

# جزوه درس شبکه 951

پرسپترون

ملاحظه کرد: طبقه بندی فضای سه بعدی به دو طبقه.

if  $x \in F^+ \Rightarrow Y=1$  طبقه اول

if  $x \in F^- \Rightarrow Y=0$  طبقه دوم

اگر  $F^+$  و  $F^-$  را در دو خط از بردارهای ورودی بنامیم، ضرایب را  $(F^+, F^-)$  را مشخص می‌کنیم.

حزبین طبقه بندی را سطح تقسیم می‌نامند که عبارت است از:  $\hat{N} = 0$

decision Surface  $\equiv \hat{N} = 0 \quad \sum_{p=1}^1 w_{p+1} \cdot x_{p+1}$

$\Rightarrow w_1 x_1 + w_2 x_2 + \dots + w_p x_p + b = w \cdot X + b = 0$


یعنی اگر فضای ورودی واقعی  $X$  را درجه  $P$  بگیریم  $(X = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix})$  معنی تقسیم یک

خط  $w_1 x_1 + w_2 x_2 + b = 0$



و اگر فضای ورودی واقعی  $P$  بگیریم، معنی تقسیم یک صفحه  $(P=1)$

در حالت کلی یک hyperplane (فوق صفحه)  $P$  بگیریم.



اصل تعداد: در شبکه  $P$  بردار ورودی بردار وزنها همواره بر سطح تقسیم عمود است. همیشه

فضای  $(P+1)$  یا  $(P)$  و وجه (فضای ورودی) واقعی  $(X)$ .

(با بعد  $P$ )

(با بعد  $P+1$ )

دلیل: در فضای  $(P+1)$  یا  $(P)$  بردار  $\hat{N}$  (برای  $P=1$ ) در هر تقسیم است.

$\hat{N}$  بردار  $X$  را در هر تقسیم عمود است پس بر هر ترکیبی از آن حالت عمود است.

یعنی بر هر سطح تقسیم عمود است.


در فضای ورودی واقعی  $(P)$  بردار  $\hat{N}$  (برای  $P=1$ ) نیز عمود است بر  $x_1$  و  $x_2$  دو بردار ورودی

در سطح تقسیم باشد باید داشته باشیم:

$$\begin{cases} w \cdot x_1 + b = 0 \\ w \cdot x_2 + b = 0 \end{cases}$$

$\Rightarrow w \cdot (x_1 - x_2) = 0$

و چون  $x_1 - x_2$  برای  $x_1$  و  $x_2$  بردارهای سطح تقسیم  $w$  بر این سطح، قطعاً عمود است.



- برای شخم مرسوم فضای دو بعدی و فضای واریانس یک بعدی  
 - فضا که در آن بردار W قرار دارد همان فضای تعمیم است  
 - بردار تعمیم همان بردار W است و جهت بردار W همان جهت تعمیم است  
 - بردار تعمیم همان بردار W است و جهت بردار W همان جهت تعمیم است  
 - بردار تعمیم همان بردار W است و جهت بردار W همان جهت تعمیم است

- بیان دیگر برای بردار تعمیم (مساحت تعمیم) داریم که:  $c \cdot e = W \cdot x_i = -b$  یعنی ضرب داخلی W در  $x_i$  های دومی مرتبه صاف ثابت است.

$$|W| \cdot |Proj(x_i|W)| = c \cdot e$$

و این تعبیر فیزیکی آنست که بردار W بر بردار تعمیم عمود باشد و در نتیجه با تصویر برداری نقاط دومی مرتبه برابر W ثابت باشد.

مثال: بردار تعمیم W را بیابیم از:  $x_1 - x_2 + 2 = 0$


$$\hat{W} = [1 \ -1 \ 2] \rightarrow \frac{2}{\sqrt{3}} \frac{1}{\sqrt{3}}$$

$$W_1 x_1 + W_2 x_2 + b = 0$$

- معادله فضای تعمیم عبارتست از:

$$\Rightarrow x_1 - x_2 + 2 = 0 \Rightarrow x_1 - x_2 = -2$$

و بردار W از همین فضای تعمیم است  
 $W = [1 \ -1]$



مثال =  $\hat{v} = x_1 - x_2 + 2 = 2 \Rightarrow y = \text{hardlim}(2) = 1 \ (F^+)$

$\hat{v} = 1 \Rightarrow y = 1$ ;  $\hat{v} = 0 \Rightarrow y = 1$ ;  $\hat{v} = -2 \Rightarrow y = 0 \ (F^-)$

- آموزش پرسپترون - یعنی با مشاهده دوالی مرتبه با سطح تعمیم برداری می توانیم  
 - بردار تعمیم و بردار تعمیم را بیابیم  
 - بردار تعمیم و بردار تعمیم را بیابیم  
 - بردار تعمیم و بردار تعمیم را بیابیم

Subject:


Year 90 Month 1 Date 1. 11

آموزش دستی:

$$Y = \text{AND}(x_1, x_2)$$

مثال: گیت AND منصف دو ورودی:

$x_1$	$x_2$	$y$
0	0	0
0	1	0
1	0	0
1	1	1



$$\bullet \Rightarrow y=0$$

قرار داد: 0 معادل 0 و 1 معادل 1 از بی بار 0


بالین مرز استقایی (سطح تقسیم استقایی) را داریم:

$$w = [1 \ 1] \rightarrow \hat{w} = [1 \ 1 \ b]$$

$$\Rightarrow \hat{v} = x_1 + x_2 + b = 0 \Rightarrow 1.5 + 0 + b = 0 \Rightarrow b = -1.5$$


نتیجه استقایی  $[1.5 \ 0]$

$$\Rightarrow \hat{w} = [1 \ 1 \ -1.5] \rightarrow \text{مکانه من } 0 \Rightarrow \text{دران جا منصف } 0 \Rightarrow \text{Perceptron AND.}$$



$$2x_1 + 2x_2 + b = 0 \quad ; \quad w = [2 \ 2]$$


$$w = [2 \ 2] \Rightarrow b = -3 \Rightarrow \hat{w} = [2 \ 2 \ -3] = 2 \hat{w}$$



من این اثری W اصلا اهمیت ندارد: (از تغییر یافته)

توجه: اطرالی پرسترون (یوتی تی) صرفاً جهت W اهمیت دارد نه اندازه آن (اصل بقادر).

توجه: در طراحی پرسترون برای سوکاربرد، به تعداد طراحی ممکن جواب وجود ندارد.  
 ریاضی معفر به فرستیت.  
 آموزش سوکاربرد روش رزینبات و آموزش پرسترون:



برای برآورد وزنهای اولیه آل و واقعی (در نتیجه فرزدهای تصمیم متناظر آن ها) محل فضای دیگری را به چهار ناحیه مطابق شکل تقسیم می کنند. (  $t=1, y=1$  و  $t=0, y=0$  )  
 ناحیه III و IV ناحیه I و II

- \* فرض کنید برای الگوریتم آموزشی در ناحیه I قرار داشته باشیم. می خواهیم وزن های قدم قبل (n) برای آن اصلاح کنیم.
  - I  $X_1: \begin{cases} t=1 \\ y=1 \end{cases}$  :  $w[n+1] = w[n] + 0$  (تغییر وزن صافی با سطر)
  - II  $X_2: \begin{cases} t=1 \\ y=0 \end{cases}$  :  $w[n+1] = w[n] + X_2 \rightarrow w^*$  (تغییر وزن صافی با سطر)
  - \*  $X_2: \begin{cases} t=1 \\ y=0 \end{cases}$  :  $w[n+1] = w[n] + X_2 \rightarrow w^*$  (تغییر وزن صافی با سطر)
  - \* و برای ناحیه III و IV داریم:
    - III  $X_3: \begin{cases} t=0 \\ y=0 \end{cases}$  :  $w[n+1] = w[n] + 0$
    - IV:  $X_4: \begin{cases} t=0 \\ y=1 \end{cases}$  :  $w[n+1] = w[n] - X_4$  (تغییر وزن صافی با سطر)

برای این آزمون روش زینبلاست برای آن به صورت زیر بیان کرد:  
فرض کنید تعدادی آزمونهای آموختنی  $(X_i, t_i)$  را اختیار داریم.

$$i = 1, 2, \dots, 10$$

- ۱- انتخاب روزی که شبکه لغزیده است. اختیاری یا با معادنی و احتمال آن به شبکه  $\frac{1}{5}$  است.
- ۲- آزمونهای آموختنی خود را یک به یک و در ترتیب به شبکه اعمال کرده و فرضی آن را  $(t_i)$  را برای هر یک از آنها بدست می آوریم.
- فرضی شبکه را با فرضی مطلوب آموختنی مقایسه کرده و براساس مقایسه  $t_i$  و  $y_i$  حاصل می شود. فرضی  $t_i$  را از  $t_i = 1$  یا  $t_i = 0$  مطابق رابطه  $(*)$ ، درتهای شبکه را اصلاح می نمایم.

- ۳- اگر هیچ تغییری در روز اول نداشته باشد در روزهای بعدی آموختنی اتفاق می افتد. بیان آموختنی در غیر این صورت، برگشت به درصد ۲ آموختنی و متغیر آن.

شبکه را تعیین - جایی ششم - ۱۷/۸/۹۵

آموختنی زینبلاست برای پرسیدن:

- ۱- شروع باورتهای اولیه سخن با معادنی
- ۲- اعمال آموختنی و تعیین فرضی  $t_i$ :

$$\text{if } t_i = 1 \Rightarrow w[n] = w[n-1]$$

$$\text{if } t_i = 0 \Rightarrow w[n] = w[n-1] + X_i$$

$$\text{if } t_i = 1 \Rightarrow w[n] = w[n-1] - X_i$$

۳- اگر به روزی هم آنها  $w[n] = w[n-1]$  بیان در غیر این صورت برگردید.

در لغزیده است:

$$\delta = t - y$$

$$\text{if } \delta = 0 (y = t) \Rightarrow w[n] = w[n-1] + (0) \times X$$

$$\text{if } \delta = 1 (y = 0) \Rightarrow w[n] = w[n-1] + (1) \times X$$

$$\text{if } \delta = -1 (y = 1) \Rightarrow w[n] = w[n-1] + (-1) \times X$$

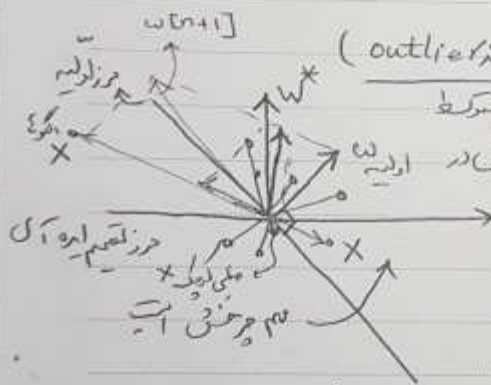
- بنا برین قانون آموزش پرسپترون بعد از هر  $n$  مرحله و محاسبه بطل زیر تریت:

$$w[n] = w[n-1] + \delta \cdot x^T$$

$\delta = t - y$  : که در آن  $t$  :  $y$  -  
 (اصلاح الگوریتم) :  
 - اصلاح الگوریتم :  
 ۱- اضافه کردن نرخ آموزش (learning rate) به قانون آموزش جهت جلوگیری از افزایش نوسانی یا ناپایداری وزن ها و تقویت الگوریتم یعنی:

$$w[n] = w[n-1] + \eta \cdot \delta \cdot x$$

که در آن نرخ آموزش عددی بین صفر و یک است:  $0 < \eta < 1$ .  
 اگر  $\eta$  کوچک انتخاب شود لغزش یا پایداری و نوسانی وزن الگوریتم کم و در سرعت آن نیز کم خواهد بود و برعکس.  $\eta$  زیاد تر یعنی:



۲- بر این وجه آموزش پرسپترون (outliers) یعنی الگوریتم آموزش با بردار  $x$  بسیار متفاوت از متوسط بردارهای آموزش در آن بردار  $x$  است.

$$x_i \rightarrow \frac{x_i}{\|x\|} \quad i = 1, 2, \dots, P$$

$$\Rightarrow \|x\| = 1$$


به این ترتیب قانون آموزش پرسپترون بطل زیر اصلاح می شود:

$$w[n] = w[n-1] + \eta \cdot \delta \cdot \frac{x}{\|x\|}$$

$$w[n] = w[n-1] + \frac{\eta}{\|x\|} \cdot \delta \cdot x$$

که در آن  $\|x\|$ ، نرم یا انرژی بردار  $x$  از آن میسرود. یعنی محاسبه آموزش با نسبت ثابت  $\frac{\eta}{\|x\|}$  بستگی به  $x$  دارد. یعنی نرخ آموزش بطور دقیق حدرا کنترل می نمود.

- یعنی محاسبه نرخ آموزش به صورت دقیق، حدرا با اندازه ی متوسط تقسیم می کند. بر این اساس مقدار کمی که برای آموزش گرفته شود، نرخ آموزش تقویت می شود.



یک مثال ساده برای محاسبه هارد لیمیت  
 برای افشردگی مخروطی شکل متبل، یک پرتون  
 طاقی باشد.  
 ۱- وزنی از این سیم را برابر برداریم  
 تمام صفر قرار می دهیم:

$$w_0 = [0 \ 0 \ 0]^T$$

۲- افشردگی مخروطی را به ترتیب به سیم اعمال می کنیم. این افشردگی عبارتند از:

$$\left( \begin{bmatrix} -1 \\ 0 \\ 1 \end{bmatrix}, t_1 \right), \left( \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix}, t_2 \right), \left( \begin{bmatrix} 0 \\ 1 \\ 1 \end{bmatrix}, t_3 \right), \left( \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix}, t_4 \right)$$

برای افشردگی  $x_1$  داریم که:

$$w \cdot x_1 = 0 \Rightarrow y = \text{hard lim}(0) = 1, \text{ if } t=0 \Rightarrow \delta = t - y = -1$$

$$\Rightarrow w_1 = w - x_1^T = [1 \ 0 \ -1]$$

$$= -x_1$$

$$x_2: y = \text{hard lim}(w_1 x_2) = \text{hard lim}(-1) = 0, t_2=0 \Rightarrow \delta = 0$$

$$\Rightarrow w_2 = w_1 = [1 \ 0 \ -1]$$

$$x_3: y = \text{hard lim}(w_2 x_3) = \text{hard lim}(-1) = 0, t_3=1 \Rightarrow \delta = 1$$

$$\Rightarrow w_3 = w_2 + x_3^T$$

$$= [1 \ 0 \ -1] + [0 \ 1 \ 1]$$

$$= [1 \ 1 \ 0]$$

$$x_4: y = \text{hard lim}(w_3 x_4) = \text{hard lim}(1) = 1, t_4=1 \Rightarrow \delta = 0$$

$$\Rightarrow w_4 = w_3 = [1 \ 1 \ 0]$$

با این مورد اول آموزش

W بعضی لحظه ها برابر با [0 0 0] و در بعضی [1 1 0] خود نرم سیم باقی می ماند  
 دیگر انجام شود  
 \* مورد دوم آموزش:

$$x_1: w_4 \cdot x_1 = -1 \Rightarrow y = 0, t_1=0 \Rightarrow \delta = 0 \Rightarrow w_5 = w_4$$



$\delta = 1$

$X_2: W_5 \cdot X_2 = W_4 \cdot X_2 = 0 \Rightarrow y = 1, t = 0 \Rightarrow W_6 = W_5 - X_2$   
 $= [1 \ 1 \ 0] - [0 \ 0 \ 1]$   
 $= [1 \ 1 \ -1]$

$\Rightarrow W_6 = [1 \ 1 \ -1]$

$X_3: W_6 \cdot X_3 = 0 \Rightarrow y = 1, t = 1 \Rightarrow \delta = 0 \Rightarrow w \checkmark$

$X_4: W_6 \cdot X_4 = 0 \Rightarrow y = 1, t = 1 \Rightarrow w \checkmark$

بیان اور تمام آموزش  $\neq$  بیان آموزش

\* آغاز آموزش آموزش:  $W = [1 \ 1 \ -1]$  ویدی

$X_1: W \cdot X_1 = -2 \Rightarrow y = 0, t = 0 \Rightarrow \checkmark$


$X_2: W \cdot X_2 = -1 \Rightarrow y = 0, t = 0 \Rightarrow \checkmark$

$X_3: W \cdot X_3 = 0 \Rightarrow y = 1, t = 1 \Rightarrow \checkmark$

$X_4: W \cdot X_4 = 0 \Rightarrow y = 1, t = 1 \Rightarrow \checkmark$

بیان آموزش آموزش  $\equiv$  بیان کل آموزش. زیرا برای هری آنها:

$y_i = t_i; i = 1, 2, 3, 4.$



لا بیس  $W = [1 \ 1 \ -1]$


برنامه ریزی آموزش پرسپترون در  $M$ :

Function  $W = \text{percept1}(X, t)$   $\Rightarrow$  help percept1

% help...

\* مشخص کردن ورودی آموزش قبل از پردازش برنامه ی  $\text{percept1}$  از این آرایه برار  $M$

در هر سطر  $x_i = X(i, :)$



$\Rightarrow X = [1 \ -1 \ \dots \ -2 \ -2 \ \dots \ -2 \ \dots \ -1 \ \dots \ -1]$   
 $\Rightarrow t = [1 \ 1 \ 0 \ \dots \ 1]$

$W = \text{zeros}(1, \text{size}(X, 2))$

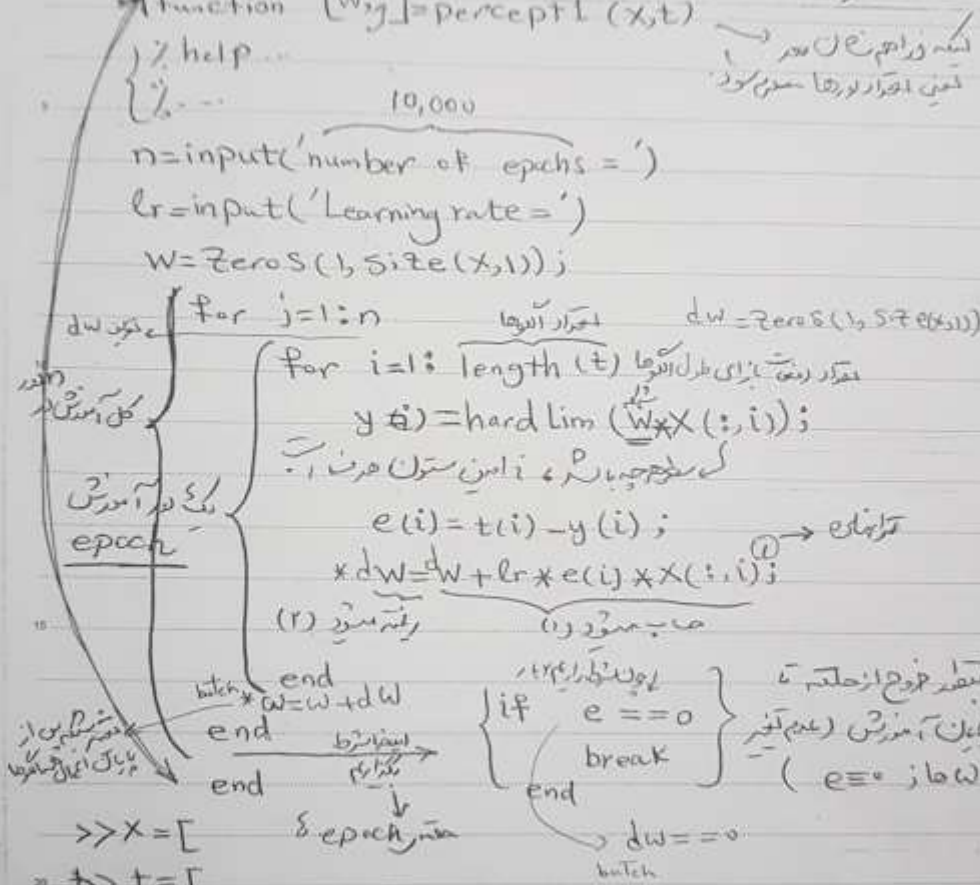
$W = [1 \ 1 \ 0 \ \dots \ 1]$

که  $\text{size}(X, 2)$   $\Rightarrow$  تعداد ستون ها

برای آموزش شبکه در  $M$  ...

```

function [W,z] = percept1(X,t)
% help ...
% ...
n = input('number of epochs = ');
lr = input('Learning rate = ');
W = zeros(size(X,1));
for j = 1:n
    dW = zeros(size(W));
    for i = 1:length(t)
        y(i) = hardlim(W*X(:,i));
        e(i) = t(i) - y(i);
        dW = dW + lr * e(i) * X(:,i);
    end
    W = W + dW;
end
end
end
    
```



$[W, R] = \text{Percept1}(X, t)$   
 انواع ممکن آموزش شبکه های عصبی -  
 -  $\text{incremental}$  (تغییر جزئی یکی یکی)  
 -  $\text{batch}$  (درستی های گروهی)

در حالیکه در روش  $\text{incremental}$  حرکت آموختن به تنهایی باعث تغییر وزنهای شبکه میشود.  
 در روش  $\text{batch}$  حرکتی یا دسته ای (batch) تا اتمام همگی آنها با هم شکل داده میشود.  
 شبکه (تغییر نمی کند) و در تمام احوال همگی آنها در حرکت های آموختن آن ها با یکدیگر  
 ارتباط دارند (مستقلاً جمع) و شبکه یکجا برای دور بعدی آموزش تغییر می کند.  
 در حالت  $\text{incr.}$  ترتیب احوال آنها در آموختن درست است. آن در نتیجه آن که در هر یک

در  $\delta$  batch و این ترتیب  $\delta$  را در هر دو شبکه و در هر دو جهت محاسبه می کنند  
 - برای هر لایه  $i$  در هر دو جهت  $\delta$  را محاسبه می کنند.  $\delta$  را در جهت  $in$  و  $out$  محاسبه می کنند.  
 شبکه ۱:  $\delta$  را محاسبه می کنند.  $\delta$  را در جهت  $in$  و  $out$  محاسبه می کنند.

- ابتدا مقادیر  $\delta$  را در جهت  $in$  محاسبه می کنند:

\* در هر دو جهت  $\delta$  را محاسبه می کنند و مساله است که عبارت برافضی:

مقدار  $\delta$  را محاسبه می کنند.  $\delta$  را در جهت  $in$  و  $out$  محاسبه می کنند.  $\delta$  را در جهت  $in$  و  $out$  محاسبه می کنند.  
 مقادیر  $\delta$  را محاسبه می کنند.  $\delta$  را در جهت  $in$  و  $out$  محاسبه می کنند.  $\delta$  را در جهت  $in$  و  $out$  محاسبه می کنند.

بجای  $\delta$  را محاسبه می کنند.  $\delta$  را در جهت  $in$  و  $out$  محاسبه می کنند.  $\delta$  را در جهت  $in$  و  $out$  محاسبه می کنند.  

$$\|W^*\| = 1 = \|X_i\| \quad i=1, 2, \dots, p$$

و تمام  $\delta$  را برابر  $\delta$  می کنند:

و هم چنین:  $\delta$  را محاسبه می کنند.  $\delta$  را در جهت  $in$  و  $out$  محاسبه می کنند.  $\delta$  را در جهت  $in$  و  $out$  محاسبه می کنند.  

$$|W^* \cdot X_i| \geq \epsilon > 0$$

که در آن  $\delta$  را محاسبه می کنند.  $\delta$  را در جهت  $in$  و  $out$  محاسبه می کنند.  $\delta$  را در جهت  $in$  و  $out$  محاسبه می کنند.

که در آن  $\delta$  را محاسبه می کنند.  $\delta$  را در جهت  $in$  و  $out$  محاسبه می کنند.  $\delta$  را در جهت  $in$  و  $out$  محاسبه می کنند.  

$$\delta(n) = \frac{W^* \cdot W[n]}{\|W[n]\|}$$

که در آن  $\delta$  را محاسبه می کنند.  $\delta$  را در جهت  $in$  و  $out$  محاسبه می کنند.  $\delta$  را در جهت  $in$  و  $out$  محاسبه می کنند.  

$$W^* \cdot W[n+1] = W^* \cdot (W[n] + \delta \cdot X)$$

که در آن  $\delta$  را محاسبه می کنند.  $\delta$  را در جهت  $in$  و  $out$  محاسبه می کنند.  $\delta$  را در جهت  $in$  و  $out$  محاسبه می کنند.  

$$= W^* \cdot W[n] + \delta \cdot W^* \cdot X$$

که در آن  $\delta$  را محاسبه می کنند.  $\delta$  را در جهت  $in$  و  $out$  محاسبه می کنند.  $\delta$  را در جهت  $in$  و  $out$  محاسبه می کنند.  

$$\delta = +1 \Rightarrow W^* \cdot X \geq \epsilon > 0 \Rightarrow \delta \cdot W^* \cdot X \geq \epsilon > 0$$

که در آن  $\delta$  را محاسبه می کنند.  $\delta$  را در جهت  $in$  و  $out$  محاسبه می کنند.  $\delta$  را در جهت  $in$  و  $out$  محاسبه می کنند.  

$$\delta = -1 \Rightarrow W^* \cdot X < 0 \Rightarrow \delta \cdot W^* \cdot X \geq \epsilon > 0$$

که در آن  $\delta$  را محاسبه می کنند.  $\delta$  را در جهت  $in$  و  $out$  محاسبه می کنند.  $\delta$  را در جهت  $in$  و  $out$  محاسبه می کنند.

که در آن  $\delta$  را محاسبه می کنند.  $\delta$  را در جهت  $in$  و  $out$  محاسبه می کنند.  $\delta$  را در جهت  $in$  و  $out$  محاسبه می کنند.  

$$W^* \cdot W[n] = W^* \cdot W[n-1] + \delta \cdot W^* \cdot X \geq \epsilon$$

$$W^* \cdot W[2] = \underbrace{W^* \cdot W[1]}_{\geq \epsilon} + \underbrace{\delta \cdot W^* \cdot X}_{\geq \epsilon} \geq 2\epsilon$$

تکرار  
تکرار

$$W^* \cdot W[n] = \dots \geq n\epsilon$$

تبدیل نموده که:

$$\begin{aligned} \Rightarrow \|W[n+1]\|^2 &= W[n+1] \cdot W[n+1] = (W[n] + \delta \cdot X) \cdot (W[n] + \delta \cdot X) \\ &= \|W[n]\|^2 + \delta \cdot W[n] \cdot X + \delta \cdot X \cdot W[n] + \delta^2 \cdot \|X\|^2 \\ &= \|W[n]\|^2 + 1 + 2\delta \cdot W[n] \cdot X \end{aligned}$$

با درجهت وسیع تغییر در  $W$  با  $\delta = 1$  یا  $-1$

$$\delta = 1 \Rightarrow \begin{cases} t=1 \\ \delta=1 \end{cases} \Rightarrow W[n] \cdot X < 0 \Rightarrow 2\delta \cdot W[n] \cdot X < 0$$

$$\delta = -1 \Rightarrow \begin{cases} t=0 \\ \delta=-1 \end{cases} \Rightarrow W[n] \cdot X \geq 0 \Rightarrow 2\delta \cdot W[n] \cdot X \leq 0$$

بنابراین در هر حال  $2\delta \cdot W[n] \cdot X \leq 0$  (برای هر تغییر برای  $\delta$  و  $X$  و  $W$ )  
پس:

$$\begin{aligned} \|W[0]\|^2 &= 1 \\ \|W[1]\|^2 &= 1 + 1 + C \leq 2 \\ \|W[2]\|^2 &= \|W[1]\|^2 + 1 + C' \leq 3 \end{aligned}$$

$$\Rightarrow \|W[n]\|^2 \leq n$$

بنابراین هر چه  $n$  بزرگتر شود:

$$\Rightarrow \cos(\theta) = \frac{W \cdot W[n]}{\|W\| \cdot \|W[n]\|} \geq \frac{n\epsilon}{\sqrt{n}} = \sqrt{n} \cdot \epsilon > 1$$

اما توجه کنید که:

$$\cos(\theta) = \cos(\cdot) \Rightarrow \text{کماند}$$

پس  $n$  (تعداد تغییر) محدود شود زیرا  $\cos$  بین  $-1$  و  $1$  است.

$$\Rightarrow n \leq \frac{1}{\epsilon^2}$$

درون 1 - در آن زمان مدل می توانیم از نظر آن و رابطه را یاد بگیریم ، n می تواند متغیر باشد  
 (اگرچه باید دانست که (یعنی n) - به n ↑ و می توان  
 - حجم ابزار پرسترون

andnet=newp(x,t)

- این  $M$  حجم ابزارها را مشخص می کند ، یعنی در هر  $E$  لحظه ای می توانیم

- تفاوت - حجم ابزارهای متغیر با زمان  $E$  در  $n$  :

\* در متغیر  $n$  همواره بطور جداگانه لحاظ می شود ، یعنی  $n$  در اندازه  $n$  می تواند  
 آنورشی (متغیر ، بنابر ابزارها) را به  $n$  اضافه کنیم .

view(andnet)

$X = [y \ t \ x \ p]$

- با  $n$  بودن فرقی معرمان مثال :

$T = \begin{bmatrix} 1 & 1 \\ -1 & 0 \end{bmatrix}$   
 تغییر  $n$   
 $3 \times 4$   
 $3 \times 4$

$newp(x,T) \rightarrow$  از روی این تغییرات  $n$  را مشخص می کند

تغییر  $n$   $x = [0 \ 0 \ 0 \ 1 \ 0 \ 1 \ 0 \ 0 \ 0 \ 1]$

$t = \dots \dots \dots$

andnet=newp(x,t)

view(andnet) این ابزارها

andnet=train(andnet,x,t)  
آموزش

andnet.trainparam.epochs=12

lr=1z

andnet.iw(1,1)

newp(x,t)

= train(x,t)

- دستور اولی که پرسترون

- آموزش

trainparam.epochs...

- تغییرات ابزارها

andnet.iw(1,1)

-  $n$  در هر درخت

andnet.iw(1,1)

andnet.iw(1,1)

andnet.b(1)

نت عددی با یک:

- بین عددی در زیر با یک نور و آن می شود. خلاصانه اعمال و در بعضی خلاصانه هر یک خاصیت
- پارامتر lr در این دستور، بی اثر است و کاری ندارد. آن نخواهد داشت.
- در طبقه آموزشی و لایه های بعدی بصورت inc. این 2 می شود.
- در lr جز پارامتر آموزشی نیست.
- فرم کامل دستور:

$$\text{andnet} = \text{newp}(x, t, 'TF', 'LF', 'hardlim', 'hardlims', \text{learnfn})$$

در این طبقه learnfn, learnfn که توابع فعالیت به مثابه پرسش است  
 ← با عددی و غیره

$$\text{andnet} = \text{newp}(x, t, 'hardlim', 'learnfn')$$

- بین اینات طبق با عددی و غیره
- اما اگر learnfn به تعداد epoch که کم می شود
- با learnfn (دستی) و غیره → حتی بهتر است. سریعتر


- محدودیت لایه های: مرز تک خطی: فقط یک خط و یک ربع به این نوع است.  
 است که با فرم سطح خطی و غیره است.

مثلاً XOR


$$p = [1 \ 0]'$$
  

$$\text{xornet}(p)$$
  

$$h_{\text{xornet}}(x)$$



اما به این خط، نمی توان مرز تعیین داد → هیچ مرز تک خطی بعد از خطی که وجود دارد.  
 هیچ مرز تک خطی در ربع چهارم قرار نمی گیرد (مثلاً XOR) است  
 بنابراین لایه های لایه های دیگر.



در خطی به هم از آن را پیدا خواهد کرد...

(ترین) طایفه لایه های برای: OR (دستی) - OR (دستی)  
 هم راستی هم با که است  
 NAND (دستی) - OR (دستی)  
 OR (دستی) - NAND (دستی)

