

Evoluční strategie

- Navrženy v 60. letech jako experimentální optimalizační metoda
- Založena na reálných číslech
- Velice rychlá s dobrou podporou teorie
- Jako první zavedla *self-adaptation* (úpravu sebe sama) jako standardní nástroj


Nejjednodušší ES

```
1    $t = 0$ 
2   Vytvoř P, ohodnoť P
3   while (not zastavovací podmínka) {
4        $t = t+1$ 
5        $n_i = p_i + G(0,\sigma)$            (mutace)
6       Pokud je N lepší, pak nahradí P
7   }
```

Mutace

- Směrodatná odchylka σ je nazývána „velikost mutace“
- σ je měněna podle “1/5 pravidla úspěšnosti”:
- σ změněna každých k iterací
 - $\sigma = \sigma / c$ pokud $p_s > 1/5$
 - $\sigma = \sigma \cdot c$ pokud $p_s < 1/5$
 - $\sigma = \sigma$ pokud $p_s = 1/5$
- kde p_s je % úspěšných mutací, $0.8 \leq c \leq 1$

Ilustrace normálního rozdělení pr.




Self-adaptation

- Zavedena velikostí mutací do chromozomu a jejich změnou
- Několik možností:
 - Jedna směrodatná odchylka pro všechny proměnné
 - Nekorelovaná směrodatná odchylka pro každou proměnnou
 - Korelované směrodatné odchylky

Mutace ①

- Chromosom: $\langle x_1, \dots, x_n, \sigma \rangle$
- $\sigma' = \sigma \cdot \exp(\tau \cdot N(0,1))$
- $x'_i = x_i + \sigma' \cdot N(0,1)$
- Typický “learning rate” (učící parametr)
$$\tau \propto 1/n^{1/2}$$
- A omezení nejmenší hodnoty $\sigma' < \varepsilon_0 \Rightarrow \sigma' = \varepsilon_0$

Mutace ①




Kruh představuje body se stejnou pravděpodobností mutace

Mutace ②

- Chromosom: $\langle x_1, \dots, x_n, \sigma_1, \dots, \sigma_n \rangle$
- $\sigma'_i = \sigma_i \cdot \exp(\tau' \cdot N(0,1) + \tau \cdot N_i(0,1))$
- $x'_i = x_i + \sigma'_i \cdot N_i(0,1)$
- Dva učící parametry:
 - τ' celkový
 - τ pro jednotlivé proměnné
- $\tau' \propto 1/(2n)^{1/2}$ a $\tau \propto 1/(2n^{1/2})^{1/2}$
- A opět $\sigma'_i < \varepsilon_0 \Rightarrow \sigma'_i = \varepsilon_0$

Mutace ②



Elipsa představuje body se stejnou pravděpodobností mutace

Mutace ③


- Chromosom: $\langle x_1, \dots, x_n, \sigma_1, \dots, \sigma_n, \alpha_1, \dots, \alpha_k \rangle$
- kde $k = n \cdot (n-1)/2$
- A kovarianční matice je dána:
 - $c_{ii} = \sigma_i^2$
 - $c_{ij} = 0$ pokud i a j nejsou korelovány
 - $c_{ij} = 1/2 \cdot (\sigma_i^2 - \sigma_j^2) \cdot \tan(2 \alpha_{ij})$ pokud i a j jsou korelovány

Mutace ③

Potom je mutace dána:

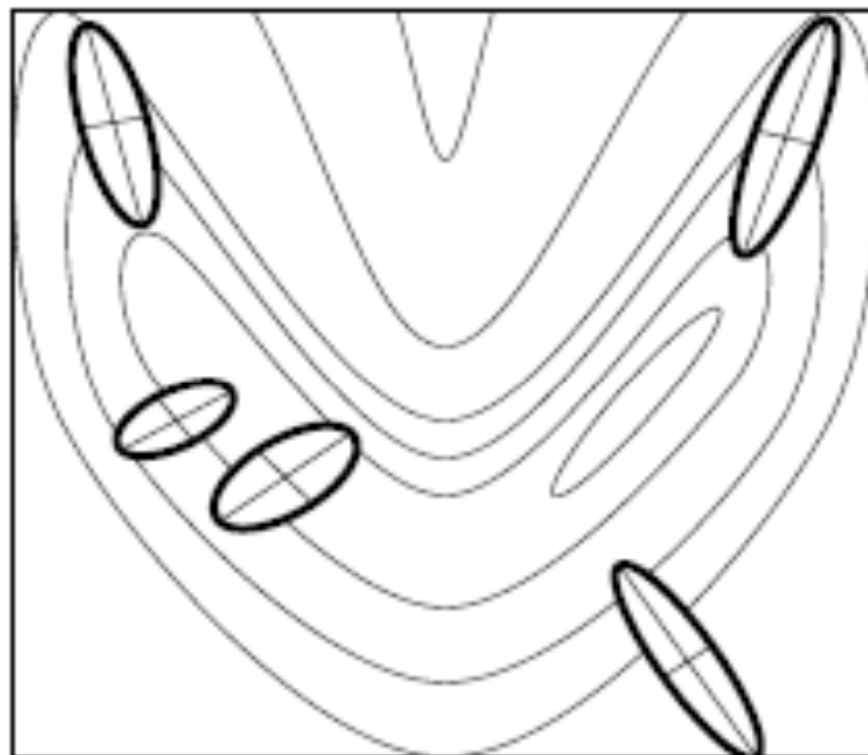

- $\sigma'_i = \sigma_i \cdot \exp(\tau' \cdot N(0,1) + \tau \cdot N_i(0,1))$
- $\alpha'_j = \alpha_j + \beta \cdot N(0,1)$
- $x' = x + N(0, C')$
 - C' je kovarianční matice C po mutaci α hodnot
- $\tau' \propto 1/(2n)^{1/2}$ a $\tau \propto 1/(2n^{1/2})^{1/2}$ a $\beta \approx 5^\circ$
- $\sigma'_i < \varepsilon_0 \Rightarrow \sigma'_i = \varepsilon_0$ a
- $|\alpha'_j| > \pi \Rightarrow \alpha'_j = \alpha'_j - 2\pi \text{sign}(\alpha'_j)$

Mutace ③





Elipsa představuje body se stejnou pravděpodobností mutace

Porovnání Mutace ② a ③




Ilustrace self-adaptation



Změna dynamické cílové funkce (vlevo) a změna směrodatné odchylky (vpravo)


Ilustrace self-adaptation




Notace ES s populací

- Dva druhy algoritmů:

- $(\mu+\lambda)$ -ES



- (μ,λ) -ES



Doporučení


- $\mu > 1$ aby se zachovaly rozdílné strategie
- $\lambda > \mu$ aby se vytvořily rozdílné strategie
- Ne tak „silná“ selekce, např., $\lambda \approx 7 \cdot \mu$
- (μ, λ) -selekce, aby nepřežili jedinci se špatnou σ

Diferenciální evoluce

- Nová metoda, vytvořena v roce 1995
- Založena na operacích na reálných vektorech
- Steady-state algoritmus
- Pouze jeden operátor a jen dva parametry => jednoduchá a přesto dostatečně robustní

Diferenciální operátor

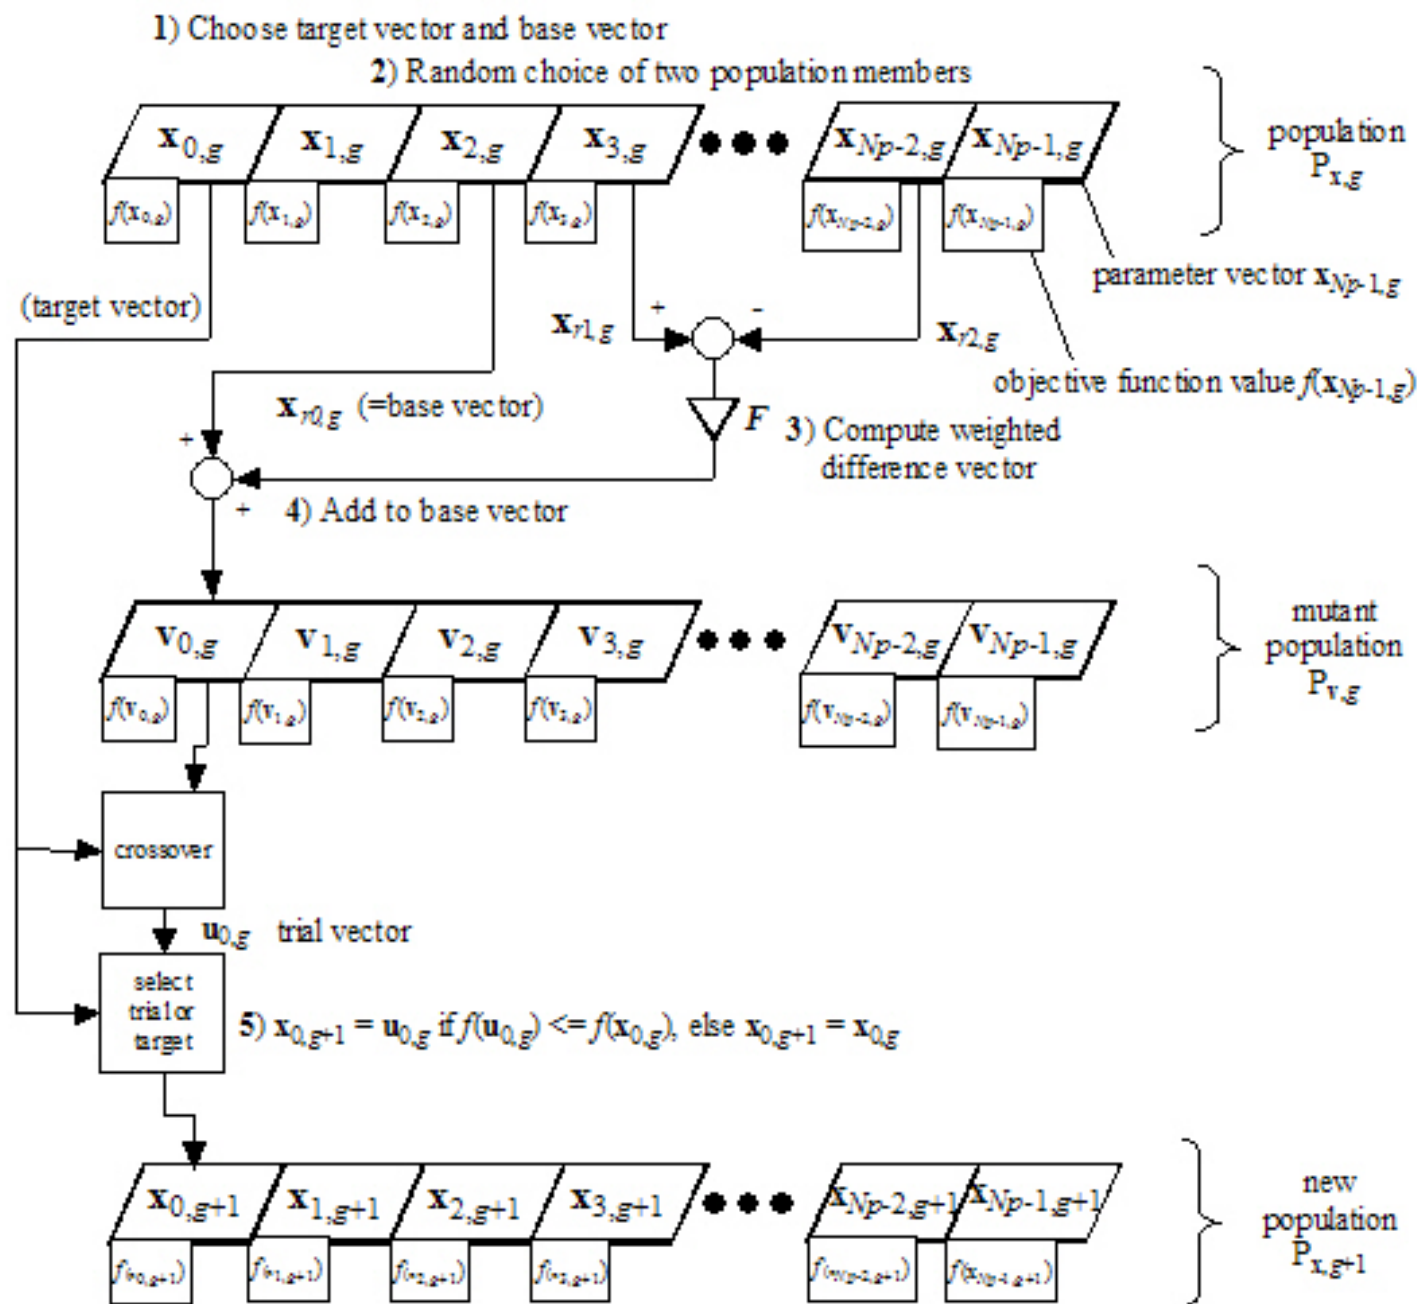
$$ch_{ij} = ch_{ij} + F_1(ch_{qj} - ch_{rj}) \\ + F_2(ch_{best,j} - ch_{ij})$$



Existuje více variant
operátoru


Náhodná selekce

Nové řešení nahradí
náhodně vybrané
pokud je lepší



- Obvykle konverguje velice rychle, ale mívá problémy vlivem neexistence „pravé“ mutace

Type 0 function



Reference

- [1] Rechenberg, I. (1973). Evolution strategy: Optimization of technical systems by means of biological evolution. Fromman-Holzboog, Stuttgart.
- [2] Schwefel, H.-P. and Bäck, T. (1995). Evolution strategies. In Périaux, J. and Winter, G., editors, Genetic Algorithms in Engineering and Computer Science. John Wiley & Sons Ltd, Chichester.
- [3] Storn, R. and Price, K. (1995). Differential Evolution : A simple and efficient adaptive scheme for global optimization over continuous spaces. Technical Report TR-95-012, University of Berkeley.
- [4] Storn, R. (1996). On the usage of differential evolution for function optimization. In NAPHIS 1996, pages 519–523. Berkeley.

Reference

- [5] A. E. Eiben, J. E. Smith, Agoston E. Eiben, J. D. Smith (2003).
Introduction to Evolutionary Computing. Springer.
- [6] Storn, R. (WWW). Homepage of Differential Evolution.
<http://www.icsi.berkeley.edu/~storn/code.html>.

Prosba. V případě, že v textu objevíte nějakou chybu nebo budete mít námět na jeho vylepšení, ozvěte se prosím na **matej.leps@fsv.cvut.cz**.

Datum poslední revize: 16.11.2007

Verze: 001