


# Genetické algoritmy

- Předpověděny J. Hollandem v 60. letech během jeho práce na *celulárních automatech*
- První „velká“ publikace o jejich použití k optimalizaci funkcí je kniha D. Goldberga z 80. let
- 2015: pro heslo „Genetic algorithms“ nalezen přibližný počet výsledků 2 920 000 (pro srovnání „Simulated annealing“ 1 430 000 výsledků)
- Za *standardní genetický algoritmus* je dnes považována binární verze z té doby

# Celulární automata (CA)




Pravidla:

- 3 Černé = Bílá
- 2 Černé = Černá
- 1 Černá = Černá
- 3 Bílé = Bílá


# 1D Celulární automata

1-dimensionální CA je založen na jedné řadě buněk (cells). Buňky se mění ze stavu do stavu podle daných pravidel.



# 2D Celulární automata



2-dimensionální CA je založen na konečné (nekonečné) síti buněk, kdy každá je v jednom z konečného počtu stavů. Čas je dán diskrétně a stav buňky v čase  $t$  je dán stavem sousedních buněk v čase  $t-1$ .



# Př.: Conway's Game of Life (Hra života)


Dvourozměrná hrací plocha Hry života se znázorňuje jako čtvercová síť. Její políčka se nazývají buňky (proto název celulární neboli buněčný automat). Každá buňka může nabývat dvou stavů, může být živá či mrtvá. Buňka sousedí s dalšími buňkami, se kterými se dotýká hranou (ortogonálně) či vrcholem (diagonálně). Nový stav buňky určuje přechodová funkce :

1. Každá živá buňka s méně než dvěma živými sousedy zemře.
2. Každá živá buňka se dvěma nebo třemi živými sousedy zůstává žít.
3. Každá živá buňka s více než třemi živými sousedy zemře.
4. Každá mrtvá buňka s právě třemi živými sousedy oživne.



[Wikimedia]

# Pr.: Conway's Game of Life




# Pr.: Conway's Game of Life



# Reálný příklad: Modelování vývoje mikrostruktury betonu

$W/c = 0.4$ , RVE  $30 \times 30 \times 30 \mu\text{m}$






[Vít Šmilauer, Zdeněk Bittnar]




# Např.: Vývin hydratačního tepla

- SCC, CEM I 42.5 R, 350 kg/m<sup>3</sup>





# Např.: Vývin hydratačního tepla

Middle



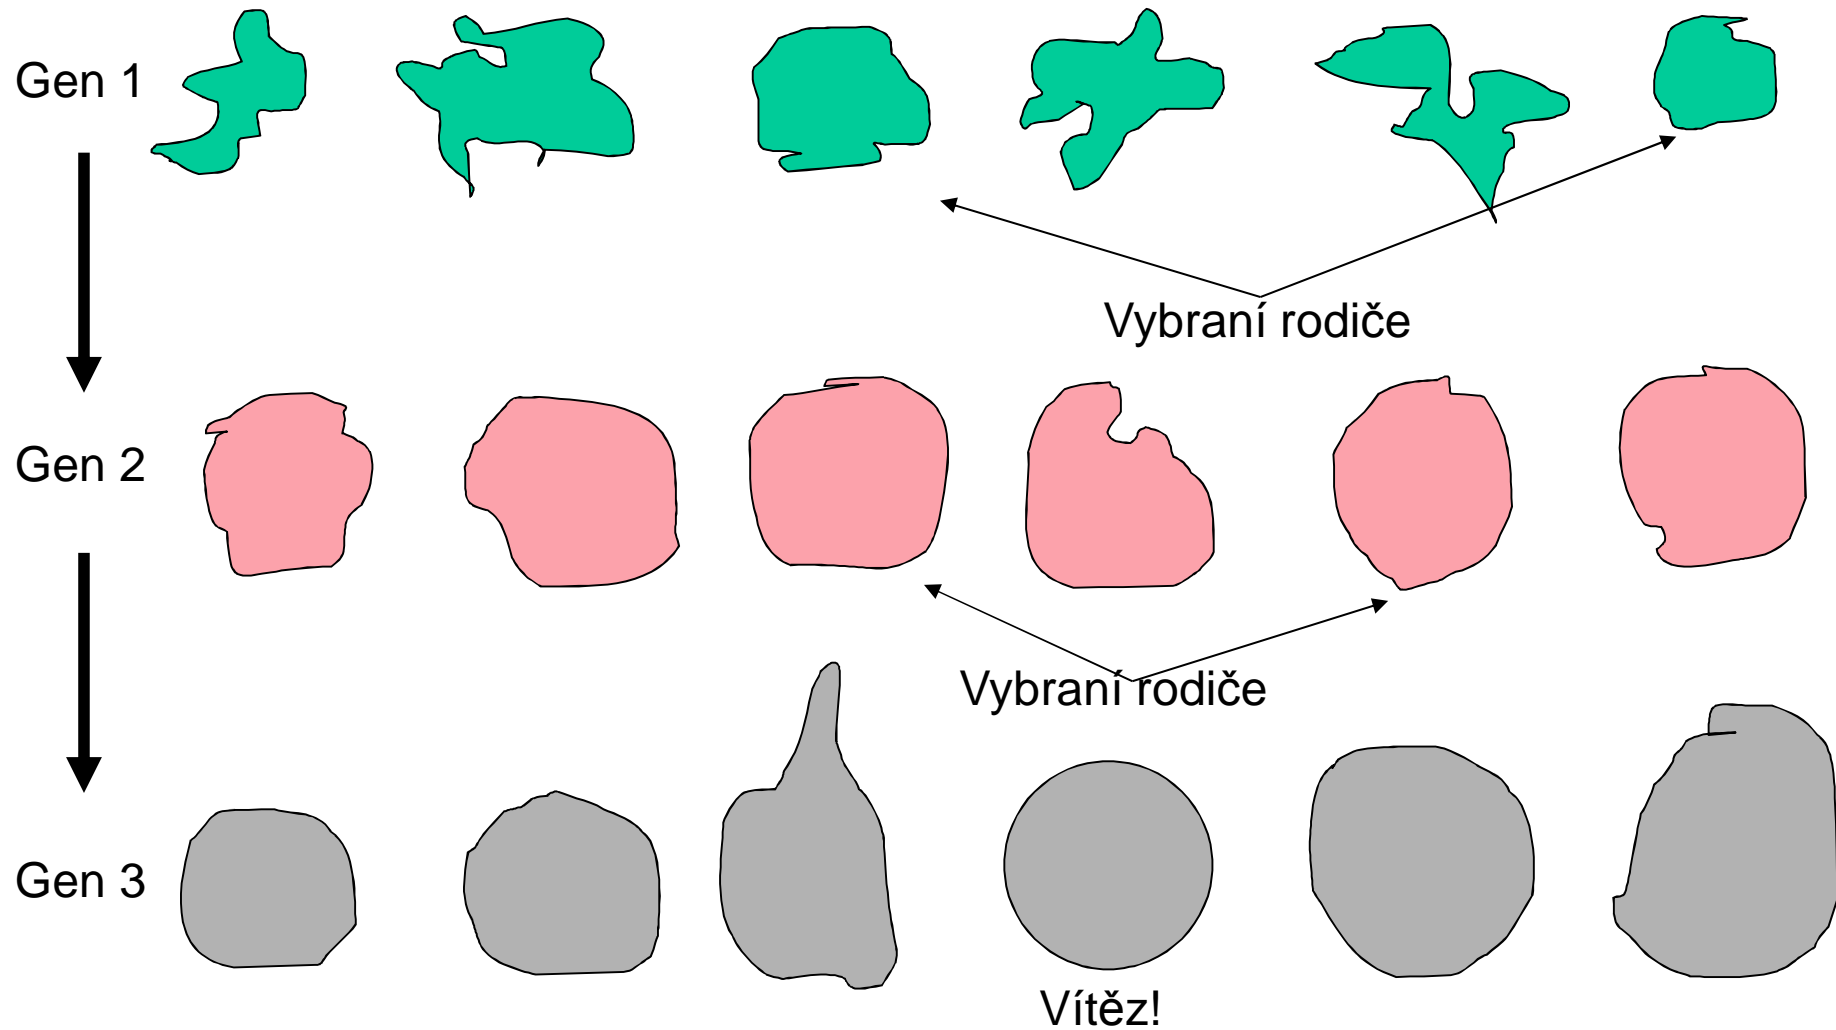
Top



# Vlastnosti GA

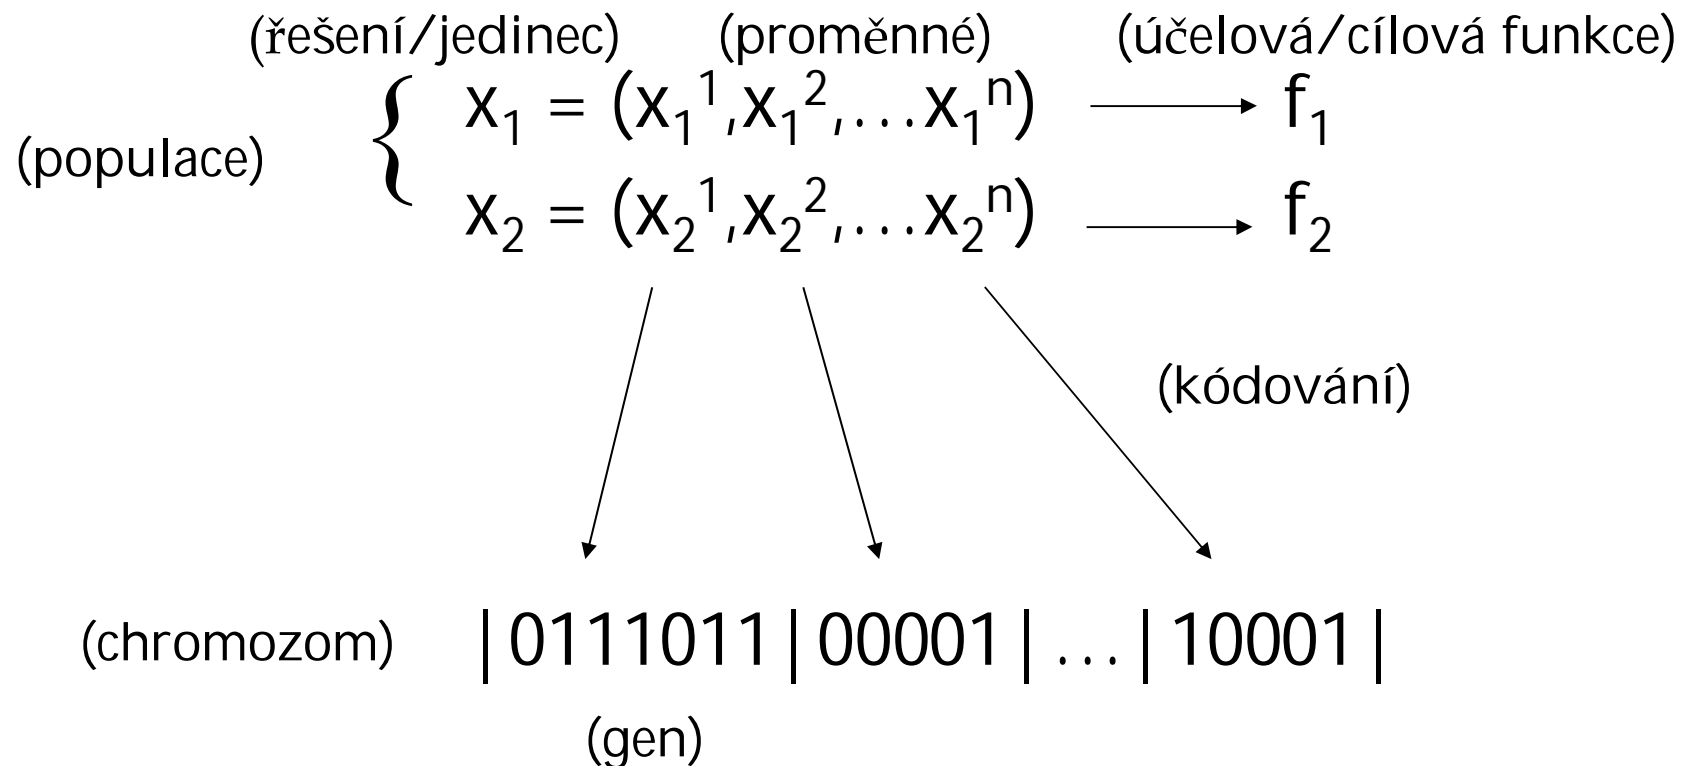
- Založeny na Darwinově myšlence „přežití nejsilnějších“
- Stochastické metody – vykazují náhodné chování
- Ne-gradientní metody- nevyžadují dokonce ani spojitost optimalizované funkce
- Důkaz konvergence založen na tzv. Schema teorému
- Většinou použity až jako poslední řešení, když ostatní metody selžou

# Přežití nejkulatějšího



# Genetické algoritmy

- Názvosloví z biologie



# Genetické algoritmy

(genotyp)	(jedinec)	(fenotyp)	(fitness/síla)
$B$	$\longrightarrow x$	$\longrightarrow f(x) = x^2$	$\longrightarrow F = \text{pořadí}$
00000000000011	$\longrightarrow 3$	$\longrightarrow 9$	$\longrightarrow F = 1$
00000000001001	$\longrightarrow 9$	$\longrightarrow 81$	$\longrightarrow F = 2$

Např.:

DNA  $\longrightarrow$  Svalovec  $\longrightarrow$  Rychlý běžec  $\longrightarrow$  Vítězství v závodech

Poznámka: V dnešních aplikacích obvykle účelová funkce a fitness splývají, nebo-li  $f \equiv F$ .

# Motivace

- Ukázkový příklad:

$$\max f(x) = x^2, \quad x[0 ; 33]$$

Řešení	Počáteční populace	Hodnota $x$	Fitness	Pravděpod.	Očekávaný počet	Aktuální počet
1	0 1 1 0 1	13	169	0,14	0,58	1
2	1 1 0 0 0	24	576	0,49	1,97	2
3	0 1 0 0 0	8	64	0,05	0,22	0
4	1 0 0 1 1	19	361	0,31	1,23	1
Suma			1170	1	4	4
Avg.			292,5	0,25	1	1
Max			576	0,49	1,97	2

Řešení	Mating pool	místo křížení	Potomci	Hodnota x	Fitness
1	0 1 1 0   1	4	0 1 1 0 0	12	144
2	1 1 0 0   0	4	1 1 0 0 1	25	625
2	1 1   0 0 0	2	1 1 0 1 1	27	729
4	1 0   0 1 1	2	1 0 0 0 0	16	256
Suma					1754
Avg.					438,5
Max					729

Řešení	Potomci	Po mutaci	Hodnota x	Fitness
1	0 1 1 0 0	1 1 1 0 0	26	676
2	1 1 0 0 1	1 1 0 0 1	25	625
2	0 1 0 1 1	0 1 0 1 1	27	729
4	1 0 0 0 0	1 0 0 1 0	18	324
Suma				2354
Avg.				588,5
Max				729



# Standardní genetický algoritmus

```
1    $t = 0$ 
2   Vytvoř  $P_0$ , ohodnoť  $P_0$ 
3   while (not zastavovací podmínka) {
4      $t = t + 1$ 
5     Vyber  $M_t$  z  $P_{t-1}$                 (aplikace výběru)
6     Změň  $M_t$                           (použití genetických operátorů)
7     Vytvoř  $P_t$  z  $M_t$  a ohodnoť  $P_t$     (vytvoření nové populace)
8   }
```

Kde  $P$  je populace, nebo-li množina možných řešení,  $M$  je tzv. mating pool (párečí rybníček),  $t$  je čítač iterací, zde nazvaných generace

# Binární reprezentace proměnných

- Celá čísla jsou v počítači uložena v lehce dostupném binárním kódu, např. pomocí binárních operátorů v jazyce C.
- V případě neexistence transformace mezi celočíselným a binárním zápisem je transformace dána:

1. Délkou binárního řetězce  $q$

$$q = \left\lceil \frac{\ln(\max_i - \min_i) - \ln(p_i)}{\ln 2} \right\rceil + 1 ,$$

# Binární reprezentace proměnných

2. Binárním řetězcem  $\mathbf{B}^i \in \{0; 1\}^q$ , který je pro danou kladnou celočíselnou hodnotu  $z_i$  dán vztahem

$$B_j^i = z_i / 2^{j-1} \pmod{2}, \quad j = 1, \dots, q.$$

3. S inverzním vztahem

$$z_i = \sum_{j=1}^q B_j^i 2^{j-1}.$$


# Hammingova bariéra

dvě čísla:

000000010000000 a

000000001111111

spolu sousedí, ale jsou v binárním kódu daleko od sebe  
(mají velkou tzv. Hammingovskou vzdálenost)




[Kvasnička et. al., 2000]

# Hammingova bariéra: řešení

1) Operátor inverze

2) Grayovo kódování

0	1/8	2/8	3/8	4/8	5/8	6/8	7/8	1
000..	001..	011..	010..	110..	111..	101..	100..	



# Operátory křížení

Záleží na typu kódování chromozomů:

- Pro binární kódování včetně Grayova kódu:
  - jednobodové křížení

původní chromozomy:

111   1111111111
000   0000000000

nové chromozomy:

111   0000000000
000   1111111111

- $k$ -bodové křížení

původní chromozomy:

111   11111   11111
000   00000   00000

nové chromozomy:

111   00000   11111
000   11111   00000

# Operátory křížení

Záleží na typu kódování chromozomů:

- Pro binární kódování včetně Grayova kódu:
  - uniformní křížení

původní chromozomy:

11111111111111
00000000000000

nové chromozomy:

1011000110101
0100111001010

Pozn. Jedno i  $k$ -bodové křížení zachovávají celistvost řešení, kdežto uniformní křížení schémata rozbíjí

# Operátory křížení

Záleží na typu kódování chromozomů:

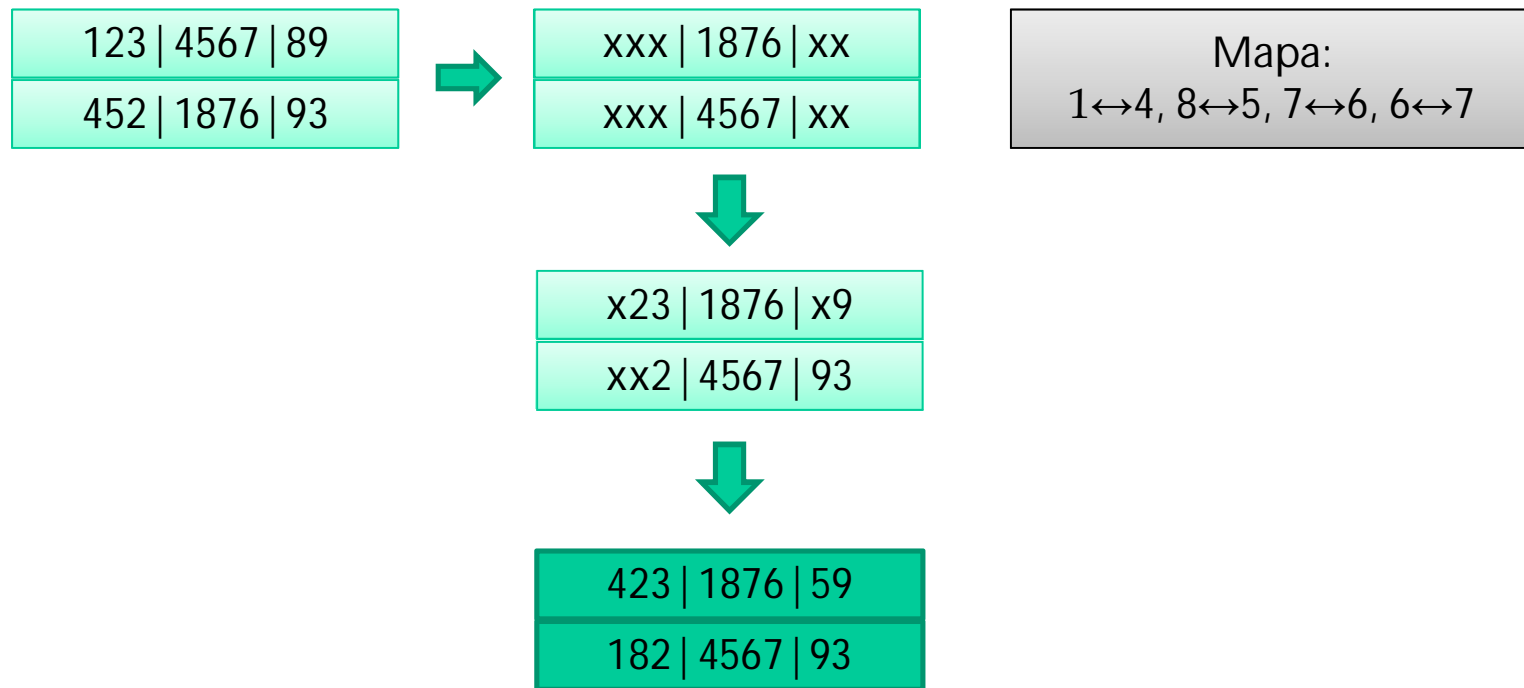
- Pro reálné reprezentace chromozomů např.:
  - Aritmetický
    - Potomek 1:  $C_1 = \alpha \cdot P_1 + (1 - \alpha) \cdot P_2$
    - Potomek 2:  $C_2 = \alpha \cdot P_2 + (1 - \alpha) \cdot P_1$
    - $\alpha$  je náhodné číslo mezi 0 a 1
  - *blend crossover* BLX- $\alpha$ 
    - Dva rodičové  $P_1$  a  $P_2$  se zadanými mezemi L a U
    - $R_1 = \max(L, P_1 - \alpha(P_2 - P_1))$
    - $R_2 = \min(U, P_2 + \alpha(P_2 - P_1))$
    - Potomci jsou vybráni náhodně mezi  $R_1$  a  $R_2$
    - $\alpha$  je většinou voleno jako 0,5



# Operátory křížení

Speciální operátory:


- **Křížení s částečným přiřazením** (PMX – *partially matched crossover*) – vhodné pro permutační úlohy



# Operátory křížení

Speciální operátory:

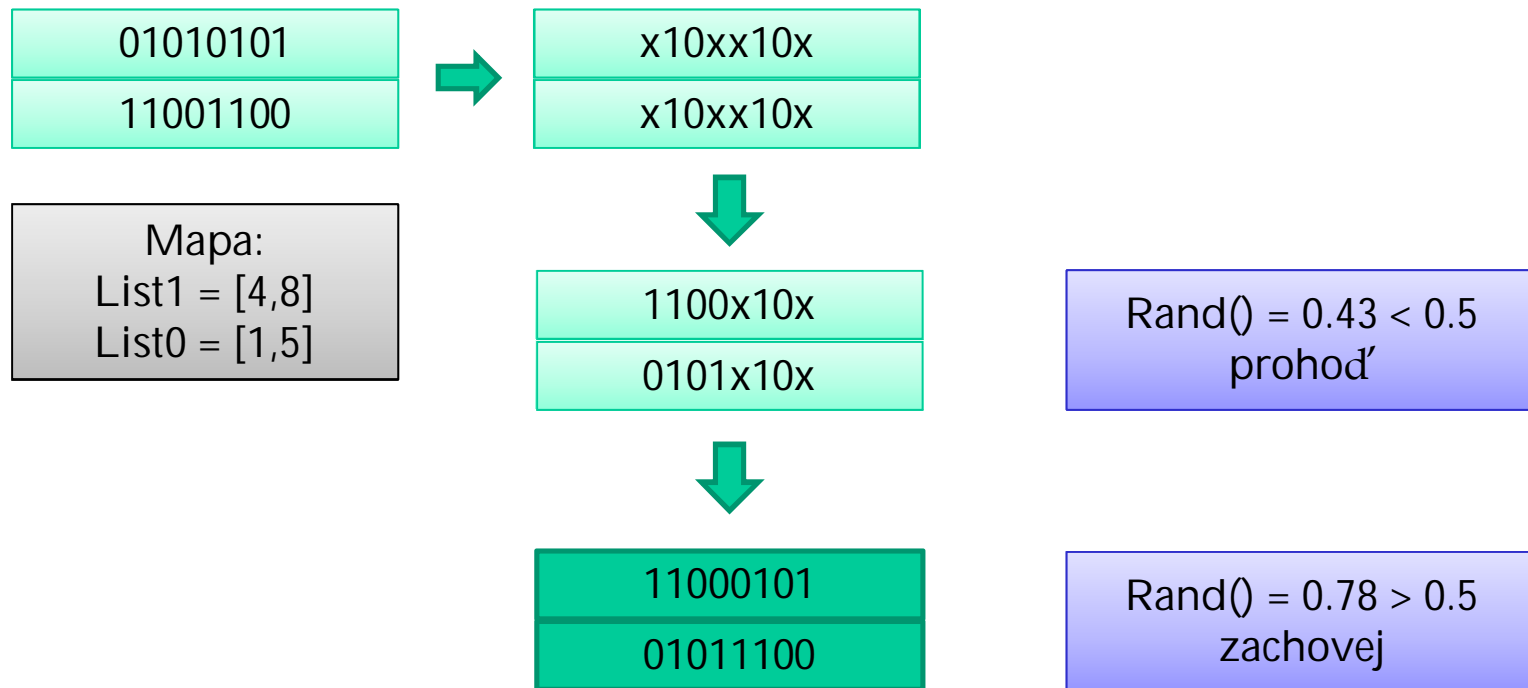
- Uniformní křížení se zachováním pořadí (*uniform order-based crossover*) – vhodné pro permutační úlohy



# Operátory křížení


Speciální operátory:

- Křížení se zachováním počtu (CPC – *count preserving crossover*) – pro úlohy zachovávající počet 1 a 0



# Operátory mutace


Záleží na typu kódování chromozomů:

- Pro binární kódování včetně Grayova kódu:
  - Jednabitová mutace
  - Vícebitová mutace až Uniformní mutace
- Pro reálné kódování:
  - Náhodná výměna – alela se nahradí jinou
  - Aditivní změna – k původní alele se přičte náhodně vygenerovaná hodnota  $c \in \langle -\varepsilon, \varepsilon \rangle$
  - Gaussovská mutace – k původní alele se přičítá normálně rozdělené číslo s nulovou střední hodnotou a  $\sigma$  směrodatnou odchylkou
- Speciální operátory pro permutační i objem zachovávající úlohy
  - Prohození dvou alel 

# Výběr řešení

- Ve fázi tvorby *mating pool*, tzv. *parent selection*, nebo při tvoření nové *generace*, tzv. *survivor selection*
- Množství možných metod, zde uvedeme:
  - Roulette wheel (ruleta)
  - SUS – Stochastic Universal Sampling
  - Tournament selection (turnajový výběr)
  - Inverzní turnajový výběr
  - Elitismus
  - Ranking a linear scaling


# Ruleta



# Ruleta

- Tradiční nástroj
- Nezaručuje vybrání nejlepšího jedince, zejména pro velikosti populace v řádu desítek a výše
- Výpočetně náročná metoda,  $n \times \mathbf{RND}()$

# SUS – Stochastic Universal Sampling





# SUS – Stochastic Universal Sampling

- Nezaručuje vybrání nejlepšího jedince, zejména pro velikosti populace v řádu desítek a výše, ale
- Zaručuje celočíselné očekávané počty, např. řešení s  $c = 2,0001$  bude vždy vybráno 2x
- Výpočetně nejméně náročná metoda, pouze 1 x **RND( )** !

# Turnajový výběr

- Vybere z populace náhodně  $k$  „soutěžících“ (nejčastěji  $k = 2$ ) a z nich vybere nejlepšího (turnaj) a tento postup se provede  $n$ -krát
- Nezaručuje vybrání nejlepšího jedince tím, že existuje pravděpodobnost, že nebude zařazen do turnaje
- Výpočetně náročné,  $k \times n \times \mathbf{RND}()$

# Inverzní turnajový výběr

- Určená pro výběr  $p$  řešení, kde  $p < n$
- Vybere z populace náhodně  $k$  „soutěžících“ (nejčastěji  $k = 2$ ) a z nich „zahodí“ nejhoršího (inverzní turnaj) a tento postup se provede  $n$ -krát
- Jako jedna z mála metod zaručuje vybrání nejlepšího jedince
- Nejvíce „demokratická“ metoda – existuje pravděpodobnost vybrání nejhoršího řešení tím, že se nedostane do turnaje
- Výpočetně náročná metoda,  $k \times n \times \mathbf{RND}()$

# Elitismus

- Má dva významy:
  - 1) Výběr nebo kopie nejlepšího řešení do další generace. Používá se nejčastěji z důvodu ztráty takového řešení vlivem náhody při výběru ruletou či turnajem
  - 2) Vlastnost nebo postup, který upřednostňuje „lepší“ řešení před ostatními.  
Např. turnaj s  $k = 3$  je více *elitistický* než turnaj s  $k = 2$

# Ranking a linear scaling

- Metody na úpravu fitness, na podporu nebo naopak na potlačení *elitismu*
- Ranking přiděluje fitness nikoliv na základě velikosti účelové funkce, ale podle pořadí daného řešení vzhledem k populaci. Např. nejlepší řešení bude mít očekávaný počet kopií 3, druhé nejlepší 2 a ostatní do výběru po 1 a zbytek (nejhorší řešení) 0.

# Ranking a linear scaling

- Linear scaling určuje fitness tak, aby fitness populace měla lineární průběh, byl zachován průměr hodnot účelových funkcí a aby maximální fitness byl v intervalu 1,2-2,0 násobku průměru (voleno uživatelem)

# Důkaz konvergence: „Schema theorem“

dvě řešení:

01010010100101010101110101010101 a  
01011010100101110001110111010111

jsou pokryty schematem:

0101#010100101#10#011101#10101#1

Očekávané množství výskytu určitého schematu v čase  $t+1$

$$m(H, t+1) \geq m(H, t) \cdot \frac{f(H)}{\bar{f}} \cdot \left[ 1 - P_c \frac{\delta(H)}{L-1} - P_m o(H) \right]$$

Viz Doc. Lažanský

# Premature Convergence


(předčasná konvergence)

- V případě, že jeden genotyp obsadí celou populaci, je populace *konvergovaná*
- Konvergence je *předčasná*, pokud nebylo nalezeno požadované řešení
- Řešení:
  - Udržování diversity v populaci
  - Multi-modální řešení



# Deceptive functions

(klamavé funkce)



Viz. Robust design optimization

# Reference

- [1] Holland, J. H. (1975). *Adaptation in Natural and Artificial Systems*. MIT Press.
- [2] Goldberg, D. (1989). *Genetic Algorithms in Search, Optimization and Machine Learning*. Addison-Wesley.
- [3] Michalewicz, Z. (1992). *Genetic Algorithms + Data Structures = Evolution Programs*. AI Series. Springer-Verlag, New York.
- [4] Wolfram, S. (2002). *Cellular Automata and Complexity*. Perseus Publishing.
- [5] A. E. Eiben, J. E. Smith (2003). *Introduction to Evolutionary Computing*. Springer.
- [6] Dreoj, Petrowsky A, Siarry P and Taillard E. (2006). *Metaheuristics for hard optimization. Methods and case studies*. Berlin Heidelberg: Springer

# Reference

- [7] P. Convey, R. Highfield: Mezi chaosem a řádem. Mladá fronta, 2003.
- [8] Dawkins, Richard: Sobecký gen. Mladá fronta, edice: Kolumbus, 2003.
- [9] Zrzavý, Jan; Storch, David; Mihulka, Stanislav: Jak se dělá evoluce. Paseka, edice: Fénix, 2004.
- [10] Mařík, V. a kol: Umělá inteligence I-IV, Academia, 1996—2003.
- [11] V. Kvasnička, J. Pospíchal, P Tiňo (2000). Evolučné algoritmy. STU Bratislava.

**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**.

Oprava 28.3.2008: Strana 37,34, Opravena reference [4] a přidána refernce [6]

Oprava 28.3.2008: Strana 18, Opravena reference

Oprava 9.11.2008: Strana 12 a 14, Oprava a zvýraznění

Oprava 9.11.2008: Vymazány stránky s celočíselným a reálným kódováním

Oprava 9.11.2008: Prohozena reference [4] a [5]

*Datum poslední revize: 9.11.2008*

*Verze: 002*