

Genetické algoritmy

Typy metaheuristických prehľadávacích algoritmov

- Algoritmus horolezca (hill climbing)
- Simulované žíhanie (simulated annealing)
- Zakázané hľadanie (tabu search)
- Evolučné algoritmy (evolutionary algorithm)
- Optimalizácia krdľom častíc (particle swarm optimization)
- ...

Genetické algoritmy

- Patria medzi evolučné algoritmy:
 - Evolučné stratégie
 - Evolučné programovanie
 - Automaty
 - Genetické programovanie
 - **Genetické algoritmy**

História

- 1960: Ingo Rechenberg predstavuje myšlienku evolučných výpočtov v práci „Evolution strategies”
- 1975: John Holland ako prvý opisuje genetický algoritmus a vydáva knihu „Adaptation in Natural and Artificial Systems”
- 1992: John Koza použil genetický algoritmus pre vývoj programov, ktoré majú vykonávať zadané úlohy. Metódu nazval genetické programovanie

Genetické algoritmy

- Genetické algoritmy (GA) sú robustný optimalizačný prístup, ktorý je odvodený od princípov prirodzeného výberu a prirodzenej genetiky
- Predstavujú výber najúspešnejšieho jedinca alebo riešenia spomedzi všetkých reprezentantov, alebo všetkých možných riešení ohraničeného priestoru

Základné atribúty GA

- Sú to náhodné prehľadávacie metódy, ktoré oproti iným optimalizačným metódam nevyžadujú žiadne priebežné informácie o riadení výpočtu
- Aplikáciou troch základných operácií: selekcie, kríženia a mutácie sa realizuje optimalizačný mechanizmus tak, aby sa hodnota účelovej funkcie minimalizovala (maximalizovala)
- GA sa vo všeobecnosti dokážu dostať z okolia lokálnych extrémov, kde môžu iné optimalizačné metódy uviaznuť a sú schopné nájsť alebo sa aspoň priblížiť ku globálnemu optimu

Základné pojmy

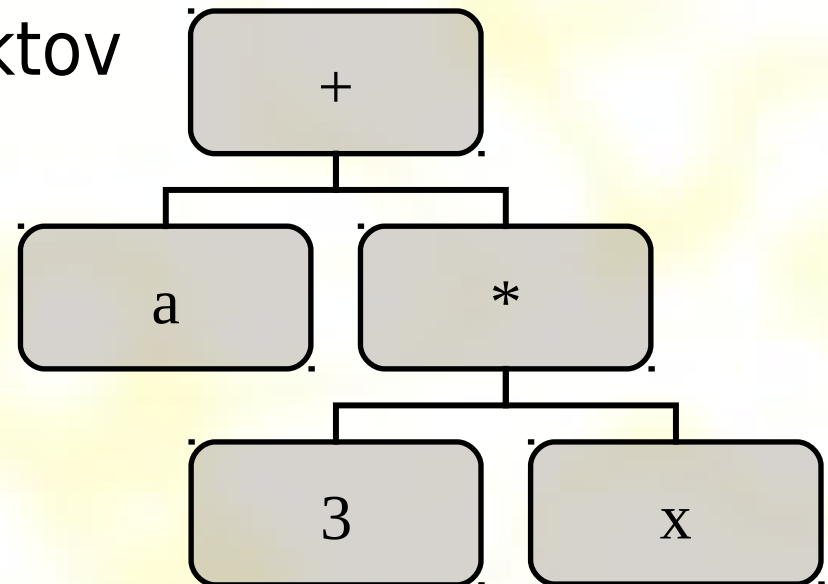
- Jediniec – nositeľ genetickej informácie
- Populácia – tvorená jedincami
- Chromozóm – reťazec génov
- Gén – reťazec kódujúci jednu vlastnosť
- Genotyp – konkrétne hodnoty génov jedinca
- Fenotyp – objekt v priestore riešeného problému, z ktorých hľadáme najlepšieho predstaviteľa. Pri výpočte fitness sa transformuje genotyp na fenotyp
- Kríženie, mutácia, výber – základné operácie GA
- Ohodnotenie populácie – fitness funkcia
- Pravdepodobnostné hodnoty kríženia a mutácie

Voľba dĺžky reťazca

- **Pevná** - štruktúra riešeného problému (objektu) je pevne zvolená a hľadáme iba jej parametre / prvky
- **Premenlivá** - štruktúra riešeného problému (objektu) nie je známa, je cieľom riešenia spolu s jej parametrami / prvkami

Príklady genotypov

- binárny reťazec - [1 0 0 1 1 1 1 0]
- celočíselný reťazec - [2 7 7 9 0 5 3]
- reálnočísel. reťazec - [7.1 2 10 0.02 258 99.9]
- symbolový reťazec - [NB NM NS Z PS PM PB]
- stromová štruktúra objektov
- ...



Voľba typu prvkov v reťazci genotypu

- binárny reťazec
 - úloha o batohu
- celočíselný reťazec
 - problém obchodného cestujúceho
 - poradie vykonávaných operácií/transakcií
- reálnočíselný reťazec
 - hľadanie extrému funkcie viacerých premenných
- stromová štruktúra objektov
 - genetické programovanie, používa sa ak je reprezentácia prehľadávaného premenlivá

Neexistuje návod, ktorý typ je na danú úlohu najvhodnejší

Chromozóm

- Základný prvok generácie (populácie jedincov)
- Je to zoskupenie elementov (génov) v reťazci
- Každý chromozóm predstavuje jedno riešenie daného problému
- Možnosti reprezentácie elementov:
 - binárny reťazec (úloha o batohu)
 - celočíselný reťazec (obchodný cestujúci)
 - reťazec reálnych čísel
 - reťazec symbolov (prirodzená reprezentácia)
 - zoskupenie prvkov stromovej štruktúry
 - ...

Populácia

- Veľkosť populácie = počet jedincov (chromozómov) v danej časovej etape resp. v konkrétnom výpočtovom cykle – generácii
- Prvá populácia je vygenerovaná náhodne
- Príklad celočíselnej populácie:

[1 2 3 4 5 6 7

5 8 9 3 0 1 3

8 1 1 1 0 2 7

8 9 1 9 9 0 6]

Fitness funkcia

- Predstavuje samotnú podstatu optimalizovaného problému
- Vyjadruje mieru vhodnosti potenciálneho riešenia
- Cieľom je nájsť riešenie s jej minimálnou resp. maximálnou hodnotou
- Jej výstupnými hodnotami sú zvyčajne skalárne (obyčajne reálnočíselné) hodnoty
- Má veľký vplyv na to, ktoré chromozómy (jedinci) ostanú v populácii

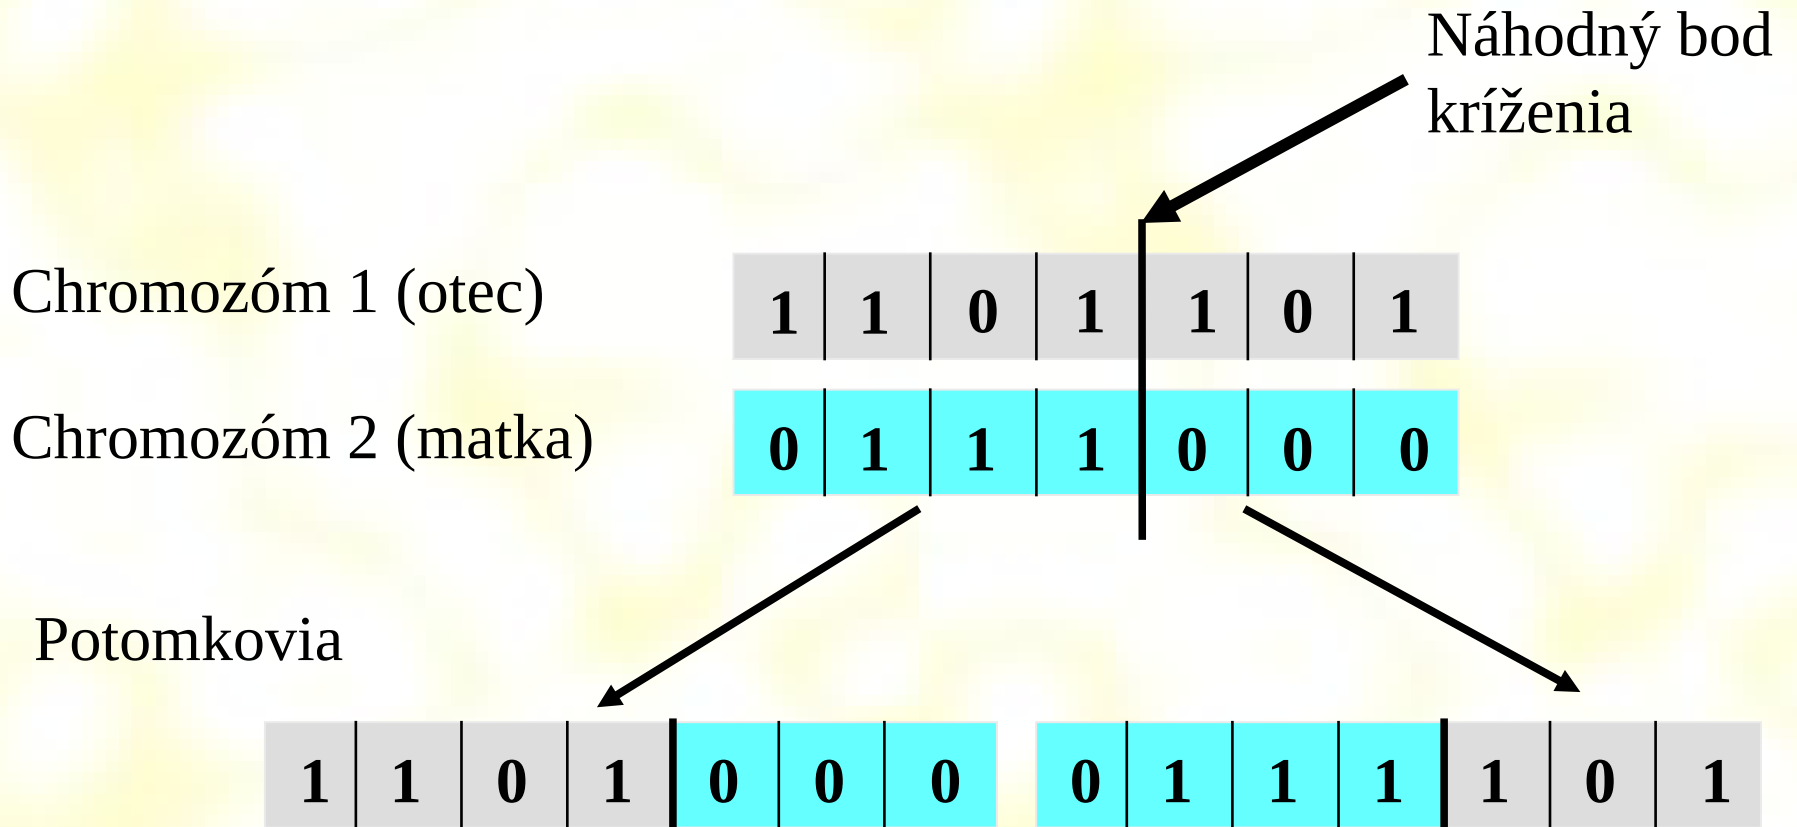
Základné genetické operácie

- Kríženie (jednobodové, viacbodové, uniformné)
- Mutácia
- Selekcia – výber

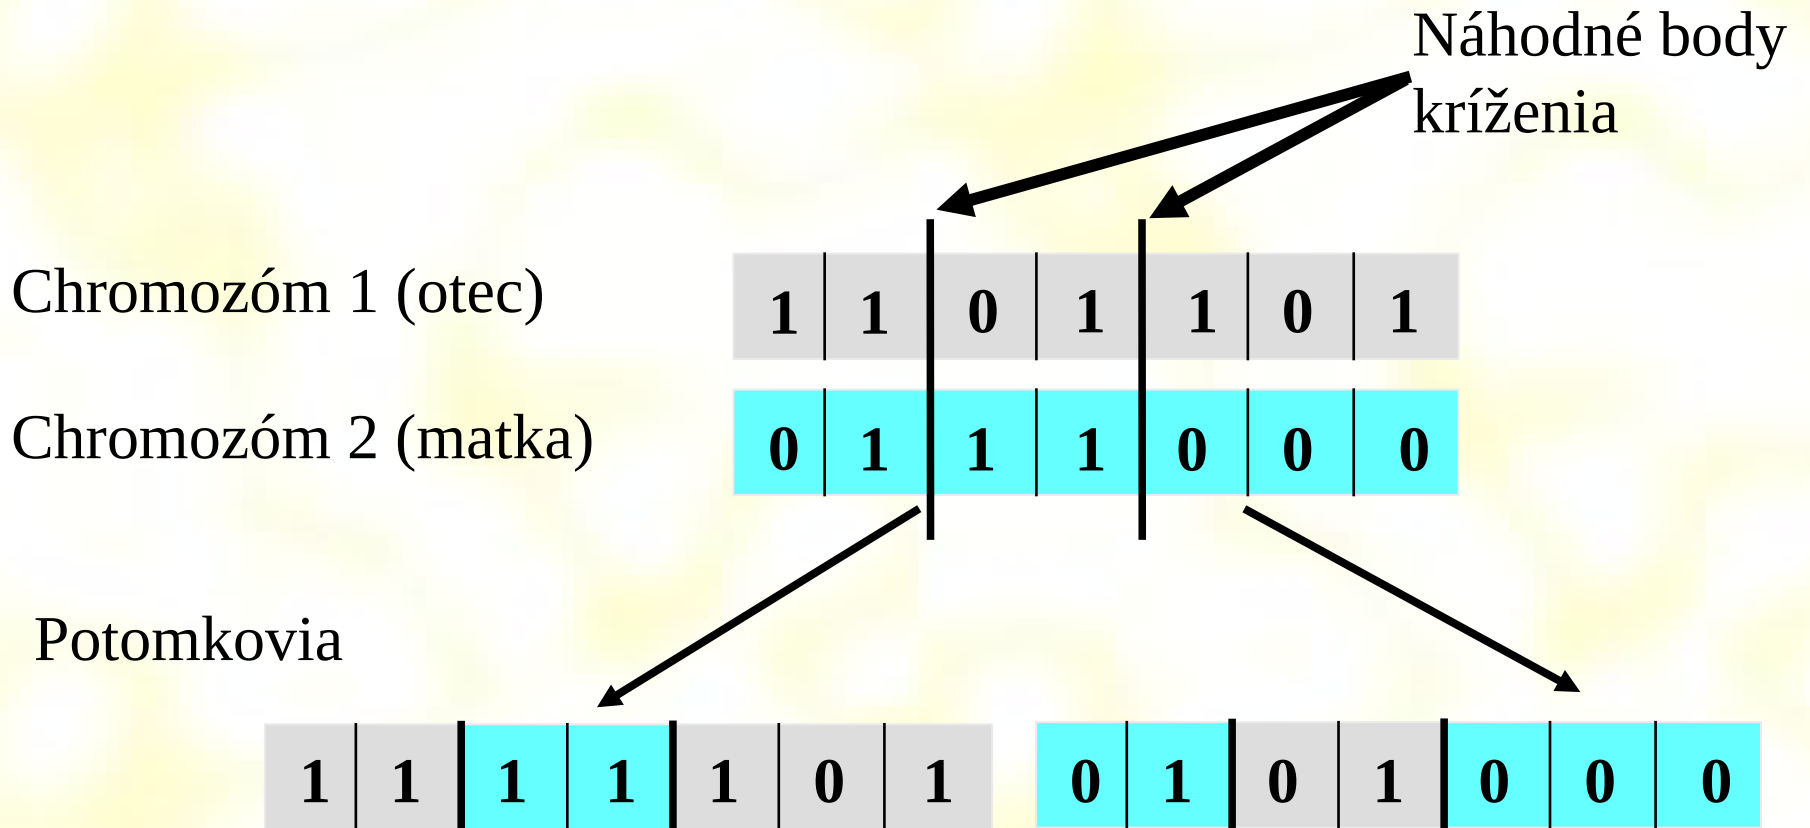
Kríženie

- Z dvoch chromozómov (otec a matka) sa spojením vytvorí jeden alebo viac nových chromozómov (potomkov), ktorí neboli súčasťou predchádzajúcej populácie
- Najvhodnejší spôsob spájania je náhodný výber miesta spojenia a vzájomné prekríženie jednotlivých častí (génov)
- Existuje viac typov operátorov kríženia:
 - kríženie
 - zmena hrany
 - ...

Príklad jednobodového kríženia



Príklad dvojbodového kríženia



Mutácia

- Používa sa, aby riešenie neuviazlo v lokálnom optime
- Rozširuje prehľadávaný priestor o riešenia, ktoré nie je možné dosiahnuť krížením
- Ide o náhodnú genetickú zmenu práve vytvoreného potomka
- Nie každý nový jedinec musí mutovať – daná je hodnota, ktorá určuje koľko percent potomkov je podrobených mutácií

Príklad mutácií

Binárny reťazec

1 1 0 1 0 0 0 1 0

1 1 0 1 0 1 0 1 0

Číselný reťazec

7.2 5.03 1999 0.001

7.2 5.07 1999 0.001

Znakový reťazec

NB PB Z NM NS Z


NB PB Z NM PB Z

Selekcia - výber

- Darwinova teória: „najlepší prežijú a stvorí potomkov“
- Existujú rôzne metódy výberu „najlepšieho potomka“:
 - ruletový výber (rulet wheel selection)
 - výber najväčších n hodnôt (rank selection)
 - turnaj (tournament selection)
 - inverzný turnaj
 - elitárstvo (elitism)
 - stochastic universal sampling
 - ...

Ruletový výber

- Tradičný nástroj, nezaručuje vybratie najlepšieho jedinca, ak je veľkosť populácie v stovkách a viac
- Každý jedinec dostane na ruletovom kole priehradku veľkosti $p_i = f_i / \sum f_j$ úmernej jeho ohodnoteniu fitness funkciou - to bude pravdepodobnosť, že bude reprodukováný
- Ruletou sa otočí n krát



Nevýhody ruletového výberu

- Nezaručuje vybratie najlepšieho jedinca, ak je veľkosť populácie v stovkách a viac
- Keď všetci jedinci majú podobné ohodnotenie: náhodné prehľadávanie s genetickým posunom
- Keď jeden až dvaja jedinci majú ohodnotenie o mnoho vyššie než zvyšok populácie: takmer všetci jedinci v novej generácii budú kópiou toho istého jedinca, predčasná konvergencia
- Riešenie je napr. použiť preškálovanie častí

Výber podľa poradia

- Obdoba ruletového výberu - nepracujeme s hodnotami fitness funkcií ale s poradovým číslom jedinca
- Jedinci sa zoradia podľa ohodnotenia a pravdepodobnosť reprodukcie je úmerná poradiu jedinca, nie jeho ohodnoteniu
- Pomalšia konvergencia
- Vylepšenie - jedincov usporiadame podľa veľkosti ohodnotenia, M najlepších jedincov okopírujeme O krát tak, že $N = M \times O$

Turnajový výber

- Náhodne vybraní jedinci z populácie podstupujú „súboj o prežitie“
- Turnajom sa náhodne vyberú 2 jedinci a vygeneruje sa náhodné číslo $r \in \langle 0, 1 \rangle$, ak je $r < T$, (T je preddefinovaný parameter), tak bude okopírovaný jedinec s vyšším ohodnotením, inak ten druhý
- Výhody - jednoduchá implementácia, zaisťuje rozmanitosť i selekčný tlak
- Nezaručuje vybratie najlepšieho jedinca, keďže existuje pravdepodobnosť, že nebude zaradený do turnaja

Elitárstvo

- Do ďalšej generácie je skopírovaných bez zmeny niekoľko najlepších jedincov
- Zaisťuje zachovanie najlepších jedincov
- Môže značne urýchliť riešenie
- Používa sa najčastejšie z dôvodu straty dobrých jedincov vplyvom náhody pri výbere ruletou či turnajom

Distribúované GA

- Jedinci sú v populácii rozmiestnení napr. v dvojrozmernom priestore (napr. toroid) a selekcia s krížením sa vykonáva lokálne
- Subpopulácie sa prekrývajú - tým je možné šírenie „dobrých“ vlastností cez celú populáciu

Algoritmus

- Vytvor prvú populáciu jedincov
- Ohodnoť jedinca v populácii fitness funkciou $f(x)$
- Vytvor novú populáciu:
 - Vyber rodičov zvolenou metódou selekcie
 - Vytvor nových jedincov krížením a mutáciou
 - Ohodnoť nových jedincov
 - Pridaj potomkov do populácie
- Nahrad' starú populáciu novou
- Opakuj, pokiaľ nie sú splnené podmienky zadania

Parametre GA

- Počet jedincov v generácii
- Pravdepodobnosť kríženia:
Udáva frekvenciu kríženia
 - 0% - nová populácia je kópiou pôvodnej
 - 100% - každý potomok je vytvorený pomocou kríženia
- Pravdepodobnosť mutácie:
Udáva frekvenciu mutácie nových potomkov
 - 100% - každý chromozóm je pozmenený
 - 0% - ani jeden nie je pozmenený

Využitie GA

- Učenie neurónových sietí
- Optimalizácia nakladania kontajnerov
- Učenie chovania robotov
- Optimalizácia infraštruktúry pre mobilnú komunikáciu
- Optimalizácia štruktúry molekúl
- Návrh usporiadania výrobných hál
- Rôzne plánovacie problémy (napr. keď jednotlivé úlohy sú navzájom závislé)
- Predpoveď akciových trhov

Základné predpoklady použitia

- Možnosť reprezentovať potenciálne riešenia (objekty optimalizácie) vo forme lineárneho reťazca parametrov alebo znakov, ktoré jednoznačne určujú jeho vlastnosti
- Algoritmizovateľnosť účelovej funkcie
- Výkonná výpočtová technika

Vlastnosti GA

- Dajú sa použiť pre riešenie problémov inak ťažko riešiteľných, napr. keď interakcie medzi jednotlivými časťami sú ťažko opísateľné
- Klady:
 - väčšinou nekončia v lokálnom maxime
 - vždy poskytnú nejaké riešenie
 - sú ľahko implementovateľné a paralelizovateľné
- Zápory:
 - nemáme záruku, že nájdené riešenie je optimálne
 - môžu byť veľmi pomalé (ak sú zle navrhnuté reprezentácie jedincov a operátory kríženia a mutácie)
 - vyžadujú vhodné nastavenie vstupných parametrov

Príklady štatistických fitness funkcií

MSE

$$mse(\mathbf{x}, \mathbf{y}) = \frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2$$

MAE

$$mae(\mathbf{x}, \mathbf{y}) = \frac{1}{N} \sum_{i=1}^N |x_i - y_i|$$

MSE REG

$$msereg(\mathbf{x}, \mathbf{y}) = \gamma \cdot mse(\mathbf{x}, \mathbf{y}) + (1 - \gamma) \cdot msw \quad msw = \frac{1}{n} \sum_{j=1}^n w_j^2$$

AIC

$$aic(\mathbf{x}, \mathbf{y}) = \log \left(\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2 \right) + \frac{2p}{N}$$

BIC

$$bic(\mathbf{x}, \mathbf{y}) = \log \left(\frac{1}{N} \sum_{i=1}^N (x_i - y_i)^2 \right) + \frac{p \cdot \log(N)}{N}$$