

3. ALGORITMI GENETICI

Un algoritm genetic efectuează operații specifice în cadrul unui proces de reproducere guvernat de operatori genetici. Noile soluții sunt create prin selecția și recombinarea cromozomilor existenți, în vederea optimizării unei funcții de evaluare specifice fiecărei probleme în parte. Semnificația acestei funcții nu este relevantă pentru algoritm, ceea ce contează fiind numai valoarea sa.

În general se pleacă de la o populație de cromozomi generată aleator și fiecare nouă populație generată prin reproducere înlocuiește parțial sau total generația anterioară. Funcția de evaluare globală se îndreaptă spre optim și oferă soluții din ce în ce mai bune problemei. Procesul este analog teoriei neo-darwiniste a evoluției biologice, care afirmă că organismele adaptate continuu la schimbările de mediu au șansele cele mai mari de supraviețuire.

3.1. Structura algoritmilor genetici

Mecanismele fundamentale care realizează legătura dintre algoritmul genetic și problema care trebuie rezolvată sunt următoarele:

- codificarea problemei în termeni de cromozomi,
- *funcția de evaluare*, care furnizează o măsură a calității fiecărui cromozom în contextul problemei respective.

Codificarea se realizează de obicei prin șiruri de cifre binare. S-a demonstrat că acest mod de codificare este robust, în sensul adaptării lui la o mare varietate de probleme practice. Ceea ce i se reproșează uneori este precizia soluției, limitată la numărul de biți, pe care se face reprezentarea. Alegerea unui număr suficient de mare de biți pentru reprezentarea valorilor reale din problemă, înlătură însă acest dezavantaj.

Mai jos se prezintă programe scrise în *MATLAB*, care fac conversia zecimal-binar și invers.

function a = zecbin(numar,nrb)

```
%ZECBIN    Face conversia zecimal-binar.
%    NUMAR - numarul zecimal intreg ce trebuie convertit.
%    NRB - numarul de biti.
%    Returneaza : un vector binar ca rezultat al conversiei.
i=0;
while numar>=2
    if rem(numar,2)==0
        a(1,nrb-i)=0;
    else
        a(1,nrb-i)=1;
    end
    i=i+1;
    numar=fix(numar/2);
end
if numar==1
    a(1,nrb-i)=1;
end
for k=1:nrb-i-1
    a(1,k)=0;
end
```

function y = binzec(a)

```
%BINZEC    Face conversia binar-zecimal.
%    A - vector ce contine numarul binar de intrare.
%    Returneaza: un numar zecimal, rezultat al conversiei.
numar=0;
```

```

nrb=length(a);
for i=1:nrb
    numar=a(1,i)*2^(nrb-i)+numar;
end
y=numar;

```

Funcția de evaluare primește la intrare șirul de cromozomi și returnează numere sau liste de numere ce reprezintă performanța cromozomilor. Ea are rolul mediului înconjurător pentru evoluția naturală.

Structura unui algoritm genetic fundamental este dată mai jos:

1. Se inițializează populația de cromozomi:

function a = initial(nrc,nrb)

%INITIAL Initializeaza aleator populatia de cromozomi.

% NRC - numarul de cromozomi.

% NRB - numarul de biti pe cromozom.

% Returneaza : o matrice aleatoare A formata din cifre binare, cu numar de linii egal cu numarul de cromozomi si numar de coloane egal cu numarul de biti pe cromozom (= nrb).

a=rand(nrc,nrb);

a=a>0.5;

2. Se evaluează fiecare cromozom din populație. Se selectează părinții noii populații.

3. Se creează o nouă generație de cromozomi prin împerecherea cromozomilor selectați, folosind operatori genetici.

4. Se șterg membrii populației inițiale, pentru a fi înlocuiți cu noua generație.

5. Se evaluează noii cromozomi și se inserează în noua populație.

6. Dacă timpul de căutare nu s-a terminat, se merge la pasul 3. În caz contrar, se oprește execuția algoritmului.

Modul de reprezentare a populației de cromozomi, modul de evaluare a cromozomilor și modul de reproducere sunt componente esențiale ale algoritmului genetic și sunt prezentate în cele ce urmează.

Selecția este un operator genetic care stabilește șirurile populației curente care vor fi alese pentru a transmite materialul lor genetic generației următoare.

Există trei tehnici de selecție:

- cea mai utilizată este *selecția proporțională*, care modelează mecanismul selecției naturale, în care cromozomii cu o evaluare mai mare au o șansă mai mare de a fi aleși. Cunoscută și sub numele de *principiul ruletei*, această tehnică presupune parcurgerea următoarelor etape:

1. Se stabilește funcția de evaluare $Eval(x_i)$ pentru fiecare cromozom x_i din populația dată

2. Se sumează toate funcțiile de evaluare $Eval = \sum_i Eval(x_i)$

3. Cromozomilor li se atribuie aleator numerele naturale i .

Repetă până la crearea unui număr suficient de perechi de cromozomi:

4. Se generează numerele aleatoare n și m , astfel ca $1 \leq n, m \leq Eval$

5. Se alege cromozomul x_i , unde i este cel mai mic număr care satisface relația: $\sum_{j \leq i} Eval(x_j) \geq n$

6. Se alege cromozomul x_j , ca la pasul 5, cu m în loc de n

7. Se stabilește perechea de cromozomi x_i și x_j .

Această modalitate de selecție poate genera serioase probleme tehnice. Dacă un cromozom din populație are o funcție de evaluare de valoare mult mai mare decât a celorlalți cromozomi, aceasta fiind departe de optim, atunci selecția proporțională va extinde foarte repede caracteristicile acestui cromozom în populație. În câteva generații populația ar putea fi alcătuită

numai din astfel de cromozomi și algoritmul genetic nu ar mai putea evolua, deci optimul nu mai poate fi găsit. Acest fenomen este cunoscut sub numele de *convergență prematură*. O altă problemă o constituie gradientul scăzut al funcției de evaluare spre sfârșitul căutării. Treptat soluția optimă este preluată de întreaga populație. Efectul este cunoscut sub numele de *terminare lentă* (slow finishing).

- O altă tehnică de selecție este *selecția pe baza rangului*, în care probabilitatea de a fi ales este o funcție liniară de locul ocupat de individ (cromozom) în cadrul populației. Avantajul constă în faptul că nu mai este necesară interpolarea permanentă a evaluării ca în cazul precedent. Un caz special de selecție de acest tip este *selecția prin trunchiere*, prin care se elimină o parte din cromozomii cu cea mai slabă evaluare, iar în locul lor se generează alții, după diferite scheme posibile. Un exemplu este prezentat în continuare:

1. Din populația actuală se elimină n cromozomi care au evaluarea cea mai slabă.

Repetă de n ori:

2. Se generează un nou cromozom x , folosind principiul ruletei
 3. Dacă x diferă de toți ceilalți cromozomi ai populației actuale, atunci el este inclus în populație; în caz contrar, este supus operatorului de “mutație” (explicat mai jos) până ce devine diferit de ceilalți cromozomi și este inclus în populație.

- O metodă euristică de selecție este *selecția elitistă*, care reține întotdeauna cei mai buni cromozomi ai populației (de regulă unul singur). Ea garantează convergența asimptotică spre un minim global, dar rata de convergență este variabilă, funcție de problemă. Elita poate introduce un efect de dominanță asupra populației care să ducă la o stagnare timpurie a procesului de evoluție. Soluția constă în utilizarea operatorului de mutație pentru reducerea sau eliminarea acestui efect.

Încrucișarea (crossover) este operatorul necesar pentru construcția noilor indivizi ai populației. Populația intermediară, formată din n cromozomi, este împărțită în $n/2$ perechi și operatorul de încrucișare este aplicat fiecărei perechi cu o anumită probabilitate χ . Valoarea lui χ este de obicei mai mare de 0,6 și de cele mai multe ori se alege $\chi = 1$.

Noii indivizi ai populației sunt generați prin combinarea unor părți alternative de material genetic provenind din două șiruri părinte a_1 și a_2 . Cea mai simplă schemă este *încrucișarea cu un singur*. Dacă numărul de biți din cromozomul-șir este $l = nrb$, atunci punctul de încrucișare este ales aleator între 1 și l . Această schemă de încrucișare este prezentată mai jos:

1. Se generează aleator un număr natural p în intervalul $[1, l(a_i)]$;
2. Se generează noua pereche de cromozomi a_{1nou} și a_{2nou} , după cum urmează:

Pentru $i \leq p$ se execută următoarea secvență:

$$a_{1nou}(i) = a_2(i) \quad \text{și} \quad a_{2nou}(i) = a_1(i);$$

Pentru $i > p$ se execută următoarea secvență:

$$a_{1nou}(i) = a_1(i) \quad \text{și} \quad a_{2nou}(i) = a_2(i).$$

function [a1,a2] = cross1(a1,a2)

%CROSS1 - Realizeaza incrucisarea intr-un singur punct.

% A1 - cromozomul a1, A2 - cromozomul a2.

% Returneaza : doi cromozomi obtinuti dupa incrucisare.

nrb = length(a1);

p = fix(nrb*rand+1);

for i=1:p,

temp(i)=a1(i);

a1(i)=a2(i);

a2(i)=temp(i);

end

O variantă mai complexă de încrucișare este *încrucișarea în două puncte*. O generalizare a

acestei scheme este încrucișarea în puncte multiple, folosită mai rar, numai în situațiile în care cromozomul conține un număr foarte mare de biți. Mai jos prezentăm schema de încrucișare în două puncte:

1. Se generează aleator două numere naturale p_1 și p_2 în intervalul $[1, l(a_i)]$;
2. Se generează noua pereche de cromozomi a_{1nou} și a_{2nou} , după cum urmează:

Pentru $p_1 \leq i \leq p_2$ se execută următoarea secvență:

$$a_{1nou}(i) = a_2(i) \quad \text{și} \quad a_{2nou}(i) = a_1(i);$$

Pentru $p_2 < i < p_1$ se execută următoarea secvență:

$$a_{1nou}(i) = a_1(i) \quad \text{și} \quad a_{2nou}(i) = a_2(i).$$

Mutația permite algoritmului genetic să găsească noi soluții în cadrul populației și îl protejează împotriva pierderii de informație în cazul unor încrucișări nepotrivite. Rata mutației este foarte redusă, *probabilitatea mutației* (notată cu μ) având valori cuprinse între 0,001 și 0,01. Dacă operatorul de selecție reduce diversitatea în populație, cel de mutație determină o nouă creștere a diversității. Cu cât probabilitatea mutației este mai mare, cu atât mai redus este riscul convergenței premature, dar apare un nou risc datorită faptului că o rată mare de mutație va transforma algoritmul genetic într-un algoritm de căutare aleatoare.

O schemă tipică de mutație pentru un cromozom $x = \langle x_1, \dots, x_n \rangle$ este:

1. Se generează aleator un număr z astfel încât $1 \leq z \leq n$;
2. Se selectează gena x_z ;
3. $x_z = 1 - x_z$.

function y = mutatie(a)

%MUTATIE Modifica aleator un bit al vectorului a.

% A - vectorul de intrare.

% Returneaza : Vectorul modificat.

nrb = length(a);

z=fix(rand*(nrb-1)+1);

a(z)=1-a(z);

y = a;

3.2. Algoritmi genetici pentru optimizare numerică

Pentru a ilustra cât mai simplu modul de funcționare a unui algoritm genetic vom rezolva două probleme simple de căutare a valorii maxime a unei funcții unidimensionale pentru un domeniu de definiție dat, folosind structura unui algoritm genetic fundamental.

Ne propunem să găsim valoarea maximă a funcției:

$$f(x) = x^2, \text{ unde } x \in [0, 31] \text{ și } x \in N. \quad (3.1)$$

Numărul de soluții posibile este $2^5 = 32$, deci pentru o codificare binară minimală fixăm lungimea cromozomului la 5 biți. Considerăm că populația este formată din 4 indivizi, iar operatorii genetici folosiți sunt mutația uniformă și încrucișarea într-un punct. Selecția se face pe principiul ruletei. Funcția de evaluare este $f(x)$.

După inițializarea aleatoare a populației sunt posibile valorile din tabelul 3.1.

Selecția cromozomilor care participă la crearea noii generații se face folosind principiul ruletei. Cromozomul 3 care are evaluarea cea mai slabă este eliminat. În locul lui se alege un alt cromozom dintre cei rămași, pentru a păstra neschimbat numărul de indivizi din populație. Este foarte posibilă alegerea cromozomului 2, care are evaluarea maximă și deci probabilitatea maximă de a fi ales.

Împerecherea cromozomilor se face aleator, iar numărul de biți schimbat între doi cromozomi în cadrul încrucișării într-un singur punct se stabilește tot aleator.

Evoluția spre noua generație se face conform tabelului 3.2.

Tabelul 3.1.

Numărul cromozomului	Reprezentare binară	Valoarea zecimală x	Evaluarea $f(x)$	Evaluarea relativă(%)
1	01101	13	169	14,4
2	11000	24	576	49,2
3	01000	8	64	5,5
4	10011	19	361	30,9
Suma			1170	100,0
Media			292,5	
Maxima			576	

Tabelul 3.2.

Cromozom părinte	Număr de biți încrucișare	Cromozom copil	Valoarea x	Evaluarea $f(x) = x^2$
011 <u>01</u>	3	01000	8	64
11 <u>000</u>	3	11101	29	841
110 <u>00</u>	2	11011	27	729
100 <u>11</u>	2	10000	16	256
Suma				1890
Media				472,5
Maxima				841

Observăm până acum o creștere a valorii maxime de la 576 la 841 și a valorii medii de la 292,5 la 472,5. Următoarele două iterații generează rezultatele prezentate în tabelele 3.3 și respectiv 3.4. Dacă în generația imediat următoare nu se obține o creștere a valorii maxime a funcției

Tabelul 3.3.

Cromozom Părinte	Număr de biți încrucișare	Cromozom copil	Valoarea x	Evaluarea $f(x)$
111 <u>01</u>	3	11000	24	576
1110 <u>1</u>	1	11101	29	841
1101 <u>1</u>	1	11011	27	729
1000 <u>0</u>	3	10101	21	441
Suma				2587
Media				646,7
Maxima				841

Tabelul 3.4.

Cromozom părinte	Număr de biți încrucișare	Cromozom copil	Valoarea x	Evaluarea $f(x)$
11 <u>000</u>	3	11101	29	841
1110 <u>1</u>	2	11111	31	961
1101 <u>1</u>	2	11001	25	625
1110 <u>1</u>	3	11000	24	576
Suma				3003
Media				750,7
Maxima				961

obiectiv $f(x)$, se poate observa o creștere a valorii medii de la 472,5 la 646,7. În ultima generație se obține valoarea maximă 961, corespunzătoare lui $x = 31$, cromozom care reprezintă

soluția problemei. Datorită instrucțiunilor aleatoare este posibil ca o nouă rulare a programului să furnizeze soluția corectă ceva mai devreme sau ceva mai târziu, dar datorită alegerii celor mai bune soluții ca bază pentru generarea unor noi soluții, convergența algoritmului spre soluția optimă este asigurată.

Un alt exemplu, care ne apropie mai mult de o problemă reală de optimizare a unei funcții de o singură variabilă este dat în cele ce urmează. Ne propunem să găsim valoarea reală a lui x din intervalul $[-1,2]$ care maximizează valoarea funcției lui Michalewicz [1], definită prin următoarea expresie: $f(x) = x \cdot \sin(10\pi \cdot x) + 1$ (3.2)

Trebuie deci să găsim o valoare x_0 din intervalul dat, astfel încât:

$$f(x_0) \geq f(x), \quad \forall x \in [-1,2] \quad (3.3)$$

Reprezentarea grafică a funcției $f(x)$ este dată în figura 3.1. Rezolvarea analitică a problemei




Fig. 3.1

presupune rezolvarea ecuației $f'(x) = 0$, care devine:

$$f'(x) = \sin(10\pi \cdot x) + 10\pi \cdot x \cdot \cos(10\pi \cdot x) = 0, \quad (3.4)$$

și care este echivalentă cu ecuația: $\tan(10\pi \cdot x) = -10\pi \cdot x$. (3.5)

Ecuația 3.5 este o ecuație transcendentă, care are o infinitate de soluții de forma:

$$x_i = \begin{cases} \frac{2i-1}{20} + \varepsilon_i, & i = 1, 2, \dots \\ 0 & i = 0 \\ \frac{2i+1}{20} - \varepsilon_i, & i = -1, -2, \dots \end{cases} \quad (3.6)$$

unde termenii ε_i formează un șir descrescător de numere reale, convergent la zero. Maximul

funcției pe domeniul indicat se obține pentru $x_{19} = \frac{37}{20} + \varepsilon_{19} \approx 1,85$ și este ceva mai mare de

valoarea lui $f(1,85)$, adică $f(1,85) = 1,85 \cdot \sin\left(18\pi + \frac{\pi}{2}\right) + 1 = 2,85$.

Pentru rezolvarea problemei cu algoritm genetic, pentru început stabilim modul de reprezentare a datelor. Soluția problemei sau cromozomul este un vector binar de lungime suficientă pentru a asigura precizia dorită. Dacă dorim ca soluția să aibă 6 zecimale, atunci domeniul $[-1, 2]$ trebuie împărțit în $3 \cdot 10^6$ valori distincte. Lungimea cromozomilor va fi de 22 biți, deoarece:

$$2^{21} < 3 \cdot 10^6 \leq 2^{22} \quad (3.7)$$

Corespondența dintre valoarea binară a cromozomului și numărul real pe care acesta îl reprezintă se face printr-o interpolare liniară simplă. Cromozomul care conține numai biți de 0 corespunde valorii reale -1, iar cromozomul care conține numai biți de 1 corespunde valorii reale +2. Orice alt cromozom reprezintă o valoare reală cuprinsă între cele două limite.

function s = interpolare(valmin,valmax,nrb,val)

%INTERPOLARE - calculeaza valoarea argumentului pentru aplicatia ceruta.

% VALMIN - valoarea minima a argumentului.

% VALMAX - valoarea maxima a argumentului.

% NRB - numarul de biti pe cromozom.

% VAL - valoarea calculata a argumentului, cuprinsa intre 0 si 2^{NRB} .

% Returneaza : valoarea corecta in domeniul de variatie a argumentului.

p=(valmax-valmin)/ 2^{nrb} ;

s=valmin+p*val;

Populația de cromozomi este inițializată prin generarea unei matrici cu număr de linii egal cu numărul cromozomilor din populație și cu număr de coloane egal cu numărul biților dintr-un cromozom, adică 22. Toate elementele matricii sunt cifre binare generate aleator.

Funcția de evaluare a cromozomilor este echivalentă funcției $f(x)$. Operatorii genetici folosiți sunt și aici încrucișarea și mutația. Încrucișarea se face într-un singur punct, iar numărul biților care se schimbă între doi cromozomi părinți este aleator. Mutația este uniformă și - de această dată - se produc mutații, deoarece elementele care stabilesc probabilitatea de mutație pe generație, numărul de cromozomi din populație și lungimea cromozomilor, sunt acum mult mai mari decât în exemplul precedent.

Algoritmul genetic folosit pentru rezolvarea problemei are o populație formată din 50 de cromozomi, probabilitate de încrucișare de 0,25 și probabilitate de mutație de 0,01. De multe ori se alege o probabilitate de încrucișare unitară. Acest lucru mărește de obicei convergența algoritmului, dar crește timpul de execuție.

Rezultatele experimentale obținute pentru o evoluție pe parcursul a 150 de generații sunt prezentate în figura 3.2. și în tabelul 3.5. Se poate observa că evaluarea maximă este apropiată




Fig. 3.2

de soluția corectă încă de la prima generație. Ea este dată de cel mai bun individ din populația inițială de 50 de indivizi care a fost generată aleator, individ care este păstrat de la o generație la alta. Din acest motiv, evaluarea maximă este o funcție monoton crescătoare. Nu același lucru se întâmplă cu evaluarea medie, care prezintă și porțiuni scăzătoare începând cu generația 20,

Tabelul 3.5.

Numărul generației	Evaluarea medie	Evaluarea maximă
1	1,089383	2,639120
5	1,498987	2,639120
10	1,885667	2,649927
20	2,513873	2,650306
30	2,562338	2,801410
40	2,632469	2,849743
50	2,754230	2,850273

datorită încrucișărilor și mutațiilor produse. Deși valoarea medie a populației este în creștere , datorită eliminării celor mai slabi indivizi la fiecare generație, se mai întâmplă, ce-i drept cu o probabilitate destul de mică, ca părinți reușiți să nu genereze întotdeauna copii la fel de reușiți sau mai reușiți, așa cum ar fi de dorit.

Algoritmul propus converge după mai puțin de 50 de generații la valoarea 2,850273, care corespunde unei erori relative de - 0,002 % . S-a folosit o selecție prin trunchiere folosind principiul ruletei și eliminând 8 dintre cei mai slabi cromozomi la fiecare generație.

BIBLIOGRAFIE

- 1) Z . Michalewicz “Genetic Algorithms + Data Structures = Evolution Programs”, Springer-Verlag , 1996 .
- 2) R. Popa “Cercetari privind elaborarea unor noi metode de testare a structurilor numerice”, Teza de doctorat , Universitatea "Dunarea de Jos" din Galati , 1998 .