

# **Hľadanie globálneho extrému reálnej funkcie reálnej premennej pomocou genetického algoritmu**

***Tomáš Kaláb, FMFI UK***

Tomas.Kalab@st.fmph.uniba.sk

## Genetický algoritmus

Genetický algoritmus je jednou z metód na riešenie optimalizačných úloh. Pomocou genetického algoritmu je často možné riešiť problémy, ktoré sú analyticky neriešiteľné, alebo je ich riešenie príliš náročné na výpočtovú časť. Existujú úspešné približné riešenia NP úplných problémov využívajúce práve genetický algoritmus (napríklad problém obchodného cestujúceho). Pri vhodnej voľbe parametrov dokáže genetický algoritmus v mnohých prípadoch nájsť riešenie blízke optimálnemu za cenu omnoho menšiu než akú vyžaduje exaktné riešenie. Použitie genetického algoritmu však nezaručuje nájdenie optimálneho riešenia, nezaručuje dokonca vôbec nájdenie nejakého riešenia. Výsledok práce genetického algoritmu je závislý od náhody. Riešenie je dosiahnuté len s určitou pravdepodobnosťou, menšou ako 1. Preto je genetický algoritmus zaradený do triedy pravdepodobnostných algoritmov.

Myšlienka genetických algoritmov je inšpirovaná darwinovskou evolúciou v prírode. Pozíciu jedincov v prírode tu zastávajú jednotlivé riešenia (resp. kandidáti na riešenie) problému. Evolučným tlakom sú postupne slabé jedince (riešenia ďaleko od optima) eliminované, a naopak silnejším je poskytnutý priestor na ďalší vývoj. Vývoj jedinca nastáva prostredníctvom malých zmien. V prípade že zmena jedinca oslabí (riešenie sa zhorší), nový jedinec je eliminovaný evolučným tlakom. V prípade že zmena povedie k vylepšeniu vlastností jedinca, má novovzniknutý jedinec vysokú pravdepodobnosť zachovania a ďalšieho vývoja.

## Základné pojmy


Pri použití genetického algoritmu je nutné zakódovať potenciálne riešenia do štruktúr, ktoré umožnia ľahkú manipuláciu s informáciou o riešení. Takéto zakódované riešenie sa nazýva chromozóm. Konkrétny tvar chromozómu závisí od riešeného problému. Môže to byť binárny vektor, reťazec znakov nejakej abecedy, permutácia a podobne.

Významným rozdielom genetického algoritmu oproti iným približným riešeniam je to, že nepracuje s jediným riešením problému, ale s celou množinou  $N$  nezávislých riešení. Táto množina sa nazýva populácia chromozómov. Veľkosť populácie je jedným z dôležitých parametrov na ktorom závisí úspešnosť a rýchlosť konvergencie algoritmu.

Práca genetického algoritmu prebieha v diskretných etapách – generáciách. Prvá generácia je tvorená náhodne vygenerovanými chromozómami. Každá ďalšia generácia je vytváraná z chromozómov predchádzajúcej generácie. Chromozómy sa do novej (detskej) generácie môžu dostať jedným z nasledujúcich spôsobov:

1. Priamym prechodom z rodičovskej generácie – chromozóm sa do detskej generácie priamo bez zmeny kopíruje
2. Mutáciou – chromozóm je s malou zmenou kopírovaný z rodičovskej generácie do detskej
3. Krížením - detský chromozóm vznikne ako kombinácia dvoch alebo viacej rodičovských chromozómov
4. Kombináciou kríženia a mutácie.

Konkrétny tvar operácií mutácie a kríženia závisí od tvaru chromozómu. Napríklad pri použití chromozómu tvaru binárneho vektora môže byť operácia mutácie realizovaná zamenou hodnoty niektorého bitu vektora. Operácia kríženia dvoch chromozómov môže byť v tomto prípade realizovaná napríklad tak, že po určitej pozícii sa kopíruje obsah prvého rodiča a od tejto pozície obsah druhého, čím vznikne prvý potomok a zo zvyšných častí vznikne druhý. Podľa pozícií na ktorých sa mení zdrojový chromozóm možno kríženie deliť na jednobodové, dvojbodové, atď. Mutácia alebo kríženie nastáva s dopredu zadanými pravdepodobnosťami. Tieto pravdepodobnosti sú ďalšími dôležitými parametrami, na ktorých závisí úspešnosť algoritmu.



Obr 1: Príklad jednobodového kríženia

Výber rodičovských chromozómov prebieha kvázinahodne. To znamená, že výber síce nie je deterministický a závisí od náhod, ale je vykonávaný tak, aby pravdepodobnosť výberu úspešnejších jedincov bola vyššia ako menej úspešných. Aby bolo možné takýto výber vykonať, musí byť úspešnosť jednotlivých chromozómov

vyjadrená takou formou, aby bolo možné jednotlivé chromozómy navzájom porovnávať. Túto úlohu plní takzvaná Fitness funkcia. Fitness funkcia je reálna funkcia definovaná na priestore chromozómov. Hodnota Fitness nejakého chromozómu vyjadruje ako dobrým riešením zadaného problému je tento chromozóm. Cieľom genetického algoritmu je teda nájsť chromozóm s maximálnou hodnotou Fitness funkcie.

Jedným z často používaných operátorov výberu je algoritmus rulety (Roulette wheel). Názov je odvodený z predstavy, že sa obvod kolesa rulety rozdelí na  $N$  intervalov, pričom každý interval zodpovedá jednému chromozómu populácie. Veľkosť intervalu je rovná hodnote Fitness príslušného chromozómu. Keď sa takáto pomyselná ruleta roztočí, pravdepodobnosť, že sa zastaví na určitom chromozóme je priamo úmerná veľkosti intervalu príslušajúceho k chromozómu, čiže veľkosti Fitness. Výber ruletou teda preferuje výber silnejších jedincov pred slabšími.

Výpočet genetického algoritmu je ukončený po splnení kritéria ukončenia. Kritériá ukončenia môžu mať rôzny tvar.

Jedným z najjednoduchších je napríklad dopredu pevne stanovený počet generácií. Inou možnosťou je zastavenie výpočtu v prípade ak sa najlepšie nájdené riešenie nezmení v priebehu stanoveného počtu generácií. V prípade, že sa nájde riešenie ktoré má splniť nejaké dopredu stanovené podmienky, je možno ako kritérium ukončenia použiť práve splnenie požadovaných podmienok.

## Kódovanie reálnych čísel

Niektoré problémy majú riešenie v tvare reálneho čísla z nejakého intervalu. Reálne číslo však nie je dobrou reprezentáciou chromozómu, pretože sa na reálnych číslach ťažšie definujú operátory mutácie a kríženia ktoré sú základom genetického algoritmu. Ako chromozóm sa oveľa ľahšie používa binárny vektor. Keďže je však problém definovaný nad reálnymi číslami, je nutné zdefinovať transformáciu binárneho vektora na reálne číslo z intervalu  $\langle a, b \rangle$ . Keďže binárnym vektorom dĺžky  $M$  je možné prirodzeným spôsobom kódovať celé čísla z intervalu  $\langle 0, 2^M - 1 \rangle$ , stačí na požadovanom intervale definovať rovnomerne rozmiestnených bodov, z ktorých každý je reprezentovaný celým číslom od 0 po  $2^M - 1$ . Transformácia binárneho vektora reprezentujúceho celé číslo  $d$  na reálne číslo  $r$  bude vyzerať nasledovne:

$$r = a + d \frac{b - a}{2^M - 1}$$

Problémom s ktorým je spojené takéto kódovanie je takzvaná Hammingova bariéra. Problém Hammingovej bariéry spočíva v tom, že niektoré čísla, ktoré na číselnej osi tesne susedia, majú v štandardnom binárnom kódovaní veľkú Hammingovu vzdialenosť – inými slovami, líšia sa vo veľkom počte bitov. Pri použití v genetickom algoritme to znamená, že na prechod medzi takýmito dvoma číslami je nutný veľký počet mutácií naraz, čo kvôli malej pravdepodobnosti v praxi nenastáva (Tabuľka 1).

číslo	Štandardné kódovanie	Grayov kód
127	0001111111	0001000000
128	0010000000	0011000000
Hammingova vzdialenosť :	8	1

**Tabuľka 1: Príklad binárnej reprezentácie čísel v štandardnom binárnom kódovaní a Grayovom kóde**


Riešením, ktoré problém Hammingovej bariéry eliminuje je použitie Grayovho kódu. Grayov kód binárneho vektora je znovu binárny vektor rovnakej dĺžky. Neobsahuje však priamo bity pôvodného vektora ale na  $i$ -tom mieste je rozdiel bitov pôvodného vektora nachádzajúcich sa na pozíciách  $i$  a  $i-1$  (tretia strana Tabuľka 1). Na rozdiel od štandardného kódovania sa Grayov kód dvoch susedných čísel líši maximálne v jednom bite.

## **Použitie genetického algoritmu na nájdenie globálneho minima predpísanej reálnej funkcie reálnej premennej.**

Opisovaný genetický algoritmus bol použitý na hľadanie globálneho minima funkcie

$$f(x) = e^{-0.01x^2} \sin(10x) \cos(8x) + 0.993851231$$

na intervale  $\langle -10, 10 \rangle$ . Funkcia  $f(x)$  je príkladom funkcie s množstvom lokálnych extrémov. (vi Obr 2). Nájš globálny extrém takejto funkcie približnými metódami je dos obťažné, pretože výpo et môže ve mi ahko skon i v lokálnom extrém. Napríklad použitie metód založených na gradiente funkcie povedie do lokálneho extrému, ktorý sa nachádza najbližšie k po iato nému bodu.



Obr 2: Graf funkcie  $f(x)$  na intervale  $\langle -10, 10 \rangle$

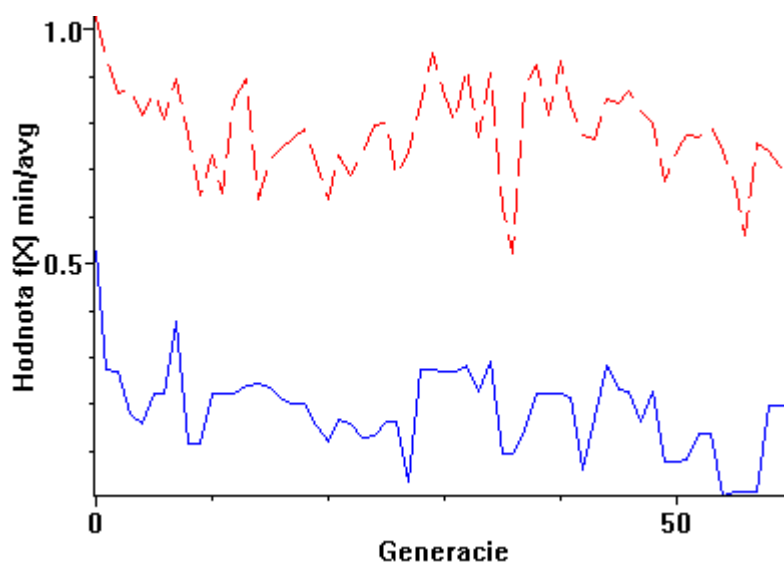
### Popis algoritmu.

Pri riešení problému globálneho extrému funkcie bol ako chromozóm použitý binárny re azec d žky 32 ako v štandardnom tak aj v Grayovom kódovaní. Mutácia bola realizovaná zámenou hodnoty jedného bitu. Mutácia bitu bola pritom realizovaná s pravdepodobnos ou  $p_{mut}$  ktorá nadobúdala hodnoty od 0.01 po 0.3.

Ako operácia križenia bolo použité jednobodové križenie binárnych vektorov 2 rodi ia , 2 potomkovia.

Po iato né pokusy boli robené s dvoma tvarmi fitness funkcie:

1.  $Fitness(x) = 2 - f(x)$
2.  $Fitness(x) = 1/f(x)$




Obr 3: Príklad priebehu výpo tu, ktorý už dosiahol hodnoty blízke lokálnemu minimu, ale nebol schopný udrža sa v okolí dosiahnutých výsledkov. Graf znázor uje priebeh hodnoty  $f(x)$  momentálne najlepšieho (modrá plná) a priemernej hodnoty  $f(x)$  v rámci populácie ( ervená prerušovaná).

Funkcia  $2-f(x)$  sa ukázala ako nedostatočná, pretože pri použití malej pravdepodobnosti mutácie nastávalo uviaznutie výpočtu tu aj v lokálnych minimách ktorá boli ďaleko od optimálneho riešenia. Pri zvyšovaní hodnoty  $p_{mut}$  sa zase dochádza k opusteniu už dosiahnutých výsledkov. Príklad takéhoto priebehu je na **Obr 3**. Je tu možné pozorovať nemonotónny priebeh funkciej hodnoty najlepšieho prvku populácie. Všetky ďalšie výpočty boli preto realizované s použitím predpisu  $Fitness(x) = 1/f(x)$ . Tento predpis Fitness funkcie dostatočne zvýhodňuje lepších jedincov, preto nedochádza k ich vymiznutiu z populácie ani pri použití vyšších pravdepodobností mutácie.

## Vplyv pravdepodobnosti mutácie na úspešnosť výpočtu

Pravdepodobnosť mutácie je jedným zo základných faktorov ktorý ovplyvňuje úspešnosť genetického algoritmu. V prípade, že je hodnota  $p_{mut}$  príliš nízka, priestor riešení prehľadávaný algoritmom sa sústreďuje zväčša v tesnej blízkosti momentálne najlepšieho jedinca. Dôsledkom je, že výpočet sa upne na momentálne (lokálne) najlepšie riešenie a je len malá pravdepodobnosť výraznej zmeny. Výsledkom takéhoto výpočtu je teda niektoré z lokálnych miním funkcie. (Obr 4).




**Obr 4: Použitie malej pravdepodobnosti mutácie – algoritmu prehľadáva len malé okolie momentálne najúspešnejšieho jedinca**

Naopak, použitie príliš veľkej pravdepodobnosti mutácie má za následok že populácia je príliš rozptýlená v priestore riešení. V takomto prípade sa najlepší jedinci v populácii nemusia udržať (najmä pri použití fitness funkcie ktorá nedostatočne uprednostňuje silnejšie jedince) a výpočet nikdy nekonverguje k prijateľnému riešeniu. (Obr 3 a Obr 5).

## Vplyv veľkosti populácie

Veľkosť populácie ovplyvňuje nepriaznivé správanie spôsobené príliš malou alebo veľkou hodnotou pravdepodobnosti mutácie. Ovplyvňuje pritom hlavne hornú hranicu použitej pravdepodobnosti mutácie – čím väčšia populácia, tým väčšiu hodnotu  $p_{mut}$  je možné použiť bez ujmy na úspešnosti výpočtov. Spodnú hranicu použitej  $p_{mut}$  zvyšovanie populácie taktiež pozitívne ovplyvňuje, ale v oveľa menšej miere ako hornú.



Obr 5: Príliš ve ká pravdepodobnos mutácie – chromozómy sú príliš rozptýlené po priestore riešení.

### Vplyv pravdepodobnosti kríženia

Na rozdiel od pravdepodobnosti mutácie, hodnota pravdepodobnosti kríženia ( $p_{\text{cros}}$ ) neovplyvnila pozorované výsledky. Túto skutočnosť možno odôvodniť tým, že kríženie pomáha v prípadoch, kedy sa riešenie problému skladá z nezávislých častí, pri ich spojení dvoch rodičovských chromozómov, z ktorých každý má niektorú z častí riešenia dobre vyvinutú môže vzniknúť chromozóm v ktorom sa práve tieto úspešné časti skombinujú. Skúmaný problém nezapadá do kategórie takýchto problémov, preto kríženie výsledkov neovplyvňuje.

### Dosiahnuté výsledky

Najlepší výsledok dosiahnutý algoritmom bol  $x = -0.7853024804$ ,  $f(x) = 0.0000000005692$ . Pre vyhodnotenie úspešnosti v závislosti od pravdepodobnosti mutácie a veľkosti populácie, boli vykonávané série 100 pokusov pre hodnoty  $p_{\text{mut}} \in \langle 0.01, 0.32 \rangle$  a  $\text{pop} \in \langle 5, 65 \rangle$ . Každý výpočet bol ukončený, ak sa hodnota najlepšieho jedinca celého výpočtu nezmenila posledných 1000 generácií. Týchto 1000 generácií sa nezaráta do dĺžky výpočtu. Správnosť výsledkov bola posudzovaná s presnosťou  $10^{-9}$  vzhľadom k funkčnej hodnote  $f(x)$ . Grafické znázornenie úspešnosti možno pozorovať na Obr 6 a Obr 7. Na dosiahnutie 90% úspešnosti je potrebná minimálne populácia 20 chromozómov. V tomto prípade je výber pravdepodobnosti mutácie obmedzený na interval  $\langle 0.12, 0.14 \rangle$ . Zväčšovanie populácie rozširuje interval na ktorom je možné dosiahnuť úspešnosť aspoň 90%. Pri populáciách veľkosti aspoň 55 chromozómov je možné dokonca voliť také hodnoty  $p_{\text{mut}}$  aby bola úspešnosť algoritmu 100%.

Použitie Grayovho kódu nijak výrazne nezasiahne do úspešnosti algoritmu. Ako je možné pozorovať porovnaním obrázkov Obr 6 a Obr 7, priebeh závislosti úspešnosti algoritmu od skúmaných parametrov je veľmi podobný a rozdiely sú spôsobené skôr náhodnými faktormi ako rozdielnym kódovaním.

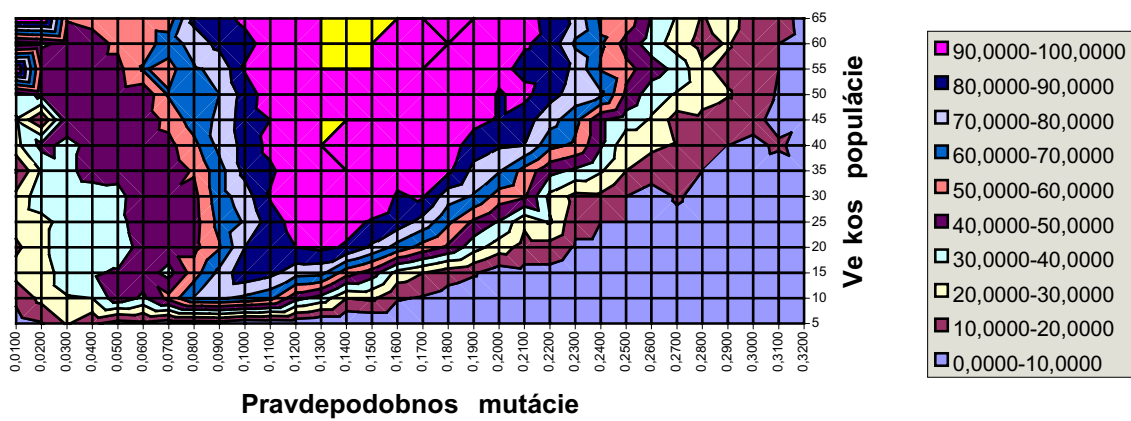
### Dĺžka výpočtu

Na obrázkoch 8 a 9 je zobrazený graf závislosti priemernej dĺžky úspešného výpočtu od voľby hodnôt. Pre praktické použitie sú veľmi zaujímavé hlavne časti, v ktorých má algoritmus úspešnosť aspoň 90%. Toto je možné porovnať s grafmi na Obr 6 a Obr 7. Ako z grafov vidno, takmer na celej tejto časti je priemerná dĺžka výpočtu medzi 750 a 1000 generáciami. V praxi teda hodnoty pravdepodobnosti mutácie a veľkosti populácie majú vplyv hlavne na počet úspešných pokusov, na dĺžku výpočtu vplyvajú iba malou mierou.

## Záver

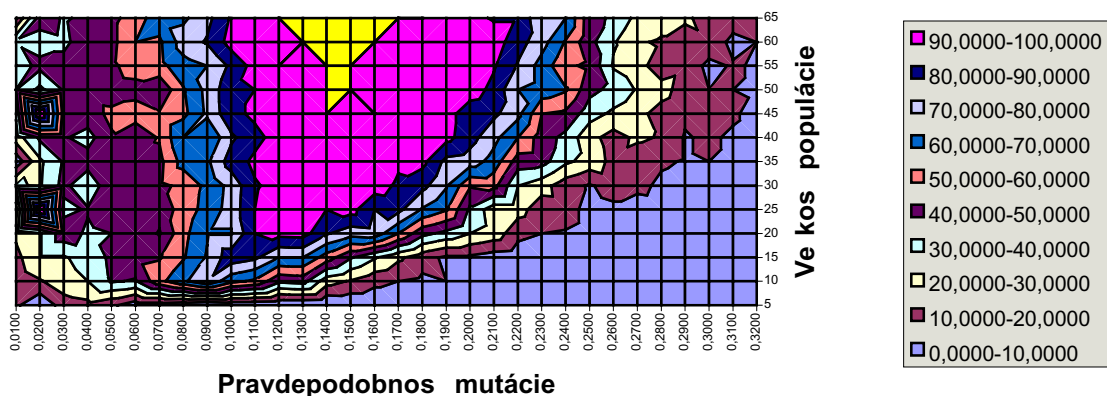
Genetický algoritmus je vhodná metóda na hľadanie globálnych extrémov reálnych funkcií s mnohými lokálnymi extrémami, na ktorých zlyhávajú algoritmy založené na znalosti gradientu, alebo prehľadávaní lokálneho okolia prípadných riešení (hill climbing). Úspešnosť algoritmu závisí hlavne na veľkosti populácie a pravdepodobnosti mutácie. Naopak, nezávisí od veľkosti populácie a pravdepodobnosti kríženia. V tomto prípade sa neprejavil vplyv Hammingovej bariéry, takže úspešnosť neovplyvnilo ani prípadné použitie Grayovho kódovania. Priemerná dĺžka úspešných výpočtov príliš nezávisela od skúmaných parametrov. Z hľadiska času procesora je preto výhodnejšie voliť spodnú hranicu použitej veľkosti populácie (20 chromozómov).

### Percentuálny počet úspešných výpočtov




Obr 6: Percentuálny počet úspešných výpočtov v závislosti od veľkosti populácie a pravdepodobnosti mutácie. (Štandardné kódovanie)

### Percentuálny počet úspešných výpočtov



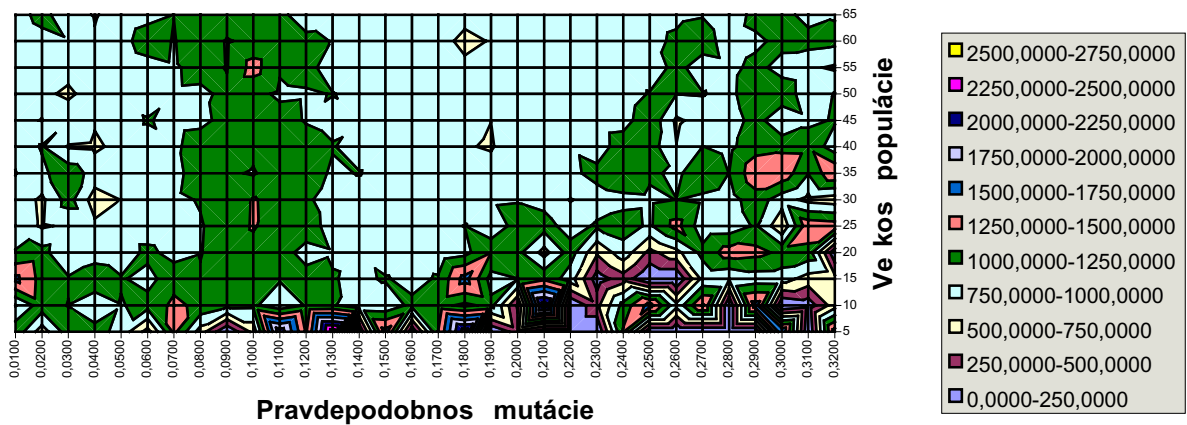
Obr 7: Percentuálny počet úspešných výpočtov v závislosti od veľkosti populácie a pravdepodobnosti mutácie. (Grayov kód)

### Priemerná d ůka úspešného výpo tu



Obr 8: Závislos priemernej d ůky výpo tu od parametrov genetického algoritmu (Štandardné kódovanie)

### Priemerná d ůka úspešného výpo tu



Obr 9: Závislos priemernej d ůky výpo tu od parametrov genetického algoritmu (Grayov kód)