

2. Algoritmi genetici și strategii evolutive

2.1 Algoritmi genetici

Structura unui algoritm genetic standard:

1. Se inițializează aleator populația de cromozomi.
2. Se evaluează fiecare cromozom din populație.
3. Se creează o nouă generație de cromozomi folosind operatori genetici (selecție, încrucișare, mutație).
4. Se șterg o parte din membrii populației actuale, pentru a fi înlocuiți cu cei din 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.

Operatorii genetici:

- **Selecția** – stabilește cei mai buni cromozomi din populație - selecția proporțională sau principiul ruletei




Fig. 2.1 *Principiul ruletei*

1. Se stabilește funcția de evaluare $Eval(x_i)$ pentru fiecare cromozom x_i din populație
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 numărului suficient de perechi de cromozomi:
 4. Se generează aleator 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 , la fel ca la pasul 5, cu m în loc de n
 7. Se stabilește perechea de cromozomi x_i și x_j .

- selecția prin trunchiere
- selecția de tip turnir

- **Încrucișarea** – stabilește modul de schimbare a materialului genetic între cromozomii părinți
- încrucișarea într-un singur punct




Fig. 2.2 *Încrucișarea într-un singur punct*

- încrucișarea în două puncte
- încrucișarea uniformă

Se face cu o anumită probabilitate χ (între 60% și 100%)

- **Mutația** – permite găsirea unor soluții noi
 - se alege aleator un bit dintr-un cromozom copil și se modifică valoarea lui
 - Se face cu o anumită probabilitate μ , foarte mică, având valori cuprinse în general între 0,1 și 1%, pe bit.
 - Determină o creștere a diversității populației, având un efect contrar operatorului de selecție, care reduce diversitatea în populația de cromozomi.

Teorema fundamentală a algoritmilor genetici (Teorema Schemei)

Schema - secvență de caractere de lungime l din alfabetul $\{0,1,*\}$. Un exemplu de schemă este $s = 0 * 1 1 0 *$.

Ordinul schemei s , notat cu $o(s)$, reprezintă numărul de simboluri diferite de "don't care" din schemă. Avem $o(s) = 4$.

Lungimea definitorie a schemei s , notată cu $\delta(s)$, reprezintă distanța dintre primul și ultimul simbol specific diferit de simbolul "don't care". Pentru cazul nostru $\delta(s) = 5 - 1 = 4$.

Funcția de performanță asociată schemei s , notată cu $f(s)$, reprezintă evaluarea medie a membrilor populației.

Probabilitatea de supraviețuire a schemei în urma încrucișării, notată cu $p(s)$, în cazul unui singur punct de încrucișare, satisface inegalitatea: $p(s) \geq 1 - \chi \cdot \frac{\delta(s)}{l-1}$.

Numărul de apariții ale schemei s în populația de la momentul t , notat cu $m(s, t)$, devine la momentul $t+1$:

$$m(s, t+1) = m(s, t) \cdot n \cdot \frac{f(s)}{\sum_{i=1}^n f(i)} = m(s, t) \cdot \frac{f(s)}{f^{\text{mediu}}}$$

Numărul reprezentanților schemei s crește odată cu trecerea timpului, dacă $f(s) > f^{mediu}$. Dacă ținem seama și de efectul combinat al operatorilor genetici de încrucișare și mutație se poate formula Teorema Schemei prin următoarea expresie:

$$m(s, t + 1) \geq m(s, t) \cdot \frac{f(s)}{f^{mediu}} \cdot \left(1 - \chi \cdot \frac{\delta(s)}{l-1} - o(s) \cdot \mu \right)$$

Exemplu de căutare a minimumului unei funcții multimodale

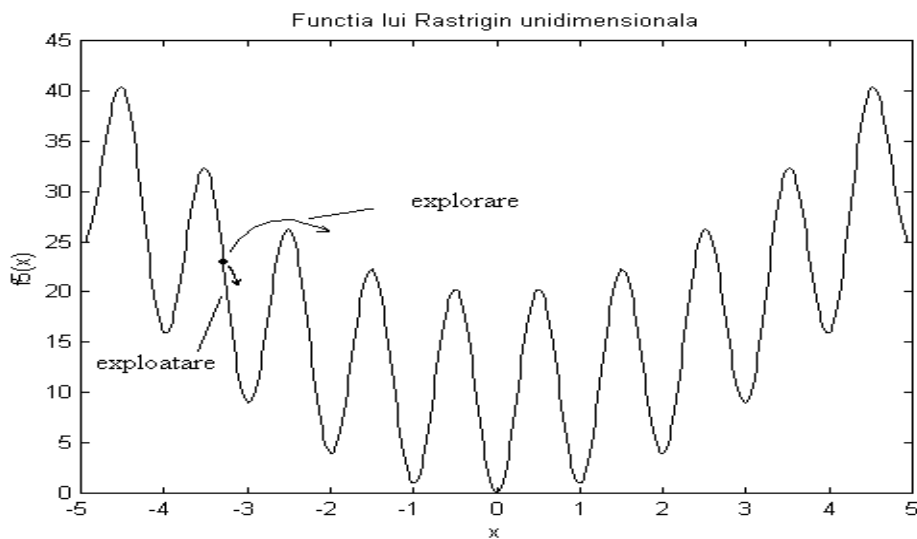


Fig. 2.3 *Funcția lui Rastrigin unidimensională*

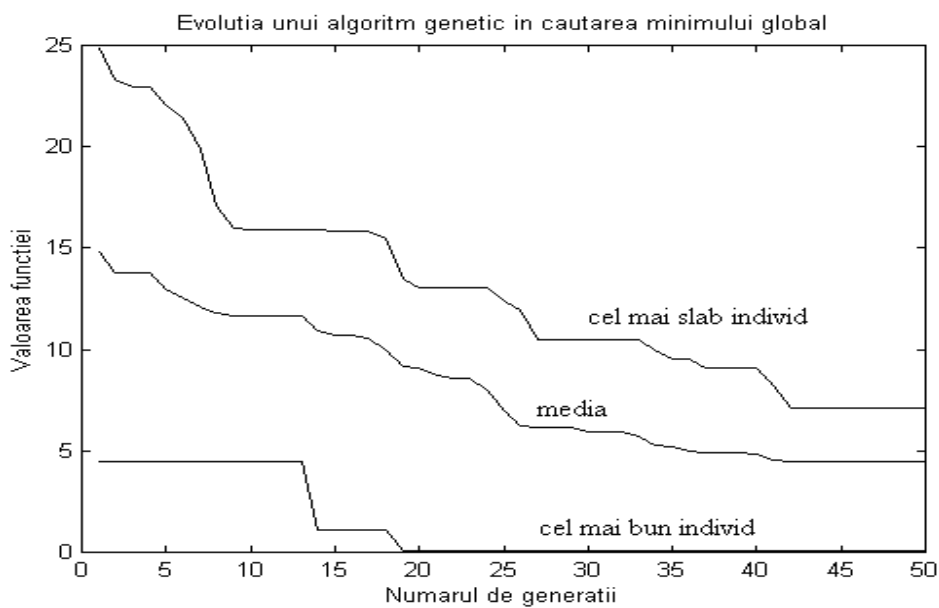


Fig. 2.4 *Evoluția în timp a populației de cromozomi*

2.2 Strategii evolutive

Structura unei strategii evolutive de tip SE(1+1):

1. Se selectează aleator o populație inițială de vectori-părinți \mathbf{x}_i , $i = \overline{1, P}$, dintr-un domeniu permis, în raport cu fiecare variabilă. Distribuția inițială este uniformă.
2. Se creează un vector-urmas, \mathbf{x}_i' , prin adăugarea la fiecare componentă a lui \mathbf{x}_i a unei variabile aleatoare cu medie zero și dispersie predefinită.
3. Se face selecția prin compararea valorilor funcției $F(\mathbf{x}_i)$ și $F(\mathbf{x}_i')$. Cei P vectori care au cele mai mici erori devin părinți pentru noua generație.
4. Procesul de generare și selecție a generațiilor se oprește la atingerea unei soluții satisfăcătoare sau la terminarea timpului de calcul disponibil.

- Strategia prezentată este de tip SE(1+1), deoarece un urmaș provine dintr-un singur părinte și ambii sunt puși în competiția supraviețuirii.
- Între părinți și urmași există mai degrabă o legătură comportamentală decât una genetică. Mecanismul descris modelează modificarea naturală posibilă a mai multor caracteristici fenotipice, lucru realizat prin variația tuturor componentelor unui părinte pentru a crea un urmaș.
- Dezavantajele metodei constau în rata scăzută de convergență și o probabilitate destul de mare de a atinge minime locale, comparativ cu algoritmi genetici.

- Rata de convergență estimată este definită de raportul dintre distanța medie parcursă spre soluția optimală și numărul de încercări necesare atingerii acesteia.
- Pentru o funcție de eroare pătratică $E(\mathbf{x}) = \sum_{i=1}^n x_i^2$, s-a demonstrat că rata optimă de convergență este obținută pentru $\sigma \approx 1,224 \cdot \frac{r}{n}$, unde σ este dispersia perturbației normale (gaussiene) cu media zero și r este distanța euclidiană obișnuită.
- Modelele fundamentale utilizate în strategiile evolutive *multi-părinți/multi-urmași* sunt $SE(\mu+\lambda)$ și respectiv $SE(\mu,\lambda)$. În primul model, μ părinți creează λ urmași și toate soluțiile concurează la supraviețuire. Cea mai bună soluție devine părinte pentru noua generație. În al doilea model numai λ urmași rămân în competiție iar părinții sunt complet înlocuiți în fiecare generație. Durata de viață a unei soluții devine astfel limitată la o singură generație. Creșterea populației duce la mărirea vitezei de optimizare raportată la un număr fix de generații.
- Adaptarea dispersiei în timpul căutării pe baze neeuristice a condus la ideea ca fiecare soluție să conțină și un *vector de perturbare* σ , care să ofere date asupra mutațiilor lui \mathbf{x} . De exemplu, dacă σ este vectorul dispersiilor fiecărei dimensiuni a lui \mathbf{x} , atunci noul vector-soluție (\mathbf{x}', σ') se poate obține din relațiile:

$$\sigma'_i = \sigma_i \cdot e^{\alpha' \cdot N(0,1) + \alpha \cdot N_i(0,1)}$$

$$\mathbf{x}'_i = \mathbf{x}_i + N(0, \sigma'_i), \quad i = \overline{1, n}.$$

$N(0,1)$ și $N_i(0,1)$ sunt variabile aleatoare cu distribuție normală iar α și α' sunt mulțimile de parametri care definesc mărimea pasului global, respectiv individual. În acest mod, strategiile evolutive se pot autoadapta la mărimea hypersuprafeței de eroare, rata de convergență crescând în consecință.

- Dacă notăm cu P mulțimea părinților și cu U mulțimea urmașilor, atunci putem scrie cele două mulțimi ca fiind formate din elementele \mathbf{I} :

$$P = \{\mathbf{I}_1, \mathbf{I}_2, \dots, \mathbf{I}_\mu\} \quad \text{și} \quad U = \{\mathbf{I}_{\mu+1}, \mathbf{I}_{\mu+2}, \dots, \mathbf{I}_{\mu+\lambda}\} .$$

$\mathbf{I} = (\mathbf{x}, \sigma)$ este un individ, unde \mathbf{x} este un vector soluție n - dimensional și σ este vectorul varianței mutațiilor, tot un vector n - dimensional.

- Operatorii evolutivi sunt:

Operatorul de selectie, $S(\Omega) \rightarrow P$, care selectează cei mai buni μ indivizi din mulțimea Ω , pentru a produce părinți în noua generație. $\Omega = P \cup U$ pentru strategia $SE(\mu+\lambda)$ și $\Omega = U$ pentru strategia $SE(\mu, \lambda)$.

Operatorul de recombinare, $R(\mathbf{I}', \mathbf{I}'') \rightarrow \mathbf{I}$ selectează indivizii \mathbf{I}' și \mathbf{I}'' din mulțimea P , cu aceeași probabilitate de împerechere. Se poate utiliza fie *recombinarea discretă* în care avem relațiile:

$$\mathbf{x}_i = \mathbf{x}_i' \text{ sau } \mathbf{x}_i'', \quad \text{și} \quad \sigma_i = \sigma_i' \text{ sau } \sigma_i'', \quad \forall i,$$

fie *recombinarea intermediară*, unde:

$$\mathbf{x}_i = \frac{1}{2} \cdot (\mathbf{x}_i' + \mathbf{x}_i'') \quad \text{și} \quad \sigma_i = \frac{1}{2} \cdot (\sigma_i' + \sigma_i''), \quad \forall i$$

Operatorul de *mutație* $M(\mathbf{I}) \rightarrow \mathbf{I}$ determină modificări în structura individului care urmează a fi generat. El are același rol ca și la algoritmi genetici, iar individul $\mathbf{I}'(\mathbf{x}', \sigma')$ se obține folosind relațiile date pe folia SE 2-6.




Fig. 2.5 Rezolvarea modelului sferei cu un algoritm genetic

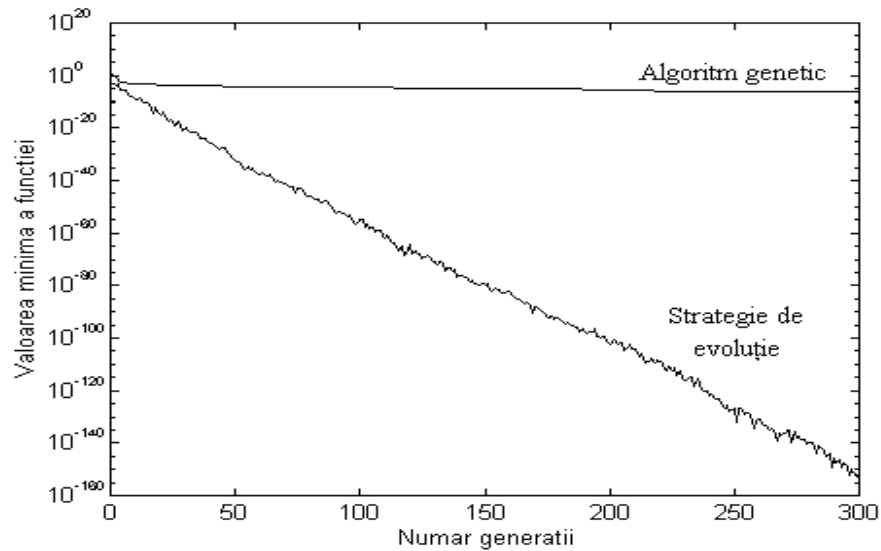


Fig. 2.6 Comparația vitezelor de convergență

În privința succesului căutării, pentru funcția lui Rastrigin, de exemplu, algoritmul genetic a găsit minimul global în toate cele 20 de încercări făcute, în timp ce strategia evolutivă SE(8,50) de mai sus, numai în 60% din cazuri.