aceste cazuri,  $N_1=N_2= \dots =N_K=N$ .

**Tabelul 2.3:** *Erori spectrale pentru MSVQ-M.*

$M$	$K$	$N$	$SD$ [dB]
1	4	64	1,2
2	4	64	1,08
4	4	64	1,02
1	3	256	1,11
2	3	256	1,01
4	3	256	0,98

Se observă că eroarea spectrală scade odată cu creșterea parametrului  $M$  și, de asemenea scade odată cu scăderea numărului de stadii, respectiv cu creșterea numărului de vectori de reproducere pe stadiu. În ambele variante, cu 4, respectiv cu 3 stadii, numărul total de biți este 24 (4 stadii x 6

biți/stadiu; 3 stadii x 8 biți/stadiu). Cazul  $M=1$  este echivalent cu situația algoritmului MSVQ necombinat cu algoritmul  $M$ .

În continuare se face evaluarea complexității și a memoriei pentru algoritmul MSVQ-M.

Astfel, complexitatea se calculează prin relația

$$C = 2k N_1 + 2k M \sum_{i=2}^K N_i, \quad (2.38)$$

considerând doar înmulțirile și eroarea pătratică ponderată ca distanță între vectori. În plus, algoritmul MSVQ-M necesită mai multe operații de comparare.

Memoria folosită se calculează prin

$$Mem = \sum_{i=1}^K 2k N_i \quad (2.39)$$

**Tabelul 2.4:** Caracteristici pentru cuantizorul vectorial prin despicare.

$s$	$n_i$	$N_i$	$C$ [înmulțiri]	$Mem$ [octeți]	$SD$ [dB]
3	3;3;4	256;256;256	5120	5120	1,17
2	5;5	4096;4096	81920	81920	1,03

**Tabelul 2.5:** Caracteristici pentru MSVQ-M.

$K$	$N$	parametrul $M$	$C$ [înmulțiri]	$Mem$ [octeți]	$SD$ [dB]
4	64	1	5120	5120	1,21
		2	8960		1,09
		4	16640		1,04
3	256	1	15360	15360	1,10
		2	25600		1,02
		4	46080		0,95
2	4096	1	163840	163840	0,92
		2	245760		0,90
		4	409600		0,88

În tabelele 2.4 și 2.5 se prezintă comparativ pentru diferite variante de cuantizoare vectoriale prin desplicare și, respectiv, MSVQ-M, complexitatea, memoria și eroarea spectrală (valorile erorii spectrale au fost luate din [4] și [5], iar complexitatea și memoria au fost calculate de autor conform relațiilor prezentate). De notat că în toate cazurile rata cuantizoarelor este 24 biți/vector.

Pentru a compara cele două metode trebuie analizate complexitatea, memoria și eroarea spectrală, având în vedere că rata este aceeași. Deși cele două metode nu au fost implementate pe aceeași bază de date, ceea ce implică doar o comparare orientativă a erorilor spectrale în cele două cazuri, se poate spune că metoda MSVQ-M este superioară pe ansamblu metodei de cuantizare vectorială prin desplicare. Această superioritate se datorează în special metodei de proiectare îmbunătățită a cărții de cod, deoarece în [4] metoda de cuantizare vectorială prin desplicare se compară cu o metodă MSVQ clasică ( $M=1$  și proiectare a cărților de cod separat pentru fiecare stadiu), rezultând că această din urmă metodă este inferioară.

În încheierea analizei comparative a metodelor de cuantizare vectorială prin desplicare și MSVQ-M trebuie remarcat următorul fapt legat de complexitate: dacă s-ar considera și operațiile de comparare, valorile din tabelele 2.4 și 2.5 ar crește cu cantități mai mari pentru MSVQ-M, deoarece această metodă necesită mai multe comparații pentru determinarea celor mai mici  $M$  distanțe, pe când la cuantizarea vectorială prin desplicare se determină numai cea mai mică distanță.

Pe aceste două metode, cuantizarea vectorială prin desplicare și MSVQ-M (sau MSVQ), se bazează majoritatea celorlalte metode de cuantizare a parametrilor LSF prezente în literatură, metode care încearcă îmbunătățirea performanțelor: reducerea erorii spectrale, reducerea complexității și a memoriei folosite, protecția împotriva erorilor care apar la propagarea pe canalul de transmisiune.

În continuare se enumeră pe scurt câteva din ideile desprinse din lucrările din literatură care tratează aspectele prezentate mai sus.

În [16] se prezintă o metodă de adaptare a cărților de cod pentru un cuantizor vectorial prin desplicare, posibilă datorită proprietății de ordonare a componentelor vectorilor LSF. Cuantizarea primului subvector ( $n_1=3$ ) al

vectorului de intrare prin  $(\hat{f}_1, \hat{f}_2, \hat{f}_3)$ , impune condiția ca toate elementele cărții de cod pentru subvectorul 2 să verifice condiția  $\hat{f}_{4i} > \hat{f}_3, i = 1, \dots, N_2$ , care în mod normal nu poate fi îndeplinită în totalitate. Prin procedura de adaptare descrisă, toți subvectorii din cartea de cod cu  $N_2$  elemente se modifică, astfel încât se restrânge spațiul ocupat de această carte de cod. Se obține o micșorare a regiunilor Voronoi rezultând posibilitatea reducerii erorii de cuantizare. Aceeași adaptare se face și pentru cartea de cod pentru subvectorul 3. În urma experimentărilor rezultă o reducere a numărului de cadre care au erori spectrale între 2 și 4 dB, dar crește complexitatea, datorită adaptării celor două cărți de cod.

O altă metodă adaptivă, aplicată la un MSVQ este prezentată în [17]. Cartea de cod a primului stadiu se adaptează în felul următor: vectorul de reproducere care a fost utilizat cel mai puțin în ultimul timp se elimină din cartea de cod și se înlocuiește cu cuantizatul vectorului curent (suma ieșirilor cuantizoarelor celor două stadii); apoi se trece la cuantizarea vectorului următor. În acest fel se obține o cuantizare transparentă pentru 22 biți/cadru. Complexitatea înregistrează însă o creștere datorită faptului că după fiecare cuantizare, trebuie determinat vectorul de reproducere care a fost folosit mai puțin în ultimul timp.

În [8] se prezintă un cuantizor vectorial de tip latice. O latice reprezintă o mulțime de puncte uniform distribuite într-un spațiu restrâns din  $\mathcal{R}^n$ . Un cuantizor vectorial de tip latice are o carte de cod ai cărei vectori de reproducere constituie o latice. În procesul de cuantizare al unui vector, se cuantizează la început prin căutare totală subvectorul format din frecvențele  $f_3$  și  $f_7$  numite puncte "ancoră", deoarece determină intervalele în care se află ceilalți parametri LSF:  $f_1$  și  $f_2$  în intervalele  $(0, \hat{f}_3)$ ,  $f_4, f_5, f_6$  în intervalul  $(\hat{f}_3, \hat{f}_7)$ , iar  $f_8, f_9$  și  $f_{10}$  în intervalul  $(\hat{f}_7, 4000)$ . Apoi, se definesc în felul următor 3 subvectori, având dimensiunile 2, 3, și, respectiv, 3.

$$\mathbf{x}_1 = (x_{11}, x_{12}), \begin{cases} x_{11} = \frac{f_1}{\hat{f}_3} \\ x_{12} = \frac{\hat{f}_3 - f_2}{\hat{f}_3} \end{cases} \quad (2.40a)$$

$$\mathbf{x}_2 = (x_{21}, x_{22}, x_{23}), \begin{cases} x_{21} = \frac{f_4 - \hat{f}_3}{\hat{f}_7 - \hat{f}_3} \\ x_{22} = \frac{f_5 - \hat{f}_4}{\hat{f}_7 - \hat{f}_3} \\ x_{23} = \frac{\hat{f}_7 - f_6}{\hat{f}_7 - \hat{f}_3} \end{cases} \quad (2.40b)$$

$$\mathbf{x}_3 = (x_{31}, x_{32}, x_{33}), \begin{cases} x_{31} = \frac{f_8 - \hat{f}_7}{4000 - \hat{f}_7} \\ x_{32} = \frac{f_9 - \hat{f}_8}{4000 - \hat{f}_7} \\ x_{33} = \frac{4000 - f_{10}}{4000 - \hat{f}_7} \end{cases} \quad (2.40c)$$

Se demonstrează că distribuțiile acestor subvectori sunt de forma unui triunghi dreptunghic isoscel, pentru  $\mathbf{x}_1$ , respectiv sub formă de piramidă regulată pentru  $\mathbf{x}_2$  și  $\mathbf{x}_3$ . Cărțile de cod pentru cei 3 subvectori conțin numere întregi uniform distribuite (latice), astfel încât să acopere zonele ocupate de distribuțiile subvectorilor. Suma acestor numere întregi (2 numere pentru  $\mathbf{x}_1$ , respectiv câte 3 pentru  $\mathbf{x}_2$  și  $\mathbf{x}_3$ ) este sau pară, sau impară, fiind mai mică sau egală cu un număr fixat inițial. De exemplu, pentru vectorul  $\mathbf{x}_1$ , se arată în tabelul 2.6 vectorii de reproducere pentru cazul când suma componentelor este pară, mai mică sau egală cu 6. În total, sunt 16 vectori, care acoperă în plan un triunghi dreptunghic isoscel.

Înainte de cuantizare, subvectorii  $\mathbf{x}_1$ ,  $\mathbf{x}_2$  și  $\mathbf{x}_3$  se înmulțesc cu constante alese convenabil pe baza secvenței de antrenament, astfel încât să se încadreze în zonele acoperite de cartea de cod. Evident că acești subvectori vor avea după înmulțire componente neîntregi. Găsirea vectorului de reproducere se face în acest caz foarte simplu, necesitând doar două înmulțiri cu matrici și rotunjirea la valorile întregi cele mai apropiate (procedeu descris pe larg în [8]).

**Tabelul 2.6:** Vectorii de reproducere  $(x_{11}, x_{12})$  pentru un cuantizor vectorial de tip latice.

0,6	0,4	0,2	0,0
1,5	1,3	1,1	
2,4	2,2	2,0	
3,3	3,1		
4,2	4,0		
5,1			
6,0			

Această metodă are o complexitate foarte mică, nu necesită practic memorie decât doar pentru cartea de cod a subvectorului  $(f_3, f_7)$ , dar cuantizarea transparentă se obține pentru o rată mai mare, de 28 biți/vector.

În [9] se prezintă un concept nou de abordare a cuantizării vectoriale. Ideea de bază este reprezentată de existența unei relații între codul unui vector de reproducere (reprezentarea binară care se transmite la decodor) și valoarea sa (cele  $k$  componente),

$$y_j = T b_j, \quad (2.41)$$

unde  $y_j, j=0, \dots, N-1$  reprezintă vectorii de reproducere,  $b_j$  reprezintă codurile corespunzătoare, iar  $T$  este o matrice. Codul  $b_j$  are forma, numită cod bloc

$$b_j = (+1, i_j(1), i_j(2), \dots, i_j(k), c_j(1), \dots, c_j(r))^T, \quad (2.42)$$

preluată din domeniul teoriei codării. Biții  $i_j(l), l=1, \dots, k$  sunt biții de informație care corespund reprezentării binare a lui  $j$ , în care simbolul 0 se înlocuiește cu 1, iar 1 cu -1, iar  $c_j(l), l=1, \dots, r$  sunt biții de paritate care se obțin prin produse între biții de informație. Deoarece lungimea codului  $b_j$  este  $k+r+1$ , matricea  $T$  are dimensiunea  $(k+r+1) \times k$ . Pentru un cuantizor care folosește o relație de forma (2.41), în procesul de proiectare trebuie determinată matricea  $T$  și de asemenea trebuie specificat modul cum se obțin biții de paritate.

Avantajul esențial al acestei metode este, așa cum se demonstrează pe larg în [9], robustețea față de erorile care apar la propagarea pe canal.

Memoria folosită este cu atât mai mică cu cât numărul  $r$  de biți de paritate este mai mic, deoarece trebuie memorată matricea  $T$ , pe baza căreia se calculează vectorii de reproducere. Calcularea vectorilor de reproducere, pe de altă parte produce creșterea complexității, însă având în vedere că în codul  $b_j$  sunt numai 1 și -1, înmulțirea dată de (2.41) se transformă în adunări și scăderi.

Pe baza celor prezentate despre codul bloc, atât proiectarea cât și căutarea celui mai apropiat vector de reproducere se fac având la bază metodele de cuantizare vectorială prin desplicare și MSVQ. Ca element de noutate, la cuantizarea vectorială prin desplicare ( $n_1=5$ ,  $n_2=5$ ) se rețin  $L$  subvectori de reproducere care produc cele mai mici erori  $L$  din cele 2 cărți de cod, alegându-se vectorul care produce cea mai mică eroare în raport cu vectorul de cuantizat, din cele  $L^2$  posibilități.

Având în vedere succinta trecere în revistă a metodelor de cuantizare vectorială a parametrilor LSF, autorul se va orienta înspre găsirea unei metode de cuantizare vectorială rapidă (de complexitate redusă) care însă să nu sacrifice performanțele, adică să nu producă creșterea erorii spectrale.

În capitolul 2, s-a prezentat reprezentarea unui semnal vocal prin parametri LSF, arătându-se unele contribuții ale autorului în acest sens. De asemenea sunt prezentate și principalele metode de cuantizare vectorială ale acestor parametrii.



### 3. PROIECTAREA CĂRȚII DE COD A UNUI CUANTIZOR VECTORIAL

#### 3.1 Generalități

Proiectarea cărții de cod a unui cuantizor vectorial, adică determinarea vectorilor de reproducere, se face anterior procesului de cuantizare propriuzisă (codare și decodare), pe baza unei secvențe de antrenament, care cuprinde un mare număr de vectori. Vectorii de reproducere trebuie să fie reprezentativi pentru informația conținută în secvența de antrenament. Apoi, cuantizarea se aplică pentru alți vectori, diferiți de cei de antrenament. Cu cât secvența de antrenament conține un număr mai mare de vectori, cu caracteristici mai diferite, cu atât vectorii de cuantizat vor fi "aproximați" mai exact cu ajutorul vectorilor de reproducere din cartea de cod.

În cele mai multe cazuri, deci și pentru cuantizarea vectorială a parametrilor LSF, cartea de cod se proiectează cu ajutorul algoritmului generalizat al lui Lloyd, prezentat în capitolul 1. O problemă importantă o reprezintă alegerea cărții de cod inițiale, care urmează să fie îmbunătățită. O posibilitate ar fi folosirea ca și carte de cod inițială a unei cărți aleatoare care să conțină  $N$  vectori de antrenament, aleși la întâmplare. Altă posibilitate ar fi alegerea a  $N$  vectori egal depărtați unul de altul în secvența de antrenament, adică  $\mathbf{x}_1, \mathbf{x}_{r+1}, \mathbf{x}_{2r+1}, \dots, \mathbf{x}_{(N-1)r+1}$ , unde  $r = n/N$ ,  $n$  fiind lungimea secvenței de antrenament. În [4] și [11] se folosește o metodă care aplică algoritmul Lloyd succesiv pentru cărți de cod având 2,4,8,..., $N$  vectori de reproducere. Astfel, mai întâi se determină centroidul întregii secvențe de antrenament, care apoi se "despică" în doi vectori (unul dintre acești vectori se obține prin modificarea cu o cantitate mică a fiecărei componente a centroidului, iar celălalt poate fi chiar centroidul). În continuare, de fiecare dată, dublarea numărului de vectori de reproducere se face prin astfel de despicări, apoi se optimizează cartea de cod cu acel număr de vectori de reproducere, până la obținerea numărului dorit de vectori de reproducere,  $N$ .

(A nu se confunda această metodă de proiectare a cărții de cod în care se fac "despicări", adică dublări ale numărului de vectori, cu metoda de codare prin despicare, în care un vector se împarte în subvectori de dimensiune mai mică în vederea reducerii complexității și memoriei în procesul de codare).

În [14], Equitz prezintă o metodă de proiectare a unei cărți de cod, în care vectorii de antrenament se grupează în *mănunchiuri*, fiecare mănunchi conținând vectori cât mai apropiați din spațiul  $k$ -dimensional, centrozii acestor mănunchiuri reprezentând în final vectorii de reproducere. În principiu acest algoritm se desfășoară în felul următor: la început, fiecare vector de antrenament reprezintă un mănunchi, deci există  $n$  mănunchiuri; apoi se unesc împreună cei mai apropiați doi vectori de antrenament, într-un singur mănunchi, astfel numărul de mănunchiuri devenind  $n-1$ . Procesul continuă în acest mod, de fiecare dată se unesc cele mai apropiate două mănunchiuri, până când numărul de mănunchiuri devine egal cu  $N$ , mărimea dorită a cărții de cod. Acest procedeu numit PNN (pairwise nearest neighbor - împerecherea inteligentă a celor mai apropiați vectori), a fost aplicat în [14] pentru cuantizarea vectorială a imaginilor, și are avantajul unui timp de realizare mult mai scurt decât algoritmul Lloyd, fără a crește eroarea de cuantizare.

**Autorul aplică algoritmul PNN pentru proiectarea cărții de cod pentru vectori cu parametri LSF, adaptându-l în funcție de particularitățile acestui tip de vectori.**

### **3.2 Utilizarea algoritmului PNN pentru cuantizarea vectorială a parametrilor LSF**

Varianta principială a algoritmului prezentată anterior necesită un volum mare de calcul, deoarece secvența de antrenament conține foarte mulți vectori. În [14] Equitz propune o metodă rapidă de efectuare a acestui algoritm, bazată pe următoarea idee: căutarea în vederea găsirii celor mai apropiate două mănunchiuri să nu se facă în întreaga secvență de antrenament, ci în zone mai mici care cuprind vectori apropiați; pentru

aceasta, mai întâi se împarte întreaga secvență de antrenament în zone care conțin cel mult un număr prestabilit de vectori,  $b$ , apropiați în spațiu, aceste zone numindu-se *buchete*; apoi, în fiecare buchet se găsesc cele mai apropiate două mănunchiuri (la început fiecare mănunchi conține un vector); în final, doar într-o fracțiune, de obicei jumătate, din aceste buchete perechea de mănunchiuri mai apropiate se unește într-un singur mănunchi; buchetele în care se fac uniri sunt acelea în care distanțele între cele două mănunchiuri mai apropiate sunt cele mai mici; apoi, din nou se inspectează buchetele în vederea găsirii celor mai apropiate două mănunchiuri, urmată de unirea mănunchiurilor, până când numărul de mănunchiuri devine egal cu  $N$ .

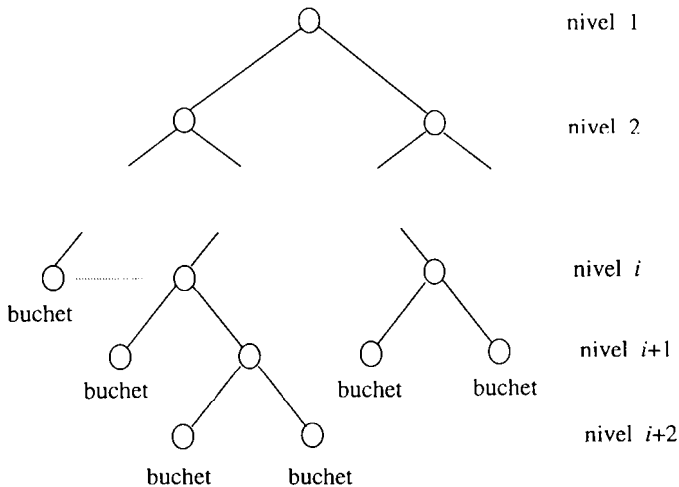
### 3.2.1 Împărțirea secvenței de antrenament în buchete

Pentru proiectarea cărții de cod autorul a folosit o secvență de antrenament conținând  $n=2790$  vectori cu parametri LSF, având dimensiunea  $k=10$ , proveniți de la un singur vorbitor. După captarea cu ajutorul unui microfon, semnalul vocal a fost amplificat prin intermediul unui amplificator de tip MT 60, având amplificarea de 60 dB. Apoi s-a făcut achiziția semnalului prin intermediul plăcii de tip DS 1101 conținând un procesor de semnal TMS 320 E14. Achiziția s-a făcut cu frecvența de eșantionare  $f_e=8$  kHz, fiind urmată de o filtrare numerică de tip trece jos, la 4 kHz și o analiză prin predicție liniară de ordinul 10, efectuată prin metoda autocorelației. Durata unui cadru de semnal pentru care s-a făcut predicția liniară a fost de 25 ms, conținând 200 de eșantioane. Programul pentru dialogul între calculatorul gazdă și sistemul DS 1101 în vederea achiziției, ca și cel pentru predicția liniară au fost scrise în limbajul C. Pe baza vectorilor cu coeficienți de predicție, s-au obținut vectorii cu parametri LSF, pe baza unui program în MATLAB.

Proiectarea cărții de cod s-a făcut în vederea realizării unui cuantizor vectorial de tipul prin despicare. Vectorii au fost despicați în 3 subvectori, având dimensiunile 3, 3 și, respectiv, 4. Astfel, pentru fiecare din cei 3 subvectori s-a proiectat câte o carte de cod, conținând câte 256 vectori de reproducere, adică rata cuantizorului a fost de  $8 \times 3 = 24$  biți/vector. În continuare se descrie proiectarea completă a cărții de cod pentru un singur

subvector, prezentându-se la sfârșit rezultatele obținute pentru toți cei 3 subvectori.

Așa cum s-a amintit în descrierea făcută în introducerea acestui paragraf, mai întâi s-a făcut o împărțire a secvenței de antrenament în buchete. Împărțirea s-a făcut separat pentru cele 3 secvențe de antrenament rezultate prin considerarea componentelor de la 1 la 3, de la 4 la 6, și respectiv de la 7 la 10, ale secvenței inițiale cu dimensiunea 10. Împărțirea în buchete s-a făcut conform arborilor  $k$ -dimensionali [14]. Un astfel de arbore conține mai multe niveluri (figura 3.1). Primul nivel conține un singur nod, numit rădăcină, în care vectorii corespunzători secvenței de antrenament se împart conform unui anumit criteriu în 2 subsecvențe distincte. Aceste 2 subsecvențe devin secvențele asociate celor 2 noduri de pe nivelul 2, unde la rândul lor, cele două secvențe se împart, rezultând 4 subsecvențe. Procesul continuă în acest mod. Subsecvențele care au un număr de vectori mai mic sau egal cu un număr prestabilit, notat  $b$ , devin buchete, sau noduri terminale, împărțirea continuând pentru celelalte subsecvențe, până când toate se vor transforma în buchete.



**Figura 3.1:** Structura unui arbore pentru împărțirea în buchete.

Conform celor expuse este evident că odată cu apariția buchetelor, numărul de noduri de pe un nivel nu se va mai dubla față de nivelul

precedent, astfel încât arborele va avea o structură neregulată, cu ramuri inegale.

Foarte important este criteriul după care se face împărțirea secvențelor în subsecvențe în fiecare din noduri. Criteriul ales de autor, același ca în [14], cuprinde următoarele etape:

- mai întâi, pentru fiecare componentă a vectorilor asociați unui nod se calculează dispersia conform relației

$$\sigma_i^2 = \frac{\sum_{j=1}^{n'} (x_{ij} - m_i)^2}{n'}, i = 1, \dots, k, \quad (3.1)$$

unde  $k$  reprezintă dimensiunea subvectorilor (3, 3 sau 4),  $x_{ij}$  reprezintă componenta  $i$  a vectorului  $j$ ,  $m_i$  este valoarea medie a componentei  $i$ ,

$$m_i = \frac{\sum_{j=1}^{n'} x_{ij}}{n'}, i = 1, \dots, k, \quad (3.2)$$

iar  $n'$  reprezintă numărul de vectori de antrenament asociați nodului respectiv.

- în continuare se determină care din cele  $k$  componente are cea mai mare dispersie; fie  $c$  această componentă,  $c \in \{1, \dots, k\}$ , valoarea medie  $m_c$  a componentei respective reprezintă valoarea de prag asociată nodului respectiv.

-în vederea împărțirii secvenței asociate unui nod în două subsecvențe distincte, vectorii a căror componentă  $x_{cj}$  este mai mică decât  $m_c$  se asociază primei subsecvențe iar cei cu componenta  $x_{cj}$  mai mare sau egală cu  $m_c$  se asociază celei de-a doua subsecvențe ( $j = 1, \dots, n'$ ). (Se notează cu  $n_{s1}$  și  $n_{s2}$  numărul de vectori din cele 2 subsecvențe,  $n_{s1} + n_{s2} = n'$ ). De remarcat că valorile de prag  $m_c$  și componentele  $c$  asociate nodurilor, pot să difere de la nod la nod, chiar dacă nodurile sunt pe același nivel.

În acest caz autorul a ales numărul maxim de vectori conținuți de un buchet,  $b=10$ . Programul care face împărțirea secvenței de antrenament în buchete a fost scris în limbajul C. În figura 3.2 se prezintă organigrama acestui program, care este valabilă evident pentru toți cei 3 subvectori în care s-a împărțit vectorul cu dimensiunea  $k=10$ .

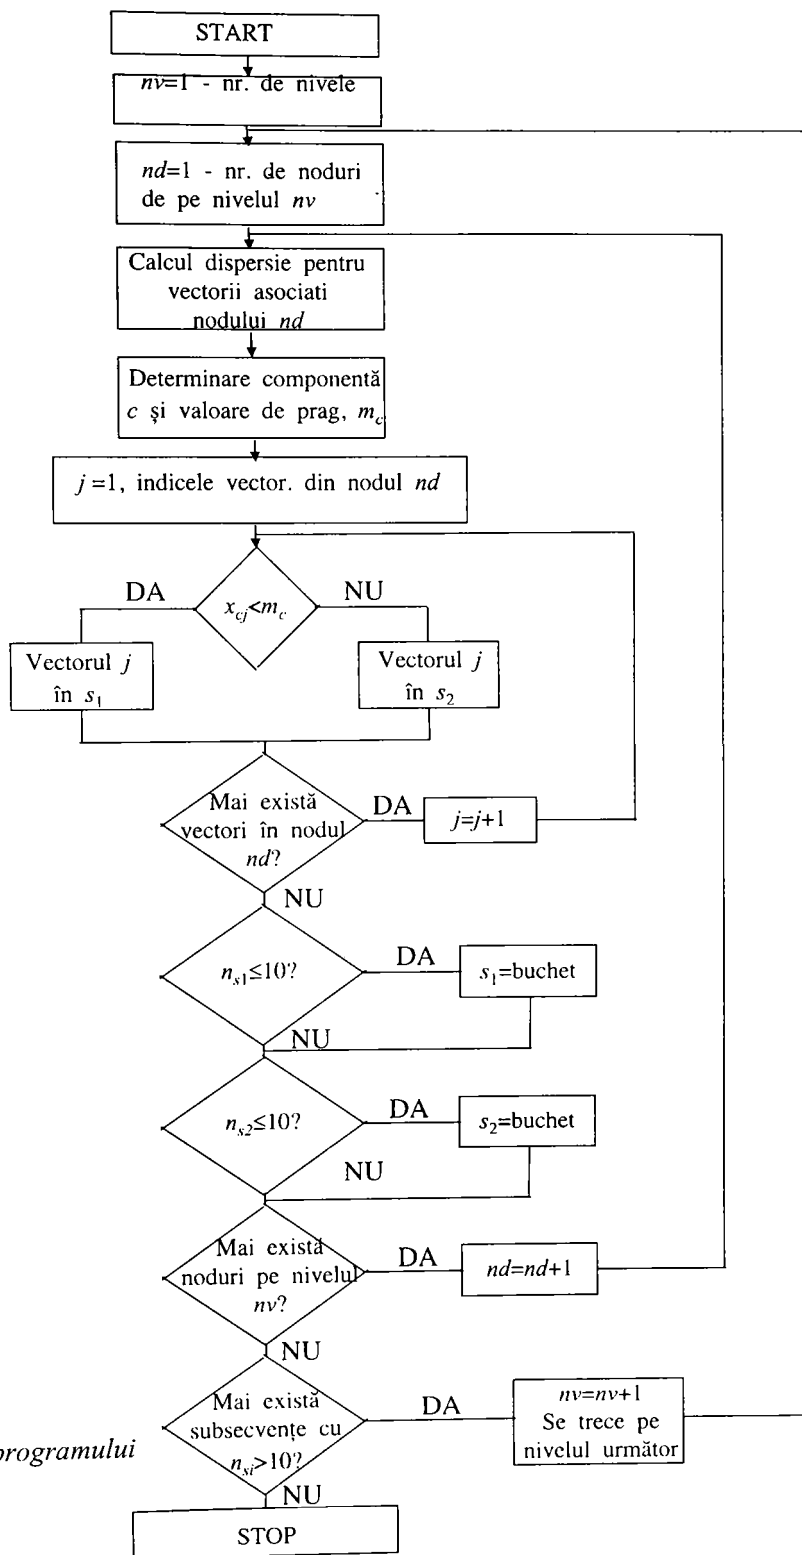


Figura 3.2: Organigrama programului de împărțire a secvenței de antrenament în buchete.

Referitor la programul a cărui organigramă s-a prezentat anterior, se impun următoarele observații:

- vectorii de antrenament asociați nodului rădăcină (întreaga secvență de antrenament) se depun într-o memorie,  $M_1$ .

- pentru fiecare nod al arborelui, vectorii asociați se împart în două subsecvențe, notate  $s_1$  și  $s_2$ , conform criteriului prezentat; dacă o subsecvență are 10 vectori sau mai puțini, ea devine buchet, și vectorii corespunzători se depun într-o memorie, notată  $M_2$ , iar dacă are mai mult de 10 vectori va constitui o secvență asociată cu un nod de pe nivelul următor; în acest caz vectorii corespunzători se depun în altă memorie notată  $M_3$ .

- după parcurgerea tuturor nodurilor de pe un nivel, vectorii corespunzători subsecvențelor care nu au devenit buchete, vor constitui vectorii secvențelor asociate nodurilor de pe următorul nivel, și se vor transfera din memoria  $M_3$  în memoria  $M_1$ , peste vectorii care au constituit secvențele asociate nodurilor de pe nivelul curent, care nu mai sunt necesari; în memoria  $M_2$ , după fiecare nivel se vor acumula vectorii componenți ai buchetelor.

**În acest fel autorul a asigurat o bună organizare a datelor în memorie, în scopul folosirii unei memorii cât mai mici.** Astfel, fără efectuarea acestei alocări dinamice a memoriei, zona de memorie ocupată de  $M_1$  și  $M_3$ , ar fi necesară pentru fiecare nivel în parte. Pentru un nivel sunt necesari  $2 \times 2790 \times 4 \times 2 \cong 45000$  octeți. (S-a considerat cazul cel mai defavorabil, pentru dimensiunea  $k=4$  a vectorilor, fiecare componentă fiind memorată prin 2 octeți). Deoarece arborele a avut 8...10 niveluri, rezultă că ar fi fost necesară o memorie de circa 400 kocteți.

În tabelul 3.1 se prezintă, separat, pentru subvectorii care conțin parametrii LSF de la 1 la 3, de la 4 la 6, respectiv de la 7 la 10, numărul de subsecvențe și numărul de buchete rezultate pentru fiecare nivel, precum și numărul total de buchete obținute,  $N_B$ .

Numărul de vectori pe buchete obținut a fost cuprins între 4 și 10, rezultând o medie de aproximativ 7 vectori pe buchet, așa cum rezultă din tabelul 3.1.

Privind blocurile din organigrama programului de împărțire a secvenței de antrenament în buchete, se constată că se fac înmulțiri doar la

determinarea dispersiei. În rest se fac doar comparații sau transferuri de date între diferite zone de memorie. O expresie analitică a complexității nu se poate obține, deoarece de la un anumit nivel încep să apară buchetele, ceea ce reduce numărul de vectori din secvențele asociate nodurilor, neputându-se estima pe fiecare nivel câte buchete apar. Din tabelul 3.1, rezultă că

**Tabelul 3.1:** Rezultatele algoritmului de împărțire a secvenței de antrenament în buchete.

Subvectorul 1, 2, 3,			Subvectorul 4, 5, 6,		Subvectorul 7, 8, 9,10	
Nivelul	Subsecvențe	Buchete	Subsecvențe	Buchete	Subsecvențe	Buchete
1	2	0	2	0	2	0
2	4	0	4	0	4	0
3	8	0	8	0	8	0
4	16	0	16	0	16	0
5	32	0	32	0	32	0
6	63	1	64	0	64	0
7	119	7	123	5	121	7
8	140	98	139	107	119	123
9	7	273	17	261	38	200
10	0	14	0	34	4	72
11	-	-	-	-	0	8
$N_B$		393		407		410

începând cu nivelurile 6 sau 7 apar primele buchete, pe nivelul 8 încă se mai împarte un număr considerabil de secvențe, în timp ce pe ultimele niveluri numărul buchetelor crește brusc, astfel scăzând numărul de secvențe care se împart. Pentru a determina o limită superioară a complexității se consideră acoperitor că pe primele 8 niveluri nu se obțin buchete (adică subsecvențele au mai mult de 10 vectori), ceea ce înseamnă că pe fiecare din aceste niveluri se calculează dispersia pentru 2790 vectori de antrenament (pentru 3 componente). În acest fel complexitatea este

$$C=2790 \times 3 \times 8= 66960 \text{ înmulțiri}$$



Desigur că această complexitate crește odată cu lungimea secvenței de antrenament, când în plus va crește și numărul de niveluri.

Pentru simplitate, complexitatea s-a calculat doar pentru subvectorii cu componentele 1, 2 și 3. În mod similar complexitatea se poate calcula și pentru subvectorii cu componentele 4, 5 și 6, și respectiv pentru cei cu componentele 7, 8, 9, 10, fiind proporțională cu dimensiunea  $k$ .

### 3.2.2 Algoritmul PNN rapid. Obținerea vectorilor de reproducere

Împărțirea secvenței de antrenament în regiuni mici de vectori sau buchete, permite o căutare mai rapidă în vederea grupării vectorilor în mănunchiuri. Două mănunchiuri se unesc într-unul singur, dacă după unire introduc cea mai mică eroare de cuantizare, dintre toate perechile de mănunchiuri posibile. Situația este mai simplă la început, când fiecare mănunchi conține un singur vector. Odată cu prima unire de mănunchiuri, există un mănunchi cu 2 vectori, iar în continuare după alte uniri, numărul de vectori pe mănunchi crește. În [14] se deduce expresia erorii de cuantizare a vectorilor din două mănunchiuri  $C_i$  și  $C_j$  care se unesc, dacă acești vectori sunt cuantizați prin centroidul mănunchiului rezultat după unire, notat  $C_{ij}$  astfel

$$E_{ij} = \sum_{x \in C_{ij}} |x - \bar{x}_{ij}|^2 = E_i + E_j + \frac{n_i n_j}{n_i + n_j} |\bar{x}_i - \bar{x}_j|^2, \quad (3.3)$$

unde operatorul  $||^2$  reprezintă norma euclidiană a vectorului,  $n_i$  și  $n_j$  reprezintă numărul vectorilor din cele două mănunchiuri  $C_i$  și  $C_j$ ,  $\bar{x}_i$  și  $\bar{x}_j$  reprezintă centroizii (media) vectorilor din mănunchiurile  $C_i$  și  $C_j$ ,  $\bar{x}_{ij}$  reprezintă centroidul vectorilor din mănunchiul  $C_{ij}$ ,

$$\bar{x}_{ij} = \frac{n_i \bar{x}_i + n_j \bar{x}_j}{n_i + n_j}, \quad (3.4)$$

iar  $E_i$  și  $E_j$  erorile corespunzătoare mănunchiurilor  $C_i$  și  $C_j$ ,

$$E_i = \sum_{x \in C_i} |x - \bar{x}_i|^2. \quad (3.5)$$

Din relația (3.3) se observă că pentru a calcula eroarea  $E_{ij}$  nu este necesară cunoașterea explicită a vectorilor care compun mănunchiurile care se unesc, ci numai a numărului lor, a centrozilor lor, precum și a erorilor de cuantizare care se fac la cuantizarea vectorilor componenți prin centroidul fiecărui mănunchi.

Pentru o mai clară înțelegere a modului în care se alege perechea de mănunchiuri care se va uni, se consideră un caz simplu. Se presupune că există 3 mănunchiuri, cu  $n_1, n_2, n_3$  vectori fiecare, iar erorile de cuantizare ale vectorilor din fiecare mănunchi prin centroidul mănunchiului sunt  $E_1, E_2, E_3$ . Aplicând relația (3.3), erorile totale de cuantizare ale vectorilor din cele 3 mănunchiuri, în urma celor 3 uniri posibile sunt:

- când se unesc mănunchiurile 1 și 2,

$$E = E_{12} + E_3 = E_1 + E_2 + \frac{n_1 n_2}{n_1 + n_2} |\bar{x}_1 - \bar{x}_2|^2 + E_3, \quad (3.6)$$

- când se unesc mănunchiurile 1 și 3,

$$E = E_{13} + E_2 = E_1 + E_3 + \frac{n_1 n_3}{n_1 + n_3} |\bar{x}_1 - \bar{x}_3|^2 + E_2, \quad (3.7)$$

- când se unesc mănunchiurile 2 și 3,

$$E = E_1 + E_{23} = E_1 + E_2 + E_3 + \frac{n_2 n_3}{n_2 + n_3} |\bar{x}_2 - \bar{x}_3|^2. \quad (3.8)$$

Privind relațiile de mai sus, se constată că termenul  $E_1 + E_2 + E_3$  apare în toate cele 3 cazuri, ceea ce înseamnă că se vor uni mănunchiurile pentru care termenul  $\frac{n_i n_j}{n_i + n_j} |\bar{x}_i - \bar{x}_j|^2$  este minim.

În acest fel, la începutul algoritmului PNN rapid, în fiecare buchet se găsește perechea de mănunchiuri care produce eroarea minimă prin unire, numită "candidata" buchetului respectiv. Apoi într-o fracțiune din buchete (de exemplu în 50%) se fac efectiv unirile, și anume, în acele buchete în care creșterile erorii prin unire, (adică  $\frac{n_i n_j}{n_i + n_j} |\bar{x}_i - \bar{x}_j|^2$ ) sunt cele mai mici.

Motivul pentru care nu se fac uniri în toate buchetele este următorul: există buchete care conțin mănunchiuri îndepărtate, prin a căror unire eroarea totală ar crește mult; de aceea, deoarece în buchetele în care se fac uniri se

modifică parametrii  $n_i$  și  $\bar{x}_i$ , se reia procesul de căutare a candidatelor în fiecare buchet, și astfel se pot face uniri și în buchete în care anterior s-au mai făcut, dar care produc creșteri mai mici ale erorii totale. Algoritmul PNN rapid continuă în acest fel, reluându-se procesul de căutare a candidatelor și efectuându-se uniri. Astfel, numărul total de mănunchiuri existente în toți bucheții, notat  $N_{TM}$ , va scădea, algoritmul încheindu-se când numărul  $N_{TM}$  va fi egal cu mărimea dorită a cărții de cod,  $N$ . Vectorii de reproducere vor fi centroizii mănunchiurilor obținute.

O problemă deosebit de importantă, nediscutată în [14] este dată de raportul între mărimea dorită a cărții de cod  $N$ , care uzual poate avea valorile 256, 512, 1024, 2048 sau 4096 și valoarea numărului de buchete  $N_B$  obținut. În cazul de față s-a văzut că  $N_B$  are valori în jurul lui 400, pentru cei 3 subvectori. Deoarece  $N=256$  (valoare identică pentru toate cele 3 cărți de cod, la cuantizorul prin despicare), se observă că  $N < N_B$ , ceea ce ar însemna că, dacă s-ar face uniri până când fiecare buchet va rămâne cu un mănunchi, numărul de vectori de reproducere posibili ar fi egal cu  $N_B$  și nu s-ar mai putea reduce. În plus, pentru a se ajunge în această situație s-ar încălca principiul de a se face uniri doar în buchetele în care unirile provoacă creșteri mai mici ale erorii de cuantizare. O primă soluție ar fi scăderea numărului de buchete, impunând ca  $b$ , numărul maxim de vectori pentru un buchet să aibe valori mai mari. Aceasta ar duce însă la creșterea volumului de calcul necesar pentru găsirea candidatei în fiecare buchet (care este proporțional cu  $C_b^2$ ). **Autorul propune în acest caz o variantă modificată a algoritmului PNN rapid:** se fac uniri de fiecare dată doar în jumătate dintre buchete; după un număr de astfel de iterații, în unele buchete, care conțin vectori mai apropiați, se fac mai multe uniri între mănunchiuri decât în altele, numărul de mănunchiuri în aceste buchete scăzând; fiecare astfel de buchet, în situația când ajunge să conțină 2 mănunchiuri, se unește cu cel mai apropiat buchet, determinat pe baza distanței dintre centroizii generali ai buchetelor (media vectorilor din buchetul respectiv); astfel, numărul de buchete scade, crescând numărul de mănunchiuri în buchetele care se unesc; procesul continuă până când numărul total de mănunchiuri din toate buchetele,  $N_{TM}$ , devine egal cu  $N$ .

În figura 3.3 se prezintă organigrama programului care implementează algoritmul PNN rapid modificat, scris în limbajul C.

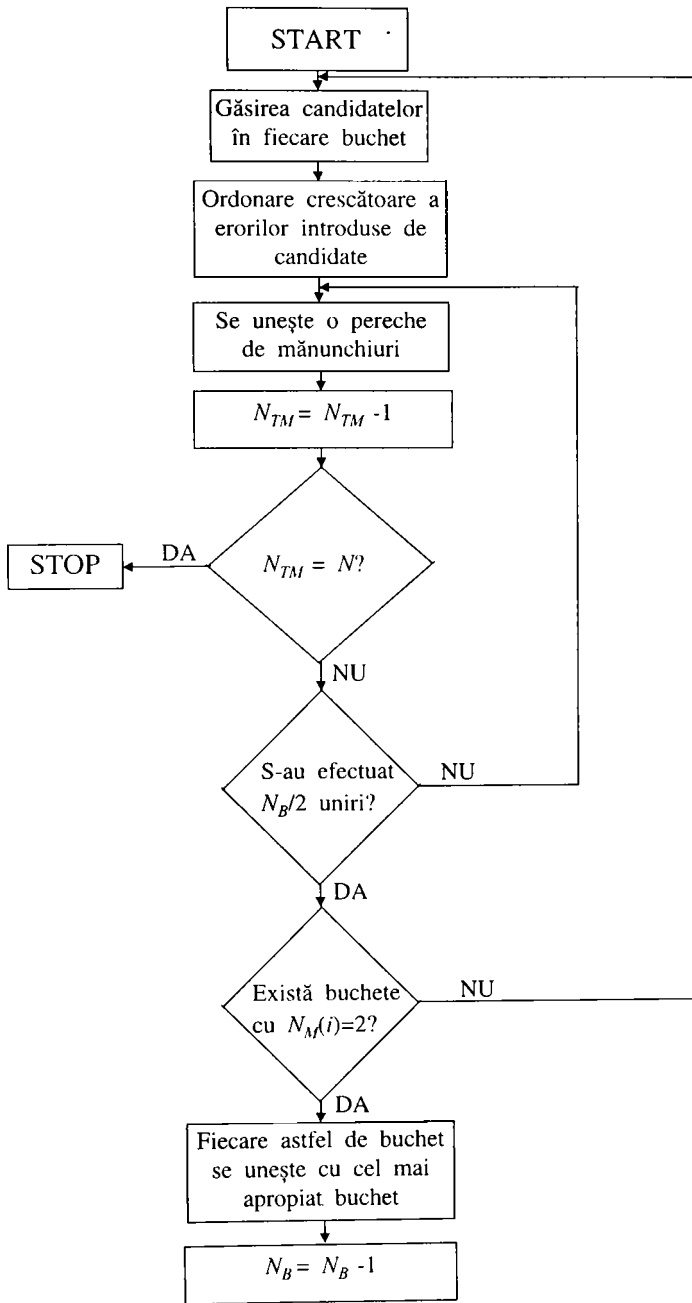


Figura 3.3: Organigrama programului pentru algoritmul PNN.

În legătură cu algoritmul PNN rapid descris prin organigrama din figura 3.3 (programul complet este prezentat în Anexa 2), se impun următoarele observații:

- la început, fiecare din cei  $n$  vectori de antrenament constituie câte un mănunchi, deci numărul total de mănunchiuri este  $N_{M}=n$ .

- gășirea perechii de mănunchiuri candidată pentru fiecare buchet, presupune calculul ultimului termen al relației (3.3) pentru fiecare pereche de mănunchiuri.

- pentru a se face uniri între mănunchiuri doar în jumătate din numărul de buchete, se face o ordonare crescătoare a erorilor introduse de fiecare dintre perechile candidate, făcându-se uniri în primele  $N_B/2$  buchete din tabelul obținut în urma ordonării.

- pentru un buchet  $i$ , care are numărul de mănunchiuri  $N_M(i)=2$ , se calculează distanța de la centroidul său la centroizii tuturor celorlalte buchete, în scopul gășirii celui mai apropiat buchet.

- unind două buchete, scade numărul de buchete,  $N_B$ , ceea ce înseamnă că scade numărul de uniri între mănunchiuri ( $N_B/2$ ) care se vor face la următoarea parcurgere a buchetelor; iar tot prin unirea a două buchete crește numărul de mănunchiuri  $N_M(i)$  al buchetului rezultat.

În urma rulării programului, separat pentru cele 3 structuri de buchete obținute pentru fiecare din cei 3 subvectori s-au obținut următoarele rezultate:

- în toate cele 3 cazuri, bucla mai mare a programului, cea în care se face determinarea candidatelor, urmată de uniri între mănunchiuri și eventual între buchete, se parcurge de 20 de ori.

- de asemenea, după 4 astfel de bucle, apar primele buchete cu  $N_M(i)=2$ , deci se fac uniri între buchete.

- în final, rămân 65, 62, și, respectiv 68 de buchete, pentru cele 3 tipuri de subvectori; fiecare din cele 3 grupe de buchete conțin în total 256 de mănunchiuri, ale căror centroizi reprezintă vectorii de reproducere.

Pe baza rezultatelor obținute la rularea programului se face o evaluare a complexității, considerând operațiile de înmulțire. Referitor la organigrama din figura 3.3 se identifică blocurile în care se fac înmulțiri. Aceste blocuri sunt:

- a) blocul pentru găsirea candidatelor în fiecare buchet, unde ultimul termen al relației 3.3 se calculează pentru fiecare pereche de două mănunchiuri a buchetului cercetat.

- b) blocul în care se face unirea a 2 mănunchiuri, unde se aplică relația 3.4 pentru determinarea centroidului mănunchiului rezultat.

- c) blocul în care fiecare buchet cu numărul de mănunchiuri  $N_{M(i)}=2$  se unește cu cel mai apropiat buchet, în care în primul rând se calculează distanțele de la buchetul respectiv la toate buchetele existente, și în al doilea rând, trebuie determinat centroidul general al buchetului rezultat prin unire, pe baza relației (3.4).

Evaluarea complexității în cazul determinării candidatelor în buchete, este ceva mai dificilă deoarece numărul de mănunchiuri este în continuă scădere și de aceea se va face o evaluare aproximativă. Astfel, la primele 3 parcurgeri ale buclei mari, numărul de buchete este 393, iar numărul de mănunchiuri este succesiv 2790, 2590, 2390, ceea ce înseamnă că fiecare buchet are în medie aproximativ 7, apoi 6,5, iar la a 3-a parcurgere a buclei, 6 mănunchiuri. Aceasta înseamnă că ultimul termen din relația 3.3 se calculează de aproximativ  $393(C_7^2 + C_7^2 + C_6^2) = 22400$  ori. În următoarele 17 parcurgeri ale buclei, numărul de buchete scade de la 393 la 65, iar numărul de mănunchiuri de la 2190 la 256. Se poate considera cu aproximație că fiecare buchet are în medie 5 mănunchiuri. Știind că s-au făcut în acest timp  $2190 - 256 = 1934$  uniri, înseamnă că s-au cercetat un număr dublu de buchete, adică 3868. Rezultă că ultimul termen al relației (3.3) s-a calculat de  $3868 \times C_5^2 = 38680$  ori. Rezultă că în total, în cele 20 de parcurgeri ale buclei, acest termen s-a calculat de aproximativ 61000 ori, iar deoarece necesită 6 înmulțiri, determinarea candidatelor din buchete necesită  $36,6 \times 10^4$  înmulțiri.

Deoarece inițial există  $N_{TM}=2790$  mănunchiuri, iar în final rămân  $N_{TM}=N=256$  mănunchiuri, înseamnă că se fac  $2790-256=2534$  uniri între mănunchiuri. Pentru  $k=3$ , relația 3.4 implică 6 înmulțiri și o împărțire, adică, în total unirile între mănunchiuri necesită  $2534 \times 7=17738$  înmulțiri.

Referitor la determinarea celui mai apropiat buchet față de un buchet cu 2 mănunchiuri, din rezultatele obținute în urma rulării programului rezultă că s-au făcut aproximativ 20 de uniri între buchete, în medie, la fiecare din

cele 17 parcurgeri ale buclei. Știind că în total, în această perioadă s-au cercetat 3868 buchete înseamnă că distanța între centroizii generali a 2 buchete s-a calculat în total de  $20 \times 3868 = 77360$  ori. Știind că o astfel de distanță necesită 3 înmulțiri (pentru  $k=3$ ) rezultă un total de aproximativ  $23 \times 10^4$  înmulțiri.

Deoarece, la început sunt  $N_b=393$  buchete și în final rămân 65, pentru  $k=3$ , rezultă că s-au făcut  $393-65=328$  uniri între buchete, adică  $328 \times 7=2296$  înmulțiri, pentru calcularea centroidului general.

Considerând în final, toate înmulțirile din cele 3 blocuri rezultă un număr total de aproximativ  $60 \times 10^4$  înmulțiri. Bineînțeles că aceste înmulțiri reprezintă operațiile necesare numai în cazul subvectorilor cu componentele 1, 2 și 3. Pentru subvectorii cu componentele 4, 5, 6 numărul de înmulțiri este cam de același ordin, iar pentru subvectorii cu componentele 7, 8, 9 și 10 este ceva mai mare datorită dimensiunii  $k=4$  a vectorilor.

Dacă se adaugă și înmulțirile din cadrul algoritmului de împărțire în buchete, se obține un număr total de aproximativ  $67 \times 10^4$  înmulțiri.

Așa cum s-a arătat anterior, o metodă alternativă pentru situația când  $N_b > N$  ar fi mărirea numărului maxim de vectori pe buchet. De exemplu, pentru un număr maxim de 40 de vectori pe buchet, ar putea rezulta 100 de bucheți cu 28 de vectori fiecare, în medie. În acest caz s-ar face câte 50 de uniri între mănunchiurile candidate, necesitând aproximativ 50 de parcurgeri ale buclei mari (fără să se facă uniri între buchete). Pentru determinarea candidatelor ar trebui să se calculeze aproximativ  $50 \times$

$(C_{28}^2 + C_{28}^2 + C_{27}^2 + C_{27}^2 + \dots + C_3^2 + C_3^2) = 73 \times 10^4$  de distanțe între mănunchiuri (numărul mediu de mănunchiuri pe buchet scade cu un pas de 0,5 de la 28 până la aproximativ 2,5). Fără a mai considera numărul de înmulțiri necesar pentru calculul unei distanțe, este evident că în acest caz complexitatea este mult mai mare. Chiar dacă complexitatea nu este un factor foarte important având în vedere că acești algoritmi se desfășoară o singură dată, înaintea codării, valoarea mai mică obținută constituie un argument pentru ideea propusă.

Pentru o primă apreciere a calității cărții de cod proiectate prin algoritmul PNN rapid, în tabelul 3.2 se arată eroarea medie, sub formă de eroare pătratică, în  $\text{Hz}^2$ , obținută prin cuantizarea, prin căutare totală a celor

2790 vectori de antrenament cu cei 256 de vectori de reproducere, precum și aceeași eroare pentru cuantizarea a 310 vectori de test, diferiți de cei de antrenament, dar roștiți de același vorbitor (separat pentru cele trei tipuri de subvectori). Programele care implementează cuantizarea au fost scrise în limbajul C.

**Tabelul 3.2:** Eroarea obținută la un cuantizor vectorial folosind cartea de cod PNN.

Subvectori		$f_1 \dots f_3$	$f_4 \dots f_6$	$f_7 \dots f_{10}$
Eroarea medie	Vectori de antrenament	523	1641	2171
în Hz <sup>2</sup> pentru:	Vectori de test	705	2211	2823

Se observă că pentru vectorii de test eroarea este ceva mai mare, lucru normal, deoarece ei nu au fost cuprinși în procesul de proiectare. De exemplu, pentru subvectorul cu componentele  $f_4$ ,  $f_5$ ,  $f_6$ , o eroare medie pătratică de 2211 Hz<sup>2</sup> reprezintă o diferență de aproximativ 27 Hz, în medie, între componentele cuantizate și cele originale (în general aceste componente au valori cuprinse între 1000 și 2500 Hz).

Autorul a proiectat, de asemenea, o carte de cod în care, prin despicări succesive și aplicări ale algoritmului generalizat al lui Lloyd se obțin cărțile de cod cu dimensiunile 2, 4, 8, ..., 256, la fel cum s-a procedat în [4] (algoritm descris pe scurt și în paragraful 3.1). În tabelul 3.3 se prezintă rezultatele obținute în acest caz.

**Tabelul 3.3:** Eroarea obținută la un cuantizor vectorial folosind cartea de cod Lloyd, prin despicări succesive.

Subvectori		$f_1 \dots f_3$	$f_4 \dots f_6$	$f_7 \dots f_{10}$
Eroarea medie	Vectori de antrenament	573	1600	2390
în Hz <sup>2</sup> pentru:	Vectori de test	769	2240	3178

Se observă că rezultatele obținute în acest caz sunt ceva mai slabe decât cele obținute pentru o carte de cod proiectată cu algoritmul PNN rapid. În plus, complexitatea algoritmului de proiectare este mult mai mare.



Au fost necesare în medie câte 12 iterații Lloyd pentru fiecare dimensiune a cărții de cod. De exemplu, pentru fiecare din cele 3 cărți de cod s-au calculat  $2790 \times 12 \times (2+4+8+\dots+256) = 17 \times 10^6$  distanțe  $k$ -dimensionale (adică  $51 \times 10^6$  înmulțiri pentru  $k=3$ ).

În final, s-a aplicat algoritmul generalizat al lui Lloyd considerând ca și carte inițială, pentru îmbunătățit, cartea de cod obținută prin algoritmul PNN rapid. Convergența a fost mult mai rapidă fiind necesare 6-7 iterații. Astfel, pe lângă cele  $67 \times 10^4$  înmulțiri necesare pentru obținerea cărții inițiale, s-au mai efectuat  $2790 \times 6 \times 256 \times 3 \cong 12.8 \cdot 10^6$  înmulțiri, adică un total de  $13,4 \times 10^6$  înmulțiri, ceea ce reprezintă aproximativ 25% din înmulțirile necesare proiectării cărții de cod folosind despicări succesive și algoritmul generalizat al lui Lloyd. În tabelul 3.4 se prezintă erorile obținute în acest caz.

**Tabelul 3.4:** Eroarea obținută la un cuantizor vectorial folosind cartea de cod PNN îmbunătățită prin algoritmul Lloyd.

Subvectori		$f_1, \dots, f_3$	$f_4, \dots, f_6$	$f_7, \dots, f_{10}$
Eroarea medie	Vectori de antrenament	476	1471	1939
în Hz <sup>2</sup> pentru:	Vectori de test	723	2133	2866

În comparație cu rezultatele din tabelul 3.2 se observă o îmbunătățire a performanțelor, pentru secvența de antrenament, ceea ce era obligatoriu, în timp ce pentru secvența de test eroarea scade doar pentru subvectorii  $f_4, \dots, f_6$ , crescând puțin pentru subvectorii  $f_1, \dots, f_3$  și  $f_7, \dots, f_{10}$ . Acest rezultat este explicabil, deoarece cartea de cod a fost îmbunătățită pentru secvența de antrenament, secvența de test diferind de aceasta.

În concluzie, aceste rezultate confirmă cele obținute în [14] și anume că proiectarea unei cărți de cod prin algoritmul PNN rapid are o complexitate mult mai mică decât algoritmul clasic al lui Lloyd, având în plus și o eroare mai mică. Meritul autorului este că a introdus o variantă modificată a algoritmului PNN rapid, pe care a aplicat-o pentru vectori de tip LSF, adaptând-o în funcție de caracteristicile acestui tip de vectori.

### 3.3 Analiza calității unui cuantizor vectorial în funcție de diferitele forme ale erorii pătratice ponderate

Așa cum s-a arătat în paragraful 2.2, calitatea unui cuantizor vectorial pentru parametri LSF se apreciază prin eroarea spectrală medie  $SD$ . Eroarea spectrală care se face la cuantizarea unui vector  $i$ , căruia îi corespunde o densitate spectrală de putere  $S_i(f)$ , prin alt vector căruia îi corespunde densitatea spectrală de putere  $\hat{S}_i(f)$  este

$$SD_i^2 = \frac{2}{f_e} \int_0^{f_e/2} [10 \log_{10}(S_i(f)) - 10 \log_{10}(\hat{S}_i(f))]^2 df \quad (3.9)$$

Pentru calculul lui  $SD_i^2$ , s-a descompus aria reprezentată de această integrală în porțiuni foarte mici, cu lățimea de 1 Hz, s-au calculat ariile acestor porțiuni, însumându-se apoi în final aceste arii. Programul prin care se calculează această mărime a fost scris de autor în limbajul C.

Eroarea spectrală medie pentru cazul când cuantizarea s-a făcut folosind eroarea pătratică s-a obținut la valoarea  $SD=0,933$  dB, 5 cadre din cele 310 având erori spectrale mai mari decât 2 dB, întrunind cerințele necesare pentru o cuantizare transparentă (vezi paragraful 2.2).

În scopul reducerii erorii spectrale medii și a numărului de cadre cu eroare mai mare decât 2 dB s-a folosit apoi eroarea pătratică ponderată,

$$d(f, \hat{f}) = \sum_{i=1}^{10} [w_i (f_i - \hat{f}_i)]^2, \quad (3.10)$$

unde ponderea  $w_i$  s-a calculat cu relația

$$w_i = [S(f_i)]^r, r = 1/6, \quad (3.11)$$

iar  $S(f_i)$  s-a calculat cu relația exactă (2.19).

Folosirea erorii pătratice ponderate are ca efect cuantizarea mai precisă a componentelor  $f_i$  la care densitatea spectrală de putere are valori mai mari, în scopul reconstituirii mai precise a porțiunilor din spectru cu amplitudine mai mare.

Pentru verificarea experimentală a acestei ipoteze autorul a considerat un vector cu parametri LSF (din secvența de antrenament), pentru care a calculat ponderile  $w_i$  aferente, tabelul 3.5. Apoi s-au făcut diverse modificări unora dintre acești parametri, calculându-se în fiecare caz eroarea spectrală între vectorul inițial și cel cu parametrii modificați, ca în tabelul 3.6.

**Tabelul 3.5:** Componentele LSF și ponderile aferente.

$f_i$	201	423	800	923	1477	1658	2156	2528	2996	3512
$W_i$	2,73	1,78	2,20	1,73	1,28	1,25	0,80	0,78	0,58	0,58

**Tabelul 3.6:** Erorile spectrale în funcție de modificările parametrilor LSF.

Modificarea făcută	SD
$f_i \leftarrow f_i + 20$ Hz $i=1,2,3$	0,62 dB
$f_i \leftarrow f_i + 20$ Hz $i=8,9,10$	0,36 dB
$f_1 \leftarrow f_1 + 20$ Hz	0,42 dB
$f_2 \leftarrow f_2 + 20$ Hz	0,27 dB
$f_3 \leftarrow f_3 + 20$ Hz	0,52 dB
$f_4 \leftarrow f_4 + 20$ Hz	0,25 dB
$f_5 \leftarrow f_5 + 20$ Hz	0,25 dB
$f_6 \leftarrow f_6 + 20$ Hz	0,29 dB

Rezultatele din tabelul 3.6 confirmă în linii mari aceste ipoteze, deoarece se observă că eroarea spectrală este cu atât mai mare cu cât ponderile parametrilor modificați sunt mai mari.

**În scopul evidențierii efectului global al erorii pătratică ponderate asupra întregii secvențe de test, autorul a realizat experimentul descris în continuare.** S-a considerat mai întâi, pentru subvectorul  $(f_1, f_2, f_3)$ , cartea de cod obținută prin algoritmul PNN rapid. Cei 310 vectori de test s-au cuantizat folosind atât eroarea pătratică ponderată (prescurtat e.p.p.), cât și cea pătratică (e.p.), prin intermediul cărții de cod amintite. O mare parte din vectori (circa 80%) și-au găsit același vector de reproducere prin ambele

tipuri de distanțe, ceilalți 20% găsiindu-și vectori de reproducere diferiți. În tabelul 3.7 se arată, pentru 2 vectori de cuantizat din aceasta ultimă categorie, vectorii de reproducere găsiți în cele 2 cazuri, precum și ponderile  $w_i$  (s-au considerat numai subvectorii cu componentele  $f_1, f_2, f_3$ ).

**Tabelul 3.7:** Rezultatele cuantizării folosind e.p. și e.p.p.

$f_i$	212	340	558	208	297	665
$w_i$	3,09	2,80	1,97	3,16	2,51	1,40
e.p.	198	323	554	233	296	673
e.p.p.	205	355	574	197	298	698

După cum se vede din datele prezentate pentru cei 2 vectori, componentele 1, în primul rând, și 2, care au ponderi mari, sunt cuantizate mai precis când se folosește eroarea pătratică ponderată. În schimb, componenta 3, este cuantizată mai puțin precis în cazul acesta. Chiar dacă în cazul erorii pătratice ponderate, eroarea de cuantizare sub formă pătratică este mai mare, eroarea spectrală scade, de exemplu, pentru primul vector, de la 0,396 dB la 0,354 dB, iar pentru al doilea, de la 0,817 dB la 0,595 dB. În ambele cazuri s-au considerat componentele  $f_4, \dots, f_{10}$  de la vectorul cuantizat, identice cu cele ale vectorului de cuantizat.

Referitor la modul de exprimare a erorii pătratice ponderate, autorul a observat că, indiferent dacă ponderea  $w_i$  este la puterea a 2-a, ca în relația (3.10) sau la puterea întâi, eroarea  $SD$  are valori foarte apropiate, astfel încât, pentru simplitatea calculului s-a folosit  $w$  la puterea întâi.

În continuare s-a efectuat cuantizarea întregii secvențe de test folosind eroarea pătratică ponderată, pentru fiecare din cei 3 subvectori folosindu-se cartea de cod obținută prin algoritmul PNN rapid. Eroarea spectrală medie obținută în acest caz a fost de 0,903 dB, obținându-se o scădere de 0,03 dB față de cea obținută când s-a folosit eroarea pătratică, cu aceleași 3 cărți de cod. Numărul de vectori cu eroare spectrală mai mare ca 2 dB a fost de 3.

În scopul îmbunătățirii și mai mult a performanțelor, cele 3 cărți de cod s-au proiectat pentru eroarea pătratică ponderată. Astfel, plecând de la

cele 3 cărți de cod obținute prin algoritmul PNN rapid, s-a aplicat algoritmul generalizat Lloyd, folosind însă eroarea pătratică ponderată pentru cuantizarea secvențelor de antrenament.

Cu ajutorul celor 3 cărți de cod obținute în acest fel s-a făcut din nou cuantizarea secvenței de test, obținându-se o reducere suplimentară a erorii spectrale cu 0,01 dB, un singur vector mai având eroarea spectrală peste 2 dB.

**În continuare, pe baza relațiilor obținute pentru densitatea spectrală de putere, în paragraful 2.1, autorul a introdus 2 noi ponderi.** Având în vedere forma expresiilor (2.24) și (2.27) pentru  $S(f_i)$ , constanta  $r$  din expresia (3.11) a lui  $w_i$ , care în literatură se spune că poate lua valori în intervalul 0,1 ... 0,2, s-a ales valoarea  $1/6=0,1666$  (cum dealtfel s-a și utilizat deja în acest paragraf). Astfel, pentru  $w_i$  rezultă relațiile

$$w_i = \frac{K'}{(f_{i+1} - f_i)(f_i - f_{i-1})}, \quad i = 1, \dots, 10, \quad (3.12)$$

unde  $f_0 = 0$  și  $f_{11} = \frac{f_e}{2} = 4000\text{Hz}$ , și

$$w_i = \frac{K'_1}{(f_{i+3} + 3f_{i+1} - 4f_i)(4f_i - 3f_{i-1} - f_{i-3})}, \quad i = 1, \dots, 10. \quad (3.13)$$

Pentru relația (3.13) valorile  $f_i$  au fost definite în tabelul 2.1, iar constantele  $K'$  și  $K'_1$  sunt rădăcinile de ordinul 6 din constantele  $K$  și  $K_1$  prezentate în paragraful 2.1, adică  $K'=1,32 \times 10^5$  și  $K'_1=4,76 \times 10^6$ .

Cu aceste două ponderi s-au făcut aceleași etape de prelucrare ca și cu ponderea în care  $S(f_i)$  s-a calculat cu relația exactă (2.19). De asemenea s-a utilizat și ponderea

$$w_i = \frac{1}{f_{i+1} - f_i} + \frac{1}{f_i - f_{i-1}}, \quad (3.14)$$

dată empiric în [13] de Laroia și colectivul, prezentată și în paragraful 2.2.

În tabelul 3.8 se prezintă rezultatele obținute (eroarea spectrală medie  $SD$  și numărul de cadre cu eroarea spectrală mai mare decât 2 dB,  $n_m$ ), pentru diferite ponderi utilizate, specificându-se dacă s-a utilizat cartea de cod proiectată pentru eroarea pătratică ponderată (e.p.p.) sau doar cea pentru eroarea pătratică (e.p.).

**Tabelul 3.8:** Rezultatele obținute prin cuantizarea vectorială cu eroarea pătratică ponderată.

Pondere	Cartea de cod	$SD$ [dB]	$n_m$
(3.11)	e.p.	0,903	3
	e.p.p.	0,893	1
(3.12)	e.p.	0,898	4
	e.p.p.	0,888	2
(3.13)	e.p.	0,903	3
	e.p.p.	0,894	2
(3.14)	e.p.p.	0,899	2
Fără pondere	e.p.	0,933	5

Din tabelul 3.8 se pot trage mai multe concluzii.

- în primul rând se observă că reducerea mai puternică a erorii spectrale medii se obține prin utilizarea erorii pătratice ponderate, chiar dacă cartea de cod nu este proiectată pentru această eroare, iar proiectarea cărții de cod pentru eroarea pătratică ponderată produce o scădere mai mică a erorii spectrale medii.

- cu cele două ponderi propuse de autor se obțin rezultate apropiate față de cele obținute cu relațiile propuse în literatură (prin relațiile (3.11) și (3.14)).

- ponderea propusă de autor prin relația (3.12) dă rezultate ceva mai bune pentru  $SD$  decât ponderea calculată pe baza relației exacte a densității spectrale de putere  $S(f_i)$ , adică cea dată de relația (3.11); acest lucru pare neașteptat ținând cont că în paragraful 2.1, tabelul 2.2, valorile obținute pentru  $S(f)$  difereau de cele calculate cu formula exactă.

- o explicație a concluziei anterioare poate fi dată prin faptul că  $S(f)$  corespunzător ponderii (3.12) are variații mari în raport cu valorile obținute prin relația exactă, ceea ce înseamnă că se cuantizează și mai precis componentele  $f_i$  cărora le corespund vârfuri în spectre.

- pe de altă parte, tot cu ponderea dată prin (3.12) se obțin rezultate mai slabe în ce privește vectorii cu eroare spectrală mai mare decât 2 dB

În final se poate spune că ponderile propuse de autor dau rezultate similare cu ponderile propuse în literatură, pentru o comparare mai exactă fiind necesară poate o bază de date mai mare, atât ca vectori de antrenament cât și ca vectori de test. Principalul avantaj al acestor ponderi este însă simplitatea relațiilor, ele necesitând practic o înmulțire și o împărțire, în timp ce, pentru ponderea dată de relația (3.11), este necesară calcularea exactă a  $S(f_i)$ , urmată de ridicarea la puterea  $r$ . De exemplu, prin relația (2.19) sunt necesare pentru calculul lui  $S(f_i)$  11 înmulțiri între numere obținute prin aplicarea funcției *sinus*. În ce privește ponderea dată prin relația (3.14), chiar dacă este simplă, ea nu este demonstrată, ci dată empiric [15].

În capitolul 3 s-a realizat proiectarea printr-o metodă nouă a cărții de cod pentru realizarea unui cuantizor vectorial prin despicare și testarea cărții de cod obținute pentru diferite forme ale erorii pătratice ponderate, unele propuse de autor.

#### 4. CUANTIZAREA VECTORIALA A PARAMETRILOR LSF PRIN METODA COMBINATĂ ARBORE-CAUTARE TOTALĂ

Așa cum s-a arătat la sfârșitul capitolului 2, autorul s-a orientat înspre obținerea unei metode de cuantizare vectorială a parametrilor LSF de complexitate redusă (metodă rapidă).

Cea mai rapidă metodă de cuantizare vectorială (așa cum s-a spus, procesul de codare este cel care determină "rapiditatea", decodarea fiind totdeauna la fel de simplă) cunoscută în literatură este metoda de tip arbore, (TSVQ - tree structured VQ) [1], [2], care, în principiu necesită  $k$  operații (teste) pentru determinarea celor  $k$  biți din codul vectorului. Așa cum se va arăta, această metodă conduce însă la creșterea erorii de cuantizare, față de situația când codarea s-ar fi făcut prin căutare totală. În [2] se prezintă o altă metodă rapidă, tot de tip arbore, care se bazează pe o structurare a cărții de cod, având ca efect o creștere a complexității față de TSVQ, fără a produce însă creșterea erorii de cuantizare față de căutarea totală. Ambele metode se folosesc în literatură, însă doar pentru vectorii formați din eșantioane de semnal vocal. **Autorul preia principiul celei de-a doua metode și îl adaptează astfel încât să fie folosit la cuantizarea parametrilor LSF, rezultând cea mai rapidă metodă de cuantizare vectorială a parametrilor LSF, fără a produce creșterea erorii de cuantizare.**


##### 4.1 Cuantizarea vectorială de tip arbore

În acest paragraf autorul demonstrează de ce un cuantizor vectorial de tip arbore (TSVQ) este suboptimal față de un cuantizor vectorial de tip Voronoi (în care codarea se face prin căutare totală).

Structura generală a unui TSVQ (partea de codare) este prezentată în figura 4.1. Arborele conține  $d$  niveluri,  $2^d - 1$  noduri interne și  $2^d$  noduri terminale. Fiecărui nod terminal îi corespunde un cod sau un vector de



reproducere. Evident că numărul de noduri terminale,  $2^d$  este egal cu  $N$ , mărimea cărții de cod, de unde  $d = \log_2 N$ .



**Figura 4.1:** Codorul unui cuantizor de tip arbore.


În procesul de codare, vectorul de cuantizat parcurge o “cale” prin arbore, de la nodul rădăcină, situat pe primul nivel, până la un nod terminal, în funcție de teste binare făcute în nodurile interne. Prin testul făcut pe fiecare nivel se determină câte un bit al codului.

Pentru a proiecta un astfel de cuantizor vectorial trebuie specificat modul cum se fac testele în nodurile interne, precum și vectorii de reproducere corespunzători nodurilor terminale.

În figura 4.2 se arată un exemplu de TSVQ, pentru  $d=2$ , în spațiul bidimensional ( $k=2$ ), arătându-se arborele, figura 4.2a) și regiunile de cuantizare, figura 4.2 b). Distanța folosită în procesul de codare este distanța euclidiană.

Pe nivelul 1, întreg spațiul  $\mathfrak{R}^2$  este împărțit în 2 regiuni de cuantizare distincte. Testul care se face în singurul nod de pe nivelul 1 determină de care parte a frontierei reprezentată prin dreapta  $A$  este situat vectorul de cuantizat,  $x$ , sau, echivalent, de care din cei doi vectori de reproducere notați  $y_1$  și  $y_2$  este mai apropiat. Cei doi vectori de reproducere sunt egal depărtați de dreapta  $A$ . Pe nivelul 2, cele două regiuni de cuantizare corespunzătoare nivelului 1, se împart fiecare, separat, în câte două regiuni de cuantizare distincte, delimitate de dreptele  $B$  și  $C$ . Vectorii de reproducere  $y_{11}$  și  $y_{12}$  sunt egal depărtați de dreapta  $B$ , iar  $y_{21}$  și  $y_{22}$  sunt

egal depărtați de dreapta  $C$ . Deoarece proiectarea cuantizorului (obținerea vectorilor de reproducere) se face separat în cele două regiuni corespunzătoare nivelului 1, vectorii  $y_{11}$  și  $y_{21}$ , respectiv  $y_{12}$  și  $y_{22}$  nu mai




**Figura 4.2:** Structura arborelui și a regiunilor de cuantizare pentru un TSVQ cu  $N=4$  și  $k=2$ .

sunt egal depărtați de fețele comune ale regiunilor respective ca la un cuantizor vectorial de tip Voronoi. Astfel, în procesul de cuantizare, vectorul  $x$ , după ce pe nivelul 1 a fost atribuit regiunii corespunzătoare lui  $y_2$ , în urma testului de pe nivelul 2 se atribuie regiunii corespunzătoare lui  $y_{22}$ , deși se vede că este mai apropiat de  $y_{12}$ . În acest fel, vectorul de cuantizat  $x$  nu-și mai găsește cel mai apropiat vector de reproducere, producând creșterea erorii de cuantizare. În acest exemplu simplu de TSVQ, cartea de cod are  $N=4$  vectori de reproducere. Evident că în practică numărul de vectori de reproducere este mult mai mare.

Ceea ce este caracteristic acestui tip de cuantizor vectorial, explicând rapiditatea procesului de codare, este faptul că fiecare test elimină jumătate din vectorii de reproducere care ar putea reprezenta versiunea cuantizată a vectorului de cuantizat.

Considerând tot cazul  $k=2$ , dreptele după care se fac testele în noduri pot să fie înclinate față de axele sistemului de coordonate, ( $A$  și  $C$  în figura 4.2), sau pot să fie perpendiculare pe aceste axe ( $B$ ). În primul caz testul implică înlocuirea componentelor vectorului de cuantizat în ecuația dreptei care separă cele două semiplane și efectuarea unei comparații. Dacă toate

dreptele de test sunt perpendiculare, se compară una dintre componentele vectorului de cuantizat cu o valoare, corespunzătoare uneia din dreptele perpendiculare. Evident că în al doilea caz testul este mai simplu, iar regiunile de cuantizare rezultate sunt de formă dreptunghiulară. Oricum, în ambele cazuri, regiunile de cuantizare diferă de regiunile obținute în cazul unui cuantizor vectorial de tip Voronoi, unde fiecare față a frontierei unei regiuni este egal depărtată de doi vectori de reproducere, așa cum se arată în figura 4.3.



**Figura 4.3:** *Regiunile de cuantizare la un cuantizor vectorial de tip Voronoi.*

Pe baza celor prezentate rezultă suboptimalitatea unui TSVQ, deoarece regiunile de cuantizare diferă de cele optimale și, în plus, nu se găsește totdeauna cel mai apropiat vector de reproducere din cei disponibili. Această problemă a suboptimalității este tratată de autor și în [48].

#### **4.2 Principiul cuantizării vectoriale prin metoda combinată arbore-căutare totală**

În [2] se descrie o metodă de cuantizare vectorială care combină metoda de tip arbore cu metoda de căutare totală. Efectul este obținerea aceleiași erori de cuantizare ca și la căutarea totală cu prețul creșterii complexității față de metoda de tip arbore.

La această metodă de cuantizare, codarea se face tot după o structură de tip arbore, care conține  $d$  niveluri,  $2^d-1$  noduri interne și  $2^d$  noduri terminale. Deosebirea esențială față de metoda TSVQ este că fiecărui nod terminal îi corespund mai mulți vectori de reproducere. După parcurgerea arborelui, cu ajutorul testelor binare efectuate asupra vectorului de cuantizat, se ajunge într-un nod terminal, unde se face o căutare totală printre vectorii de reproducere corespunzători aceluși nod terminal, pentru a se găsi codul sau cuantizatul vectorului de cuantizat. Pentru un astfel de cuantizor, numărul de niveluri  $d$  este mai mic decât  $\log_2 N$ .


Pentru a se proiecta un astfel de cuantizor vectorial, trebuie să fie disponibili vectorii de reproducere ai unui cuantizor de tip Voronoi, optimizat conform algoritmului generalizat al lui Lloyd. Acești vectori de reproducere se vor regăsi printre vectorii corespunzători nodurilor terminale.

Deși procesul de codare, până la ajungerea într-un nod terminal, se face identic cu cel de la TSVQ, există o deosebire majoră: dacă la TSVQ fiecare test elimină jumătate din vectorii de reproducere candidați, în acest caz se elimină mai puțin de jumătate din acești vectori. Mai precis, există unii vectori care rămân printre vectorii posibil de a reprezenta cuantizatul vectorului de intrare, indiferent de rezultatul testului binar. Sau, în urma testului binar, vectorii de reproducere disponibili se împart în două grupe care au și elemente comune.

În continuare autorul prezintă printr-un exemplu din spațiu  $\mathfrak{R}^2$ , pentru un arbore cu un singur nivel, modul de determinare a vectorilor care se elimină și care rămân, în funcție de testul efectuat.

În figura 4.4 se arată regiunile de cuantizare și vectorii de reproducere, pentru un cuantizor de tip Voronoi, cu  $N=16$ . Testul se face cu ajutorul unei drepte, notată  $A$ , perpendiculară pe axa  $Ox_1$ , caracterizată prin  $x_1=a$ . Se presupune că vectorul de cuantizat este  $\mathbf{x}=(x'_1, x'_2)$ . Deoarece  $x'_1 > a$ , trebuie reținuți în primul rând toți vectorii de reproducere care au componenta  $x_1 > a$ , adică cei notați 1, 7, 12, 13, 14, 15, 16. Regiunile unora dintre acești vectori intersectează dreapta  $A$  (vectorii 1, 7, 16). Este posibil să existe vectori de reproducere care au  $x_1 < a$ , dar regiunile lor de cuantizare conțin și puncte cu  $x_1 > a$ , adică intersectează dreapta  $A$ . Deoarece în aceste puncte

se pot găsi posibili vectori de cuantizat, cazul vectorului  $x$ , trebuie reținuți și astfel de vectori (vectorii 10 și 11). Ceilalți vectori de reproducere, adică 2, 3, 4, 5, 6, 8 și 9, se elimină.



**Figura 4.4:** Regiunile și vectorii de reproducere pentru un cuantizor de tip Voronoi cu  $N=16$ .

Apoi se face o căutare totală printre toți vectorii de reproducere reținuți. În acest fel, vectorul de cuantizat își va găsi cu siguranță cel mai apropiat vector de reproducere din cartea de cod a cuantizorului de tip Voronoi, adică cel notat cu 11.

În concluzie, indiferent de poziția vectorului de cuantizat față de dreapta de test, se rețin vectorii de reproducere ale căror regiuni intersectează dreapta de test, împreună cu vectorii de reproducere situați de aceeași parte cu vectorul de cuantizat față de dreapta de test, și ale căror regiuni de cuantizare nu intersectează această dreaptă.

Desigur că procesul de codare poate continua pe mai multe niveluri. Pentru aceasta, regiunea situată la stânga dreptei A, împreună cu vectorii de reproducere reținuți când vectorul de cuantizat are  $x'_1 < a$  se atribuie pentru analiză primului nod de pe nivelul 2, iar regiunea situată de cealaltă parte a dreptei A împreună cu vectorii de reproducere reținuți când  $x'_1 > a$  se atribuie celui alt nod de pe nivelul 2. În aceste noduri se reiau separat procesele executate în nodul rădăcină (stabilirea dreptei de test și a vectorilor de

reproducere reținuți în cele 2 cazuri). Procesul continuă în acest mod, până când numărul vectorilor de reproducere reținuți scade suficient de mult, pentru a permite o căutare totală cu o complexitate cât mai mică.

În continuarea acestei lucrări, această metodă va fi referită ca metoda de cuantizare vectorială *combinată arbore-căutare totală*.

Creșterea în complexitate față de TSVQ înregistrată la această metodă se datorează căutării care se face în nodurile terminale. Însă, dacă proiectarea este realizată corespunzător, adică vectorii de reproducere care se rețin, respectiv, se elimină sunt corect determinați, atunci eroarea medie de cuantizare este aceeași cu cea care s-ar obține printr-o căutare totală realizată asupra celor  $N$  vectori de reproducere ai cuantizor de tip Voronoi.

### 4.3 Structurarea cărții de cod a unui cuantizor vectorial în vederea aplicării metodei combinate arbore-căutare totală

#### 4.3.1 Descrierea generală a procesului de structurare

Pentru aplicarea metodei combinate arbore-căutare totală trebuie să fie disponibilă o carte de cod optimă, specifică unui cuantizor de tip Voronoi. Această carte de cod trebuie prelucrată (structurată) în vederea determinării pentru fiecare nod intern al arborelui a componentei vectorului de cuantizat care se va testa (și a valorii cu care se compară componenta respectivă) precum și a vectorilor de reproducere asociați fiecărui nod terminal.

Se notează cu  $m = 2^d$  numărul nodurilor terminale ale arborelui, respectiv cu  $n_i$ ,  $i=1, \dots, m$ , numărul de vectori de reproducere asociați cu fiecare din aceste noduri, iar  $p_i$ ,  $i=1, \dots, m$ , reprezintă probabilitatea ca un vector de cuantizat să fie atribuit în urma testelor, nodului terminal  $i$ . În aceste condiții numărul de distanțe calculate pentru codarea unui vector, efectuate într-unul din nodurile terminale este

$$n_{dist} = p_1 n_1 + p_2 n_2 + \dots + p_m n_m \quad (4.1)$$

Se consideră că în fiecare nod intern, pentru efectuarea testului, componenta  $j$  a vectorului de cuantizat se compară cu o valoare, notată  $v_j$ ,


adică dreapta în raport cu care se face testul este perpendiculară pe una din axele sistemului de coordonate (în cazul  $k=2$ ). Pentru o proiectare optimă, în fiecare nod, perechea  $(j, v_j)$  trebuie aleasă astfel încât numărul de distanțe  $n_{dist}$  să fie minim. Componenta  $j$  poate lua valori întregi din mulțimea  $\{1, 2, \dots, k\}$ , iar  $v_j$  aparține intervalului în care componenta respectivă poate lua valori conform secvenței de antrenament. În acest fel, pentru fiecare din cele  $2^l-1$  noduri interne ale arborelui trebuie testate toate perechile posibile  $(j, v_j)$ , în vederea găsirii unui minim pentru  $n_{dist}$ .

Dacă, de exemplu  $v_j$  ia, în medie 50 de valori în intervalul specificat, într-un nod ar exista  $50k$  perechi  $(j, v_j)$  posibile. În total, expresia  $n_{dist}$  poate avea  $(50k)^{m-1}$  valori posibile. Dacă  $k=3$  și  $m=64$ , se obțin  $150^{63}$  cazuri posibile. Această operație este deosebit de complexă și de aceea, așa cum se propune și în [2], se realizează o optimizare locală. Adică, în fiecare nod, independent de alte noduri, se determină perechea  $(j, v_j)$  pentru care, la cuantizarea unui vector  $x$ , s-ar calcula un număr minim de distanțe, în funcție de vectorii de reproducere reținuți în urma testului binar efectuat.

În acest sens se consideră un nod intern al arborelui notat  $i$ . În urma divizării realizată de dreapta de test în nodul de pe nivelul precedent din care se ajunge în acest nod intern, se obțin două regiuni dreptunghiulare. Una dintre aceste regiuni, cea atribuită nodului  $i$ , notată  $R_i$ , este intersectată de regiunile de cuantizare a  $N_i$  vectori de reproducere (acești  $N_i$  vectori de reproducere reprezintă vectorii reținuți în cazul când vectorul de cuantizat este plasat în regiunea care apoi s-a atribuit nodului  $i$ ).

În figura 4.5 se arată această configurație pentru cazul  $k=2$ . În acest caz, în perechea  $(j, v_j)$  față de care se face testul,  $j$  poate lua valoarea 1 sau 2, iar  $v_j \in (a_j, b_j)$ .

Se consideră  $x=(x_1, x_2)$  un vector de cuantizat (nearătat în figura 4.5). În acest caz  $p_s$  este probabilitatea ca un astfel de vector să aibe componenta  $x_j \leq v_j$ , iar  $p_d$  este probabilitatea ca vectorul respectiv să aibe  $x_j > v_j$ ,  $j=1,2$ . Rezultă că  $p_s+p_d=1$ .  $n_s$  este numărul regiunilor de cuantizare care conțin vectori pentru care  $x_j \leq v_j$ , iar  $n_d$  este numărul regiunilor de cuantizare care conțin vectori pentru care  $x_j > v_j$ ,  $j=1,2$ . Evident că  $n_s+n_d > N_i$ . În aceste condiții, dintre toate perechile posibile  $(j, v_j)$ , trebuie aleasă aceea pentru



**Figura 4.5:** Regiunea  $R_j$  și regiunile de cuantizare care o intersectează.

care expresia  $n'_{dist} = p_s n_s + p_d n_d$  este minimă. Adică, dacă un vector de cuantizat ajunge în nodul  $i$  în urma testelor efectuate pe nivelurile precedente, după testul efectuat în nodul  $i$ , își va găsi cel mai apropiat vector de reproducere în urma unui număr minim de distanțe calculate. (Se presupune că nodul  $i$  se află pe nivelul  $d$ , ultimul al arborelui, iar în acest caz  $n_s$  și  $n_d$  reprezintă numărul de vectori de reproducere asociați cu cele două noduri terminale la care se ajunge din nodul  $i$ ).

Acest procedeu, de determinare a perechii  $(j, v_j)$  optime se aplică pentru toate nodurile de pe un anumit nivel al arborelui. Dacă valorile  $n_s$  și  $n_d$  din aceste noduri sunt suficient de mici, structurarea se încheie. În caz contrar se trece pe nivelul următor. Valorile  $n_s$  și  $n_d$  ale acestor noduri vor fi valorile  $n_1, n_2, \dots, n_m$  asociate nodurilor terminale. Bineînțeles că pentru fiecare nod terminal trebuie să se cunoască nu numai valoarea  $n_i$ , ci și care sunt cei  $n_i$  vectori de reproducere asociați nodului (din cei  $N$  vectori de reproducere ai cărții de cod).

Probabilitățile  $p_s$  și  $p_d$  se determină pe baza vectorilor din secvența de antrenament. Fiecărei regiuni de tipul  $R_j$  îi sunt atribuiți pe lângă cei  $N_j$  vectori de reproducere, și  $N_{ai}$  vectori de antrenament situați în acea regiune. În funcție de perechea  $(j, v_j)$ , acești vectori de antrenament se împart în 2 grupe distincte, adică cei cu probabilitatea  $p_s$  și cei cu probabilitatea  $p_d$ . După stabilirea perechii  $(j, v_j)$  conform criteriului de minim



enunțat, cele două grupe de vectori de antrenament rezultate (cele care au probabilitățile  $p_s$  și, respectiv,  $p_d$ ), vor reprezenta vectorii de antrenament atribuiți celor 2 regiuni corespunzătoare celor 2 noduri de pe nivelul următor.

Dacă determinarea probabilităților  $p_s$  și  $p_d$  nu ridică probleme, fiind simplă dacă se cunoaște secvența de antrenament, determinarea lui  $n_s$  și  $n_d$  pentru diferite perechi  $(j, v_j)$  este mai dificilă. Sau, mai precis, ceea ce este mai dificil este determinarea acelor regiuni de cuantizare care intersectează dreapta (planul, pentru  $k > 2$ ) în raport cu care se face testul, adică  $x_j = v_j$ . Vectorii de reproducere corespunzători acestor regiuni de cuantizare, se vor găsi în ambele grupe de vectori de reproducere care rezultă în urma efectuării testului.

În [2] se propune pentru determinarea parametrilor  $n_s$  și  $n_d$  o metodă numită metoda proiecțiilor. Conform acestei metode se determină pentru orice valoare  $v_j$  a oricăreia din cele  $k$  componente, care sunt valorile lui  $n_s$  și  $n_d$ . Aceasta presupune următorii pași.

1. Se generează niște vectori  $(x_1, \dots, x_k)$  uniform distribuiți în porțiunea (mărginită) din  $\mathfrak{R}^k$  în care vectorii de cuantizat pot lua valori, adică  $x_j \in (a_j, b_j)$ ,  $j = 1, \dots, k$ . Acești vectori se cuantizează prin intermediul cărții de cod cu  $N$  vectori de reproducere ai cuantizorului Voronoi, proiectată conform algoritmului Lloyd.

2. În urma cuantizării, vectorii uniform distribuiți sunt repartizați în cele  $N$  regiuni de cuantizare. Pe baza acestor vectori se determină proiecțiile fiecărui regiuni pe cele  $k$  componente. Astfel, pentru o regiune  $R_i$ ,  $i = 1, \dots, N$ , proiecțiile după componenta  $j$ ,  $j = 1, \dots, k$  sunt

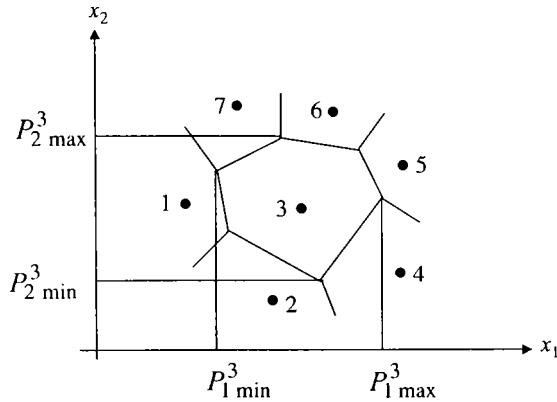
$$P_{j \min}^i = \min_{x \in R_i} (x_j : Q(\mathbf{x}) = y_j) \quad (4.2)$$

și respectiv

$$P_{j \max}^i = \max_{x \in R_i} (x_j : Q(\mathbf{x}) = y_j) \quad (4.3)$$

unde vectorii  $\mathbf{x}$  de forma  $\mathbf{x} = (x_1, x_2, \dots, x_k)$  reprezintă vectorii atribuiți regiunii  $R_i$  în urma procesului de cuantizare. În figura 4.6 se arată proiecțiile

pentru regiunea  $R_3$ , pentru cazul  $k=2$ . Evident că pentru o determinare cât mai exactă a acestor proiecții, vectorii uniform distribuiți trebuie să fie cât mai apropiați între ei, pentru a acoperi tot spațiul  $\mathfrak{R}^2$ .



**Figura 4.6:** Proiecțiile regiunii  $R_3$  pe cele două axe ale sistemului de coordonate.

3. Fiind disponibile proiecțiile tuturor celor  $N$  regiuni după cele  $k$  componente, se pot determina parametrii  $n_s$  și  $n_d$  pentru orice valoare  $v_j \in (a_j, b_j)$ ,  $j = 1, \dots, k$ , în modul următor:  $n_s$  reprezintă numărul regiunilor de cuantizare pentru care  $P^i_{j \min} < v_j$ , iar  $n_d$  reprezintă numărul regiunilor de cuantizare pentru care  $P^i_{j \max} > v_j$ ; parametrul  $i$ ,  $i=1, \dots, N$ .

După cum rezultă din prezentarea pașilor parcurși în cadrul metodei proiecțiilor, exceptând pasul 1, predomină operațiile de comparare. Astfel, dacă se notează cu  $N_{mediu}$  numărul mediu de vectori uniform distribuiți atribuiți fiecărei regiuni de cuantizare, numărul total de operații (comparații) care se fac la pasul 2 este

$$n_{c2} = N(2N_{mediu})k, \quad (4.4)$$

unde factorul 2 apare datorită faptului că se fac  $N_{mediu}$  comparații pentru determinarea proiecției minime și, respectiv, același număr de comparații pentru determinarea proiecției maxime. Pentru determinarea numărului de operații care se fac în cadrul pasului 3, se notează cu  $n_{mediu}$  numărul mediu

al valorilor  $v_j$  pentru care se dorește determinarea parametrilor  $n_s$  și  $n_d$ , pentru fiecare din cele  $k$  componente. Astfel numărul total de operații este

$$n_{c3} = (n_{\text{mediu}} 2N)k, \quad (4.5)$$

unde factorul 2 apare pentru că se fac comparații cu cele  $N$  proiecții minime, pentru determinarea lui  $n_s$  și apoi cu cele  $N$  proiecții maxime, pentru determinarea lui  $n_d$ .

### 4.3.2 Determinarea parametrilor $n_s$ și $n_d$ prin metoda intersecțiilor

**Autorul propune o altă metodă pentru determinarea parametrilor  $n_s$  și  $n_d$ .** Înainte de descrierea metodei generale, pentru determinarea lui  $n_s$  și  $n_d$  pentru toate valorile  $v_j$  ale tuturor componentelor, se descrie aplicarea metodei pentru o singură valoare  $v_j$  a unei componente. Astfel, se generează vectorii de forma  $x=(x_1, \dots, v_j, \dots, x_k)$ , unde componenta  $j$  are o valoare fixă  $v_j$ , iar celelalte  $k-1$  componente iau valori uniform distribuite în gama în care aceste componente iau valori conform secvenței de antrenament. Apoi, acești vectori se cuantizează prin intermediul celor  $N$  vectori de reproducere ai cărții de cod a cuantizatorului Voronoi proiectată prin algoritmul Lloyd. Regiunile de cuantizare ale vectorilor de reproducere care au reprezentat cel puțin o dată versiunea cuantizată a vreunui vector de forma  $x$ , intersecțează dreapta (planul, pentru  $k>2$ )  $x_j=v_j$  și prin urmare acești vectori vor face parte din ambele grupe de vectori de reproducere. Vectorii de reproducere care nu au reprezentat niciodată cuantizatul vreunui vector de forma  $x$  vor face parte din prima grupă (cea care conține  $n_s$  vectori) dacă  $x_j \leq v_j$ , sau din a doua grupă (care conține  $n_d$  vectori) dacă  $x_j > v_j$ .

În figura 4.7 se exemplifică metoda propusă de autor, pentru cazul  $k=2$ . Se generează vectori de forma  $(v_1, x_2)$ , unde  $v_1$  este valoarea pentru care se dorește determinarea parametrilor  $n_s$  și  $n_d$ , iar  $x_2$  ia valori egal depărtate în gama admisibilă. Acești vectori sunt notați prin "\*" și sunt cuantizați pe baza căutării totale, în ordine, prin vectorii de reproducere notați 1, 1, 1, 16, 7, 11, 11 și 10. Acești vectori de reproducere vor face parte din ambele grupe, adică grupa care conține  $n_s$  vectori, și, respectiv,

grupa care conține  $n_d$  vectori. Apoi, dintre vectorii de reproducere care nu au reprezentat niciodată versiunea cuantizată a vectorilor de forma  $(v_1, x_2)$ , cei notați 2, 3, 4, 5, 6, 8 și 9 vor face parte din grupa cu  $n_s$  vectori (deci  $n_s=12$ ) iar cei notați 12, 13, 14 și 15 vor face parte din grupa cu  $n_d$  vectori (deci  $n_d=9$ ).





Figura 4.7: Explicativă pentru determinarea lui  $n_s$  și  $n_d$  pentru  $k=2$ .

Pe baza acestui exemplu, în care s-a arătat, cum se determină  $n_s$  și  $n_d$  pentru valoarea  $v_1$  a componenteii 1, se va arăta prin generalizare, cum se obțin valorile  $n_s$  și  $n_d$  corespunzătoare tuturor valorilor  $v_j$  ale celor  $k$  componente ale vectorilor. **Această metodă propusă de autor va fi referită în continuare ca metoda intersecțiilor.**

La fel ca și la metoda proiecțiilor, mai întâi se generează vectorii de forma  $(x_1, \dots, x_k)$ , uniform distribuiți în porțiunea mărginită din  $\mathfrak{R}^k$  în care vectorii de cuantizat pot lua valori, adică  $x_j \in (a_j, b_j)$ . În figura 4.8 se arată acești vectori pentru cazul  $k=2$ .

Astfel,  $x_1$  ia valori în intervalul  $(a_1, b_1)$ , egal decalate între ele cu pasul  $\Delta_1$ , iar  $x_2$  ia valori în intervalul  $(a_2, b_2)$ , egal decalate cu pasul  $\Delta_2$ . În practică se poate ca  $\Delta_1 = \Delta_2$ .



**Figura 4.8:** Dispunerea vectorilor uniform distribuiți în cazul  $k=2$ .

Considerând vectorii care au  $x_1=a_1$ , adică

$$\begin{cases} a_1, a_2 \\ a_1, a_2 + \Delta_2 \\ \vdots \\ a_1, b_2 \end{cases} \quad (4.6)$$

prin cuantizarea acestora prin intermediul celor  $N$  vectori de reproducere, se pot determina parametrii  $n_s$  și  $n_d$  pentru  $v_1=a_1$ . Apoi, prin cuantizarea vectorilor care au  $x_1=a_1+\Delta_1$ , adică

$$\begin{cases} a_1 + \Delta_1, a_2 \\ a_1 + \Delta_1, a_2 + \Delta_2 \\ \vdots \\ a_1 + \Delta_1, b_2 \end{cases} \quad (4.7)$$

se determină parametrii  $n_s$  și  $n_d$  pentru  $v_1=a_1+\Delta_1$ . În continuare, în acest fel,  $x_1$  crește cu  $\Delta_1$  în timp ce  $x_2$  ia valori în toată gama admisibilă, până când se ajunge la vectorii cu  $x_1=b_1$ , adică

$$\begin{cases} b_1, a_2 \\ b_1, a_2 + \Delta_2 \\ \vdots \\ b_1, b_2 \end{cases} \quad (4.8)$$

Prin cuantizarea acestor vectori se determină parametrii  $n_s$  și  $n_d$  pentru  $v_1=b_1$ . În acest fel s-au cuantizat toți vectorii din figura 4.8. Din figură se poate observa că în același timp s-au generat și cuantizat vectorii care au  $x_2=a_2$ ,  $x_2=a_2+\Delta_2$ ,  $x_2=a_2+2\Delta_2$ , ...,  $x_2=b_2$ , de fiecare dată  $x_1$  luând valori în întreaga gamă admisibilă. Astfel se pot determina parametrii  $n_s$  și  $n_d$  pentru  $v_2=a_2$ , pentru  $v_2=a_2+\Delta_2$  și așa mai departe, pentru  $v_2=b_2$ . În concluzie, prin cuantizarea vectorilor uniform distribuiți în porțiunea mărginită din  $\mathfrak{R}^2$ , se determină parametrii  $n_s$  și  $n_d$  pentru valorile ambelor componente ( $k=2$ ), valori distribuite uniform în gama admisibilă.

Acest rezultat se poate explica și în felul următor: considerând că se cuantizează un vector  $(x'_1, x'_2)$  oarecare din porțiunea mărginită, înainte sau după cuantizarea acestui vector s-au cuantizat sau se vor mai cuantiza vectori care au  $x_1=x'_1$  și  $x_2$ =variabil, sau  $x_1$ =variabil și  $x_2=x'_2$ ; pe baza rezultatelor obținute prin cuantizarea lui  $(x'_1, x'_2)$  și a celorlalți vectori amintiți, se determină regiunile de cuantizare care intersectează dreptele  $x_1=x'_1$  și  $x_2=x'_2$  și apoi a parametrilor  $n_s$  și  $n_d$  pentru  $v_1=x'_1$  și  $v_2=x'_2$ .

Această idee se poate aplica în același mod și pentru valori ale lui  $k$  mai mari decât 2. Astfel, pentru vectori de forma  $(x_1, x_2, \dots, x_k)$ , fiecare componentă se poate scrie sub forma

$$x_i = a_i + q\Delta_i; q = 0, 1, 2, \dots; i = 1, 2, \dots, k. \quad (4.9)$$

Considerând că fiecare componentă din cele  $k$  poate avea  $n_{mediu}$  valori egal depărtate unele de altele, se poate scrie că

$$b_i = a_i + (n_{mediu} - 1)\Delta_i; i = 1, 2, \dots, k. \quad (4.10)$$

În acest fel, se dorește determinarea parametrilor  $n_s$  și  $n_d$  pentru  $kn_{mediu}$  valori (câte  $n_{mediu}$  valori pentru fiecare din cele  $k$  componente).

Pentru determinarea acestor  $kn_{mediu}$  perechi de parametri, se creează  $kn_{mediu}$  tablouri (zone de memorie), fiecare cu  $N$  locații. După cuantizarea fiecărui vector uniform distribuit,  $(x_1, x_2, \dots, x_k)$ , se vor face înscrieri în  $k$  din cele  $kn_{mediu}$  tablouri, la locația  $ii$ , unde  $ii$  reprezintă codul obținut prin

codarea vectorului  $(x_1, x_2, \dots, x_k)$ ,  $ii$  putând lua orice valoare de la 1 până la  $N$ . Aceste înscrieri se vor face în tablourile corespunzătoare valorilor de forma  $a_i + q\Delta_i$  pe care le are fiecare din cele  $k$  componente  $x_i$  ale vectorului respectiv.

De exemplu, dacă inițial toate locațiile conțin valoarea 0, se poate înscrie valoarea 1, la locația  $ii$ , în fiecare din cele  $k$  tablouri.

Pe parcursul cuantizării fiecăruia din cei  $(n_{mediu})^k$  vectori uniformi distribuiți, fiecare din cele  $kn_{mediu}$  valori se va regăsi de  $n_{mediu}$  ori printre componentele vectorilor uniformi, producând înscrierea valorii 1 la locația  $ii$  din tabloul propriu. (Se poate scrie valoarea 1 de mai multe ori în aceeași locație, deoarece mai mulți vectori, pentru care una dintre componente este identică, se pot cuantiza prin același vector de reproducere).

După încheierea acestui proces de cuantizare și înscriere în memorie, va urma un proces de analiză a acestor tablouri, în scopul determinării parametrilor  $n_s$  și  $n_d$  pentru fiecare din cele  $kn_{mediu}$  valori.

Se va începe cu componenta  $i=1$ , primul tablou fiind cel corespunzător valorii  $a_1$ . Se vor analiza toate locațiile  $j$ ,  $j=1, \dots, N$ , în felul următor (se subliniază că în aceste locații s-au făcut înscrieri după cuantizarea tuturor vectorilor care au  $x_1=a_1$ ):

- dacă la o locație  $j$  se găsește valoarea 1, înseamnă că regiunea de cuantizare a aceluși vector de reproducere intersectează dreapta  $x_1=a_1$ , adică vectorul de reproducere corespunzător  $y_j$ , va face parte din ambele grupe.

- dacă la o locație  $j$  se găsește valoarea 0, înseamnă că regiunea de cuantizare a aceluși vector de reproducere nu intersectează dreapta  $x_1=a_1$ ; dacă  $y_{j1} \leq a_1$ , vectorul de reproducere  $y_j$  va face parte din grupa cu  $n_s$  elemente, iar dacă  $y_{j1} > a_1$ , din grupa cu  $n_d$  elemente ( $y_{j1}$  este prima componentă a vectorului de reproducere  $k$ -dimensional  $y_j$ ).

Apoi procesul continuă asemănător pentru celelalte  $n_{mediu}-1$  valori corespunzătoare pentru  $i=1$ , după care se repetă aceleași operații pentru  $i=2, 3, \dots, k$ .

Pentru a se face o comparație a metodei intersecțiilor, propusă de autor, cu metoda proiecțiilor, prezentă în literatură, din punct de vedere al numărului de operații, trebuie remarcat că în ambele metode se generează

aceiași număr de vectori uniform distribuiți, astfel încât pentru cuantizarea acestora se face același număr de operații. Deosebirile se vor arăta în continuare. La metoda intersecțiilor, după cuantizarea fiecărui vector, se fac  $k$  înscrieri în memorie, deci în total se fac

$$m' = N_{mediu} N k \quad (4.11)$$

înscrieri, iar apoi, în cadrul procesului de analiză a tablourilor din memorie se fac

$$m'' = n_{mediu} (N + 0,7N) k \quad (4.12)$$

comparații. Termenul  $0,7N$  se justifică prin aceea că, în general (așa cum se va arăta ulterior), aproximativ 70% din regiunile de cuantizare nu intersectează dreapta  $x_i = a_i + q\Delta_i$ , deci trebuie făcută încă o comparație pentru a se determina în care grupă intră vectorii corespunzători acelor regiuni de cuantizare.

Revăzând relațiile (4.4) și (4.5) rezultă că la metoda proiecțiilor se fac  $n_{c2} + n_{c3}$  comparații,

$$n_{c2} + n_{c3} = 2NN_{mediu} k + 2Nn_{mediu} k. \quad (4.13)$$

Pentru metoda intersecțiilor se consideră de asemenea comparațiile (deci nu se consideră înscrierile în memorie), astfel că, dacă se compară relațiile (4.12) și (4.13) se observă s-a obținut o evidentă reducere a numărului de operații matematice.

Pentru un caz practic,  $N=256$   $k=3$ ,  $n_{mediu}=50$ , se obține

$$N_{mediu} = \frac{(n_{mediu})^k}{N} = \frac{50^3}{256} \approx 500.$$

Rezultă  $n_{c2} + n_{c3} = 2 \times 256 \times 500 \times 3 + 2 \times 256 \times 50 \times 3 \approx 845000$ , respectiv

$m'' = 50 \times 3 \times (256 + 0,7 \times 256) \approx 65250$ , adică o reducere de aproximativ 12 ori a numărului de operații matematice pentru metoda intersecțiilor.



O altă deosebire între cele două metode este în ce privește valorile componentelor pentru care se determină parametrii  $n_s$  și  $n_d$ . La metoda proiecțiilor, acești parametri se pot determina pentru valori independente de componentele vectorilor uniform distribuiți cuantizați, în timp ce la metoda intersecțiilor parametrii se determină numai pentru valori identice cu componentele vectorilor uniform distribuiți cuantizați. Acest fapt nu constituie însă un dezavantaj pentru metoda intersecțiilor, deoarece în ambele cazuri numărul vectorilor uniform distribuiți trebuie să fie suficient de mare pentru a asigura precizia necesară.

### 4.3.3 Aplicarea metodei intersecțiilor pentru structurarea unei cărți de cod la un cuantizor vectorial pentru parametri LSF

În capitolul 3 autorul a realizat cuantizarea vectorială a parametrilor LSF folosind metoda prin desplicare. În acest sens au fost proiectate 3 cărți de cod, fiecare cu  $N=256$  vectori de reproducere, câte una pentru fiecare din cei 3 subvectori (care au avut dimensiunile 3, 3 și 4). În procesul de codare, pentru fiecare subvector s-a făcut o căutare totală în cartea de cod aferentă. În scopul reducerii complexității, autorul dorește realizarea codării pentru fiecare din cei 3 subvectori prin metoda combinată arbore-căutare totală. Pentru aceasta, trebuie structurate cele trei cărți de cod, autorul realizând acest lucru folosind metoda intersecțiilor.

În tabelul 4.1 se prezintă gama de variație a fiecăruia din cei 10 parametri LSF, așa cum rezultă prin calcul pe baza secvenței de antrenament de 2790 vectori.

**Tabelul 4.1:** Gama de variație a parametrilor LSF.

Parametrul LSF	$f_1$	$f_2$	$f_3$	$f_4$	$f_5$	$f_6$	$f_7$	$f_8$	$f_9$	$f_{10}$
Gama de variație	141	223	429	751	925	1117	1684	2289	2558	2890
$(f_{min}, f_{max})$ [Hz]	576	905	1425	1768	2086	2444	2765	3101	3382	3721

Conform acestor intervale de variație, numărul vectorilor uniform distribuiți care trebuie generați și cuantizați ar fi foarte mare. Bazându-se pe două observații, autorul arată că nu trebuie generați toți vectorii posibili.

Prima observație este că, perechea  $(j, v_j)$  (componenta și valoarea cu care se compară aceasta) conform căreia vectorii de reproducere asociați unui nod al arborelui se împart în cele două grupe, trebuie aleasă astfel încât parametrii  $n_s$  și  $n_d$  care se obțin să aibe valori apropiate. Această restricție a fost impusă deoarece se dorește ca arborele după care se va face codarea să aibe ramuri egale, sau, numărul de noduri să se dubleze pe fiecare nivel față de nivelul precedent. Dacă  $n_s$  și  $n_d$  ar avea valori mai diferite, după câteva niveluri, unele grupe vor avea un număr foarte mic de vectori de reproducere asociați, făcând imposibilă continuarea procesului de împărțire. În acest fel unele niveluri vor conține atât noduri terminale cât și noduri interne, unde procesul de împărțire în câte două grupe va continua. Acest lucru nu este de dorit, deoarece procesul de codare ar fi mai neregulat, în funcție de calea urmată prin arbore, urmând să se ajungă într-un nod terminal după un număr diferit de comparații. Așa cum va rezulta și din exemplele următoare, pentru ca  $n_s$  și  $n_d$  să aibe valori apropiate, valoarea  $v_j$  trebuie să fie centrală față de intervalul respectiv de variație al parametrului LSF.

A doua observație susține că expresia  $n'_{dist} = p_s n_s + p_d n_d$ , care trebuie minimizată la alegerea perechii  $(j, v_j)$ , are valori minime în zona centrală a intervalului în care fiecare componentă ia valori. Acest fapt rezultă din datele prezentate în tabelul 4.2, unde se arată valorile calculate ale expresiei  $n'_{dist} = p_s n_s + p_d n_d$  pentru componentele  $f_1, f_2, f_3$ , în funcție de câteva valori, egal depărtate, din intervalul de variație al fiecărei componente. În toate cele trei cazuri s-a considerat întreaga carte de cod, cu 256 vectori de reproducere, adică s-au împărțit vectorii de reproducere asociați nodului rădăcină.

Din tabelul 4.2 rezultă mai multe concluzii:

- valoarea expresiei  $n'_{dist}$  care trebuie minimizată are variații mai mari de la o componentă la alta decât în cadrul aceleiași componente, în funcție de diferitele valori ale lui  $f_p, i=1, 2, 3$ .

**Tabelul 4.2:** Valori ale expresiei  $n'_{dist}$ .

Valori $f_1$ [Hz]	$p_s$ $p_d$	$n_s$ $n_d$	$n'_{dist}$	Valori $f_2$ [Hz]	$p_s$ $p_d$	$n_s$ $n_d$	$n'_{dist}$	Valori $f_3$ [Hz]	$p_s$ $p_d$	$n_s$ $n_d$	$n'_{dist}$
248	0,48 0,51	153 209	181,7	410	0,41 0,58	92 203	156,8	740	0,34 0,63	79 210	164,6
250	0,50 0,49	157 205	180,9	420	0,44 0,55	96 197	152,2	750	0,37 0,62	85 207	161,6
252	0,52 0,47	158 204	180	430	0,46 0,53	99 190	147,8	760	0,40 0,59	97 206	162,4
254	0,53 0,46	160 202	179	440	0,48 0,51	103 187	146	770	0,43 0,56	100 201	157
256	0,55 0,44	163 200	179	450	0,50 0,49	107 180	143	780	0,46 0,53	105 195	153
258	0,56 0,43	164 198	178	460	0,52 0,47	110 177	141	790	0,49 0,50	109 192	150
260	0,58 0,41	166 196	178	470	0,54 0,45	114 177	142	800	0,52 0,47	121 188	152
262	0,59 0,40	169 196	180	480	0,56 0,43	120 173	143	810	0,55 0,44	126 185	152
264	0,60 0,39	169 194	178	490	0,57 0,42	129 168	145	820	0,58 0,41	130 173	147
266	0,61 0,38	172 192	179	500	0,59 0,40	132 162	144	830	0,60 0,39	135 169	148,3
268	0,62 0,37	174 188	179	510	0,60 0,39	133 155	141	840	0,63 0,36	144 165	151,7
270	0,64 0,35	175 186	178	520	0,62 0,37	138 152	143	850	0,66 0,33	154 159	155,7
272	0,65 0,34	178 180	178,8	530	0,63 0,36	140 152	144,4	860	0,68 0,31	159 152	156,8
274	0,66 0,33	179 178	178,7	540	0,65 0,34	145 149	146,4	870	0,70 0,29	163 141	156,6
276	0,66 0,33	181 176	179,3	550	0,66 0,33	149 142	146,7	880	0,73 0,26	171 133	161

- intervalele în care vectorii de antrenament au ambele probabilități semnificative (adică  $p_s$  sau  $p_d$  mai mari decât  $0,25 \div 0,30$ ), sunt mult mai mici decât intervalele în care aceeași vectori iau valori (tabelul 4.1)

- în situația în care  $p_s \cong p_d$ ,  $n_s$  și  $n_d$  sunt mult diferite și invers, când  $n_s \cong n_d$ ,  $p_s$  și  $p_d$  sunt mult diferite.

- valoarea expresiei  $n'_{dist}$  are variații în general mici la variațiile specificate în tabelul 4.2 pentru parametrii  $f_i$  (2Hz pentru  $f_1$ , 10 Hz pentru  $f_2$  și  $f_3$ )

Pe baza celor două observații precum și a concluziilor rezultate din analiza rezultatelor prezentate în tabelul 4.2, autorul a adaptat algoritmul general de structurare a cărții de cod în vederea codării prin metoda arbore-căutare totală pentru a fi aplicat vectorilor care conțin parametri LSF.

Înainte de prezentarea structurii complete a acestui algoritm, se prezintă modul de determinare a parametrilor  $n_s$  și  $n_d$  pentru un nod, care se va aplica apoi în orice nod al arborelui.

Mai întâi s-a determinat valoarea  $v_j$  pentru fiecare din cele 3 (sau 4) componente ale vectorilor. Ideea de bază rezultată din cele două observații anterioare este că trebuie generați și cuantizați numai acei vectori uniform distribuiți pentru care parametrii  $n_s$  și  $n_d$  au valori apropiate.

De exemplu, în cazul vectorilor de forma  $(f_1, f_2, f_3)$ , pentru determinarea valorii  $v_3$ , trebuie generați vectori în care  $f_3$  ia câteva valori egal depărtate într-un interval limitat, iar  $f_1$  și  $f_2$  iau valori egal depărtate în toată gama admisibilă conform tabelului 4.1. Intervalul limitat este acela pentru care parametrii  $n_s$  și  $n_d$  au valori apropiate. În final, dintre toate valorile lui  $f_3$ ,  $v_3$  va fi aceea pentru care valoarea expresiei  $n'_{dist}$  este minimă.

Foarte important a fost să se determine care este valoarea lui  $f_3$  de la care începe intervalul limitat. În acest scop s-a început de la o valoare a lui  $f_3$  situată în prima parte a gamei de variație din tabelul 4.1, determinându-se  $p_s$  și  $p_d$ , adică probabilitatea ca un vector de antrenament să aibe componenta a 3-a mai mică sau mai mare decât valoarea respectivă a lui  $f_3$ . Acest procedeu se repetă, crescând fin valoarea lui  $f_3$  până când se obține o valoare a lui  $p_s$  de 0,4. Începând cu această valoare a lui  $f_3$  se generează vectorii uniform distribuiți pentru care se calculează valorile expresiei  $n'_{dist}$ . Pentru determinarea valorii inițiale a lui  $f_3$ , s-a folosit calculul probabilităților  $p_s$  și  $p_d$  deoarece acesta necesită mai puține operații decât calculul lui  $n_s$  și  $n_d$ . Valoarea  $p_s=0,4$  s-a ales ținând cont de rezultatele prezentate în tabelul 4.2, și anume că, începând de la această probabilitate,

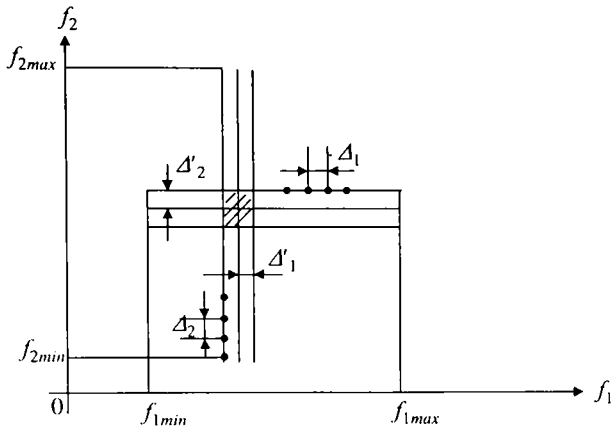
parametrii  $n_s$  și  $n_d$  încep să aibe valori comparabile. Desigur, valorile lui  $n_s$  și  $n_d$  pentru  $p_s=0,4$  diferă de la componentă la componentă (așa cum se vede și în tabelul 4.2) precum și de la un nod al arborelui la altul. Aceasta a fost însă o soluție de compromis care să permită generarea, în ansamblu, a cât mai puțini vectori uniformi. Legătura între  $p_s$  și, respectiv,  $n_s$  și  $n_d$  este doar o constatare experimentală, având în vedere că  $p_s$  și  $p_d$  se referă la vectorii de antrenament, iar  $n_s$  și  $n_d$  la vectorii de reproducere, care însă acoperă aceeași zonă a spațiului  $k$ -dimensional.

Începând de la valoarea lui  $f_3$  pentru care  $p_3=0,4$ , se calculează parametrii  $n_s$  și  $n_d$ , valoarea lui  $f_3$  crescând apoi cu câte 10 Hz, până când între parametrii  $n_s$  și  $n_d$  există relația  $n_s/n_d=0,9$ . Începând de la această valoare, se face o modificare mai fină a lui  $f_3$ , și anume cu 5 Hz, pentru ca raportul  $n_s/n_d$  să crească mai lent, rămânând cât mai apropiat de 1. Se mai generează în total vectori uniformi în care  $f_3$  ia 3 valori decalate cu 5 Hz, începând de la aceea pentru care  $n_s/n_d=0,9$ . Dintre aceste 3 valori, valoarea pentru care expresia  $n'_{dist}$  are valoarea minimă este valoarea  $v_3$ .

În continuare acest procedeu se repetă și pentru determinarea valorilor  $v_2$  și  $v_1$ , ale componentelor  $f_2$  și  $f_1$ , din cadrul vectorului  $(f_1, f_2, f_3)$ . Deoarece  $f_1$  are o gamă dinamică mai mică, după determinarea valorii pentru care  $p_s=0,4$ ,  $f_1$  se crește cu 4 Hz, iar din momentul în care  $n_s/n_d=0,9$ , cu 2 Hz. În final, fiecare componentă având o valoare "candidată", se determină pentru care din aceste componente expresia  $n'_{dist}$  are valoarea minimă.

În concluzie, față de forma generală a metodei intersecțiilor, care necesită generarea și cuantizarea unui număr foarte mare de vectori, autorul a propus o variantă simplificată, în scopul reducerii numărului de vectori generați și cuantizați, simplificarea fiind posibilă datorită modului în care sunt distribuți parametrii LSF. Dacă la forma generală a metodei, parametrii  $n_s$  și  $n_d$  pentru oricare din valorile posibile ale tuturor celor  $k$  componente se determinau după generarea o singură dată a tuturor vectorilor uniform distribuți, în varianta simplificată, se generează pentru fiecare componentă în parte alți vectori, așa cum se arată în figura 4.9, pentru cazul  $k=2$ .

În figura 4.9 se arată vectorii generați pentru determinarea parametrilor  $n_s$  și  $n_d$ , pentru componenta 1, în care valorile fixe ale lui  $f_1$  (3 valori), sunt decalate cu valoarea  $\Delta'_1$ , iar componenta  $f_2$  ia valori decalate cu valoarea  $\Delta_2$ ,



**Figura 4.9:** Vectorii uniform distribuiți în varianta simplificată a metodei intersecțiilor.

în intervalul  $(f_{2min}, f_{2max})$ . În mod asemănător se arată vectorii folosiți pentru determinarea parametrilor  $n_s$  și  $n_d$  pentru componenta 2. Tot din figura 4.9 se observă că unii vectori sunt generați de două ori (cei din porțiunea hașurată), dar aceștia sunt în număr foarte mic. Pe ansamblu, numărul vectorilor generați în varianta simplificată a metodei intersecțiilor este mult mai mic, față de forma generală, când ar fi trebuit să se genereze vectori care să acopere dreptunghiul  $(f_{1min}, f_{1max}), (f_{2min}, f_{2max})$ .


De asemenea, se mai impun câteva precizări asupra valorilor pașilor,  $\Delta_1, \Delta_2$ , respectiv,  $\Delta'_1$  și  $\Delta'_2$ . În forma generală a metodei intersecțiilor  $\Delta_1$  era implicit egal cu  $\Delta'_1$ , iar  $\Delta_2$  egal cu  $\Delta'_2$  (vezi figura 4.8). În forma simplificată a metodei  $\Delta_1 \neq \Delta'_1$ , deoarece  $\Delta_1$  reprezintă pasul cu care se modifică  $f_1$ , pentru vectorii care au  $f_2$  constant, acești vectori fiind necesari pentru determinarea regiunilor de cuantizare care intersecțează dreapta  $f_2 = \text{constant}$ .  $\Delta'_1$  reprezintă pasul cu care se modifică  $f_1$  într-un interval îngust, dintre valorile respective ale lui  $f_1$ , determinându-se cea pentru care mărimea  $n'_{dist}$  are valoare minimă, notată  $v_1$ . În mod similar și  $\Delta_2$  este diferit de  $\Delta'_2$ .

O mare importanță pentru realizarea cât mai corectă a procesului de structurare a cărții de cod o are modul în care iau valori componentele care se modifică în toată gama admisibilă (de exemplu  $f_1$  și  $f_2$ , când  $f_3$  este fix). Mai exact, în descrierea generală făcută anterior s-a spus că acele

componente vor fi distanțate unele de altele cu un pas,  $\Delta_1$ . De valoarea acestui pas depinde cât de corect se vor determina regiunile care intersectează dreapta  $x_j=v_j$ .

În figura 4.10 se arată un exemplu, din spațiul  $k=2$  care întărește această afirmație. Astfel, sunt arătați 4 vectori de reproducere, notați 1, 2, 3, 4 și se dorește să se determine care dintre regiunile de cuantizare ale acestor vectori intersectează dreapta  $f_1=v_1$ . Pentru aceasta se generează 4 vectori în care prima componentă are valoarea  $v_1$ , iar a doua componentă are valori egal depărtate cu  $\Delta_1$ ,

$$\begin{cases} (v_1, a_1) \\ (v_1, a_1 + \Delta_2) \\ (v_1, a_1 + 2\Delta_2) \\ (v_1, a_1 + 3\Delta_2) \end{cases} \quad (4.14)$$



**Figura 4.10:** Explicativă pentru determinarea intersecțiilor cu dreapta  $f_1=v_1$ .

Din figură se observă că, deși dreapta  $f_1=v_1$  intersectează regiunea de cuantizare a vectorului 1, nici unul din cei 4 vectori generați nu se cuantizează prin vectorul de reproducere 1. Cauza pentru care apare această inexactitate este valoarea prea mare a pasului  $\Delta_2$ , deoarece, din figură se observă cu ușurință că o valoare mai mică a pasului  $\Delta_2$  ar permite determinarea și a vectorului de reproducere 1 printre cei ale căror regiuni

intersectează dreapta  $f_1=v_1$ . În aceste condiții, la cuantizarea vectorului  $x=(f_1', f_2')$ , considerând că testul se face în raport cu valoarea  $v_1$  a componentei 1, acest vector va fi comparat cu vectorii de reproducere ale căror regiuni intersectează dreapta  $f_1=v_1$  (adică 4, 3 și 2) sau cu cei care au componenta  $f_1>v_1$ , dar regiunile lor nu intersectează dreapta  $f_1=v_1$  (nu este cazul). Prin urmare, vectorul  $x=(f_1', f_2')$  va fi cuantizat prin vectorul de reproducere 2 și nu prin 1, din a cărei regiune de cuantizare face parte, producându-se o creștere a erorii de cuantizare.

Modul cel mai simplu și totodată cel mai sigur de alegere a pasului  $\Delta_i$  este stabilirea acestuia la valoarea de 1 Hz, valoarea minimă prin care pot diferi între ele componentele vectorilor. În această situație inconvenientul ar fi din nou numărul mare de vectori uniform distribuiți care trebuie generați și cuantizați, prelungind mult timpul necesar structurării cărții de cod. Pentru a se vedea dacă, în practică, pasul poate avea o valoare mai mare decât 1 Hz, se poate proceda în modul următor: se determină numărul regiunilor de cuantizare care intersectează o dreaptă  $f_i=v_i$ , în situația în care pasul  $\Delta_j$ ,  $j \neq i$  are valoarea de 1 Hz; apoi se crește progresiv acest pas (2 Hz, 3 Hz, ..., ) până când numărul regiunilor care intersectează dreapta scade. Cea mai mare valoare a pasului pentru care numărul de regiuni rămâne același ca pentru pasul de 1 Hz, este cea optimă. Desigur că această metodă este pur experimentală, neputându-se justifica teoretic valoarea care se obține.

**O altă soluție, propusă de asemenea de autor, își propune să obțină o valoare pentru pasul  $\Delta_i$ , estimând dimensiunile regiunilor de cuantizare.** În acest sens se determină pentru fiecare vector de reproducere component al cărții de cod, distanța (euclidiană) până la cel mai apropiat vector de reproducere, notată  $d_{min}$ . Apoi se calculează media aritmetică a acestor distanțe pentru cei  $N$  vectori ai cărții de cod respective, notată  $d_{med}$ . Mărimea obținută are semnificația unei distanțe medii între oricare 2 vectori de reproducere învecinați. În tabelul 4.3 se arată aceste distanțe pentru cele 3 cărți de cod (cele care conțin vectorii cu componentele  $f_1, \dots, f_3, f_4, \dots, f_6$  și  $f_7, \dots, f_{10}$ ), precum și numărul vectorilor pentru care distanța până la cel mai



apropiat vector de reproducere este mai mică decât o anumită valoare, inferioară lui  $d_{med}$ .


**Tabelul 4.3:** Valori ale parametrului  $d_{med}$ .

Cartea de cod	$f_1 \dots f_3$	$f_4 \dots f_6$	$f_7 \dots f_{10}$
$d_{med}$	47,1	75,7	83,9
Număr de vectori	18 cu $d_{min} < 30$	8 cu $d_{min} < 50$	7 cu $d_{min} < 40$

Dacă vectorii de reproducere ar fi uniform distribuiți, regiunile de cuantizare ar avea forma unor pătrate (pentru  $k=2$ ) sau cuburi (pentru  $k=3$ ), cu laturile egale chiar cu distanța  $d_{med}$ . În acest caz, o valoare a lui  $\Delta_i$ , egală cu  $d_{med}$  ar permite determinarea corectă a regiunilor care intersectează dreapta  $f_i = v_i$ . Deoarece regiunile de cuantizare au forme mult mai complicate, este evident că pasul  $\Delta_i$  trebuie ales mai mic decât  $d_{med}$ . Pe baza datelor din tabelul 4.3, inclusiv numărul vectorilor cu distanța  $d$  mult mai mică decât  $d_{med}$ , autorul propune ca pasul  $\Delta_i$  să aibe o valoare cuprinsă în intervalul  $(0,3 \dots 0,5)d_{med}$ .

Rezultatele obținute experimental pentru câteva valori ale pasului  $\Delta_i$ , care vor confirma valorile propuse de autor, se vor arăta ulterior, după prezentarea organigramei algoritmului de structurare și a organigramei celui de codare.

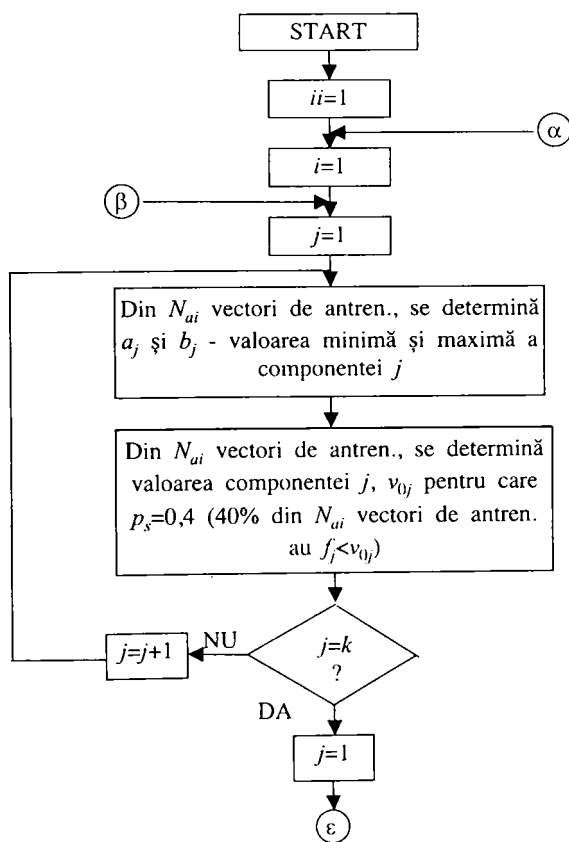
Înainte de prezentarea acestor organigrame se introduc unele notații necesare pentru buna înțelegere (unele notații au fost deja prezentate).

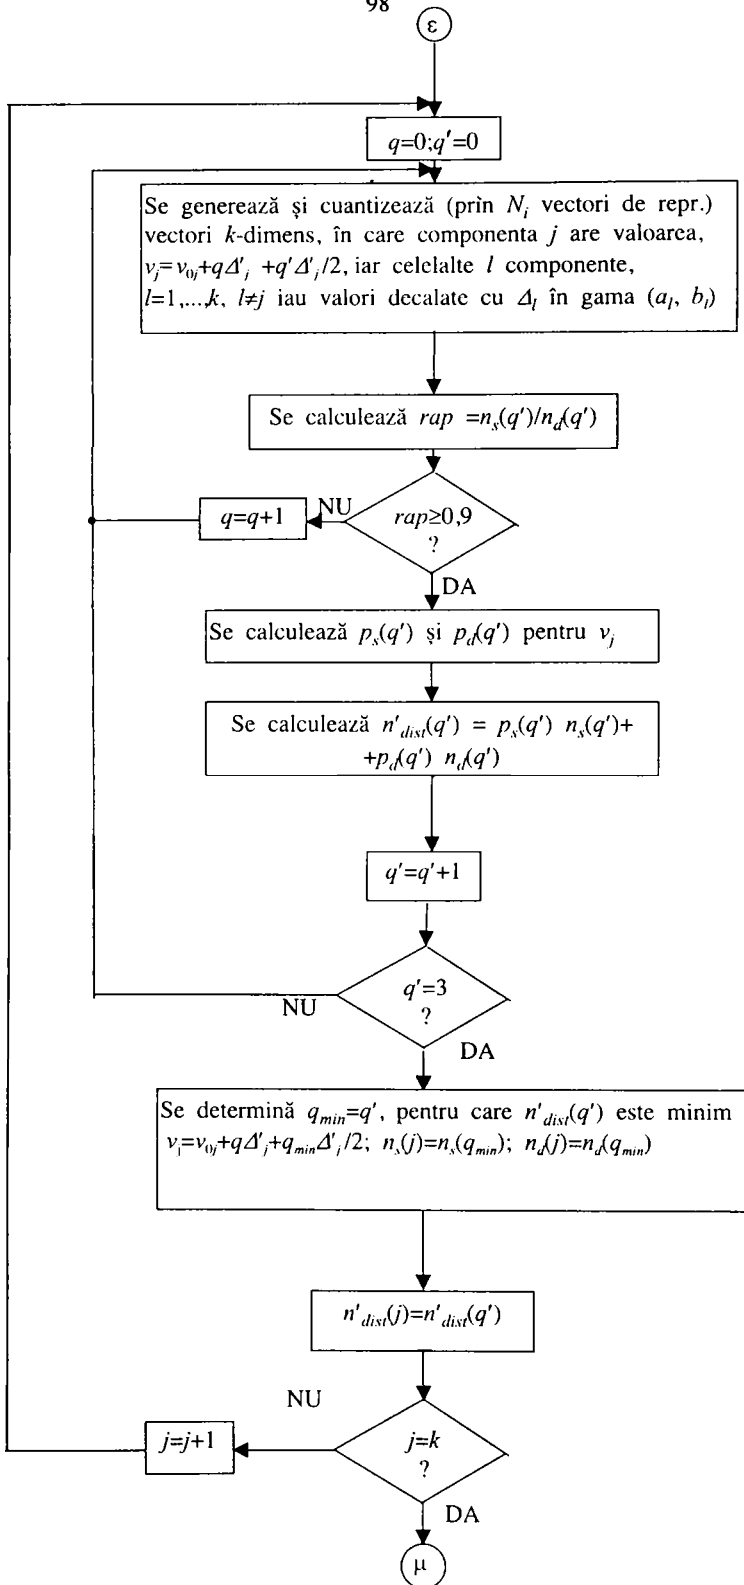


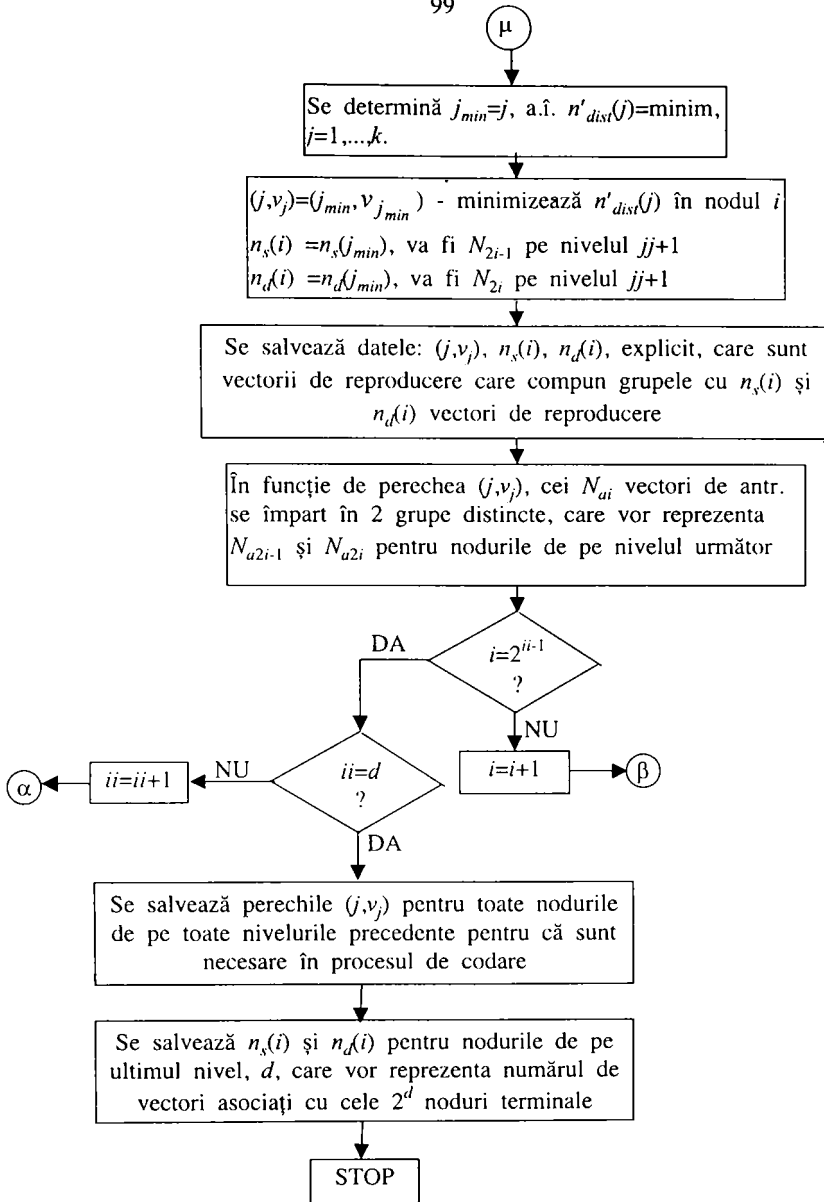
**Figura 4.11:** Structura arborelui folosit la structurare și codare.

Din figura 4.11 se vede că arborele după care se face atât structurarea cât și codarea conține  $d$  niveluri, nivelul curent fiind notat cu  $ii$ ,  $ii=1, \dots, d$ . Pe fiecare nivel există  $2^{ii-1}$  noduri interne, nodul curent fiind notat  $i$ ,  $i=1, \dots, 2^{ii-1}$ . Arborele mai conține  $2(2^{d-1})=2^d=m$  noduri terminale. Fiecărui nod intern îi sunt asociați  $N_i$  vectori de reproducere și  $N_{ai}$  vectori de antrenament (nodului 1 de pe nivelul 1 îi sunt asociați  $N_1=N$  vectori de reproducere, adică toți vectorii de reproducere din cartea de cod, și  $N_{a1}=n$  vectori de antrenament, adică toți vectorii din secvența de antrenament). În general dintr-un nod  $i$ , situat pe nivelul  $ii$ , se ajunge în nodurile  $2i-1$  și  $2i$  de pe nivelul următor,  $ii+1$ . Vectorii de antrenament  $k$  dimensional sunt de forma  $(f_1, f_2, \dots, f_k)$ ,  $k=3$  sau  $k=4$ .

În figura 4.12 se prezintă organigrama programului (vezi Anexa 2) care implementează algoritmul de structurare a cărții de cod. Arborele are  $d=6$  niveluri, adică o valoare care permite așa cum se va arăta, o reducere suficientă a complexității, nodurile terminale având asociate valori suficient de mici pentru parametrii  $n_i$ , numărul vectorilor de reproducere asociați.







**Figura 4.12:** Organigrama programului de structurare a cărții de cod.

Programul care implementează acest algoritm, scris în limbajul C, a fost rulat separat pentru cele trei cărți de cod.

După determinarea perechii  $(j, v_j)$  în toate nodurile de pe un nivel, algoritmul se poate încheia, dacă s-au parcurs toate nivelurile dorite. De

aceea în momentul respectiv, trebuie să fie disponibile toate datele necesare care trebuie folosite în procesul de codare, în vederea memorării. Acestea sunt:

- perechile  $(j, v_j)$  pentru toate nodurile interne, memorate în tabloul  $\text{comp}[ii][i]$  pentru componenta  $j$ , respectiv, în tabloul  $\text{val}[ii][i]$  pentru valoarea  $v_j$ .

- numărul de vectori de reproducere  $n_l$ , asociat cu fiecare din cele  $m$  noduri terminale, care provin din parametri  $n_s(i)$  și  $n_d(i)$  ale celor  $m/2$  noduri de pe nivelul  $d$ , precum și indicii (între 1 și  $N$ ) acestor vectori.

Pe parcursul rulării programului nu sunt păstrați decât parametrii  $n_s(i)$  și  $n_d(i)$  și indicii care corespund nivelului precedent, cei de pe celelalte niveluri nemaifiind necesari. În acest fel se face o economie de memorie.

Pentru o mai clară imagine asupra rezultatelor procesului de structurare, în tabelul 4.4 se arată valorile parametrilor  $n_s$ ,  $n_d$  precum și numărul de regiuni care intersectează un plan oarecare  $f_i = \text{constant}$ ,  $i=1,2,3$ , notat  $n_{com}$ , care se obțin în nodul rădăcină ( $N_i=256$ ).

**Tabelul 4.4:** Parametrii  $n_s$ ,  $n_d$ ,  $n_{com}$  obținuți în nodul rădăcină.

Parametrul LSF	$f_1=265$	$f_2=520$	$f_3=845$
$n_s$	171	138	148
$n_d$	186	152	163
$n_{com}$	56	36	102

Din tabelul 4.4 rezultă prin diferență față de 256 și numărul regiunilor de cuantizare care nu intersectează un anumit plan, adică 200, 220 și, respectiv 154. În funcție de aceste date și de alte date obținute în cursul rulării programelor dar neprezentate aici, s-a ales o valoare aproximativă de  $0,7N$  ( $N=256$ ) pentru numărul regiunilor de cuantizare care nu intersectează un anumit plan, această valoare fiind necesară la determinarea numărului de operații care se fac la metoda intersecțiilor.

Așa cum s-a mai spus, pasul  $\Delta_l$  are valoarea 4 Hz pentru  $f_1$  și, respectiv, 10 Hz pentru celelalte componente. Pasul  $\Delta_l$ ,  $l=1, \dots, k$  are diverse

valori în intervalul  $(0,3 \dots 0,5) d_{mediu}$ . După efectuarea codării se vor discuta rezultatele obținute în funcție de diversele valori ale pasului  $\Delta_i$ .

În continuare, în tabelul 4.5 se arată pentru exemplificare, valorile celor 3 componente ale vectorilor  $(f_1, f_2, f_3)$  distribuți uniform, în situația când  $f_3$  are o valoare fixă, de exemplu  $f_3=500$  Hz. Prin cuantizarea acestor vectori s-au determinat regiunile de cuantizare care intersectează planul  $f_3=\text{constant}$ , (egal cu 500 Hz).

**Tabelul 4.5:** Valori ale vectorilor uniform distribuți.

141	223	500
141	243	500
141	483	500
161	223	500
161	483	500
241	243	500
241	263	500
241	483	500
461	483	500
481	483	500

Componentele  $f_1$  și  $f_2$  au valorile inițiale 141 și respectiv 223 (aceste valori corespund limitelor inferioare ale lui  $f_1$  și  $f_2$ , tabelul 4.1). La început  $f_1$  rămâne la valoarea de 141, iar  $f_2$  crește cu pasul  $\Delta_2=20$ , până la o valoare apropiată de  $f_3$ , dar mai mică (483 față de 500). În continuare,  $f_1$  crește cu

pasul  $\Delta_1=20$  la valoarea de 161, în timp ce  $f_2$  crește în același fel. Când  $f_1$  depășește valoarea inițială a lui  $f_2$  (adică 223), a patra linie în tabelul 4.5,  $f_2$  va avea o valoare inițială mai mare, astfel încât să fie îndeplinită condiția  $f_1 < f_2$ . În continuare, odată cu creșterea lui  $f_1$ ,  $f_2$  va avea o gamă dinamică din ce în ce mai mică.

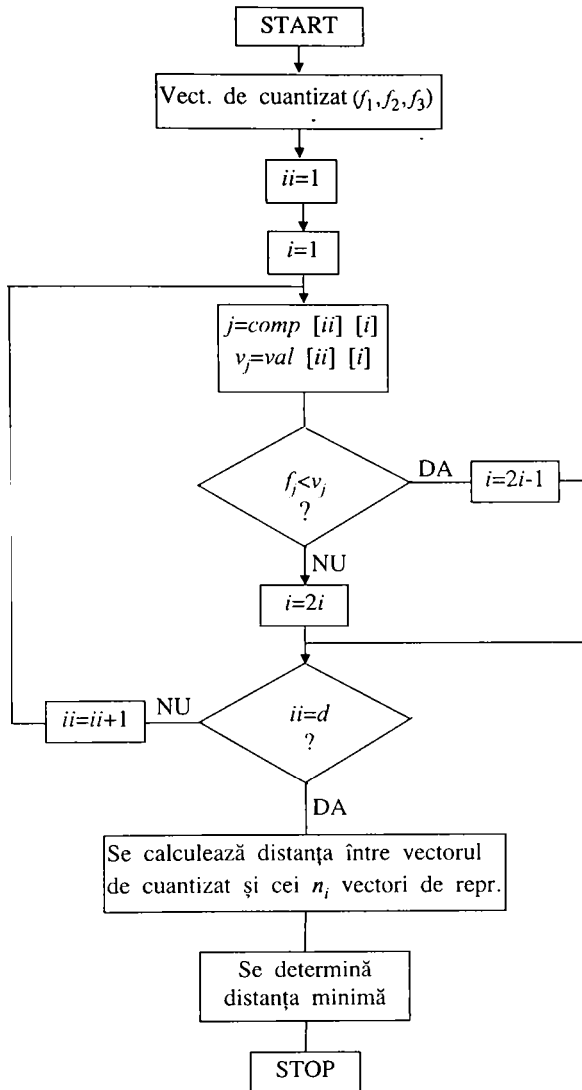
În acest fel se generează și ceilalți vectori de tipul  $(f_1, f_2, f_3)$ , precum și vectorii  $(f_4, f_5, f_6)$  și, respectiv,  $(f_7, f_8, f_9, f_{10})$ . Condiția  $f_{i-1} < f_i < f_{i+1}$ ,  $i=2, 5$ , și, respectiv,  $i=8,9$  trebuie îndeplinită la generarea tuturor vectorilor uniform distribuiți.

#### 4.4 Algoritmul de codare al cuantizării vectoriale prin metoda combinată arbore-căutare totală

Pe baza rezultatelor obținute în procesul de structurare pentru cele 3 cărți de cod s-a efectuat algoritmul de codare prin metoda combinată arbore-căutare totală, pentru o secvență de 310 vectori de test.

În figura 4.13 se prezintă organigrama programului care implementează acest algoritm, scris în limbajul C. Organigrama programului este descrisă pentru subvectorii cu componentele  $f_1, f_2, f_3$ , ea fiind similară și pentru ceilalți subvectori.

În fiecare nod al arborelui,  $i$ , de pe un nivel  $ii$ , se citesc mai întâi elementele perechii  $(j, v_j)$ , iar apoi se face testul. În funcție de rezultatul testului, se află valoarea nodului  $i$  de pe nivelul următor. Nodul  $i$  obținut în urma testului de pe ultimul nivel  $d$ , va reprezenta nodul terminal. Apoi se va face o căutare totală printre cei  $n_i$  vectori de reproducere asociați nodului terminal  $i$ . Distanța minimă obținută (considerată ca distanță euclidiană) reprezintă de fapt eroarea de cuantizare, indicele vectorului de reproducere față de care s-a obținut distanța minimă reprezintă codul vectorului de cuantizat, iar vectorul de reproducere reprezintă versiunea cuantizată a vectorului de cuantizat.



**Figura 4.13:** Organigrama programului de codare prin metoda combinată arbore-căutare totală.

În tabelul 4.6 se prezintă eroarea medie de cuantizare, notată  $E_{u-ct}$ , pentru diferite valori ale pasului  $\Delta_i$ ,  $i=1, \dots, k$ , folosite în partea de structurare a cărții de cod, pentru fiecare din cele 3 tipuri de subvectori, comparativ cu eroarea medie notată  $E_{ct}$ , obținută la cuantizarea acelorași vectori prin



căutare totală. În toate cele 3 cazuri,  $\Delta_i = \Delta$ ,  $i=1,2,3$ , apoi  $i=4,5,6$  și, respectiv,  $i=7,8,9,10$ .

**Tabelul 4.6:** Erori medii obținute în funcție de valori ale pasului  $\Delta$ .

Subvectorii	$f_1, f_2, f_3$	$f_4, f_5, f_6$	$f_7, f_8, f_9, f_{10}$
$E_{ct}$ [Hz <sup>2</sup> ]	705,56	2211,51	2823,75
$E_{a-ct}$ [Hz <sup>2</sup> ]	705,56 pt. $\Delta=20$ Hz	2211,51 pt. $\Delta=35$ Hz	2823,75 pt. $\Delta=30$ Hz
$E_{a-ct}$ [Hz <sup>2</sup> ]	706,91 pt. $\Delta=25$ Hz	2212,05 pt. $\Delta=40$ Hz	2235,39 pt. $\Delta=35$ Hz

Din tabel se observă că pentru fiecare tip de subvector, o anumită valoare a pasului  $\Delta$  permite obținerea aceleiași erori medii ca și la căutarea totală. Creșterea valorii pasului  $\Delta$  peste valoarea respectivă provoacă creșterea erorii medii de cuantizare. Astfel, în cazul subvectorilor  $f_1, f_2, f_3$ , la 2 vectori din cei 310 s-a produs creșterea erorii de cuantizare, de la valoarea 1533 Hz<sup>2</sup> la 1634 Hz<sup>2</sup> (pentru primul) și respectiv de la 1509 Hz<sup>2</sup> la 1890 Hz<sup>2</sup> (pentru al doilea). În cazul subvectorilor  $f_4, f_5, f_6$ , la un vector a crescut eroarea de la 13556 Hz<sup>2</sup> la 13702 Hz<sup>2</sup>, iar în cazul subvectorilor  $f_7, f_8, f_9, f_{10}$  eroarea a crescut de la 1846 Hz<sup>2</sup> la 3461 Hz<sup>2</sup> pentru un vector și, respectiv de la 7246 Hz<sup>2</sup> la 8294 Hz<sup>2</sup> pentru un alt vector.

Valorile pașilor  $\Delta$  din tabelul 4.6 pentru care erorile obținute prin cele 2 metode sunt egale reprezintă niște valori de prag maxime care permit acest lucru. Desigur că pentru alți vectori de test este posibil să existe vectori de tipul  $x$  din figura 4.10, care produc creșterea erorii medii. Oricum, datorită valorilor mici ale pașilor  $\Delta$ , acești vectori au probabilități minime de apariție.

Un alt experiment care confirmă în mare măsură valoarea propusă pentru pasul  $\Delta$  constă în determinarea regiunilor de cuantizare care intersectează un plan în spațiul  $k=3$  sau  $k=4$ , (adică vectorii care au  $f_i = \text{constant}$ ), prin modificarea valorilor  $f_j$ ,  $j \neq i$ , cu valori ale pasului  $\Delta$ , din ce în ce mai mici.

**Tabelul 4.7:** Valori ale numărului de regiuni care intersectează un anumit plan.

pas \ $f_3$	792	842	847	852
20	47	55	57	54
15	47	55	57	54
10	48	55	56	57
5	49	56	57	58
1	50	57	57	59

Astfel, în tabelul 4.7, se prezintă numărul regiunilor de cuantizare care intersectează planul specificat prin  $f_3 = \text{constant}$  (s-au ales pentru  $f_3$  valorile 792, 842, 847 și 852 Hz). Pentru determinarea acestor regiuni, componentele  $f_1$  și  $f_2$  au luat valori în toată gama admisibilă, distanțate între ele mai întâi prin valoarea  $\Delta = 20$  Hz, adică acea valoare a pasului care, conform tabelului 4.6 permite obținerea unei erori identice cu cea obținută în cazul în care codarea s-a făcut prin căutare totală. Apoi, acest pas a fost redus treptat, până la valoarea minimă de 1 Hz. Se observă că, față de valoarea de 20 Hz, numărul regiunilor care intersectează planul crește odată cu micșorarea pasului, ceea ce înseamnă că, mai există, pentru fiecare valoare  $f_3$ , de la 2 până la 5 regiuni de cuantizare care nu sunt determinate ca făcând parte din cele care sunt comune celor două grupe. Acest lucru ar putea avea ca efect creșterea erorii medii de cuantizare, dacă în zonele respective sunt vectori de cuantizat. Având în vedere numărul relativ mic al acestor regiuni, creșterea posibilă a erorii medii de cuantizare este relativ mică.

**Cea mai importantă consecință a aplicării cuantizării vectoriale prin metoda arbore-căutare totală este reducerea complexității de calcul în procesul de codare.** Pentru o evaluare simplă și rapidă a complexității trebuie cunoscute valorile numărului de vectori de reproducere,  $n_i$ , asociate cu nodurile terminale. Valoarea medie a numărului de vectori, pentru fiecare din cele trei tipuri de subvectori (în fiecare caz, pentru cele 64 noduri terminale) reprezintă cu bună aproximare numărul de distanțe care se calculează în procesul de codare. Pentru o determinare mai exactă ar trebui aplicată relația (4.1) în funcție de probabilitățile vectorilor de test de a intra în unul din nodurile terminale.

Astfel, s-au obținut următoarele valori pentru numărul mediu de vectori asociați nodurilor terminale: pentru subvectorii  $(f_1, f_2, f_3)$ ,  $n_{m1,3}=15,60$ ; pentru subvectorii  $(f_4, f_5, f_6)$ ,  $n_{m4,6}=16,32$ ; iar pentru  $(f_7, f_8, f_9, f_{10})$ ,  $n_{m7,10}=25,9$ . Se observă că, odată cu creșterea dimensiunii vectorilor, valoarea medie a numărului de vectori asociați cu nodurile terminale crește, sau numărul regiunilor de cuantizare care intersectează un plan crește odată cu dimensiunea spațiului. În acest fel, pentru codarea unui vector complexitatea are expresia

$$C = 3n_{m1,3} + 3n_{m4,6} + 4n_{m7,10} \quad (4.15)$$

adică

$$C = 15,60 \times 3 + 16,32 \times 3 + 25,9 \times 4 \cong 200 \text{ înmulțiri}$$

Dacă pentru subvectorii  $(f_7, f_8, f_9, f_{10})$  s-a făcut o structurare și respectiv o codare pe 7 niveluri, numărul mediu de vectori asociați celor 128 noduri terminale a scăzut la valoarea de 17,57, ceea ce a avut ca efect scăderea numărului de înmulțiri la valoarea de 166.

Memoria necesară pentru un cuantizor vectorial de tipul arbore-căutare totală conține spațiul necesar pentru memorarea vectorilor de reproducere ale celor 3 cărți de cod, precum și un spațiu pentru memorarea informației obținute în urma procesului de structurare: în primul rând indicii vectorilor de reproducere asociați cu fiecare din cele  $2^d$  noduri terminale (precum și numărul de vectori  $n_i$  pentru fiecare din aceste noduri), iar apoi perechile pentru testare  $(j, v_j)$  din fiecare din cele  $2^d - 1$  noduri interne. Astfel, memoria totală este

$$Mem = kN2 + 2^d(n_{m1,3} + n_{m4,6} + n_{m7,10}) + 3 \cdot 2^d \cdot 1 + 3 \cdot (2^d - 1)(2 + 1) \quad (4.16)$$

adică

$$Mem = 10 \times 256 \times 2 + 2^6(15,60 + 16,32 + 25,9) + 3 \times 2^6 + 3 \times (2^6 - 1) \times 3 \cong 9580 \text{ octeti}$$

S-a considerat că fiecare componentă a vectorilor de reproducere se memorează pe 2 octeți, la fel ca și valoarea  $v_j$ , restul mărimilor necesitând câte un octet.

În cazul în care pentru subvectorii  $(f_7, f_8, f_9, f_{10})$  s-a făcut o structurare pe 7 nivele memoria devine

$$Mem = k \cdot N \cdot 2 + 2^d (n_{m1,3} + n_{m4,6}) + 2^{d+1} n_{m7,10} + 2 \cdot 2^d \cdot 1 + 2^{d+1} + 2(2^d - 1) \cdot (2 + 1) + (2^{d+1} - 1)(2 + 1) \quad (4.17)$$

adică,

$$M = 10 \times 256 \times 2 + 2^6(15,6 + 16,3) + 2^7 \times 17,5 + 2 \times 2^6 + 2^7 + 2(2^6 - 1) \times 3 + 3 \times (2^7 - 1) \times 3 = 10400$$

octeți, deci, în acest fel, memoria a înregistrat o ușoară creștere.

O comparație a acestor rezultate cu cele obținute prin alte metode din literatură se va face după prezentarea structurării și codării folosind eroarea pătratică ponderată.

#### 4.5 Realizarea structurării cărții de cod și a codării pentru cazul erorii pătratice ponderate

Structurarea celor 3 cărți de cod în vederea aplicării cuantizării vectoriale prin metoda combinată arbore căutare-totală s-a efectuat pentru situația în care măsura erorii de cuantizare a fost eroarea pătratică. Dar așa cum s-a arătat în paragraful 2.2, pentru scăderea erorii spectrale  $SD$ , pentru o anumită rată a cuantizării, se folosește eroarea pătratică ponderată, autorul propunând două variante de ponderi  $w_r$ . De aceea, structurarea trebuie să fie aplicabilă și în cazul erorii pătratice ponderate. Acest lucru însă ridică anumite probleme suplimentare.

Cartea de cod pentru eroarea pătratică ponderată s-a obținut, așa cum s-a arătat, plecând de la o carte de cod obținută prin algoritmul PNN, cu dimensiunea  $N=256$ , căreia i s-a aplicat algoritmul Lloyd, în care secvența de antrenament a fost cuantizată pe baza erorii pătratice ponderată. De exemplu, pentru cartea de cod corespunzătoare componentelor  $f_1, f_2, f_3$ , folosind eroarea pătratică ponderată dată prin (3.12), au fost necesare și componentele  $f_4$  ale vectorilor de antrenament respectivi. Adică, structura

finală a acestei cărți de cod pentru  $f_1, f_2, f_3$  depinde și de componentele  $f_4$  ale vectorilor de antrenament.

Considerând că cei  $N$  vectori de reproducere sunt dați (pentru  $k=3$ ), deci structura regiunilor de cuantizare este fixă, depinzând de vectorii de reproducere, se poate ajunge la un paradox: un vector oarecare, care are anumite valori pentru  $f_1, f_2$  și  $f_3$  poate să aparțină unei regiuni de cuantizare pentru o valoare a lui  $f_4$ , iar dacă  $f_4$  are o altă valoare, poate aparține altei regiuni de cuantizare, deoarece  $f_4$  intervine în ponderea  $w_3$ . Adică, dacă s-ar prezenta într-un desen vectorii de reproducere corespunzători pentru  $k=3$  împreună cu regiunile lor de cuantizare, orice punct (vector) din spațiul  $k=3$  poate aparține la două sau chiar mai multe regiuni de cuantizare. Explicația acestui paradox este că, vectorilor de reproducere cu  $k=3$  trebuie să li se asocieze, pentru determinarea formei regiunilor de cuantizare, vectorii de antrenament cu  $k=4$ , pentru că și a 4-a componentă contribuie la găsirea vectorului de reproducere asociat unui anumit vector cu  $k=3$ . Indicele vectorului de reproducere găsit codează însă numai primele 3 componente ale vectorului respectiv, a 4-a componentă făcând parte din următorul subvector care conține componentele  $f_4, f_5, f_6$ .

Desigur că aspectele amintite nu au importanță la un cuantizor vectorial prin despicare în care codarea se face prin căutare totală în interiorul fiecăreia din cele 3 cărți de cod. În cazul în care codarea se face prin metoda combinată arbore-căutare totală, în procesul de structurare a cărții de cod se pune problema determinării regiunilor de cuantizare de care aparțin vectorii uniform distribuiți caracterizați prin  $f_i = \text{constant}$ . Pentru  $k=3$ , acest lucru înseamnă determinarea regiunilor de cuantizare care intersectează planul caracterizat prin  $f_i = \text{constant}$  ( $i$  poate lua una dintre valorile 1, 2 sau 3). În cazul folosirii erorii pătratice fără pondere, acest lucru se făcea simplu prin cuantizarea vectorilor uniform distribuiți respectivi. În cazul erorii pătratice ponderate, de exemplu cea în care ponderea este dată prin (3.12), la cuantizarea vectorilor uniform distribuiți intervine ponderea  $w_3$  care depinde și de  $f_4$ . Aceasta înseamnă că acestor vectori trebuie să li se precizeze și componenta  $f_4$ . Teoretic,  $f_4$  ar trebui să ia valori cât mai multe în intervalul în care această componentă poate lua valori conform secvenței de antrenament, tabelul 4.1. Aceasta ar conduce practic la generarea unor

vectori uniform distribuiți cu dimensiunea 4 ceea ce ar mări foarte mult durata de execuție a programului care implementează structurarea cărții de cod. În plus, pentru subvectorul cu componentele  $f_4, f_5$  și  $f_6$  trebuie generați vectori uniformi care conțin și componentele  $f_3$  și  $f_7$  care intervin în ponderile  $w_4$  și  $w_6$ . În mod similar, pentru subvectorul cu componentele  $f_7, f_8, f_9$  și  $f_{10}$  trebuie generată și componenta  $f_6$ .

Practic însă, s-a constatat că nu este nevoie să se genereze pentru  $f_4$  valori în toată gama admisibilă. Pentru a justifica această afirmație, s-a făcut experimentul descris în continuare. S-a generat mai întâi vectorul având parametrii:  $f_1=141$  Hz,  $f_2=223$  Hz,  $f_3=792$  Hz (primul vector din tabelul 4.5), iar pentru  $f_4$  s-au considerat valorile:  $f_4=f_3+100xi$ [Hz],  $i=1, 2, \dots, 9$ , acoperindu-se toată gama în care poate lua valori  $f_4$ . Acest vector a fost cuantizat, pentru fiecare din cele 9 valori ale lui  $f_4$ . Procesul s-a repetat cu  $f_2$  având succesiv valorile 243 Hz, 263 Hz, ..., 543 Hz (decalate cu câte 20 Hz), în scopul determinării regiunilor de cuantizare care intersectează planul  $f_3=792$  Hz. În urma cuantizării s-au constatat următoarele:

- pentru diferitele valori ale lui  $f_4$  (când  $f_2=\text{constant}$ ) s-au obținut cel mult 3 coduri ( în cele mai multe cazuri 1 cod sau 2) distincte.
- începând de la valoarea a 4-a a lui  $f_4$ , codul obținut nu s-a mai modificat, obținându-se același cod până la 9-a valoare.
- în cazul în care pentru vectorul cu componentele  $f_1, f_2, f_3$  fixate s-au obținut mai multe coduri (maximum 3) pentru diferitele valori ale lui  $f_4$ , aceste coduri s-au regăsit printre codurile obținute când  $f_2$  a avut valori cu 20 Hz mai mici sau mai mari.

Acest experiment a fost reluat și pentru alte valori ale lui  $f_1, f_2, f_3$ , obținându-se rezultate asemănătoare. Considerând distanța dintre un vector  $f=(f_1, f_2, f_3)$  și vectorul de reproducere  $y_i=(y_{i1}, y_{i2}, y_{i3})$ ,

$$d(f, y_i) = w_1(f_1 - y_{i1})^2 + w_2(f_2 - y_{i2})^2 + w_3(f_3 - y_{i3})^2, \quad (4.18)$$

unde

$$w_3 = \frac{1,32 \cdot 10^5}{(f_3 - f_2)(f_4 - f_3)},$$

rezultatele experimentale obținute se explică prin faptul că odată cu creșterea lui  $f_4$  ponderea  $w_3$  are valori tot mai mici, nemaicontând în raport cu

ponderile  $w_1$  și  $w_2$  care vor fi esențiale în stabilirea vectorului  $y_i$  pentru care distanța  $d(f, y_i)$  este minimă, iar  $w_3$  este singurul termen în care intervine  $f_4$ .

S-a demonstrat că aceste concluzii sunt valabile și pentru subvectorii  $(f_4, f_5, f_6)$  respectiv  $(f_7, f_8, f_9, f_{10})$ .

Pe baza acestor rezultate, autorul a procedat în felul următor pentru realizarea structurării:

- pentru cartea de cod cu componentele  $f_1, f_2, f_3$ , pentru fiecare vector uniform s-au considerat 3 valori pentru  $f_4$ , adică  $f_4 = f_3 + 100xi$  [Hz],  $i=1,2,3$ .

- pentru cartea de cod cu componentele  $f_4, f_5, f_6$  pentru fiecare vector uniform s-au considerat 3 valori pentru  $f_3$ ,  $f_3 = f_4 - 100xi$  [Hz],  $i=1,2,3$  și 3 valori pentru  $f_7, f_7 = f_6 + 150xi$  [Hz],  $i=1,2,3$ .

- pentru cartea de cod cu componentele  $f_7, f_8, f_9, f_{10}$  pentru fiecare vector uniform s-au considerat 3 valori pentru  $f_6, f_6 = f_7 - 150xi$  [Hz],  $i=1,2,3$ .

Pasul de 150 Hz pentru  $f_6$  și  $f_7$  se justifică prin faptul că aceste componente au o gamă dinamică mai mare.

După efectuarea procesului de structurare, s-a efectuat cuantizarea folosind metoda combinată arbore căutare-totală, pentru aceeași secvență de 310 vectori de test. S-a obținut pentru fiecare din cei 3 subvectori aceeași eroare medie (sub formă pătratică ponderată) ca și în cazul utilizării cuantizării prin căutare totală.

Deosebirea care apare în urma structurării cărților de cod în această situație, când măsura erorii de cuantizare este eroarea pătratică ponderată este creșterea numărului de vectori de reproducere asociați nodurilor terminale. Astfel, așa cum s-a arătat anterior, la cuantizarea unui vector  $(f_1, f_2, f_3)$ , intervine și componenta  $f_4$  care ia 3 valori distincte, putându-se obține 2 sau 3 coduri diferite. În acest fel crește numărul regiunilor de cuantizare care intersectează planul  $f_3 = \text{constant}$ , adică crește numărul vectorilor de reproducere comuni celor două grupe care rezultă după efectuarea testului în oricare din nodurile arborelui. Afirmația anterioară este valabilă și pentru ceilalți doi subvectori.

Astfel, la structurarea cărții de cod corespunzătoare componentelor  $(f_1, f_2, f_3)$  s-a obținut un număr mediu de vectori pe nod terminal  $n_{m1,3} = 17,43$ , pentru cea cu componentele  $(f_4, f_5, f_6)$ ,  $n_{m4,6} = 19,5$ , iar pentru cea cu componentele  $(f_7, f_8, f_9, f_{10})$ ,  $n_{m7,10} = 28,5$ .

În această situație, ținând cont că datorită ponderii se mai face o înmulțire pe lângă cea necesară pentru ridicarea la pătrat a diferenței între componenta vectorului de cuantizat și cea a vectorului de reproducere, complexitatea este

$$C = 2(3 \cdot 17,43 + 3 \cdot 19,5 + 4 \cdot 28,5) = 450 \text{ înmulțiri}$$

Memoria folosită în acest caz este

$$Mem = 10 \cdot 256 \cdot 2 + 2^6(17,43 + 19,5 + 28,5) + 3 \cdot 2^6 + 3 \cdot (2^6 - 1) \cdot 3 = 10066 \text{ octeți}$$

În tabelul 4.8 se reprezintă complexitatea, memoria și eroarea spectrală pentru cazul unui cuantizor prin despicare în care codarea s-a făcut prin căutare totală, (VQ desp. c.t.) așa cum au fost prezentate în paragraful 2.2 și, respectiv, pentru un cuantizor prin despicare în care codarea s-a realizat prin metoda combinată arbore căutare-totală, (VQ desp. a.-c.t.). În ambele cazuri, despicarea a fost de tipul (3,3,4), cu o rată de 24 biți/vector, și se reprezintă rezultatele pentru distanța de tip eroare pătratică (e.p.), respectiv eroare pătratică ponderată (e.p.p.), în care ponderea este dată de relația (3.12), propusă de autor.

**Tabelul 4.8:** Valori ale caracteristicilor unui cuantizor vectorial în funcție de metoda de codare și eroarea folosită.

VQ desp. c.t	Complexitate	Memorie	Er. Spectrală
e.p.	2560	5120	0,933 dB
e.p.p.	5120	5120	0,888 dB
VQ desp. a.-c.t.	Complexitate	Memorie	Er. Spectrală
e.p.	200	9580	0,933 dB
e.p.p.	450	10066	0,888 dB

Din tabelul 4.8 se observă că, atât în cazul folosirii erorii pătratice, cât și pentru eroarea pătratică ponderată, realizarea codării prin metoda combinată arbore-căutare totală produce scăderea complexității de aproximativ 11-12 ori, în timp ce memoria necesară crește de doar aproape 2 ori, în raport cu căutarea totală. Și de asemenea, ceea ce este esențial, folosirea acestei metode de codare nu produce creșterea erorii spectrale, indiferent de tipul măsurii erorii folosite. **Rezultă că avantajul acestei metode propuse**



**de autor este reducerea drastică a complexității de calcul, fără creșterea erorii spectrale, cu prețul unei ușoare creșteri a memoriei utilizate.**

În capitolul 4, autorul a introdus și implementat codarea prin metoda combinată arbore-căutare totală ca alternativă la codarea prin căutare totală, în cadrul cuantizării vectoriale prin despicare prezentate în capitolul 3. În urma aplicării acestei metode se obține o complexitate deosebit de scăzută, fără afectarea erorii de cuantizare în comparație cu căutarea totală.

## 5. CONCLUZII ȘI CONTRIBUȚII ORIGINALE

Teza abordează domeniul cuantizării vectoriale și cuprinde contribuțiile autorului referitoare la metode și algoritmi, cu aplicații la cuantizarea vectorială a semnalului vocal reprezentat prin linii spectrale de frecvență (parametri LSF).

În capitolul 1 autorul prezintă sub o formă sistematizată principalele noțiuni și principii utilizate la cuantizarea vectorială, precum și unele contribuții originale.

**1.1** Autorul demonstrează că în cazul în care măsura erorii de cuantizare este eroarea pătratică ponderată, regiunile de cuantizare nu mai sunt mărginite de drepte sau plane, ci de curbe sau suprafețe mai complicate, astfel încât cuantizorul vectorial nu mai este regulat și politop. Acest fapt nu afectează însă aplicabilitatea metodelor de cuantizare vectorială folosite de autor.

**1.2** Proprietatea cunoscută de compresie a cuantizării vectoriale, este demonstrată de autor pe baza a două exemple simple, pentru vectori având dimensiunile 2 și, respectiv, 3. Această compresie este rezultatul corelației între componentele vectorilor. De asemenea, se demonstrează că se produce o scădere a erorii de cuantizare la aceeași rată a cuantizării, față de cuantizarea scalară, în cazul în care între componentele vectorilor există o corelație suplimentară în sensul că ele sunt în ordine crescătoare.

În capitolul 2 se prezintă reprezentarea unui semnal vocal prin parametri LSF, arătându-se unele contribuții ale autorului în acest sens. De asemenea, sunt prezentate și principalele metode de cuantizare vectorială ale acestor parametri.

**2.1** Autorul deduce o relație care exprimă densitatea spectrală de putere în funcție de parametrii LSF. Apoi, se demonstrează, teoretic și experimental, că densitatea spectrală de putere pentru o frecvență corespunzătoare unei linii spectrale, depinde în special de parametrii LSF

învecinați. Pe această bază se deduc două relații de calcul aproximativ și simplificat al densității spectrale de putere. Cele două relații, verificate experimental, vor fi folosite pentru calculul ponderilor în cadrul erorii pătratice ponderate.

**2.2.** Pentru o cuantizare "transparentă" a parametrilor LSF, în literatură se arată că este necesară o rată de circa 25 biți/vector. Acest lucru implică un mare număr de vectori de reproducere, adică o zonă de memorie mare pentru memorarea lor, precum și un mare număr de operații pentru cuantizarea unui vector. De aceea, în practică sunt utilizate metode suboptimale care permit o reducere semnificativă a memoriei și a complexității, cu prețul unei ușoare creșteri a erorii de cuantizare. În urma cercetării bibliografiei s-a constatat că principalele metode folosite în acest sens sunt cuantizarea vectorială prin despicare și cuantizarea vectorială în mai multe stadii. Aproape toate celelalte metode folosesc ca bază una din cele două metode, iar prin diverse soluții se încearcă reducerea erorii de cuantizare (sub formă de eroare spectrală), a complexității sau a memoriei pentru o anumită rată a cuantizării.

Capitolul 3 este dedicat proiectării printr-o metodă nouă a cărții de cod pentru realizarea unui cuantizor vectorial prin despicare și testării cărții de cod obținute pentru diferite forme ale erorii pătratice ponderate.

**3.1** Față de soluția clasică a proiectării cărții de cod folosind algoritmul generalizat Lloyd pentru cărți de cod având succesiv mărimile 2, 4, 8, ...,  $N$ , autorul folosește pentru vectori cu parametri LSF algoritmul PNN (pairwise nearest neighbor - împerecherea inteligentă a celor mai apropiați vectori), utilizat în literatură numai la cuantizarea imaginilor.

**3.2** În scopul reducerii numărului de operații necesare în algoritmul PNN, autorul utilizează o metodă originală de împărțire a secvenței de antrenament în buchete, urmată de grupări între mănunchiuri, iar în final se face o alăturare a unora dintre buchete, astfel încât să se obțină numărul dorit,  $N$ , de mănunchiuri. În acest fel, autorul introduce o variantă modificată a algoritmului PNN și o aplică pentru vectori cu parametri LSF.

Pentru verificarea experimentală a metodei propuse pentru proiectarea cărții de cod s-a folosit o secvență de antrenament de 2790 vectori LSF.

S-au obținut 3 cărți de cod cu dimensiunile vectorilor 3, 3 și, respectiv 4, conform despicării realizate. Fiecare carte de cod, are  $N=256$  vectori, realizându-se o rată de 24 biți/vector.

**3.3** Comparativ cu cartea de cod proiectată folosind algoritmul Lloyd pentru cărți de cod având succesiv mărimile 2, 4, 8, ..., 256, proiectarea unei cărți prin algoritmul PNN modificat necesită mult mai puține operații (aproximativ 25%). Cuantizând atât secvența de antrenament cât și o secvență de test de 310 vectori, diferită de cea de antrenament și folosind cartea de cod PNN s-au obținut erori cu 5% până la 10% mai mici față de cele obținute prin cartea de cod proiectată prin algoritmul Lloyd. Rezultă că prin aplicarea algoritmului PNN modificat se obține atât reducerea volumului de calcul cât și scăderea erorii de cuantizare.

**3.4** Aplicarea algoritmului Lloyd celor 3 cărți obținute prin algoritmul PNN modificat conduce la o convergență mai rapidă (6 iterații Lloyd față de 12) decât în cazul aplicării pentru cărțile de cod cu mărimile 2, 4, 8, ..., 256. La cuantizarea secvenței de antrenament eroarea a scăzut cu 5% până la 10%, în timp ce la cuantizarea secvenței de test a rămas aproximativ în aceleași limite. Toate aceste rezultate experimentale dovedesc calitatea algoritmului PNN modificat.

**3.5** Deoarece programele care implementează proiectarea celor 3 cărți de cod PNN utilizează un volum mare de date, autorul a folosit o alocare dinamică a memoriei, în scopul reducerii capacității de memorie utilizate. Astfel, s-a folosit o memorie de circa 45 kocteți față de 400 kocteți cât s-ar fi folosit fără alocarea dinamică.

**3.6** Autorul verifică experimental prin câteva exemple de vectori că folosirea erorii pătratice ponderate produce cuantizarea mai precisă, comparativ cu eroarea pătratică, a componentelor cu pondere mare ale vectorilor LSF. De asemenea, printr-un alt experiment, se arată că eroarea spectrală este cu atât mai mică cu cât componentele cu ponderi mari sunt cuantizate mai precis, chiar dacă cele cu pondere mică sunt cuantizate mai puțin precis.

**3.7** Se cuantizează o secvență de test de 310 vectori, folosind mai întâi ca și măsură a distanței între doi vectori eroarea pătratică, iar apoi

eroarea pătratică ponderată, în care ponderea are o valoare calculată ca rădăcină de ordinul 6 din valoarea exactă a densității spectrale de putere. În cazul erorii pătratice ponderate, se obține, așa cum era de așteptat, o reducere a erorii spectrale medii (de la 0,93 dB la 0,90 dB).

**3.8** Pe baza relațiilor simplificate și aproximative pentru densitatea spectrală de putere deduse în capitolul 2, autorul introduce 2 noi relații de calcul pentru pondere. Se obțin valori foarte apropiate pentru eroarea spectrală medie, în raport cu cea obținută cu relația exactă a ponderii, cu avantajul unui număr mult mai mic de operații.

În capitolul 4, autorul introduce și implementează codarea prin metoda combinată arbore-căutare totală ca alternativă la codarea prin căutare totală, în cadrul cuantizării vectoriale prin desplicare prezentate în capitolul 3. În urma aplicării acestei metode se obține o complexitate deosebit de scăzută, fără afectarea erorii de cuantizare în comparație cu căutarea totală.

**4.1** Este prezentată această metodă, aplicată conform bibliografiei numai pentru vectori constituiți din eșantioane de semnal vocal, pe care autorul o va aplica pentru vectori LSF. Metoda constă în realizarea unei succesiuni de teste binare într-o structură de tip arbore până se ajunge într-unul din nodurile terminale. În nodul terminal respectiv se face o căutare totală printre vectorii de reproducere asociați aceluși nod. Vectorii de reproducere asociați nodurilor terminale fac parte din cartea de cod optimă pentru secvența de antrenament așa cum a fost proiectată în capitolul precedent.

**4.2** Pentru a se aplica codarea prin metoda combinată arbore-căutare totală este necesar să se realizeze o structurare a cărții de cod. Aceasta înseamnă că pentru fiecare nod intern al arborelui trebuie determinată componenta  $j$  care se testează ( $j$  poate lua orice valoare între 1 și  $k$ , unde  $k$  este dimensiunea vectorilor) și valoarea cu care se face compararea. De asemenea, pentru nodurile terminale trebuie determinați vectorii de reproducere asociați. Pentru a se realiza structurarea în acest fel, este esențială determinarea regiunilor de cuantizare situate de o parte și de alta a unei drepte sau plan din spațiul  $k$ -dimensional. În acest scop, autorul propune o nouă metodă, numită a intersecțiilor, care necesită un volum de

calcul mult mai mic (de aproximativ 12 ori) decât metoda proiecțiilor, prezentă în literatură. Pe baza acestei metode se poate face o structurare pentru orice vectori, nu numai pentru vectori LSF. În principiu metoda intersecțiilor permite realizarea structurării pe baza informației obținute prin cuantizarea unor vectori uniform distribuiți, obținuți prin modificarea pe rând a componentelor cu un anumit pas.

**4.3** Autorul realizează structurarea pentru vectori LSF, pe baza caracteristicilor acestor vectori concepând o formă simplificată a metodei intersecțiilor, pentru micșorarea numărului de vectori generați, în scopul micșorării suplimentare a volumului de calcul. Pasul cu care se modifică componenta variabilă a vectorilor uniform distribuiți s-a stabilit la valoarea de 0,3...0,5 din distanța medie dintre vectorii de reproducere învecinați. Această valoare a fost confirmată pe baza experimentelor. Astfel, efectuând cuantizarea conform metodei descrise la începutul acestui capitol, s-a obținut aceeași eroare medie ca și în situația în care s-a făcut prin căutare totală, cu avantajul reducerii foarte mari a complexității. Un alt experiment care confirmă valoarea determinată de autor pentru pasul de modificare a componente variabile a vectorilor, este realizat prin generarea și cuantizarea unor vectori pentru care pasul are valori din ce în ce mai mici, până la 1 Hz.

**4.5** Același algoritm de structurare a cărții de cod se face apoi utilizând eroarea pătratică ponderată pentru calculul distanței între 2 vectori, în care ponderea are una din cele două relații introduse de autor. Deoarece structurarea se face separat pentru cele 3 tipuri de subvectori, iar în calculul erorii ponderate intervin și componente diferite de ale subvectorului respectiv (de exemplu pentru structurarea cărții de cod pentru subvectorii  $f_4$ ,  $f_5$ ,  $f_6$  intervin și componentele  $f_3$  și  $f_7$ ), autorul face o analiză privind structurarea regiunilor de cuantizare în acest caz. De aici rezultă valori corespunzătoare pentru componentele care nu aparțin subvectorului pentru care se face structurarea, dar intervin în calculul ponderii. Și în acest caz eroarea medie de cuantizare se obține egală cu cea obținută în situația în care codarea s-a făcut prin căutare totală (folosind eroarea pătratică ponderată), din nou obținându-se o reducere foarte mare a complexității.

**4.6** În final, autorul face o comparație între cele două variante de codare, prin metoda combinată arbore-căutare totală, respectiv prin căutare totală, folosite în cadrul cuantizării vectoriale prin despicare. În cazul primei variante, introduse de autor, complexitatea se reduce de circa 11-12 ori, obținându-se aceeași eroare față de a doua variantă, cu prețul creșterii capacității de memorie utilizate de aproximativ doar 2 ori.

Teza are un caracter unitar conținând toate elementele necesare implementării unui cuantizor vectorial: definirea principalelor noțiuni legate de cuantizarea vectorială, prezentarea parametrilor ce urmează să fie cuantizați, proiectarea cărții de cod și realizarea procesului propriuzis de cuantizare.

## ANEXA 1. Notații și prescurtări folosite în cadrul tezei

VQ, cuantizarea vectorială, (vector quantization în limba engleză)

$Q$ , funcția de cuantizare

$\mathbf{x}=(x_1, x_2, \dots, x_k)$ , vector cu dimensiunea  $k$ , unde  $x_i$ ,  $i=1, \dots, k$  reprezintă componentele vectorului

$\alpha$ , funcția de codare

$\beta$ , funcția de decodare

$\mathcal{L}$ , cartea de cod

$I$ , mulțimea codurilor

$N$ , mărimea cărții de cod

$\mathfrak{R}^k$  spațiul cu dimensiunea  $k$

$R_i$ , regiune de cuantizare

$F_i$ , frontiera unei regiuni de cuantizare

$d(\cdot, \cdot)$ , distanța între doi vectori

$H_i$ , mulțimea (semispațiul) care conține toți vectorii mai apropiați de vectorul de reproducere  $i$  decât de vectorul de reproducere  $j$

$w_i$ , funcția pondere

$n$ , lungimea secvenței de antrenament

$Mem$ , memoria unui cuantizor vectorial

$C$ , complexitatea unui cuantizor vectorial

LSF, linii spectrale de frecvență

$f_i$ , frecvențele liniilor spectrale

parametrii LPC, parametrii obținuți prin codare prin predicție liniară (linear predictive coding în limba engleză)

$S(f)$ , densitatea spectrală de putere

$p$ , ordinul modelului liniar predictiv

$a_i$ ,  $i=1, \dots, p$ , coeficienții de predicție

$A(z)$ , polinomul coeficienților de predicție

$SD$ , eroarea spectrală, (spectral distortion în limba engleză)

MSVQ, cuantizor vectorial în mai multe stadii (multistage vector quantizer, în limba engleză)

TSVQ, cuantizor vectorial de tip arbore (tree structured vector quantizer, în limba engleză)

$K$ , numărul de stadii la algoritmul MSVQ

$d$ , numărul de niveluri al unei structuri de tip arbore

$M$ , parametru specific în cadrul algoritmului MSVQ-M

algoritmul PNN, împerecherea inteligentă a celor mai apropiate vecinătăți (pairwise nearest neighbor, în limba engleză)



$s_1, s_2$ , subsecvențele rezultate în urma împărțirii efectuate într-un nod al arborelui pentru obținerea buchetelor

$n_{s1}, n_{s2}$ , numărul vectorilor de antrenament din subsecvențele  $s_1$  și  $s_2$

$C_i$ , mănunchi

$C_{ij}$ , mănunchiul obținut prin unirea mănunchirilor  $C_i$  și  $C_j$

$\bar{x}_i$ , centroidul mănunchiului  $C_i$

$E_i$ , eroarea de cuantizare a vectorilor din mănunchiul  $C_i$  prin centroidul mănunchiului

$\bar{x}_i$ , centroidul mănunchiului  $C_i$

$N_B$ , numărul de buchete

$N_{TM}$ , numărul total de mănunchiuri

$m$ , numărul de noduri terminale în cadrul arborelui de la cuantizarea vectorială de tip arbore-căutare totală

$(j, v_j)$ , componenta și valoarea cu care se compară componenta respectivă

$n_s, n_d$ , numărul regiunilor de cuantizare situate la stânga, respectiv la dreapta față de un plan

$N_i$ , numărul vectorilor de reproducere asociați cu nodul  $i$  de pe un nivel al arborelui utilizat pentru structurarea cărții de cod

$N_{ai}$ , numărul vectorilor de antrenament asociați cu nodul  $i$  de pe un nivel al arborelui utilizat pentru structurarea cărții de cod

$N_{mediu}$ , numărul mediu de vectori de reproducere dintr-o regiune de cuantizare

$n_{mediu}$ , numărul mediu de valori ale unei componente a unui vector pentru care se determină parametrii  $n_s$  și  $n_d$

$\Delta_i$ , valoarea pasului cu care se modifică o componentă LSF în cadrul metodei intersecțiilor

## ANEXA 2. Programe realizate de autor și folosite în cadrul tezei

Din multitudinea de programe realizate de autor în cadrul elaborării acestei teze, în această anexă se prezintă două dintre ele, considerate mai reprezentative

### 1. Programul care implementează algoritmul de structurare a cărții de cod

```
#include<stdio.h>
#include<conio.h>
#include<alloc.h>
#include<math.h>
#include<process.h>
FILE *fp1,*fp2,*fp3,*fp4,*fp5,*fp6;
int niv=6;/*nr de nivele*/
double ii,jj; int j7,j8,de7,de8;
int bu,nll[128],nrr[128],de1,de2;float pl[3],pr[3],plf[3],prf[3];int nl1[128],nr1[128];
int ll[128],rr[128],nv;
int N1=1024,n=2790,n1=256,ind,j1,y,p,s,ip,s1,l,id,in,t,k,S1,r,r1,c,c1,coord;
unsigned int cod[350],q[256],jmax,a2min,nr,sum=0,stf[3][220],drf[3][220],com[3][150],comun1[128];
unsigned int stf[3][220],drf[3][220],commf[3][200];
unsigned int comf[128][150];
float rap.aa[3],x,x1,y1,min[128],minim[250],max,prag[7][128],a[3],b[3],d[256];long int i,j,i1;int
g1=0,g2=0,g3=0;
long int dim=3;/*dimens.vectorilor*/
int coordon[7][128],lim,depl,depla,out,val;float pas;
float df0,df1,df2,p1=0.51,p2=0.49,min0,min1,min2,max0,max1,max2,E[4],Emin;
int sfa[128]; int sfv[128];int comun[128],omun[128];
float huge *ptr1;float huge *ptr2;int huge *ptr3;int huge *ptr4;int huge *ptr5;int huge *ptr6; int huge
*ptr7;int huge *ptr8;
void main (void) {
for(i=0;i<3;i++) /*initializ.cu 0 a probabil.*/
pl[i]=pr[i]=0; clrscr();
ptr1=(float huge*)farmalloc(3700);
if(ptr1==0)
{printf("nu se poate aloca memorie 1");
exit(1);
}
if(!(fp1=fopen("c:\\home\\mischie\\car3.dat","r+")))
{puts("nu se poate deschide fis1");
exit(1);}
for(i=0;i<dim*n1;i++)
{fscanf(fp1,"%f",&x);
*(ptr1+i)=x;} /*vectori de reproducere*/
fclose(fp1);
for(i=212*dim;i<233*dim;i++)
```

```

printf(" %5.1f ",*(ptr1+i));
printf("\n");
ptr2=(float huge*)farmalloc(37050);
if(ptr2==0)
    {printf("nu se poate aloca memorie 2");
    exit(1);
    }
if(!(fp2=fopen("c:\\home\\mischie\\antr3.dat","r+")))
    {puts("nu se poate deschide fis1");
    exit(1);}
for(i=0;i<dim*n;i++)
    {fscanf(fp2,"%f",&x);
    *(ptr2+i)=x;} /*vectori de antrenam.*/
fclose(fp2);
printf("\n");
for(i=2780;i<2790;i++)
    printf(" %5.1f ",*(ptr2+i));
printf("\n");
ptr3=(int huge*)farmalloc(10000); /*memorie pt.indicii vectorilor de antren.*/
if(ptr3==0)
    {printf("nu se poate aloca memorie 3");
    exit(1);
    }
ptr4=(int huge*)farmalloc(5500); /*memorie pt.indicii vector.de repr.din celule*/
if(ptr4==0)
    {printf("nu se poate aloca memorie 4");
    exit(1);
    }
ptr5=(int huge*)farmalloc(5000); /*memorie pt.indicii vectorilor de antren.*/
if(ptr5==0) /*din grupele -st.- rezultate dupa impartire*/
    {printf("nu se poate aloca memorie 5");
    exit(1);
    }
ptr6=(int huge*)farmalloc(5000); /*memorie pt.indicii vector.de antr.*/
if(ptr6==0) /*din grupele -dr.-rezultate dupa impartire*/
    {printf("nu se poate aloca memorie 6");
    exit(1);
    }
ptr7=(int huge*)farmalloc(5000); /*memorie pt.indicii vectorilor de repr.*/
if(ptr7==0) /*din grupa-st,-de eroare min.rezultate dupa impartire*/
    {printf("nu se poate aloca memorie 7");
    exit(1);
    }
ptr8=(int huge*)farmalloc(5000); /*memorie pt.indicii vector.de antr.*/
if(ptr8==0) /*din grupa-dr,-de eroare min.rezultate dupa impartire*/
    {printf("nu se poate aloca memorie 8");
    exit(1);
    }
}

```

```

/*initializari*/
sfa[0]=2790;
sfv[0]=256;
for(i=0;i<n;i++){
    *(ptr3+i)=i;
}
for(i=0;i<n1;i++){
    *(ptr4+i)=i;
}
for(ii=0;ii<niv;ii++){ /*nr de nivele de despicare */
j7=0;j8=0;
for(jj=0;jj<pow(2,ii);jj++) /*nr de celule care se despic pe niv.ii*/
{ depl=0;
if(jj==0) depl=0;
else{ for(i=0;i<jj;i++)
depl=depl+sfa[i];}
b[0]=190;b[1]=270;b[2]=520; /*valorile de la care se pleaca*/
max0=0;min0=4000;
for(ip=0;;ip++)
{ pl[0]=0;pr[0]=0;
for(i=0;i<sfa[jj];i++) /*determinare probabilitati*/
{ in=(ptr3+depl+i);
if(*(ptr2+dim*in+0)<b[0]+1*ip) pl[0]=pl[0]+1;
else pr[0]=pr[0]+1;
if(ip==0){ if(*(ptr2+dim*in+0)<min0) min0=(ptr2+dim*in+0);
if(*(ptr2+dim*in+0)>max0) max0=(ptr2+dim*in+0);
}
}
}
pl[0]=(float)pl[0]/sfa[jj];pr[0]=(float)pr[0]/sfa[jj];
if((pl[0])>0.5) break;
}
b[0]=b[0]+ip*1;
printf("\n%d %f %f %5.1f",ip,pl[0],pr[0],b[0]);
max1=0;min1=4000;
for(ip=0;;ip++)
{ pl[1]=0;pr[1]=0;
for(i=0;i<sfa[jj];i++)
{ in=(ptr3+depl+i);
if(*(ptr2+dim*in+1)<b[1]+2*ip) pl[1]=pl[1]+1;
else pr[1]=pr[1]+1;
if(ip==0){ if(*(ptr2+dim*in+1)<min1) min1=(ptr2+dim*in+1);
if(*(ptr2+dim*in+1)>max1) max1=(ptr2+dim*in+1);
}
}
}
pl[1]=(float)pl[1]/sfa[jj];pr[1]=(float)pr[1]/sfa[jj];
if((pl[1])>0.5) break;
}
b[1]=b[1]+ip*2;
printf("\n%d %f %f %5.1f",ip,pl[1],pr[1],b[1]);

```

```

min2=4000;max2=0;
for(ip=0;ip++)
{ pl[2]=0;pr[2]=0;
  for(i=0;i<sfajj;i++)
  { in=(ptr3+depl+i);
    if(*(ptr2+dim*in+2)<b[2]+1*ip) pl[2]=pl[2]+1;
    else pr[2]=pr[2]+1;
    if(ip==0){ if(*(ptr2+dim*in+2)<min2) min2=*(ptr2+dim*in+2);
                if(*(ptr2+dim*in+2)>max2) max2=*(ptr2+dim*in+2);
              }
    }
  pl[2]=(float)pl[2]/sfajj;pr[2]=(float)pr[2]/sfajj;
  if((pl[2])>0.5) break;
}
b[2]=b[2]+ip*1;
printf("\n%d %f %f %5.1f",ip,pl[2],pr[2],b[2]);
for(j=0;j<3;j++) /*coordonata */
  printf(" %f %f;",pl[j],pr[j]);
/* getch(); */
printf("\n");
printf(" %5.1f %5.1f %5.1f %5.1f %5.1f %5.1f",min0,max0,min1,max1,min2,max2);
/* getch(); */
for(i=0;i<256;i++)
  q[i]=0;
out=0;pas=10;
df2=20;df1=20;df0=20;
for(bu=0;:)
{nv=0;
a[0]=min0;a[1]=min1;a[2]=b[2]+10*bu+out*pas; /*coordonata 2*/
for(i=0;i<n1;i++)
  q[i]=0;
  depl=0;
  if(jj==0) depl=0;
  else{for(id=0;id<jj;id++)
        depl=depl+sfv[id]; }
for(j1=0;j1++)
{printf("\n%5.1f %5.1f %5.1f",a[0],a[1],a[2]);
for(j=0;j++)
{nv=nv+1;
for(i=0;i<sfv[jj];i++)
  {d[i]=0;
  in=(ptr4+depl+i);
  for(k=0;k<3;k++)
  {x=(ptr1+in*3+k); /*calcul distanta*/
  d[i]=d[i]+(x-a[k])*(x-a[k]);} }
minim[j]=d[0];coord=0; /*determin.minim*/
for(i=1;i<sfv[jj];i++)
  {if(d[i]<minim[j]) {minim[j]=d[i];coord=i;}

```

```

    printf("");
cod[j]=coord;
if(coord==202)
{ printf("\n acum  %5.1f %5.1f %5.1f",a[0],a[1],a[2]); getch();}
if(minim[j]<10000) q[coord]=q[coord]+1;
a[l]=a[l]+df1; if(a[l]>max1+df1) {jmax=j;break;}
    if(a[l]>a[2]) {jmax=j;break;}
}
printf("\n  %d",j1);
printf("\n  %2.1f",jj);
/*for(i=0;i<256;i++)
    printf("%d; ",q[i]);      */
nr=0;
for(i=0;i<sfv[jj];i++)
    if(q[i]==0) nr=nr+1;
    printf("\nnr=%d",nr);
    printf("\n%5.1f %5.1f %5.1f",a[0],a[1],a[2]);
/*  getch(); */
a[0]=a[0]+df0;a[1]=min1;if(a[0]>min1){a[1]=a[0]+10;} if(a[0]>max0+df0) break; }
printf("\n");
for(j=0;j<jmax;j++)
    {printf("%6.1f %d; ",minim[j],cod[j]);
    }
    printf("\n");
for(i=0;i<sfv[jj];i++)
    printf("%d; ",q[i]);
nr=0;
s=0;r=0;c=0;
for(i=0;i<sfv[jj];i++)
    { in=(ptr4+depl+i);
    if(q[i]==0){ nr=nr+1;
        if(*(ptr1+dim*i+2)<a[2]) {st[out][s]=in;
            s=s+1;}

        else {dr[out][r]=in;
            r=r+1;} }
    else {com[out][c]=in;c=c+1;}
    sum=sum+q[i];}
    printf("\n nr=%d",nr);
    printf("\n sum=%d\n",sum);
for(i=0;i<s;i++)
    printf("%d ",st[out][i]);
printf("\n");
for(i=0;i<r;i++)
    printf("%d ",dr[out][i]);
printf("\n");
for(i=0;i<c;i++)
    printf("%d ",com[out][i]);
ll[out]=s+c;rr[out]=r+c;omun[out]=c;

```

```

rap=(float)ll[out]/rr[out];
if(rap>0.9) { pas=5;
    depla=0; /*recalculare probabilitati 2 */
    if(jj==0) depla=0;
    else {for(i=0;i<jj;i++)
        depla=depla+sfa[i];}
    pl[out]=0;pr[out]=0;
    for(i=0;i<sfa[jj];i++)
        {in=(ptr3+depla+i);
        if(*(ptr2+dim*in+2)<a[2]) pl[out]=pl[out]+1;
        else pr[out]=pr[out]+1;
        }
    pl[out]=(float)pl[out]/sfa[jj];pr[out]=(float)pr[out]/sfa[jj];

    E[out]=ll[out]*pl[out]+rr[out]*pr[out];
    out=out+1;}
else {bu=bu+1;}
    if(out==3) break;
}/* sfirsit coord 2*/
Emin=E[0]; val=0;
for(i=1;i<out;i++)
    if(E[i]<Emin) {Emin=E[i];val=i; }
    b[2]=a[2]-(out-1-val)*pas;
    nll[2]=ll[val];nrr[2]=rr[val];comun[2]=omun[val];
for(i=0;i<nll[2]-comun[2];i++)
    stf[2][i]=st[val][i];
for(i=0;i<nrr[2]-comun[2];i++)
    drf[2][i]=dr[val][i];
for(i=0;i<comun[2];i++)
    commf[2][i]=com[val][i];
plf[2]=pl[val];prf[2]=pr[val];
out=0;pas=10;
for(bu=0;;)
    {a[0]=min0;a[1]=b[1]+bu*10+out*pas;a[2]=a[1]+10;if(a[2]<min2) a[2]=min2; /*coordonata 1 */
    for(i=0;i<256;i++) /*!!!*/
        q[i]=0;
    for(j=0;j<jj)
        {printf("\n%5.1f %5.1f %5.1f",a[0],a[1],a[2]);
        for(j=0;j++)
            {for(i=0;i<sfv[jj];i++)
                {d[i]=0;
                in=(ptr4+depl+i);
                for(k=0;k<3;k++)
                    {x=(ptr1+in*dim+k); /*calcul distanta*/
                    d[i]=d[i]+(x-a[k])*(x-a[k]);} }
                }
            }
        }
    minim[j]=d[0];coord=0; /*determin.minim*/
    for(i=1;i<sfv[jj];i++)
        {if(d[i]<minim[j]) {minim[j]=d[i];coord=i;}

```

```

printf("");}
cod[j]=coord;if(minim[j]<10000) q[coord]=q[coord]+1;
a[2]=a[2]+df2; if(a[2]>max2+df2) {jmax=j;break;}
}
printf("\n %d\n",j1);
printf("\n %2.1f\n",jj);
/*for(i=0;i<256;i++)
printf("%d;",q[i]); */
nr=0;
for(i=0;i<sfv[jj];i++)
{if(q[i]==0) nr=nr+1;
}
printf("\nnr=%d",nr);
printf("\n%5.1f %5.1f %5.1f",a[0],a[1],a[2]);
/* getch(); */ /*570!!!*/
a[0]=a[0]+df0;a[2]=a[1]+10;if(a[2]<min2) a[2]=min2;if(a[0]>a[1]) break;
if(a[0]>max0+df0) break; }

printf("\n");
nr=0;
s=0;r=0;c=0;
for(i=0;i<sfv[jj];i++)
{in=(ptr4+depl+i);
if(q[i]==0){ nr=nr+1;
if(*(ptr1+dim*in+1)<a[1]) {st[out][s]=in;
s=s+1;}
else {dr[out][r]=in;
r=r+1;} }
else {com[out][c]=in;
c=c+1;}
sum=sum+q[i];}
printf("\n nr=%d",nr);
ll[out]=c+s;rr[out]=c+r;omun[out]=c;
printf("\n");
rap=(float)ll[out]/rr[out];
if(rap>0.9) { pas=5;
depla=0; /*recalculare probabilitati 1 */
if(jj==0) depla=0;
else{for(i=0;i<jj;i++)
depla=depla+sfa[i];}
pl[out]=0;pr[out]=0;
for(i=0;i<sfa[jj];i++)
{in=(ptr3+depla+i);
if(*(ptr2+dim*in+1)<a[1]) pl[out]=pl[out]+1;
else pr[out]=pr[out]+1;
}
pl[out]=(float)pl[out]/sfa[jj];pr[out]=(float)pr[out]/sfa[jj];

E[out]=ll[out]*pl[out]+rr[out]*pr[out];

```



```

        out=out+1;}
        else{bu=bu+1;}
        if(out==3) break;
    }/* sfirsit coord 0*/
Emin=E[0]; val=0;
for(i=1;i<out;i++)
    if(E[i]<Emin) {Emin=E[i];val=i; }
    b[1]=a[1]-(out-1-val)*pas;
    nll[1]=ll[val];nrr[1]=rr[val];comun[1]=omun[val];
for(i=0;i<nll[1]-comun[1];i++)
    stf[1][i]=st[val][i];
for(i=0;i<nrr[1]-comun[1];i++)
    drf[1][i]=dr[val][i];
for(i=0;i<comun[1];i++)
    commf[1][i]=com[val][i];
plf[1]=pl[val];prf[1]=pr[val];

out=0;pas=4;
for(bu=0:;)
    {a[0]=b[0]+bu*4+out*pas;a[1]=a[0]+10;a[2]=min2; /*coordonata 0*/
    for(i=0;i<n1;i++)
        q[i]=0;
    for(j=0;j1++)
        {printf("\n%5.1f %5.1f %5.1f",a[0],a[1],a[2]);
        for(j=0;j++)
            {for(i=0;i<sfv[j];i++)
                {d[i]=0;
                in=(ptr4+depl+i);
                for(k=0;k<3;k++)
                    {x=(ptr1+in*dim+k); /*calcul distanta*/
                    d[i]=d[i]+(x-a[k])*(x-a[k]);} }
                minim[j]=d[0];coord=0; /*determin.minim*/
            for(i=1;i<sfv[j];i++)
                {if(d[i]<minim[j]) {minim[j]=d[i];coord=i;}
                printf("");}
            cod[j]=coord;if(minim[j]<10000) q[coord]=q[coord]+1;
            a[2]=a[2]+df2; if(a[2]>max2+df2) {jmax=j;break;}
        }
        printf("\n %d\n",j1);
        printf("\n %2.1f\n",jj);
        /*for(i=0;i<256;i++)
            printf("%d; ",q[i]); */
        nr=0;
        for(i=0;i<sfv[j];i++)
            {if(q[i]==0) nr=nr+1;
            }
        printf("\nnr=%d",nr);
        printf("\n%5.1f %5.1f %5.1f",a[0],a[1],a[2]);
    }

```

```

getch();
a[1]=a[1]+df1;a[2]=min2; if(a[1]>min2) a[2]=a[1]+20;if(a[1]>max1+df1) break; }
printf("\n");
nr=0;
s=0;r=0;c=0;
for(i=0;i<sfv[jj];i++)
{in=(ptr4+depl+i);
if(q[i]==0){ nr=nr+1;
if(*(ptr1+3*in+0)<a[0]) {st[out][s]=in;
s=s+1;}
else {dr[out][r]=in;
r=r+1;} }
else {com[out][c]=in;
c=c+1;}
sum=sum+q[i];}
printf("\n nr=%d",nr);
ll[out]=c+s;rr[out]=c+r;omun[out]=c;
printf("\n");
rap=(float)ll[out]/rr[out];
if(rap>0.9) {pas=2;
depla=0;
if(jj==0) depla=0;
else {for(i=0;i<jj;i++)
depla=depla+sfa[i];}
pl[out]=0;pr[out]=0; /*recalculare probabilitati 0 */
for(i=0;i<sfa[jj];i++)
{in=(ptr3+depla+i);
if(*(ptr2+dim*in+0)<a[0]) pl[out]=pl[out]+1;
else pr[out]=pr[out]+1;
}
pl[out]=(float)pl[out]/sfa[jj];pr[out]=(float)pr[out]/sfa[jj];

E[out]=ll[out]*pl[out]+rr[out]*pr[out];
out=out+1;}
else {bu=bu+1;}
if(out==3) break;
}
Emin=E[0]; val=0;
for(i=1;i<out;i++)
if(E[i]<Emin) {Emin=E[i];val=i;}
b[0]=a[0]-(out-1-val)*pas;
nll[0]=ll[val];nrr[0]=rr[val];comun[0]=omun[val];
for(i=0;i<nll[0]-comun[0];i++)
stf[0][i]=st[val][i];
for(i=0;i<nrr[0]-comun[0];i++)
drf[0][i]=dr[val][i];
for(i=0;i<comun[0];i++)
commf[0][i]=com[val][i];

```

```
plf[0]=pl[val];prf[0]=pr[val];
```

```
for(j=0;j<3;j++)
  printf(" %d %d;",nll[j],nrr[j]);
printf("\n");
/* getch(); */
for(i=0;i<3;i++) /* coordonata */
  {aa[i]=(float)plf[i]*nll[i]+prf[i]*nrr[i];
  printf("%5.1f;",aa[i]);}
min[jj]=aa[0];
coordon[ii][jj]=0;
for(i=1;i<3;i++)
  if(aa[i]<min[jj]) {coordon[ii][jj]=i;min[jj]=aa[i];}
printf("\n%d %5.1f",coordon[ii][jj],min[jj]);
printf("");
lim=coordon[ii][jj]; /*valoarea coordonatei care da minimul*/
prag[ii][jj]=b[lim];
nll[jj]=nll[lim];nrr[jj]=nrr[lim];comun1[jj]=comun[lim];
de7=j7;
for(i=0;i<nll[jj]-comun1[jj];i++) /*elem.grupeii care dau minimul*/
  {*(ptr7+de7+i)=stf[lim][i];
  j7=j7+1;printf("");}
de8=j8;
for(i=0;i<nrr[jj]-comun1[jj];i++)
  {*(ptr8+de8+i)=drf[lim][i];
  j8=j8+1;printf("");}
for(i=0;i<comun1[jj];i++)
  {comf[jj][i]=commf[lim][i];
  printf("");}
} /*sfirsit jj*/
for(jj=0;jj<pow(2,ii);jj++)
  {sfv[2*jj]=nll[jj]; /*nr.de elem.din cele doua celule obtin.din */
  sfv[2*jj+1]=nrr[jj];} /*impart.grupeii jj*/
printf("\n");

for(jj=0;jj<pow(2,ii);jj++)
  {printf("%d %5.1f",coordon[ii][jj],prag[ii][jj]);
  printf("%d %d",sfv[2*jj],sfv[2*jj+1]);}
printf("\n");
/*getch(); */
de7=0;de8=0;
for(jj=0;jj<pow(2,ii);jj++)
  {
  if(jj==0) depl=0;

for(i=0;i<nll[jj]-comun1[jj];i++) /*indicii vector.din prima celula*/
  *(ptr4+depl+i)=*(ptr7+de7+i);
```

```

    de7=de7+n11[jj]-comun1[jj];
for(i=0;i<comun1[jj];i++)
    *(ptr4+depl+n11[jj]-comun1[jj]+i)=comf[jj][i];

for(i=0;i<n11[jj]-comun1[jj];i++) /*indicii vector.din celula doi*/
    *(ptr4+depl+sfv[2*jj]+i)=(ptr8+de8+i);
    de8=de8+n11[jj]-comun1[jj];
for(i=0;i<comun1[jj];i++)
    *(ptr4+depl+sfv[2*jj]+n11[jj]-comun1[jj]+i)=comf[jj][i];

for(i=0;i<sfv[2*jj];i++)
    printf("%d ",*(ptr4+depl+i));
    printf("\n ");
for(i=0;i<sfv[2*jj+1];i++)
    printf("%d ",*(ptr4+depl+sfv[2*jj]+i));

    depl=depl+sfv[2*jj]+sfv[2*jj+1]; /*actualiz.deplasament*/
    printf("\n");
} /*sfirsit jj*/
printf("\n");
de1=0;de2=0; /*initial.cu 0 a deplas.in ptr5 si ptr6*/
for(jj=0;jj<pow(2,ii);jj++) /*impartire vect.de antren in celule*/
{lim=coordon[ii][jj];
    depl=0;s=0;r=0;
if(jj==0) depl=0;
    else {for(i=0;i<jj;i++)
        depl=depl+sfa[i];}
for(i=0;i<sfa[jj];i++)
{in=(ptr3+depl+i);
if(*(ptr2+dim*in+lim)<prag[ii][jj]) {*(ptr5+de1+s)=in;
    s=s+1;}
    else {*(ptr6+de2+r)=in;
        r=r+1;}
}
n11[jj]=s;nrr[jj]=r;
de1=de1+s;de2=de2+r;
} /* sfirsit jj*/
for(jj=0;jj<pow(2,ii);jj++) /*stabil.num.de vect.de antren.din cele 2 celule*/
{ sfa[2*jj]=n11[jj];sfa[2*jj+1]=nrr[jj];
    printf("\n%d %d ",sfa[2*jj],sfa[2*jj+1]); }
/* getch(); */
printf("\n");
for(jj=0;jj<pow(2,ii);jj++)
{if(jj==0) {depl=0;de1=0;de2=0;}

for(i=0;i<n11[jj];i++) /*indicii vector.din prima celula*/
{*(ptr3+depl+i)=(ptr5+de1+i);
    printf("");}

```

```

for(i=0;i<nrr[jj];i++) /*indicii vector.din celula doi*/
    {*(ptr3+depl+nll[jj]+i)=*(ptr6+de2+i);
    printf("");}
for(i=0;i<30;i++)
    printf("%d ",*(ptr3+depl+i));
printf("\n");
for(i=0;i<30;i++)
    printf("%d ",*(ptr3+depl+sfa[2*jj]+i));
printf("\n");
depl=depl+sfa[2*jj]+sfa[2*jj+1];
de1=de1+nll[jj];de2=de2+nrr[jj];
}/*sfirsit jj */
} /*sfirsit ii*/
if(!(fp3=fopen("c:\\home\\miscie\\coor36.dat","w+")))
    {puts("nu se poate deschide fis3");
    exit(1);}
for(ii=0;ii<niv;ii++)
    for(jj=0;jj<pow(2,ii);jj++)
        fprintf(fp3,"%d ",coordon[ii][jj]);
fclose(fp3);
if(!(fp4=fopen("c:\\home\\miscie\\pra36.dat","w+")))
    {puts("nu se poate deschide fis4");
    exit(1);}
for(ii=0;ii<niv;ii++)
    for(jj=0;jj<pow(2,ii);jj++)
        fprintf(fp4,"%5.1f",prag[ii][jj]);
fclose(fp4);
if(!(fp5=fopen("c:\\home\\miscie\\sf36.dat","w+")))
    {puts("nu se poate deschide fis5");
    exit(1);}
for(jj=0;jj<pow(2,niv-1);jj++)
    {fprintf(fp5,"%d ",sfv[2*jj]);
    fprintf(fp5,"%d ",sfv[2*jj+1]);}
fclose(fp5);
if(!(fp6=fopen("c:\\home\\miscie\\indic36.dat","w+")))
    {puts("nu se poate deschide fis6");
    exit(1);}
s=0;
for(jj=0;jj<pow(2,niv-1);jj++)
    s=s+sfv[2*jj]+sfv[2*jj+1];
for(i=0;i<s;i++)
    fprintf(fp6,"%d ",*(ptr4+i));
fclose(fp6);
for(jj=0;jj<pow(2,niv);jj++)
    printf("%4.1f",min[jj]);
printf("");
}

```

## 2. Program care implementează algoritmul PNN rapid

```

#include<stdio.h>
#include<conio.h>
#include<alloc.h>
#include<stdlib.h>
FILE *fp1,*fp2,*fp3;
int NB=410,NB1,NC[420],NC1[420];float x; /*nr.de bucheti,nr.de cluster/buch,centroizi ai clusterului
*/
int NV=2790; /*nr de vectori(clusteri)*/
float CG[420][10]; /*centroid general*/
int dim=4,sum=0; /* dimens. vectorilor */
float min,x1,y,S[420][10],S1[11][12],S2[420],S3[420],dis[420];
int u,u1,umin,i,ii,s,j,i1,j1,k,l,l1[420],J[420],n[420][10],loc[420],prag,suma=0,Nuniri;
float huge *ptr;
float tabl(float huge*ptr,int i,int j,int k)
    {int sss=0,ss;
    for(ss=0;ss<i;ss++)
        sss=sss+NC1[ss]+2;
    return(*(ptr+sss*dim+j*dim+k));
    }
float dist(int i,int j,int k)
    {float d=0;int t;
    for(t=0;t<dim;t++)
        d=d+(tabl(ptr,i,j,t)-tabl(ptr,i,k,t))*(tabl(ptr,i,j,t)-tabl(ptr,i,k,t));
    return d;
    }
int adresa(int i,int j,int k)
    {int sss=0,ss,adr;
    for(ss=0;ss<i;ss++)
        sss=sss+NC1[ss]+2;
        adr=sss*dim+j*dim+k;
    return adr;
    }
void main(void) {
clrscr();
if(!(fp1=fopen("c:\\home\\mischie\\nvect710.dat","r+")))
{puts("\n nu se poate deschide fis1");
exit(1);}
for(i=0;i<NB;i++)
    fscanf(fp1,"%d",&NC[i]);
for(i=0;i<NB;i++)
    NC1[i]=NC[i];
printf("%d %d %d %d %d %d %d",NC[0],NC[1],NC[2],NC[3],NC[4],NC[5],NC[6]);
fclose(fp1);
for(i=0;i<NB;i++)

```

```

suma=suma+NC[i];
printf("\n%d\n",suma);
ptr=(float huge*)farmalloc(150000); /*pt.citirea buchetilor*/
if(ptr==0)
{printf("\nnu se poate aloca memorie");
exit(1);
}

if(!(fp2=fopen("c:\\home\\miscie\\buche710.dat","r+")))
{puts("nu se poate deschide fis2");
exit(1);}

for(i=0;i<NB;i++)
{sum=sum+NC[i-1];
for(j=0;j<NC[i];j++)
for(k=0;k<dim;k++)
{fscanf(fp2,"%f",&x);
*(ptr+(sum+j)*dim+k)=x;}
sum=sum+2;
}
fclose(fp2);
printf("\n sum=%d\n",sum);
for(i=50;i<150;i++)
printf("%5.1f ",*(ptr+i));
getch();
NB1=NB; /*nr de buch.folosit pt a determ. 1/2 din nr.real de bucheti*/
printf("\n%5.1f %5.1f %5.1f %5.1f",tabl(ptr,0,0,0),tabl(ptr,0,1,1),tabl(ptr,1,0,3),tabl(ptr,1,0,4));
getch();
for(i=0;i<NB;i++) /*centrozii generali se initializeaza cu 0 */
for(k=0;k<dim;k++)
CG[i][k]=0;
for(i=0;i<NB;i++) /*se calculeaza centrozii generali*/
for(k=0;k<dim;k++)
{for(j=0;j<NC[i];j++)
CG[i][k]=CG[i][k]+tabl(ptr,i,j,k);
CG[i][k]=CG[i][k]/NC[i];
printf("");
}
for(i=0;i<NB;i++) /*initializare cu 0 a erorilor pe cluster*/
for(j=0;j<NC[i];j++) /*si cu 1 a numerelor de vectori pe cluster*/
{S[i][j]=0;
n[i][j]=1;}
for(ii=0;;ii++)
{for(i=0;i<NB;i++) /*i=nr.curent al buchetului in care se face cercetarea*/
{printf("\n i=%d",i);
if(NC[i]==0) S2[i]=S3[i];
else
{for(j=0;j<NC[i];j++) /*calcul distante S1[j][k]*/

```

```

for(k=j+1;k<NC[i];k++)
    {S1[j][k]=*(float)n[i][j]*S[i][j]+(float)n[i][k]*S[i][k]+*(float)n[i][j]*(float)n[i][k]/((float)n[i][j]+(float)n[i][k])*dist(i,j,k);
    printf(""); }

min=S1[0][1];I[i]=0;J[i]=1;      /*determinare minim S1[j][k]*/
for(j=0;j<NC[i];j++)
    for(k=j+1;k<NC[i];k++)
        if(S1[j][k]<min) {min=S1[j][k]; I[i]=j;J[i]=k;
        }
    S2[i]=min;
}
}
for(i=0;i<NB;i++)
printf(" %d %d ",I[i],J[i]);
for(i=0;i<NB;i++)
printf(" %5.4f",S2[i]);
printf("\n");
getch();
/*Ordonare crescatoare a erorilor S2[i]*/
for(i=0;i<NB;i++)
S3[i]=S2[i]; /*de fapt se ordoneaza S3==S2,ca sa nu se piarda S2*/
for(j=0;j++)
{y=0;
for(i=0;i<NB-1;i++)
    {if(S2[i]>S2[i+1])
        {x1=S2[i];
        S2[i]=S2[i+1];
        S2[i+1]=x1;
        y=y+1;}
    }
    if (y==0) break;
}
printf("\n");
for(i=0;i<NB;i++)
printf(" %5.3f",S2[i]);
/*determinare loc*/
for(j=0;j<NB;j++)
    for(i=0;i<NB;i++)
        if (S3[i]==S2[j]) {loc[i]=j;
        }
for(i=0;i<NB;i++)
    printf(" %d ",loc[i]);
printf("\n");

/*uniri in primii NB1/2 bucheti d.p.d.v. al erorilor minime,*/
prag=(int)NB1/2;Nuniri=0;      /* incep cu buchetul aflat pe locul 0,*/

```



```

for(j=0;j<NB;j++) /* pina la locul NB1/2,fara buch.cu NC[i]=0 */
{if(Nuniri==prag) break;
for(i=0;i<NB;i++)
if(loc[i]==j)

    if(NC[i]>0) /*unirile se fac numai daca NC[i]>0*/
    {
    NC[i]=NC[i]-1;
    NV=Nv-1;
    Nuniri=Nuniri+1;
    i1=I[i];j1=J[i];
    S[i][i1]=S3[i]; /*noua val.a erorii in clusterul obtin.prin unire*/
    for(k=0;k<dim;k++)
    {*(ptr+adresa(i,i1,k))=((float)n[i][i1]*tabl(ptr,i,i1,k)+(float)n[i][j1]*tabl(ptr,i,j1,k))/((float)n[i][i
1]+(float)n[i][j1]);
    printf("");}
    /*noua valoare a centroidului */
    n[i][i1]=n[i][i1]+n[i][j1]; /*noul nr.de vect./cluster */
    for(s=j1;s<NC[i];s++)
    {n[i][s]=n[i][s+1]; /* decalari in sus ale nr.de vect/clust,erorii si */
    S[i][s]=S[i][s+1]; /* centroidului datorita disparitiei clusterului j1 */
    for(k=0;k<dim;k++)
    *(ptr+adresa(i,s,k))=tabl(ptr,i,s+1,k);
    }
    break;
}

if(NV==256) break;
}
if(NV==256) break;
suma=0;
for(i=0;i<NB;i++)
{suma=suma+NC[i];
printf(" %d %d;",NC1[i],NC[i]);}
printf("\n%d \n",suma);
for(i=0;i<NB;i++)
if(NC[i]>0)
if(NC[i]==2)
{printf("\n buchetul %d se alatura altui buchet",i);
NC[i]=0;NB1=NB1-1;
for(u=0;u<NB;u++) /*calcul dist.intre CG[i] si CG[u]*/
if(NC[u]>0) /*buch. u sa nu fi fost deja alaturat!*/
{dis[u]=0;
for(k=0;k<dim;k++)
{x=CG[i][k];y=CG[u][k];
dis[u]=dis[u]+(x-y)*(x-y);}
}
for(u=0;u<NB;u++) /*prima dist.calcul.este primul minim*/

```

```

if(NC[u]>0)
    if(NC[u]<=NC1[u]+0) /*sa nu se alature unui buch. care a mai"absorbit*/
        {min=dis[u];umin=u;break;} /* bucheti" */
for(u1=u+1;u1<NB;u1++) /*se gaseste dist.minima*/
    if(NC[u1]>0)
        if(NC[u1]<=NC1[u1]+0) /*la fel ca mai sus!*/
            if(dis[u1]<min) {min=dis[u1];umin=u1;}
printf("\numin=%d,pt.care NC1=%d, NC=%d ",umin,NC1[umin],NC[umin]);
/* getch(); */
for(k=0;k<dim;k++) /*noul centr.gen.in buchetul umin*/
    {CG[umin][k]=(NC1[i]*CG[i][k]+NC1[umin]*CG[umin][k])/(NC1[i]+NC1[umin]);
    printf("");}
for(k=0;k<dim;k++) /*mutarea celor 2 centr.din buch.i in buch.umin*/
    {*(ptr+adresa(umin,NC[umin],k))=tabl(ptr,i,0,k);
    *(ptr+adresa(umin,NC[umin]+1,k))=tabl(ptr,i,1,k);} /*Aici!!*/
printf("\n");
for(k=0;k<dim;k++)
    printf(" %5.1f",tabl(ptr,umin,NC[umin],k));/*centroid pt.clust.1*/
printf("\n"); /*dupa mutarea in noul buch.umin*/
for(k=0;k<dim;k++)
    printf(" %5.1f",tabl(ptr,umin,NC[umin]+1,k)); /*la fel pt.cl.2*/
printf("\n");
for(k=0;k<dim;k++)
    printf(" %5.1f",tabl(ptr,i,0,k)); /*centr.pt.cl.1 inainte de mutare*/
printf("\n");
for(k=0;k<dim;k++) /*la fel.pt.cl.2*/
    printf(" %5.1f",tabl(ptr,i,1,k));
    k=NC[umin];
S[umin][k]=S[i][0]; /*erorile celor 2 clust.se atas.in buch.umin*/
S[umin][k+1]=S[i][1]; /*Aici!!!*/
n[umin][k]=n[i][0]; /*nr.de vectori/cluster din buch.i se transf.*/
n[umin][k+1]=n[i][1]; /*Aici!!!*/ /* in buchetul umin*/
NC[umin]=NC[umin]+2; /*nr de clust.in buch.obtinut prin adugarea buch.i*/
} /*sfirs.unirii clusterilor*/
}
printf("\n %d \n",ii);
suma=0;
for(i=0;i<NB;i++)
    {printf(" %d ",NC[i]);
    suma=suma+NC[i]; }
printf("\n%d\n ",suma);
for(i=0;i<NB;i++)
    {for(j=0;j<NC[i];j++)
    {for(k=0;k<dim;k++)
        printf("%5.5f ",tabl(ptr,i,j,k));
        printf("\n");}
    printf("\n i=%d",i);/*getch();*/ }
if(! (fp3 = fopen("c:\home\mischie\car710.dat", "w+"))

```

```
{puts("nu se poate deschide fis3");  
exit(1);}  
for(i=0;i<NB;i++)  
for(j=0;j<NC[i];j++)  
for(k=0;k<dim;k++)  
fprintf(fp3,"%5.2f ",tabl(ptr,i,j,k));  
fclose(fp2);  
  
}
```

**BIBLIOGRAFIE**

- [1] A. Gersho, R.M. Gray, "Vector Quantization and Signal Compression", Kluwer Academic Publishers, London 1993.
- [2] V. Ramasubramanian, K. Paliwal, "Fast  $K$ -Dimensional Tree Algorithms for Nearest Neighbor Search with Application to Vector Quantization Encoding", IEEE Trans. on Signal Processing, pp.518-531, March 1992.
- [3] N. Moayeri, D. Neuhoff, "Time-Memory Tradeoffs in Vector Quantizer Codebook Searching Based on Decision Trees", IEEE Trans. on Speech and Audio Processing, pp.490-506, October 1994.
- [4] K. Paliwal, B. Atal, "Efficient Vector Quantization of LPC Parameters at 24 Bits/Frame", IEEE Trans. on Speech and Audio Processing, pp.3-14, January 1993.
- [5] W. Le Blanc, B. Bhattacharya, S. Mahmoud, V. Cuperman, "Efficient Search and Design Procedures for Robust Multi-Stage VQ of LPC Parameters for 4 kb/s Speech Coding", IEEE Trans. on Speech and Audio Processing, pp.373-385, October 1994.
- [6] W. Gardner, B. Rao, "Theoretical Analysis of the High-Rate Vector Quantization of LPC Parameters", IEEE Trans. on Speech and Audio Processing, pp.367-381, September 1995.
- [7] F. Song, B. Huang, "Optimal Quantization on LSP Parameters", IEEE Trans. on Speech and Audio Processing, pp.15-24, January 1993.
- [8] M. Xie, J. Adoul, "Algebraic Vector Quantization of LSP Parameters with Low Storage and Computational Complexity", IEEE Trans. on Speech and Audio Processing, pp.234-239, May 1996.
- [9] R. Hagen, "Robust LPC Spectrum Quantization- Vector Quantization by a Linear Mapping of a Block Code", IEEE Trans. on Speech and Audio Processing, pp.266-280, July 1996.
- [10] A. Buzo, A. Gray, R.M. Gray, J. Markel, "Speech Coding Based Upon Vector Quantization", IEEE Trans. on Acoustics Speech and Signal Processing, pp.562-574, October 1980.
- [11] Y. Linde, A. Buzo, R. M.Gray, "An Algorithm for Vector Quantizer design", IEEE Trans. Communications, pp.84-95, January 1980.

- [12] B. Juang, D. Gray, A. Gray, "Distorsion performance of vector quantization for LPC voice coding", IEEE Trans. on Acoustics Speech and Signal Processing, pp.294-303, April 1982.
- [13] R. Ramachandran, M. Sondhi, N. Seshadri, B. Atal, "A Two Codebook Format for Robust Quantization of Line Spectral Frequencies", IEEE Trans. on Speech and Audio Processing, pp.157-168, May 1995.
- [14] W. Equitz, "A new Vector Quantization Clustering Algorithm", IEEE Trans. on Acoustics Speech and Signal Processing, pp.1568-1575, October 1989.
- [15] R. Laroia, N. Phamdo, N. Farvardin, "Robust and Efficient Quantization of Speech LSP Parameters using Structured Vector Quantizers", presented in ICASSP '91 Toronto, Canada, April 1991.
- [16] K. Malone, T. Fischer, "Enumeration and Trellis-Search Coding Schemes for Speech LSP Parameters", IEEE Trans. on Speech and Audio Processing, pp.304-315, July 1993.
- [17] M. Ferrer-Ballester, A. Figueiras-Vidal, "Efficient Adaptive Vector Quantization of LPC Parameters", IEEE Trans. on Speech and Audio Processing, pp.314-317, July 1995.
- [18] M. Balacrishnan, W. Perlman, L. Lu, "Variable-Rate Tree Structured Vector Quantizers", IEEE Trans. on Information Theory, pp.917-930, July 1995.
- [19] N. Moayeri, D. Neuhoff, W. Stark, "Fine Coarse Vector Quantization", IEEE Trans. on Signal Processing, pp.1503-1515, July 1991.
- [20] D. Lee, S. Baek, K. Sung, "Modified  $K$ -means Algorithm for Vector Quantizer Design", IEEE Signal Processing Letters, pp.2-4, January 1997.
- [21] Y. Hussain, N. Farvardin, "Variable-Rate Finite-State Vector Quantization and Application to Speech and Image Coding", IEEE Trans. on Speech and Audio Processing, pp.25-38, January 1993.
- [22] F. Jean, H. Wang, "Transparent Quantization of Speech LSP Parameters Based on KLT and 2-D-Prediction", IEEE Trans. on Speech and Audio Processing, pp.60-65, January 1996.
- [23] P. Laurent, "Expression of Spectral Distorsion using Line Spectrum Frequencies", IEEE Trans. on Speech and Audio Processing, pp.481-483, September 1997.

- [24] J. Pan, T. Fischer, "Vector Quantization of Speech Line Spectrum Pair Parameters and Reflection Coefficients", IEEE Trans. on Speech and Audio Processing, pp.106-115, March 1998.
- [25] K. Law, C.Chan, "Split Dimension Vector Quantization of Parcor Coefficients for Low Bit Rate Speech Coding", IEEE Trans. on Speech and Audio Processing, pp.443-446, July 1994.
- [26] A. Gersho, V. Cuperman, "Vector Quantization. A pattern matching technique for speech coding", IEEE Communication Magazine, pp 15-21, December 1983.
- [27] R. M.Gray, "Vector Quantization", IEEE ASSP Magazine, pp.4-29, April 1984.
- [28] L. Rabiner, R. Schafer, "Digital Processing of Speech Signal", Prentice-Hall, New Jersey, 1978.
- [29] A. Oppenheim, R. Schafer, "Digital Signal Processing", Prentice Hall, New Jersey, 1975.
- [30] C. Marven, G. Ewers, "Digital Signal Processing", Texas Instruments, 1993.
- [31] P. Swasek, "Quantization", University of Rhode Island, 1985.
- [32] B. Atal, V. Cuperman, A. Gersho, "Speech and Audio Coding for Wireless and Network Applications", Kluwer Academic Publishers, London 1993.
- [33] P. Cosman, K. Oehler, E. Riskin, R. Gray, "Using Vector Quantization for Image Processing", IEEE Proceedings, pp.1326-1341, September 1993.
- [34] C. Wu, J. Chen, "A Novel Two Level Method for the Computation of the LSP Frequencies Using a Decimation-in-Degree Algorithm", IEEE Trans. on Speech and Audio Processing, pp.106-115, March 1997.
- [35] C. Nasar, M. Soleymani, "Codebook Design for Trellis Quantization Using Simulated Annealing", IEEE Trans. on Speech and Audio Processing, pp.400-405, October 1993.
- [36] W. Chan, A. Gersho, "High Fidelity Audio Coding with Generalized Product Code VQ", Speech and Audio Coding for Wireless and Network Applications, Kluwer Academic Publishers, pp.153-160, London 1993
- [37] N. Phamdo, N. Farvardin, T. Moriya, "Combined Source-Channel Coding of LSP Parameters Using Multi-Stage Vector Quantization", Speech and Audio Coding for Wireless and Network Applications, Kluwer Academic Publishers, pp.181-190, London 1993

- [38] S. Wang, E. Paksoy, A. Gersho, "Product Code Vector Quantization of LPC Parameters", *Speech and Audio Coding for Wireless and Network Applications*, Kluwer Academic Publishers, pp.252-258, London 1993
- [39] E. Pop, V. Tiponuț, I. Naforniță, A. Mihăescu, L. Toma, "Metode în Prelucrarea Numerică a Semnalelor", vol. I și II, Ed. Facla Timișoara, 1986.
- [40] A. Millea, "Măsurări electrice. Principii și metode", Ed. Tehnică București, 1980.
- [41] L. Toma, A. Stoian, "Predicția liniară", Catedra de Electronică Aplicată, I.P. Timișoara, 1987.
- [42] S. Mischie, L. Toma, "Programs for Serial Communication between a M80-UC Microsystem and an IBM Personal Computer", ICATE '91, pp.E29, Craiova 1991.
- [43] S. Mischie, L. Toma, "Quantization of LPC Parameters", *Proceedings of the Symposium on Electronics and Telecommunications, Timișoara*, vol. III, pp.145-150, 1994.
- [44] S. Mischie, A. Iacovliev, "An Algorithm for Vector Quantizer Design using Pairwise Nearest Neighbor", *Proceedings of the Symposium on Electronics and Telecommunications, Timișoara*, vol. II, pp.99-104, 1996.
- [45] A. Iacovliev, S. Mischie, "Determination of Prediction Coefficients of Speech with Digital Signal Processor (DSP)", *Proceedings of the Symposium on Electronics and Telecommunications, Timișoara*, vol. II, pp.176-179, 1996.
- [46] S. Mischie, "Structurarea cărții de cod a unui cuantizor vectorial de tip Voronoi în vederea cuantizării vectoriale prin metoda combinată arbore-căutare totală", *Buletinul Științific al Universității "Politehnica" din Timișoara*, Tom 43/57 Electrotehnică, Electronică, Comunicații, 1998.
- [47] S. Mischie, D. Stoiciu, L. Toma, "Efficient Computation of LPC Power Spectral Density at Speech LSF's", *Buletinul Științific al Universității "Politehnica" din Timișoara*, Tom 43/57 Electrotehnică, Electronică, Comunicații, 1998.
- [48] S. Mischie, A. Iacovliev, "Performance Evaluation of Unstructured, Tree-Structured and Tree Searched-Unstructured Vector Quantizers for LSF's", *Proceedings of the Symposium on Electronics and Telecommunications, Timișoara*, 1998.

[49] S. Mischie, "Calculul erorilor în procesul de cuantizare", referatul nr.1 pentru doctorat, 1994.

[50] S. Mischie, "Algoritmi de cuantizare vectorială", referatul nr.2 pentru doctorat, 1996.