

## Algoritmi evolutivi

1. Specificul calculului evolutiv
2. Structura unui algoritm evolutiv
3. Reguli de codificare. Exemple de probleme specifice.
4. Reguli de decodificare.
5. Construirea funcției de adaptare
6. Selecția
  - 6.1 Elitismul
  - 6.2 Selecția de tip ruletă
  - 6.3 Selecția pe baza rangurilor
  - 6.4 Selecția de tip turnir
7. Încrucișare
8. Mutație
9. Domenii de aplicabilitate
10. Aplicații

### 1. Specificul calculului evolutiv

Un *algoritm evolutiv* este o metodă de căutare prin analogie cu evoluția biologică (de tip darwinist). Pentru găsirea soluției se utilizează o populație de soluții potențiale care evoluează prin aplicarea iterativă a unor operatori stohastici. Elementele populației reprezintă soluții potențiale ale problemei. Pentru a ghida căutarea către soluția problemei asupra populației se aplică transformări specifice evoluției naturale:

- *Selecție*. Elementele populației care se apropie de soluția problemei sunt considerate adecvate și sunt favorizate în sensul că au mai multe șanse de a supraviețui în generația următoare precum și de a participa la generarea de "urmași".

- *Încrucișare*. La fel ca la înmulțirea din natură pornind de la două sau mai multe elemente ale populației (numite părinți) se generează noi elemente (numite urmași). În funcție de calitatea acestora (apropierea de soluția problemei) urmașii își pot înlocui părinții.

- *Mutație*. Pentru a asigura variabilitatea populației se aplică, la fel ca în natură, transformări cu caracter aleator asupra elementelor populației permițând apariția unor trăsături (gene) care doar prin încrucișare și selecție nu ar fi apărut în cadrul populației.

În funcție de modul în care este construită populația și de modul în care este implementată evoluția, sistemele de calcul evolutiv se încadrează în una dintre următoarele categorii:

- *Algoritmi genetici*. Se folosesc în special pentru rezolvarea unor probleme de optimizare discretă (combinatorială). Populația este reprezentată de stări din spațiul problemei codificate binar (un element al populației este un șir de biți) iar principalii operatori sunt cei de încrucișare și selecție, cel de mutație având probabilitate mică de aplicare.

- *Strategii evolutive*. Au fost concepute inițial pentru a rezolva probleme de optimizare continuă. Populația este constituită din elemente din domeniul de definiție al funcției obiectiv. Operatorul principal este cel de mutație dar și recombinarea este folosită. Pentru strategiile evolutive au fost dezvoltate scheme de adaptare a parametrilor de control (auto-adaptare).

- *Programare genetică*. Scopul programării genetice este dezvoltarea unor "modele" de calcul (programe simple). Astfel, populația este reprezentată de programe care candidează la rezolvarea problemei. Există diferite reprezentări ale elementelor populației, una dintre cele mai clasice fiind aceea în care se utilizează o structură arborescentă pentru reprezentarea programelor. În anumite aplicații, cum este regresia simbolică, programele sunt de fapt expresii.

De exemplu, "programul-expresie" " $a+b*c$ " poate fi descris prin  $(+ a (* b c))$ . O astfel de structură este poate fi ușor codificată în Clips sau Lisp. Într-o astfel de reprezentare încrucișarea este realizată selectând aleator subarbori din arborele asociat programelor părinte și interschimbându-le. Ca și în cazul algoritmilor genetici mutația are pondere mică.


- *Programare evolutivă*. Inițial programarea evolutivă a avut ca obiectiv dezvoltarea unor structuri de calcul (automate) printr-un proces de evoluție în care operatorul principal este cel de mutație. Ulterior programarea evolutivă a fost orientată către rezolvarea problemelor de optimizare având aceeași sferă de aplicabilitate ca și strategiile evolutive.

Toate aceste metode se bazează pe faptul că simulează evoluția unei mulțimi (populație) de structuri informaționale sub acțiunea unor procese similare celor din evoluția naturală și anume: selecție, mutație și încrucișare.

Acțiunea acestor procese este controlată prin intermediul unei funcții de "fitness" care măsoară gradul de adaptare a fiecărui individ la mediul din care face parte. De exemplu, în cazul rezolvării unei probleme de optimizare (găsirea maximumului sau minimumului unei funcții) funcția de adaptare este chiar funcția obiectiv a problemei.

## 2. Structura unui algoritm evolutiv

Majoritatea algoritmilor evolutivi au un caracter iterativ. Structura generală a unui astfel de algoritm (algoritm genetic, strategie evolutivă etc.) este:



Pseudocodul ar putea fi scris și astfel:

```

t := 0; // inițializarea indicatorului de iterație
init P(t); // inițializarea (aleatoare) a populației (mulțime de configurații a caror structură depinde de problemă)
evaluează P(t); // calculul funcției de adaptare pentru fiecare individ al populației
repeat // proces iterativ de evoluție
    t = t + 1 // incrementarea indicatorului de iterație
    P1(t) = select P(t) // selectarea unei sub-populații în scopul reproducerii (părinți)
    P2(t) = recombine P1(t) // încrucișarea "genelor" părinților având ca rezultat obținerea unei noi populații
    P3(t) = mutate P2(t) // perturbarea aleatoare a noii populații (mutație)
    evaluează P3(t) // evaluarea noii populații (calculul funcției de adaptare pentru noua populație)
    P(t+1) = survive (P(t), P3(t)) // selecția supraviețuitorilor din cele două populații (pe baza valorii funcției de adaptare)
until <condiție de stop>
  
```

Codarea diferă de la problemă la problemă; cele mai des folosite metode fiind codarea binară, reală sau cu permutări.

Condiția de oprire se poate referi la numărul de iterații (generații) sau la proprietățile populației curente (de exemplu, întreaga populație converge către o singură valoare).

### 3. Reguli de codificare. Exemple de probleme specifice

Modul în care o configurație este codificată într-un cromozom depinde de problema concretă. Există trei variante principale de codificare:

**Codificare binară.** Este varianta clasică. În acest caz cromozomii sunt vectori cu elemente din  $\{0,1\}$  iar spațiul de căutare este  $S = \{0,1\}^n$ , cu  $n$  numărul de gene ( $n$  este corelat cu dimensiunea problemei). Este adecvată pentru problemele de optimizare combinatorială în care configurațiile pot fi specificate ca vectori binari.

*Exemplul 1. Problema maximizării numărului de biți egali cu 1 (ONEMAX problem).* Se pune problema determinării șirului de biți  $(x_1, \dots, x_n)$ ,  $x_i \in \{0,1\}$  care maximizează funcția

$$f: \{0,1\}^n \rightarrow \mathbb{N}, f(x_1, \dots, x_n) = \sum_{j=1}^n x_j$$

Problema este echivalentă cu a determina configurația de biți care are cele mai multe elemente egale cu 1. Aceasta este evident  $(1, \dots, 1)$  problema fiind una artificială folosită pentru a testa algoritmi genetici.

*Exemplul 2. Problema submulțimii de sumă maximă limitată de un prag.* Se consideră o mulțime  $W = \{w_1, \dots, w_n\}$  de valori întregi și  $M$  o valoare întreagă. Se caută o submulțime  $S \subseteq W$  cu proprietatea că suma elementelor lui  $S$  este cât mai apropiată de  $M$  dar nu îl depășește. Orice submulțime  $S$  poate fi reprezentată printr-un vector  $(s_1, s_2, \dots, s_n)$  cu  $s_i = 0$  dacă  $w_i \notin S$  și  $s_i = 1$  dacă  $w_i \in S$ . Suma elementelor unei submulțimi  $S$  este în acest caz  $\sum_{j=1}^n w_j s_j$

*Exemplul 3. Problema rucsacului.* Se consideră un set de  $n$  obiecte caracterizate prin greutatea  $(w_1, \dots, w_n)$  și prin valorile  $(v_1, \dots, v_n)$ . Se pune problema determinării unui subset de obiecte pentru a fi introduse într-un rucsac de capacitate  $C$  astfel încât valoarea obiectelor selectate să fie maximă. O soluție a acestei probleme poate fi codificată ca un șir de  $n$  valori binare în felul următor:  $s_i = 1$  dacă obiectul  $i$  este selectat, respectiv  $s_i = 0$  dacă obiectul nu este selectat.

Pentru 5 obiecte posibile de introdus în sac, o *genă* reprezintă un bit  $(x_i)$ , în timp ce cromozomul este o soluție potențială (de exemplu 01101 înseamnă că articolele 2, 3 și 5 vor fi incluse în sac).

Funcția de adaptare / fitness indică cât de bună este o soluție (cât este de adaptat un cromozom).

De exemplu, presupunem că la un moment dat avem combinația:

| $I$   | 1  | 2  | 3  | 4  | 5  |
|-------|----|----|----|----|----|
| $w_i$ | 70 | 55 | 40 | 15 | 5  |
| $v_i$ | 40 | 15 | 5  | 30 | 10 |

Atunci, pentru cromozomul: 01101, constrângerea este:  $w = 55 + 40 + 5 = 100 \leq C = 100$  (ok), iar funcția de adaptare:  $v = 15 + 5 + 10 = 30$

**Exemplul 4. Problema împachetării.** Se consideră un set de  $n$  obiecte caracterizate prin dimensiunile  $(d_1, d_2, \dots, d_n)$  și un set de  $m$  cutii având capacitățile  $(c_1, c_2, \dots, c_m)$ . Se pune problema plasării obiectelor în cutii astfel încât capacitatea acestora să nu fie depășită iar numărul de cutii utilizate să fie cât mai mic. O posibilă reprezentare binară pentru această problemă este următoarea: se utilizează o matrice cu  $n$  linii și  $m$  coloane iar elementul  $S_{ij}$  are valoarea 1 dacă obiectul  $i$  este plasat în cutia  $j$  și 0 în caz contrar. Prin liniarizarea matricii se ajunge ca fiecare soluție să fie reprezentată printr-un cromozom conținând  $mn$  gene.

**Exemplul 5. Optimizarea unei funcții definite pe un domeniu continuu.** Se consideră o funcție  $f : D = [a_1, b_1] \times [a_2, b_2] \times \dots \times [a_n, b_n] \subset \mathbf{R}^n \rightarrow \mathbf{R}$  și se caută  $x^* = (x_1^*, \dots, x_n^*)$  care minimizează funcția  $f$  ( $f(x^*) < f(x)$  pentru orice  $x \in D$ ). În acest caz codificarea binară nu este evidentă. Fiecare dintre componentele  $x_i$  ale lui  $x$  sunt transformate după cum urmează:

- (i) se scalează pentru a fi aduse în intervalul  $[0,1]$ :  $v_i = (x_i - a_i) / (b_i - a_i)$ ;
- (ii) se stabilește numărul de biți utilizați pentru reprezentare ( $r$ ) și se aduce valoarea  $v_i$  în mulțimea  $\{0,1,\dots, 2^r - 1\}$ :  $u_i = [v_i * (2^r - 1)]$ . Valoarea obținută se reprezintă în baza 2. De exemplu, pentru  $x = (1.25, 2.3) \in [1,2] \times [2,3]$  și  $r = 5$  se obține aproximativ  $x = (0.25, 0.3)$  iar cromozomul asociat va avea  $2r = 10$  componente binare:  $(0,0,1,1,1,0,1,0,0,1)$ . Este evident că această codificare are caracter aproximativ, motiv pentru care în cazul variabilelor reale se preferă utilizarea codificării reale.

Utilizarea reprezentării binare în cazul în care configurațiile corespunzătoare problemei sunt vectori de valori reale prezintă dezavantajul că valori reale aflate la distanță mică au asociate reprezentări binare aflate la distanță mare (diferă în multe poziții binare). De exemplu reprezentarea lui 7 pe 4 biți este 0111 iar reprezentarea lui 8 este 1000. Se remarcă faptul că trecerea de la reprezentarea lui 7 la cea a lui 8 necesită nu mai puțin de 5 complementari de biți. O altă variantă de codificare care evită acest dezavantaj este codificarea de tip Gray caracterizată prin faptul că valori întregi succesive au asociate șiruri de biți care diferă într-o singură poziție.

**Codificare reală.** Este adecvată pentru problemele de optimizare pe domenii continue (vezi exemplul 5 de mai sus). În acest caz cromozomii sunt vectori cu elemente reale, fiind chiar elementele domeniului de definiție al funcției (pentru exemplul de mai sus cromozomul este chiar  $x = (1.25, 2.3)$ ). Avantajul acestei reprezentări este faptul că este naturală și nu necesită proceduri speciale de codificare/decodificare.

**Codificare specifică.** Se alege o variantă cât mai apropiată de specificul problemei.

**Exemplul 6. Problema împachetării.** În varianta de codificare binară apare dezavantajul că pot fi generate configurații care nu sunt fezabile. Acestea sunt de exemplu matricile care conțin mai multe valori egale cu 1 pe o linie (aceasta ar însemna că un obiect este simultan inclus în mai multe cutii). Pentru a evita astfel de situații se poate utiliza un alt tip de reprezentare: un vector cu  $n$  componente  $(s_1, \dots, s_n)$  în care  $s_i \in \{1, \dots, m\}$  reprezintă cutia în care este inclus obiectul  $i$ .

**Exemplul 7. Problema comis-voiajorului.** Se consideră un set de  $n$  orașe și se pune problema găsirii unui traseu care să treacă o singură dată prin fiecare oraș și care să aibă costul minim (dacă costul este proporțional cu lungimea traseului atunci se caută trasee de lungime minimă). O codificare naturală a unei configurații (traseu) este:  $(s_1, \dots, s_n)$  unde  $s_i \in \{1, \dots, n\}$  reprezintă numărul de ordine al orașului vizitat la etapa  $i$  (la fiecare etapa comis-voiajorul se află într-un oraș). Pentru a fi respectată restricția ca fiecare oraș să fie vizitat o singură dată este necesar ca elementele vectorului  $s$  să fie distincte ( $s_i \neq s_j$  pentru orice  $i \neq j$ ). Astfel fiecare configurație poate fi interpretată ca o permutare de ordin  $n$ , motiv pentru care această codificare este numită și codificare de tip permutare.

## 4. Reguli de decodificare

Decodificarea asigură pregătirea evaluării configurației.

Atenție specială ridică decodificarea doar în cazul codificării binare a unor vectori cu valori reale (vezi exemplul 5 de la codificarea binară). În cazul codificării binare clasice a unei valori din intervalul  $[a, b]$  pentru a obține valoarea decodificată pornind de la șirul de  $r$  biți obținut prin codificare se folosește relația:

$$\delta(s_1, \dots, s_r) = a + \frac{b-a}{2^r-1} \sum_{j=1}^r s_j 2^{j-1}$$

## 5. Construirea funcției de adaptare

Pentru a folosi analogia dintre procesele de căutare și cele de evoluție din natură este util să se reformuleze problemele de optimizare ca probleme de maximizare (orice problemă de minimizare poate fi transformată într-una de maximizare prin schimbarea semnului funcției obiectiv). Pentru o problemă de minimizare de forma: să se determine  $x^* \in D$  cu proprietatea că  $f(x^*) < f(x)$  pentru orice  $x \in D$ , funcția de adaptare are fi  $F(x) = -f(x)$ . În cazul unei probleme de maximizare atunci funcția de adaptare poate fi chiar funcția obiectiv.

*Exemplul 8. Problema ONEMAX.* În acest caz funcția de adaptare coincide cu funcția obiectiv a problemei, calitatea unei soluții fiind reflectată de numărul de componente egale cu 1.

*Exemplul 9. Problema comis-voiajorului.* În acest caz, dacă se folosește reprezentarea de tip permutare restricția problemei (trecerea o singură dată prin fiecare oraș) este implicit satisfăcută. Dacă matricea  $C$  conține costurile  $c(i, j)$  reprezintă costul trecerii de la orașul  $i$  la orașul  $j$ ) atunci funcția de cost poate fi descrisă prin:

$$f(s_1, \dots, s_n) = \sum_{i=1}^{n-1} c(s_i, s_{i+1}) + c(s_n, s_1).$$

În condițiile în care costul trebuie minimizat, funcția de adaptare va fi opusa funcției cost.

## 6. Selecția

Selecția are ca scop determinarea populației intermediare ce conține părinții care vor fi supuși operatorilor genetici de încrucișare și mutație precum și determinarea elementelor ce vor face parte din generația următoare. Criteriul de selecție se bazează pe gradul de adaptare al configurației la cerințele problemei, exprimat prin valoarea funcției de adaptare.

Nu este obligatoriu ca atât părinții cât și supraviețuitorii se fie determinați prin selecție, fiind posibil ca aceasta să fie folosită doar într-o singură etapă. De exemplu, toți indivizii populației curente sunt potențiali părinți dar după încrucișare și mutație doar cei determinați prin procesul de selecție vor supraviețui. Pe de altă parte este posibil ca părinți să fie doar indivizii selectați iar toți cei generați prin încrucișare și mutație să fie transferați în noua generație.

Procesul de selecție nu depinde de modul de codificare a elementelor populației fiind însă legat de funcția de adaptare.

Există mai multe metode de selecție.

### 6.1. Elitismul

Această modalitate de selecție presupune că cel mai adaptat individ este copiat direct în noua populație (mai rar primii câțiva cei mai adaptați). Aceasta asigură faptul că niciodată nu se va pierde soluția cea mai bună.


### 6.2. Selecția de tip ruletă

Ideea de bază a acestui tip de selecție este că indivizii mai adaptați au șanse mai mari. „Ruleta” se „învârtă” de  $n$  ori pentru a se alege  $n$  indivizi.

$$\text{fitness}(A) = 3$$

$$\text{fitness}(B) = 1$$

$$\text{fitness}(C) = 2$$



Fie  $S$  suma tuturor funcțiilor de adaptare (ale tuturor indivizilor din populație).

-Se generează un număr aleatoriu  $N$  între 1 și  $S$

-Se returnează cromozomul a cărui funcție de adaptare adăugată la suma parțială este  $\geq N$

-Cromozom: 1 2 3 4 5 6

-Fitness: 8 2 17 7 4 11

-Suma parțială: 8 10 27 34 38 49

- $N$  ( $1 \leq N \leq 49$ ): 23

- Selectat: 3

### 6.3. Selecția pe baza rangurilor

Se ordonează crescător valorile funcției de adaptare pentru toate elementele populației. Se rețin valorile distincte și li se asociază câte un rang (cea mai mică valoare are rangul 1, iar cea mai mare are rangul maxim). Se partiționează populația în grupuri de elemente care au aceeași valoare a funcției de adaptare și li se asociază rangul corespunzător valorii. Presupunând că sunt  $k$  grupuri se construiește distribuția de probabilitate:

$$\left( \begin{array}{cccccc} 1 & 2 & \dots & i & \dots & k \\ p_1 & p_2 & \dots & p_i & \dots & p_k \end{array} \right) \quad \text{cu } p_i = \frac{i}{\sum_{j=1}^k j}$$

Se generează câte un rang aleator în conformitatea cu distribuția de mai sus (folosind metoda ruletei de exemplu) după care se selectează uniform aleator un element din grupul corespunzător rangului.

O altă modalitate de stabilire a probabilităților de selecție pornind de la rangul elementelor este următoarea. Se ordonează crescător cele  $m$  elemente ale populației și  $i$  se asociază câte un rang (0 pentru elementul cu cel mai mic grad de adaptare și  $m - 1$  pentru elementul cu cel mai mare grad de adaptare). Probabilitatea de selecție a elementului  $i$  se calculează astfel:

$$p_i = \frac{\alpha + (\text{rang}(i)/(m - 1)) * (\beta - \alpha)}{m}$$

cu  $\alpha < \beta$  valori alese astfel încât  $\sum_{i=1}^m p_i = 1$ , ceea ce implică  $\alpha + \beta = 2$ .  $\alpha$  poate fi interpretat ca numărul mediu de copii ale celui mai slab element iar  $\beta$  ca numărul mediu de copii ale celui mai bun element.

#### 6.4. Selecția de tip turnir

În acest caz se aleg aleatoriu  $k$  membri din populație și se determină cel mai adaptat dintre aceștia. Procedura se repetă pentru a selecta mai mulți părinți. Această metodă este mai rapidă decât selecțiile prin ruletă sau ranguri.

Probabilitatea selectării individului  $i$  depinde de mărimea funcției de adaptare a lui  $i$ , precum și de dimensiunea eșantionului  $k$ . Turnirul poate fi determinist sau probabilistic.


### 7. Încrucișarea

Încrucișarea permite combinarea informațiilor provenite de la doi sau mai mulți părinți pentru generarea unui sau mai multor urmași. Vom considera doar cazul a doi părinți (notați cu  $x$  și  $y$ ) care generează doi urmași (notați cu  $x'$  și  $y'$ ). Încrucișarea (numită uneori recombinare) depinde de modul de codificare a datelor aplicându-se direct asupra cromozomilor.

Variante specifice *codificării binare* (cromozomul este o succesiune de  $n$  cifre binare):

*Încrucișare cu un punct de tăietură.* Se alege (aleator) un  $k \in \{1, \dots, n-1\}$  numit punct de tăietură (încrucișare) și se construiesc urmașii în modul următor:

$$x' = (x_1, \dots, x_k, y_{k+1}, \dots, y_n) \quad \text{și} \quad y' = (y_1, \dots, y_k, x_{k+1}, \dots, x_n).$$



*Încrucișare cu două sau mai multe puncte de tăietură* se realizează asemănător cu cea de mai sus, doar că pot exista mai multe puncte de tăiere.

*Încrucișare uniformă.* La construirea fiecărui urmaș se selectează cu probabilitatea  $p$  o genă din primul părinte și cu probabilitatea  $1-p$  o genă din al doilea părinte. Cazul cel mai natural este cel în care  $p = 0.5$ .

*Încrucișare specifică codificării de tip permutare.* În cazul codificărilor specifice și operatorii de încrucișare și mutație sunt specifici fiind de regulă bazați pe transformări cu caracter euristic sau pe transformări întâlnite în alte tehnici de rezolvare a problemei. De exemplu în cazul codificării de tip permutare trebuie ca încrucișarea să conserve specificul codificării.

*Exemplul 10.* Să considerăm problema comis voiajorului cu 7 orașe (identificate prin A, B, C, D, E, F și G) și două configurații cu rol de părinți:  $(A, B, C, D, E, F, G)$  și  $(D, C, F, E, A, B, G)$ . În acest caz încrucișarea cu un punct ( $k = 3$ ) conduce la  $(D, C, F, A, B, E, G)$  respectiv  $(A, B, C, D, F, E, G)$ . Primul fiu este obținut preluând secvența formată din primele  $k = 3$  orașe din al doilea părinte, iar celelalte orașe sunt tot din al doilea părinte însă amplasate în ordinea în care ele apar în primul părinte. În acest fel se asigură faptul că urmașii conțin aceleași elemente însă amplasate în altă ordine decât cea din cadrul părinților.

Nu e necesar ca încrucișarea să se aplice întotdeauna, modul de aplicare putând fi controlat prin intermediul unei probabilități (numită probabilitate de încrucișare și notată cu  $p_c$ ). Valori uzuale pentru  $p_c$  sunt cuprinse între 0.2 și 0.9.

## 8. Mutația

Asigură alterarea valorii unor gene pentru a evita situațiile în care o anumită alelă nu apare în populație ca urmare a faptului că nu a fost generată de la început. În felul acesta este asigurată diversitatea populației.

În cazul codificării binare cel mai simplu și frecvent operator de mutație este cel în care se selectează aleator un cromozom, în cadrul acestuia se selectează o genă iar valoarea acesteia este modificată (0 devine 1 iar 1 devine 0). În funcție de modul în care se selectează cromozomii și genele există diverse variante.

De exemplu pentru fiecare cromozom se decide cu o anumită probabilitate ( $p_m$ , numită probabilitate de mutație) dacă el va fi supus mutației sau nu. În caz afirmativ se selectează (uniform aleator) o genă și valoarea acesteia se modifică. În felul acesta într-un cromozom poate fi modificată o singură genă.

O altă variantă este aceea în care toate genele se consideră ca făcând parte din aceeași structură și pentru fiecare dintre ele se decide dacă va fi modificată sau nu. În felul acesta este posibil ca mai multe gene din cadrul unui cromozom să fie modificate.

În cazul codificării de tip permutare mutația cea mai simplă constă în schimbarea poziției a două elemente. De exemplu în cazul TSP de la configurația  $(D, C, F, A, B, E, G)$  se ajunge la configurația  $(D, C, E, A, B, F, G)$  prin interschimbarea elementelor de pe pozițiile 3 și 6.

## 9. Domenii de aplicabilitate

Algoritmii evolutivi se utilizează în general pentru probleme de optimizare, atunci când nu există altă strategie de rezolvare a problemei și este acceptat un răspuns aproximativ.

Câteva dintre domeniile de aplicabilitate sunt:

- *Planificare*. Majoritatea problemelor de planificare (alegerea traseelor optime ale unor vehicule, rutarea mesajelor într-o rețea, planificarea unor activități etc.) pot fi formulate ca probleme de optimizare. Multe dintre acestea sunt probleme din clasa "NP-hard" necunoscându-se algoritmi de rezolvare care să aibă complexitate polinomială. Pentru astfel de probleme algoritmii evolutivi oferă posibilitatea obținerii în timp rezonabil a unor soluții sub-optimale de calitate acceptabilă.

- *Proiectare*. Algoritmii evolutivi sunt aplicați cu succes în proiectarea circuitelor digitale, a filtrelor dar și a unor structuri de calcul cum sunt rețelele neuronale. Ca metode de estimare a parametrilor unor sisteme care optimizează anumite criterii se aplică în diverse domenii din inginerie cum ar fi: proiectarea avioanelor, proiectarea reactoarelor chimice, proiectarea structurilor în construcții etc.

- *Simulare și identificare*. Simularea presupune să se determine modul de comportare a unui sistem pornind de la un model al acestuia. Identificarea este sarcina inversă a identificării structurii sistemului pornind de la modul de comportare. Algoritmii evolutivi sunt utilizați atât în simularea unor sisteme din inginerie dar și din economie (de exemplu pentru modelarea proceselor de competiție în marketing). Identificarea unui model este utilă în special în efectuarea de predicții în diverse domenii (economie, finanțe, medicină, științele mediului etc.)

- *Control*. Algoritmii evolutivi pot fi utilizați pentru a implementa controlere on-line asociate sistemelor dinamice (de exemplu pentru a controla roboții mobili).

- *Clasificare*. Un sistem de clasificare se bazează pe o populație de reguli de asociere (reguli de producție) care evoluează pentru a se adapta problemei de rezolvat (calitatea unei reguli se stabilește pe baza unor exemple). Algoritmii evolutivi au fost utilizați cu succes în clasificarea imaginilor, în biologie (pentru determinarea structurii proteinelor) sau în medicină (pentru clasificarea electrocardiogramelor).



## 10. Aplicații

1. Să se minimizeze funcția următoare (funcția Rastrigin generalizată), pentru  $n = 5$ :

$$f(\mathbf{x}) = nA + \sum_{i=1}^n x_i^2 - A \cos(\omega x_i).$$

Pentru  $A = 10$  și  $\omega = 2\pi$ , funcția are minimul  $f(0)=0$ . Domeniul variabilelor este:  $-5.12 < x_i < 5.12$ .

Populația poate conține 100 de indivizi inițializați aleatoriu din domeniul de definiție al variabilelor. Cromozomii vor fi vectori de 5 numere reale. Se va utiliza selecția prin turnir cu 2 indivizi. Probabilitatea de încrucișare se va considera 90% iar probabilitatea de mutație 2%. Pentru mutație, se va reinițializa gena cu o valoare din domeniul de definiție. Se va utiliza elitismul.

Având în vedere că un algoritm evolutiv este o metodă euristică de optimizare, se va considera soluție o aproximare suficient de fină a soluției exacte, de exemplu, cu o eroare maximă de  $10^{-4}$ .

2. Să se rezolve problema rucsacului folosind codificarea binară.

## Referințe bibliografice

1. DUMITRACHE, I., N. CONSTANTIN, M, DRAGOICEA: Rețele neurale. Identificarea și conducerea proceselor, Ed. Matrix Rom, 1999.
2. DUMITRESCU, D. Algoritmi genetici și strategii evolutive – aplicații în inteligența artificială și în domenii conexe, Edit. Albastră, 2000
3. ȘERBAN, S.: Modelare și simulare, Ed. Printech Rom, 2007.
4. [http://www.ici.ro/RRIA/ria2007\\_4/art02.html](http://www.ici.ro/RRIA/ria2007_4/art02.html)
5. <http://web.info.uvt.ro/~dzaharie/cursnn1.pdf>
6. <http://web-ng.info.uvt.ro/~dzaharie/cdsa5.pdf>
7. <http://www.ipe.ro/RePEc/WorkingPapers/cs14-2.pdf>