

CAPITOLUL 3

COMPRESIA FĂRĂ PIERDERI PRIN CODARE HUFFMAN

La începutul acestui capitol sunt prezentate câteva preliminarii matematice privind compresia fără pierderi, necesare în analiza și evaluarea procedurilor de codare din această categorie. În cazul transmisiilor la mică distanță sau la puteri de emisie mari efectul perturbațiilor este neglijabil, situații în care se pune numai problema realizării codării surselor discrete de informație de așa manieră încât, pe de o parte, transmisia pe canal să poată fi posibilă, iar pe de altă parte, să se asigure un timp cât mai mic pentru transmiterea informației sursei respective. În acest scop, sursa primară de informație cu alfabetul $S = \{s_1, s_2, \dots, s_N\}$ este adaptată statistic la canalul de transmisiuni, care acceptă simbolurile din mulțimea $X = \{x_1, x_2, \dots, x_M\}$, numită *alfabetul* de la intrarea canalului sau *alfabetul codului* folosit. Fiecărui mesaj s_k , $k = \overline{1, N}$, i se atașează un cuvânt de cod, c_k , format dintr-o succesiune de simboluri $x_k \in X$, de așa manieră încât timpul necesar transmiterii informației sursei primare să fie minim.

3.1. Definirea codurilor nesingulare, unic decodabile și instantanee

Fie $S = \{s_1, s_2, \dots, s_N\}$ mulțimea mesajelor unei surse discrete de informație, $X = \{x_1, x_2, \dots, x_M\}$ alfabetul codului și $C = \{c_1, c_2, \dots, c_M\}$, mulțimea cuvintelor de cod. Prin operația de codare se realizează bijecția dintre mesajele $s_k \in S$ și cuvintele de cod $c_k \in C$.

Prin definiție, un cod se numește *nesingular*, dacă toate cuvintele de cod sunt distințe.

Prin definiție, un cod se numește *unic decodabil*, dacă fiecarei succesiuni de simboluri recepționate îi corespunde o singură succesiune de mesaje ale sursei primare S .

Pentru fixarea ideilor, se consideră o sursă discretă de informație $S = \{s_1, s_2, s_3, s_4\}$ și alfabetul codului $X = \{0,1\}$. Dacă mulțimea cuvintelor de cod este $C = \{c_1, c_2, c_3, c_4\}$, cu $c_1 \rightarrow 1$, $c_2 \rightarrow 01$, $c_3 \rightarrow 10$ și $c_4 \rightarrow 11$, codul este nesingular, deoarece toate cuvintele de cod sunt distințe. Dacă, însă, se recepționează secvența 1101, aceasta poate fi interpretată în trei moduri diferite, și anume fie s_4s_2 , fie $s_1s_1s_2$, fie $s_1s_3s_1$, deci codul respectiv nu este unic decodabil.

O posibilitate de obținere a codurilor unic decodabile ar fi utilizarea unui simbol special în alfabetul codului, care să marcheze fie începutul fiecărui cuvânt de cod, fie sfârșitul acestuia. De exemplu, dacă simbolul α marchează sfârșitul fiecărui cuvânt de cod, atunci la recepționarea secvenței $11\alpha 01\alpha$ în condițiile exemplului considerat, se decide că s-a transmis succesiunea mesajelor s_4s_2 , codul devenind astfel unic decodabil.

Datorită ușurinței cu care se pot genera două stări, notate simbolic cu 0, respectiv 1, alfabetul codului este format numai din aceste două simboluri. De aceea, se pune problema de a se întocmi coduri unic decodabile folosind alfabetul binar $X = \{0,1\}$.

Considerând aceeași sursă discretă, ce poate furniza patru mesaje și un alfabet de cod binar, se presupun următoarele două coduri codul A , în care $s_1 \rightarrow c_1 \rightarrow 0$, $s_2 \rightarrow c_2 \rightarrow 10$, $s_3 \rightarrow c_3 \rightarrow 110$, $s_4 \rightarrow c_4 \rightarrow 1110$ și codul B , în care $s_1 \rightarrow c_1 \rightarrow 0$, $s_2 \rightarrow c_2 \rightarrow 01$, $s_3 \rightarrow c_3 \rightarrow 011$, $s_4 \rightarrow c_4 \rightarrow 0111$. Atât codul A , cât și codul B sunt unic decodabile, deoarece în cazul codului A un zero marchează sfârșitul fiecărui cuvânt de cod, în timp ce în cazul codului B un zero marchează începutul fiecărui cuvânt de cod. Deși ambele coduri sunt unic decodabile, între acestea există o diferență importantă în cazul codului A , decodarea (interpretarea) fiecărui cuvânt de cod se poate realiza odată cu recepționarea integrală a acestuia, în timp ce în cazul codului B decodarea fiecărui cuvânt de cod trebuie să mai aștepte un timp, până la recepționarea primului simbol din cuvântul următor.

Pentru a stabili diferența dintre cele două coduri, este necesar să se introducă noțiunea de prefix a unui cuvânt de cod.

Prin definiție, succesiunea $x_{i_1}x_{i_2}\cdots x_{i_k}$, este *prefix* al cuvântului de cod $c_i \rightarrow x_{i_1}x_{i_2}\cdots x_{i_m}$, dacă $k \leq m$.

Prin definiție, un cod se numește *instantaneu*, dacă nici un cuvânt de cod nu este prefix pentru celelalte cuvinte de cod.

În cazul codului B , cuvântul de cod c_1 , este prefix al cuvintelor c_2 , c_3 și c_4 , cuvântul de cod c_2 este prefix al cuvintelor c_3 și c_4 , iar cuvântul de cod c_3 este prefix pentru c_4 .

Evident, dacă un cod este instantaneu, el este și unic decodabil, reciproc nefiind totdeauna adevărată.

Pentru a stabili dacă un cod este instantaneu, i se atașează graful arborescent. În general, dacă alfabetul codului este $X = \{x_1, x_2, \dots, x_M\}$, graful arborescent se întocmește astfel se pleacă dintr-un nod inițial, numit rădăcina grafului, care se desface în M ramuri (arce) pe care se alocă arbitrar cele M simboluri x_1, x_2, \dots, x_M din alfabetul codului. Din cele M noduri formate la capetele celor M ramuri se desfac din nou câte M ramuri, pe care se alocă arbitrar literele din alfabetul codului și aşa mai departe.

Cuvintele de cod se formează citind ramurile, plecându-se de la rădăcina grafului arborescent spre nodurile terminale. Dacă toate cuvintele de cod corespund nodurilor terminale în graful arborescent, nici un cuvânt de cod nu este prefix pentru altul și, deci, codul este instantaneu.

Grafurile arborescente pentru codurile A și B sunt date în Fig. 3.1.




Fig. 3.1.a) Graful arborescent al codului instantaneu A; b) Graful arborescent al codului B

3.2. Teorema de existență a codurilor instantanee

Această teoremă stabilește condiția necesară și suficientă de existență a codurilor instantanee, referitoare la lungimile cuvintelor de cod.

Prin definiție, *lungimea* unui cuvânt de cod reprezintă numărul de simboluri din alfabetul codului, din care este format cuvântul respectiv.

Se consideră o sursă discretă de informație, caracterizată de mulțimea mesajelor $S = \{s_1, s_2, \dots, s_N\}$, alfabetul codului $X = \{x_1, x_2, \dots, x_M\}$, mulțimea cuvintelor de cod $C = \{c_1, c_2, \dots, c_N\}$ și mulțimea lungimilor cuvintelor de cod $L = \{l_1, l_2, \dots, l_N\}$.

Un cuvânt de cod c_k este format dintr-o succesiune de l_k simboluri din alfabetul codului, de forma

$$c_k \rightarrow x_i \dots x_j \dots x_l$$

Condiția necesară și suficientă de existență a codurilor instantanee este dată de inegalitatea lui Kraft, de forma

$$\sum_{k=1}^N M^{-l_k} \leq 1 \quad (3.1)$$

unde M este numărul de simboluri din alfabetul codului, N este numărul cuvintelor de cod și l_k - lungimea cuvintelor de cod.

Pentru a demonstra suficiența teoremei de existență, se consideră adevărată relația (3.1) și, pe baza acesteia, se întocmește un cod care se va dovedi instantaneu.

Lungimile l_1, l_2, \dots, l_N ale cuvintelor de cod pot fi distincte sau nu. Fie n_1 numărul cuvintelor de cod formate numai dintr-un singur simbol (lungime egală cu unitatea), n_2 numărul cuvintelor de cod formate din două simboluri (lungime egală cu doi) și așa mai

departe, fie n_l , numărul cuvintelor de cod de lungimea cea mai mare, egală cu l .

Evident

$$\sum_{i=1}^l n_i = N \quad (3.2)$$

Cu aceste notații, rezultă că în inegalitatea (3.1) suma va conține n_1 termeni de forma M^{-1} , n_2 termeni de forma M^{-2} și aşa mai departe, n_l termeni de forma M^{-l} . În consecință, inegalitatea (3.1) se poate scrie, echivalent, sub forma

$$\sum_{i=1}^l n_i M^{-i} \leq 1 \quad (3.3)$$

Înmulțind relația (3.3) cu $M^l \geq 0$, rezultă

$$n_l \leq M^l - n_1 M^{l-1} - \dots - n_{l-2} M^2 - n_{l-1} M \quad (3.4)$$

Neglijând în relația (3.4) termenul $n_l \geq 1$ și împărțind apoi noua relație cu $M \geq 2$, rezultă inegalitatea

$$n_{l-1} \leq M^{l-1} - n_1 M^{l-2} - \dots - n_{l-3} M^2 - n_{l-2} M \quad (3.5)$$

Neglijând în relația (3.5) termenul $n_{l-1} \geq 1$ și împărțind apoi noua relație cu $M \geq 2$, rezultă inegalitatea

$$n_{l-2} \leq M^{l-2} - n_1 M^{l-3} - \dots - n_{l-3} M \quad (3.6)$$

În mod analog, se poate obține un sir de inegalități, ultimele trei fiind de forma

$$n_3 \leq M^3 - n_1 M^2 - n_2 M \quad (3.7)$$

$$n_2 \leq M^2 - n_1 M \quad (3.8)$$

$$n_1 \leq M \quad (3.9)$$

Evident, dacă inegalitatea (3.1) este satisfăcută, cu atât mai mult vor fi satisfăcute inegalitățile (3.4) până la (3.9).

Pe baza acestor inegalități se poate întocmi un cod

instantaneu, după cum urmează:

Se alege arbitrar un număr n_1 de cuvinte de lungime unu, care respectă inegalitatea (3.9). Rămân astfel disponibile $M - n_1$ prefixe formate dintr-un singur simbol, cu care se pot forma cuvinte de lungime egală cu doi, al căror număr este egal cu

$$(M - n_1)M = M^2 - n_1M \quad (3.10)$$

Alegându-se arbitrar dintre acestea n_2 cuvinte ce respectă relația (3.8), rămâne disponibil un număr de prefixe din două simboluri, egal cu $M^2 - n_1M - n_2$, cu care se pot forma cuvinte de lungime egală cu trei, în număr de


$$(M^2 - n_1M - n_2)M = M^3 - n_1M^2 - n_2M \quad (3.11)$$

Dintre acestea, se aleg arbitrar n_3 cuvinte care respectă relația (3.7). În mod analog se formează și celelalte cuvinte.

Deoarece nici un cuvânt nu devine prefix pentru altul, codul astfel întocmit este instantaneu, demonstrându-se astfel suficiența teoremei de existență a codurilor instantanee. Deoarece codurile instantanee formează o subclasă a codurilor unic decodabile, rezultă că s-a demonstrat suficiența teoremei de existență și pentru codurile unic decodabile.

Pentru a demonstra necesitatea teoremei de existență a codurilor instantanee, se pleacă de la aserțiunea: cuvintele unui cod instantaneu pot fi aranjate totdeauna în nodurile terminale ale unui graf arborescent. Fie l cea mai mare lungime a cuvintelor de cod. La nivelul l arborele va avea, evident, un număr de M^l noduri. Fiecare cuvânt de lungime $l_k \leq l$ blochează utilizarea a M^{l-l_k} noduri pe nivelul l . De exemplu, dacă $l=3$, $M=2$, (simbolurile "0" și "1") și se alege un cuvânt de lungime $l_k = 2$, fie acesta $c_k = 01$, atunci pe nivelul $l = 3$ se blochează utilizarea a $2^{3-2} = 2$ noduri, aşa cum este

arătat în figură care urmează.



Deoarece două cuvinte distincte blochează noduri diferite pe nivelul l , rezultă că numărul de noduri blocate pe nivelul l , rezultă că numărul de noduri blocate pe nivelul l este mărginit superior de numărul de noduri de pe acest nivel, adică

$$\sum_{k=1}^N M^{l-l_k} \leq M^l \quad (3.12)$$

Simplificând cu $M^l > 0$, rezultă inegalitatea (3.1), care trebuia demonstrată.

Teorema *fiind de existență*, înseamnă că, dacă lungimile cuvintelor de cod satisfac inegalitatea (3.1), există cel puțin un procedeu de codare prin care să rezulte un cod instantaneu. Aceasta nu înseamnă că orice cod care satisface inegalitatea (3.1) este instantaneu. Teorema stabilește că folosindu-se lungimi ale cuvintelor de cod ce satisfac inegalitatea (3.1), se poate întocmi cel puțin un cod instantaneu și, deci, unic decodabil. Dacă pentru un cod dat este satisfăcută inegalitatea lui Kraft, pentru a decide dacă acesta este instantaneu, i se atașează graful arborescent și, dacă toate cuvintele de cod sunt noduri terminale, se decide că este

instantaneu.

Dacă pentru un cod dat inegalitatea (3.1) nu este satisfăcută, atunci, cu certitudine, codul nu este instantaneu și nici unic decodabil și, prin nici un procedeu de codare care va folosi aceleași lungimi ale cuvintelor de cod, nu se poate întocmi un cod instantaneu sau unic decodabil.

3.3. Lungimea medie a cuvintelor de cod

Pentru o sursă discretă de informație și un alfabet de cod impus, se poate întocmi o mulțime de coduri instantanee sau unic decodabile. În scopul comparării acestora și a alegerii celui sau celor mai bune (eficiente), se consideră drept criteriu de comparație timpul necesar transmiterii informației sursei codate, de mărimea acestui timp fiind legate o serie de cheltuieli. Un cod instantaneu va fi cu atât mai eficient, cu cât timpul necesar transmiterii informației sursei discrete va fi mai mic. Este posibil să se întocmească o multitudine de coduri instantanee de eficiență maximă.

Pentru a compara diverse coduri instantanee, se va defini lungimea medie a cuvintelor de cod, care, aşa cum se va demonstra, este proporțională cu timpul mediu de transmitere a cuvintelor de cod. În felul acesta, se va demonstra că cel mai eficient cod instantaneu care se obține, este cel pentru care lungimea medie a cuvintelor de cod este minimă.

Fie, pentru aceasta, o sursă discretă, completă și fără memorie, caracterizată de distribuția:

$$S : \begin{pmatrix} s_1 & \cdots & s_k & \cdots & s_N \\ p(s_1) & \cdots & p(s_k) & \cdots & p(s_N) \end{pmatrix} \quad (3.13)$$

Fie, de asemenea, mulțimea simbolurilor din alfabetul

codului

$$X = \{x_1, x_2, \dots, x_M\} \text{ și multimea cuvintelor de cod } C = \{c_1, c_2, \dots, c_N\}.$$

Datorită corespondenței bijective dintre $s_k \in S$ și $c_k \in C$, rezultă

$$p(s_k) = p(c_k), \quad (3.14)$$

unde $p(c_k)$ reprezintă probabilitatea cuvântului c_k .

Informația atașată mesajului s_k , notată cu $i(s_k)$, va fi atunci egală cu informația atașată cuvântului c_k , notată cu $i(c_k)$, și se va calcula cu relația clasice

$$i(s_k) = i(c_k) = -\log p(s_k), \quad (3.15)$$

Dacă se notează cu $H(X)$ entropia codului utilizat, atunci, aceasta măsoară informația medie pe un simbol din alfabetul codului.

Fie $H(S)$ entropia sursei ce urmează a fi codată, adică informația medie pe un mesaj.

Dacă l_1, l_2, \dots, l_N sunt lungimile cuvintelor de cod, lungimea medie a acestora se calculează cu relația

$$\bar{l} = \sum_{k=1}^N p(s_k) l_k \quad (3.16)$$

Pe de altă parte este evident că numărul mediu de simboluri ale unui cuvânt de cod, adică \bar{l} , este dat de raportul dintre informația medie pe cuvânt, $H(S)$, și informația medie pe un simbol constituent, adică

$$\bar{l} = \frac{H(S)}{H(X)} \quad (3.17)$$

Dacă se ține cont de (1.12) și (3.16), relația (3.17) se poate scrie

scrie echivalent sub forma

$$\sum_{k=1}^N p(s_k)l_k = \frac{-\sum_{k=1}^N p(s_k)\log p(s_k)}{H(X)} \quad (3.18)$$

sau

$$\sum_{k=1}^N p(s_k)[l_k H(X) + \log p(s_k)] = 0 \quad (3.19)$$

O condiție suficientă, dar nu întotdeauna necesară, pentru satisfacerea relației (1.19) este ca

$$l_k = -\frac{\log p(s_k)}{H(X)} \quad (3.20)$$

Dacă se notează cu $\bar{\tau}$ durata medie de transmitere a unui simbol din alfabetul codului X, rezultă că durata de transmitere T_k a cuvântului de cod c_k , de lungime l_k , se poate determina cu relația

$$T_k = \bar{\tau} \cdot l_k \quad (3.21)$$

Duratele T_k , $k = \overline{1, N}$, de transmitere a cuvintelor de cod, determină o nouă variabilă aleatoare discretă, ce poate lua valori cu probabilitățile $p(s_k) = p(c_k)$ și, deci, durata medie de transmitere a unui cuvânt de cod este

$$\bar{T} = \sum_{k=1}^N T_k p(s_k) = \bar{\tau} \cdot \sum_{k=1}^N p(s_k) l_k \quad (3.22)$$

Comparând relațiile (3.16) și (3.22), rezultă

$$\bar{T} = \bar{\tau} \cdot \bar{l} \quad (3.23)$$

adică durata medie de transmitere a cuvintelor va fi cu atât mai mică, cu cât lungimea medie a acestora va fi mai mică.

Mărirea eficienței transmisiunii se poate, deci, obține selectând acel cod instantaneu care asigură o lungime medie minimă

a cuvintelor de cod.

Eficiența transmisiunii poate fi definită, dacă există o margine inferioară a lungimii medii, \bar{l} , a cuvintelor de cod.

Din relația (3.17) rezultă că micșorarea lui \bar{l} se poate realiza fie prin micșorarea entropiei sursei ce urmează a fi codată, fie prin mărirea entropiei codului, adică mărirea informației medii pe un simbol din alfabetul codului.

Deoarece entropia sursei $H(S)$ nu poate fi modificată fără alterarea sursei initiale, rezultă că singura posibilitate pentru micșorarea lungimii medii a cuvintelor de cod rămâne mărirea entropiei codului printr-o codare adecvată.

Notând cu \bar{l}_{\min} , lungimea medie minimă posibilă a cuvintelor de cod, se poate scrie relația

$$\bar{l}_{\min} = \frac{H(S)}{\max[H(X)]} \quad (3.24)$$

Deoarece în urma codării sursei S , utilizarea simbolurilor din alfabetul codului X depinde, în general, de unul sau mai multe simboluri folosite anterior, rezultă că, în general, sursa secundară X este o sursă cu memorie. La limită, când sursa secundară X devine fără memorie și simbolurile acesteia sunt folosite echiprobabil, adică

$$p(x_1) = p(x_2) = \dots = p(x_M) = \frac{1}{M}, \quad (3.25)$$

rezultă marginea superioară a entropiei sursei secundare X egală cu $\log M$ și, deci, marginea inferioară a lungimii medii a cuvintelor de

cod este $\frac{H(S)}{\log M}$.

În general, se poate scrie sirul de inegalități

$$\bar{l} \geq \bar{l}_{\min} \geq \frac{H(S)}{\log M} \quad (3.26)$$

În cazul particular, frecvent folosit în aplicații, al codurilor binare, $M=2$, caz în care relația (3.26) devine

$$\bar{l} \geq \bar{l}_{\min} \geq H(S) \quad (3.27)$$

Cu alte cuvinte, în cazul codurilor binare instantanee nu se pot obține lungimi medii ale cuvintelor de cod mai mici decât entropia sursei ce urmează a fi codată.

3.4. Eficiență și redundanță unui cod

Prin definiție, se numește *eficiență* unui cod și va fi notată cu η , raportul dintre marginea inferioară a lungimii medii a cuvintelor de cod și lungimea medie a acestora, adică

$$\eta = \frac{H(S)}{\bar{l}} = \frac{H(S)}{\bar{l} \log M} \quad (3.28)$$

Înlocuind (3.20) în relația (3.28), rezultă o relație echivalentă de calcul pentru eficiență unui cod instantaneu, și anume

$$\eta = \frac{H(X)}{\log M} \quad (3.29)$$

Prin definiție, se numește *redundanță* unui cod și va fi notată cu ρ , mărimea complementară eficienței, adică

$$\rho = 1 - \eta \quad (3.30)$$

Din relația (3.29) rezultă că valoarea maximă a eficienței este $\eta = 1$.

Prin definiție, un cod se numește *absolut optimal*, dacă eficiența acestuia este maximă.

În cazul codului absolut optimal, din relația (3.28) rezultă

$$H(S) = \bar{l} \log M \quad (3.31)$$

Înlocuind în această relație $H(S)$ și \bar{l} cu relațiile lor de calcul, rezultă

$$\sum_{k=1}^N p(s_k) [l_k \log M + \log p(s_k)] = 0 \quad (3.32)$$

O condiție suficientă pentru satisfacerea acestei relații este

$$l_k \log M + \log p(s_k) = 0 \quad (3.33)$$

Din (3.33) rezultă

$$p(s_k) = M^{-l_k} \quad (3.34)$$

Sumând după k de la 1 la N în relația (3.34), se obține

$$\sum_{k=1}^N M^{-l_k} = \sum_{k=1}^N p(s_k) = 1, \quad (3.35)$$

adică în cazul codurilor absolut optimale inegalitatea lui Kraft devine egalitate. În acest caz mesajele trebuie furnizate cu probabilitățile date de relația (3.34).

3.5. Teorema codării surselor discrete, complete și fără memorie pe canale neperturbate

S-a demonstrat în paragraful precedent că, dacă fiecare mesaj al unei surse discrete, complete și fără memorie este furnizat cu probabilitatea data de relația (3.34), se poate obține un cod absolut optimal. Logaritmând în bază doi această relație, rezultă

$$l_k = -\frac{\log p(s_k)}{\log 2} \quad (3.36)$$

Conform definiției lungimii cuvintelor de cod, rezultă că

numai în cazul codurilor absolut optimale raportul $-\frac{\log p(s_k)}{\log M}$ este

un număr întreg pozitiv, ce poate fi considerat egal cu lungimea cuvântului de cod c_k .

În general, sursa discretă de informație își furnizează mesajele cu diverse probabilități care nu respectă relația (3.34) și, deci, raportul $-\frac{\log p(s_k)}{\log M}$ nu mai este un număr întreg. În acest

caz, lungimile cuvintelor de cod, l_k , $k = \overline{1, N}$, se aleg numerele întregi pozitive care respectă dubla inegalitate

$$-\frac{\log p(s_k)}{\log M} \leq l_k < -\frac{\log p(s_k)}{\log M} + 1 \quad (3.37)$$

Alegând astfel lungimile cuvintelor de cod, se poate demonstra că inegalitatea lui Kraft este satisfăcută, deci, cu astfel de lungimi se poate întocmi totdeauna un cod instantaneu.

Într-adevăr, din prima inegalitate a relației (3.27) rezultă

$$M^{-l_k} \leq p(s_k) \quad (3.38)$$

Sumând după k , de la $k=1$ la $k=N$ și ținând cont că sursa discretă de informație este completă, rezultă

$$\sum_{k=1}^N M^{-l_k} \leq \sum_{k=1}^N p(s_k) = 1 \quad (3.39)$$

Multiplicând relația (3.37) cu $p(s_k) > 0$ și apoi sumând după k , de la $k=1$ la $k=N$, rezultă

$$\begin{aligned} \frac{-\sum_{k=1}^N p(s_k) \log p(s_k)}{\log M} &\leq \sum_{k=1}^N p(s_k) \gamma_k < \\ &< \frac{-\sum_{k=1}^N p(s_k) \log p(s_k)}{\log M} + \sum_{k=1}^N p(s_k) \end{aligned} \quad (3.40)$$

Ținând cont de (3.18), (3.19) și de faptul că totdeauna sursele discrete de informație sunt complete, relația (3.40) devine

$$\frac{H(S)}{\log M} \leq \bar{l} < \frac{H(S)}{\log M} + 1 \quad (3.41)$$

Relația (3.41) este adevărată pentru orice sursă S discretă, completă și fără memorie, deci va fi adevărată și pentru extensia sa de ordinul m .

Notând cu $H(S^m)$ entropia extensiei de ordinul m și cu \bar{l}_m , lungimea medie a cuvintelor de cod corespunzătoare mesajelor compuse σ_k ale extensiei de ordinul m , relația (3.41) se poate scrie sub forma

$$\frac{H(S^m)}{\log M} \leq \bar{l}_m < \frac{H(S^m)}{\log M} + 1 \quad (3.42)$$

Așa cum s-a demonstrat în Capitolul 1,

$$H(S^m) = mH(S) \quad (3.43)$$

Ținând cont de (3.43), relația (3.42) devine

$$\frac{H(S)}{\log M} \leq \frac{\bar{l}_m}{m} < \frac{H(S)}{\log M} + \frac{l}{m} \quad (3.44)$$

Pe de altă parte

$$\frac{\bar{l}_m}{m} = \bar{l} \quad (3.45)$$

deoarece un mesaj compus este format dintr-o succesiune de m mesaje ale sursei inițiale S .

Din (3.44) și (3.45) rezultă că, la limită, când $m \rightarrow \infty$, lungimea medie a cuvintelor de cod atinge marginea inferioară a lungimii medii a cuvintelor de cod, adică

$$\bar{l} = \frac{H(S)}{\log M} \quad (3.46)$$

obtinându-se astfel un cod absolut optimal.

Conform acestei teoreme, rezultă că, efectuându-se codări pe extensii ale unei surse discrete de informație, se pot obține lungimi medii ale cuvintelor de cod cu atât mai mici, cu cât ordinul extensiei este mai mare. La limită, când ordinul extensiei tinde la infinit, se obține lungimea medie cea mai mică posibilă a cuvintelor de cod, egală cu marginea inferioară a acestora.

În practică nu se poate coda extensia de ordinul m a sursei primare, când m tinde la infinit. Ordinul extensiei va avea totdeauna o valoare finită și, cu cât ordinul extensiei este mai mare, cu atât complexitatea instalației de codare crește. Mai mult, de la o anumită valoare a ordinului extensiei, creșterea ordinului în continuare va duce la scăderi nesemnificative ale lungimii medii a cuvintelor de cod, astfel că nu se mai justifică prețul de cost ridicat, dictat de creșterea complexității instalației de codare. Din această cauză, în practică, în multe situații reale, se realizează codări pe mesaje individuale, utilizându-se procedee de codare care conduc la coduri instantanee de eficiență cât mai ridicată, adică acele care conduc spre lungimi medii ale cuvintelor de cod cele mai mici posibile. Dintre procedeele de codare posibile s-au impus, procedeul de codare Huffman, procedeul de codare binară Shannon – Fano și codarea aritmetică.

3.6. Procedeu de codare binară Huffman statică

Acest procedeu se bazează pe ideea de a partiționa mulțimea mesajelor sursei $S = \{s_1, s_2, \dots, s_N\}$ în submulțimile S_0 și S_1 , astfel încât suma probabilităților mesajelor incluse în S_0 să fie cât mai apropiată de suma probabilităților mesajelor incluse în S_1 . La rândul lor, submulțimile S_0 și S_1 pot fi partiționate în submulțimile S_{00} și S_{01} , respectiv S_{10} și S_{11} astfel încât suma probabilităților mesajelor incluse în cele patru submulțimi să fie cât mai apropiate posibil. Procedeul se continuă în mod similar până când se obțin submulțimi ce conțin un singur mesaj.

În felul acesta, pentru orice distribuție a sursei S ce urmează a fi codată se va obține un cod compact, adică lungimi medii ale cuvintelor de cod ce nu mai pot fi micșorate prin nici un alt procedeu de codare.

Pentru ca partițiile să satisfacă condițiile menționate, se procedează astfel:

1) Se ordonează mulțimea mesajelor sursei S în ordinea descrescătoare a probabilităților, obținându-se astfel mulțimea ordonată $R_0 = \{s_1, s_2, \dots, s_N\}$, cu $p(s_1) \geq p(s_2) \geq \dots \geq p(s_N)$, cu schimbarea eventuală a indicilor mesajelor pentru realizarea ordonării respective;

2) Se reunesc ultimele două mesaje (de probabilitățile cele mai mici) într-un nou mesaj, notat cu r_1 , căruia i se alocă o probabilitate egală cu suma probabilităților mesajelor componente. Se ordonează din nou mesajele în ordinea descrescătoare a probabilităților, formându-se astfel prima sursă restrânsă $R_1 = \{s_1, s_2, \dots, r_1, \dots\}$, cu $p(s_1) \geq p(s_2) \geq \dots \geq p(r_1) \geq \dots$.

3) Se reunesc ultimele două mesaje din sursa restrânsă R_1 într-un nou mesaj r_2 , de probabilitate egală cu suma probabilităților mesajelor componente. Se ordonează mesajele în ordine descrescătoare, formându-se astfel sursa restrânsă R_2 . În mod analog, din R_2 se formează sursa restrânsă R_3 și aşa mai departe, până când se obține o sursă restrânsă formată numai din două mesaje, $R_n = \{r_n, r_{n-1}\}$, cu $p(r_n) \geq p(r_{n-1})$. De fapt, r_n va fi S_0 și r_{n-1} va fi S_1 sau invers.

Din modul de formare a surselor restrânse R_i , rezultă că multimea S a mesajelor poate fi partitioanată în două submulțimi r_n și r_{n-1} astfel încât probabilitățile $p(r_n)$ și $p(r_{n-1})$ sunt cele mai apropiate posibil. La rândul lor, submulțimile r_n și r_{n-1} , pot fi partitioionate în alte două submulțimi, de probabilitățile cele mai apropiate posibil. Partiționările se continuă până se obțin submulțimi care conțin un singur mesaj.

4) Cuvintele de cod corespunzătoare fiecărui mesaj se obțin astfel:

- submulțimii r_n i se alocă simbolul "0" (sau "1");
- submulțimii r_{n-1} , i se alocă simbolul "1" (sau "0");
- la fiecare partiționare se alocă arbitrar celor două submulțimi "0" sau "1", operația continuându-se până se obțin submulțimi ce conțin un singur mesaj s_k , $k = \overline{1, N}$.

Deoarece alocarea lui "0" și "1" este arbitrară la fiecare partiționare, rezultă că unei surse S i se pot atașa o multitudine de coduri instantanee, toate, însă, având aceeași lungime medie a cuvintelor de cod, care nu mai poate fi micșorată prin nici un alt procedeu de codare a mesajelor luate individual.

Dacă sursa primară S poate furniza N mesaje, atunci submulțimea restrânsă R_1 , va avea $N-1$ mesaje, submulțimea restrânsă R_2 va conține $N-2$ mesaje și aşa mai departe, ultima submulțime restrânsă R_n va conține $N-n$ mesaje, care sunt r_n și r_{n-1} , adică se poate scrie:

$$N-n=2 \Rightarrow n=N-2 \quad (3.47)$$

Dacă submulțimii r_n î se alocă simbolul "0" și submulțimii r_{n-1} simbolul "1", celor $N-2$ partilionări putându-li-se aloca arbitrar "0" sau "1", rezultă un total de 2^{N-2} posibilități de codare. Dacă, însă, submulțimii r_n î se alocă simbolul "1", iar submulțimii r_{n-1} simbolul "0", mai rezultă 2^{N-2} posibilități de codare. Rezultă, deci, că prin acest procedeu de codare se pot realiza $2^{N-2} + 2^{N-2} = 2^{N-1}$ coduri instantanee, toate având toate aceeași lungime medie a cuvintelor de cod.

Prin definiție, se numește cod compact, codul care realizează lungimea medie minimă a cuvintelor de cod. Deoarece prin procedeul de codare Huffman se obține cea mai mică lungime medie a cuvintelor de cod, înseamnă că prin acest procedeu se obțin coduri instantanee compacte. Evident, un cod absolut optimal este și compact, reciproca nefiind totdeauna valabilă.

Exemplul 3.1.

Se presupune sursa discretă de informație caracterizată de distribuția:

$$S: \begin{pmatrix} s_1 & s_2 & s_3 & s_4 & s_5 & s_6 \\ 0,1 & 0,2 & 0,3 & 0,15 & 0,05 & 0,2 \end{pmatrix}.$$

Codarea binară Huffman a acestei surse se poate realiza astfel:




Fig. 3.2. Schema de codare pentru exemplul 3.1

Graful și cuvintele de cod corespunzătoare codării efectuate sunt date în Fig. 3.3.




Fig. 3.3. Graful corespunzător codului

3.6.1. Coduri Huffman de dispersie minimă

Codurile Huffman de dispersie minimă se obțin când la

reordonarea sursei restrânse, simbolul compus se plasează pe poziția cea mai de sus posibil în sursa restrânsă. În felul acesta cuvântul de cod atribuit simbolului compus va avea cea mai mică lungime posibilă. Cum acest cuvânt va deveni prefix pentru simbolurile constituente, cuvintele de cod corespunzătoare acestora vor avea o lungime cu o unitate mai mare decât lungimea prefixului, deci și acestea vor rezulta de lungime minimă. Ca urmare, diferențele dintre lungimile cuvintelor de cod devin minime, ceea ce va conduce, evident, și la o dispersie minimă.

Pentru fixarea ideilor, se presupune sursa discretă de informație caracterizată de distribuția:

$$S: \begin{pmatrix} s_1 & s_2 & s_3 & s_4 & s_5 \\ 0,2 & 0,4 & 0,2 & 0,1 & 0,1 \end{pmatrix}$$

Pentru această sursă se efectuează codarea Huffman, plasând întâi mesajele sursei restrânse pe pozițiile cele mai jos posibile în listă și apoi pe pozițiile cele mai de sus posibile.

În primul caz rezultă schema de codare din Fig. 3.4, iar graful și cuvintele de cod ca în Fig. 3.5.




Fig. 3.4. Schema de codare




Fig. 3.5. Graful și cuvintele de cod

Pentru acest cod, lungimea medie și dispersia sunt:

$$\bar{l} = 0,2 \cdot 2 + 0,4 \cdot 1 + 0,2 \cdot 3 + 0,1 \cdot 3 + 0,1 \cdot 4 = 2,2 \text{ biți/mesaj}$$

$$\sigma_l^2 = \sum_{i=1}^5 (l_i - \bar{l})^2 = 0,2^2 + 1,2^2 + 0,8^2 + 1,8^2 + 1,8^2 = 8,6$$

Pentru cazul în care în codarea Huffman mesajele sursei restrânse se plasează pe pozițiile cele mai de sus în listă, se obține schema de codare din Fig. 3.6 și graful și cuvintele de cod ca în Fig. 3.7.




Fig. 3.6. Schema de codare




Fig. 3.7. Graful și cuvintele de cod

Pentru acest cod, lungimea medie este, evident, aceeași, în timp ce dispersia devine

$$\sigma_2^2 = \sum_{i=1}^5 \left(l_i - \bar{l} \right)^2 = 0,2^2 + 0,2^2 + 0,2^2 + 0,8^2 + 0,8^2 = 1,4$$

Deși din punct de vedere informațional, cele două coduri sunt identice, în practică se preferă folosirea celor de dispersie minimă, din motive de transmisie.

De exemplu, dacă se dorește să se transmită mesaje ale sursei cu o viteză de 10.000 mesaje/sec., este necesar un canal cu capacitatea de 22.000 biți/sec. Deoarece viteza de generare a bițiilor oscilează în jurul valorii de 22.000 biți/sec., funcție de succesiunea de mesaje furnizate la un moment dat, ieșirea sursei este încărcată într-un buffer. Dacă, de exemplu, sursa generează la un moment dat șiruri de mesaje s_4 și s_5 mai multe secunde, pentru primul cod se generează 40.000 biți/sec. și în fiecare secundă ar trebui un buffer de capacitate de 18.000 biți. Cu al doilea cod se generează 30.000 biți/sec. și bufferul ar trebui să aibă capacitatea de 8.000 biți. Dacă se transmit șiruri de mesaje s_2 , cu primul cod se generează 10.000 biți/sec. și canalul nu e folosit la capacitatea sa, rămânând un deficit de 12.000 biți/sec., pe când cu al doilea cod se generează 20.000

biți/sec., deficitul existent în exploatarea canalului fiind numai de 2.000 biți/sec. Așadar, din motive de transmisie este mai rezonabil să se alege al doilea cod decât primul.

3.6.2. Procedeul de codare binară Shannon – Fano

Acest procedeu se aplică de obicei în cazurile particulare în care probabilitățile de furnizare ale mesajelor sunt puteri întregi pozitive ale lui $(1/2)$, adică, de forma:

$$p(s_k) = \left(\frac{1}{2}\right)^{l_k} = 2^{-l_k}, \quad (\forall) k = \overline{1, N} \quad (3.48)$$

unde l_k este un număr întreg pozitiv.

Dacă relația (3.48) este satisfăcută, mulțimea $S = \{s_1, s_2, \dots, s_N\}$ a mesajelor sursei discrete de informație ce urmează a fi codată poate fi partionată în două submulțimi S_0 și S_1 , astfel încât suma probabilităților mesajelor incluse în S_0 , notată cu $p(S_0)$, să fie egală cu suma probabilităților mesajelor incluse în S_1 , notată cu $p(S_1)$. Sursa S fiind totdeauna completă, se poate scrie:

$$\left. \begin{array}{l} p(S_0) = p(S_1) \\ p(S_0) + p(S_1) = 1 \end{array} \right\} \rightarrow p(S_0) = p(S_1) = \frac{1}{2} = 2^{-1} \quad (3.49)$$

Submulțimile S_0 și S_1 se pot partiona la rândul lor în S_{00} și S_{01} , respectiv în S_{10} și S_{11} , astfel încât suma probabilităților mesajelor incluse în cele patru submulțimi să fie aceeași, adică se poate scrie relația:

$$p(S_{00}) = p(S_{01}) = p(S_{10}) = p(S_{11}) = \left(\frac{1}{2}\right)^2 = 2^{-2} \quad (3.50)$$

Se procedează în mod analog până se obțin submulțimi care conțin un singur mesaj. Se observă că fiecare submulțime are suma probabilităților mesajelor incluse egală cu o putere întreagă a lui $(1/2)$. Puterea întreagă este egală cu numărul indicilor submulțimii respective. Dacă submulțimea conține un singur mesaj, s_k , și are un număr de indici egal cu l_k , atunci se poate scrie:

$$p(s_k) = \left(\frac{1}{2}\right)^{l_k} = 2^{-l_k} \quad (3.51)$$

de unde rezultă necesitatea ca sursa S ce urmează a fi codată să-și furnizeze mesajele cu probabilități egale cu $1/2$ la o putere întreagă, pozitivă.

Sursa fiind completă, se poate scrie:

$$\sum_{k=1}^N p(s_k) = 1 \quad (3.52)$$

Înlocuind (3.51) în (3.52), rezultă:

$$\sum_{k=1}^N 2^{-l_k} = 1, \quad (3.53)$$

ceea ce înseamnă că inegalitatea lui Kraft (3.1) devine în acest caz egalitate.

Cuvintele de cod se vor obține, atunci, astfel:

1. Se atribuie simbolul "0" submulțimii S_0 și simbolul "1" submulțimii S_1 , (sau invers), astfel că toate cuvintele corespunzătoare mesajelor incluse în S_0 vor începe cu "0" și toate cuvintele corespunzătoare mesajelor incluse în S_1 , vor începe cu "1" (sau invers);

2. Se alocă submulțimilor S_{00} și S_{10} ca al doilea mesaj "0", iar submulțimilor S_{01} și S_{11} ca al doilea mesaj "1" (sau invers). În felul acesta, cuvintele de cod corespunzătoare mesajelor incluse în

S_{00} vor începe cu 00, cuvintele de cod corespunzătoare mesajelor incluse în S_{10} vor începe cu 10 și aşa mai departe, cuvintele de cod corespunzătoare mesajelor induse în S_{11} vor începe cu 11.

3. Operația se continuă în același mod, până când în fiecare submulțime rămâne un singur mesaj, căruia îi va corespunde cuvântul de cod format din sirul de indici ai submulțimii respective.

Deoarece la fiecare partitōnare în două submulțimi atribuirea mesajelor "0" și "1" este arbitrară, rezultă că prin acest procedeu se pot obține o multitudine de coduri instantanee, dar toate absolut optimale.

În principiu, procedeul de codare descris s-ar putea aplica în general, adică și atunci când relația (3.53) nu este satisfăcută. În acest caz, partitōnările în submulțimi trebuie efectuate astfel încât suma probabilităților mesajelor incluse în submulțimile respective să fie cât mai apropiate. Atribuind simbolurile "0" și "1" ca în procedeul descris, se obțin totdeauna coduri instantanee.

Cu cât sumele probabilităților mesajelor componente ale submulțimilor respective vor fi mai apropiate, cu atât lungimea medie a cuvintelor de cod va fi mai mică.

Exemplul 3.2.

Se consideră sursa discretă de informație caracterizată de distribuția:

$$S : \begin{pmatrix} s_1 & s_2 & s_3 & s_4 & s_5 & s_6 & s_7 & s_8 \\ 2^{-2} & 2^{-2} & 2^{-3} & 2^{-3} & 2^{-4} & 2^{-4} & 2^{-4} & 2^{-4} \end{pmatrix}.$$

Procedeul de codare binară Shannon - Fano este sintetizat în tabelul de mai jos.

Mesaje	Probabilități	Partiții				Cuvânt de cod
s_1	2^{-2}	0	0			0 0
s_2	2^{-2}		1			0 1
s_3	2^{-3}	1	0	0		1 0 0
s_4	2^{-3}			1		1 0 1
s_5	2^{-4}	1	0	0	0	1 1 0 0
s_6	2^{-4}			1	1	1 1 0 1
s_7	2^{-4}	1		1	0	1 1 1 0
s_8	2^{-4}				1	1 1 1 1

Graful arborescent atașat codului astfel obținut este reprezentat în Fig. 3.8.




Fig. 3.8. Graful arborescent atașat codului din tabel

3.6.3. Lungimea medie a cuvintelor de cod în cazul codului binar Huffman

Se știe că pentru un cod optimal

$$H(S) \leq \bar{l} \leq H(S) + 1 \quad (3.54)$$

Limita superioară din relația (3.54) nu este foarte precisă. În [25] se arată că dacă p_{max} este cea mai mare probabilitate cu care este furnizat un mesaj, atunci pentru $p_{max} < 0,5$, limită superioară pentru codul Huffman este $H(S) + p_{max}$, în timp ce pentru $p_{max} \geq 0,5$, limita superioară este $H(S) + p_{max} + 0,086$.

În aplicațiile în care numărul de mesaje ale sursei este mare, p_{max} este relativ mic și redundanța codului, care este diferența dintre lungimea medie și entropie, exprimată în procente din entropie, este relativ mică. În cazul în care alfabetul sursei este mic și probabilitățile de apariție ale diferitelor mesaje sunt nechilibrate, valoarea probabilității p_{max} poate fi relativ mare și codul Huffman poate deveni ineficient, adică redundanța să reprezinte un procent semnificativ din entropie.

Exemplul 3.3.

Fie o sursă care furnizează mesajele $S = \{s_1, s_2, s_3\}$, cu probabilitățile $p(s_1) = 0,8; p(s_2) = 0,02; p(s_3) = 0,18$. Entropia sursei este de 0,816 biți/mesaj.

Codul Huffman pentru această sursă este dat în Fig. 3.9.




Fig. 3.9. Schema de codare pentru codul din Exemplul 3.3.

Lungimea medie pentru acest cod este 1,2 biți/simbol. Redundanța este 0,384 biți/simbol, aproximativ 47% din $H(S)$. Aceasta înseamnă că pentru a coda această sursă sunt necesari cu 47% mai mulți biți decât minimul necesar. Uneori, pentru micșorarea redundanței se realizează codarea Huffman pe extensia sursei inițiale. Astfel, dacă se consideră extensia de ordinul 2 a sursei precedente, se obțin $3^2=9$ mesaje. Dacă se efectuează codarea Huffman a sursei extinse, se obțin cuvintele de cod din Tabelul 3.1.

Tabelul 3.1.

Mesaj compus	Probabilitate	Cuvânt de cod
s ₁ s ₁	0,64	0
s ₁ s ₂	0,016	10101
s ₁ s ₃	0,144	11
s ₂ s ₁	0,016	101000
s ₂ s ₂	0,0004	101000
s ₂ s ₃	0,0036	1010011
s ₃ s ₁	0,1440	100
s ₃ s ₂	0,0036	10100100
s ₃ s ₃	0,0324	1011

Pentru acest cod, lungimea medie este $\bar{l}_e = 1,7516$ biți/mesaj.

Cum un mesaj al sursei extinse este format din două mesaje ale alfabetului original, rezultă că lungimea medie, \bar{l} , exprimată în funcție de alfabetul original este $\bar{l}=0,8758$, redundanța este de aproximativ 0,06 biți/simbol, adică aproximativ 7% din entropie.

Dacă probabilitățile mesajelor sunt mult neechilibrate, atunci ar putea fi necesară codarea pe extensii de ordin superior, în scopul scăderii la valori acceptabile ale redundanței. Prin creșterea ordinului extensiei, mărimea alfabetului sursei extinse crește exponențial cu ordinul extensiei și codarea Huffman poate deveni ineficientă din punct de vedere al prețului de cost, caz în care se folosește *codarea aritmetică*, care va fi discutată ulterior.

3.6.4. Procedeul de codare Huffman generalizat

În acest caz, alfabetul codului conține mai mult de două simboluri. Procedeul de codare este asemănător celui din cazul binar, parcurgându-se următoarele etape:

- 1) Se ordonează mesajele sursei ce urmează a fi codată în ordinea descrescătoare a probabilităților;
- 2) Dacă alfabetul codului conține $M \geq 3$ simboluri, se reunesc ultimele M mesaje (de probabilitățile cele mai mici) într-un singur mesaj, căruia i se alocă probabilitatea egală cu suma probabilităților mesajelor componente. Se ordonează din nou mesajele în ordinea descrescătoare a probabilităților, formându-se astfel prima sursă restrânsă R_1 . Procedându-se în mod analog, se formează sursa restrânsă R_2 din R_1 , R_3 din R_2 și aşa mai departe, până când se obține o sursă restrânsă care conține M mesaje. Pentru ca ultima sursă restrânsă să conțină M mesaje cărora să li se aloce arbitrar cele M mesaje din alfabetul codului, înainte de a realiza

restrângerile respective, se face următorul raționament:

- la formarea primei surse restrânse, reunindu-se M mesaje într-un singur mesaj, va rezulta un număr de mesaje egal cu $N - M + 1 = N - (M - 1)$;

- a doua sursă restrânsă va conține, prin reunirea ultimelor M mesaje, un număr de mesaje egal cu $N - 2M + 2 = N - 2(M - 1)$;

- raționându-se în mod analog, după n restrângerii, ultima sursă restrânsă va conține un număr de mesaje egal cu $N - n(M - 1)$, care trebuie să fie egal cu numărul M al mesajelor din alfabetul codului, adică

$$M = N - n(M - 1) \Rightarrow n = \frac{N - M}{(M - 1)} \quad (3.55)$$

Deoarece n (numărul de restrângerii) trebuie să fie un număr întreg pozitiv, se va considera:

$$n_1 = \left\lceil \frac{N - M}{M - 1} \right\rceil \quad (3.56)$$

unde $\lceil m \rceil$ simbolizează cel mai mic număr întreg, mai mare sau egal decât m . Astfel, sursa va trebui să aibă un număr de mesaje N_1 , calculat cu relația

$$N_1 = M + n_1(M - 1) \quad (3.57)$$

- Dacă sursa S ce urmează a fi codată are un număr N de mesaje care nu verifică relația (3.57), se va adăuga la sursa respectivă un număr de mesaje, până când această relație este satisfăcută. Mesajelor adăugate li se vor aloca probabilități nule, astfel că sursa inițială nu va fi alterată, deoarece mesajele de probabilități nule nu vor fi furnizate niciodată.

3) La fiecare partiție în M submulțimi se alocă arbitrar cele M mesaje din alfabetul codului. Deoarece alocarea celor M mesaje din

alfabetul codului se face arbitrar, rezultă că prin acest procedeu va rezulta o multitudine de coduri instantanee, toate cu aceeași lungime medie a cuvintelor de cod, care nu mai poate fi micșorată prin nici un alt procedeu de codare, adică toate codurile astfel obținute vor fi instantanee și compacte.

Exemplul 3.4.

Se presupune sursa discretă de informație caracterizată de distribuția

$$S: \begin{pmatrix} s_1 & s_2 & s_3 & s_4 & s_5 & s_6 \\ 0,1 & 0,2 & 0,3 & 0,15 & 0,05 & 0,2 \end{pmatrix}$$

Dacă alfabetul codului este $X = \{x_1, x_2, x_3\}$, să se realizeze o codare Huffman generalizată.

Înainte de a realiza codarea, se verifică dacă este satisfăcută relația (3.57) care, pentru cazul particular considerat, devine:

$N_1 = 2n_1 + 3$, unde $n_1 = \left\lceil \frac{6-3}{3} \right\rceil = 2$, deci $N_1 = 7$. Va trebui adăugat

un nou mesaj, fie acesta s_7 , de probabilitate nulă, adică $p(s_7) = 0$. Pentru realizarea codării, se procedează după cum se arată în Fig. 3.10.




Fig. 3.10. Schema de codare pentru Exemplul 3.4.

Cuvintele de cod corespunzătoare mesajelor sursei sunt

$$s_1 \rightarrow c_1 \rightarrow x_1 x_3 x_1$$

$$s_2 \rightarrow c_2 \rightarrow x_3$$

$$s_3 \rightarrow c_3 \rightarrow x_2$$

$$s_4 \rightarrow c_4 \rightarrow x_1 x_2$$

$$s_5 \rightarrow c_5 \rightarrow x_1 x_3 x_2$$

$$s_6 \rightarrow c_6 \rightarrow x_1 x_1$$

Graful corespunzător codului este dat în Fig. 3.11.




Fig. 3.11. Graful atașat codului

3.7. Codarea binară Huffman dinamică (adaptivă)

Procedeul de codare binară Huffman descris în paragraful 3.6 necesită cunoașterea probabilităților cu care sursa își furnizează mesajele. În literatura de specialitate această situație este cunoscută și sub denumirea de codare Huffman statică. În cazul în care probabilitățile de furnizare a mesajelor nu sunt cunoscute, se folosește codarea Huffman *dinamică* sau *adaptivă*.

În descrierea codării Huffman dinamice sau adaptive se vor

folosi următoarele notații și noțiuni:

- Nodurile terminale sau externe din graful arborescent se vor numi frunze, corespunzând mesajelor sursei;
- Cuvântul de cod pentru un mesaj se obține parcurgând arborele de la rădăcină la frunza corespunzătoare simbolului. Prin convenție, zero se va aloca unei ramuri din stânga și unu, unei ramuri din dreapta;
- Nodurile de la extremitățile ramurilor care pleacă dintr-un nod reprezentă fișii sau copiii nodului respectiv, numit nod părinte;
- Ponderea unui nod extern este numărul de apariții a simbolului corespunzător frunzei respective până la acel moment;
- Ponderea unui nod intern este suma ponderilor fiilor nodului respectiv;
- Dacă sursa ce urmează a fi codată furnizează n mesaje, în graf există $2n+1$ noduri interne și externe, numerotate în continuare y_1, \dots, y_{2n+1} . Dacă x_j este ponderea nodului cu numărul y_j , trebuie să existe relația $x_1 \leq x_2 \leq \dots \leq x_{2n+1}$;
- Nodurile y_{2j-1} și y_{2j} sunt fișii ai aceluiași nod părinte, iar numărul de ordine al părintelui este mai mare decât y_{2j-1} și y_{2j} .

Ultimele două caracteristici se numesc de *fraternitate* și orice arbore care are această proprietate este un *arbore Huffman*.

În codarea Huffman dinamică, nici emițătorul, nici receptorul nu cunosc statistica sursei la începerea transmisiei, astfel încât arborii de la transmisie și recepție constau dintr-un singur nod corespunzător mesajelor încă netransmise, de pondere zero. Pe parcursul transmisiei, nodurile corespunzătoare mesajelor transmise sunt adăugate arborelui, care este reconfigurat pe baza unui procedeu de actualizare. Înaintea începerii transmiterii se stabilește un cod pentru fiecare mesaj, după cum urmează:

Dacă sursa furnizează mesajele s_1, s_2, \dots, s_N , se determină parametrii e și r , astfel încât $N = 2^e + r$, $0 \leq r < 2^e$. Mesajul s_k este codat prin reprezentarea pe $e+1$ biți a lui $k-1$, dacă $1 \leq k \leq 2r$, în caz contrar, s_k este reprezentarea pe e biți a lui $k-r-1$. De exemplu, pentru $N = 26 \rightarrow r = 10$ și $e = 4 \rightarrow s_1 = 00000$, $s_2 = 00001, \dots, s_{22} = 1011$.

3.7.1. Actualizarea arborelui

Algoritmul de actualizare necesită ca nodurile să fie numerotate într-o ordine stabilită. Cel mai mare număr de nod este al rădăcinii. Cel mai mic se asignează nodului încă netransmis, care este nod gol, (NG).

Mulțimea nodurilor cu aceeași pondere formează un *bloc*. Rolul algoritmului de actualizare este de a păstra proprietatea de *fraternitate* în timpul modificării arborelui, pentru a reflecta ultima estimare a frecvenței de furnizare a mesajului.

Pentru ca procedura de actualizare de la emițător și receptor să opereze cu aceeași informație, arborele de la emițător este actualizat după codarea fiecărui mesaj, iar la recepție arborele este actualizat după decodarea fiecărui mesaj.

Organograma algoritmului de actualizare este prezentată în Fig. 3.12.




Fig. 3.12. Procedura de actualizare pentru algoritmul de codare dinamică Huffman

Procedura de actualizare este următoarea: după ce un mesaj a fost codat la emisie sau decodat la recepție, nodul extern corespunzător mesajului este examinat pentru a vedea dacă are cel mai mare număr de nod din bloc. Dacă nodul extern nu are cel mai mare număr de nod, el este interschimbat cu nodul care are cel mai mare număr din bloc, cu condiția ca acesta să nu fie părintele nodului ce urmează a fi actualizat. Ponderea nodului extern este apoi incrementată. Dacă nu se interschimbă nodurile înaintea incrementării ponderii nodului, este posibil ca ordonarea cerută de proprietățile de fraternitate să fie distrusă. Odată incrementată ponderea nodului, s-a adaptat arboarele Huffman la acel nivel.

Se trece apoi la nivelul următor, prin examinarea nodului părinte al nodului a cărui pondere a fost incrementată, pentru a vedea dacă are cel mai mare număr din bloc. Dacă nu are, este schimbat cu nodul cu cel mai mare număr din bloc. Din nou, face excepție nodul cu cel mai mare număr, dacă acesta este părinte pentru nodul considerat. Odată ce s-a efectuat schimbarea (sau s-a decis că nu este necesară), ponderea nodului părinte este incrementată. Procesul se termină când se ajunge la nodul rădăcină.

Când mesajul ce urmează a fi codat sau decodat apare pentru prima dată, acestuia i se atribuie un nod extern și se atașează un nou nod NG în graf.

Atât nodul extern cât și nodul NG sunt fii al vechiului NG. Cum mesajul corespunzător noului nod extern a apărut o singură dată, acestuia i se atribuie ponderea 1.

Cum vechiul nod NG este părinte pentru noul nod extern, ponderea sa se incrementează cu 1 și se continuă astfel până la rădăcină.




Exemplul 3.5.

Se presupune că se dorește codarea Huffman adaptivă a secvenței $[a\ a\ r\ d\ v\ a]$, care conține 4 din 26 de mesaje posibile, reprezentate de literele mici ale unui alfabet. Pentru codarea acestor mesaje se folosește codul prezentat în paragraful 3.7.

Procesul de actualizare este arătat în Fig. 3.13. Se începe cu nodul NG. Numărul total de noduri este $2 \cdot 26 + 1 = 53$, astfel încât se începe numărătoarea inversă, cu numărul 53 asignat nodului rădăcină. Prima literă ce urmează a se transmite este a . Cum litera nu este în arbore, se transmite a și se adaugă aceasta în arbore. Nodul NG dă naștere unui nou nod NG și unui nod terminal, corespunzător literei a . Ponderea nodului terminal va fi mai mare

decât a nodului NG, astfel încât se asignează numărul 51 nodului NG și 52 nodului terminal corespunzător literei a . Următoarea literă de transmis este tot a . De această dată, codul transmis este 1, deoarece litera este în graf. Nodul corespunzător lui a are cel mai mare număr din bloc (dacă nu se consideră nodul său părinte), aşa încât nu este nevoie să schimbăm nodurile. Se incrementează ponderea nodului extern și a nodului rădăcină. Următoarea literă de transmis este r . Cum litera nu are un nod corespunzător în arbore, se transmite cuvântul de cod pentru nodul NG, care este 0, urmat de indexul lui r . Nodul NG dă naștere unui nou nod NG și unui nod extern corespunzător lui r . Din nou, nu este necesară actualizarea arborelui, ci numai incrementarea corespunzătoare a ponderilor nodurilor. Următoarea literă este d , care, de asemenea, se transmite pentru prima dată. Se transmite codul pentru nodul NG, care este 00, urmat de indexul pentru d . Nodul NG dă iar naștere la două noduri. Încă nu este nevoie de a actualiza arborele. Acestea se schimbă cu transmiterea literei următoare, v , care nu a mai fost întâlnită. S-a transmis codul frunzei goale, 000, urmat de codul pentru litera v . În arbore se adaugă nodurile 45 și 46, cu 46 ca nod terminal pentru v . Se incrementează ponderea nodului extern 46 și a vechiului NG. Se merge la nodul părinte al vechiului NG, adică nodul 49 care nu are cel mai mare număr din bloc, aşa că se schimbă cu 50, care este cel mai mare număr din bloc și se incrementează ponderea acestuia. Se merge la rădăcina nodului 50 care este 51 și care nu are cel mai mare număr din bloc, aşa că se schimbă cu 52, a cărui pondere se incrementează. Se merge la rădăcina nodului 52, adică nodul 53, care este nod rădăcină și se incrementează ponderea acestuia. Urmează mesajul a , care este în graf, aşa încât se transmite 0. Deoarece numărul nodului extern corespunzător lui a este maxim în bloc, se incrementează ponderea acestuia și a părintelui, care este

nod rădăcină.






Fig. 3.13. Arborele Huffman adaptiv, după ce s-a transmis secvența *aardva*
a10r00d000v0

3.7.2. Codarea

Diagrama pentru codare este prezentată în Fig. 3.14. Inițial, arborii de la codare și decodare sunt formați dintr-un singur nod NG. Prin urmare, cuvântul de cod corespunzător primului mesaj ce apare este transmis în clar. După primul mesaj, de fiecare dată când trebuie codat un mesaj ce apare pentru prima dată, se transmite întâi codul pentru nodul NG, care se obține prin parcurgerea arborelui Huffman de la rădăcină la nodul NG.

Aceasta înștiințează receptorul că mesajul al cărui cod urmează nu are încă un nod în arborele Huffman. Codul nodului NG este urmat de codul prestabilit pentru mesaj. Dacă mesajul ce urmează a fi codat are un nod corespunzător în arbore, atunci este transmisă succesiunea de biți obținută prin traversarea arborelui de

la rădăcină la nodul extern corespunzător mesajului.




Figura 3.14. Organigramă pentru codare

Exemplul 3.6.

În Exemplul 3.5 s-a folosit un alfabet de 26 de litere. Pentru a obține codul prestabilit pentru mesaj trebuie găsite valorile pentru e și r , astfel încât $2^e + r = 26$ cu $0 \leq r < 2^e \rightarrow e = 4, r = 10$.

Primul mesaj de codat este a . Cum a este prima literă din alfabet, $k=1$. Deoarece $2 \cdot r = 20 > k = 1$, litera a va fi reprezentarea pe $e+1 = 5$ biți a numărului $k-1 = 1-1 = 0$, adică 00000. Arborele este actualizat după diagrama din Fig. 3.13, nodul gol a dat naștere unui nod extern corespunzător lui a și unui nou nod gol. Nodul extern corespunzător lui a are ponderea 1, iar nodul gol, 0. Nodul intern are ponderea 1 (suma ponderilor fililor). Următorul mesaj este

a. Cum acesta există deja în arbore, cuvântul de cod corespunzător se obține prin traversarea grafului de la rădăcină la nodul corespunzător, în cazul de față este 1.

După transmiterea codului pentru cel de-al doilea *a*, ponderea nodului extern corespunzător acestuia este incrementată la 2, ca și ponderea părintelui.

Al treilea mesaj de transmis este *r*. Cum acesta este la prima apariție, se transmite codul nodului gol, adică 0, urmat de codul lui *r*. (*r*, fiind a optzecea literă din alfabetul de 26 de litere, înseamnă că $k = 18$; deoarece $18 < 2r = 20$, litera *r* va fi reprezentarea binară pe $k+1=4+1=5$ biți a numărului $k-1=18-1=17$, adică 10001). Arborele este actualizat și se continuă cu mesajul *d*. Folosind același procedeu pentru *d*, se transmite codul nodului gol, care este 00 urmat de indexul lui *d*, care este 00011 (*d* fiind a patra literă din alfabet și deoarece $4 < 20$, litera *d* va fi reprezentarea binară pe $k+1=4+1=5$ biți a numărului $k-1=4-1=3$, adică 00011). Următorul simbol, *v*, este al 22-lea în alfabet și fiind mai mare decât 20 se transmite codul pentru nodul gol, 000, urmat de reprezentarea binară pe 4 biți a lui $22-10-1=11$, adică 1011. Următorul mesaj este *a*, pentru care se transmite 0.

Secvența transmisă este:

a 1 0 r 0 0 d 0 0 0 v 0, echivalentă cu

00000	1	0	1001	00	00011	000	1011	0
a	a	gol	r	gol	d	gol	v	a

3.7.3. Decodarea

Organograma pentru decodare este prezentată în Fig. 3.15.




Fig. 3.15. Organigramă pentru decodarea Huffman dinamică

Pe măsură ce este citită secvența binară recepționată, arborele se parcurge într-un mod identic cu cel de la codare.

Odată identificat codul unei frunze din secvența recepționată, se decodează mesajul corespunzător acelei frunze. Dacă frunza este frunză goală, se verifică următorii e biți pentru a vedea dacă rezultă un număr mai mic decât r . Dacă este mai mic, se mai citește un bit pentru a completa codul mesajului. Indexul mesajului se obține adăugând o unitate la numărul zecimal corespunzător secvenței de e sau $e+1$ biți. Odată decodat mesajul, arborele este actualizat și următorul bit recepționat este folosit pentru a porni o nouă parcurgere a arborelui.

Exemplul 3.7.

Să se decodeze secvența codată anterior, 0 0 0 0 0 1 0 1 0 0 0
1 0 0 0 0 0 1 1 0 0 0 1 0 1 1 0.

Inițial arborele de la decodor constă numai dintr-un nod gol, aşa că primul mesaj ce urmează a fi decodat se obține din listă. Se citesc $e=4$ biți, 0000, care corespunde numărului zecimal 0. Deoarece $0 < r = 10$ rezultă că se mai citește un bit, rezultând secvența 00000. Se decodează în zecimal și se adaugă o unitate, astfel indexul simbolului recepționat este 1, care îi corespunde lui a în listă, prin urmare, prima literă decodată este a .

Arborele este actualizat. Următorul bit recepționat este 1, care îi corespunde căii de la rădăcină la nodul extern a , astfel încât al doilea mesaj decodat este tot a .

Următorul bit este 0, care corespunde căii de la rădăcină la nodul gol. Următorii patru biți 1000 corespund numărului zecimal 8, care este mai mic decât 10, astfel încât se mai citește un bit pentru a obține cuvântul 10001, al cărui echivalent zecimal plus o unitate este 18, care este indexul lui r . Se decodează r și se actualizează arborele. Următorii doi biți 00 reprezintă parcurgerea grafului până la frunza goală. Se citesc următorii 4 biți 0001, care corespund lui $1 < 10$, deci se mai citește un bit, adică secvența 00011. Pentru a obține indexul simbolului recepționat din listă, se adaugă o unitate la valoarea zecimală a celor 5 biți. Valoarea indexului este 4, care corespunde simbolului d . Continuând, se obține secvența decodată $a \ a \ r \ d \ v \ a$.

3.8. Aplicații ale codării Huffman

În continuare sunt prezentate câteva aplicații simple ale codării Huffman în compresie, această codare fiind, de obicei, folosită în practică împreună cu alte tehnici de codare.

1. Compresia fără pierderi a imaginilor

Codarea Huffman poate fi folosită în compresia imaginilor digitale, când fiecare pixel poate lua valori dintr-o mulțime finită. În cazul imaginilor monocrome, această mulțime constă din numere întregi de la 0 la 225.

Rezultatele pentru patru imagini de test pentru care s-a aplicat codarea Huffman sunt arătate în Tabelul 3.2 [86].

Tabelul 3.2

Numele imaginii de test	Biți/pixel	Mărimea totală a imaginii(biți)	Raportul de compresie
Sena	6,90	56.525	1,16
Sensin	7,38	60.457	1,08
Pământ	4,78	39.158	1,67
Omaha	7,00	57.488	1,14

În reprezentarea imaginii originale (necompressoate) se folosesc 8 biți/pixel. Imaginea constă din 256 de rânduri a către 256 de pixeli, deci reprezentarea necompressoată folosește 65.536 biți.

Din Tabelul 3.2 se observă că raportul de compresie diferă de la imagine la imagine, obținându-se o reducere de numai aproximativ $\frac{1}{2}$ până la 1bit/pixel, după compresie. Pentru unele

aplicații această reducere este acceptabilă. De exemplu, dacă într-o arhivă există sute de imagini, o reducere de un bit pe pixel salvează mulți megabyți în spațiul discului. În codarea din exemplul considerat nu s-a ținut cont de structura din date, dată de corelația dintre pixeli. Dintr-o inspecție vizuală a imaginii, se poate observa că într-o imagine pixelii sunt corelați cu vecinii lor. Un model grosier pentru determinarea valorii unui pixel poate fi dat de relația $\hat{x}_n = x_{n-1}$, adică valoarea estimată pentru un pixel este egală cu a valoarea pixelului precedent. Secvența reziduală va fi diferența dintre pixelii vecini. Dacă se consideră acest model și se folosește codul Huffman pentru a coda secvența reziduală, rezultatele sunt cele din Tabelul 3.3 [86].

Tabelul 3.3.

Numele imaginii de test	Biți/pixel	Mărimea totală a imaginii (biți)	Raportul de compresie
Sena	3,84	31.472	2,08
Sensin	4,63	37.880	1,73
Pământ	3,92	32.136	2,04
Omaha	6,34	51.986	1,26

După cum se observă, se obține o îmbunătățire a raportului de compresie față de cazul precedent. Rezultatele din Tabelele 3.2 și 3.3 sunt obținute folosind un sistem în doi pași, în unul s-a obținut statistica sursei, iar în al doilea s-a efectuat codarea Huffman. În loc să se folosească sistemul în doi pași, se poate folosi un cod Huffman adaptiv. Rezultatele pentru acesta sunt prezentate în Tabelul 3.4 [86].

Tabelul 3.4.

Nume imagine de test	Biți/pixel	Mărimea totală a imaginii (biți)	Raportul de compresie
Sena	3,93	32,261	2,03
Sensin	4,63	37,896	1,73
Pământ	4,82	39,504	1,66
Omaha	6,39	52,321	1,25

Se observă că diferențele dintre codul Huffman static și cel adaptiv sunt mici. Algoritmul Huffman adaptiv este preferat în sistemele care lucrează on-line sau în timp real, când nu este posibilă cunoașterea prealabilă a statisticii sursei. Acesta, însă, este mai dificil de implementat decât cel static. Aplicația particulară va determina care din cele două este mai convenabil.

2. Compresia textelor

În compresia textelor se folosește frecvent codarea Huffman, deoarece în texte, se folosește un alfabet discret care, într-un domeniu dat, are probabilități relativ staționare. De exemplu, modelul de probabilitate pentru un roman nu va difera semnificativ de modelul de probabilitate pentru alt roman. Similar, modelul de probabilitate pentru un set de programe C nu va difera prea mult de modelul de probabilitate pentru un alt set de programe C.

O îmbunătățire a compresie se poate obține, dacă mai întâi se îndepărtează redundanța din date, materializată în corelația între mesajele din fișier, care este semnificativă în textele literare. De exemplu, în capitolul de față, *Huf* este întotdeauna urmat de *fman*.

3. Compresia audio

Altă clasă de date care se pretează foarte bine pentru compresie este clasa de date audio de pe compact discuri (CD). Semnalul audio pentru fiecare canal stereo este eșantionat la 44,1 kHz și fiecare eșantion este reprezentat pe 16 biți, ceea ce conduce la o cantitate enormă de date stocate pe CD care, pentru a fi transmise, ar necesita un canal cu capacitate semnificativă. Compresia este cu siguranță utilă în acest caz. În Tabelul 3.5 se arată, pentru diverse tipuri de surse audio, mărimea fișierului, entropia, mărimea estimată a fișierului compresat cu codarea Huffman și raportul de compresie rezultat [86].

Tabelul 3.5. Codarea Huffman pe 16 biți a semnalului audio

Numele fișierului	Mărimea originală a fișierului	Entropia (biți)	Mărimea estimată a fișierului compresat(biți)	Raportul de compresie
Mozart	939.862	12,8	725.420	1,30
Cohn	402.442	13,8	349.300	1,15
Mir	884.020	13,7	759.540	1,16

Ca și la alte aplicații, se poate obține o creștere a compresiei, dacă mai întâi este îndepărtată corelația din date. Datele audio pot fi modelate numeric. Se folosește modelul foarte simplu care a fost folosit în exemplul codării imaginii: valoarea estimată a unui eșantion este aceeași cu valoarea eșantionului anterior. Folosind acest model se obține o secvență reziduală. Entropia acestei secvențe diferență este prezentată în Tabelul 3.6 [86].

Tabelul 3.6. Codarea Huffman pe 16 biți a secvenței reziduale audio

Numele fișierului	Mărimea originală a fișierului (bytes)	Entropia diferențială (biți)	Mărimea estimată a fișierului compresat (bytes)	Raportul de compresie
Mozart	939.862	9,7	569.792	1,65
Cohn	402.442	10,4	261.590	1,54
Mir	884.020	10,9	602.240	1,47

Se observă o reducere de aproximativ 60% a mărimii fișierului compresat față de fișierul original.