


# Προσαρμοζόμενα Φίλτρα


(adaptive filters)



- A Εισαγωγικά - Φίλτρα Wiener
- B Προσέγγιση - Αλγόριθμος LMS
- Γ Εφαρμογές

# A

## Πρώτη προσέγγιση

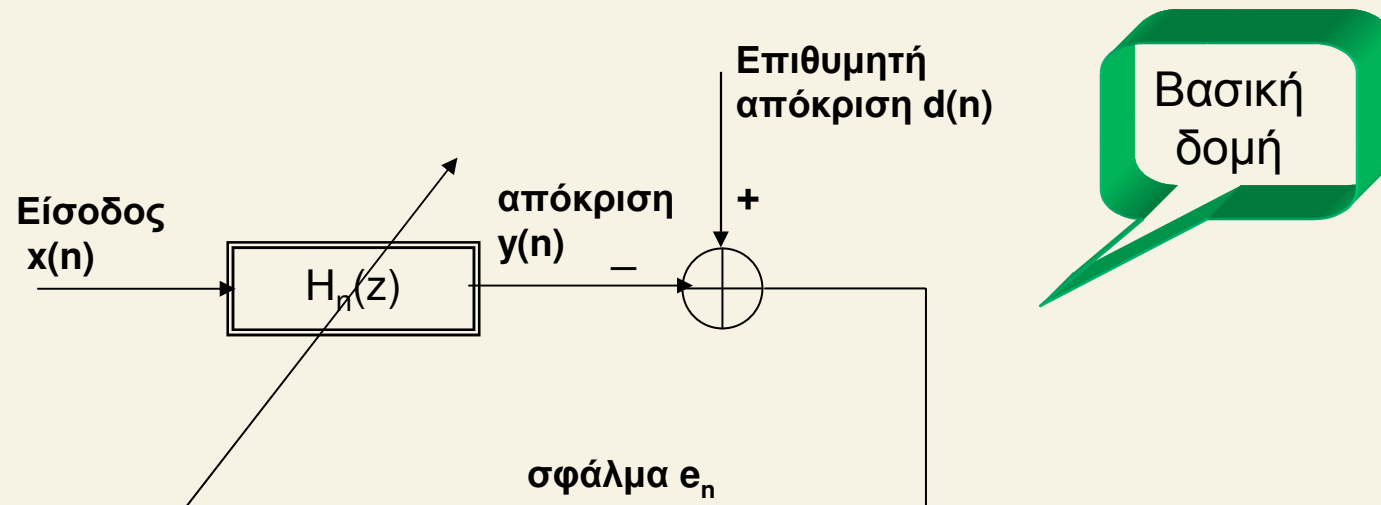


**Οι συντελεστές  $h_n(k)$  εξαρτώνται από την χρονική στιγμή  $n$ .**

Τα προσαρμοζόμενα φίλτρα (και τα αντίστοιχα συστήματα) είναι (συνήθως) FIR φίλτρα με μεταβαλλόμενους συντελεστές. Οι συντελεστές  $h(k)$  μεταβάλλονται σε κάθε χρονική στιγμή  $n$  με τέτοιο τρόπο ώστε να ελαττώσουν κάποια συνάρτηση κόστους - σφάλματος.

# A

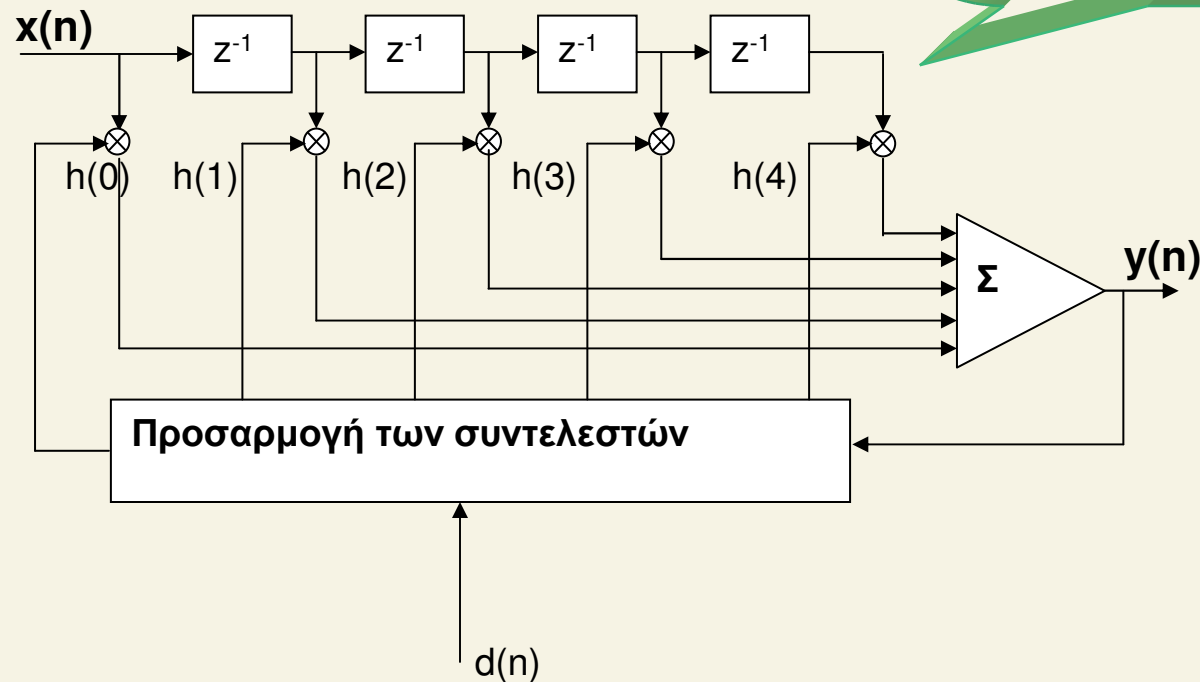

## Διαδικασία ελαχιστοποίησης του σφάλματος



Το σφάλμα  $e_n$  προκύπτει από την διαφορά του σήματος εισόδου και του **επιθυμητού** σήματος. Το σήμα αυτό  $e_n$  χρησιμοποιείται για την προσαρμογή των συντελεστών  $h(k)$

# A

## Adaptive FIR φίλτρα



Το φίλτρο αυτό έχει 5 συντελεστές που μεταβάλλονται ώστε τελικά να επιτευχθεί η ελαχιστοποίηση του σφάλματος

# A

## Adaptive FIR φίλτρα - Υπολογισμοί

$$y(n) = \sum_{k=0}^{N-1} h(k)x(n-k) \quad n = 0, \dots, M$$

$$e_n = d(n) - y(n)$$

Οι συντελεστές  $h(k)$  βρίσκονται με την ελαχιστοποίηση του τετραγωνικού σφάλματος  $e^2$  για όλα τα σημεία  $n$  του σήματος.

Δηλαδή την ελαχιστοποίηση του αθροίσματος :

$$J = \sum_{n=0}^M e_n^2$$

# A

## Υπολογισμοί (συνέχεια)

$$\begin{aligned} J &= \sum_{n=0}^M e_n^2 = \sum_{n=0}^M \left[ d(n) - \sum_{k=0}^{N-1} h(k)x(n-k) \right]^2 \\ &= \sum_{n=0}^M d^2(n) - 2 \sum_{k=0}^{N-1} h(k)r_{dx}(k) + \sum_{k=0}^{N-1} \sum_{l=0}^{N-1} h(k)h(l)r_{xx}(k-l) \end{aligned}$$

$r_{dx}$  = ετεροσυσχέτιση μεταξύ  $d$  και  $x$ :

$$r_{dx}(k) = \sum_{n=0}^M d(n)x(n-k) \quad 0 \leq k \leq N-1$$

$r_{xx}$  = αυτοσυσχέτιση του  $x$ :

$$r_{xx}(k) = \sum_{n=0}^M x(n)x(n-k) \quad 0 \leq k \leq N-1$$

# A

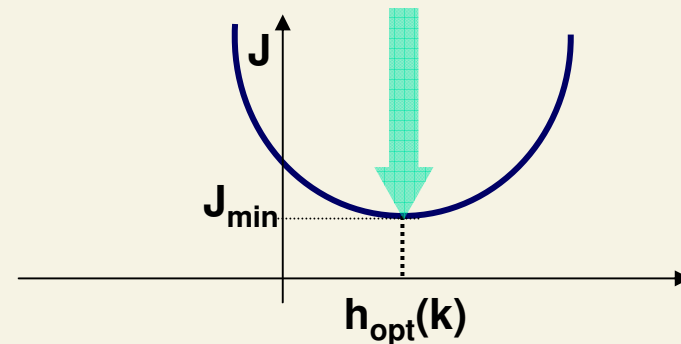
## Ελαχιστοποίηση του J εξίσωση *Wiener-Hopf*

$$\frac{\partial J}{\partial h(m)} = 0 \quad 0 \leq m \leq N-1 \Rightarrow$$

$$\sum_{k=0}^{N-1} h_{\text{opt}}(k) r_{xx}(k-m) = r_{dx}(m) \quad 0 \leq m \leq N-1$$


Σε μορφή πίνακα:

$$\mathbf{h}_{\text{opt}} \mathbf{r}_{xx} = \mathbf{r}_{dx}$$



# A

## Το ελάχιστο σφάλμα



Όταν ισχύει η συνθήκη Wiener-Hopf :  $\sum_{k=0}^{N-1} h_{\text{opt}}(k) r_{\text{xx}}(k-m) = r_{\text{dx}}(m)$

δηλ. έχουμε τους βέλτιστους συντελεστές,


το σφάλμα J είναι ελάχιστο και έχει την εξής τιμή:

$$\begin{aligned}
 J_{\min} &= \sum_{n=0}^M d^2(n) - 2 \sum_{k=0}^{N-1} h(k) r_{\text{dx}}(k) + \sum_{k=0}^{N-1} \sum_{l=0}^{N-1} h(k) h(l) r_{\text{xx}}(k-l) = \\
 &= \sum_{n=0}^M d^2(n) - 2 \sum_{k=0}^{N-1} h_{\text{opt}}(k) r_{\text{dx}}(k) + \sum_{k=0}^{N-1} \sum_{l=0}^{N-1} h_{\text{opt}}(k) h_{\text{opt}}(l) r_{\text{xx}}(k-l) = \\
 &= \sum_{n=0}^M d^2(n) - 2 \sum_{k=0}^{N-1} h_{\text{opt}}(k) r_{\text{dx}}(k) + \sum_{k=0}^{N-1} h_{\text{opt}}(k) r_{\text{dx}}(k) = \\
 &= \sum_{n=0}^M d^2(n) - \sum_{k=0}^{N-1} h_{\text{opt}}(k) r_{\text{dx}}(k)
 \end{aligned}$$



# A

## Παράδειγμα (5 σημεία)



$$r_{xx}(k) = \sum_{n=0}^{19} x(n)x(n-k) \quad 0 \leq k \leq 4$$



$$r_{dx}(k) = \sum_{n=0}^{19} d(n)x(n-k) \quad 0 \leq k \leq 4$$

$$\sum_{k=0}^4 h(k)r_{xx}(k-m) = r_{dx}(m) \quad 0 \leq m \leq 4$$

# Παράδειγμα - φίλτρο 1ης τάξεως

$$y(n) = hx(n)$$

$$e_n = d(n) - hx(n)$$



$$J = \sum_{n=0}^M e_n^2 = \sum_{n=0}^M [d(n) - hx(n)]^2 =$$

$$= \sum_{n=0}^M [d(n)]^2 + \sum_{n=0}^M [hx(n)]^2 - 2 \sum_{n=0}^M [d(n)hx(n)] \Rightarrow$$

$$\frac{\partial J}{\partial h} = 0 \Rightarrow 2 \sum_0^M h_{opt} [x(n)]^2 - 2 \sum_0^M d(n)x(n) = 0 \Rightarrow$$

$$h_{opt} \sum_{n=0}^M [x(n)]^2 = \sum_0^M d(n)x(n)$$

συνέχεια 



## Παράδειγμα - φίλτρο 1ης τάξεως (συνέχεια)

Ποία είναι η συσχέτιση του σφάλματος  $e_n$  με το σήμα  $x(n)$ ??

$$\begin{aligned} r_{xe_n} &= \sum_{n=0}^M e_n x(n) = \sum_{n=0}^M [d(n) - h_{\text{opt}} x(n)] [x(n)] = \\ &= \sum_{n=0}^M [d(n)x(n)] - h_{\text{opt}} \sum_{n=0}^M [x(n)]^2 = \\ &= \sum_{n=0}^M [d(n)x(n)] - \frac{\sum_{n=0}^M [d(n)x(n)]}{\sum_{n=0}^M [x(n)]^2} \sum_{n=0}^M [x(n)]^2 = 0 \end{aligned}$$

Δηλαδή το σφάλμα  $e_n$  είναι ορθογώνιο με το σήμα  $x(n)$

**Αποδεικνύεται ότι σε κάθε περίπτωση που έχουμε συνθήκη ελαχίστου σφάλματος το σφάλμα  $e_n$  είναι ορθογώνιο με το σήμα  $x(n)$ .**

$$\text{Δηλαδή } E\{e(n)x(n)\}=0$$

# A

## Στατιστική θεώρηση (Wiener)

$$y(n) = \mathbf{H}^T \mathbf{X}_n \quad \text{όπου } \mathbf{X}_n = [x_n \ x_{n-1} \ \dots \ x_{n-(N-1)}]^T$$
$$\text{και } \mathbf{H} = [h(0) \ h(1) \ \dots \ h(N-1)]^T, \quad (\tau = \text{ανάστροφος})$$

Αντίστοιχα το σφάλμα  $e_n$  γράφεται:

$$e_n = y(n) - d(n) = \mathbf{H}^T \mathbf{X}_n - d(n)$$

Και το τετραγωνικό σφάλμα:  $e_n^2 = d^2(n) - 2d(n) \mathbf{X}_n^T \mathbf{H} + \mathbf{H}^T \mathbf{X}_n \mathbf{X}_n^T \mathbf{H} \Rightarrow$

$$\mathbf{J} = \mathbf{E}\{e_n^2\} = \mathbf{E}\{d^2(n)\} - 2\mathbf{E}\{d(n) \mathbf{X}_n^T \mathbf{H}\} + \mathbf{E}\{\mathbf{H}^T \mathbf{X}_n \mathbf{X}_n^T \mathbf{H}\} = \sigma^2 - 2\mathbf{P}^T \mathbf{H} + \mathbf{H}^T \mathbf{R} \mathbf{H}$$

$\sigma^2$  είναι η διακύμανση του  $d(n)$ ,  $\mathbf{P} = \mathbf{E}\{d(n) \mathbf{x}_n\}$  είναι το  $N$  διαστάσεων διάνυσμα ετεροσυσχέτισης μεταξύ  $d(n)$  και  $\mathbf{X}_n$  δηλ.  $\mathbf{P} = [r_{dx}(0), r_{dx}(1) \ \dots \ r_{dx}(N-1)]^T$


Και  $\mathbf{R}$  ο  $(N \times N)$  πίνακας αυτοσυσχέτισης :  $\mathbf{R} = \mathbf{E}\{\mathbf{x}_n \mathbf{x}_n^T\}$  Δηλ.  $\mathbf{R}_{ij} = r_{xx}(i-j)$

# A


## Οι βέλτιστοι συντελεστές

Η συνάρτηση κόστους  $J$  παριστάνει μία επιφάνεια και επειδή η συνάρτηση αυτή είναι τετραγωνική έχει ένα και μοναδικό ελάχιστο.

$$\nabla = \frac{dJ}{dH} = -2P + 2RH \Rightarrow H_{\text{opt}} = R^{-1}P$$



Στη συνέχεια θα δούμε πώς το ελάχιστο αυτό μπορεί να προσεγγισθεί σε διαδοχικά βήματα δηλαδή με προσαρμογή





# Υλοποίηση του φίλτρου Wiener «με προσαρμογή»

# Ο αλγόριθμος LMS (Least Mean Squares)

*Είναι ο βασικός αλγόριθμος προσαρμοζόμενων φίλτρων*


Βρίσκει το ελάχιστο του σφάλματος  $J$  με διαδοχικά βήματα που βασίζονται στην παράγωγο (βάθμωση  $\nabla J$ ) της συνάρτησης  $J$ .

**Προϋποθέσεις:**

- Το σύστημα είναι **στατικό**
- Οι τιμές (παράμετροι)  $h(k)$

**διορθώνονται** σε κάθε χρονική στιγμή  **$n$**

δηλαδή  $h(k)=h_n(k)$





# B

## Ο αλγόριθμος LMS - Υλοποίηση

Η **διόρθωση** των τιμών  $h(k)$  γίνεται σύμφωνα με την θεμελιώδη σχέση


$$\mathbf{h}_n(\mathbf{k}) = \mathbf{h}_{n-1}(\mathbf{k}) + \mu \mathbf{e}_n \mathbf{x}(n-\mathbf{k}) \quad 0 \leq k \leq N-1 \quad n=0,1,2 \dots M$$

Όπου

- $\mathbf{e}_n = \mathbf{d}(n) - \mathbf{y}(n)$  είναι το σφάλμα
- $\mu$  είναι το **βήμα**, μία παράμετρος που καθορίζει την ταχύτητα σύγκλισης
- Για εξασφάλιση ευστάθειας το  $\mu$  επιλέγεται στην εξής περιοχή τιμών:  
 $0 < \mu < \frac{1}{N P_x}$  όπου  $P_x = \eta$  ισχύς του σήματος  $P_x = \frac{1}{M+1} \sum_{n=0}^M x^2(n)$
- $\mathbf{e}(n)\mathbf{x}(n-\mathbf{k})$  είναι μία προσέγγιση (του αρνητικού) της βάθμωσης ( $\nabla J$ )

## B

# Ο αλγόριθμος LMS - ΠΩΣ ΠΡΟΕΚΥΨΕ



Η εύρεση του ελαχίστου  $J_{\min}$  γίνεται μέσω της βάθμωσης  $\nabla_n$

$$\nabla_n = \frac{\partial J}{\partial \mathbf{H}_n} = \left\{ \frac{\partial J}{\partial h_n(0)}, \frac{\partial J}{\partial h_n(1)}, \dots, \frac{\partial J}{\partial h_n(N-1)} \right\}^T$$

σε διαδοχικά βήματα :  $\mathbf{H}_{n+1} = \mathbf{H}_n - \mu \nabla_n$

όπου  $\mathbf{H}_n = \{h_n(k) \quad k=0, \dots, N-1\}^T$

# B

## Ο αλγόριθμος LMS - ΠΩΣ ΠΡΟΕΚΥΨΕ

### εξίσωση Widrow-Hopf

Η εκτίμηση της βάρωσης γίνεται βάσει του **στιγμιαίου** σφάλματος και είναι:


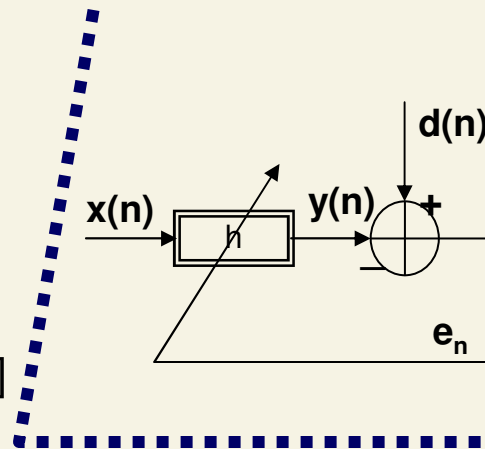
$$\hat{\nabla}_n = \frac{\partial e_n^2}{\partial H_n} = 2e_n \frac{\partial e_n}{\partial H_n} = 2e_n \frac{\partial (d_n - y_n)}{\partial H_n} = -2e_n \frac{\partial y_n}{\partial H_n} = -2e_n X_n$$

$$H_{n+1} = H_n + 2 e_n \mu X_n$$

# Παράδειγμα - φίλτρο 1ης τάξεως

$$y(n) = hx(n) \quad e_n = d(n) - hx(n)$$

$$\begin{aligned} J &= \sum_{n=0}^M e_n^2 = \sum_{n=0}^M [d(n) - hx(n)]^2 = \\ &= \sum_{n=0}^M [d(n)]^2 + \sum_{n=0}^M [hx(n)]^2 - 2 \sum_{n=0}^M [d(n)hx(n)] \end{aligned}$$



**Εύρεση της λύσης  $\frac{\partial J}{\partial h} = 0$  σταδιακά (χωρίς προσέγγιση):  $h = h_n$**

$$h_{n+1} = h_n - \mu \frac{\partial J}{\partial h} \quad \text{καί} \quad \frac{\partial J}{\partial h} = 2h \sum_0^M [x(n)]^2 - 2 \sum_0^M d(n)x(n) = 2hR_{xx}(0) - 2r_{dx}(0)$$

$$\Rightarrow h_{n+1} = h_n - \mu [2h_n R_{xx}(0) - 2r_{dx}(0)] = [1 - 2\mu R_{xx}(0)]h_n + 2\mu r_{dx}(0)$$

$$H(z) = az^{-1}H(z) + b \rightarrow H(z) = b/(1 - az^{-1}) \rightarrow |a| < 1 \quad \text{για ευστάθεια}$$

## Παράδειγμα - φίλτρο 1ης τάξεως (συνέχεια)

Προσέγγιση της λύσης  $\frac{\partial J}{\partial h} = 0$  με τον αλγόριθμο LMS

$$h_{n+1} = h_n - \mu \frac{\partial J}{\partial h} \quad \text{καί}$$

$$\frac{\partial J}{\partial h} = \frac{\partial e_n^2}{\partial h} = 2e_n \frac{\partial e_n}{\partial h} = 2e_n \frac{\partial [x(n) - y(n)]}{\partial h} = 2e_n \frac{\partial [x(n) - hx(n)]}{\partial h} = -2e_n x(n)$$

$$\Rightarrow h_{n+1} = h_n - \mu [-2e_n x(n)] = h_n + 2\mu e_n x(n)$$

# B

## Άλλες μορφές του αλγορίθμου LMS

NLMS (normalized LMS)

SELMS (sign-error LMS)

SDLMS (sign-data LMS)

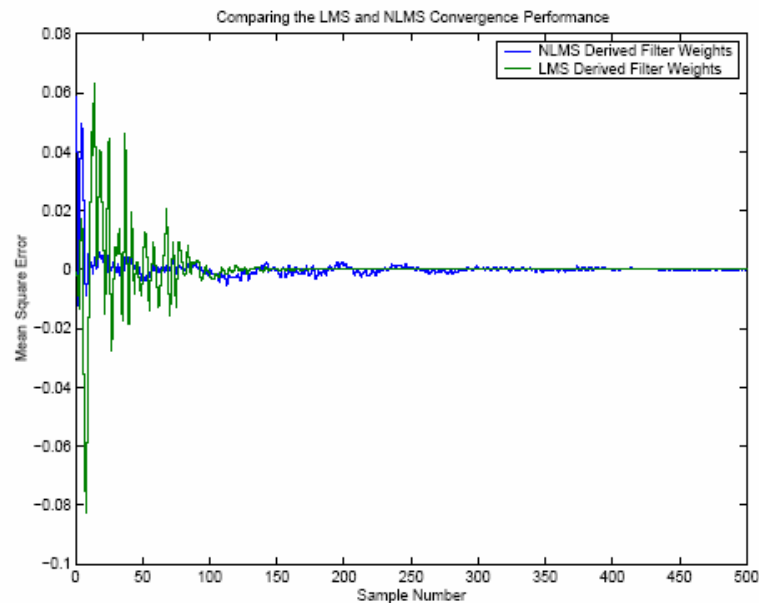
SSLMS (sign-sign LMS)

# B

## NLMS- normalized LMS

Στον NLMS το βήμα σύγκλισης  $\mu$  μεταβάλεται σύμφωνα με την (στιγμιαία) ισχύ του σήματος

Αυτό συνεπάγεται ταχύτερη σύγκλιση



Στο σχήμα δεικνύεται συγκριτικά η συμπεριφορά (σύγκλισης) των αλγορίθμων LMS και NLMS

# B

## SELMS (sign-error LMS)

$$h_n(k) = h_{n-1}(k) + \mu \operatorname{sgn}[e_n] x(n-k)$$

$$\text{όπου } \operatorname{sgn}[e_n] = \begin{cases} 1 & e_n > 0 \\ 0 & e_n = 0 \\ -1 & e_n < 0 \end{cases}$$

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



# B

## SDLMS (sign-data LMS)

$$h_n(k) = h_{n-1}(k) + \mu e_n \operatorname{sgn}[x(n-k)]$$

$$\text{όπου } \operatorname{sgn}[x] = \begin{cases} 1 & x > 0 \\ 0 & x = 0 \\ -1 & x < 0 \end{cases}$$

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


# B

## SSLMS (sign-sign LMS)

$$h_n(k) = h_{n-1}(k) + \mu \operatorname{sgn}[e_n] \operatorname{sgn}[x(n-k)]$$

$$\text{όπου } \operatorname{sgn}[z] = \begin{cases} 1 & z > 0 \\ 0 & z = 0 \\ -1 & z < 0 \end{cases}$$

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

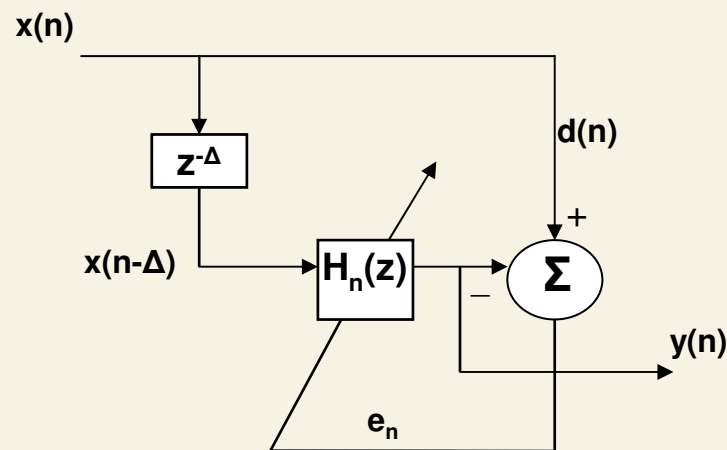


## Εφαρμογή 1


# Ανάδειξη (φασματικής) γραμμής

(line enhancer)


Αναφέρεται σε ένα ημιτονικό σήμα (φασματική γραμμή) που βρίσκεται μέσα σε **θόρυβο** ευρέως φάσματος και ασυσχέτιστο με το σήμα.




*Με καθυστέρηση  $\Delta$  σημείων το σήμα εισόδου  $x(n-\Delta)$  αποσυσχετίζεται από το επιθυμητό σήμα  $d(n)=x(n)$*



Δίνεται το σήμα  $x(n) = \sin(2\pi/50n) + \text{noise}(n)$   
όπου ο θόρυβος  $\text{noise}(n)$  είναι Gaussian μορφής  $\sigma^2 = 1$   
ασυσχέτιστος από το ημιτονικό σήμα.  
 $\Delta = 1$ ,  $\mu = 0.01$  και  $N = 20$ . Εφαρμόζουμε τον LMS αλγόριθμο



(α)



(β)

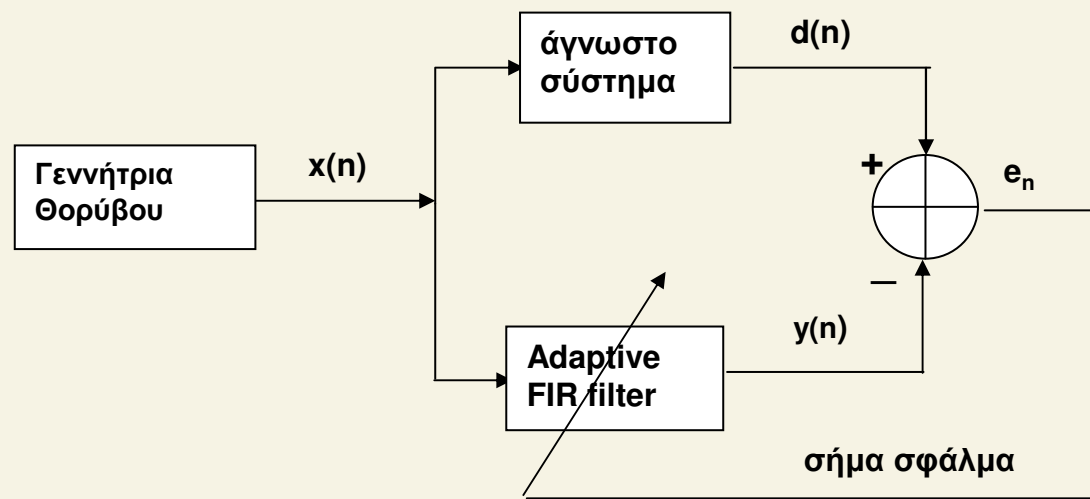
χρόνος

α) Το ημιτονικό σήμα με προσθετικό θόρυβο  $\sigma^2 = 1$ .


β) η βελτιωμένη έξοδος του line enhancer (και το ιδανικό ημίτονο).



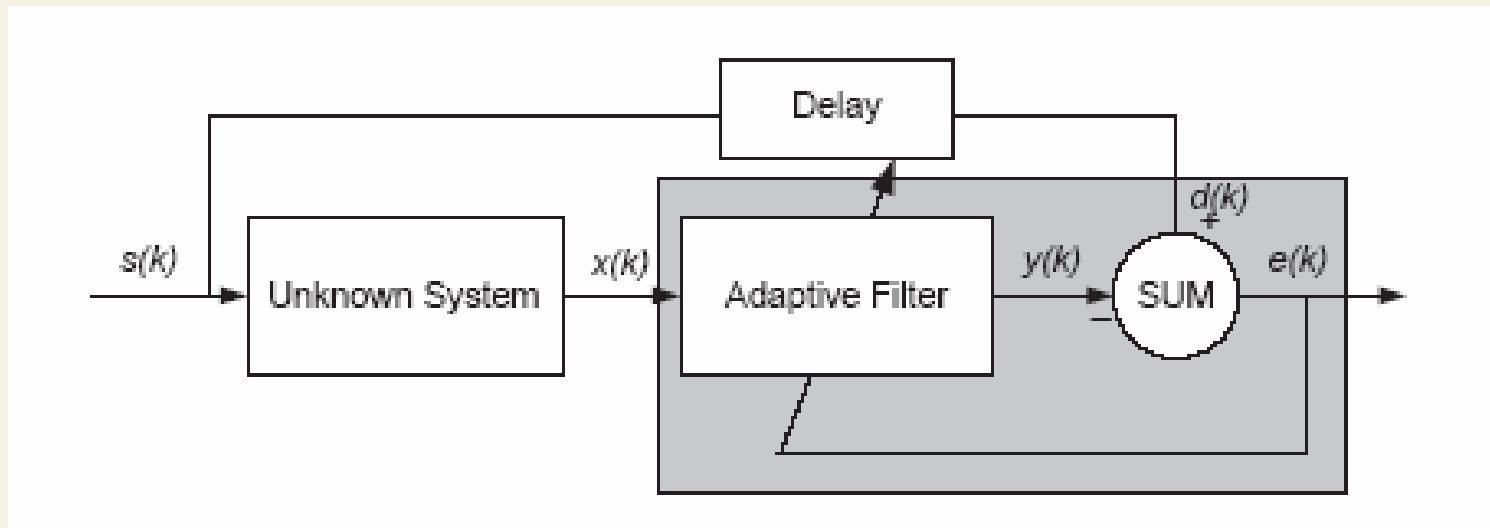
## Εφαρμογή 2 Ταυτοποίηση συστήματος (system identification)




*Βασική δομή ταυτοποίησης προσαρμοζόμενου συστήματος. Το άγνωστο σύστημα θα βρεθεί με το adaptive FIR filter.*

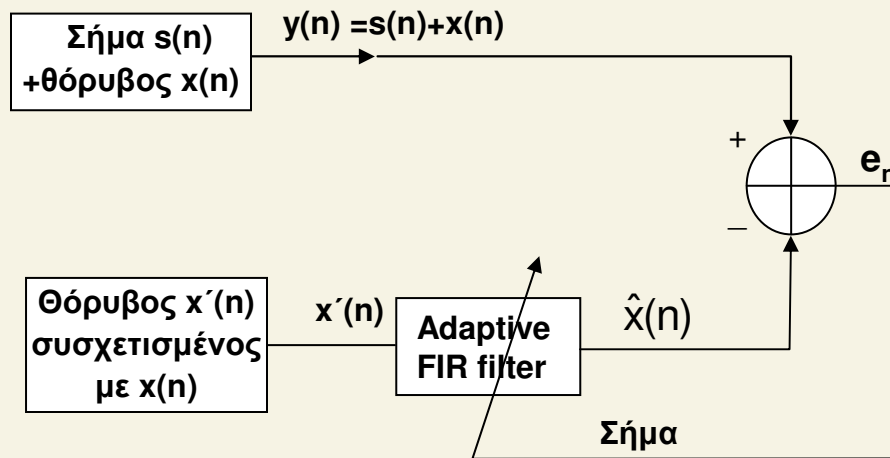


## Εφαρμογή 3 Ταυτοποίηση αντιστρόφου συστήματος (inverse system identification)





## Εφαρμογή 4 Εξάλειψη θορύβου (Adaptive noise canceler)



$$e_n = y(n) - \hat{x}(n) = s(n) + x(n) - \hat{x}(n)$$

$$e_n^2 = s^2(n) + [x(n) - \hat{x}(n)]^2 + 2s(n)[x(n) - \hat{x}(n)]$$

$$E\{e_n^2\} = E\{s^2(n)\} + E\{x(n) - \hat{x}(n)\}^2 + 2E\{s(n)[x(n) - \hat{x}(n)]\}$$

$$E\{e_n^2\} = E\{s^2(n)\} + E\{x(n) - \hat{x}(n)\}^2$$

$$\min E\{e_n^2\} = E\{s^2(n)\} + \min E\{x(n) - \hat{x}(n)\}^2$$

**Εδώ το σήμα-σφάλμα συγκλίνει προς το επιθυμητό σήμα εισόδου !**

# Βιβλιογραφία

1. Hayes, Monson H., *Statistical Digital Signal Processing and Modeling*, John Wiley & Sons, 1996, 493-552.
2. Haykin, Simon, *Adaptive Filter Theory*, Prentice-Hall, Inc., 1996
3. <http://www.spd.eee.strath.ac.uk/~interact/AF/aftutorial/apps/noiseinspeech/noiseinspeech.html>
4. Bernard Widrow and Samuel D. Stearns: *Adaptive Signal Processing*, Prentice-Hall, Inc., Upper Saddle River, NJ, 1985.
5. Steven M. Kay: *Fundamentals of Statistical Signal Processing--Detection Theory*, Volume 2, Prentice-Hall, Inc., 1998
6. V.K. Ingle and J. Proakis, *Digital Signal Processing*, PWS Publishing Company, 1997
7. S. Stearns and R. David, *Signal Processing Algorithms*, Prentice Hall Inc. Englewood Cliffs, New Jersey, 1988
8. Ifeachor E.C & Jervis B.W., *Digital Signal Processing: A practical Approach*, Addison-Wesley, 1993



# Matlab demos and commands

LMS Adaptive Equalization [lmsadeq](#)  
LMS Adaptive Linear Prediction [lmsadlp](#)  
LMS Adaptive Noise Cancellation [lmsdemo](#)  
LMS Adaptive Time-Delay Estimation [lmsadtde](#)  
Nonstationary Channel Estimation [kalmnsce](#)  
RLS Adaptive Noise Cancellation [rlsdemo](#)

[adaptlms](#), [adaptnlms](#),  
[adaptrls](#), [adaptsd](#),  
[adaptse](#), [adaptss](#)

## Εργασίες - ερωτήσεις

1. Θέτωντας κατάλληλο delay υλοποιήστε την εύρεση αντίστροφου συστήματος
2. Βρείτε τους συντελεστές  $h_{opt}$  από την εξίσωση Wiener-Hopf και συγκρίνεται με τους συντελεστές του lms αλγορίθμου.
3. Επαληθεύστε τα όρια τιμών του συντελεστού σύγκλισης  $\mu$
4. Συγκρίνετε τους αλγορίθμους του matlab (adaptlms, adaptsd, adaptse, και adaptss)
5. Υπολογίστε το μέσο τετραγωνικό σφάλμα για ένα αριθμό σημείων 10N και παρακολουθείστε έτσι την σύγκλιση του LMS αλγορίθμου