

Prednáška 3

Optimalizačné metódy pre funkcie n-premenných

Študujme **reálnu funkciu** n-premenných

$$f: R^n \rightarrow R$$

Našou úlohou bude nájsť také $x_{opt} \in R^n$, pre ktoré má funkcia f minimum

$$\mathbf{x}_{opt} = \arg \min f(\mathbf{x})$$


Túto úlohu budeme riešiť pomocou:

- (1) gradientových metód
- (2) negradientových metód

Typickým predstaviteľom negradientových metód na hľadanie minima funkcií n-premenných je simplexova metóda.

1. Simplexová metóda


Pod **simplexom** v n -rozmernom priestore R^n rozumieme množinu $n+1$ bodov - vrcholov, pričom každá dvojica vrcholov je spojená hranou.



Formálne, simplex vyjadríme ako množinu

$$S = \{P_1, P_2, \dots, P_{n+1}\} \subset R^n$$

Hovoríme, že simplex S je **nedegenerovaný**, ak žiadny z vrcholov neleží v rovine obsahujúcej ostatné vrcholy simplexu



Podmienka pre nedegenerovaný simplex môže byť preformulovaná tak, že n vektorov

$$P_2 - P_1, P_3 - P_1, \dots, P_n - P_1, P_{n+1} - P_1,$$

je lineárne nezávislá. Nech bod P_i má tento tvar

$$P_i = (x_1^{(i)}, x_2^{(i)}, \dots, x_n^{(i)})$$


potom podmienka lineárnej nezávislosti môže byť vyjadrená pomocou podmienky nenulovosti determinantu

$$\begin{vmatrix} x_1^{(2)} - x_1^{(1)} & x_2^{(2)} - x_2^{(1)} & \dots & x_n^{(2)} - x_n^{(1)} \\ x_1^{(3)} - x_1^{(1)} & x_2^{(3)} - x_2^{(1)} & \dots & x_n^{(3)} - x_n^{(1)} \\ \dots & \dots & \dots & \dots \\ x_1^{(n+1)} - x_1^{(1)} & x_2^{(n+1)} - x_2^{(1)} & \dots & x_n^{(n+1)} - x_n^{(1)} \end{vmatrix} \neq 0$$

Priamka v priestore je určená dvoma bodmi P_A a P_B

$$P_\alpha = (1 - \alpha)P_A + \alpha P_B$$

kde $\alpha \in R$ je parameter priamky, platí $P_0 = P_A$ a $P_1 = P_B$.



Priamka je **orientovaná** v zmysle rastúceho parametra α

$$P_\alpha < P_\beta \Leftrightarrow \alpha < \beta$$

Ťažisko simplexu S je určené ako "aritmetický priemer" jeho vrcholov

$$P_C = \frac{1}{n+1} \sum_{i=1}^{n+1} P_i$$

Funkčné hodnoty minimalizovanej funkcie f na vrcholoch simplexu označíme

$$F_1 = f(P_1), F_2 = f(P_2), \dots, F_n = f(P_n), F_{n+1} = f(P_{n+1})$$

Medzi vrcholmi simplexu odlíšime dva vrcholy, vrchol P_L a vrchol P_H , v ktorých má funkcia f maximálnu resp. minimálnu hodnotu

$$P_H = \arg \max_{P \in S} f(P)$$


$$P_L = \arg \min_{P \in S} f(P)$$

V simplexovej metóde hrá dôležitú úlohu **t'azisko** vrcholov simplexu okrem vrcholu P_H

$$\bar{P} = \frac{1}{n} \left(\sum_{i=1}^{n+1} P_i - P_H \right)$$


α -reflexia vrcholu P_H vzhľadom k t'azisku \bar{P}

$$P_\alpha^* = (1 - \alpha)P_H + \alpha\bar{P}$$



Redukcia simplexu S vzhl'adom k vrcholu P_L

$$P'_i = \frac{1}{2}(P_i + P_L) \quad (\text{pre } i = 1, 2, \dots, n, n+1)$$



Elementárny krok simplexovej metódy

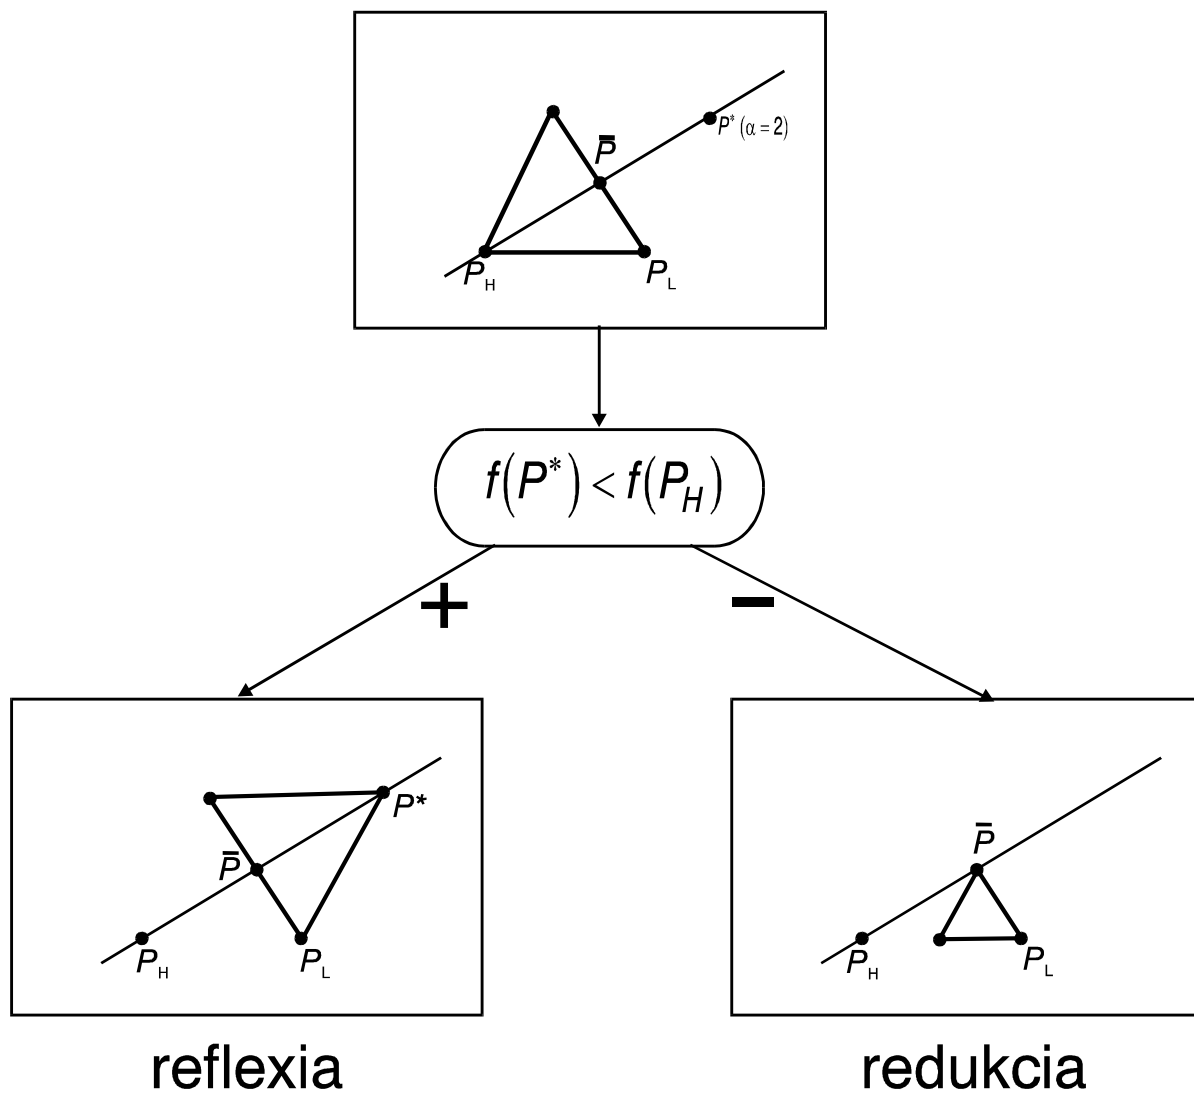
- (1) Pre daný simplex S určíme vrcholy P_L a P_H
- (2) Určíme ťažisko \bar{P} .
- (3) Zostrojíme 2-reflexiu P^* vrcholu P_H okolo \bar{P} , $P^* = 2\bar{P} - P_H$.
- (4) Ak $f(P^*) < f(P_H)$, potom $P_H \leftarrow P^*$, v opačnom prípade vykonáme redukciu simplexu okolo vrcholu P_L .

Kroky (1-4) opakujeme tak dlho, až

$$|f(P_H) - f(P_L)| < \varepsilon$$

kde ε je malé kladné číslo (presnosť)

Diagramatická interpretácia elementárneho kroku simplexovej metódy



Konštrukcia počiatočného simplexu

Máme zadaný jeden vrchol P_0 a dĺžku hrany d

$$P_i = P_0 + d E_i \quad (\text{pre } i = 1, 2, \dots, n)$$

$$P_{n+1} = P_0$$


kde "body" E_i sú zadané ako jednotkové smerové vektory

$$E_1 = (1, 0, 0, \dots, 0)$$

$$E_2 = (0, 1, 0, \dots, 0)$$

.....

$$E_n = (0, 0, 0, \dots, 1)$$




Algoritmus simplexovej metódy


```

read( $P_0, d, \varepsilon, k_{\max}$ );
S:=initial set of simplex
vertices;
norm:= $\infty$ ; k:=0;
while (norm $>\varepsilon$ ) and ( $k < k_{\max}$ ) do
begin k:=k+1;
     $P_H := \arg \max f(P)$ ;
     $P_L := \arg \min f(P)$ ;
    norm:=abs( $f(P_H) - f(P_L)$ );
     $P^* := 2\bar{P} - P_H$ ;
    if  $f(P^*) < f(P_H)$  then
    S:=(S- $\{P_H\}$ )+ $\{P^*\}$  else
    simplex is reduced;
end;
write( $P_L, f(P_L)$ );

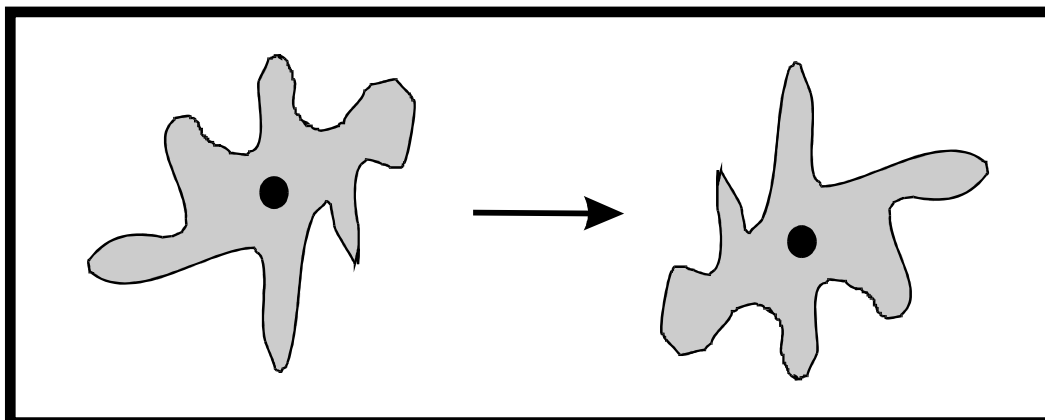
```

Diagramatické znázornenie priebehu simplexovej metódy



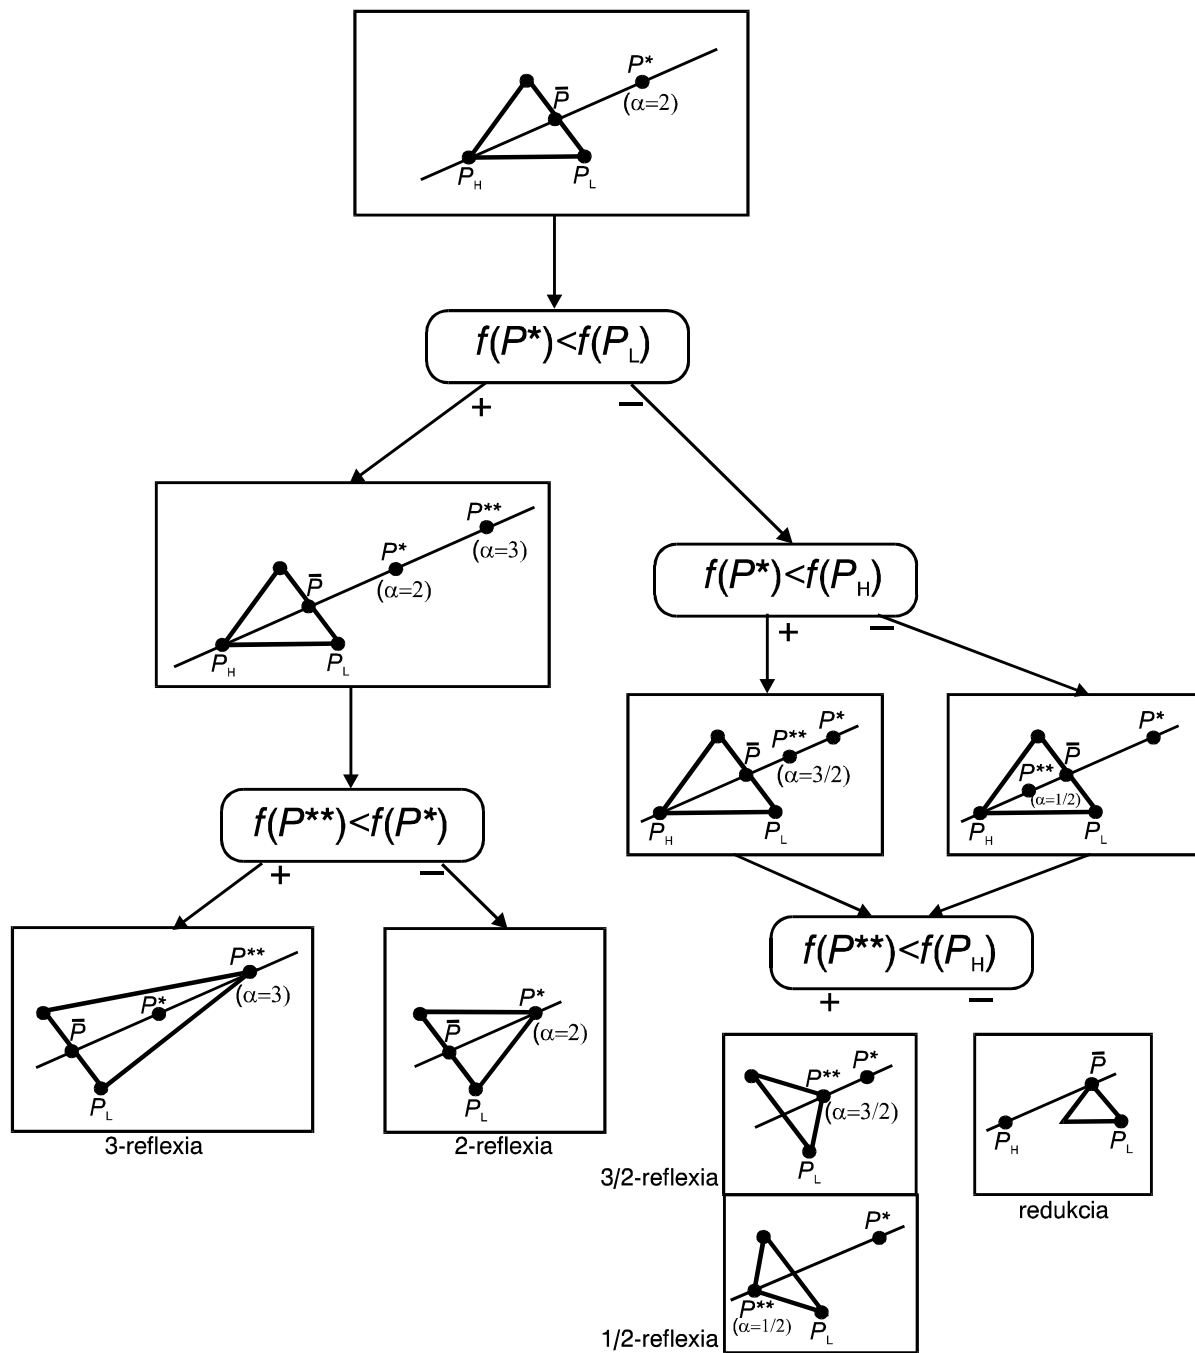
Poznámka: V priebehu simplexovej metódy dochádza často k redukcii simplexu, t.j. stáva sa stále menším a menším. Táto skutočnosť podstatne znižuje efektívnosť simplexovej metódy v blízkosti minima.

2. Modifikácia simplexovej metódy -AMÉBA



V štandardnej verzii simplexovej metódy relatívne často dochádza k redukcii simplexu, t.j. spomaluje sa rýchlosť metódy. Tento nedostatok odstraňuje modifikácia simplexovej metódy - **améba**, v ktorej je simplex dynamicky menený v závislosti na povrchu minimalizovanej funkcie.


Diagramatická vizualizácia elementárneho kroku améby



Algoritmus améby

```
read( $P_0, d, \varepsilon, k_{\max}$ );  
S:=initial set of simplex  
  vertices;  
norm:= $\infty$ ; k:=0;  
while (norm $>\varepsilon$ ) and (k $<k_{\max}$ ) do  
begin k:=k+1;  
   $P_H$ :=arg max f(P);  
   $P_L$ :=arg min f(P);  
  norm:=abs(f( $P_H$ )-f( $P_L$ ));  
   $P^*$ := $2\bar{P}-P_H$ ;  
  if f( $P^*$ ) $<$ f( $P_L$ ) then  
  begin  $P^{**}$ := $3\bar{P}-2P_H$ ;  
    if f( $P^{**}$ ) $<$ f( $P^*$ ) then  
    S:=(S- $\{P_H\}$ )+ $\{P^{**}\}$  else  
    S:=(S- $\{P_H\}$ )+ $\{P^*\}$ ;  
  end else  
  if f( $P^*$ ) $<$ f( $P_H$ ) then  
   $P^{**}$ := $-1/2P_H+3/2\bar{P}$  else  
   $P^{**}$ := $1/2P_H+1/2\bar{P}$ ;  
  if f( $P^{**}$ ) $<$ f( $P_H$ ) then  
  S:=(S- $\{P_H\}$ )+ $\{P^{**}\}$  else  
  simplex is reduced;  
end;  
write( $P_L, f(P_L)$ );
```

Diagramatické znázornenie priebehu améby



3. Stochastická simplexová metóda

Modifikácia štandardnej simplexovej metódy so stochastickými prvkami, ktorá je vhodná na hľadanie globálneho minima.

CRS - Controlled Random Search

W.L.Price (1965)

prototyp moderných stochastických optimalizačných metód

Populácia bodov P ($|P| \gg n$)

$$\mathcal{P} = \{P_1, P_2, \dots, P_m\}$$

Body z populácie P s maximálnou resp. minimálnou funkčnou hodnotou sú

$$P_{max} = \arg \max_{P \in \mathcal{P}} f(P)$$

$$P_{min} = \arg \min_{P \in \mathcal{P}} f(P)$$

Simplex S obsahuje $n+1$ bodov *náhodne* vybraných z populácie P

$$S = \{P_{\alpha_1}, P_{\alpha_2}, \dots, P_{\alpha_{n+1}}\} \subset \mathcal{P}$$

Štandardným postupom zostrojíme 2-reflexiu P^* v danom simplexe S .

Elementárny krok stochastickej simplexovej metódy

- (1) Z populácie P náhodne výber $n+1$ bodov, ktoré tvoria simplex S .
- (2) V rámci simplexu S zostroj 2-reflexiu P^* podobne ako v štandardnej simplexovej metóde.
- (3) Ak $f(P^*) < f(P_{\max})$, potom bod P_{\max} zameň za reflexiu P^* (t.j. populácia P sa modifikuje, $P \leftarrow (P \setminus \{P_{\max}\}) \cup \{P^*\}$).


Kroky (1-3) opakuj tak dloho, až sú splnené podmienky ukončenia algoritmu.

Algoritmus stochastickej simplexovej metódy


```
read(m, ε, kmax) ;
P := randomly generated population
    composed of m points ;
norm := ∞ ; k := 0 ;
while (norm > ε) and (k < kmax) do
begin k := k + 1 ;
    norm := abs(f(Pmax) - f(Pmin)) ;
    S := randomly selected simplex
        from the population P ;
    P* := reflexion of S ;
    if f(P*) < f(Pmax) then
        P := (P \ {Pmax}) ∪ {P*} ;
end ;
write(Pmin, f(Pmin)) ;
```

Tri po sebe idúce elementárne kroky stochastickej simplexovej metódy


Krok 1



Krok 2






Krok 3




Schematické znázornenie populácií pre rôzne etapy stochastickej simplexovej metódy

Počiatočná populácia



Konečná populácia



Poznámka: S rastom iteračných krokov metódy, "priemer" populácie sa znižuje v dôsledku toho, že sa vždy odstraňujú "okrajové" body P_{\max} .