

## Prednáška 3

Moderné gradientové optimalizačné metódy pre funkcie n-premenných

Študujme **reálnu funkciu** n-premenných

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

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

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

Túto úlohu budeme riešiť pomocou:

- (1) Newtonovou metódou
- (2) Metódou združených gradientov  
(conjugated gradients)
- (3) Metódou premennej metriky  
(variable metrics)

Posledné dve metódy sa v literatúre označujú ako "**moderné** (gradientové) optimalizačné metódy".

## 1. Newtonova metóda

Jednoduché zovšeobecnenie Newtonovej optimalizačnej metódy pre funkcie 1-premennej na prípad funkcií  $n$ -premenných.

Budeme približne riešiť rovnicu

$$\text{grad } f(\mathbf{x}) = \mathbf{0}$$

Nech  $\mathbf{x} = \mathbf{x}_0 + \boldsymbol{\delta}$ , kde  $\boldsymbol{\delta} = (\delta_1, \delta_2, \dots, \delta_n)$ , potom

$$\text{grad } f(\mathbf{x}_0 + \boldsymbol{\delta}) = \mathbf{0}$$

Ľavá strana bude upravená pomocou Taylorovho rozvoja

$$\text{grad } f(\mathbf{x}_0) + H(\mathbf{x}_0)\boldsymbol{\delta} + \dots = \mathbf{0}$$

Ak budeme uvažovať len prvé dva členy rozvoja a budeme predpokladať, že Hessián  $H(\mathbf{x}_0)$  je nesingulárna matica, potom

$$\boldsymbol{\delta} \approx -H^{-1}(\mathbf{x}_0) \text{grad } f(\mathbf{x}_0)$$

**Poznámka:** Výchylka  $\delta$  je formálne určená dvoma ekvivalentnými spôsobmi: buď ako riešenie systému lineárnych rovníc

$$H(\mathbf{x}_o)\delta \approx -\text{grad } f(\mathbf{x}_o)$$

alebo pomocou inverznej matice

$$\delta \approx -H^{-1}(\mathbf{x}_o) \text{grad } f(\mathbf{x}_o)$$

Pretože, numerický výpočet inverznej matice je približne dvakrát náročnejší ako priame riešenie systému lineárnych rovníc, doporučuje sa vektor  $\delta$  určiť riešením systému lineárnych rovníc. Explicitný výraz pre  $\delta$  pomocou inverznej matice budeme používať z dôvodov formálnej jednoduchosti zápisu.

Riešenie rovnice  $\text{grad } f(\mathbf{x}) = \mathbf{0}$  má potom tento približný tvar

$$\mathbf{x} \approx \mathbf{x}_0 - H^{-1}(\mathbf{x}_0) \text{grad } f(\mathbf{x}_0)$$

Toto riešenie slúži ako podklad pre konštrukciu rekurentnej formule, ktorá je základom Newtonovej optimalizačnej metódy

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

pre  $k=0, 1, 2, \dots$  a  $\mathbf{x}_0$  je zadaná počiatočné riešenie. Rekurentná aplikácia tejto formule je ukončená keď začne platiť  $|\mathbf{x}_{k+1} - \mathbf{x}_k| < \varepsilon$ , kde  $\varepsilon > 0$  je zadaná presnosť požadovaného riešenia.

Algoritmus Newtonovej metódy:

```
read ( $\mathbf{x}_0, k_{\max}, \varepsilon$ );  
k:=0; norm:= $\infty$ ;  $\mathbf{x}:=\mathbf{x}_0$ ;  
while (k<kmax) and (norm> $\varepsilon$ ) do  
begin k:=k+1;  
    solve SLE  $H(\mathbf{x})\delta=-\text{grad } f(\mathbf{x})$ ;  
     $\mathbf{x}' := \mathbf{x} + \delta$ ;  
    norm:= $|\mathbf{x} - \mathbf{x}'|$ ;  
     $\mathbf{x} := \mathbf{x}'$ ;  
end;  
write ( $\mathbf{x}, f(\mathbf{x})$ );
```

Príkaz solve SLE  $H(\mathbf{x})\delta=-\text{grad } f(\mathbf{x})$ ;  
znamená, že použitím nejakej metódy  
(napr. Gaussovej eliminačnej metódy)  
systém lineárnych rovníc (SLE)  $H(\mathbf{x})\delta=-\text{grad } f(\mathbf{x})$   
je vyriešený vzhľadom k  
vektoru  $\delta$ .

## Poznámky:

(1) Newtonova metóda nájde riešenie rovnice  $\text{grad } f(\mathbf{x}) = \mathbf{0}$ , t.j. nájde stacionárne stavy funkcie  $f(\mathbf{x})$ . Tieto stacionárne stavy sú klasifikované pomocou Hessiánu  $H(\mathbf{x})$ :

Ak  $\mathbf{x}$  je stacionárny bod a Hessián  $H(\mathbf{x})$  je pozitívne negatívny, potom v bode  $\mathbf{x}$  má funkcia  $f(\mathbf{x})$  minimum.

(2) Pri Newtonovej metóde nemáme nijakú záruku či konverguje k minimu alebo k maximu (konverguje k stacionárnemu bodu).

(3) Funkcia  $f(\mathbf{x})$  musí byť dvakrát diferencovateľná na celom  $R^n$ , počítame gradient a Hessián funkcie.

(4) Výpočet Hessiánu môže byť časovo a pamäťovo veľmi náročný, menovite pre funkcie mnohých (niekoľko sto) premenných.

## 1a. Linearizovaná Newtonova metóda

Pre určitý typ minimalizovanej funkcie výpočet Hessiánu môže byť podstatne zjednodušený.

$$f(\mathbf{x}) = \sum_{k=1}^p g_k^2(\mathbf{x})$$

Pre túto funkciu platí vlastnosť

$$f(\mathbf{x}^*) = 0 \Leftrightarrow \forall k \in [1, p]: g_k(\mathbf{x}^*) = 0$$

Nutná a postačujúca podmienka pre existenciu takého  $\mathbf{x}^*$ ,  $f(\mathbf{x}^*) = 0$ , aby pre každé  $k \in [1, p]$  platilo  $g_k(\mathbf{x}^*) = 0$ .

Funkcia  $f(\mathbf{x})$  sa vyskytuje v **regresnej analýze** a pri transformácii konštrukcie **riešenia systému nelineárnych rovníc na minimalizačný problém.**

## Regresná analýza ako minimalizačný problém

Majme regresnú tabuľku (tréningovú množinu)

$$A_{train} = \{ \mathbf{x}_i / y_i; i = 1, 2, \dots, p \}$$

Našou úlohou je adaptovať parametre  $\boldsymbol{\omega}$  modelovej funkcie  $F(\mathbf{x}, \boldsymbol{\omega})$  tak, aby čo najlepšie reprodukovala tréningovú množinu

$$E(\boldsymbol{\omega}) = \sum_{i=1}^p (F(\mathbf{x}_i, \boldsymbol{\omega}) - y_i)^2$$

Adaptačný proces modelovej funkcie spočíva v tom, že sa minimalizuje účelová funkcia  $E(\boldsymbol{\omega})$

$$\boldsymbol{\omega}_{opt} = \arg \min_{\boldsymbol{\omega}} E(\boldsymbol{\omega})$$



Transformácia konštrukcie riešenie systému nelineárnych rovníc na minimalizačný problém.

Študujme systém nelineárnych rovníc

$$g_1(x_1, x_2, \dots, x_n) = 0$$

$$g_2(x_1, x_2, \dots, x_n) = 0$$

.....

$$g_p(x_1, x_2, \dots, x_n) = 0$$

Našou úlohou je nájsť také  $\mathbf{x}^*$  pre ktoré vyššie uvedené rovnice budú splnené. Definujeme si funkciu

$$f(\mathbf{x}) = \sum_{k=1}^p g_k^2(\mathbf{x})$$

Ak sa nám podarí nájsť také globálne minimum  $f(\mathbf{x}^*) = 0$ , potom vektor  $\mathbf{x}^*$  je riešením systému nelineárnych rovníc.

Výpočet Hessiánu pre funkciu

$$f(\mathbf{x}) = \sum_{k=1}^p g_k^2(\mathbf{x})$$

$$\frac{\partial f(\mathbf{x})}{\partial x_i} = 2 \sum_{k=1}^p g_k(\mathbf{x}) \frac{\partial g_k(\mathbf{x})}{\partial x_i}$$

$$\frac{\partial^2 f(\mathbf{x})}{\partial x_i \partial x_j} = 2 \sum_{k=1}^p \frac{\partial g_k(\mathbf{x})}{\partial x_i} \frac{\partial g_k(\mathbf{x})}{\partial x_j} + 2 \sum_{k=1}^p g_k(\mathbf{x}) \frac{\partial^2 g_k(\mathbf{x})}{\partial x_i \partial x_j}$$

Budeme predpokladať, že vektor  $\mathbf{x}$  je blízko  $\mathbf{x}^*$ , potom  $g_k(\mathbf{x}) \approx 0$ , pre  $k=1, 2, \dots$ , potom približný výraz pre elementy Hessiánu má tento tvar

$$H_{ij}(\mathbf{x}) \approx \frac{\partial^2 f(\mathbf{x})}{\partial x_i \partial x_j} \approx 2 \sum_{k=1}^p \frac{\partial g_k(\mathbf{x})}{\partial x_i} \frac{\partial g_k(\mathbf{x})}{\partial x_j}$$

V maticovom formalizme tento výraz má tvar

$$H(\mathbf{x}) \approx 2 \sum_{k=1}^p (\text{grad } g_k(\mathbf{x}))^T (\text{grad } g_k(\mathbf{x}))$$

Newtonová metóda v ktorej

(1) účelová funkcia má tvar

$$f(\mathbf{x}) = \sum_{k=1}^p g_k^2(\mathbf{x})$$

(2) a Hessián sa počíta pomocou gradientu

sa nazýva **linearizovaná Newtonova metóda**. Obvykle znamená **podstatné urýchlenie** algoritmu.