

## 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

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


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  $\alpha$

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

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  $P_H$

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


**$\alpha$ -reflexia** vrcholu  $P_H$  vzhľadom k t'azisku  $\bar{P}$

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



**Redukcia** simplexu  $S$  vzhľadom 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**

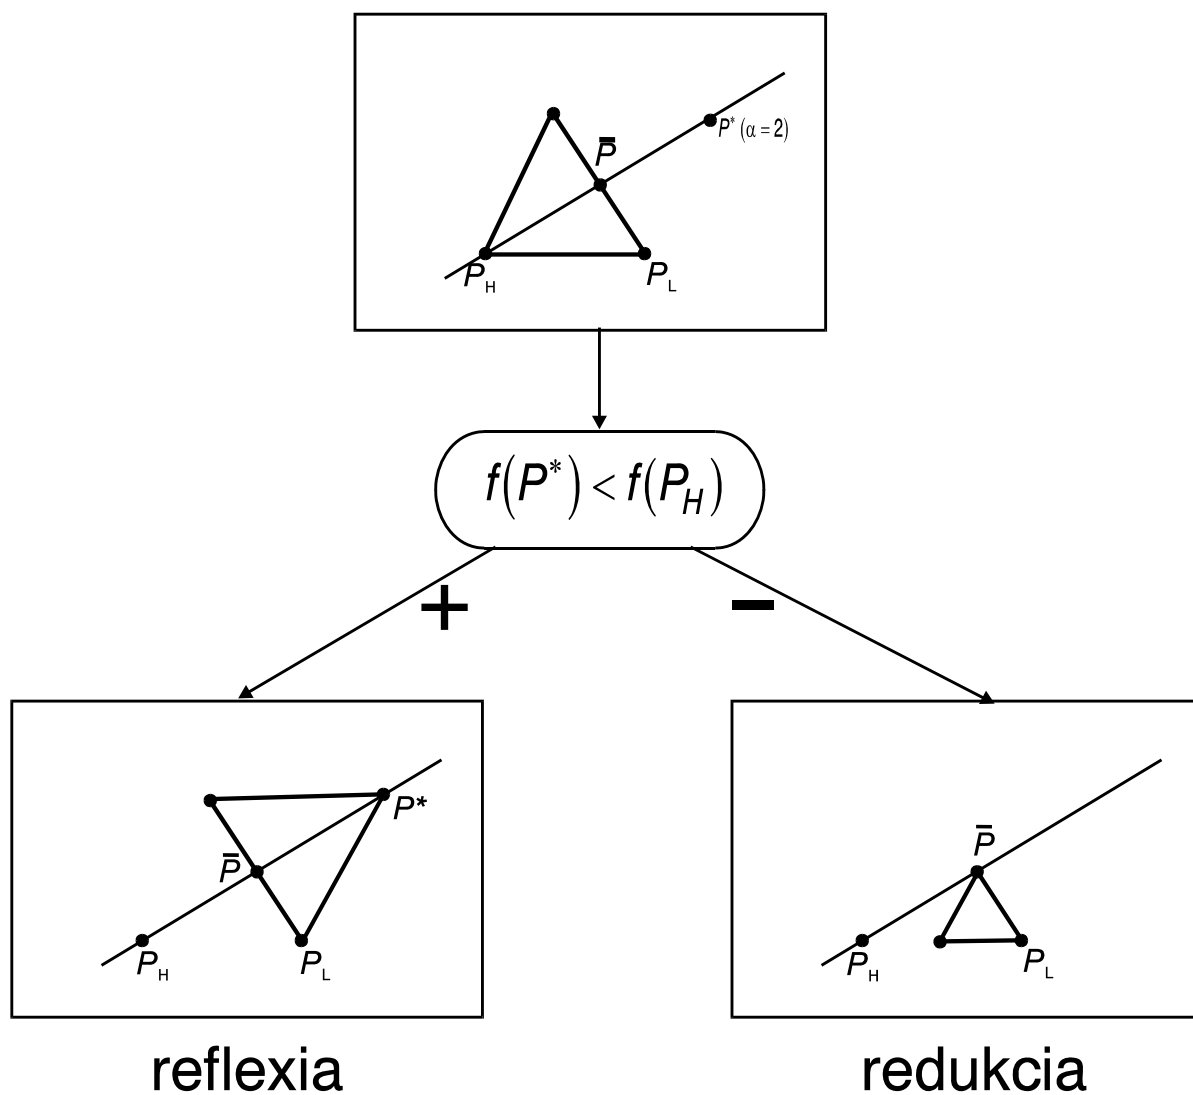
- (1) Pre daný simplex  $S$  určíme vrcholy  $P_L$  a  $P_H$
- (2) Určíme ťažisko  $\bar{P}$ .
- (3) Zostrojíme 2-reflexiu  $P^*$  vrcholu  $P_H$  okolo  $\bar{P}$ ,  $P^* = 2\bar{P} - P_H$ .
- (4) Ak  $f(P^*) < f(P_H)$ , potom  $P_H \leftarrow P^*$ , v opačnom prípade vykonáme redukciu simplexu okolo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

Kroky (1-4) opakujeme tak dlho, až

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

kde  $\varepsilon$  je malé kladné číslo (presnosť)

## Diagramatická interpretácia elementárneho kroku simplexovej metódy



## Konštrukcia počítačného 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



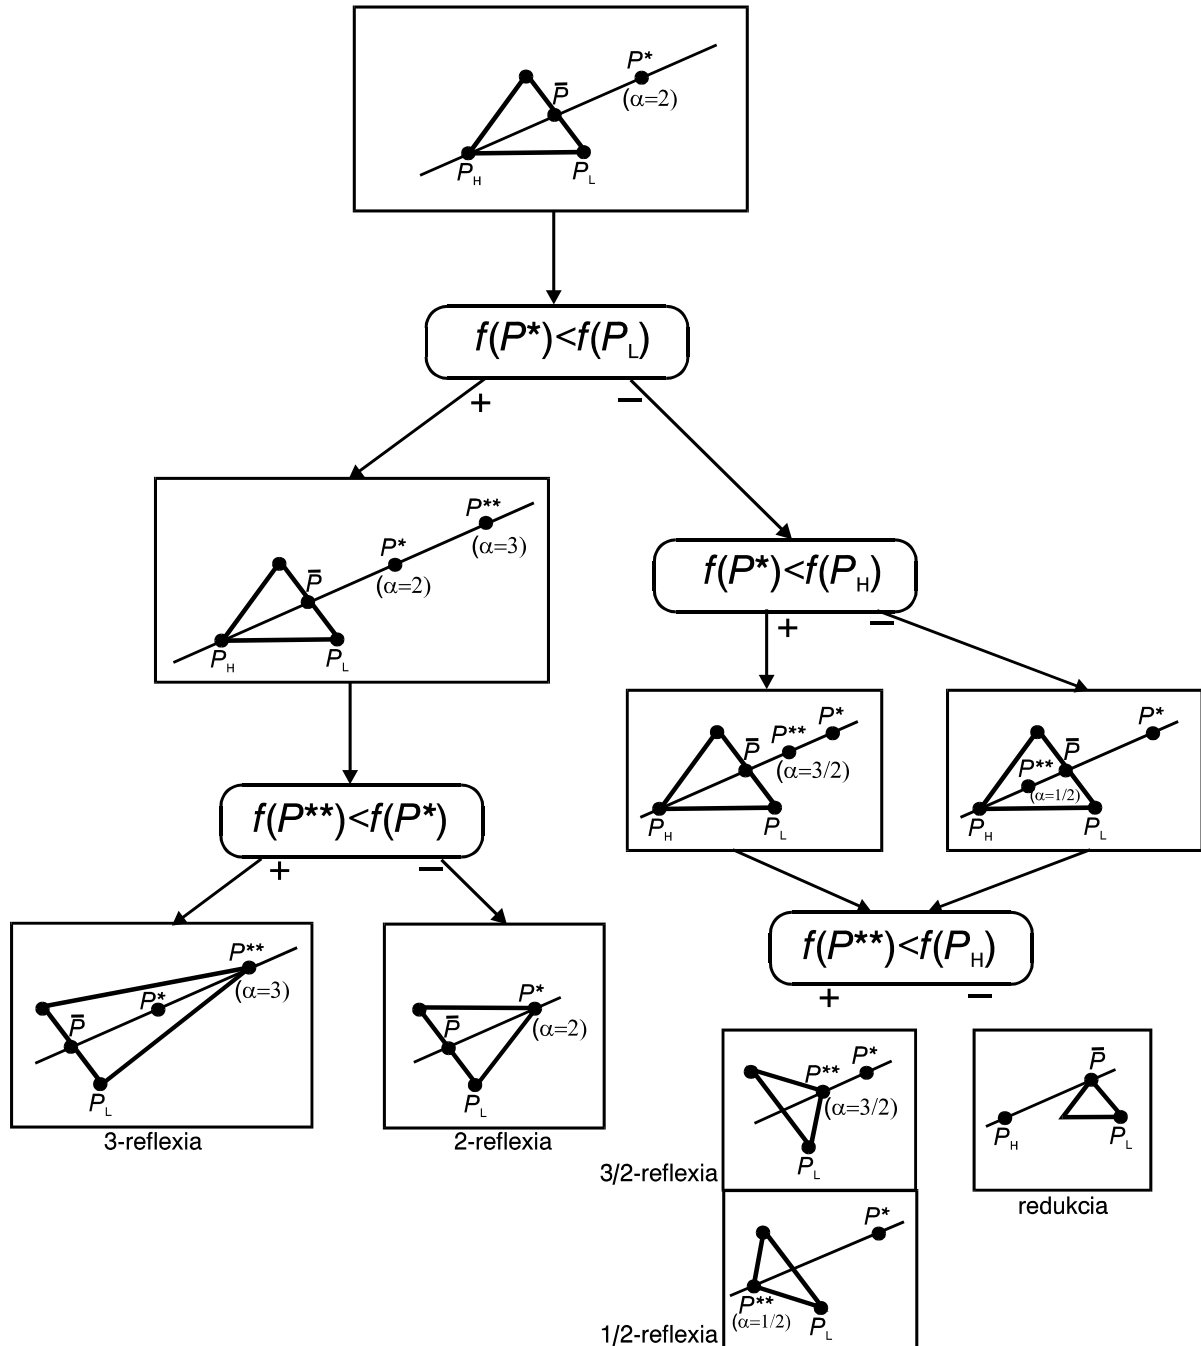
**Poznámka:** V priebehu simplexovej metódy dochádza často k redukcii simplexu, t.j. stáva sa stále menším a menším. Táto skutočnosť podstatne znižuje efektívnosť simplexovej metódy v blízkosti minima.

## 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  $P$  ( $|P| \gg n$ )

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

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

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

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

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

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

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  $P_{\max}$ .

## 4. Definícia gradientu

Študujme funkciu

$$F(\lambda) = f(\mathbf{x}_0 + \lambda \mathbf{n})$$

kde  $\mathbf{x}_0 = (x_1^0, x_2^0, \dots, x_n^0) \in \mathbb{R}^n$  je daný bod (vektor) a  $\mathbf{n} = (n_1^0, n_2^0, \dots, n_n^0) \in \mathbb{R}^n$  je normalizovaný smerový vektor ( $|\mathbf{n}|=1$ ). Funkcia  $F(\lambda)$  popisuje "zúženie" funkcie  $f(\mathbf{x})$  na priamku  $p$  definovanú bodom  $\mathbf{x}_0$  a smerom  $\mathbf{n}$ .



Derivácie tejto funkcie podľa premennej  $\lambda$  je určená vzťahom

$$F'(\lambda) = \text{grad } f(\mathbf{x}_0 + \lambda \mathbf{n}) \cdot \mathbf{n}$$

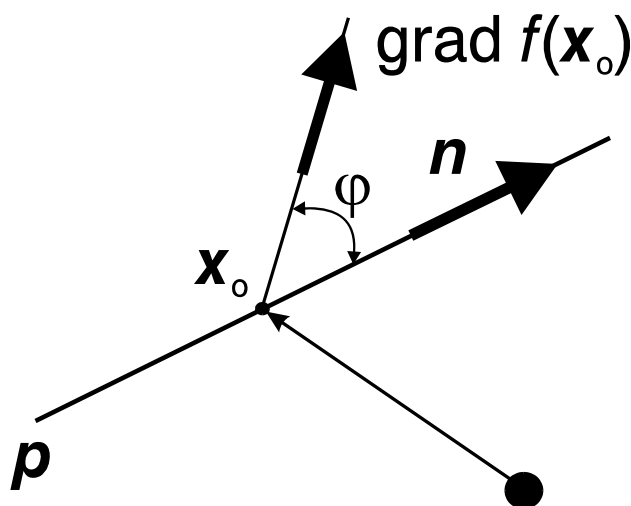
Výraz  $\text{grad } f(\mathbf{x})$  sa nazýva **gradient** funkcie  $f$  v bode  $\mathbf{x}$  a je definovaný ako vektor, ktorého komponenty sú 1. parciálne derivácie vzhľadom k premenným  $x_1, x_2, \dots, x_n$

$$\text{grad } f(\mathbf{x}) = \left( \frac{\partial f(\mathbf{x})}{\partial x_1}, \frac{\partial f(\mathbf{x})}{\partial x_2}, \dots, \frac{\partial f(\mathbf{x})}{\partial x_n} \right)$$

Hodnota derivácie  $F'(\lambda)$  pre  $\lambda=0$  sa nazýva **derivácie funkcie  $f(\mathbf{x})$  v bode  $\mathbf{x}_0$  a v smere  $\mathbf{n}$**

$$F'(0) = \text{grad } f(\mathbf{x}_0) \cdot \mathbf{n} = |\text{grad } f(\mathbf{x}_0)| \cos(\varphi)$$

kde  $\varphi$  je uhol, ktorý medzi smerom  $\mathbf{n}$  a  $\text{grad } f(\mathbf{x}_0)$



## Geometrická interpretácia gradientu

Budeme študovať nasledujúce dva limitné prípady pre deriváciu v smere, a to (1) smer je paralelný s gradientom ( $\varphi=0$ ) a (2) smer je antiparalelný s gradientom ( $\varphi=\pi$ )

$$F'(0)|_{\varphi=0} = +|\text{grad } f(\mathbf{x}_o)| > 0$$

$$F'(0)|_{\varphi=\pi} = -|\text{grad } f(\mathbf{x}_o)| < 0$$

V smere gradientu  $\text{grad } f(\mathbf{x}_o)$  funkcia  $f(\mathbf{x})$  **najrýchlejšie rastie**, podobne, v opačnom smere -  $\text{grad } f(\mathbf{x}_o)$  funkcia  $f(\mathbf{x})$  **najrýchlejšie klesá**.


## 5. Metóda najprudšieho spádu (steepest descent method)

Táto metóda je založená na geometrickej interpretácii gradientu, ako smeru v ktorom funkcia najrýchlejšie rastie. Budeme hľadať minimum funkcie  $f(\mathbf{x})$ , metóda najprudšieho spádu je založená na nasledujúcej rekurentnej formule

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \lambda \text{grad } f(\mathbf{x}_k)$$

kde kladný parameter  $\lambda > 0$  je určený tak, aby platilo  $f(\mathbf{x}_{k+1}) < f(\mathbf{x}_k)$ . To znamená, že tento parameter je určený dvoma protichodnými podmienkami, a to dostatočne malý, aby platila predchádzajúca nerovnosť a súčasne dostatočne veľký, aby bola zabezpečená dostatočná rýchlosť konvergencie metódy.

## Grafická ilustrácia metódy najprudšieho spádu



## Stratégia pre voľbu parametra $\lambda$



Ak platí  $f(\mathbf{x}_{k+1}) > f(\mathbf{x}_k)$  (t.j. metóda prestáva monotónne konvergovať), potom parameter  $\lambda$  sa zmenší

$$\lambda \leftarrow \alpha \cdot \lambda$$



kde  $0 < \alpha < 1$ .

### Algoritmus gradientovej metódy najprudšieho spádu

```
read( $\mathbf{x}, \lambda, \varepsilon, \alpha, k_{\max}$ );  
norm :=  $\infty$ ; k := 0;  
while (norm >  $\varepsilon$ ) and (k <  $k_{\max}$ ) do  
begin k := k + 1;  
     $\mathbf{x}' := \mathbf{x} - \lambda * \text{grad}f(\mathbf{x})$ ;  
    norm :=  $|\mathbf{x} - \mathbf{x}'|$ ;  
    if  $f(\mathbf{x}') > f(\mathbf{x})$  then  
         $\lambda := \alpha * \lambda$ ;  
         $\mathbf{x} := \mathbf{x}'$ ;  
end;  
write( $\mathbf{x}, f(\mathbf{x})$ );
```

### Grafická vizualizácia

## metódy najprudšieho spádu



Metóda sa stáva veľmi pomalou v blízkosti minima alebo na "plochých" úsekoch.