

# **PROCESAREA SEMNALELOR - CURS 09**

**SERII DE TIMP - MODELE ARMA**

Cristian Rusu

# CUPRINS

- mediere exponențială
- modele MA
- modele ARMA

# MEDIERE EXPONENȚIALĂ

- funcțiile de mediere glisantă atribuie aceeași pondere elementelor și folosește un număr finit de elemente din trecut
- o idee nouă: contribuția pe care o are fiecare termen în medie descrește pe măsură ce trece timpul
- primim o serie de timp cu  $N$  elemente:  $x[0], x[2], \dots, x[N - 1]$
- creăm o nouă serie de timp:
$$s[0] = x[0]$$
$$s[t] = \alpha x[t] + (1 - \alpha)s[t - 1], t > 1$$
- $\alpha$  se numește factorul de uitare (sau de netezire),  $0 \leq \alpha \leq 1$
- $\alpha$  trebuie ales

# MEDIERE EXPONENȚIALĂ

- de ce se numește mediere exponențială?

$$\begin{aligned} s[t] &= \alpha x[t] + (1 - \alpha)s[t - 1] \\ &= \alpha x[t] + \alpha(1 - \alpha)x[t - 1] + (1 - \alpha)^2 s[t - 2] \\ &= \alpha(x[t] + (1 - \alpha)x[t - 1]) + (1 - \alpha)^2 s[t - 2] \\ &= \dots \end{aligned}$$

# MEDIERE EXPONENȚIALĂ

- de ce se numește mediere exponențială?

$$\begin{aligned} s[t] &= \alpha x[t] + (1 - \alpha)s[t - 1] \\ &= \alpha x[t] + \alpha(1 - \alpha)x[t - 1] + (1 - \alpha)^2 s[t - 2] \\ &= \alpha(x[t] + (1 - \alpha)x[t - 1]) + (1 - \alpha)^2 s[t - 2] \\ &= \alpha(x[t] + (1 - \alpha)x[t - 1] + (1 - \alpha)^2 x[t - 2] + \dots + (1 - \alpha)^{t-1} x[1]) + (1 - \alpha)^t x[0] \\ &= \alpha \sum_{i=0}^{t-1} (1 - \alpha)^i x[t - i] + (1 - \alpha)^t x[0] \end{aligned}$$

- progresia matematică de puteri ale lui  $(1 - \alpha)$  este o versiune discretă a funcției exponențiale
- de ce se numește mediere?

# MEDIERE EXPONENȚIALĂ

- de ce se numește mediere?

$$\alpha \sum_{i=0}^{t-1} (1 - \alpha)^i = \alpha \frac{1 - (1 - \alpha)^t}{1 - (1 - \alpha)} = 1 - (1 - \alpha)^t$$

- deci avem că:

$$\alpha \sum_{i=0}^{t-1} (1 - \alpha)^i - (1 - \alpha)^t = 1$$

- adică avem o mediere ponderată

# MEDIERE EXPONENȚIALĂ

- cum îl calculăm pe  $\alpha$ ?

$$\begin{aligned}s[t] &= \alpha(x[t] + (1 - \alpha)x[t - 1] + (1 - \alpha)^2x[t - 2] + \dots + (1 - \alpha)^{t-1}x[1]) + (1 - \alpha)^tx[0] \\ &= \alpha \sum_{i=0}^{t-1} (1 - \alpha)^i x[t - i] + (1 - \alpha)^t x[0]\end{aligned}$$

- avem două opțiuni:
  - îl alegem
  - îl calculăm
- dacă vrem să îl calculăm cum facem?

# MEDIERE EXPONENȚIALĂ

- cum îl calculăm pe  $\alpha$ ?

$$\begin{aligned} s[t] &= \alpha(x[t] + (1 - \alpha)x[t - 1] + (1 - \alpha)^2x[t - 2] + \dots + (1 - \alpha)^{t-1}x[1]) + (1 - \alpha)^t x[0] \\ &= \alpha \sum_{i=0}^{t-1} (1 - \alpha)^i x[t - i] + (1 - \alpha)^t x[0] \end{aligned}$$

- avem două opțiuni:
  - îl alegem
  - îl calculăm

- dacă vrem să îl calculăm cum facem?

- minimizăm  $\sum_{t=0}^{N-2} (s[t] - x[t + 1])^2$ , nu  $\sum_{t=0}^{N-1} (s[t] - x[t])^2$  care are o soluție banală<sup>0</sup>
- putem să folosim cele mai mici pătrate ca să rezolvăm pentru  $\alpha$ ?



# MEDIERE EXPONENȚIALĂ

- cum îl calculăm pe  $\alpha$ ?

$$\begin{aligned} s[t] &= \alpha(x[t] + (1 - \alpha)x[t - 1] + (1 - \alpha)^2x[t - 2] + \dots + (1 - \alpha)^{t-1}x[1]) + (1 - \alpha)^t x[0] \\ &= \alpha \sum_{i=0}^{t-1} (1 - \alpha)^i x[t - i] + (1 - \alpha)^t x[0] \end{aligned}$$

- avem două opțiuni:
  - îl alegem
  - îl calculăm

- dacă vrem să îl calculăm cum facem?

- minimizăm  $\sum_{t=0}^{N-2} (s[t] - x[t + 1])^2$ , nu  $\sum_{t=0}^{N-1} (s[t] - x[t])^2$  care are o soluție banală<sup>0</sup>
- putem să folosim cele mai mici pătrate ca să rezolvăm pentru  $\alpha$ ?
- NU, pentru că problema nu este liniară în  $\alpha$
- atunci, cum găsim  $\alpha$ ?

# MEDIERE EXPONENȚIALĂ

- un calcul greșit pentru  $\alpha$

$$(s[t] - x[t + 1])^2 = (\alpha(x[t] - s[t - 1]) + s[t - 1] - x[t + 1])^2$$

- adică avem nevoie de

$$\alpha(x[t] - s[t - 1]) \approx x[t + 1] - s[t - 1]$$

- cum rezolvăm acum?

# MEDIERE EXPONENȚIALĂ

- un calcul greșit pentru  $\alpha$

$$(s[t] - x[t + 1])^2 = (\alpha(x[t] - s[t - 1]) + s[t - 1] - x[t + 1])^2$$

- adică avem nevoie de

$$\alpha(x[t] - s[t - 1]) \approx x[t + 1] - s[t - 1]$$

- cum rezolvăm acum?

$$\begin{bmatrix} x[t] - s[t - 1] \\ x[t - 1] - s[t - 2] \\ x[t - 2] - s[t - 3] \\ \vdots \\ x[2] - s[1] \end{bmatrix} \alpha = \begin{bmatrix} x[t + 1] - s[t - 1] \\ x[t] - s[t - 2] \\ x[t - 1] - s[t - 3] \\ \vdots \\ x[3] - s[1] \end{bmatrix}$$

# MEDIERE EXPONENȚIALĂ

- un calcul greșit pentru  $\alpha$

$$(s[t] - x[t + 1])^2 = (\alpha(x[t] - s[t - 1]) + s[t - 1] - x[t + 1])^2$$

- adică avem nevoie de

$$\alpha(x[t] - s[t - 1]) \approx x[t + 1] - s[t - 1]$$

- cum rezolvăm acum?

$$\begin{bmatrix} x[t] - s[t - 1] \\ x[t - 1] - s[t - 2] \\ x[t - 2] - s[t - 3] \\ \vdots \\ x[2] - s[1] \end{bmatrix} \alpha = \begin{bmatrix} x[t + 1] - s[t - 1] \\ x[t] - s[t - 2] \\ x[t - 1] - s[t - 3] \\ \vdots \\ x[3] - s[1] \end{bmatrix}$$

- $\alpha = \frac{\mathbf{a}^T \mathbf{b}}{\mathbf{a}^T \mathbf{a}} = \frac{\mathbf{a}^T \mathbf{b}}{\|\mathbf{a}\|_2^2}$

# MODELUL MA

- modelul medie glisantă (moving average - MA)
  - ideea: trecutul afectează viitorul (combinații ale valorilor din trecut pot prezice valori din viitor)
  - la momentul  $i$  vom face o combinație liniară de erori anterioare
  - cât de mult mergem în trecut? un orizont  $p$  pe care îl alegem
- formularea matematică

$$\hat{y}[i] = \epsilon[i] + \theta_1\epsilon[i-1] + \theta_2\epsilon[i-2] + \dots + \theta_p\epsilon[i-p] + \mu = \begin{bmatrix} 1 & \theta_1 & \dots & \theta_p & 1 \end{bmatrix} \begin{bmatrix} \epsilon[i] \\ \epsilon[i-1] \\ \vdots \\ \epsilon[i-p] \\ \mu \end{bmatrix}$$

- ce este operația de mai sus?

# MODELUL MA

- modelul medie glisantă (moving average - MA)
  - ideea: trecutul afectează viitorul (combinații ale valorilor din trecut pot prezice valori din viitor)
  - la momentul  $i$  vom face o combinație liniară de erori anterioare
  - cât de mult mergem în trecut? un orizont  $p$  pe care îl alegem
- formularea matematică

$$\hat{y}[i] = \epsilon[i] + \theta_1\epsilon[i-1] + \theta_2\epsilon[i-2] + \dots + \theta_p\epsilon[i-p] + \mu = \begin{bmatrix} 1 & \theta_1 & \dots & \theta_p & 1 \end{bmatrix} \begin{bmatrix} \epsilon[i] \\ \epsilon[i-1] \\ \vdots \\ \epsilon[i-p] \\ \mu \end{bmatrix}$$

- ce este operația de mai sus?
- produs scalar, deci din nou cele mai mici pătrate pentru a estima parametrii  $\theta$  ai modelului
- eroarea la fiecare pas poate să fie estimată ca zgomot gaussian

# MODELUL MA

- un exemplu
- estimăm media unei serii să fie 12, apoi la fiecare moment de timp avem și presupunem că am estimat  $\theta_1 = \frac{1}{2}$

ziua	predicția	valoarea reală	eroarea
1	12	14	2
2	$13 = 12 + 2/2$	13	0
3	$12 = 12 + 0/2$	8	-4
4	$10 = 12 - 4/2$	14	4
5	...	...	...
6	...	...	...

- Presupunerea implicită este că valorile reale fluctuează în jurul mediei

# COMBINAȚIA: ARMA

- $ARMA = AR(p) + MA(q)$

$$y[t] = \sum_{i=1}^p x_i y[t-i] + \sum_{i=1}^q \theta_i \epsilon[t-i] + \epsilon[t]$$

- parametrii sunt:
  - $p$  parametrii auto-regresivi
  - $q$  parametrii de mediere
- problema: din cauza MA, optimizarea parametrilor devine foarte dificilă aici
- discuție la tablă cazul  $p = 1$  și  $q = 1$



# DATA VIITOARE

- modele mai avansate pentru serii de timp

