



Adaptivna obdelava signalov v telekomunikacijah

5. del

2003/04

1



Pregled tem:


- gradientni algoritem
 - hitrost adaptacije in presežek napake
- LMS algoritem
 - zgledi
 - analiza LMS algoritma
- predznačni algoritem
 - analiza predznačnega algoritma
 - predznačni algoritem na osnovi približka gradienta
- primerjava algoritmov



2

Gradientni algoritem

- Utež popravljamo v nasprotni smeri gradienta kriterijske funkcije:



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

- Presežek napake je posledica perturbacije uteži in napak pri merjenju gradienta:


$$M_p = \frac{\delta^2 R}{\xi_{min}}$$

$$M_g = \frac{\overline{\xi - \xi_{min}}}{\xi_{min}} = \frac{\mu \xi_{min}}{4N\delta^2(1 - \mu R)}$$

3

Hitrost adaptacije

- Zanima nas število vzorcev n , pri katerem pade presežek srednje kvadratne napake za faktor e . Odgovor poiščemo iz krivulje učenja:



- časovna konstanta τ :

$$\tau = -\frac{N}{\ln k} \approx -\frac{N}{k - 1} = \frac{N}{\mu R}$$

4

Povečanje ξ zaradi perturbacije in napake gradienta

1. zaradi namerne perturbacije uteži pri meritvi gradienta $M_p = \frac{\delta^2 R}{\xi_{min}}$
2. zaradi napake pri meritvi gradienta $M_g = \frac{\xi_{min}}{4\delta^2 \tau R}$

$$\xi_0 = (1 + M_p + M_g) \xi_{min}$$

- neprilagojenosti sta obratnosorazmerni:
- želimo zmanjšati oba vpliva hkrati:

$$M_g = \frac{1}{4\tau M_p}$$

$$\xi_{0min} = \left(1 + \frac{1}{\sqrt{\tau}}\right) \xi_{min}$$

pogoj: $M_g = M_p = \frac{1}{2\sqrt{\tau}}$

5

Povezava minimalne napake s hitrostjo adaptacije

- srednja kvadratična napaka se v ravnotežnem stanju poveča za najmanj:

$$\xi_{0min} = \left(1 + \frac{1}{\sqrt{\tau}}\right) \xi_{min}$$

Ne moremo imeti hkrati majhnega povečanja napake in hitre adaptacije uteži:

- hitra adaptacija pomeni manjhen τ in s tem večji ξ_{0min}
- počasna adaptacija pomeni velik τ in s tem manjši ξ_{0min}

Rešitev problema je v spreminjanju adaptacijske konstante :


- na začetku izberemo večjo vrednost adaptacijske konstante μ
- ko se približujemo optimalni vrednosti uteži, zmanjšujemo μ

$$\tau = -\frac{N}{\ln k} \approx -\frac{N}{k-1} = \frac{N}{\mu R}$$

6

LMS algoritem

- Gradientni algoritem: $w[m + 1] = w[m] - \mu \nabla [m]$
- **LMS algoritem**: namesto natančnega gradienta kvadrata napake uporabimo preprost približek na osnovi ene same meritve!




- **LMS** (Least Mean Square) algoritem:

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

7

LMS algoritem - zgled 1

- Signal na vhodu in željeni signal sta konstantna: $x=5, d=10$



- LMS algoritem: $w[n + 1] = w[n] + 2 \mu \varepsilon[n] x[n]$

- Izberemo utež μ :


$$0 < \mu < \frac{1}{R}$$

$$\mu = 1/100$$

8

LMS algoritem - zglede 2

- Podana sta signal na vhodu in želeni signal:



- LMS algoritem: $w[n + 1] = w[n] + 2 \mu \varepsilon[n] x[n]$

- Kako izberemo utež μ ?


$$0 < \mu < \frac{1}{R}$$

$$\mu = 0.5 \mu_0 ?$$

9


LMS algoritem - zglede 2-a

- $\mu = 0.5$



LMS algoritem - zglede 2-b

- $\mu = 0.05$




Analiza napak pri LMS algoritmu

- varianca gradienta v ravnotežnem stanju: $\overline{\eta^2[n]} = \overline{\hat{\nabla}^2[n]} = 4 \overline{\epsilon^2[n]x^2[n]} = 4 \xi_{min} R$
- varianca uteži: $\text{var}(w) = \frac{\mu \xi_{min}}{1 - \mu R}$ $\text{var}(w) = \mu \xi_{min}$
- presežek napake v ravnotežnem stanju: $\overline{\xi} - \xi_{min} = \overline{v^2} R = \mu \xi_{min} R$
- neprilagoditev: $M = \frac{\overline{\xi} - \xi_{min}}{\xi_{min}} = \mu R$
- približek časovne konstante τ : $\tau = \frac{1}{2 \ln(1 - 2\mu R)} \approx \frac{1}{4\mu R}$
- neprilagoditev in hitrost adaptacije sta v obratnem sorazmerju: $M = \frac{1}{4\tau}$

Predznačni algoritem

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

- namesto natančnega gradienta povprečja kvadrata napake upoštevamo samo **predznak gradienta** (+ ali -)!



$$w[m + 1] = w[m] - \mu \text{sign}(\hat{\nabla}[m])$$

- predznak gradienta je odvisen samo od odmika od optimalne uteži:

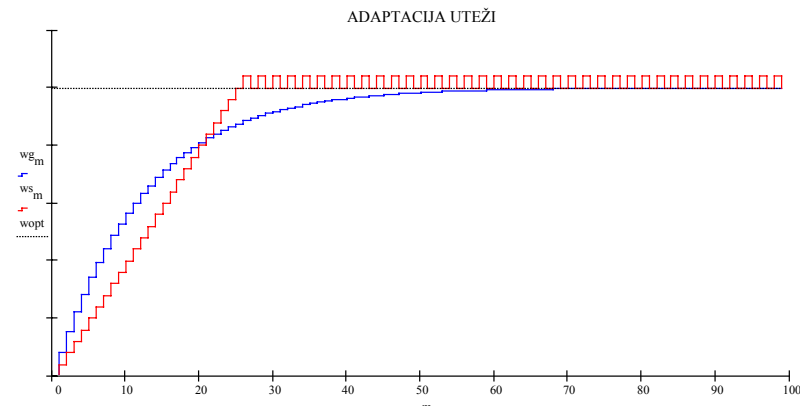
$$v[m + 1] = v[m] - \mu \text{sign}(v[m])$$

13

Proces adaptacije uteži

Zgled: $x[n]=2 \cos(n \pi/6)$, $d[n]=2 \cos(n \pi/6+\pi/3)$, $\mu=0.02$

- gradientni algoritem
- predznačni algoritem

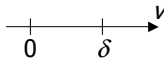


14

Analiza predznačnega algoritma

- predznačni algoritem: $v[m + 1] = v[m] - \mu \text{sign}(v[m])$

- v najslabšem primeru je presežek napake:

$$\overline{\xi - \xi_{min}} = \frac{\mu^2 R}{2}$$


- neprilagojenost v okolici optimalne uteži:

$$M = \frac{\overline{\xi - \xi_{min}}}{\xi_{min}} = \frac{\mu^2 R}{2\xi_{min}}$$

15

Poenostavljeni SIGN algoritem

- predznačni algoritem: $w[m + 1] = w[m] - \mu \text{sign}(\hat{\nabla}[m])$

- uporabimo približek gradienta:

$$\hat{\nabla}[n] = -2 \varepsilon[n]x[n]$$

- **poenostavljeni SIGN** algoritem:

$$w[n + 1] = w[n] + \mu \text{sign}(\varepsilon[n])\text{sign}(x[n])$$

16

Analiza SIGN algoritma:

- poenostavljeni SIGN algoritem:

$$w[n+1] = w[n] + \mu \operatorname{sign}(\varepsilon[n]) \operatorname{sign}(x[n])$$

- odstopanje od optimalne uteži:

$$v[n+1] = v[n] + \mu \operatorname{sign}(\varepsilon[n]x[n])$$

$$\varepsilon[n] = \varepsilon_{min}[n] - v[n]x[n]$$

$$v[n+1] = v[n] + \mu \operatorname{sign}(\varepsilon_{min}[n]x[n] - v[n]x^2[n])$$

Napaka v okolici optimalne uteži je odvisna od minimalne napake:

- če je minimalna napaka enaka 0, se utež spreminja v okolici $w_{opt} \pm \mu$
- zaradi residualnega šuma nastopajo tudi popravki v napačno smer, število popravkov v pravi smeri pa narašča z odmikom od optimalne uteži !!

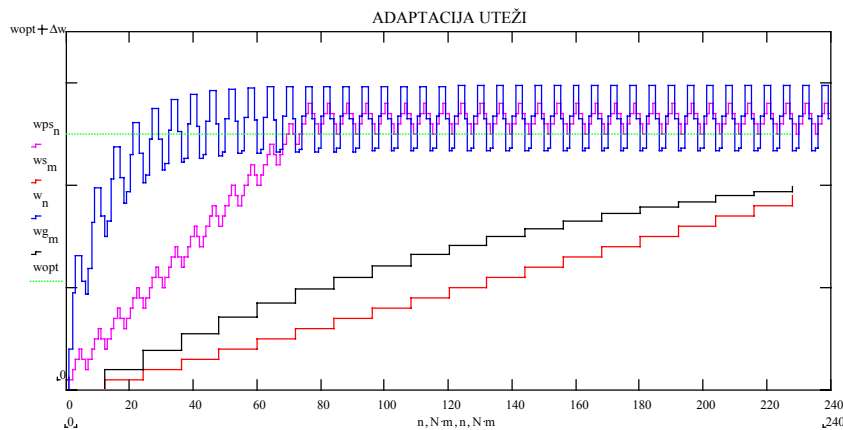
17

Primerjava algoritmov

Zgled: $x[n]=2 \cos(n \pi/6)$, $d[n]=2 \cos(n \pi/6+\pi/3)$, $\mu=0.02$

- gradientni algoritem, SIGN algoritem,
- LMS algoritem, poenostavljeni SIGN algoritem

$w_{opt}=0.5$



18