

## **Cuantizarea vectorială** **Partea a I-a. Prezentarea cuantizării vectoriale**

**Ș.I. ing Cornel Balint**  
**prof. dr. ing. Miranda Naforniță**  
**Universitatea Politehnica Timișoara**

**ABSTRACT.** During last years, vector quantization becomes a powerful technique for data compression, in particular for image and speech signals. This paper, structured as two part series, present a tutorial on vectorial coding, introducing the fundamentals vectorial quantizer and of adaptive vectorial coding as a method for coding nonstationary sources. Part two presents a general mathematical definition of adaptive vector quantization and an original classification.

### **1. Introducere**

Codarea vectorială este o generalizare a codării scalare, fiind o extindere a acesteia la codarea unui vector privit ca un set de numere reale. Un vector poate reprezenta de exemplu un segment de semnal vocal sau de imagine.

În literatură sunt prezentate numeroase metode de cuantizare vectorială, fiecare dintre acestea fiind dezvoltate și optimizate pentru un anumit tip de semnal particular, avându-se în vedere anumite criterii de performanță impuse.

Un număr mare din aceste metode de cuantizare se numesc metode de cuantizare adaptivă, acest calificativ fiind utilizat în diverse sensuri, pentru a indica faptul că algoritmul este adaptat într-un fel sau altul semnalului de intrare, în vederea realizării unei cuantizări optime într-un sens precizat, pentru semnalul dat [GG93]. În cele ce urmează se vor prezenta principiile cuantizării vectoriale și se va realiza o clasificare a metodelor de cuantizare adaptivă.

## 2. Cuantizarea vectorială

Un cuantizor vectorial VQ [GG93], [Ger82],  $k$  - dimensional și de mărime  $N$  este o aplicație a unui vector sau a unui punct din spațiul euclidian  $k$ -dimensional,  $P^k$  pe o mulțime finită  $X$  numită dicționar (codebook) și conținând  $N$  elemente, numite cuvinte de cod:

$$Q: R^k \rightarrow C, \quad C \in R^k \quad (2.1.)$$

$$C = (y_1, y_2, \dots, y_N) \text{ și } y_i \in R^k, \text{ pentru orice } i \in I = \{1, 2, 3, \dots, N\}, \quad (2.2.)$$

unde  $I$  este o mulțime de numere întregi, numite index.

Cuantizorul vectorial divide spațiul  $R^k$  în regiuni:

$$R_i = \{x \in R^k : Q(x) = y_i\}, \quad i \in I \quad (2.3.)$$

$$\text{care formează o partiție a spațiului } R^k : \bigcup_i R_i = R^k \text{ și } R_i \cap R_j = \emptyset \quad (2.4.)$$

și asociază fiecărei regiuni un cuvânt de cod din  $C$ .

Se definește un cuantizor vectorial ca fiind regulat, dacă partițiile  $P_i$  ale spațiului vectorial de intrare formează un set convex, adică dacă pentru orice  $a_i, b_i \in R_i$  și orice  $0 < \lambda < 1$ , avem îndeplinită condiția:

$$(1 - \lambda)a_i + \lambda b_i \in R_i$$

Un cuantizor vectorial este politopal dacă este regulat și dacă partițiile  $P_i$  ale spațiului  $P_k$  sunt limitate de hiperplane în spațiul  $P_k$ .

Un cuantizor vectorial constă din două părți: un codor și un decodor, reprezentate în fig. 2.1.

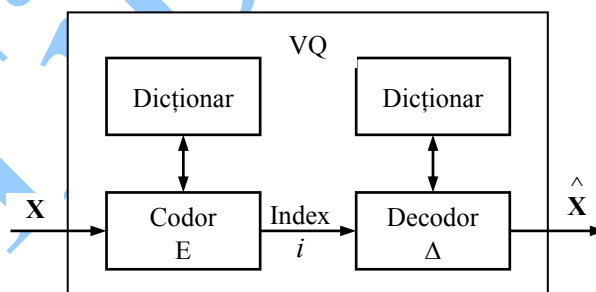


Fig. 2.1. Codorul și decodorul vectorial

Codorul  $E$  realizează maparea spațiului  $R^k$  spre indexul  $I$ , iar decodorul  $\Delta$  realizează maparea inversă:

$$E: P^k \rightarrow I \text{ și } \Delta: I \rightarrow P^k \quad (2.5.)$$

și prin urmare operația de cuantizare vectorială se poate reprezenta ca o succesiune a celor două operații de codare și decodare:

$$\hat{\mathbf{x}} = Q(\mathbf{x}) = D(E(\mathbf{x})) \quad (2.6.)$$

Atât codorul cât și decodorul dispun de câte o copie a dicționarului.

### 3. Cuantizarea optimală a unui vector aleator

Fie  $\mathbf{X}$  un vector aleator, de dimensiune  $k$ , continuu distribuit în spațiul  $P^k$ , adică având funcția densitate de probabilitate  $f_{\mathbf{X}}(\mathbf{x})$  finită și continuă pe  $P^k$ .

În timp ce  $\mathbf{X}$  este continuu distribuit,  $\hat{\mathbf{X}}$  are o distribuție discretă, densitatea sa de probabilitate fiind [FOW96]

$$f_{\hat{\mathbf{X}}}(\mathbf{x}) = \sum_{i=1}^N p_i \delta(\mathbf{x} - \mathbf{y}_i), \text{ unde } p_i \text{ este probabilitatea ca } \hat{\mathbf{X}} = \mathbf{y}_i. \quad (3.1.)$$

Se definește rata de cuantizare, în biți pe simbol prin:

$$R_Q = \frac{1}{k} \max_{f_{\mathbf{X}}} I(\mathbf{X}; \hat{\mathbf{X}}), \quad (3.2.)$$

unde  $I(\mathbf{X}; \hat{\mathbf{X}})$  este informația mutuală între vectorii  $\mathbf{X}$  și  $\hat{\mathbf{X}}$ . Se arată [FOW96] că pentru un cuantizor vectorial aceasta este

$$R_Q = \frac{1}{k} \log_2 N, \text{ unde } N = |\mathcal{C}| \text{ este mărimea dicționarului.} \quad (3.3.)$$

Performanțele unui codor vectorial se pot estima prin măsura distorsiunii medii pe care o introduce cuantizorul, definită prin relația:

$$D_Q = E[d(\mathbf{X}, \hat{\mathbf{X}})] = \int_{R^k} d(\mathbf{X}, \hat{\mathbf{X}}) f_{\mathbf{X}}(\mathbf{X}) d\mathbf{x} = \int_{R^k} d(\mathbf{X}, Q(\mathbf{X})) f_{\mathbf{X}}(\mathbf{X}) d\mathbf{x} \quad (3.4.)$$

în care  $d$  este o funcție de cost.

Cuantizorul optimal pentru un semnal cu o densitate de probabilitate dată este acel cuantizor care va minimiza distorsiunea exprimată prin relația (10). Un cuantizor este optimal dacă îndeplinește două condiții:

a) condiția de cel mai apropiat vecin: cea mai bună cuantizare este aceea care atribuie unui vector cuvântul de cod din dicționar care este cel mai apropiat de vectorul dat, în sensul măsurii distorsiunii, adică  $\hat{\mathbf{x}} = Q(\mathbf{x})$  dacă și numai dacă  $d(\mathbf{x}, \mathbf{y}_i) \leq d(\mathbf{x}, \mathbf{y}_j), \forall j$ . (3.5.)

b) condiția de centroid: pentru o partiție dată a spațiului  $P^k$ , cuvântul de cod asociat cu fiecare partiție trebuie astfel ales, încât să minimizeze eroarea medie față de toți vectorii din acea regiune:

$$\mathbf{y}_i = \arg \min_{\mathbf{y}} E[d(\mathbf{X}, \mathbf{y}) | \mathbf{X} \in R_i] \quad (3.6.)$$

care corespunde definiției centroidului în cazul în care  $d$  este eroarea medie pătratică  $y_i = E[\mathbf{X} | \mathbf{X} \in R_i]$

Funcția de cost nenegativă,  $d(\mathbf{x}, \hat{\mathbf{x}})$  asociată vectorului de intrare  $\mathbf{x}$  și vectorului reconstituit  $\hat{\mathbf{x}}$ , care definește eroarea sau distorsiunea de cuantizare și permite aprecierea performanțelor cuantizorului, poate avea diferite forme, dintre care câteva cazuri particulare, care prezintă interes practic sunt [GG93], [Fow96], [GK82], [Gra90], [ZBL94]:

- eroarea pătratică sau distanța euclidiană, definită prin relația:

$$d(\mathbf{X}, \hat{\mathbf{X}}) = \|\mathbf{X} - \hat{\mathbf{X}}\|^2 = \sum_{i=1}^k (X_i - \hat{X}_i)^2 \quad (3.7.)$$

- distorsiunea definită de o funcție de tip  $d(\mathbf{X}, \hat{\mathbf{X}}) = \sum_{i=1}^k d_m(X_i, \hat{X}_i)$  în

care  $d_m(x, \hat{x})$  este o funcție aditivă, în cele mai multe cazuri de forma

$$d_m(x, \hat{x}) = |x - \hat{x}|^m \quad (3.8.)$$

cu  $m$  pozitiv (pentru  $m = 1$  se regăsește norma  $l_1$  iar pentru  $m = 2$  se regăsește distorsiunea medie pătratică).

- eroarea pătratică ponderată:

$$d(\mathbf{x}, \hat{\mathbf{x}}) = (\mathbf{x} - \hat{\mathbf{x}})^t \mathbf{W} (\mathbf{x} - \hat{\mathbf{x}}) \quad (3.9.)$$

unde  $\mathbf{W}$  este o matrice pătrată de ponderare, simetrică și pozitiv definită. Un caz particular este acela în care matricea  $\mathbf{W}$  este o matrice diagonală, cu elementele  $w_{ii} > 0$ :

$$d(\mathbf{x}, \hat{\mathbf{x}}) = \sum_{i=1}^k w_{ii} (x_i - \hat{x}_i)^2, \quad (3.10.)$$

care permite atribuirea de ponderi diferite diverselor componente ale vectorului. Eroarea ponderată poate fi interpretată ca o eroare neponderată între vectorii  $\mathbf{x}' = \mathbf{A}\mathbf{x}$  și  $\hat{\mathbf{x}}' = \mathbf{A}\hat{\mathbf{x}}$  unde matricea  $\mathbf{A}$  se obține prin factorizarea  $\mathbf{W} = \mathbf{A}^t \mathbf{A}$ . Măsurile  $d(\mathbf{x}, \mathbf{y})$  ale distorsiunii prezentate sunt simetrice față de argumentele  $\mathbf{x}$  și  $\mathbf{y}$ . În unele cazuri, se poate alege o matrice  $\mathbf{W}$  nesimetrică, ca de exemplu  $\mathbf{W}(\mathbf{x}) = \|\mathbf{x}\|^{-2} \mathbf{I}$ , cu  $\mathbf{I}$  matricea identitate (unitate):  $d(\mathbf{x}, \hat{\mathbf{x}}) = \|\mathbf{x} - \hat{\mathbf{x}}\|^2 / \|\mathbf{x}\|^2$ , care atribuie o valoare cu atât mai mare distorsiunii, cu cât semnalul este mai mic [GG93].

- eroarea maximă sau norma  $l_\infty$ , definită prin:

$$d_{\max}(\mathbf{x}, \hat{\mathbf{x}}) = \max_i |x_i - \hat{x}_i|. \quad (3.11.)$$

#### 4. Proiectarea unui cuantizor vectorial

Obținerea unui cuantizor vectorial optim presupune existența unui set de vectori de antrenare,  $T$ , care conține un număr suficient de mare de vectori cu o distribuție apropiată de a vectorilor care urmează a fi codați. Condițiile necesare de cuantizare optimală prezentate anterior nu sunt însă și condiții suficiente, dar stau la baza celui mai cunoscut algoritm de construcție a dicționarului unui cuantizor vectorial, algoritmul LBG (Linde – Buzo – Gray) [LBG80], care presupune următorii pași:

Pasul 1. Fiind dat un dicționar inițial, de dimensiune  $N$ , se partiționează spațiul  $P^k$  folosind regula celui mai apropiat vecin.

Pasul 2. Se calculează centriodul pentru fiecare partiție a  $P^k$  și se creează un nou dicționar, care conține valorile astfel calculate pentru centroizi.

Pasul 3. Se calculează distorsiunea medie. Dacă distorsiunea medie s-a modificat cu mai puțin decât o valoare de prag impusă algoritmul se oprește; dacă nu, se revine la pasul 1 și se reiau calculele.

Se arată că acest algoritm conduce întotdeauna la un cuantizor local optimal.

O altă metodă de a construi dicționarul este bazată pe rețele neuronale artificiale, fiind cunoscută sub numele de învățare Kohonen [Koh88]. Pentru fiecare vector  $\mathbf{X}(n)$  din setul de învățare, se calculează un nou cuvânt de cod definit prin:

$$y_i(n) = y_i(n-1) + \alpha_i(n) N_i(j, n) [X(n) - y_i(n-1)] \quad (4.1.)$$

unde  $\alpha_i(n)$  este rata de învățare, o funcție care scade de la 0 la 1 pe măsură ce învățarea progresează și  $N_i(j, n)$  este o funcție de vecinătate, care exprimă relația de vecinătate a vectorilor din dicționar cu noul vector  $\mathbf{X}(n)$ .

În literatură se prezintă și alte metode de construcție a unui dicționar pentru un cuantizor vectorial: inițializarea aleatoare, relaxarea stimulată [FMF89], desplicarea dicționarului [GG93]. Cuantizarea vectorială după regula celui mai apropiat vecin, ilustrată în fig. 4.1, este definită prin relația:

$$R_i = \{ \mathbf{x} : d(\mathbf{x}, \mathbf{y}_i) \leq d(\mathbf{x}, \mathbf{y}_j), \quad \forall j \in I \} \quad (4.2.)$$

Cuantizorul este complet determinată dacă se cunoaște dicționarul și se definește măsura distorsiunii. Partițiile spațiului  $P^k$  se numesc în acest caz regiuni Voronoi, dacă satisfac condițiile de regulat și politopal [GG93].

Algoritmul de codare se poate rezuma astfel:  
*Pasul 1. Se fac inițializările:  $d = d_0$ ,  $j = 1$  și  $i = 1$ .*  
*Pasul 2. Se calculează  $D_j = d(x, y_j)$ .*  
*Pasul 3. Dacă  $D_j < d$ , se pune  $D_j \rightarrow d$  și  $j \rightarrow i$ .*  
*Pasul 4. Dacă  $j < N$  se pune  $j + 1 \rightarrow j$  și se revine la pasul 2.*  
*Pasul 5. Dacă  $j = N$ , stop. Rezultatul este indexul  $i$ .*

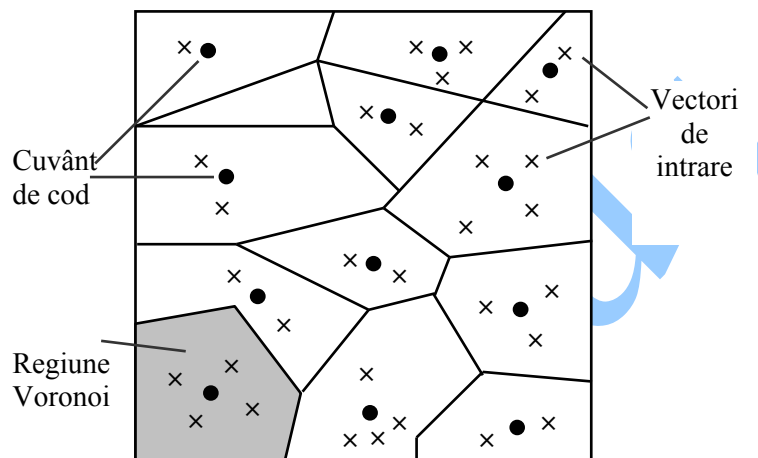


Fig. 4.1. Cuantizarea vectorială

Pentru un dicționar dat, cuantizorul se numește optimal în sens local, dacă o perturbare suficient de mică a unui vector de cod nu conduce la creșterea distorsiunii  $D$ . Un cuantizor este optimal în sens global, dacă nu există un alt cuantizor, cu un dicționar diferit de cel considerat, care să asigure o distorsiune mai mică decât  $D$ .

## Bibliografie

- [FMF89] **J. K. Flanagan, D. R. Morell, R. L. Frost, C. J. Read, B. E. Nelson** – *Vector Quantization Codebook Design generation Using Simulated Annealing*, Proceedings of ICASSP 89, vol. 3, August 1989.
- [Fow96] **J. E. Fowler** – *Adaptive Vector Quantization for the Coding of Nonstationary Sources*, Ph. D. Dissertation, Ohio State University, 1996.

- [Ger82] **A. Gersho** – *On the Structure on Vector Quantizers*, IEEE Trans. Inf. Theory, IT vol. 28, march 1982.
- [GG93] **A. Gersho, R. M. Gray** – *Vector Quantization and Signal Compression*, Kluwer Academic Publishers, 1993.
- [GK82] **R. M. Gray, E. Karnin** – *Multiple Local Optima in Vector Quantizer*, IEEE Trans on Inform. Theory IT vol. 28, march 1982.
- [Gra90] **R. M. Gray** – *Source Coding Theory*, Kluwer Academic Press, Boston, 1990.
- [Koh88] **T. Kohonen** – *Self-Organization and Associative Memory*, Springer Verlag, Berlin, 1988.
- [LBG80] **Z. Linde, A. Buzo, R. M. Gray** – *An Algorithm for Vector Quantizer Design*, IEEE Transaction On Communications, vol. COM-28, January, 1980.
- [ZBL94] **K. Zeger, A. Bist, T. Linder** – *Universal Source Coding with Codebook Transmission*, IEEE Transaction on Communications, vol. 42, Feb.,March, April 1994.