

# Strategii evolutive

- Specific
- Structura generală
- Operatori de recombinare
- Operatori de mutație
- Variante de selecție a supraviețuitorilor
- Adaptarea și auto-adaptarea parametrilor

# Specific

**Strategii evolutive:** metode evolutive de rezolvare a problemelor de optimizare în domenii continue

**Istoric:** prima strategie a fost dezvoltată în 1964 de către Bienert, Rechenberg și Schwefel (studenți la Politehnica din Berlin) cu scopul de a optimiza structura unei conducte flexibile

**Codificarea datelor:** reală (elementele populației sunt vectori cu elemente reale)

**Operator principal:** mutație

**Particularitate:** auto-adaptarea parametrilor de control a mutației

# Structura generală

Clasa de probleme:

Se caută  $x^*$  in  $D \subseteq \mathbb{R}^n$  cu proprietatea că

$f(x^*) < f(x)$  pentru orice  $x$  din  $D$

**Populația** constă din elemente din  $D$  (vectori cu componente reale)

**Obs.** O configurație este cu atât mai bună cu cât valoarea lui  $f$  este mai mică

Structura algoritmului:

Inițializarea populației

Evaluare populație inițială

REPEAT

generare urmași prin recombinare

modificarea urmașilor prin mutație

evaluarea urmașilor

selecția supraviețuitorilor

UNTIL <e satisfăcută o condiție de oprire>

Criteria referitoare la resurse  
(ex: număr generații)

Criteria referitoare la convergență  
(ex: valoare  $f$  sau măsura a diversității)

# Operatori de recombinare

**Specific:** constă în generarea unui urmaș pornind de la un set de părinți

$$y = \sum_{i=1}^{\rho} c_i x^i, \quad 0 < c_i < 1, \quad \sum_{i=1}^{\rho} c_i = 1$$

**Recombinare intermediară**

**(convexă):** urmașul este o combinație liniară a părinților

$$y_j = \begin{cases} x_j^1 & \text{cu probabilitatea } p_1 \\ x_j^2 & \text{cu probabilitatea } p_2 \\ \vdots & \\ x_j^{\rho} & \text{cu probabilitatea } p_{\rho} \end{cases},$$

**Recombinare discretă:** urmașul este constituit din componente selectate aleator de la părinți

$$0 < p_i < 1, \quad \sum_{i=1}^{\rho} p_i = 1$$

# Operatori de recombinare

Recombinare geometrică:

$$y_j = (x_j^1)^{c_1} (x_j^2)^{c_2} \dots (x_j^\rho)^{c_\rho}, \quad 0 < c_i < 1, \quad \sum_{i=1}^{\rho} c_i = 1$$

**Observație:** a fost introdusă de Michalewicz pentru probleme de optimizare cu restricții

Recombinare euristică:

$y = x^i + u(x^i - x^k)$  cu  $x^i$  element cel puțin la fel de bun ca și  $x^k$

$u$  – valoare aleatoare din  $(0,1)$

# Operatori de recombinare

Recombinare de tip SBX (Simulated Binary Crossover) [Deb, Agrawal, 1995]:

**Idee:** reproducerea proprietăților încrucișării cu un punct de tăietură

**Observații:**

- Încrucișarea cu un punct de tăietură conservă suma valorilor elementelor:  $p_1 + p_2 = c_1 + c_2$
- Diferența dintre urmași poate fi mai mică (efect de contracție) sau mai mare (efect de extensie)
- Deb și Agrawal au studiat distribuția raportului  $|c_1 - c_2| / |p_1 - p_2|$  și au propus o regulă de calcul specifică

# Operatori de recombinare

Recombinare de tip SBX (Simulated Binary Crossover) [Deb, Agrawal, 1995]:

Mod de calcul:

$$c_1 = \bar{p} - \frac{\beta}{2}(p_2 - p_1) \quad c_2 = \bar{p} + \frac{\beta}{2}(p_2 - p_1)$$
$$\bar{p} = \frac{p_1 + p_2}{2}$$
$$\beta = \begin{cases} (2u)^{1/(d+1)} & \text{daca } u \leq 0.5 \\ \left(\frac{1}{2(1-u)}\right)^{1/(d+1)} & \text{daca } u > 0.5 \end{cases} \quad u = \text{rand}(0,1)$$

**Parametrul d:** permite controlul distantei dintre părinți și urmași

- Valori mari ale lui d conduc la urmași apropiați de părinți
- Valori mici ale lui d conduc la urmași mai îndepărtați de părinți

# Operatori de mutație

**Principiu general:** mutația constă în perturbarea a elementelor populației prin adăugarea unei variabile aleatoare

$$x' = x + z$$

$$z = (z_1, \dots, z_n)$$

vector aleator cu medie 0 și

matrice de covarianța  $C = (c_{ij})_{i,j=1,n}$

**Specific:** mutația prin perturbarea cu un vector aleator de medie 0 favorizează modificările mici ale configurației curente pe când mutația specifică algoritmilor genetici nu face distincție între perturbații mici și perturbații mari.



# Operatori de mutație

Variante:

**V1.** Componentele vectorului de perturbare sunt variabile aleatoare independente ( $E(z_i z_j) = E(z_i)E(z_j) = 0$ ) cu aceeași repartiție.

Exemple:

a) fiecare componentă a vectorului perturbație are repartiția uniformă în  $[-s, s]$

b) fiecare componentă a vectorului perturbație are repartiția  $N(0, s)$

**Obs.** Matricea de covarianță va fi o matrice diagonală de forma  $C = \text{diag}(s^2, s^2, \dots, s^2)$  iar valoarea  $s$  este singurul parametru al mutației

# Operatori de mutație

Variante:

**V2.** Componentele vectorului de perturbare sunt variabile aleatoare independente ( $E(z_i z_j) = E(z_i)E(z_j) = 0$ ) însă cu repartiții având parametri diferiți.

Exemple:

- a) componenta  $z_i$  a vectorului perturbație are repartiția uniformă în  $[-s_i, s_i]$
- b) fiecare componentă a vectorului perturbație are repartiția  $N(0, s_i)$

**Obs.** Matricea de covarianță va fi o matrice diagonală de forma

$C = \text{diag}(s_1^2, s_2^2, \dots, s_n^2)$  iar parametrii mutației sunt  $s_1, s_2, \dots, s_n$

# Operatori de mutație

Variante:

**V3.** Componentele vectorului de perturbare sunt variabile aleatoare corelate

Exemplu:

a) vectorul  $z$  are repartiția  $N(0, C)$

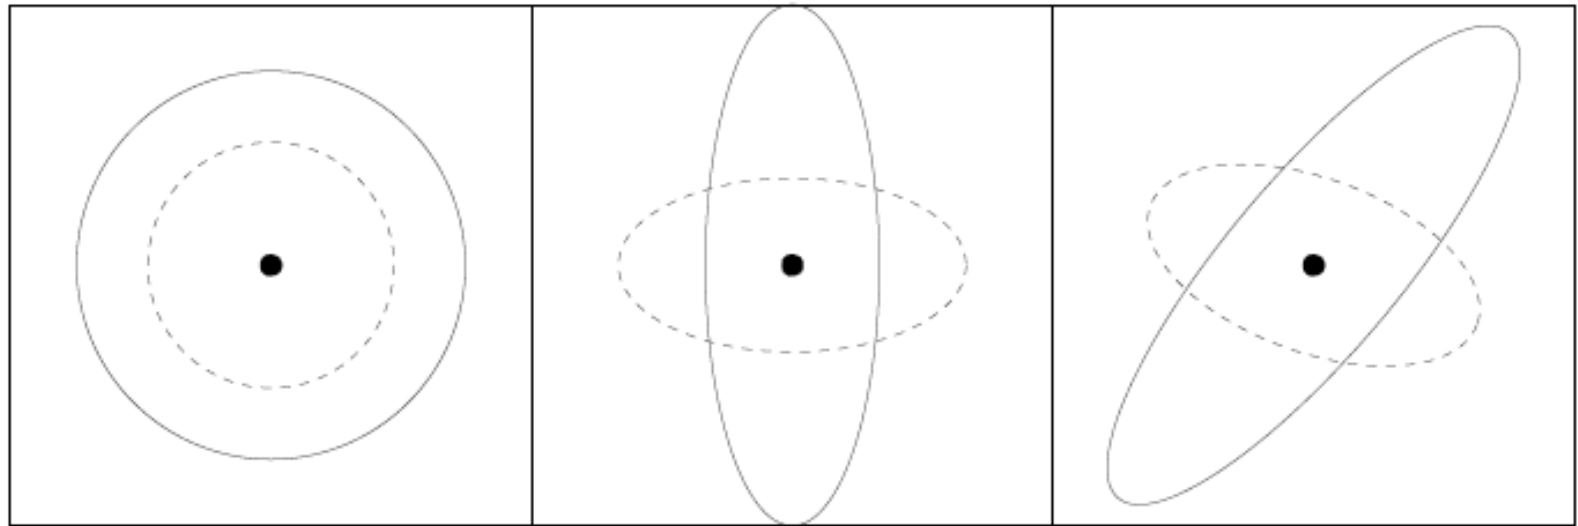
**Obs.** Matricea de covarianță va avea elemente nenule și în afara diagonalei principale astfel că vor fi  $n(n+1)/2$  parametri de control ai mutației:

$s_1, s_2, \dots, s_n$  - pași de mutație

$a_1, a_2, \dots, a_k$  - unghiuri de rotație ( $k=n(n-1)/2$ )

$$c_{ij} = \frac{1}{2} \cdot (s_i^2 - s_j^2) \cdot \tan(2 a_{ij})$$

# Operatori de mutație



$$\mathcal{N}(m, \sigma^2 \mathbf{I}) \sim m + \sigma \mathcal{N}(\mathbf{0}, \mathbf{I}) \quad \mathcal{N}(m, \mathbf{D}^2) \sim m + \mathbf{D} \mathcal{N}(\mathbf{0}, \mathbf{I}) \quad \mathcal{N}(m, \mathbf{C}) \sim m + \mathbf{C}^{\frac{1}{2}} \mathcal{N}(\mathbf{0}, \mathbf{I})$$

Variante de mutatie

[Hansen, PPSN 2006]

# Operatori de mutație


**Problema:** alegerea parametrilor de control ai mutației

**Exemplu:** perturbație de tip  $N(0,s)$

- $s$  mare  $\rightarrow$  perturbație mare
- $s$  mic  $\rightarrow$  perturbație mică

**Soluții:**

- Metode euristice de adaptare (exemplu: regula 1/5)
- Autoadaptare (modificarea parametrilor prin încrucișare și mutație)



# Operatori de mutație

## Regula 1/5.

Regulă euristică dezvoltată pentru SE având perturbații independente caracterizate printr-un singur parametru  $s$

**Idee:**  $s$  se ajustează în funcție de rata de succes a mutației

## Rata (probabilitatea) de succes

$p_s = \frac{\text{nr. de mutații care conduc la îmbunătățiri ale configurației}}{\text{nr total de mutații}}$

- Obs.**
1. Rata de succes se estimează după cel puțin  $n$  mutații
  2. A fost dedusă pentru cazul unui singur element în populație

# Operatori de mutatie

Regula 1/5.

$$s' = \begin{cases} s/c & \text{daca } p_s > 1/5 \\ cs & \text{daca } p_s < 1/5 \\ s & \text{daca } p_s = 1/5 \end{cases}$$

Studii teoretice asupra unor cazuri particulare de funcții obiectiv (ex: funcția sferă) au condus la concluzia că valori adecvate pentru  $c$  sunt  $0.8 \leq c < 1$  (ex:  $c=0.817$ )

# Operatori de mutație

Autoadaptare.

Idee:

- se extind elementele populației cu valorile parametrilor de control
- se aplică recombinare și mutație specifică și pentru parametrii de control
- vor fi favorizate valorile parametrilor de control care conduc la indivizi competitivi

Extinderea elementelor populației în funcție de tipul de perturbație

$$\bar{x} = (x_1, \dots, x_n, s)$$

$$\bar{x} = (x_1, \dots, x_n, s_1, \dots, s_n)$$

$$\bar{x} = (x_1, \dots, x_n, s_1, \dots, s_n, a_1, \dots, a_{n(n-1)/2})$$



# Operatori de mutație

## Etape:

- se modifică componentele corespunzătoare parametrilor de control
- se modifică componentele corespunzătoare variabilelor de decizie

**Exemplu:** perturbare bazată pe variabile aleatoare independente

$$\bar{x} = (x_1, \dots, x_n, s_1, \dots, s_n)$$

$$s'_i = s_i \exp(r) \exp(r_i),$$

$$r \in N(0, 1/\sqrt{2n}), r_i \in N(0, 1/\sqrt{2\sqrt{n}})$$

$$x'_i = x_i + s'_i z \quad \text{cu } z \in N(0, 1)$$

Variabile cu repartiție lognormală

- asigură pozitivitatea lui  $s$

- simetrică în jurul lui 1

# Operatori de mutație

**Obs:** Există și variante de mutație care nu folosesc perturbare bazată pe distribuție normală

Varianta propusă de Michalewicz (1996):

$$x'_i(t) = \begin{cases} x_i(t) + \Delta(t, b_i - x_i(t)) & \text{daca } u < 0.5 \\ x_i(t) - \Delta(t, x_i(t) - a_i) & \text{daca } u \geq 0.5 \end{cases}$$

$$\Delta(t, y) = y \cdot u \cdot (1 - t/T)^p, \quad p > 0$$

- $a_i$  și  $b_i$  sunt limitele domeniului de valori corespunzătoare componentei  $x_i$
- $u$  este o valoare generată aleator în  $(0,1)$
- $t$  este indicatorul de iterație
- $T$  este numărul maxim de iterații

# Operatori de mutație

CMA – ES (Covariance Matrix Adaptation –ES) [Hansen, 1996]

Initialize  $\mathbf{m} \in \mathbb{R}^n$ ,  $\sigma \in \mathbb{R}_+$ ,  $\mathbf{C} = \mathbf{I}$ , and  $\mathbf{p}_c = \mathbf{0}$ ,  $\mathbf{p}_\sigma = \mathbf{0}$ ,  
 set  $c_c \approx 4/n$ ,  $c_\sigma \approx 4/n$ ,  $c_{cov} \approx \mu_{eff}/n^2$ ,  $\mu_{cov} = \mu_{eff}$ ,  $d_\sigma \approx 1 + \sqrt{\frac{\mu_{eff}}{n}}$ ,  
 $\lambda$ , and  $w_i, i = 1, \dots, \mu$  such that  $\mu_{eff} \approx 0.3 \lambda$ , where  $\mu_{eff} = \frac{1}{\sum_{i=1}^{\mu} w_i^2}$

While not terminate

$$\mathbf{x}_i = \mathbf{m} + \sigma \mathbf{z}_i, \quad \mathbf{z}_i \sim \mathcal{N}_i(\mathbf{0}, \mathbf{C}), \quad \text{sampling}$$

$$\mathbf{m} \leftarrow \mathbf{m} + \sigma \langle \mathbf{z} \rangle_{sel} \quad \text{where } \langle \mathbf{z} \rangle_{sel} = \sum_{i=1}^{\mu} w_i \mathbf{z}_{i:\lambda} \quad \text{update mean}$$

$$\mathbf{p}_c \leftarrow (1 - c_c) \mathbf{p}_c + \mathbb{1}_{\{\|\mathbf{p}_\sigma\| < 1.5\sqrt{n}\}} \sqrt{1 - (1 - c_c)^2} \sqrt{\mu_{eff}} \langle \mathbf{z} \rangle_{sel} \quad \text{cumulation for } \mathbf{C}$$

$$\mathbf{C} \leftarrow (1 - c_{cov}) \mathbf{C} + c_{cov} \frac{1}{\mu_{cov}} \mathbf{p}_c \mathbf{p}_c^T \quad \text{update } \mathbf{C}$$

$$+ c_{cov} \left(1 - \frac{1}{\mu_{cov}}\right) \mathbf{Z} \quad \text{where } \mathbf{Z} = \sum_{i=1}^{\mu} w_i \mathbf{z}_{i:\lambda} \mathbf{z}_{i:\lambda}^T$$

$$\mathbf{p}_\sigma \leftarrow (1 - c_\sigma) \mathbf{p}_\sigma + \sqrt{1 - (1 - c_\sigma)^2} \sqrt{\mu_{eff}} \mathbf{C}^{-\frac{1}{2}} \langle \mathbf{z} \rangle_{sel} \quad \text{cumulation for } \sigma$$

$$\sigma \leftarrow \sigma \times \exp\left(\frac{c_\sigma}{d_\sigma} \left(\frac{\|\mathbf{p}_\sigma\|}{\mathbb{E}\|\mathcal{N}(\mathbf{0}, \mathbf{I})\|} - 1\right)\right) \quad \text{update of } \sigma$$

# Selecția supraviețuitorilor

Variante:

$(\mu, \lambda)$

Din  $\mu$  părinți se generează  $\lambda > \mu$  urmași iar dintre aceștia se selectează  $\mu$  supraviețuitori (obs: este important ca numărul urmașilor să fie mai mare decât cel al părinților)

$(\mu + \lambda)$

Din  $\mu$  părinți se generează  $\lambda$  urmași iar din populația reunită a părinților și urmașilor se selectează  $\mu$  supraviețuitori (selecție prin trunchiere). Este o selecție elitistă (cel mai bun element al populației nu se pierde)

**Observație:** dacă se utilizează recombinare atunci și numărul părinților ( $\rho$ ) se poate specifica:

$(\mu / \rho + \lambda)$

$(\mu / \rho, \lambda)$

# Selecția supraviețuitorilor

## Cazuri particulare:

(1+1) – dintr-un singur părinte se generează un urmaș care se acceptă doar dacă este mai bun decât părintele (similar cu algoritmi aleatori de tip Matyas sau Solis-Wets)

(1,+ $\lambda$ ) – dintr-un singur părinte se generează mai mulți urmași prin mutație; cel mai bun dintre urmași este selectat (părintele poate participa sau nu la selecție)

( $\mu$ +1) – dintr-o populație de  $\mu$  părinți se generează un fiu iar dacă acesta este mai bun decât cel mai slab element al populației atunci este selectat

**Obs:** varianta ( $\mu + \lambda$ ) este mai orientată înspre exploatare decât ( $\mu, \lambda$ )

# Selecția supraviețuitorilor

Varianta ( $\mu+1$ ) corespunde strategiei de tip “steady state” (sau asincronă)

## Strategie generațională:

- La fiecare iterație se construiește o nouă populație de urmași
- Procesul de selecție este aplicat asupra populației de urmași sau asupra populațiilor reunite
- Prelucrare **sincronă**

## Strategie steady state:

- La fiecare iterație se construiește un singur element care este asimilat în populația curentă dacă este suficient de bun
- Prelucrare **asincronă**

# Variante ale SE

Strategii de tipul  $(\mu, k, \lambda, \rho)$


Durata de viață a elementelor este limitată la  $k$  generații (elementele care au supraviețuit de-a lungul a  $k$  generații sunt eliminate – cu excepția celui mai bun element al populației)

Folosește recombinare cu  $\square$  părinți

Strategii evolutive rapide:

Perturbarea este bazată pe repartiția Cauchy

$$\varphi(x) = \frac{s}{\pi(x^2 + s^2)}$$



# Analiza comportării strategiilor evolutive

## Criterii de evaluare:

### Eficacitate:

- Valoarea funcției obiectiv după un anumit număr prestabilit de evaluări (nfe = number of function evaluation)

### Eficiența:

- Numărul de evaluări de funcții necesare pentru ca funcția obiectiv să atingă o anumită valoare (aproximare cu o anumită acuratețe)

### Rata de succes

- Raportul dintre numărul de rulări în care algoritmul atinge valoarea dorită și numărul total de evaluari



# Sumar SE

Reprezentare	Vectori cu componente reale
Recombinare	Discretă sau intermediară
Mutație	Perturbare aleatoare (uniformă, normală Cauchy)
Selecție părinți	Uniform aleatoare sau sistematică
Selecție supraviețuitori	$(\mu, \lambda)$ sau $(\mu + \lambda)$
Particularitate	Auto-adaptare a parametrilor de control a mutației