


# Evolučné algoritmy

---

## Optimalizačný problém

Spracované podľa knihy

V. Kvasničku a J. Pospíchala




# Optimalizačný problém

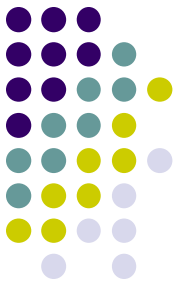


- Nech funkcia  $f : D \rightarrow R$  zobrazuje  $n$ -rozmernú kocku  $D$  (karteziánsky súčin uzavretých intervalov  $[a_i, b_i]$ ) na reálne čísla  $y \in R$ ,


$$D = \prod_{i=1}^n [a_i, b_i] = [a_1, b_1] \times [a_2, b_2] \times \dots \times [a_n, b_n]$$



# Táto funkcia je ohraničená dvomi podmienkami:



- (1) Existuje taký algoritmus, ktorý funkciu  $f$  "vypočíta dostatočne rýchlo" s požadovanou presnosťou pre každé  $x \in D$  (hovoríme, že funkcia  $f$  je *dobre vypočítateľná*).
- (2) Pre každú dvojicu lokálnych miním  $x_1, x_2 \in D$  je vzdialenosť  $|x_1 - x_2|$  väčšia ako dané kladné číslo  $\delta > 0$ ,  $|x_1 - x_2| > \delta$ .



# Optimalizačný problém



- Podmienka zhora ohraničuje počet lokálnych miním funkcie  $f$ , ktoré sa vyskytujú na kocke  $D$ .
- Nie je možné, aby sa v ľubovoľnom okolí minima funkcie vyskytovalo iné minimum, pre určité malé okolie minima funkcie by vyššie uvedená podmienka  $|\mathbf{x}_1 - \mathbf{x}_2| > \delta$  prestala platiť.
- Podmienka automaticky vylučuje z triedy prípustných funkcií tie funkcie, ktoré sú "fraktálového" typu, t. j. v každom okolí nejakého minima sa nachádza aspoň jedno iné minimum.

# Optimalizačný problém



*Globálne minimum* funkcie  $f$  na kocke  $D$  je určené vzťahom

$$\mathbf{x}_{opt} = \arg \min_{\mathbf{x} \in D} f(\mathbf{x})$$


Nájdenie globálneho minima použitím klasických optimalizačných metód (gradientových a negradientových) patrí medzi **ťažko riešiteľné problémy pre funkcie**, ktoré nie sú ohraničené ďalšími podmienkami (napr. že  $f(\mathbf{x})$  je konvexná funkcia v oblasti  $D$ ).

Z týchto dôvodov sa v súčasnosti pri riešení problému často používajú **tzv. evolučné optimalizačné algoritmy**, ktoré poskytujú riešenia blízke globálnemu alebo s ním totožné.

# Transformácia spojitého optimalizačného problému na binárny optimalizačný problém



- Predpokladajme, že každá z  $n$  premenných vektora  $\mathbf{x} \in D$  je vyjadrená v binárnej reprezentácii bitovým vektorom dĺžky  $k$ . To znamená, že vektor  $\mathbf{x} \in D$  je v binárnej reprezentácii vyjadrený bitovým vektorom dĺžky  $kn$ .



Nech funkcia  $f$  vyhovuje druhej podmienke pre danú kladnú konštantu  $\delta$ . Budeme predpokladať, že dĺžka binárnej reprezentácie  $k$  je zvolená tak, že platí

$$\delta \gg \frac{(b_i - a_i)}{(2^k - 1)} \quad (\text{pre } i = 1, 2, \dots, n)$$

Táto podmienka vyžaduje, aby minimálna vzdialenosť medzi dvoma minimami funkcie  $f(\mathbf{x})$  nad oblasťou  $D$  bola omnoho väčšia ako "presnosť" binárnej reprezentácie pre každú premennú vektora  $\mathbf{x} \in D$ .

# Optimalizačný problém



- Prechod od binárneho vektora  $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_{kn}) \in \{0, 1\}^{kn}$  k spojitému vektoru  $\mathbf{x} = (x_1, x_2, \dots, x_n) \in D$  sa môže formálne chápať ako transformácia


$$\Gamma : \{0, 1\}^{kn} \rightarrow D$$

$$\mathbf{x} = \Gamma(\alpha)$$

ktorá zobrazuje množinu binárnych vektorov dĺžky  $kn$  na body -  $n$ -tice reálnych čísel z kocky  $D$ .

Ináč povedané, konečná množina ( $2^{kn}$ ) binárnych vektorov dĺžky  $kn$  je reprezentovaná pomocou zobrazenia  $\Gamma$  bodmi, ktoré môžu byť v oblasti  $D$  usporiadané do ortogonálnej mriežky

# Optimalizačný problém



Minimalizačný problém pri použití binárnej reprezentácie  $n$ -rozmerných vektorov  $\mathbf{x}$  sa teda realizuje na konečnej množine diskretných bodov.

Označme binárny vektor dĺžky  $kn$ , ktorý bol získaný riešením daného optimalizačného problému, pričom funkcia  $f$  tohto problému je totožná s funkciou  $f$  v optimalizačnom probléme

$$\tilde{\alpha}_{opt} = \arg \min_{\alpha \in \{0,1\}^{kn}} f(\Gamma(\alpha))$$

$$\mathbf{x}_{opt} \approx \tilde{\mathbf{x}}_{opt} = \Gamma(\tilde{\alpha}_{opt})$$



# Binárna reprezentácia reálnych čísel




- Nech binárny vektor  $\alpha$  dĺžky  $k$  je interpretovaný ako celé číslo

$$\text{int}(\alpha) = \sum_{i=1}^k \alpha_i 2^{k-i} = \alpha_1 2^{k-1} + \alpha_2 2^{k-2} + \dots + \alpha_{k-1} 2 + \alpha_k$$

- K tomuto celému číslu jednoduchým spôsobom priradíme reálne číslo, ktoré môže byť chápané ako aproximácia reálneho čísla  $x \in [a, b]$


$$x \approx \text{real}(\alpha) = a + \frac{b-a}{2^k - 1} \text{int}(\alpha)$$





# Binárna reprezentácia reálnych čísel

- Táto konštrukcia racionálneho čísla  $a \leq \text{real}(\alpha) \leq b$  z binárneho reťazca  $\alpha$  dĺžky  $k$  sa formálne interpretuje ako "transformácia" binárnej reprezentácie na "reálnu" reprezentáciu,
- zostrojené racionálne číslo  $\text{real}(\alpha)$  aproximuje požadované reálne číslo  $x$  s presnosťou  $(b-a)/(2^k-1)$ . Interval  $[a, b]$  obsahuje  $m=2^k$  bodov  $x_1=a, x_2=a+(b-a)/(2^k-1), \dots, x_i=a+(i-1)(b-a)/(2^k-1), \dots, x_m=b$ ,



# Binárna reprezentácia reálnych čísel



- Inverzná transformácia má tvar


$$\text{int}(\alpha) = \left[ \frac{x - a}{b - a} (2^k - 1) \right]$$

- Prechod od binárneho vektora  $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_{kn}) \in \{0, 1\}^{kn}$  k spojitému vektoru  $\mathbf{x} = (x_1, x_2, \dots, x_n) \in D$  sa môže formálne chápať ako transformácia

$$\Gamma : \{0, 1\}^{kn} \rightarrow D \quad \mathbf{x} = \Gamma(\alpha)$$

- ktorá zobrazuje množinu binárnych vektorov dĺžky  $kn$  na body -  $n$ -tice reálnych čísel z kocky  $D$ . Ináč povedané, konečná množina  $(2^{kn})$  binárnych vektorov dĺžky  $kn$  je reprezentovaná pomocou zobrazenia  $\Gamma$  bodmi, ktoré môžu byť v oblasti  $D$  usporiadané do ortogonálnej mriežky.

# Základné stochastické optimalizačné algoritmy: *slepý algoritmus a horolezecký algoritmus*




- Dva základné typy stochastických optimalizačných algoritmov, ktoré aj keď neobsahujú evolučné rysy, budú slúžiť ako základ pre formuláciu evolučných optimalizačných algoritmov.
- *Slepý algoritmus* - základný stochastický algoritmus, ktorý opakovane generuje náhodne riešenie z oblasti  $D$  a zapamätá si ho len vtedy, ak bolo lepšie ako to riešenie, ktoré už bolo zaznamenané v predchádzajúcej histórii algoritmu. Z dôvodov kompatibility tohto algoritmu s evolučnými algoritmami uvidíme jeho implementáciu pre binárnu reprezentáciu vektorov – riešení.

# Slepý algoritmus



```
procedure Blind_Algorithm(input:  $t_{\max}, k, n$ ; output:  $\alpha_{\text{fin}}, f_{\text{fin}}$ );  
begin  $f_{\text{fin}} := \infty$ ;  $t := 0$ ;  
  while  $t < t_{\max}$  do  
    begin  $t := t + 1$ ;  
       $\alpha :=$  náhodne generovaný binárny  
        vektor dĺžky  $kn$ ;  
      if  $f(\Gamma(\alpha)) < f_{\text{fin}}$  then  
        begin  $\alpha_{\text{fin}} := \alpha$ ;  $f_{\text{fin}} := f(\Gamma(\alpha))$  end;  
      end;  
    end;
```



# Slepý algoritmus




- Dá sa dokázať, že tento jednoduchý stochastický optimalizačný algoritmus poskytuje korektné globálne minimum optimalizačného problému realizovaného nad ortogonálnou mriežkou bodov z oblasti  $D$  za predpokladu, že parameter procedúry  $t_{max}$  asymptoticky rastie do nekonečna

$$\lim_{t_{max} \rightarrow \infty} P(t_{max} | \alpha_{fin} = \alpha_{opt}) = 1$$

kde  $P(t_{max} | \alpha_{fin} = \alpha_{opt})$  je pravdepodobnosť toho, že slepý algoritmus po  $t_{max}$  iteračných krokoch poskytne výstupné riešenie, ktoré je totožné s presným riešením (globálne minimum).

# Horolezecký algoritmus



- ktorý iteračne hľadá najlepšie lokálne riešenie v určitom okolí a toto riešenie sa v ďalšom kroku použije ako "stred" novej oblasti
- operácia *mutácie* stochasticky transformuje binárny vektor  $\alpha$  na nový binárny vektor  $\alpha'$ , pričom stochastičnosť tohto procesu je určená pravdepodobnosťou  $P_{mut}$

$$\alpha' = O_{mut}(\alpha)$$

- kde  $\alpha$  a  $\alpha'$  sú dva binárne vektory rovnakej dĺžky  $kn$ , kde jednotlivé komponenty  $\alpha'$  sú určené takto

$$\alpha'_i = \begin{cases} 1 - \alpha_i & (\text{pre } random < P_{mut}) \\ \alpha_i & (\text{ostatné prípady}) \end{cases}$$

# Horolezecký algoritmus



- Okolie  $U(\alpha)$  binárneho vektora  $\alpha$  sa zostrojí pomocou vektorov

$$U(\alpha) = \{\alpha' = O_{mut}(\alpha)\}$$

pričom budeme predpokladať, že kardinalita (počet elementov) sa rovná predpísanej hodnote  $|U(\alpha)| = c_0$  kde  $c_0$  je dané kladné celé číslo.

Poznamenajme, že v dôsledku stochastičnosti aplikácie operácie mutácie na daný binárny vektor  $\alpha$  má zloženie okolia  $U(\alpha)$  tiež stochastický charakter.


To, či nejaký vektor  $\alpha'$  patrí alebo nepatrí do okolia  $U(\alpha)$ , je určené len pravdepodobnostne, a nie deterministicky.

Najlepšie riešenie v okolí  $U(\alpha)$  je určené takto  $\alpha^* = \arg \min_{\alpha' \in U(\alpha)} f(\Gamma(\alpha'))$


V horolezeckom algoritme sa takto získané riešenie  $\alpha^*$  použije ako "stred" v ďalšom iteračnom kroku algoritmu




# Horolezecký algoritmus



```
procedure Hill_Climbing(input:  $t_{\max}, c_0, P_{\text{mut}}$ ; output:  $f_{\text{fin}}, \alpha_{\text{fin}}$ );  
begin  $\alpha :=$  náhodne generovaný binárny vektor dĺžky  $kn$ ;  
   $f_{\text{fin}} := \infty$ ;  $t := 0$ ;  
  while  $t < t_{\max}$  do  
  begin  $t := t + 1$ ;  $\alpha^* = \arg \min_{\alpha' \in U(\alpha)} (\Gamma(\alpha))$ ;  
    if  $f(\Gamma(\alpha^*)) < f_{\text{fin}}$  then  
    begin  
       $\alpha_{\text{fin}} := \alpha^*$ ;  
       $f_{\text{fin}} := f(\Gamma(\alpha^*))$   
    end;  
     $\alpha := \alpha^*$ ;  
  end;  
end;
```






# Metóda zakázaného hľadania (tabu search)

- Glover - koncom 80-tých rokov, ako určité zovšeobecnenie horolezeckého algoritmu (HA) na riešenie zložitých optimalizačných úloh predovšetkým z operačného výskumu.
- Základnou nevýhodou algoritmu HA je, že sa po určitom počte iteračných krokov vracia k lokálnemu optimálnemu riešeniu, ktoré sa vyskytlo už v jeho predchádzajúcom priebehu (problém zacyklenia).
- Glover navrhol jednoduchú heuristiku, ako tento problém odstrániť. Do horolezeckého algoritmu je zavedená tzv. *krátkodobá pamäť*, ktorá si pre určitý krátky interval predchádzajúcej histórie algoritmu pamätá inverzné transformácie k tým transformáciám riešení, ktoré poskytovali lokálne optimálne riešenia. Tieto inverzné transformácie **sú zakázané (tabu)** pri tvorbe nového okolia pre dané aktuálne riešenie.

# Metóda zakázaného hľadania (tabu search)



Definujme si množinu prípustných transformácií  $S = \{t_1, t_2, \dots, t_p\}$


Transformácia  $t \in S$  zobrazuje binárny vektor  $\alpha \in \{0,1\}^{kn}$  na iný binárny vektor  $\alpha' \in \{0,1\}^{kn}$   
 $t : \{0,1\}^{kn} \rightarrow \{0,1\}^{kn}$   
pre  $\forall t \in S$ . Jednoduchá realizácia týchto transformácií je  $t_i(\dots\alpha_i\dots) = (\dots 1 - \alpha_i \dots)$

pre  $i=1,2,\dots,p=kn$ . Operátor  $t_i$  zmení v  $i$ -tej polohe binárnu hodnotu na jej komplement.

Vo všeobecnosti, transformácie z  $S$  sú ohraničené nasledujúcimi podmienkami:

- Nech  $t_1, t_2 \in S$  sú dve rôzne transformácie,  $t_1 \neq t_2$ , potom pre  $\forall \alpha \in \{0,1\}^{kn}$  platí  $t_1\alpha \neq t_2\alpha$ .
- Pre každú transformáciu  $t \in S$  existuje taká transformácia  $t^{-1} \in S$ , ktorá je inverzná k  $t$ ,  $tt^{-1}\alpha = t^{-1}t\alpha = \alpha$ , pre  $\forall \alpha \in \{0,1\}^{kn}$ .
- Pre každú dvojicu  $\alpha_1, \alpha_2 \in \{0,1\}^{kn}$  rôznych binárnych vektorov,  $\alpha_1 \neq \alpha_2$ , existuje taká postupnosť  $t_{i_1}, t_{i_2}, \dots, t_{i_n} \in S$  transformácií, že "východzí" vektor  $\alpha_1$  je postupne pretransformovaný na "konečný" vektor  $\alpha_2$

$$\alpha_1 = \beta'_1 \xrightarrow{t_{i_1}} \beta'_2 \xrightarrow{t_{i_2}} \dots \xrightarrow{t_{i_n}} \alpha_2 = \beta'_n$$



# Metóda zakázaného hľadania (tabu search)

- Okolie  $U(\alpha)$  obsahuje obrazy  $\alpha$  vytvorené transformáciami  $t \in S$


$$U(\alpha) = \{t\alpha; \forall t \in S\}$$

- Pôvodný horolezecký algoritmus bude teraz modifikovaný tak, že namiesto okolia generovaného náhodne pomocou stochastického operátora mutácie, použijeme deterministicky nové definované okolie, generované pomocou prípustných transformácií z množiny  $S$ .
- Hlavná myšlienka tejto heuristiky je **zakázaný zoznam  $T$  (tabu list)**, majúci vlastnosť krátkodobej pamäti, ktorý dočasne obsahuje inverzné transformácie k použitým transformáciám v predchádzajúcich iteráciách. Zakázaný zoznam transformácií  $T \subseteq S$ , maximálnej kardinality  $s$ ,  $0 \leq |T| \leq s$ , je zostrojený a systematicky obnovovaný v priebehu celého algoritmu

# Metóda zakázaného hľadania (tabu search)



- Ak transformácia  $t$  patrí pre danú iteráciu do zakázaného zoznamu,  $t \in T$ , potom sa nemôže používať v lokálnej minimalizácii v rámci okolia aktuálneho riešenia  $\alpha$ .
- Pri inicializácii algoritmu je zakázaný zoznam prázdny, po každej iterácii sa do zakázaného zoznamu dodá transformácia, ktorá poskytla lokálne optimálne riešenie zostrojené z riešenia z predchádzajúcej iterácie.
- Po  $s$  iteráciách zakázaný zoznam už obsahuje  $s$  transformácií, zo zakázaného zoznamu sa vylúči transformácia, ktorá tam bola dodaná pred  $s$  iteráciami.




## Metóda zakázaného hľadania (tabu search)

- Uvedieme pseudopascalovskú procedúru pre metódu zakázaného hľadania.
- Vstupnými parametrami sú  $time_{max}$  a  $s$ , ktoré určujú maximálny počet iteračných krokov resp. veľkosť zakázaného zoznamu  $T$ .
- Procedúra obsahuje dva cykly: vonkajší while-cyklus realizuje iteračné kroky zakázaného hľadania, zatiaľ čo
- vnútorný for-cyklus slúži pre konštrukciu okolia  $U(\alpha)$ .  
Poznamenajme, že toto okolie nie je explicitne zostrojené, generujú sa len jeho elementy a tie sa hneď testujú, či ich funkčná hodnota nie je menšia ako lokálne najlepšia funkčná hodnota  $f_{fin-loc}$ .
- Vonkajší cyklus je ukončený operáciou obnovy zakázaného zoznamu.


# Metóda zakázaného hľadania (tabu search)



```
procedure Tabu_Search(input:timemax, s, S, k, n ; output: ffin, αfin);  
begin α:=náhodne generovaný binárny vektor dĺžky kn;  
    ffin:=∞; time:=0; T:=∅;  
    while time<timemax do  
        begin time:=time+1; ffin-loc:=∞;  
            for t∈S do {S je množina povolených transformácií }  
                begin α':=tα;  
                    if (t∉T and f(Γ(α'))<ffin-loc) or f(Γ(α'))<ffin then  
                        begin α*:=α';  
                            t*:=t;  
                            ffin-loc:=f(Γ(α'))  
                        end;  
                    end;  
                if ffin-loc<ffin then begin ffin:=ffin-loc; αfin:=α* end;  
                    α:=α*;  
                if |T|<s then T:=T∪{t-1} else T:=(T∪{t-1})\{ t };  
            end; { z T je odstránená najstaršia transformácia }  
    end;
```



# Metóda zakázaného hľadania (tabu search)




Veľkosť zakázaného zoznamu  $s=2$ .

Metóda je inicializovaná náhodne generovaným vektorom  $\alpha$ .

Pomocou transformácií  $t$  z množiny prípustných transformácií  $S$  je zostrojené prvé okolie  $U(\alpha)$ .

Najlepšie riešenie z tohto okolia je označené  $\alpha_1$ , v nasledujúcom iteračnom kroku je toto riešenie použité ako "stred" pre konštrukciu nového okolia. Inverzná transformácia je zavedená do zakázaného zoznamu  $T$ , ktorý bol pôvodne prázdny. Menšie bloky v pravom stĺpci odpovedajú zakázaným zoznamom pre jednotlivé iteračné kroky.





# Evolučné programovanie



- patrí medzi tie stochastické optimalizačné algoritmy, ktoré možno chápať ako jednoduché zovšeobecnenie horolezeckého algoritmu
- Základná úloha spočíva v riešení nasledujúceho optimalizačného problému



$$\alpha_{opt} = \arg \min_{\alpha \in \{0,1\}^k} f(\alpha)$$

- kde  $f, f: \{0,1\}^k \rightarrow R$  je funkcia, ktorá zobrazuje binárne vektory dĺžky  $k$  na reálne čísla. Nech  $P$  je množina - populácia riešení tvaru

$$P = \{\alpha_1, \alpha_2, \dots, \alpha_p\} \subseteq \{0,1\}^k$$

Z populácie  $P$  sa náhodne vyberie podpopulácia rodičov  $Q$ , ktorá je upravená pomocou operátora mutácie na podpopuláciu potomkov  $Q'$ . Z týchto dvoch podpopulácií sa vytvorí zjednotená podpopulácia  $R$ . Aplikovaním turnaja na túto podpopuláciu  $R$  dostaneme podpopuláciu nasledovníkov  $S$ . Podpopulácia nasledovníkov sa vracia do pôvodnej populácie  $P$  tak, že sa pôvodná rodičovská podpopulácia  $Q$  odstráni.

# Evolučné programovanie




# Evolučné programovanie

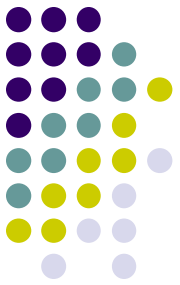


```
procedure Evolutionary_Programming(output: P);  
begin P:= náhodne generovaná populácia chromozómov;  
    stop_criterion:=false;  
    while not stop_criterion do  
        begin Q:= náhodne vybraná podpopulácia z P;  
            Q':=Omut(Q); R:=Q∪Q'; S:=Otournament(R);  
            P:=(P\Q)∪S;  
            if konvergenčné kritériá sú splnené then  
                stop_criterion:=true;  
        end;  
    end;  
{Výstupom je populácia splňujúca konvergenčné kritériá}
```

# Genetické programovanie



- Na prelome 80-tých a 90-tých rokov americký informatik John Koza (Stanford University) navrhol originálnu modifikáciu genetického algoritmu, ktorú nazval ***genetické programovanie***.
- V tomto prístupe sú chromozómy - znakové reťazce nahradené zložitejšími štruktúrami - funkciami.
- Čo sa rozumie pod pojmom "funkcia"?



Jednoduchá funkcia " $x*(1+x)$ " je  
reprezentovaná pomocou syntaktického  
stromu (parse tree)