



Adaptivna obdelava signalov v telekomunikacijah

7. del

2003/04

Anton Umek

1



Pregled tem:


- Adaptivno transversalno sito
 - graf kriterijske funkcije
 - gradient kriterijske funkcije in optimalni vektor uteži
- Gradientni postopki
 - spust po največji strmini
 - Newtonov postopek
 - primerjava obeh postopkov
- LMS algoritem
 - posplošitev enodimenzionalnega postopka
 - LMS adaptivno sito



2

Adaptivno transverzalno sito

- Izhodni signal $y[u]$ je konvolucija vhodnega signala $x[u]$ in uteži $w_0, w_1 \dots w_{N-1}$:



- Izhodni signal $y[n]$ je skalarni produkt vektorja vhodnega signala in vektorja uteži :

$$y[n] = \mathbf{x}^T[n] \mathbf{w} = \mathbf{w}^T \mathbf{x}[n]$$

3

Zapis kriterijske funkcije

$$\xi = \mathbf{w}^T \mathbf{R} \mathbf{w} - 2\mathbf{p}^T \mathbf{w} + \overline{d^2[n]}$$

avtokorelacijska matrika
vhodnega signala \mathbf{x}

vektor križnih korelacij med
vhodnim signalom \mathbf{x} in želenim
signalom \mathbf{d}

$$\mathbf{R} = \begin{bmatrix} r_0 & r_1 & r_2 & \dots & r_{N-1} \\ r_1 & r_0 & r_1 & \dots & r_{N-2} \\ r_2 & r_1 & r_0 & \dots & r_{N-3} \\ \dots & \dots & \dots & \dots & \dots \\ r_{N-1} & r_{N-2} & r_{N-3} & \dots & r_0 \end{bmatrix}$$

$$\mathbf{p} = \begin{bmatrix} p_0 \\ p_1 \\ p_2 \\ \dots \\ p_{N-1} \end{bmatrix}$$

$$r_m = \overline{x[n]x[n-m]}$$


$$p_m = \overline{d[n]x[n-m]}$$

4

Graf kriterijske funkcije (1)

- Kriterijska funkcija je kvadratična funkcija vektorja uteži. Za primer sita z dvema utežmi je $\xi(w_0, w_1)$ **dvodimenzionalni paraboloid**:


$$\xi = [w_0 \ w_1] \begin{bmatrix} r_0 & r_1 \\ r_1 & r_0 \end{bmatrix} \begin{bmatrix} w_0 \\ w_1 \end{bmatrix} - 2 [p_0 \ p_1] \begin{bmatrix} w_0 \\ w_1 \end{bmatrix} + \overline{d^2[r]}$$



5

Graf kriterijske funkcije (2)

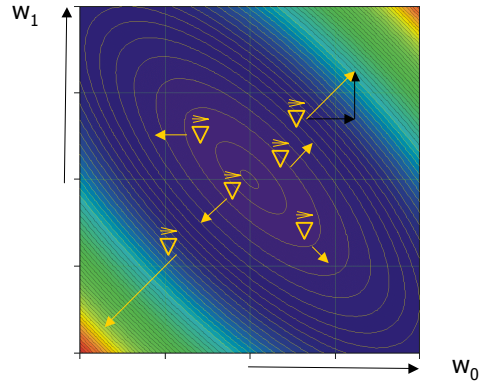
- Kriterijsko funkcijo lahko ponazorimo s plastnicami v ravnini (w_0, w_1)
- Plastnice (izohipse) združujejo točke z enako vrednostjo kriterijske funkcije: $\xi(w_0, w_1) = \text{konst}$
- Pri situ z dvema utežmi so izohipse koncentrične **elipse**:



6

Gradient kriterijske funkcije

$$\nabla = \begin{bmatrix} \frac{\partial \xi}{\partial w_0} \\ \frac{\partial \xi}{\partial w_1} \\ \frac{\partial \xi}{\partial w_2} \\ \vdots \\ \frac{\partial \xi}{\partial w_{N-1}} \end{bmatrix} = 2(\mathbf{R}\mathbf{w} - \mathbf{p})$$



- Smer gradienta je pravokotna na izohipse.
- Velikost gradienta je obratnosorazmerna razdalji med izohipsami.
- Pri optimalnem vektorju uteži je gradient enak 0:

$$\mathbf{w}_{opt} = \mathbf{R}^{-1}\mathbf{p}$$

7

Lastnosti vhodnega signala in oblika izohips



- Oblika izohips je odvisna samo od lastnosti vhodnega signala:

$$\xi(\mathbf{v}) = \xi_{min} + \mathbf{v}^T \mathbf{R} \mathbf{v}$$

- Lastne vrednosti λ in lastni vektorji \mathbf{Q} matrike \mathbf{R} : $\mathbf{R} \mathbf{Q} = \lambda \mathbf{Q}$
- Lastni vektorji kažejo v smeri polosi elips, **sploščenost elips** pa je odvisna od razmerje lastnih vrednosti matrike \mathbf{R} :

$$\mathbf{R} = \begin{bmatrix} 2 & 1.75 \\ 1.75 & 2 \end{bmatrix}$$

$$\lambda = \begin{bmatrix} 0.25 \\ 3.75 \end{bmatrix}$$



$$\mathbf{R} = \begin{bmatrix} 2 & 0.1 \\ 0.1 & 2 \end{bmatrix}$$

$$\lambda = \begin{bmatrix} 1.9 \\ 2.1 \end{bmatrix}$$

8

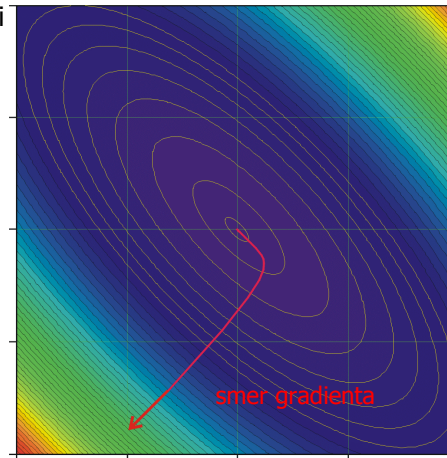
Gradientni postopek iskanja optimalne uteži - 1

Spust po največji strmini :

- utež spreminjamo v nasprotni smeri gradienta, kar ustreza spustu po največji strmini (steepest descent):

$$\mathbf{w}[m + 1] = \mathbf{w}[m] - \mu \nabla[m]$$

- spust po največji strmini **ni najkrajša pot** do optimalne točke !



9

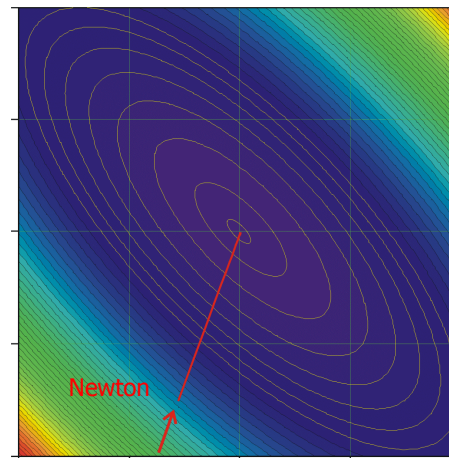
Gradientni postopek iskanja optimalne uteži - 2

Newtonov postopek :

- utež spreminjamo direktno v smeri optimalne vrednosti:

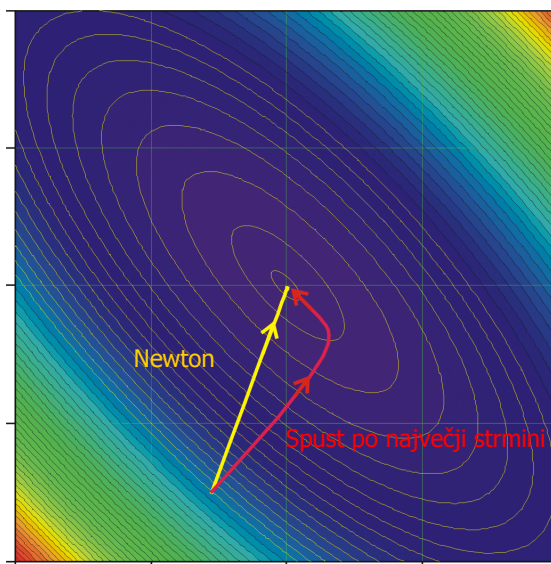
$$\mathbf{w}[m + 1] = \mathbf{w}[m] - \mu \mathbf{R}^{-1} \nabla[m]$$

- rešitev v enem koraku za primer $\mu=0.5$
- računamo inverzno matriko !



10

Primerjava gradientnih postopkov



11

Večdimenzionalni LMS algoritem


- uteži spreminjamo v nasprotni smeri **približka** gradienta:

$$\mathbf{w}[n+1] = \mathbf{w}[n] + 2\mu\varepsilon[n]\mathbf{x}[n]$$

- izbira konstante μ :

$$0 < \mu < \frac{1}{\lambda_{maks}} < \frac{1}{Nr_0}$$


- Pot popravljanja uteži je podobna kot pri spustu po največji strmini. Odstopanja so posledica napačne ocene gradienta.



12

Adaptivno LMS sito

- glavna prednost LMS algoritma je preprostost, ki omogoča ceneno izvedbo adaptivnega transversalnega LMS sita:



13

Posplošitve na več dimenzij $N > 1$

$$y[n] = w x[n]$$

$$y[n] = \mathbf{x}^T[n] \mathbf{w} = \mathbf{w}^T \mathbf{x}[n]$$

$$\xi = R w^2 - 2 P w + \overline{d^2[n]}$$

$$\xi = \mathbf{w}^T \mathbf{R} \mathbf{w} - 2 \mathbf{p}^T \mathbf{w} + \overline{d^2[n]}$$

$$\frac{d\xi}{dw} = 2(Rw - P)$$

$$\nabla = 2(\mathbf{R} \mathbf{w} - \mathbf{P})$$

$$w_{opt} = \frac{P}{R}$$

$$\mathbf{w}_{opt} = \mathbf{R}^{-1} \mathbf{p}$$

$$w[m+1] = w[m] - \mu \nabla[m]$$

$$\mathbf{w}[m+1] = \mathbf{w}[m] - \mu \nabla[m]$$

$$\mathbf{w}[m+1] = \mathbf{w}[m] - \mu \mathbf{R}^{-1} \nabla[m]$$

$$w[n+1] = w[n] + 2\mu \varepsilon[n] x[n]$$

$$\mathbf{w}[n+1] = \mathbf{w}[n] + 2\mu \varepsilon[n] \mathbf{x}[n]$$

14