

Utilizarea fractalilor în compresia de date

Prof.dr. Ion IVAN, prep. Daniel VERNIŞ, ec. Elena ZERFUS
Catedra de Informatică Economică, A.S.E., Bucureşti

Descrierea obiectelor geometrice cu forme complexe care necesită reprezentarea lor pe ecranul calculatorului, în scopul recunoașterii și identificării formelor din natură, este foarte dificilă și în același timp foarte costisitoare. Tocmai de aceea studiile privind reprezentarea unor forme geometrice complexe, cu ajutorul unor funcții matematice, sunt reluate acum după aproape 100 de ani de cînd s-au facut primele încercări în acest sens.

Cuvinte cheie: compresie de date, fractali.

1. Introducere

Studiile au condus la concluzia că viața însăși este susținută pe baza teoriei fractale. De exemplu, generarea unor forme de viață se face cu ajutorul informațiilor genetice conținute în nucleu, prin repetarea la diferite scări a celulelor sau a structurilor celulare.

S-a ajuns la concluzia că teoria fractalilor este importantă nu numai pentru generarea unor forme din natură pe ecranul calculatorului, dar mai ales pentru înțelegerea și studierea fenomenelor și proceselor fizice, economice, sociale și biologice. Descrierea acestor fenomene și procese din realitate este mult mai fidelă cu ajutorul modelării matematice prin teoria fractalilor.

2. Clasificarea fractalilor

Din punctul de vedere al modului de generație, fractali se împart în:

- fractali naturali, existenți în natură sau care sunt creați în urma unor procese naturale. De exemplu: munții, țărmurile, sistemul nervos, arborii, sistemul de ramificații al bronhiilor etc.
- fractali artificiali, modele informatic ale fractalilor naturali, întâlniți și sub denumirea de seturi de fractali sau ansambluri de fractali.

Din punctul de vedere al transformărilor care stau la baza generării fractalilor, aceștia se împart în :

- fractali liniari, care sunt generați cu ajutorul transformărilor geometrice liniare aplicate asupra unor puncte, segmente suprafețe sau corpuri. De exemplu, curbele Von

Koch, care se bazează pe următoarea transformare:

- se pleacă de la un triunghi echilateral cu latura având o lungime finită;
- fiecare latură este secționată în trei părți egale, segmentul din mijloc se elimină și se înlocuiește cu un unghi ale căruia laturi sunt două segmente egale cu segmentul eliminat (figura 1).

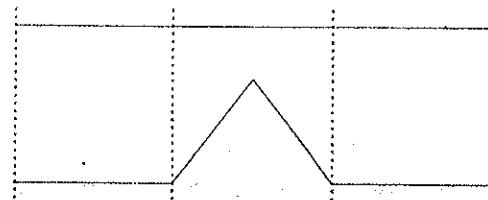


Fig. 1. Curba Koch, prima iteratie

- pentru fiecare segment al figurii obținute se repetă operația anterioară.

Dacă se pornește de la un triunghi echilateral, se obține o linie poligonală închisă, cu latura din ce în ce mai mică. Fractalii liniari pot fi la rîndul lor artificiali sau naturali.

– fractali neliniari, care se obțin cu ajutorul transformărilor geometrice neliniare (pot fi artificiali sau naturali). Fractalii neliniari se împart, în funcție de transformarea care stă la baza generării lor, în:

- fractali autopătratici, care sunt obținuți cu ajutorul generatorului pătratic $z^2 + c$ unde z și c sunt numere complexe. De exemplu, mulțimea Mandelbrot este generată astfel: se consideră un plan complex, în care se explorează un domeniu rectangular complex de laturi Ix și ly , cu colțul stînga jos (x_0, y_0) . Un punct curent din acest domeniu va fi

notat cu z_0 iar fiecare punct z i se aplică următoarea transformare:

$$\begin{aligned} T : D &\rightarrow D \\ T(z) &= z^2 + z \end{aligned}$$

Pe parcursul acestor iterații se testează modulul numărului $T(z)$:

$M^2 = [\operatorname{Im}(z)]^2 + [\operatorname{Re}(z)]^2$, unde $\operatorname{Im}(z)$ reprezintă partea imaginara a lui z ; $\operatorname{Re}(z)$ reprezintă partea reală a lui z .

Dacă după un număr de iterații n , $M < 2$ atunci z_0 va aparține mulțimii Mandelbrot.

- fractali de autoinversiune, care se obțin prin aplicarea unor transformări geometrice inverse unor puncte, segmente, suprafete sau corpuși.

Fractalii artificiali se împart la rîndul lor în:

- fractali aleatori, care sunt generați aleator utilizând procese stohastice. Structurile fractale în natură sunt aleatoare, dar este folositor să studiem fractalii determiniști care sunt generați iterativ într-un mod determinat.
- fractali determiniști, prin studierea cărora ne putem apropia de proprietățile fractalilor aleatori.

3. Transformări în teoria fractală

Dezvoltarea aplicațiilor în domeniul teoriei fractalilor a dus la creșterea interesului pentru cercetările din domeniul compresiei de date și de imagine.

În cadrul tehnicilor de compresie a imaginilor, o metodă bazată pe teoria Sistemelor de Funcții Iterative (IFS) a captat atenția specialiștilor în ultimii ani. Scopul acestei tehnici, cunoscută sub numele de *problema fractală inversă* este de a găsi un IFS al căruia atractor este cît mai apropiat de imaginea sursă. Singura limitare a acestei metode este că se obțin timpi de compresie de 30 pînă la 60 de minute, în funcție de imaginea compresată. Algoritmii de compresie cu fractali sunt bazați pe două transformări din teoria fractală: transformarea de autosimilaritate și transformarea afină sau de înrudire a părților cu întregul.

Autosimilaritatea este definită în teoria fractală ca fiind proprietatea unui obiect de a avea orice detaliu al sau asemănător cu întregul la orice scară.

În continuare se prezintă cîteva definiții:

1. O transformare $W: R^n \rightarrow R^n$ afină este o transformare de forma $W(x) = T(x) + b$, unde T este o transformare liniară pe R^n și $b \in R^n$ este un vector.

2. O funcție $W: D \rightarrow D, D \subseteq R^n$ este denumită contracție pe D , dacă există un număr real c , cu valori în intervalul $(0,1)$, astfel încât $d(W(x), W(y)) \leq c \cdot d(x, y)$, pentru x, y din D și pentru o metrică d definită pe R^n . Numărul real c este denumit în acest caz *contractivitatea* lui W .

3. Dacă $d(W(x), W(y)) = c \cdot d(x, y)$, atunci funcția W definită anterior este numită *similaritate*.

O familie de contracții $\{\omega_1, \omega_2, \dots, \omega_m\}$ este cunoscută sub numele de schemă sau sistem de funcții iterative (IFS). Dacă există un subset $F \subseteq D$, astfel încât pentru un IFS

$$\{\omega_1, \omega_2, \dots, \omega_m\}, F = \bigcup_{i=1}^m \omega_i(F), \text{ atunci } F$$

este un *invariant* pentru acest IFS. Dacă F este un invariant pentru o colecție de similarități, F este cunoscut sub numele de set autosimilar.

Fie S clasa tuturor submultimilor continue, nenule din D . Se definește un corpul δ pe mulțimea $A \in S$, ca fiind mulțimea punctelor din A cu proprietatea:

$$A_\delta = \{x \in D : |x - a| \leq \delta, a \in A\}.$$

Să definim distanța dintre două mulțimi de puncte $d(A, B)$ ca fiind:

$$d(A, B) = \inf\{\delta : A \subset B_\delta \wedge B \subset A_\delta\}$$

Distanța dintre funcții este cunoscută sub denumirea de metrică Hausdorff pe mulțimea S . Se pot folosi și alte funcții de distanță între două mulțimi.

Fiind dat un IFS $\{\omega_1, \omega_2, \dots, \omega_m\}$, există un singur set invariant F , astfel încât $F = \bigcup_{i=1}^m \omega_i(F)$, atunci setul F este *atractorul* sistemului.

Dacă E este o submulțime compactă și nevidă astfel încât $\omega_i(E) \subset E$ și

$W(E) = \bigcup_{i=1}^m \omega_i(E)$, vom defini iterația de ordin k a lui W , $W^k(E)$, ca fiind:

$$W^0(E) = E, W^k(E) = W(W^{k-1}(E)).$$

Pentru $1 \leq k$, vom avea $F = \bigcap_{i=1}^{\infty} W^k(E)$.

Secvența de iterații $W^k(E)$ este convergentă spre atratorul sistemului pentru orice mulțime E . Aceasta înseamnă că putem avea o familie de contracții care aproximează imagini complexe și, folosind această familie de contracții, imaginile pot fi memorate și transmise într-un mod eficient. Odată definit un IFS putem obține imaginea compactă de acesta. Dacă se dorește compresia unei imagini arbitrară în acest mod, trebuie să găsim mai întâi o familie de contracții, astfel încât atratorul imaginii să fie cea mai fidelă aproximare posibilă a imaginii. *Teorema colajului* a lui Barnsley definește cât de bine poate aproxima un atrator o imagine: fiind dat un set de contracții $\{\omega_1, \omega_2, \dots, \omega_m\}$ pe R^n astfel încât

$|w_i(x) - w_i(y)| \leq c \cdot |x - y|, \forall x, y \in R^n \wedge \forall i$, cu $c < 1$; fie $E \subset R^n$ o mulțime compactă și nevidă; atunci: $d(E, F) \leq d(E, \bigcup_{i=1}^m w_i(E)) \frac{1}{(1-c)}$,

unde F este o mulțime invariantă pentru ω_i și d este metrica Hausdorff.

Ca o consecință a acestei teoreme, orice submulțime a lui R^n poate fi aproximată cu o toleranță sau eroare arbitrară de un set autosimilar. De exemplu, fiind dat $\delta > 0$, există un set de contracții $\{\omega_1, \omega_2, \dots, \omega_m\}$ pentru o similaritate W , cu un set invariant F care satisfacă condiția $d(E, F) < \delta$.

Problema găsirii unui IFS $\{\omega_1, \omega_2, \dots, \omega_m\}$ al cărui atrator F este foarte apropiat de o imagine dată I este echivalentă cu minimizarea distanței $d(I, \bigcup_{i=1}^m w_i(I))$.

4. Algoritmi de compresie a imaginilor cu fractali

Ideea utilizării fractalilor în compresia imaginilor aparține cercetătorului M.F. Barnsley. Algoritmul propus de el lucrează prin divizarea imaginii într-o rețea de blocuri domeniu nesuprapuse $D = \{D_i\}$ de

B^*B pixeli și în blocuri rang $R = \{R_i\}$ de dimensiune $2B^*2B$ pixeli.

Pe baza celor două tipuri de blocuri se generează un IFS de transfer al blocurilor rang în blocuri domeniu. Pentru fiecare R_i se realizează o căutare exhaustivă pentru găsirea blocului domeniu D_i din D care aproximează cel mai bine rangul. Se memorează pentru fiecare bloc rang R_i câte o valoare w_{ijk} constând din coordonatele (x, y) ale blocului domeniu D_i folosit, luminozitate, schimbările sau transformările efectuate asupra acestui bloc pentru a se realiza o copie cât mai fidelă a rangului R_i .

Algoritmul de determinare a valorii w_{ijk} este prezentat mai jos în pseudocod :

```

 $d_{min} \leftarrow \infty$ 
for toate blocurile rang nesuprapuse  $R_i$  din  $R$ 
    for toate posibilele domenii  $D_j$  din  $D$ 
        for toate cele  $k$  posibile transformări
             $w_{ijk}$  ia valoarea aproximării lui  $R_i$  folo-
                sind  $D_j$ 
             $d_{ijk} \leftarrow$  distanta( $R_i, w_{ijk}(D_j)$ );
            if  $d_{ijk} < d_{min}$  then  $d_{min} \leftarrow d_{ijk}$ 
             $w_i \leftarrow w_{ijk}$ 
        scrie  $w_i$ ;
    
```

O caracteristică atractivă a compresiei de imagini cu fractali este independența față de rezoluție a imaginii decompresate. La decompresie, nu este necesar ca dimensiunile imaginii decompresate să fie aceleași ca cele ale imaginii inițiale. Dimensiunile blocurilor transformate nu fac parte din procesul de compresie. De aceea, ele pot fi schimbată. Dacă imaginea este decompresată la o dimensiune mai mare decât mărimea originală, se generează prin algoritm detaliu acceptabile pentru ochiul uman.

Algoritmul lui Barnsley lucrează bine cînd este paralelizat sau este codificat hardware dar, în general, are nevoie de un timp foarte mare pentru compresia imaginilor (figura 2). Jaquin a introdus o clasificare a blocurilor (blocuri de mărginire a imaginii, blocuri din mijlocul imaginii și blocuri umbră), astfel încât căutarea unui bloc rang să fie făcută numai între blocurile domeniu de aceeași categorie. Aceasta oferă algoritmului o im-

bunătățire a performanței prin reducerea căutării exhaustive pentru fiecare bloc.

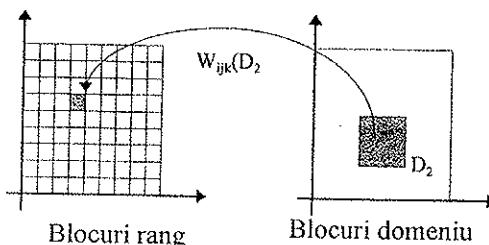


Fig. 2. Algoritmul Barnsley

Algoritmul lui Jaquin este prezentat în continuare:

```

for toate blocurile rang nesuprapuse  $R_i$  din  $R$ 
    clasifică în margine, mijloc sau umbră
for toate posibilele domenii  $D_j$  din  $D$ 
    clasifică în margine, mijloc sau umbră
     $d_{min} \leftarrow \infty$ 
for toate blocurile rang nesuprapuse  $R_i$  din  $R$ 
    for toate posibilele domenii  $D_j$  din  $D$  de
        aceeași categorie
    for toate cele  $k$  posibile transformări
        if  $w_{ijk}$  poate conduce  $D_j$  printr-o serie de
            transformări la o aproximare a a lui  $R_i$ 
             $d_{ijk} \leftarrow$  distanta( $R_i, w_{ijk}(D_j)$ );
            if  $d_{ijk} < d_{min}$  then  $d_{min} \leftarrow d_{ijk}$ 
             $w_i \leftarrow w_{ijk}$ 
            scrie  $w_i$ ;
    
```

Acest algoritm a deschis calea unor cercetări de reducere a spațiului de căutare a blocurilor similare. În detaliu, transformările aplicate unei imagini sursă sunt:

- scalarea blocului domeniu pentru a se potrivi cu blocul rang, în general o reducere de la $16*16$ la $8*8$ sau $4*4$;
- una din 8 izometrii (figura 3) folosite pentru minimizarea erorilor reziduale dintre rang și domeniu, transformă un bloc;

Aceste două transformări sunt cunoscute sub numele de transformări geometrice.

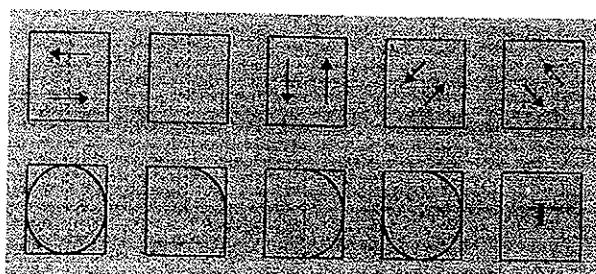


Fig. 3. Izometrii

- scalări neomogene de luminozitate, care se aplică fiecărui pixel din blocul domeniu parțial transformat după formula $r(i,j) = \alpha \cdot d(i,j) + \beta$, unde $r(i,j)$ indică pixelul rezultat; α controlează contrastul și β controlează luminozitatea;

Această transformare este denumită transformarea de masă.

- transformarea blocului domeniu într-o mască pentru blocul rang.

5. Performanțele compresiei cu fractali

Pentru testarea performanțelor algoritmului se folosește fișierul castel.tga. Timpul de compresie obținut este de 16 minute.

Procesul de decompresie se realizează iterativ. La fiecare iterație se realizează o îmbunătățire a calității imaginii.

Fișierul imagine castel.tga are o refacere rapidă în procesul de decompresie, el fiind parțial reconstituit după cinci sau șase iterări (figura 4). Pierderea de informație la compresie este de circa 2-3% în cazul acestei imagini, după o decompresie de 16 iterări. Rata de compresie a imaginii este de 43.75%, obținându-se un câștig de spațiu de memorie de 56.25%, care este comparabil în aceste cazuri cu gradul de compresie obținut la compresia imaginilor cu ajutorul algoritmilor de compresie fără pierdere de informație. Performanțele algoritmilor de compresie cu fractali sunt vizibile în cazul fișierelor de dimensiuni foarte mari. De exemplu, pentru un fișier imagine Targa, având dimensiunile $1024*768$ în nuanțe de gri (grayscale), cu o lungime de 786450 de octeți, se obține un fișier compresat cu lungimea de 36004 octeți.

În acest caz se obține o rată de compresie de 4.578%, adică de aproape 22:1. Compresia obținută în acest caz este foarte bună, însă timpul de compresie este de 214 minute. Trebuie realizat un compromis între gradul de compresie și timpul necesar compresiei. Pentru a obține o calitate bună a imaginii la decompresie trebuie efectuate minim 28 de iterări.

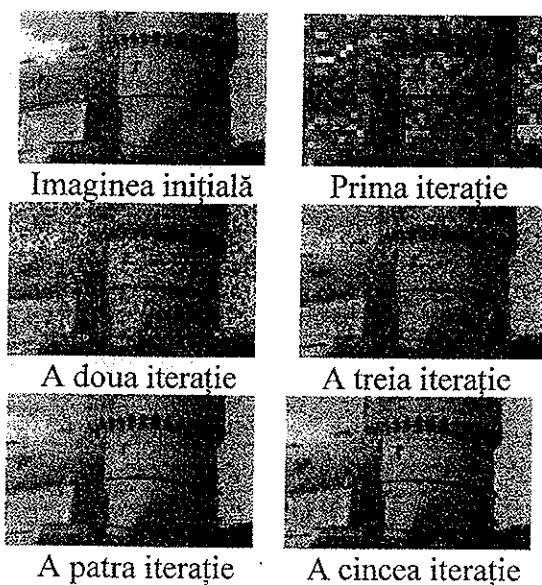


Fig. 4. Decompresia fișierului *castel.tga*

Se observă evoluția ascendentă de la o etapă la alta. Numărul iterăriilor poate crește, iar prin încercări repetitive este posibilă identificarea unui număr pentru care calitatea decompresiei este corespunzătoare. Încercările noastre conduc la un număr de 16 iterării, ca nivel performant.

Bibliografie

- [Be90] Bell T.C., Cleary J.G., Witten I.N. - Text Compression, Prentice Hall Englewood Cliffs, N.J. 1990
- [Dc95] *** Data Compression Conference, Snawbird, UT, 28-30 martie 1995, ISBN 0-8186-7012-6, Editura IEEE Compu Press
- [Ia95] I. Iacob - Compresia imaginilor folosind teoria fractalilor, PC Report, nr.34, Iulie 1995
- [Iv95] I.Ivan, D. Verniș - Analiza comparată a algoritmilor de compresie date, PC World, nr.12, Decembrie 1995
- [Iv95] I.Ivan, D. Verniș - Comprimarea datelor, PC Report, nr. 9, Septembrie 1996
- [Iv96] I.Ivan, D. Verniș - Evaluarea seturilor de date destinate compresării, Revista de statistică, nr.1, Ianuarie 1996
- [Ze97] E. Zerfus - Fractalii și seriile de timp, PC Report, nr.1, Ianuarie 1997