

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



# شبکه‌های عصبی مصنوعی

درس ۱۰

# یادگیری ویدرو-هاف

## Widrow-Hoff Learning

کاظم فولادی قلعه  
دانشکده مهندسی، پردیس فارابی  
دانشگاه تهران

<http://courses.fouladi.ir/nn>



# Widrow-Hoff Learning

(LMS Algorithm)

## یادگیری ویدرو-هاف

### WIDROW-HOFF LEARNING

الگوریتم یادگیری ویدرو-هاف،  
یک الگوریتم کاهش تندترین شیب تقریبی است  
که در آن، شاخص کارایی، **خطای میانگین مربعات (LMS)** است.

- کاربردهای متعدد آن در پردازش سیگنال (مانند حذف نویز و پژواک)
- پیش‌نمای الگوریتم پس‌انتشار خطا

اهمیت

یادگیری ویدرو-هاف


۱

# شبکه ی آدالاین



Input

Linear Neuron



$$\mathbf{a} = \text{purelin}(\mathbf{W}\mathbf{p} + \mathbf{b}) = \mathbf{W}\mathbf{p} + \mathbf{b}$$

$$\mathbf{a} = \text{purelin}(\mathbf{W}\mathbf{p} + \mathbf{b})$$

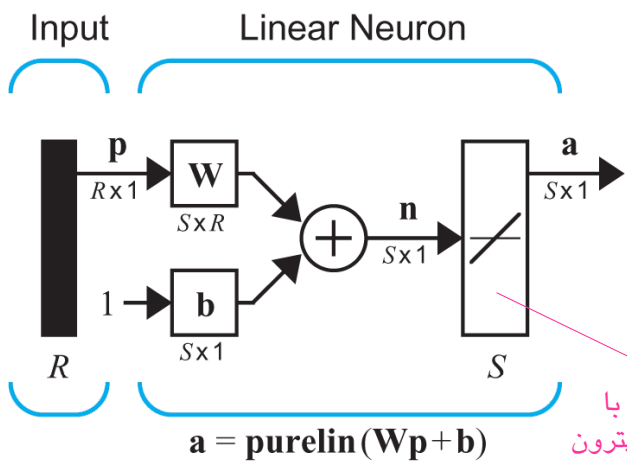
$$a_i = \text{purelin}(n_i) = \text{purelin}(i\mathbf{w}^T \mathbf{p} + b_i) = i\mathbf{w}^T \mathbf{p} + b_i$$

$$i\mathbf{w} = \begin{bmatrix} w_{i,1} \\ w_{i,2} \\ \vdots \\ w_{i,R} \end{bmatrix}$$

# شبکه‌ی آدالاین

## ADALINE NETWORK

شبکه‌ی آدالاین بسیار شبیه پرسپترون است، با این تفاوت که تابع انتقال آن، **خطی** است.



**ADALINE:** ADAPtive LInear NEURon (NETwork) + **LMS:** Least Mean Square (**learning algorithm**)

$$\mathbf{a} = \text{purelin}(\mathbf{W}\mathbf{p} + \mathbf{b}) = \mathbf{W}\mathbf{p} + \mathbf{b}$$

تنها تفاوت با معماری پرسپترون

$$a_i = \text{purelin}(n_i) = \text{purelin}({}_i\mathbf{w}^T \mathbf{p} + b_i) = {}_i\mathbf{w}^T \mathbf{p} + b_i$$

$${}_i\mathbf{w} = \begin{bmatrix} w_{i,1} \\ w_{i,2} \\ \vdots \\ w_{i,R} \end{bmatrix}$$

## شبکه‌ی آدالین

## الگوریتم LMS

ADALINE NETWORK


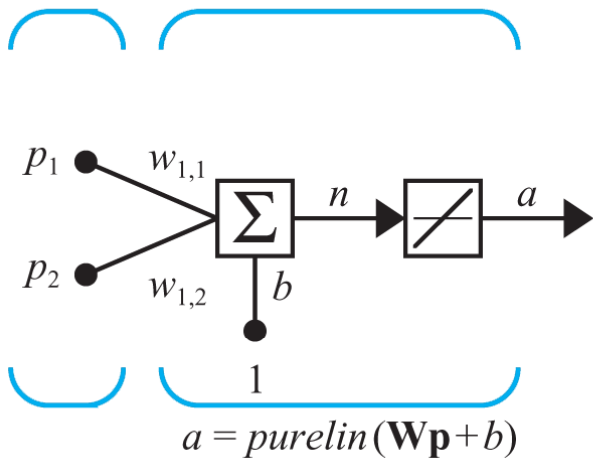
هر دو شبکه‌ی آدالین و پرسپترون محدودیت ذاتی یکسانی دارند: تنها می‌توانند مسائل جداپذیر خطی را حل کنند.

اما الگوریتم LMS قوی‌تر از قاعده‌ی یادگیری پرسپترون است:

- قاعده‌ی یادگیری پرسپترون تضمین همگرایی به راه‌حل برای الگوهای آموزشی دارد، اما شبکه‌ی حاصل می‌تواند به نویز حساس باشد (زیرا الگوها اغلب نزدیک مرز تصمیم قرار می‌گیرند).
- الگوریتم LMS خطای میانگین مربعات را می‌نیمم می‌کند و بنابراین مرزهای تصمیم‌گیری را تا جای ممکن از الگوهای آموزشی دور می‌کند.
- الگوریتم LMS کاربردهای عملی بیشتری نسبت به قاعده‌ی یادگیری پرسپترون پیدا کرده است. (به‌ویژه در پردازش سیگنال دیجیتال (DSP))



Inputs Two-Input Neuron




$$a = \text{purelin}(n) = \text{purelin}({}_1\mathbf{w}^T \mathbf{p} + b) = {}_1\mathbf{w}^T \mathbf{p} + b$$

$$a = {}_1\mathbf{w}^T \mathbf{p} + b = w_{1,1}p_1 + w_{1,2}p_2 + b$$




## آدالین دو-ورودی

## TWO-INPUT ADALINE



تفکیک‌گر خطی درست مانند پرسپترون



$$a = \text{purelin}(n) = \text{purelin}({}_1\mathbf{W}^T \mathbf{p} + b) = {}_1\mathbf{W}^T \mathbf{p} + b$$

$$a = {}_1\mathbf{W}^T \mathbf{p} + b = w_{1,1}p_1 + w_{1,2}p_2 + b$$

مرز تصمیم با  $n = 0$  به دست می‌آید که یک خط است: یک طرف خروجی مثبت و یک طرف خروجی منفی

یادگیری ویدرو-هاف

۲

# خطای میانگین مربعات



Training Set:

$$\{\mathbf{p}_1, \mathbf{t}_1\}, \{\mathbf{p}_2, \mathbf{t}_2\}, \dots, \{\mathbf{p}_Q, \mathbf{t}_Q\}$$

Input:  $\mathbf{p}_q$       Target:  $\mathbf{t}_q$

Notation:

$$\mathbf{x} = \begin{bmatrix} \mathbf{w} \\ 1 \end{bmatrix} \quad \mathbf{z} = \begin{bmatrix} \mathbf{p} \\ 1 \end{bmatrix} \quad a = \mathbf{w}^T \mathbf{p} + b \quad \longrightarrow \quad a = \mathbf{x}^T \mathbf{z}$$

Mean Square Error:

$$F(\mathbf{x}) = E[e^2] = E[(t - a)^2] = E[(t - \mathbf{x}^T \mathbf{z})^2]$$

## خطای میانگین مربعات

MEAN SQUARE ERROR

Training Set:

$$\{\mathbf{p}_1, \mathbf{t}_1\}, \{\mathbf{p}_2, \mathbf{t}_2\}, \dots, \{\mathbf{p}_Q, \mathbf{t}_Q\}$$

Input:  $\mathbf{p}_q$  Target:  $\mathbf{t}_q$ 

Notation:

$$\mathbf{x} = \begin{bmatrix} \mathbf{w} \\ 1 \end{bmatrix} \quad \mathbf{z} = \begin{bmatrix} \mathbf{p} \\ 1 \end{bmatrix} \quad a = \mathbf{w}^T \mathbf{p} + b \quad \longrightarrow \quad a = \mathbf{x}^T \mathbf{z}$$

Mean Square Error:

$$F(\mathbf{x}) = E[e^2] = E[(t - a)^2] = E[(t - \mathbf{x}^T \mathbf{z})^2]$$

↓

امید ریاضی: متوسط زمانی برای سیگنال‌های قطعی



$$F(\mathbf{x}) = E[e^2] = E[(t - a)^2] = E[(t - \mathbf{x}^T \mathbf{z})^2]$$

$$F(\mathbf{x}) = E[t^2 - 2t\mathbf{x}^T \mathbf{z} + \mathbf{x}^T \mathbf{z} \mathbf{z}^T \mathbf{x}]$$

$$F(\mathbf{x}) = E[t^2] - 2\mathbf{x}^T E[t\mathbf{z}] + \mathbf{x}^T E[\mathbf{z} \mathbf{z}^T] \mathbf{x}$$

$$F(\mathbf{x}) = c - 2\mathbf{x}^T \mathbf{h} + \mathbf{x}^T \mathbf{R} \mathbf{x}$$

$$c = E[t^2] \quad \mathbf{h} = E[t\mathbf{z}] \quad \mathbf{R} = E[\mathbf{z} \mathbf{z}^T]$$

*The mean square error for the ADALINE Network is a quadratic function:*

$$F(\mathbf{x}) = c + \mathbf{d}^T \mathbf{x} + \frac{1}{2} \mathbf{x}^T \mathbf{A} \mathbf{x}$$

$$\mathbf{d} = -2\mathbf{h} \quad \mathbf{A} = 2\mathbf{R}$$

## تحلیل خطا

ERROR ANALYSIS

$$F(\mathbf{x}) = E[e^2] = E[(t - a)^2] = E[(t - \mathbf{x}^T \mathbf{z})^2]$$

$$F(\mathbf{x}) = E[t^2 - 2t\mathbf{x}^T \mathbf{z} + \mathbf{x}^T \mathbf{z} \mathbf{z}^T \mathbf{x}]$$

$$F(\mathbf{x}) = E[t^2] - 2\mathbf{x}^T E[t\mathbf{z}] + \mathbf{x}^T E[\mathbf{z} \mathbf{z}^T] \mathbf{x}$$

$$F(\mathbf{x}) = c - 2\mathbf{x}^T \mathbf{h} + \mathbf{x}^T \mathbf{R} \mathbf{x}$$

$$c = E[t^2] \quad \mathbf{h} = E[t\mathbf{z}] \quad \mathbf{R} = E[\mathbf{z} \mathbf{z}^T]$$

همبستگی متقابل میان بردار ورودی و تارگت مربوطه ✓

ماتریس همبستگی ورودی‌ها ↘

*The mean square error for the ADALINE Network is a quadratic function:*

$$F(\mathbf{x}) = c + \mathbf{d}^T \mathbf{x} + \frac{1}{2} \mathbf{x}^T \mathbf{A} \mathbf{x}$$

$$\mathbf{d} = -2\mathbf{h} \quad \mathbf{A} = 2\mathbf{R}$$



Hessian Matrix:

$$\mathbf{A} = 2\mathbf{R}$$

The correlation matrix  $\mathbf{R}$  must be at least positive semidefinite. If there are any zero eigenvalues, the performance index will either have a weak minimum or else no stationary point, otherwise there will be a unique global minimum  $\mathbf{x}^*$ .

$$\nabla F(\mathbf{x}) = \nabla \left( c + \mathbf{d}^T \mathbf{x} + \frac{1}{2} \mathbf{x}^T \mathbf{A} \mathbf{x} \right) = \mathbf{d} + \mathbf{A} \mathbf{x} = -2\mathbf{h} + 2\mathbf{R} \mathbf{x}$$

$$-2\mathbf{h} + 2\mathbf{R} \mathbf{x} = \mathbf{0}$$

If  $\mathbf{R}$  is positive definite:

$$\mathbf{x}^* = \mathbf{R}^{-1} \mathbf{h}$$

## نقطه‌ی ایستادن

STATIONARY POINT

Hessian Matrix:

$$\mathbf{A} = 2\mathbf{R}$$

The correlation matrix  $\mathbf{R}$  must be at least positive semidefinite. If there are any zero eigenvalues, the performance index will either have a weak minimum or else no stationary point, otherwise there will be a unique global minimum  $\mathbf{x}^*$ .

$$\nabla F(\mathbf{x}) = \nabla \left( c + \mathbf{d}^T \mathbf{x} + \frac{1}{2} \mathbf{x}^T \mathbf{A} \mathbf{x} \right) = \mathbf{d} + \mathbf{A} \mathbf{x} = -2\mathbf{h} + 2\mathbf{R} \mathbf{x}$$

$$-2\mathbf{h} + 2\mathbf{R} \mathbf{x} = \mathbf{0}$$

If  $\mathbf{R}$  is positive definite:

اگر  $\mathbf{A} > 0$  باشد، این نقطه می‌نیم سراسری است.  $\mathbf{x}^* = \mathbf{R}^{-1} \mathbf{h}$

\* اگر نخواهیم  $\mathbf{R}^{-1}$  را محاسبه کنیم، می‌توانیم از الگوریتم کاهش تندترین شیب استفاده کنیم.





Approximate mean square error (one sample):

$$\hat{F}(\mathbf{x}) = (t(k) - a(k))^2 = e^2(k)$$

Approximate (stochastic) gradient:

$$\hat{\nabla}F(\mathbf{x}) = \nabla e^2(k)$$

$$[\nabla e^2(k)]_j = \frac{\partial e^2(k)}{\partial w_{1,j}} = 2e(k) \frac{\partial e(k)}{\partial w_{1,j}} \quad j = 1, 2, \dots, R$$

$$[\nabla e^2(k)]_{R+1} = \frac{\partial e^2(k)}{\partial b} = 2e(k) \frac{\partial e(k)}{\partial b}$$

## کاهش تندترین شیب تقریبی

APPROXIMATE STEEPEST DESCENT

خطای میانگین مربعات را با خطا روی یک نمونه تقریب می‌زنیم. ( $E$  برداشته می‌شود).

Approximate mean square error (one sample):

$$\hat{F}(\mathbf{x}) = (t(k) - a(k))^2 = e^2(k)$$

Approximate (stochastic) gradient:

$$\hat{\nabla}F(\mathbf{x}) = \nabla e^2(k) \quad \text{گرادین تقریبی (تصادفی):}$$

$$\text{مربوط به وزن‌ها:} \quad [\nabla e^2(k)]_j = \frac{\partial e^2(k)}{\partial w_{1,j}} = 2e(k) \frac{\partial e(k)}{\partial w_{1,j}} \quad j = 1, 2, \dots, R$$

$$\text{مربوط به بایاس:} \quad [\nabla e^2(k)]_{R+1} = \frac{\partial e^2(k)}{\partial b} = 2e(k) \frac{\partial e(k)}{\partial b}$$

\* یادگیری برخط (online) / افزایشی (incremental) ← با استفاده از گرادینان تقریبی



$$\frac{\partial e(k)}{\partial w_{1,j}} = \frac{\partial [t(k) - a(k)]}{\partial w_{1,j}} = \frac{\partial}{\partial w_{1,j}} [t(k) - (\mathbf{w}_1^T \mathbf{p}(k) + b)]$$

$$\frac{\partial e(k)}{\partial w_{1,j}} = \frac{\partial}{\partial w_{1,j}} \left[ t(k) - \left( \sum_{i=1}^R w_{1,i} p_i(k) + b \right) \right]$$

$$\frac{\partial e(k)}{\partial w_{1,j}} = -p_j(k) \qquad \frac{\partial e(k)}{\partial b} = -1$$

$$\hat{\nabla} F(\mathbf{x}) = \nabla e^2(k) = -2e(k)\mathbf{z}(k)$$

## محاسبه‌ی گرادیان تقریبی

APPROXIMATE GRADIENT CALCULATION

محاسبه‌ی مشتقات جزئی:

$$\frac{\partial e(k)}{\partial w_{1,j}} = \frac{\partial [t(k) - a(k)]}{\partial w_{1,j}} = \frac{\partial}{\partial w_{1,j}} [t(k) - (\mathbf{w}_1^T \mathbf{p}(k) + b)]$$

$$\frac{\partial e(k)}{\partial w_{1,j}} = \frac{\partial}{\partial w_{1,j}} \left[ t(k) - \left( \sum_{i=1}^R w_{1,i} p_i(k) + b \right) \right]$$

$$\frac{\partial e(k)}{\partial w_{1,j}} = -p_j(k)$$

$$\frac{\partial e(k)}{\partial b} = -1$$

فقط در یک جمله غیر صفر می‌شود.

$$\hat{\nabla} F(\mathbf{x}) = \nabla e^2(k) = -2e(k)\mathbf{z}(k)$$

تنها لازم است خطا را در ورودی ضرب کنیم (و ضرب در -2)


$$\mathbf{z}(k) = \begin{bmatrix} p_1(k) \\ p_2(k) \\ \vdots \\ p_R(k) \\ 1 \end{bmatrix}$$

یادگیری ویدرو-هاف

۳

الگوریتم  
LMS

# LMS Algorithm



$$\mathbf{x}_{k+1} = \mathbf{x}_k - \alpha \nabla F(\mathbf{x}) \Big|_{\mathbf{x} = \mathbf{x}_k}$$

$$\mathbf{x}_{k+1} = \mathbf{x}_k + 2\alpha e(k) \mathbf{z}(k)$$

$${}_1\mathbf{w}(k+1) = {}_1\mathbf{w}(k) + 2\alpha e(k) \mathbf{p}(k)$$

$$b(k+1) = b(k) + 2\alpha e(k)$$

## الگوریتم LMS

### LMS ALGORITHM

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \alpha \nabla F(\mathbf{x}) \Big|_{\mathbf{x} = \mathbf{x}_k}$$



$$\mathbf{x}_{k+1} = \mathbf{x}_k + 2\alpha e(k) \mathbf{z}(k)$$



$${}_1\mathbf{w}(k+1) = {}_1\mathbf{w}(k) + 2\alpha e(k) \mathbf{p}(k)$$

$$b(k+1) = b(k) + 2\alpha e(k)$$

الگوریتم LMS

قاعده‌ی ویدرو-هاف

قاعده‌ی دلتا



$${}_i\mathbf{w}(k+1) = {}_i\mathbf{w}(k) + 2\alpha e_i(k)\mathbf{p}(k)$$

$$b_i(k+1) = b_i(k) + 2\alpha e_i(k)$$

Matrix Form:

$$\mathbf{W}(k+1) = \mathbf{W}(k) + 2\alpha \mathbf{e}(k)\mathbf{p}^T(k)$$

$$\mathbf{b}(k+1) = \mathbf{b}(k) + 2\alpha \mathbf{e}(k)$$



## الگوریتم LMS

در حالت چند نرونی (چند خروجی)

### MULTIPLE-NEURON CASE

سطر  $i$ ام ماتریس  $\mathbf{W}$  
$${}_i\mathbf{w}(k+1) = {}_i\mathbf{w}(k) + 2\alpha e_i(k)\mathbf{p}(k)$$

$$b_i(k+1) = b_i(k) + 2\alpha e_i(k)$$

Matrix Form:

$$\mathbf{W}(k+1) = \mathbf{W}(k) + 2\alpha \mathbf{e}(k)\mathbf{p}^T(k)$$

$$\mathbf{b}(k+1) = \mathbf{b}(k) + 2\alpha \mathbf{e}(k)$$

یادگیری ویدرو-هاف

۴

# تحلیل همگرایی

## تحلیل همگرایی الگوریتم LMS

ANALYSIS OF CONVERGENCE

$$\mathbf{x}_{k+1} = \mathbf{x}_k + 2\alpha e(k)\mathbf{z}(k)$$

$\mathbf{x}_k$  فقط تابعی است از

$$\mathbf{z}(k-1), \mathbf{z}(k-2), \dots, \mathbf{z}(0)$$

با فرض مستقل آماری بودن بردارهای ورودی متوالی،  
 $\mathbf{x}_k$  مستقل از  $\mathbf{z}(k)$  می‌شود.

اثبات می‌کنیم که

برای فرآیندهای ورودی ایستان که شرایط فوق را برآورده کند،  
 مقدار مورد انتظار (امید ریاضی) بردار وزن همگرا می‌شود به:

$$\mathbf{x}^* = \mathbf{R}^{-1}\mathbf{h}$$



$$\mathbf{x}_{k+1} = \mathbf{x}_k + 2\alpha e(k)\mathbf{z}(k)$$

$$E[\mathbf{x}_{k+1}] = E[\mathbf{x}_k] + 2\alpha E[e(k)\mathbf{z}(k)]$$

$$E[\mathbf{x}_{k+1}] = E[\mathbf{x}_k] + 2\alpha \{E[t(k)\mathbf{z}(k)] - E[(\mathbf{x}_k^T \mathbf{z}(k))\mathbf{z}(k)]\}$$

$$E[\mathbf{x}_{k+1}] = E[\mathbf{x}_k] + 2\alpha \{E[t_k \mathbf{z}(k)] - E[(\mathbf{z}(k)\mathbf{z}^T(k))\mathbf{x}_k]\}$$

$$E[\mathbf{x}_{k+1}] = E[\mathbf{x}_k] + 2\alpha \{\mathbf{h} - \mathbf{R}E[\mathbf{x}_k]\}$$

$$E[\mathbf{x}_{k+1}] = \underbrace{[\mathbf{I} - 2\alpha\mathbf{R}]}_{\text{For stability, the eigenvalues of this matrix must fall inside the unit circle.}} E[\mathbf{x}_k] + 2\alpha\mathbf{h}$$

For stability, the eigenvalues of this matrix must fall inside the unit circle.

## تحلیل همگرایی الگوریتم LMS

ANALYSIS OF CONVERGENCE

$$\mathbf{x}_{k+1} = \mathbf{x}_k + 2\alpha e(k)\mathbf{z}(k) \quad \text{از LMS داریم:}$$

$$E[\mathbf{x}_{k+1}] = E[\mathbf{x}_k] + 2\alpha E[e(k)\mathbf{z}(k)] \quad \text{از طرفین امید ریاضی می‌گیریم:}$$

$$e(k) = t(k) - \mathbf{x}_k^T \mathbf{z}(k)$$

$$E[\mathbf{x}_{k+1}] = E[\mathbf{x}_k] + 2\alpha \{E[t(k)\mathbf{z}(k)] - E[(\mathbf{x}_k^T \mathbf{z}(k))\mathbf{z}(k)]\}$$

$\mathbf{z}^T(k)\mathbf{x}_k$  را به جای  $\mathbf{x}_k^T \mathbf{z}(k)$  جایگزین می‌کنیم:

$$E[\mathbf{x}_{k+1}] = E[\mathbf{x}_k] + 2\alpha \{E[t_k \mathbf{z}(k)] - E[(\mathbf{z}(k)\mathbf{z}^T(k))\mathbf{x}_k]\}$$


چون  $\mathbf{x}_k$  مستقل از  $\mathbf{z}(k)$  است، داریم:

$$E[\mathbf{x}_{k+1}] = E[\mathbf{x}_k] + 2\alpha \{\mathbf{h} - \mathbf{R}E[\mathbf{x}_k]\}$$

$$E[\mathbf{x}_{k+1}] = [\mathbf{I} - 2\alpha \mathbf{R}]E[\mathbf{x}_k] + 2\alpha \mathbf{h}$$

شرط پایداری سیستم دینامیکی خطی مرتبه اول:  
مقادیر ویژه باید داخل دایره‌ی واحد باشند.

For stability, the eigenvalues of this matrix must fall inside the unit circle.



$$|eig([\mathbf{I} - 2\alpha\mathbf{R}])| = |1 - 2\alpha\lambda_i| < 1$$

(where  $\lambda_i$  is an eigenvalue of  $\mathbf{R}$ )

Since  $\lambda_i > 0$ ,  $1 - 2\alpha\lambda_i < 1$  .

Therefore the stability condition simplifies to

$$1 - 2\alpha\lambda_i > -1$$

$$\alpha < 1/\lambda_i \quad \text{for all } i$$

$$0 < \alpha < 1/\lambda_{max}$$

## تحلیل همگرایی الگوریتم LMS

شرایط پایداری

CONDITIONS FOR STABILITY

$$|eig([\mathbf{I} - 2\alpha\mathbf{R}])| = |1 - 2\alpha\lambda_i| < 1$$

(where  $\lambda_i$  is an eigenvalue of  $\mathbf{R}$ )Since  $\lambda_i > 0$ ,  $1 - 2\alpha\lambda_i < 1$  .

Therefore the stability condition simplifies to

$$1 - 2\alpha\lambda_i > -1$$

$$\alpha < 1/\lambda_i \quad \text{for all } i$$

$$0 < \alpha < 1/\lambda_{max}$$



$$E[\mathbf{x}_{k+1}] = [\mathbf{I} - 2\alpha\mathbf{R}]E[\mathbf{x}_k] + 2\alpha\mathbf{h}$$

If the system is stable, then a steady state condition will be reached.

$$E[\mathbf{x}_{ss}] = [\mathbf{I} - 2\alpha\mathbf{R}]E[\mathbf{x}_{ss}] + 2\alpha\mathbf{h}$$

The solution to this equation is

$$E[\mathbf{x}_{ss}] = \mathbf{R}^{-1}\mathbf{h} = \mathbf{x}^*$$

This is also the strong minimum of the performance index.



## پاسخ حالت ماندگار

STEADY STATE RESPONSE

$$E[\mathbf{x}_{k+1}] = [\mathbf{I} - 2\alpha\mathbf{R}]E[\mathbf{x}_k] + 2\alpha\mathbf{h}$$

If the system is stable, then a steady state condition will be reached.

$$E[\mathbf{x}_{s,s}] = [\mathbf{I} - 2\alpha\mathbf{R}]E[\mathbf{x}_{s,s}] + 2\alpha\mathbf{h} \quad \text{در حالت ماندگار (دائمی):}$$

The solution to this equation is

$$E[\mathbf{x}_{s,s}] = \mathbf{R}^{-1}\mathbf{h} = \mathbf{x}^*$$

This is also the strong minimum of the performance index.

نقطه‌ی می‌نیمم سراسری شاخص کارایی



$$\text{Banana} \left\{ \mathbf{p}_1 = \begin{bmatrix} -1 \\ 1 \\ -1 \end{bmatrix}, \mathbf{t}_1 = [-1] \right\} \quad \text{Apple} \left\{ \mathbf{p}_2 = \begin{bmatrix} 1 \\ 1 \\ -1 \end{bmatrix}, \mathbf{t}_2 = [1] \right\}$$

$$\mathbf{R} = E[\mathbf{p}\mathbf{p}^T] = \frac{1}{2}\mathbf{p}_1\mathbf{p}_1^T + \frac{1}{2}\mathbf{p}_2\mathbf{p}_2^T$$

$$\mathbf{R} = \frac{1}{2} \begin{bmatrix} -1 \\ 1 \\ -1 \end{bmatrix} \begin{bmatrix} -1 & 1 & -1 \end{bmatrix} + \frac{1}{2} \begin{bmatrix} 1 \\ 1 \\ -1 \end{bmatrix} \begin{bmatrix} 1 & 1 & -1 \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & -1 \\ 0 & -1 & 1 \end{bmatrix}$$

$$\lambda_1 = 1.0, \quad \lambda_2 = 0.0, \quad \lambda_3 = 2.0$$

$$\alpha < \frac{1}{\lambda_{max}} = \frac{1}{2.0} = 0.5$$

## الگوریتم LMS

مثال (۱ از ۴)

## EXAMPLE

$$\text{Banana} \left\{ \mathbf{p}_1 = \begin{bmatrix} -1 \\ 1 \\ -1 \end{bmatrix}, \mathbf{t}_1 = [-1] \right\} \quad \text{Apple} \left\{ \mathbf{p}_2 = \begin{bmatrix} 1 \\ 1 \\ -1 \end{bmatrix}, \mathbf{t}_2 = [1] \right\}$$

$$\mathbf{R} = E[\mathbf{p}\mathbf{p}^T] = \frac{1}{2}\mathbf{p}_1\mathbf{p}_1^T + \frac{1}{2}\mathbf{p}_2\mathbf{p}_2^T$$

$$\mathbf{R} = \frac{1}{2} \begin{bmatrix} -1 \\ 1 \\ -1 \end{bmatrix} \begin{bmatrix} -1 & 1 & -1 \end{bmatrix} + \frac{1}{2} \begin{bmatrix} 1 \\ 1 \\ -1 \end{bmatrix} \begin{bmatrix} 1 & 1 & -1 \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & -1 \\ 0 & -1 & 1 \end{bmatrix}$$

$$\lambda_1 = 1.0, \quad \lambda_2 = 0.0, \quad \lambda_3 = 2.0$$

ابتدا محاسبه‌ی نرخ یادگیری پایدار  $\alpha$ 

$$\alpha < \frac{1}{\lambda_{max}} = \frac{1}{2.0} = 0.5$$

در کاربردهای واقعی ممکن است نتوانیم  $\mathbf{R}$  را محاسبه کنیم و  $\alpha$  باید با سعی و خطا انتخاب شود.



Banana  $a(0) = \mathbf{W}(0)\mathbf{p}(0) = \mathbf{W}(0)\mathbf{p}_1 = \begin{bmatrix} 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} -1 \\ 1 \\ -1 \end{bmatrix} = 0$

$$e(0) = t(0) - a(0) = t_1 - a(0) = -1 - 0 = -1$$

$$\mathbf{W}(1) = \mathbf{W}(0) + 2\alpha e(0)\mathbf{p}^T(0)$$

$$\mathbf{W}(1) = \begin{bmatrix} 0 & 0 & 0 \end{bmatrix} + 2(0.2)(-1) \begin{bmatrix} -1 \\ 1 \\ -1 \end{bmatrix}^T = \begin{bmatrix} 0.4 & -0.4 & 0.4 \end{bmatrix}$$

## الگوریتم LMS

مثال (۲ از ۴)


EXAMPLE

$$\text{Banana} \quad a(0) = \mathbf{W}(0)\mathbf{p}(0) = \mathbf{W}(0)\mathbf{p}_1 = \begin{bmatrix} 0 & 0 & 0 \end{bmatrix} \begin{bmatrix} -1 \\ 1 \\ -1 \end{bmatrix} = 0$$

$$e(0) = t(0) - a(0) = t_1 - a(0) = -1 - 0 = -1$$

$$\mathbf{W}(1) = \mathbf{W}(0) + 2\alpha e(0)\mathbf{p}^T(0)$$

$$\mathbf{W}(1) = \begin{bmatrix} 0 & 0 & 0 \end{bmatrix} + 2(0.2)(-1) \begin{bmatrix} -1 \\ 1 \\ -1 \end{bmatrix}^T = \begin{bmatrix} 0.4 & -0.4 & 0.4 \end{bmatrix}$$



Apple  $a(1) = \mathbf{W}(1)\mathbf{p}(1) = \mathbf{W}(1)\mathbf{p}_2 = \begin{bmatrix} 0.4 & -0.4 & 0.4 \end{bmatrix} \begin{bmatrix} 1 \\ 1 \\ -1 \end{bmatrix} = -0.4$

$$e(1) = t(1) - a(1) = t_2 - a(1) = 1 - (-0.4) = 1.4$$

$$\mathbf{W}(2) = \begin{bmatrix} 0.4 & -0.4 & 0.4 \end{bmatrix} + 2(0.2)(1.4) \begin{bmatrix} 1 \\ 1 \\ -1 \end{bmatrix}^T = \begin{bmatrix} 0.96 & 0.16 & -0.16 \end{bmatrix}$$

## الگوریتم LMS

مثال (۳ از ۴)

EXAMPLE

$$\text{Apple} \quad a(1) = \mathbf{W}(1)\mathbf{p}(1) = \mathbf{W}(1)\mathbf{p}_2 = \begin{bmatrix} 0.4 & -0.4 & 0.4 \end{bmatrix} \begin{bmatrix} 1 \\ 1 \\ -1 \end{bmatrix} = -0.4$$

$$e(1) = t(1) - a(1) = t_2 - a(1) = 1 - (-0.4) = 1.4$$

$$\mathbf{W}(2) = \begin{bmatrix} 0.4 & -0.4 & 0.4 \end{bmatrix} + 2(0.2)(1.4) \begin{bmatrix} 1 \\ 1 \\ -1 \end{bmatrix}^T = \begin{bmatrix} 0.96 & 0.16 & -0.16 \end{bmatrix}$$



$$a(2) = \mathbf{W}(2)\mathbf{p}(2) = \mathbf{W}(2)\mathbf{p}_1 = \begin{bmatrix} 0.96 & 0.16 & -0.16 \end{bmatrix} \begin{bmatrix} -1 \\ 1 \\ -1 \end{bmatrix} = -0.64$$

$$e(2) = t(2) - a(2) = t_1 - a(2) = -1 - (-0.64) = -0.36$$

$$\mathbf{W}(3) = \mathbf{W}(2) + 2\alpha e(2)\mathbf{p}^T(2) = \begin{bmatrix} 1.1040 & 0.0160 & -0.0160 \end{bmatrix}$$

$$\mathbf{W}(\infty) = \begin{bmatrix} 1 & 0 & 0 \end{bmatrix}$$



## الگوریتم LMS

مثال (۴ از ۴)

EXAMPLE

$$a(2) = \mathbf{W}(2)\mathbf{p}(2) = \mathbf{W}(2)\mathbf{p}_1 = \begin{bmatrix} 0.96 & 0.16 & -0.16 \end{bmatrix} \begin{bmatrix} -1 \\ 1 \\ -1 \end{bmatrix} = -0.64$$

$$e(2) = t(2) - a(2) = t_1 - a(2) = -1 - (-0.64) = -0.36$$

$$\mathbf{W}(3) = \mathbf{W}(2) + 2\alpha e(2)\mathbf{p}^T(2) = \begin{bmatrix} 1.1040 & 0.0160 & -0.0160 \end{bmatrix}$$

$$\mathbf{W}(\infty) = \begin{bmatrix} 1 & 0 & 0 \end{bmatrix}$$

مرز تصمیم پیدا شده با روش LMS بهتر از پرسپترون است (فاصله‌ی بیشتر مرز از الگوها).

یادگیری ویدرو-هاف

۵

فیلتر کردن  
و فقی

## فیلتر کردن وفقی


### ADAPTIVE FILTERING

یکی از کاربردهای گسترده‌ی آدالاین: فیلترهای وفقی


ترکیب خط شنود تأخیری با شبکه‌ی آدالاین، یک فیلتر وفقی ایجاد می‌کند.



Tapped Delay Line



Adaptive Filter




$$a(k) = \text{purelin}(\mathbf{W}\mathbf{p} + b) = \sum_{i=1}^R w_{1,i}y(k-i+1) + b$$

## فیلتر کردن افقی

### ADAPTIVE FILTERING

خط شنود تأخیری


Tapped Delay Line



خط شنود تأخیری با  $R$  خروجی  
(ورودی جاری و  $R-1$  ورودی قبلی)

فیلتر افقی

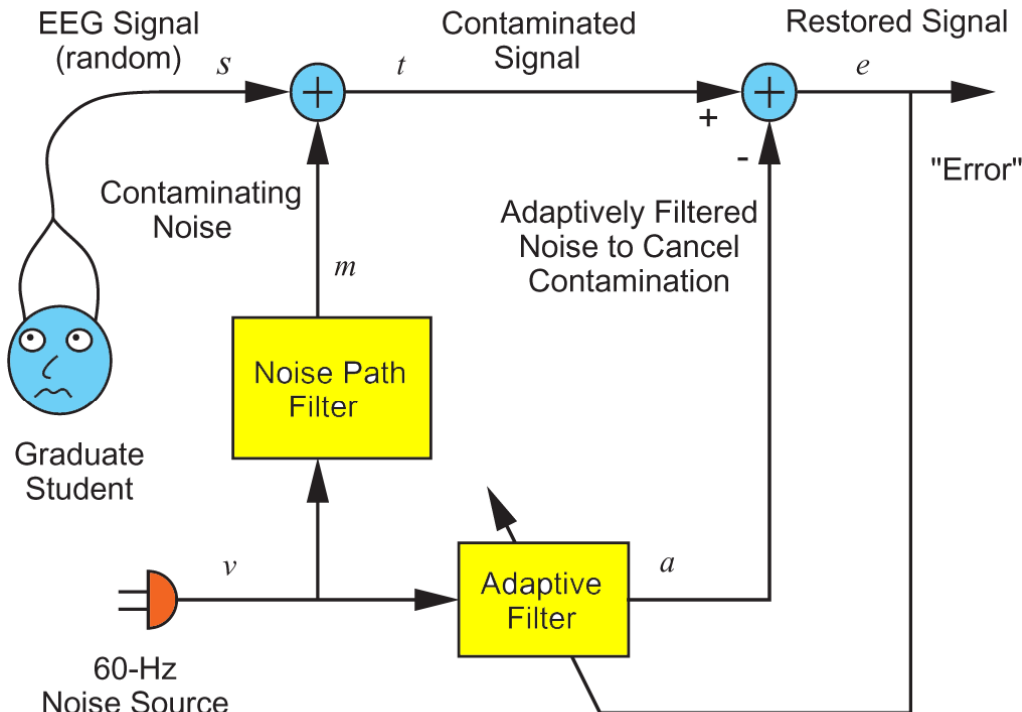

Adaptive Filter



$$a(k) = \text{purelin}(\mathbf{W}\mathbf{p} + b) = \sum_{i=1}^R w_{1,i} y(k-i+1) + b$$

این یک فیلتر FIR است (پاسخ ضربه‌ی متناهی: Finite Impulse Response).

# Example: Noise Cancellation

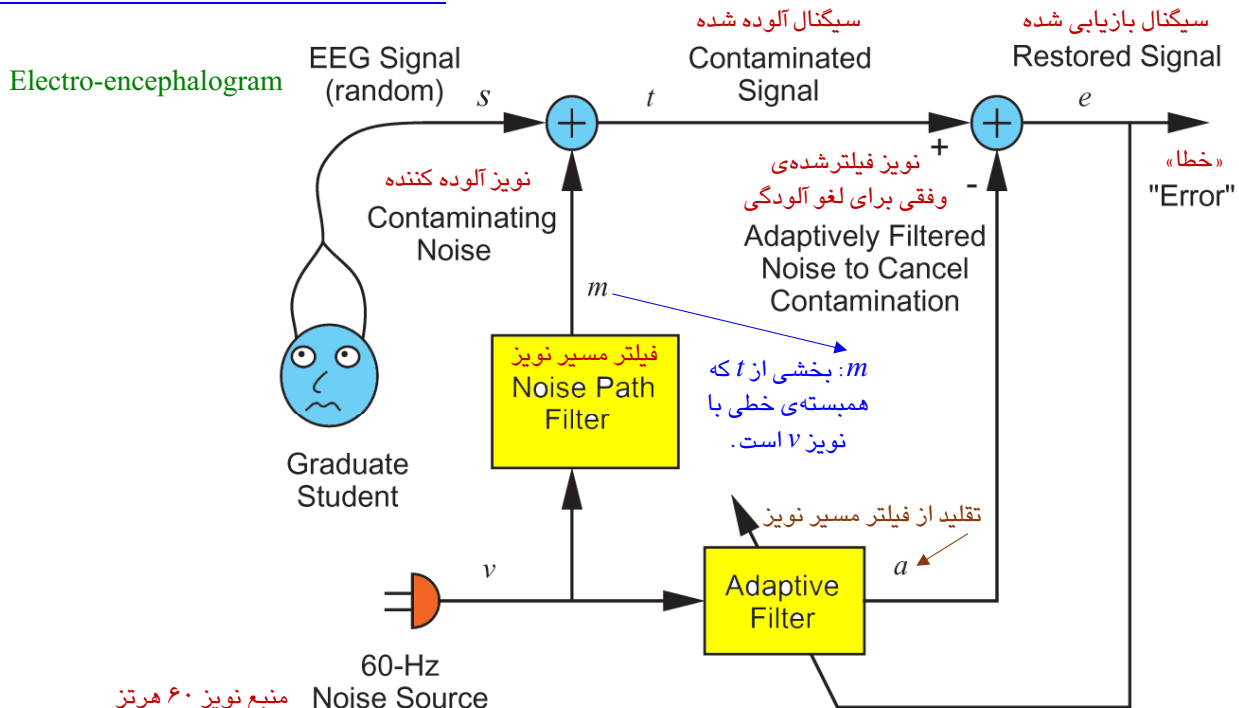


Adaptive Filter Adjusts to Minimize Error (and in doing this removes 60-Hz noise from contaminated signal)

## فیلتر کردن وفقی

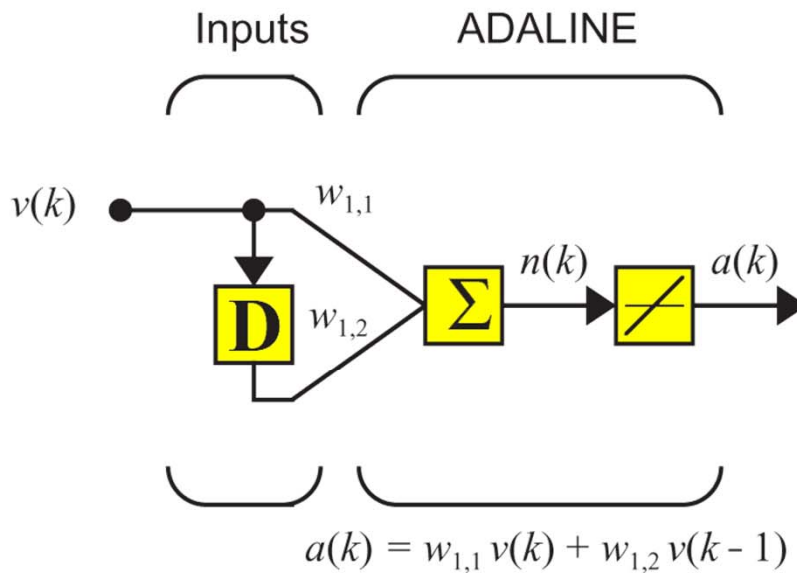
مثال: لغو نویز وفقی

## EXAMPLE: NOISE CANCELLATION



Adaptive Filter Adjusts to Minimize Error (and in doing this removes 60-Hz noise from contaminated signal)

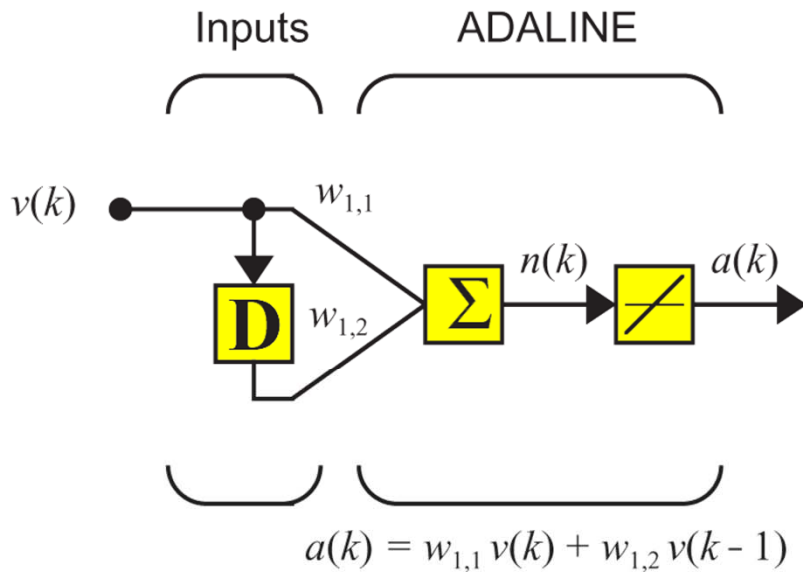
فیلتر وفقی تنظیم کننده برای می‌نیمم‌سازی خطا (که انجام آن نویز ۶۰ هرتز را از سیگنال آلوده شده حذف می‌کند.)





## فیلتر کردن افقی

فیلتر افقی رفع نویز

NOISE CANCELLATION ADAPTIVE FILTER



$$\mathbf{R} = [\mathbf{z}\mathbf{z}^T] \quad \mathbf{h} = E[t\mathbf{z}]$$

$$\mathbf{z}(k) = \begin{bmatrix} v(k) \\ v(k-1) \end{bmatrix}$$

$$t(k) = s(k) + m(k)$$

$$\mathbf{R} = \begin{bmatrix} E[v^2(k)] & E[v(k)v(k-1)] \\ E[v(k-1)v(k)] & E[v^2(k-1)] \end{bmatrix}$$

$$\mathbf{h} = \begin{bmatrix} E[(s(k) + m(k))v(k)] \\ E[(s(k) + m(k))v(k-1)] \end{bmatrix}$$

## فیلتر کردن افقی

ماتریس همبستگی

CORRELATION MATRIX

$$\mathbf{R} = [\mathbf{z}\mathbf{z}^T] \quad \mathbf{h} = E[t\mathbf{z}]$$

$$\mathbf{z}(k) = \begin{bmatrix} v(k) \\ v(k-1) \end{bmatrix}$$

$$t(k) = s(k) + m(k)$$

$$\mathbf{R} = \begin{bmatrix} E[v^2(k)] & E[v(k)v(k-1)] \\ E[v(k-1)v(k)] & E[v^2(k-1)] \end{bmatrix}$$

$$\mathbf{h} = \begin{bmatrix} E[(s(k) + m(k))v(k)] \\ E[(s(k) + m(k))v(k-1)] \end{bmatrix}$$



$$v(k) = 1.2 \sin\left(\frac{2\pi k}{3}\right) \quad m(k) = 1.2 \sin\left(\frac{2\pi k}{3} - \frac{3\pi}{4}\right)$$

$$E[v^2(k)] = (1.2)^2 \frac{1}{3} \sum_{k=1}^3 \left( \sin\left(\frac{2\pi k}{3}\right) \right)^2 = (1.2)^2 0.5 = 0.72$$

$$E[v^2(k-1)] = E[v^2(k)] = 0.72$$

$$\begin{aligned} E[v(k)v(k-1)] &= \frac{1}{3} \sum_{k=1}^3 \left( 1.2 \sin\frac{2\pi k}{3} \right) \left( 1.2 \sin\frac{2\pi(k-1)}{3} \right) \\ &= (1.2)^2 0.5 \cos\left(\frac{2\pi}{3}\right) = -0.36 \end{aligned}$$

$$\mathbf{R} = \begin{bmatrix} 0.72 & -0.36 \\ -0.36 & 0.72 \end{bmatrix}$$

## فیلتر کردن افقی

## سیگنال‌ها

SIGNALS

فرض: سیگنال EEG سیگنال تصادفی سفید (یعنی: هر لحظه با لحظه‌ی بعدی ناهمبسته است) توزیع یکنواخت  $0.2 \dots -0.2$ ، سینوسی  $60$  هرتز نمونه‌برداری شده  $180$  هرتز

$$\text{منبع نویز سینوسی} \quad v(k) = 1.2 \sin\left(\frac{2\pi k}{3}\right) \quad m(k) = 1.2 \sin\left(\frac{2\pi k}{3} - \frac{3\pi}{4}\right)$$

$$E[v^2(k)] = (1.2)^2 \frac{1}{3} \sum_{k=1}^3 \left( \sin\left(\frac{2\pi k}{3}\right) \right)^2 = (1.2)^2 0.5 = 0.72$$

$k = 1, 2, 3$  به دلیل تناوب سینوسی

$$E[v^2(k-1)] = E[v^2(k)] = 0.72$$

$$\begin{aligned} E[v(k)v(k-1)] &= \frac{1}{3} \sum_{k=1}^3 \left( 1.2 \sin\frac{2\pi k}{3} \right) \left( 1.2 \sin\frac{2\pi(k-1)}{3} \right) \\ &= (1.2)^2 0.5 \cos\left(\frac{2\pi}{3}\right) = -0.36 \end{aligned}$$

$$\mathbf{R} = \begin{bmatrix} 0.72 & -0.36 \\ -0.36 & 0.72 \end{bmatrix}$$

# Stationary Point




$$E[(s(k) + m(k))v(k)] = E[s(k)v(k)] + E[m(k)v(k)]$$

  
 0

$$E[m(k)v(k)] = \frac{1}{3} \sum_{k=1}^3 \left( 1.2 \sin\left(\frac{2\pi k}{3} - \frac{3\pi}{4}\right) \right) \left( 1.2 \sin\frac{2\pi k}{3} \right) = -0.51$$

$$E[(s(k) + m(k))v(k-1)] = E[s(k)v(k-1)] + E[m(k)v(k-1)]$$

  
 0

$$E[m(k)v(k-1)] = \frac{1}{3} \sum_{k=1}^3 \left( 1.2 \sin\left(\frac{2\pi k}{3} - \frac{3\pi}{4}\right) \right) \left( 1.2 \sin\frac{2\pi(k-1)}{3} \right) = 0.70$$

$$\mathbf{h} = \begin{bmatrix} E[(s(k) + m(k))v(k)] \\ E[(s(k) + m(k))v(k-1)] \end{bmatrix} \quad \rightarrow \quad \mathbf{h} = \begin{bmatrix} -0.51 \\ 0.70 \end{bmatrix}$$

$$\mathbf{x}^* = \mathbf{R}^{-1} \mathbf{h} = \begin{bmatrix} 0.72 & -0.36 \\ -0.36 & 0.72 \end{bmatrix}^{-1} \begin{bmatrix} -0.51 \\ 0.70 \end{bmatrix} = \begin{bmatrix} -0.30 \\ 0.82 \end{bmatrix}$$

## فیلتر کردن افقی

نقطه‌ی ایستادن

STATIONARY POINT

$$E[(s(k) + m(k))v(k)] = E[s(k)v(k)] + E[m(k)v(k)]$$



0 زیرا  $s(k)$  و  $v(k)$  مستقل با میانگین صفر هستند.

$$E[m(k)v(k)] = \frac{1}{3} \sum_{k=1}^3 \left( 1.2 \sin\left(\frac{2\pi k}{3} - \frac{3\pi}{4}\right) \right) \left( 1.2 \sin\frac{2\pi k}{3} \right) = -0.51$$

$$E[(s(k) + m(k))v(k-1)] = E[s(k)v(k-1)] + E[m(k)v(k-1)]$$



0

$$E[m(k)v(k-1)] = \frac{1}{3} \sum_{k=1}^3 \left( 1.2 \sin\left(\frac{2\pi k}{3} - \frac{3\pi}{4}\right) \right) \left( 1.2 \sin\frac{2\pi(k-1)}{3} \right) = 0.70$$

$$\mathbf{h} = \begin{bmatrix} E[(s(k) + m(k))v(k)] \\ E[(s(k) + m(k))v(k-1)] \end{bmatrix} \quad \longrightarrow \quad \mathbf{h} = \begin{bmatrix} -0.51 \\ 0.70 \end{bmatrix}$$

$$\mathbf{x}^* = \mathbf{R}^{-1} \mathbf{h} = \begin{bmatrix} 0.72 & -0.36 \\ -0.36 & 0.72 \end{bmatrix}^{-1} \begin{bmatrix} -0.51 \\ 0.70 \end{bmatrix} = \begin{bmatrix} -0.30 \\ 0.82 \end{bmatrix}$$



$$F(\mathbf{x}) = c - 2\mathbf{x}^T \mathbf{h} + \mathbf{x}^T \mathbf{R} \mathbf{x}$$

$$c = E[t^2(k)] = E[(s(k) + m(k))^2]$$

$$c = E[s^2(k)] + 2E[s(k)m(k)] + E[m^2(k)]$$

$$E[s^2(k)] = \frac{1}{0.4} \int_{-0.2}^{0.2} s^2 ds = \frac{1}{3(0.4)} s^3 \Big|_{-0.2}^{0.2} = 0.0133$$

$$E[m^2(k)] = \frac{1}{3} \sum_{k=1}^3 \left\{ 1.2 \sin\left(\frac{2\pi}{3} - \frac{3\pi}{4}\right) \right\}^2 = 0.72$$

$$c = 0.0133 + 0.72 = 0.7333$$

$$F(\mathbf{x}^*) = 0.7333 - 2(0.72) + 0.72 = 0.0133$$



## فیلتر کردن افقی

شاخص کارایی

PERFORMANCE INDEX

$$F(\mathbf{x}) = c - 2\mathbf{x}^T \mathbf{h} + \mathbf{x}^T \mathbf{R} \mathbf{x}$$

$$c = E[t^2(k)] = E[(s(k) + m(k))^2]$$

$$c = E[s^2(k)] + \underbrace{2E[s(k)m(k)]}_0 + E[m^2(k)]$$

زیرا  $s(k)$  و  $v(k)$  مستقل با میانگین صفر هستند.



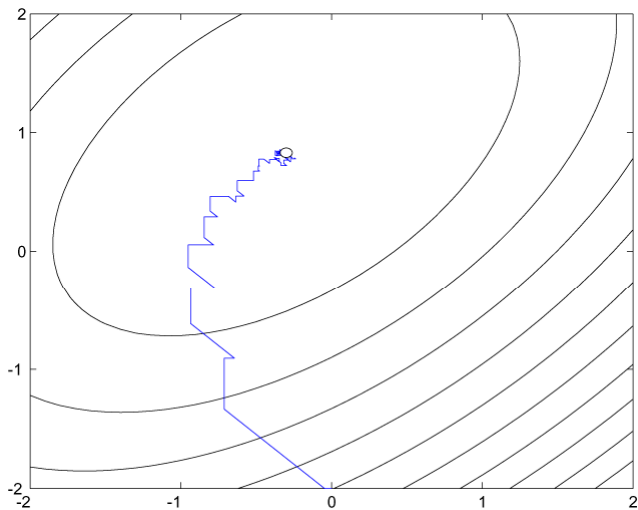
$$E[s^2(k)] = \frac{1}{0.4} \int_{-0.2}^{0.2} s^2 ds = \frac{1}{3(0.4)} s^3 \Big|_{-0.2}^{0.2} = 0.0133$$

$$E[m^2(k)] = \frac{1}{3} \sum_{k=1}^3 \left\{ 1.2 \sin\left(\frac{2\pi}{3} - \frac{3\pi}{4}\right) \right\}^2 = 0.72$$

$$c = 0.0133 + 0.72 = 0.7333$$

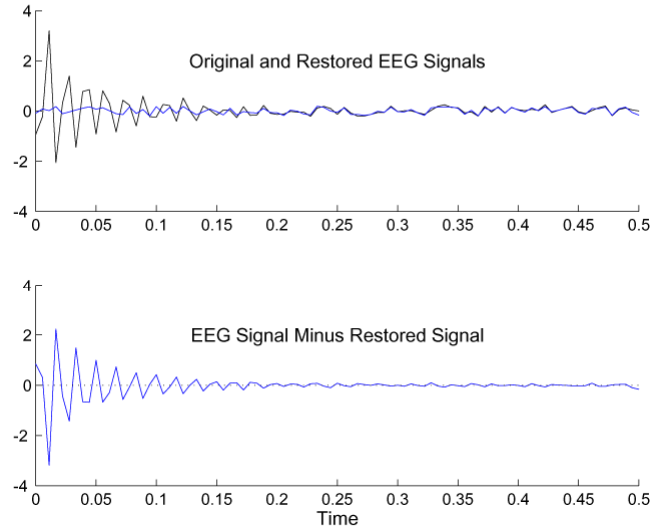

$$F(\mathbf{x}^*) = 0.7333 - 2(0.72) + 0.72 = 0.0133$$

خطای می‌نیم مربعات (که شبیه مقدار متوسط مربعات سیگنال EEG است)



## فیلتر کردن و فقی

## پاسخ LMS

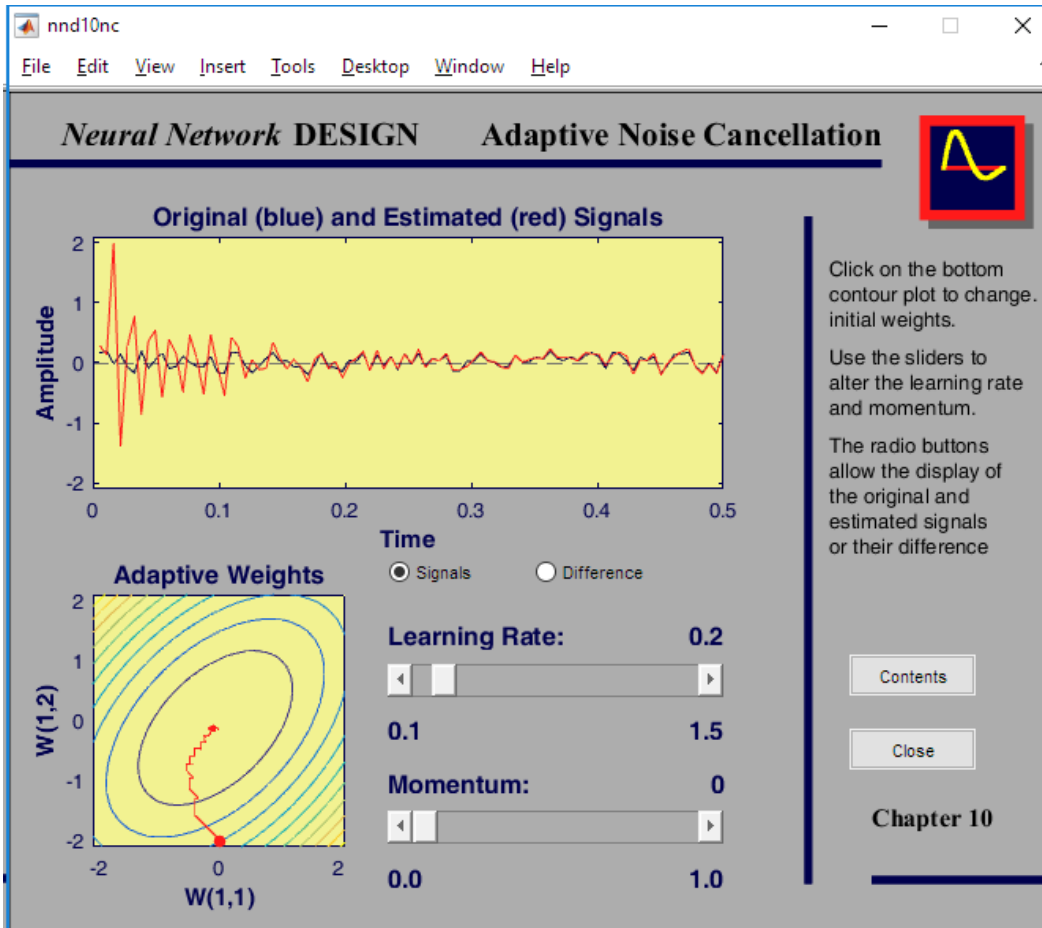
LMS RESPONSE

تراجکتوری الگوریتم LMS با  $\alpha = 0.1$

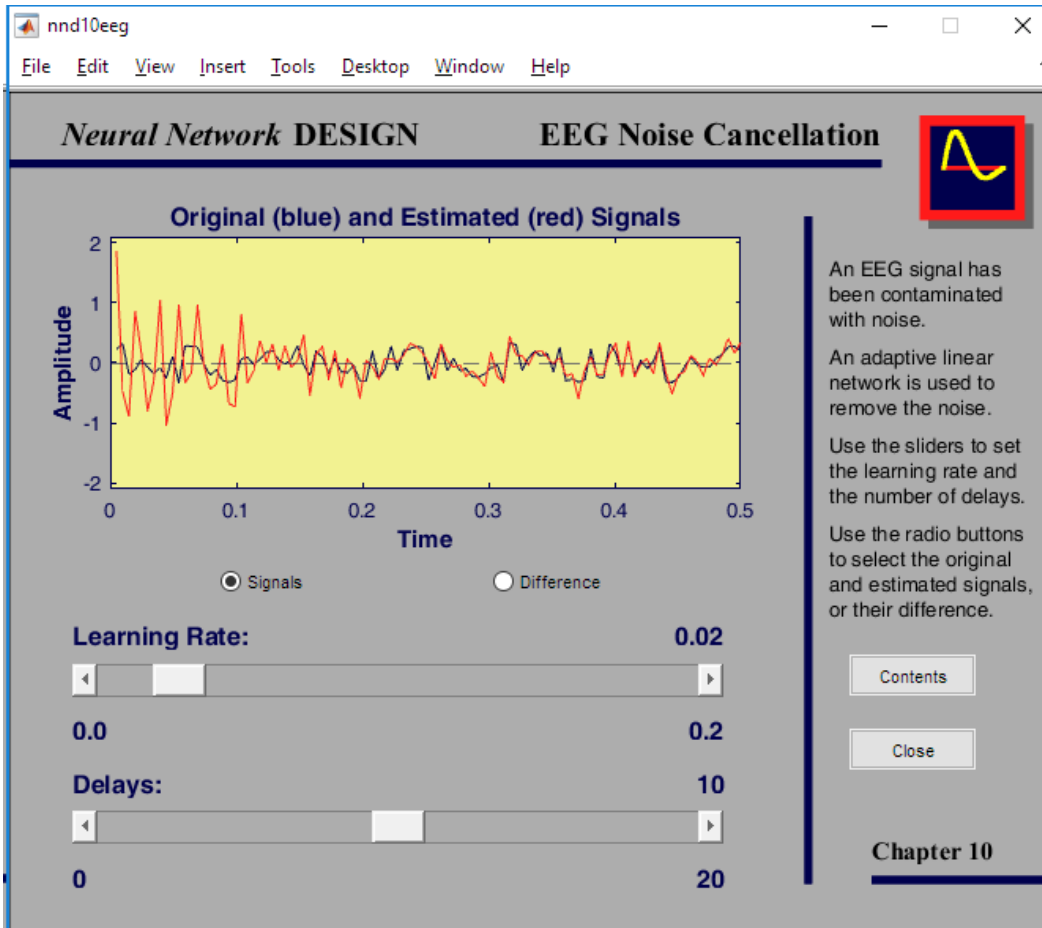
حالت مشابه کاهش گرادیان، اما نویزی

چرا خطا صفر نمی‌شود؟

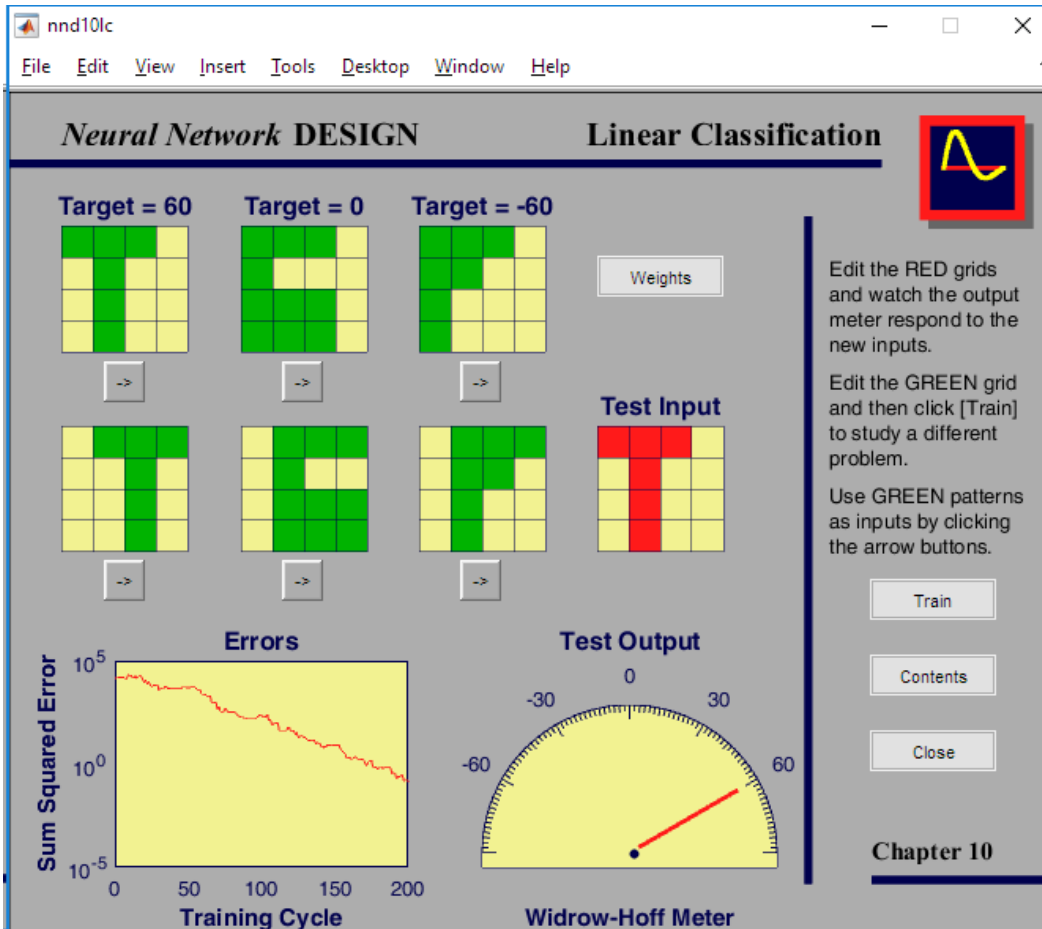
زیرا LMS از تقریب کاهش گرادیان بهره می‌برد،  
نه مقدار دقیق آن.



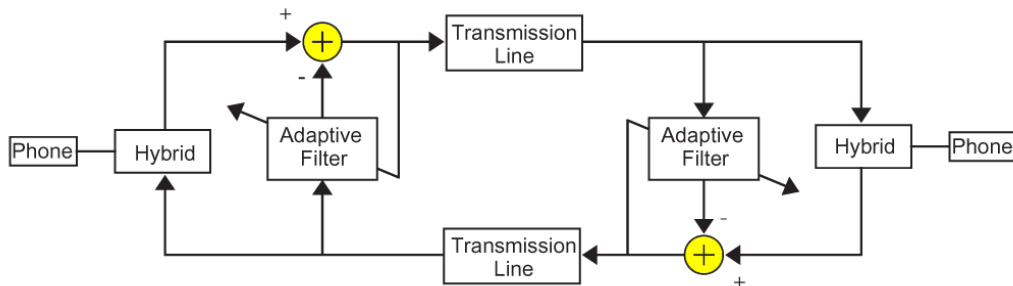
>> nnd10nc



>> nnd10eeg



>> nnd10lc

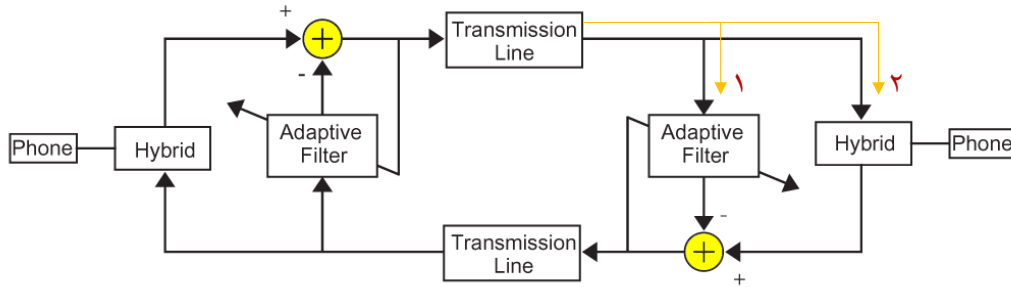


## فیلتر کردن افقی

مثال: لغو پژواک (لغو اکو)

### ECHO CANCELLATION

اکو در خطوط تلفن راه دور زیاد اتفاق می‌افتد.  
(به دلیل عدم تطابق امپدانس در دستگاه‌های هیبریدی که تقاطع میان خطوط راه دور و خطوط محلی را ایجاد می‌کنند.)



در انتهای خط راه دور، سیگنال وارده به یک فیلتر افقی و همچنین به دستگاه هیبریدی وارد می‌شود.  
خروجی تارگت فیلتر، خروجی هیبریدی است.  
پس، فیلتر سعی می‌کند بخشی از خروجی هیبریدی که همبسته با سیگنال ورودی است (یعنی اکو) را لغو کند.




یادگیری ویدرو-هاف

۶

منابع

## منبع اصلی



Martin T. Hagan, Howard B. Demuth, Mark H. Beale, Orlando De Jesus,  
**Neural Network Design,**  
 2<sup>nd</sup> Edition, Martin Hagan, 2014.  
**Chapter 10**

Online version can be downloaded from: <http://hagan.okstate.edu/nnd.html>

## 10 Widrow-Hoff Learning

Objectives	10-1
Theory and Examples	10-2
ADALINE Network	10-2
Single ADALINE	10-3
Mean Square Error	10-4
LMS Algorithm	10-7
Analysis of Convergence	10-9
Adaptive Filtering	10-13
Adaptive Noise Cancellation	10-15
Echo Cancellation	10-21
Summary of Results	10-22
Solved Problems	10-24
Epilogue	10-40
Further Reading	10-41
Exercises	10-42

### Objectives

In the previous two chapters we laid the foundation for *performance learning*, in which a network is trained to optimize its performance. In this chapter we apply the principles of performance learning to a single-layer linear neural network.

Widrow-Hoff learning is an approximate steepest descent algorithm, in which the performance index is mean square error. This algorithm is important to our discussion for two reasons. First, it is widely used today in many signal processing applications, several of which we will discuss in this chapter. In addition, it is the precursor to the backpropagation algorithm for multilayer networks, which is presented in Chapter 11.