

Grafica 3D+

Dacă însă utilizăm culori închise de la Negru (0,0,0) la Roșu, respectiv la Albastru, atunci cu ochiul stâng (lentila Roșie) selectăm (vedem) imaginea roșie iar cu ochiul drept selectăm (vedem) imaginea albastră - menține culoarea activă (vezi Figura 53). În această situație, cu ochiul stâng nu se vede imaginea albastră (este neagră prin lentila roșie) iar cu cel drept nu se vede cea roșie (este neagră prin lentila albastră - taie culoarea opusă). Din cauza aceasta, anagifele realizate cu culori închise sunt mai întunecate (vezi Figura 53) și se văd corect sau cu ochelarii inversați sau trebuie ținut cont de acest fapt la alegerea imaginilor sursă pentru ca acestea să fie cele corecte. Deci, dacă în prima variantă imaginea albastră este în/din stânga și cea roșie în/din dreapta, în cea de-a doua variantă imaginile stau invers: imaginea roșie este în/din stânga și cea albastră în/din dreapta, sau la ochelari inversăm lentilele (culorile).

4 Reprezentarea și prelucrarea imaginilor digitale

4.1 Reprezentarea imaginilor prin funcții și cuvinte picturale

În cele ce urmează, sunt abordate în special probleme referitoare la imaginile de tip 3 și 4 (definite în [[27]]) și anume câteva metode de reprezentare a imaginilor prin *linii și curbe* respectiv printr-o *mulțime de puncte critice*, prin desene descrise de Π -cuvinte (șiruri de comenzi de deplasare a cursorului pe cele patru direcții r , u , l și d). De asemenea este prezentată și o modalitate de conversie a unui desen dintr-o formă în alta. Pentru interpolare sunt utilizate curbele Bezier, datorită faptului că acestea au anumite proprietăți care se potrivesc cu desenele descrise prin *cuvinte picturale* (Π -cuvinte).

O imagine poate fi modelată printr-o funcție de două variabile definită în planul ecranului (pe matricea de puncte din fereastra de lucru, *ViewPort*). Valoarea funcției într-un punct va reprezenta nuanța (culoarea) aceluși pixel de

Cresterea Realismului Imaginilor

pe ecran. Aceasta înseamnă că funcția ia valori din mulțimea culorilor posibile ale punctelor ecranului, deci o astfel de funcție este nenegativă și mărginită.

Dacă fereastra ecran este $[u_1, u_2] \times [v_1, v_2]$ (Figura 54), punctele P_{ij} din fereastră au coordonatele limitate astfel: $v_1 \leq i \leq v_2$ și $u_1 \leq j \leq u_2$.

Fie S_{ij} pătratul definit astfel :

$$j-1 \leq x \leq j \text{ și } i-1 \leq y \leq i.$$

În pătratul S_{ij} funcția va lua o valoare constantă egală cu codul culorii punctului P_{ij} . O astfel de funcție o vom numi *funcție picturală*. Un caz particular important îl reprezintă funcțiile cu doar două valori 0 și 1 pentru imagini alb-negru.




Figura 54 – Fereastră ecran

Funcțiile picturale sunt utilizate în numeroase probleme de prelucrare a imaginilor (codificare, aproximare, filtrare, restaurare, scalare, etc.) prin diverse operații aplicate acestora .

Descrierea unei imagini printr-o *funcție picturală* este echivalentă cu descrierea acesteia prin *cuvinte picturale*.

Demonstrația acestei afirmații o vom efectua prin precizarea modului de descriere a unei imagini formată din pătrate (S_{ij}), utilizând cuvinte de descriere prezentate în continuare.

Pentru imagini alb-negru este suficient un limbaj asemănător cu cel de descriere a desenelor discontinue (Π_{\leftarrow}^* , unde $\Pi_{\leftarrow} = \{r, u, l, d, \uparrow, \downarrow\}$), doar că primitivele de desenare nu vor mai fi segmente de lungime unitate ci pătrate de latură unitate. De exemplu, Π_{\leftarrow} -cuvântul $r^5 d^4 t^4 u^4 \uparrow d r \downarrow r$ descrie imaginea din **Error! Reference source not found.**

Pentru o funcție picturală care ia valori din mulțimea $\{alb, negru\}$ există și putem construi un Π_{\leftarrow} -cuvânt care să descrie aceeași imagine.

Grafica 3D+

Desigur că există mai multe posibilități de definire a Π_{\leftarrow} -cuvintelor echivalente cu o funcție picturală. Teoretic este suficient să punem în evidență un singur Π_{\leftarrow} -cuvânt pentru o funcție picturală oarecare. Practic însă, ne interesează și *complexitatea descrierii*, adică o descriere minimă a unei imagini.

În cele ce urmează vom prezenta o primă metodă de construcție a unui cuvânt pictural pornind de la o funcție picturală dată.

Π_{\leftarrow} -cuvântul echivalent este $w = w_{v_1} w_{v_1+1} \dots w_i \dots w_{v_2-1} w_{v_2}$, unde prin w_i înțelegem subcuvântul de descriere al liniei i , iar funcția *Redu* este definită astfel: $Redu(\alpha \uparrow \downarrow \beta) = \alpha \beta$; $\alpha, \beta \in \Pi_{\leftarrow}^*$. Π_{\leftarrow} -cuvântul w_i de descriere a liniei i ($v_1 \leq i \leq v_2$) este definit astfel :

$$w_i = \begin{cases} \alpha_{i,u_1} \alpha_{i,u_1+1} \dots \alpha_{i,j} \dots \alpha_{i,u_2-1} \alpha_{i,u_2} & \text{pentru } i \text{ impar,} \\ \beta_{i,u_2} \beta_{i,u_2-1} \dots \beta_{i,j} \dots \beta_{i,u_1+1} \beta_{i+1,u_1} & \text{pentru } i \text{ par.} \end{cases}$$

Subcuvintele de colorare $(\alpha_{ij}, \beta_{ij})$ a pătratelor S_{ij} sunt definite după cum urmează:

$$\alpha_{ij} = \begin{cases} \uparrow r \downarrow & \text{pentru } j < u_2 \text{ și } f(S_{ij}) = alb, \\ r & \text{pentru } j < u_2 \text{ și } f(S_{ij}) = negru, \\ \uparrow d \downarrow & \text{pentru } j = u_2 \text{ și } f(S_{ij}) = alb, \\ d & \text{pentru } j = u_2 \text{ și } f(S_{ij}) = negru; \end{cases}$$

$$\beta_{ij} = \begin{cases} \uparrow l \downarrow & \text{pentru } j > 1 \text{ și } f(S_{ij}) = alb, \\ l & \text{pentru } j > 1 \text{ și } f(S_{ij}) = negru, \\ \uparrow d \downarrow & \text{pentru } j = 1 \text{ și } f(S_{ij}) = alb, \\ d & \text{pentru } j = 1 \text{ și } f(S_{ij}) = negru. \end{cases}$$

Se observă că Π_{\leftarrow} -cuvântul de descriere, parcurge matricea de pătrate care reprezintă imaginea descrisă de funcția f și colorează acele pătrate pentru care valoarea funcției picturale este *negru*. Ordinea de parcurgere este cea din Figura 55.




Figura 55 - Parcurgere

Cresterea Realismului Imaginilor

Invers, valoarea funcției picturale corespunzătoare pătratului S_{ij} este dată de poziția creionului (\uparrow sau \downarrow) înainte de colorarea pătratului S_{ij} .

Pentru descrierea unei imagini color putem utiliza comenzi din mulțimea $\Pi \cup C$. Pentru a descrie o imagine formată din pătrate S_{ij} de tipul celor de mai sus (vezi Figura 54), vom preciza și culoarea pătratului care se desenează (după deplasarea definită prin comanda $\tau \in \{r, u, l, d\}$). De exemplu Π_c -cuvântul $w = arbr^3 arbd^3 adbl^3 albu^3 fdrcr \in (\Pi \cup C)^*$ descrie imaginea din Figura 57 (unde $C = \{a, b, c, f\}$, iar cu f am notat culoarea *fondului* care poate fi *alb* sau poate fi interpretat ca *fără culoare*).

Pentru funcțiile picturale de descriere a imaginilor color, Π_c -cuvântul echivalent se definește analog ca și în cazul imaginilor discontinue, doar subcuvintele α_{ij} (respectiv β_{ij}) se definesc astfel :

$$\alpha_{ij} = \begin{cases} cr & \text{pentru } j < u_2 \text{ și } f(S_{ij}) = c, \\ \uparrow r & \text{pentru } j < u_2 \text{ și } f(S_{ij}) = 0 \\ cd & \text{pentru } j = u_2 \text{ și } f(S_{ij}) = c, \\ \uparrow d & \text{pentru } j = u_2 \text{ și } f(S_{ij}) = 0. \end{cases} \quad \begin{array}{l} (c = \text{culoarea lui } S_{ij}) \\ (\uparrow = \text{fără culoare}) \end{array}$$

Subcuvintele β_{ij} se definesc analog (valorile fiind $cl, \uparrow l, cd$ și $\uparrow d$).

În concluzie putem spune că mulțimea imaginilor descrise prin funcții picturale este identică cu mulțimea imaginilor descrise prin Π_c -cuvinte, adică orice imagine descrisă printr-o funcție picturală poate fi descrisă printr-un Π_c -cuvânt, și invers.




Figura 56 - Π_c -cuvânt,




Figura 57 - Π_c -cuvânt.

Grafica 3D+

A doua metodă de construcție a Π_{\leftarrow} -cuvintelor pornind de la o funcție picturală este mai eficientă (în sensul complexității descrierii) pentru imaginile *rare* (care au puține pătrate colorate în comparație cu fereastra ecran), adică raportul

$$r = \frac{|\{f(S_{ij}) > 0 \mid v_1 \leq i \leq v_2, u_1 \leq j \leq u_2\}|}{(v_2 - v_1) \cdot (u_2 - u_1)} \text{ este relativ mic.}$$

Spre deosebire de prima metodă care traversează toată fereastra (Figura 55), metoda care urmează să fie prezentată va *căuta* doar acele pătrate care sunt colorate ($f(S_{ij}) > 0$).

Pentru imagini alb-negru vom construi Π_{\leftarrow} -cuvântul astfel :

$w = w_{v_1, u_1} w_{v_1, u_1+1} \dots w_{v_1, j} \dots w_{v_1, u_2} \dots w_{i, u_1} w_{i, u_1+1} \dots w_{i, j} \dots w_{i, u_2} \dots w_{v_2, u_1} w_{v_2, u_1+1} \dots w_{v_2, j} \dots w_{v_2, u_2}$,
unde:

$$w_{i,j} = \begin{cases} \lambda & \text{dacă } f(S_{ij}) = 0, \\ r^j d^i \downarrow u \uparrow u^i l^j & \text{dacă } f(S_{ij}) > 0. \end{cases} \quad (v_1 \leq i \leq v_2, u_1 \leq j \leq u_2)$$

Pentru că acest cuvânt conține multe deplasări inutile cu *creionul* ridicat, este necesară o reducere a acestui cuvânt. Π_{\leftarrow} -cuvântul redus este $w_r = \text{ref}_{\leftarrow}(w)$ care reprezintă Π_{\leftarrow} -cuvântul independent de retrageri relativ la mulțimea retragerilor $R_{\leftarrow} = \{ud, du, lr, rl, \uparrow\downarrow, \downarrow\uparrow\}$.

Pentru imagini color definirea Π_c -cuvântului este asemănătoare. Subcuvântul $w_{i,j}$ pentru cazul $f(S_{ij}) = c > 0$ este $w_{i,j} = r^j d^i c u \uparrow u^i l^j$, unde prin \uparrow am notat culoarea *invizibilă* (prin care se permite deplasarea fără colorare).

Cuvintele picturale definite anterior sunt echivalente cu funcțiile picturale, dar nu sunt *minimale*. Desigur, ne-ar interesa un algoritm care să construiască un cuvânt de descriere cât mai scurt posibil, plecând de la o funcție picturală f :

- Construiește graful $G=(V,A)$ astfel :
 $V = \{ (i,j) \mid f(S_{ij}) > 0 \}$, $A = V \times V$;
- Calculează distanțele directe ($\delta : A \rightarrow \mathbf{N}$) dintre vârfuri astfel :
 $\delta((i_1, j_1), (i_2, j_2)) = |i_1 - i_2| + |j_1 - j_2|$, $\forall ((i_1, j_1), (i_2, j_2)) \in A$,

Cresterea Realismului Imaginilor

- Determină cel mai scurt lanț *hamiltonian*, $H = (v_{i1}, v_{i2}, \dots, v_{in})$ ($n=|V|$);
- Construiește cuvântul de descriere $w = Reduc(c_{i1}r \uparrow w_{i2} w_{i3} \dots w_{in})$, unde

$$w_{ik} = \begin{cases} \tau^{|j_1-j_2|-1} c \tau \uparrow & \text{dacă } i_1=i_2, \\ \tau^{|j_1-j_2|-1} d^{|i_2-i_1|-1} c d \uparrow & \text{dacă } i_1 < i_2, \\ \tau^{|j_1-j_2|-1} u^{|i_2-i_1|-1} c u \uparrow & \text{dacă } i_1 > i_2; \text{ iar} \end{cases}$$

- c_{i1} este culoarea pătratului v_{i1} ,
- (i_1, j_1) și (i_2, j_2) sunt coordonatele vârfurilor $v_{i_{k-1}}$ respectiv v_{i_k} ,
- $\tau=r$ pentru $j_1 < j_2$ sau $\tau=l$ pentru $j_1 > j_2$,
- c reprezintă culoarea pătratului S_{i_2, j_2} ($c=f(S_{i_2, j_2}) > 0$),
- \uparrow reprezintă culoarea *invizibilă*, dacă $f(S_{i_2, j_2})=0$,
- $Reduc(\alpha \uparrow c \beta) = \alpha c \beta$ (nu se ridică creionul dacă urmează imediat o culoare).

Algoritmul prezentat determină un cuvânt *minimal* de descriere a unei imagini definită prin funcția picturală f .

Demonstrație. Se observă că se urmărește deplasarea cursorului începând din vârful v_{i1} prin pătratele $v_{i2}, \dots, v_{i_k}, \dots, v_{in}$, pe care le colorează. În funcție de poziția relativă a două pătrate consecutive ($v_{i_{k-1}}, v_{i_k}$) din lanțul hamiltonian, cursorul se va deplasa pe unul din cele patru trasee din Figura 59.

Din cele $C^{\Delta u}$ trasee ($\Delta u = |j_1 - j_2|$, iar $\Delta v = |i_1 - i_2|$, vezi Figura 58), nu contează pe care îl vom parcurge pentru că în dreptunghiul definit de cele două vârfuri diagonal opuse nu există nici un vârf pe care trebuie să-l colorăm (dacă ar exista, atunci lanțul determinat nu mai este minim).




Figura 59 – Trasee posibile




Figura 58 – Traseul ales

Grafica 3D+

În cele ce urmează vom studia diverse moduri de descriere a imaginilor de tip 3 (formate din linii și curbe). Pentru că descrierea imaginilor formate din linii a fost prezentată în primul capitol (utilizând Π -limbaje), în continuarea acestui paragraf vor fi prezentate câteva tehnici de descriere a curbilor.

O imagine este de tip 3 dacă poate fi complet descrisă printr-un număr finit de linii și curbe [[27]]. O curbă poate fi aproximată utilizând o mulțime de puncte alese dintr-o mulțime de puncte din plan (de exemplu dintr-un sistem cartezian rectangular, ca în Figura 60 și Figura 61)

Prin unirea punctelor apropiate de curbă se va obține o aproximare poligonală formată din segmente de lungime unitate sau $\sqrt{2}$. Această aproximare se poate reprezenta prin șiruri de comenzi (pe cele 4 sau 8 direcții).

De exemplu curba din Figura 60 se poate aproxima prin desenul descris de Π -cuvântul *urruurur* iar curba din și Figura 61 prin *acura* (am notat cu *a* deplasarea pe direcția NE). Acest procedeu de trecere de la o imagine reprezentată prin curbe la o imagine reprezentată prin puncte se numește *determinarea punctelor critice*, iar procedeu invers se numește *interpolare*.




Figura 60 – Curba 4d




Figura 61 – Curba 8d

Mulțimea punctelor critice determinate de curba $c \subset \mathbb{R}^2$ este $M_{pc}(c) = \{Apr(P)/P \in c\}$ ($Apr : \mathbb{R}^2 \rightarrow \mathbb{Z}^2$, returnează cel mai apropiat punct de coordonate întregi).

O imagine reprezentată prin puncte (de tip 4) poate fi îmbunătățită prin interpolare, obținând o imagine reprezentată prin curbe. Pentru a ilustra aceasta, am ales interpolarea *Bezier* (descrisă în [[27]]). În figurile următoare (Figura 63 - și Figura 62) se poate vedea o curbă și punctele critice determinate, apoi descrierea corespunzătoare Π -cuvântului rezultat

Cresterea Realismului Imaginilor

(pentru patru respectiv opt direcții), iar în final curba Bezier corespunzătoare.




Figura 63 - Aproximare 4d




Figura 62- Aproximare 8d

Modul de determinare al curbei Bezier (din Figura 64), plecând de la șirul de puncte P_1, P_2, \dots, P_n este descris în cele ce urmează și ilustrat în Figura 65, pentru $n=4$.

Din șirul punctelor date P_1, P_2, \dots, P_n se calculează, utilizând o relație de recurență, un alt șir de puncte $P_{1,2}, P_{2,2}, \dots, P_{n-1,2}$, apoi din punctele calculate vom determina punctele $P_{1,3}, P_{2,3}, \dots, P_{n-2,3}$ (utilizând aceeași formulă) și așa mai departe până când vom ajunge la un singur punct $P_{1,n}$. Acest punct obținut pentru o valoare $\alpha \in [0,1]$ aparține curbei Bezier.




Figura 64 – Curba Bezier

Dând valori lui α din acest interval vom obține aproximarea dorită (în Figura 65, $\alpha=1/4$).

Se observă că pentru $\alpha=0$ se obține punctul P_1 iar pentru $\alpha=1$ se obține punctul P_n .

Formula de calcul a șirului de puncte de pe nivelul $m+1$ în funcție de punctele de pe nivelul m este următoarea:




Figura 65 – Interpolarea Bezier

$$P_{i,m+1}(\alpha) = (1-\alpha) \cdot P_{i,m}(\alpha) + \alpha \cdot P_{i+1,m}(\alpha); \quad i = \overline{1, n-m}; \quad m = \overline{1, n-1}; \quad \alpha = \overline{0, 1}, \quad 1/(s-1)$$

Grafica 3D+

Se observă că formula determină punctele începând de pe nivelul doi, pentru că primul nivel conține punctele date, adică $P_{i,1}(\alpha) = P_i$, $i = \overline{1, n}$.

Dacă dorim să determinăm s puncte

$$B_1 = P_{1,n}(\alpha_1), B_2 = P_{1,n}(\alpha_2), \dots, B_j = P_{1,n}(\alpha_j), \dots, B_s = P_{1,n}(\alpha_s)$$

corespunzătoare valorilor $\alpha_1 = 0$, $\alpha_2 = 1/(s-1)$, \dots , $\alpha_j = (j-1)/(s-1)$, \dots , $\alpha_s = 1$, vom calcula coordonatele punctelor $P_{1,n}(\alpha_j)$ pentru fiecare valoare α_j . Pentru a obține și alte puncte în afara celor două capete (pentru că B_1 și B_s coincid cu P_1 respectiv P_n , ca în Figura 64 pentru $s=4$), trebuie ca s să fie mai mare decât 2.

Un algoritm *Bezier* de determinare a celor s puncte (B_j , $j = \overline{1, s}$) de pe această curbă (fără a utiliza polinoame) poate fi următorul:

```

Pentru i:=1,n execută Pi,1:=Pi sf_pentru;
Pentru j:=1,s execută
    α:=(j-1)/(s-1);
    Pentru m:=1,n-1 execută
        Pentru i:=1,n-m execută
            Pi,m+1 := (1-α) · Pi,m + α · Pi+1,m
        Sfpentru
    Sfpentru;
    Bj:= P1,n
Sfpentru.
    
```

Algoritmul prezentat ne dă ca rezultat un șir de puncte B_1, B_2, \dots, B_s . Teoretic, curba de interpolare Bezier (a punctelor P_1, P_2, \dots, P_n) este:

$$\text{Bezier}(P_1, P_2, \dots, P_n) = \{ P_{1,n}(\alpha) / \alpha \in [0, 1] \}.$$

Practic, reprezentarea grafică a curbei este realizată prin desenarea celor $s-1$ segmente determinate de șirul punctelor B_1, B_2, \dots, B_s , adică

$$\text{Bezier}_{\text{Seg}}(P_1, P_2, \dots, P_n) = \{ \overline{B_j B_{j+1}} / j = \overline{1, s-1} \} \quad (\text{vezi Figura 64}).$$

Cresterea Realismului Imaginilor

Se observă în Figura 63 - și în **Error! Reference source not found.** că dacă plecăm de la o curbă c și determinăm mulțimea punctelor critice $M_{Pc}(c)$, apoi prin algoritmul \overline{Bezier} calculăm punctele $B_j, j=1,s$, acestea se depărtează de punctele critice inițiale, adică $M_{Pc}(c) \neq \{Apr(B_j) / j = 1,s\}$, iar curba $c' = \overline{Bezier}_{Seg}(M_{Pc}(c)) \neq c$. Desigur că ne-ar interesa ca această curbă determinată prin interpolarea punctelor critice să fie cât mai apropiată de curba inițială, adică :

$$\{Apr(P_{1,n}(\alpha)) / \alpha \in [0,1]\} = \{Apr(P) / P \in c\}.$$

Presupunem că avem o curbă c_0 , pentru care determinăm șirul punctelor s_0 de coordonate întregi cele mai apropiate. Acest șir poate fi descris printr-un Π -cuvânt w astfel încât mulțimea punctelor desenului descris de w să fie mulțimea punctelor critice corespunzătoare curbei c_0 , adică:

$$V(\text{dpic}(w)) = \{Apr(P) / P \in c_0\}.$$

În continuare, dacă pentru acest șir de puncte $s_0 = (Sh(a_1 \dots a_i), i = \overline{1,n})$ determinat de Π -cuvântul $w = a_1 \dots a_n$ (șir definit anterior prin funcția Sh), determinăm curba c_1 prin interpolare Bezier, este puțin probabil (deși ar fi de dorit acest lucru) să obținem aceeași curbă inițială c_0 .

Aplicând iterativ același procedeu vom obține un șir de curbe $c_0, c_1, c_2, \dots, c_p, \dots$. Problema care în mod natural se va pune este următoarea : “ Cum pot fi obținute aceste transformări, astfel încât acest șir să fie finit? ”.

Dacă reușim să obținem o curbă (prin interpolare) care să mențină punctele critice, atunci $s_1 = s_0$, deci curba de aproximare nu se mai modifică ori de câte ori se aplică aceste transformări :

$$c_0 \longrightarrow s_0 \longrightarrow c_1 \longrightarrow s_0 \longrightarrow c_1 \dots$$

Observație. Această proprietate a celor două transformări (de interpolare și de determinare a punctelor critice) este importantă, pentru că fiecare transformare este, în acest caz, inversa celeilalte. De exemplu, după codificarea unei imagini (în scopul comprimării), decodificarea (adică transformarea inversă) se va efectua printr-o interpolare (care să conserve punctele critice, deci descrierea prin Π -cuvinte).

Grafica 3D+

În acest scop, în continuare se va prezenta o transformare (prin interpolare Bezier) care conservă Π -cuvântul de descriere.

Pentru a obține un șir de puncte cât mai apropiat de punctele critice, vom grupa punctele P_1, P_2, \dots, P_n în subșiruri de o anumită lungime q (de exemplu în Figura 66 am grupat câte 5 respectiv câte 7), apoi vom aplica algoritmul *Bezier* pentru fiecare subșir.

Figura 66 - Grupuri de curbe

Curba rezultat fiind obținută prin reuniunea curbelor descrise:

$$c = \text{Bezier}(P_1, \dots, P_q) \cup \text{Bezier}(P_q, \dots, P_{2q-1}) \cup \dots \cup \text{Bezier}(P_{n-(n \text{ Mod } q)+1}, \dots, P_n)$$

O transformare de tipul 3.1.6, utilizând grupări de lungime $q < 7$, conservă punctele critice ($\text{Apr}(c) = \{P_1, P_2, \dots, P_n\}$), deci și Π -cuvântul de descriere (w), dacă acesta nu conține *retrageri* ($w \in \text{ref}(\Pi^*)$).

Demonstrația se poate face pentru fiecare q începând de la 2 până la 6.

Este mult mai eficientă gruparea punctelor inițiale, P_1, P_2, \dots, P_n în cât mai puține subșiruri (deci cât mai puține curbe Bezier) care să conserve punctele critice (fără a stabili un număr q de puncte din subșiruri). Aceasta înseamnă că se urmărește formarea de subșiruri de dimensiuni cât mai mari. La un subșir P_i, P_{i+1}, \dots, P_j care conservă punctele critice se va adăuga punctul P_{j+1} doar dacă șirul $P_i, P_{i+1}, \dots, P_j, P_{j+1}$ conservă punctele critice (situație în care se continuă cu punctul P_{j+2} și așa mai departe) altfel se începe o nouă grupare P_j, P_{j+1}, \dots . În felul acesta se vor forma subșiruri de puncte de lungime cel puțin șase, aceasta depinzând de poziția relativă a punctelor.

Algoritmul următor determină numărul minim (notat cu k) de *grupări* care conservă punctele critice:

Date P_1, P_2, \dots, P_n ; $k:=0$; $i:=1$;

Repetă $j:=i+5$; *Cât timp* $j > n$ *execută* $j:=j-1$;

Cât timp ($j < n$) și $\text{Apr}(\text{Bezier}(P_i, \dots, P_j, P_{j+1})) = \{P_i, \dots, P_j, P_{j+1}\}$ *execută* $j:=j+1$;

$k:=k+1$; *Gruparea* $k := (P_i, \dots, P_j)$; $i:=j$

Cresterea Realismului Imaginilor

Pânăcând $i=n$;

Rezultate Gruparea₁, Gruparea₂, ... , Gruparea_k.

Observație. Numărul minim de grupări care conservă punctele P_1, P_2, \dots, P_n este $NrGr(1,n)$, unde:

$$NrGr(i, j) = \begin{cases} 1 & \text{dacă } Apr(Bezier(P_i, \dots, P_j)) = \{P_i, \dots, P_j\}, \text{ (a)} \\ \min_{i < l < j} \{NrGr(i, l) + NrGr(l, j)\} & \text{dacă } Apr(Bezier(P_i, \dots, P_j)) \neq \{P_i, \dots, P_j\}. \text{ (b)} \end{cases}$$

Dacă $Lmin(i,j)$ este indicele l pentru care se realizează minimul din formula precedentă cazul b) sau este egal cu 0 pentru cazul a), atunci șirul de puncte P_1, P_2, \dots, P_n este despărțit optim în două subșiruri, și anume $(P_1, P_2, \dots, P_{Lmin(1, n)})$ și $(P_{Lmin(1, n)}, \dots, P_n)$. În continuare, fiecare subșir P_i, \dots, P_j se desparte în două subșiruri în punctul $P_{Lmin(i, j)}$ (dacă $Lmin(i,j) > 0$), și așa mai departe până când toate subșirurile au indicele de separare $Lmin(i,j)$ nul. Observăm că numărul subșirurilor astfel obținute este minim.

Pentru ca acest algoritm să fie mai rapid (pentru a nu repeta anumite calcule) se recomandă depunerea valorilor deja calculate $NrGr(i, j)$ într-o matrice pătratică M de ordin n . Valoarea $NrGr(i, j)$ o vom depune în M_{ij} . Valorile acestei matrice le vom determina succesiv pentru prima diagonală paralelă cu diagonala principală, apoi pentru a doua, și așa mai departe până se ajunge la M_{1n} care reprezintă valoarea căutată. Pe baza precizărilor anterioare, putem să evităm calculele pentru primele șase diagonale, acestea având toate valorile egale cu 1. Practic, calculul valorilor va începe cu diagonala a șaptea. Pentru a putea forma subșirurile optimale (nu ne interesează doar numărul de grupări minim dat de M_{1n}) vom memora în elementul $M_{j,i}$ indicele pentru care se realizează minimul funcției pentru subșirul punctelor de la i la j (putem acest lucru, deoarece elementele de sub diagonala principală nu sunt utilizate).

Vom construi un arbore binar care conține în fiecare perechi de forma (i,j) , unde i și j reprezintă limitele unui subșir optim determinat (P_i, \dots, P_j) . Acest arborele are rădăcina $(1,n)$. Dacă pentru un nod (i,j) al arborelui avem $Apr(Bezier(P_i, \dots, P_j)) = \{P_i, \dots, P_j\}$ atunci acest nod este un nod terminal

(frunză), altfel va avea doi subarbori cu rădăcinile (i, M_{ji}) respectiv (M_{ji}, j) . Frontul acestui arbore ne va da subșirurile optimale.

Evident că algoritmi prezentați anterior (apelând metoda programării dinamice) nu dau neapărat aceeași soluție, dar ambele sunt minimale. Dacă avem mai multe variante de despărțire a unui subșir de puncte, se preferă, separarea în punctul P_i , dacă punctele P_{i-1} , P_i și P_{i+1} sunt coliniare (aceasta asigură continuitatea curbei Bezier, deoarece aceasta este tangentă la capetele liniei poligonale determinate de punctele de interpolare). În acest fel curba are mai puține puncte de întoarcere, deci mai puține *asperități*.

În continuare se va prezenta un model de descriere a unei imagini de tip 3 (după clasificarea dată în [27]) utilizând Π_{\downarrow} -cuvinte. Aceste cuvinte vor descrie un șir de puncte care determină o curbă prin interpolare Bezier. Aceasta înseamnă că o mulțime de Π_{\downarrow} -cuvinte descrie o imagine formată din curbe, adică de tip 3. Plecând de la un anumit punct de start $P_1(x_1, y_1)$ (care poate fi chiar originea), printr-un Π_{\downarrow} -cuvânt de descriere $w = a_1 a_2 \dots a_m$, vom construi șirul punctelor de interpolare $P_2(x_2, y_2)$, $P_3(x_3, y_3)$, ..., $P_n(x_n, y_n)$. Din șirul punctelor traversate prin comnezile Π_{\downarrow} -cuvântului w , se vor selecta în vederea interpolării doar punctele traversate cu creionul coborât (\downarrow).

Fiecare Π_{\downarrow} -cuvânt descrie un șir de puncte așa cum s-a prezentat mai sus, prin funcțiile definite anterior Nr și Pb , iar prin interpolare Bezier a șirurilor construite se vor obține curbele care compun imaginea.

De exemplu Π_{\downarrow} -cuvintele următoare

$$w_1 = dr^2u^2\uparrow u^2\downarrow u\uparrow u^2r^2\downarrow r,$$

$$w_2 = \uparrow ld\downarrow d\uparrow d^2\downarrow d^3r^2u\uparrow u^2l \text{ și}$$

$$w_3 = \uparrow d\downarrow l\uparrow l^2u\downarrow u\uparrow l\downarrow d$$

descriu următoarele trei șiruri de puncte :

1. $(0,0), (0,-1), (1,-1), (2,-1), (2,0), (2,1), (2,4), (5,6)$;
2. $(5,6), (4,4), (4,1), (4,0), (4,-1), (5,-1), (6,-1), (6,0)$ și
3. $(5,2), (4,1), (2,3), (1,2)$.




Figura 67 - Caracterul **A**

Cresterea Realismului Imaginilor

Prin interpolarea acestor puncte se obțin cele trei curbe reprezentând imaginea literei *A mare de mână*, din Figura 67. Asemănător se pot defini Π -cuvinte de descriere a unor simboluri matematice.

4.2 Reprezentarea imaginilor prin arbori

Arborii memorează informațiile formelor prin noduri (stocând informații despre forme sau substructuri) și prin arce (relații dintre *părinte* și *succesori*). Arborii sunt eficienți în reprezentarea structurală care implică o descompunere ierarhică pentru că descrierea devine compactă. O altă trăsătură importantă a structurilor arborescente este capacitatea de a construi și de a descrie forme complexe, utilizând primitive cu mai multe puncte de concatenare (la structuri de tip șir am văzut că sunt doar două puncte *cap* și *coadă*).

Dacă o formă complexă poate fi reprezentată natural prin arbori atunci este de asemenea natural să generăm descrierea sa utilizând gramatici arborescente. Figura 68 arată cum poate fi utilizat un arbore pentru a descrie o formă grafică (o imagine) descompusă în *arii elementare disjuncte*. Imaginea este descompusă în patru *arii* (pătrate, considerate în ordinea a_{11} , a_{12} , a_{21} , a_{21}) iar dacă o *arie* conține puncte de aceeași culoare atunci ea va fi reprezentată printr-un nod terminal (frunză), informația fiind culoarea respectivă, altfel (dacă *aria* conține puncte de culori diferite) atunci ea va fi reprezentată printr-un nod intern și se va descompune din nou în patru *arii elementare* (care vor fi subarbori) și așa mai departe până se ajunge la nivel de punct (pixel).




Figura 68 - Descompunerea în arii elementare

O modalitate de codificare a ierarhiei descrise de un arbore este prezentată în continuare și ilustrată în Figura 69. Vârful este etichetat cu numere naturale și se utilizează caracterul "." (punct) pentru a descrie nodurile descendente. Arborele este descris prin simpla enumerare a mulțimii etichetelor nodurilor astfel :




Figura 69 - Ierarhie

$$T = \{ 1, 1.1, 1.2, 1.2.1, 1.2.2, 1.2.3, 1.2.2.1, 1.2.2.2 \}$$

Astfel de descrieri sunt adesea utilizate în compararea arborilor (calculul măsurii de similaritate, prin distanțe $d(T_1, T_2)$ T_1 și T_2 fiind arborii care se compară).

Altă metodă de codificare a unei imagini reprezentată prin *Quad-Tree* (arbri care se ramifică în patru, prezentați mai sus) utilizează șiruri de caractere care conțin codul culorilor și un alt caracter *de ramificare* (de exemplu '*'). De exemplu imaginea din Figura 70 se codifică prin șirul '*annanna'.

a	n	n	n
n	a	n	n
n	n	a	a
n	n	a	a




Figura 70 – Codificarea prin șiruri

Șirul S codificat poate fi returnat de funcția Qt definită astfel:

Funcția $Qt(l, t, n)$ Este:

$\{ (l, t) = \text{colțul stânga-sus al ferestrei} \}$

Dacă $AccCul(l, t, n)$ Atunci $Qt := Culoare(l, t)$

$\{ n = \text{lățimea pătratului} \}$

Cresterea Realismului Imaginilor

Altfel $n:=n/2$;

$$Qt:= ' * ' + Qt(l,t,n) + Qt(l+n,t,n) \\ + Qt(l,t+n,n) + Qt(l+n,t+n,n)$$

Sf_Qt.

Decodificarea șirului S poate fi realizată utilizând procedura Pt definită astfel:

Procedura $Pt(l,t,n)$ Este: { Reconstituie imaginea în (l,t) }

$Cul:=Primul_caracter(S)$; $Șterge_Primul_Caracter(S)$;

Dacă $Cul \in Mulțimii_Culorilor$ **Atunci** $Desenează_Pătratul(l,t,n,Cul)$

$$\text{Altfel } n:=n/2; Pt(l,t,n); Pt(l+n,t,n); \\ Pt(l,t+n,n); Pt(l+n,t+n,n)$$

Sf_Pt.

Codificarea a unei imagini prin arbori binari utilizează două caractere de ramificare ‘-’ și ‘|’. De exemplu imaginea din Figura 71 se codifică prin șirul: ‘-|-|an|nan|na’.

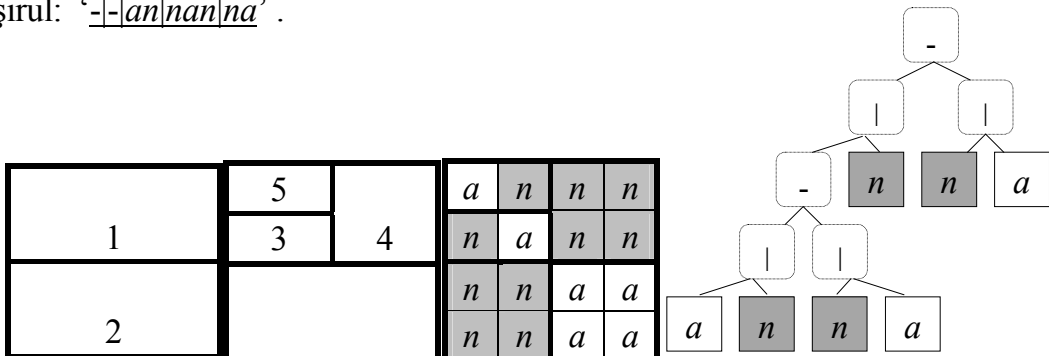


Figura 71 – Codificarea prin arbori binari

Șirul codificat poate fi returnat de funcția Bt definită astfel:

Funcția $Bt(l,t,m,n)$ Este: { (l,t) = colțul stânga-sus al ferestrei }

Dacă $AccCul(l,t,m,n)$ **Atunci** $Bt:=Culoare(l,t)$ { m,n = dim. dreptunghiului }

Altfel Dacă $m=n$ **Atunci** $m:=m/2$;

$$Bt:= ' - ' + Bt(l,t,m,n) + Bt(l,t+m,m,n)$$

Altfel $n:=n/2$;

$$Bt := ' + Bt(l, t, m, n) + Bt(l+n, t, m, n)$$

Sf_Bt.

Decodificarea poate fi realizată utilizând procedura *Pb* definită astfel:

Procedura *Pb* (*l, t, m, n*) Este: { Reconstituie imaginea în (*l, t*) }

Cul := *Primul_caracter*(*S*); *Șterge_Primul_Caracter*(*S*);

Dacă *Cul* ∈ *Mulțimii_Culorilor* Atunci

Desenează_Dreptunghiul(*l, t, m, n, Cul*)

Altfel

Dacă *Cul* = ' - ' Atunci *m* := *m*/2; *Pb*(*l, t, m, n*); *Pb*(*l, t+m, m, n*);

{ *Cul* = ' | ' } **Altfel** *n* := *n*/2; *Pb*(*l, t, m, n*); *Pb*(*l+n, t, m, n*);

Sf_Pb.

4.3 Îmbunătățirea imaginilor.

Scopul acestor prelucrări îl constituie accentuarea sau punerea în evidență a unor caracteristici conținute în imagine pentru a putea fi observate mai ușor (mai bine) la studiul acestora. Metodele utilizate în algoritmiile de îmbunătățire a imaginilor amplifică anumite caracteristici fără a mări cantitatea de informații conținută în acestea. În cele ce urmează vor fi prezentate câteva tehnici grupate după algoritmiile utilizați în următoarele două clase:

- *Operațiuni punctuale* prin care se poate realiza creșterea contrastului, reducerea zgomotului, etc. și
- *Operațiuni spațiale* care permit eliminarea zgomotului, filtrări, etc.

Pentru simplificarea prezentării, vom presupune că imaginile prelucrate prin aceste metode sunt de tip 2 (după clasificarea dată în [[27]), deci deci conțin diverse nuanțe de gri.