

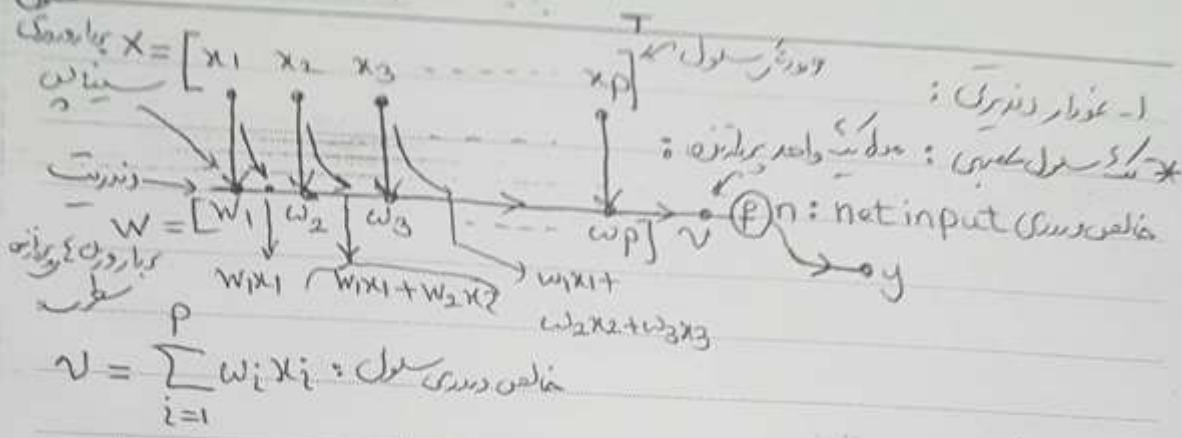
یک جزوه درس شبکه ۹۵۱

شماره 2

نمایش و مدل

Subject:

Year 9 & Month ✓ Date Yy ✓




n : net input; $M(a) \rightarrow$ MATLAB
 f : activation function (تابع فعالیّت)
 M : Transfer function (تابع انتقال) $\rightarrow f$

$y = f(v)$: خروجی مدل ; x : بردار ستونی $1 \times p$ طول
 W : بردار افقی

$\Rightarrow v = W \cdot X \rightarrow$ عمل ضرب اسکالر
 $\Rightarrow y = f(v) = f(W \cdot X)$

۲- نمودار تدریس سیگنال : (Signal Flow graf)




$w > 0$: سینین تحریکی ; $w < 0$: سینین مهارکننده
 $w = 0$: عدم انتقال
 $\Rightarrow v = \sum_i w_i x_i = W \cdot X$; $y = f(W \cdot X)$


Subject:

Year: 9th Month: V Date: 2/1/18

- بہ شکل سادہ تر:



- نہیں بڑے ریاضی (بڑی):

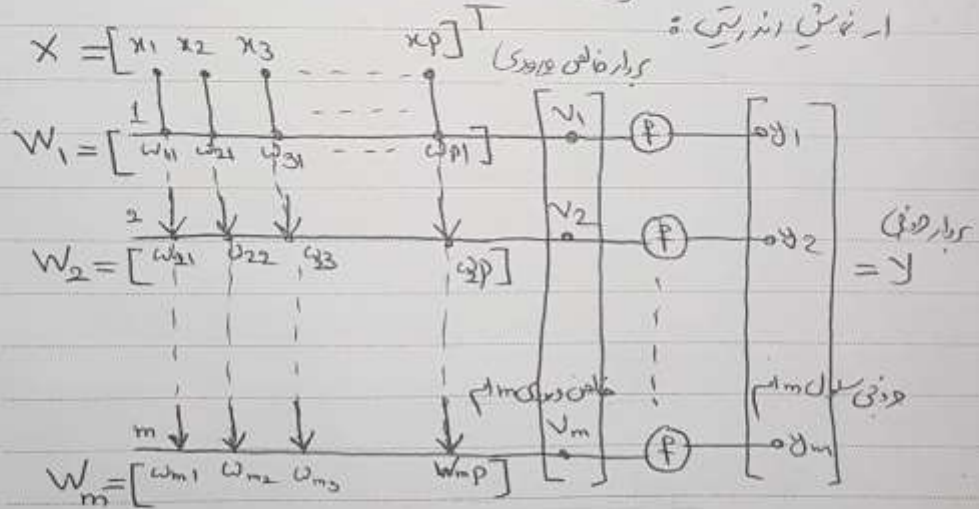


$$v = W \cdot X$$

$$y = f(v) \Rightarrow \text{بہاں نمکدریانی}$$

- عمل بیک لایر کی نوزونی (جسٹین سلول عصبی مختلف):

ا- نہیں اندازتی:



$$v = \begin{bmatrix} v_1 \\ v_2 \\ \vdots \\ v_m \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^p w_{1i} x_i \\ \sum_{i=1}^p w_{2i} x_i \\ \vdots \\ \sum_{i=1}^p w_{mi} x_i \end{bmatrix} = \begin{bmatrix} W_1 \\ W_2 \\ \vdots \\ W_m \end{bmatrix} \cdot X$$

P4PCO

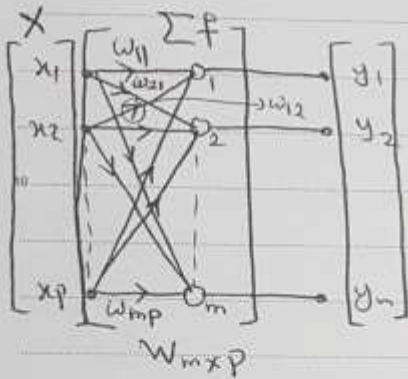
W_{m x p} کے تقاریر ہوں گا

$V = W \cdot X \rightarrow$ برابر بردی
 مابین وزنهای جفتی از آن
 حاصل بردی

حدهای هر ضلع:

$\Rightarrow \underline{y} = \underline{f}(v)$ برابر خطای بردی
 (m x 1) لوزنهای (m x 1)
 تابع فعالیتهای
 که بردی m لایه بردی


$$\begin{bmatrix} f(v_1) \\ f(v_2) \\ \vdots \\ f(v_m) \end{bmatrix} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_m \end{bmatrix}$$



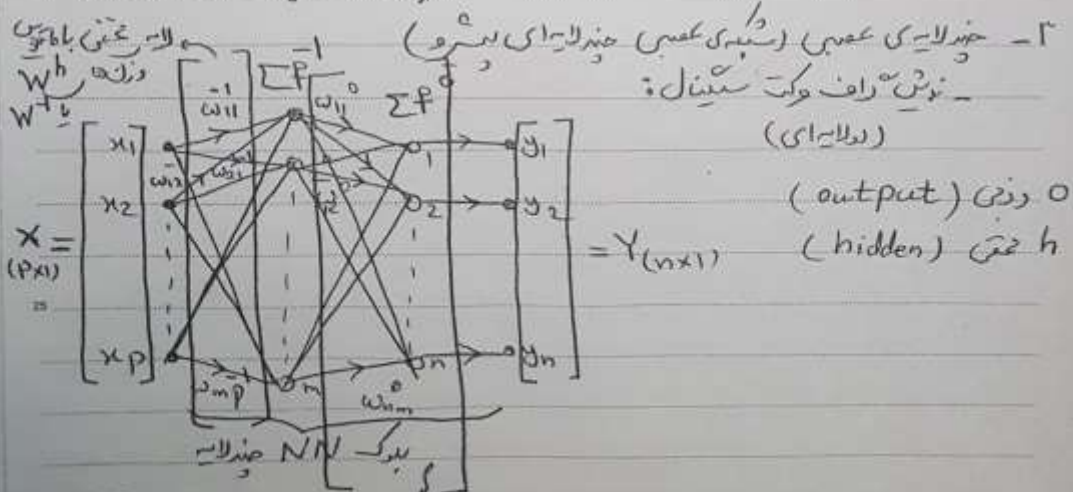
۱- نمایش گراف وکت سیگنال:
 - توابع لایم: در وزن اتصال و w_{ij}
 یا لایه های لوزن مقصد اتصال، و
 و لایه لوزن یا بردی مبدأ اتصال
 است.

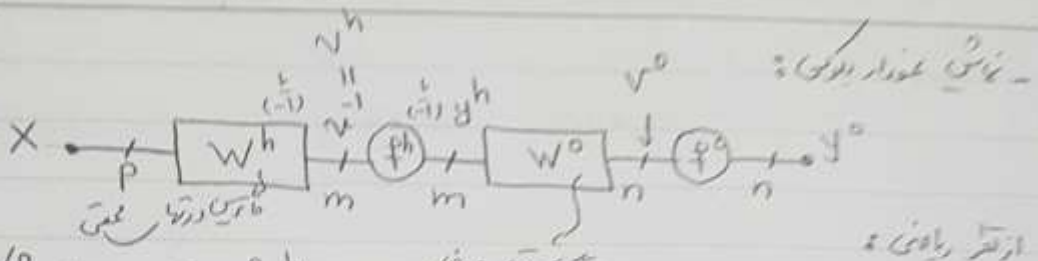
بر این ترتیب با هم داریم:
 $V = W \cdot X$
 $(m \times 1) \leftarrow y = \underline{f}(v)$

۲- لوزنهای سیگنال:



$v = W \cdot X \Rightarrow y = \underline{f}(v)$





لایه نهایی $y^o = f(W^o \cdot y^h)$


لایه پنهان $y^h = f^h(W^h \cdot X)$

$$\Rightarrow y_{(n \times 1)} = f_{(n \times m)} [W^o_{(n \times m)} \cdot f^h_{(m \times p)} (W^h_{(m \times p)} \cdot X_{(p \times 1)})]$$

تالیف تعداد لایه ها \rightarrow تالیف تعداد لایه ها

تالیف تعداد لایه ها در شبکه های عصبی:

1. پرسش سخت: hard limiter



$$f(v) = \begin{cases} 1 & v > 0 \\ 0 & v < 0 \end{cases}$$


$M: y = \text{hardlim}(v)$

$\Rightarrow X = -5 : 0.1 : 5$

$\Rightarrow Y = \text{hardlim}(X)$

$\Rightarrow \text{plot}(X, Y)$


2. پرسش سخت متقارن (متقارن):



$$f(v) = \begin{cases} 1 & v > 0 \\ -1 & v < 0 \end{cases}$$

$M: y = \text{hardlims}(\cdot)$ Symmetric متقارن


موضوع: $f(v)$ تابع v (خطی)



۳- تابع $f(v)$ خطی خالص:

$$f(v) = v$$


M : $y = \text{purelin}(v)$



۴- خطی اشباعی:

$$f(v) = \begin{cases} 1 & v > 1 \\ v & 0 \leq v \leq 1 \\ 0 & v \leq 0 \end{cases}$$

M : $y = \text{satlin}(v)$ (خطی اشباعی)




۵- خطی اشباعی متعادل (دو طرفه):

$$f(v) = \begin{cases} 1 & v > 1 \\ v & -1 < v < 1 \\ -1 & v \leq -1 \end{cases}$$

M : $y = \text{satlins}(v)$


۶- تابع اشباعی - جیبی (Sigmoid)



Sigmoid

$$f(v) = \frac{1}{1 + e^{-kv}}$$

برای $k > 0$ و $k < 0$ (تعمیر یا خنثی سازی):



فرایند:
 ۱- برگشت نور از یک سطح، یعنی اینکه مشاهده کردیم که در این حالت نور از یک سطح بازتاب می‌دهد و در جهت مخالف می‌تابد.

۲- مشتق نور از یک منبع است که استفاده از بسیاری از نورهاست. $f(v) = \frac{e^{-v}}{1+e^{-v}}$ $f(v) = \frac{e^{-v}}{1+e^{-v}}$ $f(v) = \frac{e^{-v}}{1+e^{-v}}$ $f(v) = \frac{e^{-v}}{1+e^{-v}}$

۳- امکان تعویض و تغییر در سایر توابع فعالیتی مانند $f(v) = \frac{e^{-v}}{1+e^{-v}}$ $f(v) = \frac{e^{-v}}{1+e^{-v}}$ $f(v) = \frac{e^{-v}}{1+e^{-v}}$ $f(v) = \frac{e^{-v}}{1+e^{-v}}$


$$f'(v) = \frac{e^{-v}}{(1+e^{-v})^2} = \frac{1}{1+e^{-v}} \cdot \frac{e^{-v}}{1+e^{-v}} = f(v) \cdot (1-f(v)) = y \cdot (1-y)$$

۴- که در این مشتق بسیار ساده‌ای است که به پارامترهای $f(v)$ و $1-f(v)$ $f(v) = \frac{e^{-v}}{1+e^{-v}}$ $f(v) = \frac{e^{-v}}{1+e^{-v}}$ $f(v) = \frac{e^{-v}}{1+e^{-v}}$ $f(v) = \frac{e^{-v}}{1+e^{-v}}$

توابع فعالیتی سگمندی از یک کاربرد بسیار مهم و معروف تر از توابع فعالیتی موجود است که در محاسبات

M : $\text{logsig}(,)$

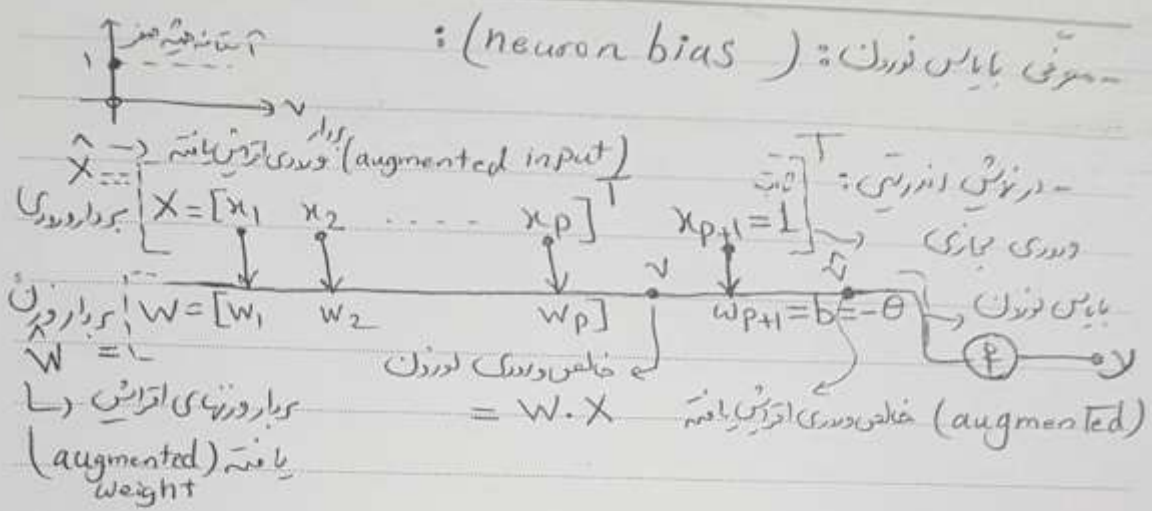
۷- تابع فعالیتی سگمندی متقارن (در طرفه) $f(v) = \frac{e^{-v} - e^v}{e^{-v} + e^v} = \frac{\sinh(v)}{\cosh(v)} = \tanh(v) = \frac{1-e^{-2v}}{1+e^{-2v}}$ $f(v) = 1-y^2$



باز هم می‌توانیم تابع فعالیتی ساده‌ای سگمندی
 لطیفه بعد از آن امکان فعالیتی معکوس برای
 درونی که مشتق


M : $\text{TanSig}(,)$ $f(v) = \frac{1-y^2}{2}$ tanh MATLAB

تفاوت: با \tanh نسبت به tansig است که برای بسیاری از محاسبات
 - اختصار: در برنامه‌نویسی tansig از \tanh بجای tansig استفاده
 نکنید.



10 - بر این ترتیب، $y = f(\hat{v}) = f(\hat{w} \cdot \hat{x})$

$$\hat{v} = \hat{w} \cdot \hat{x} = \sum_{i=1}^{p+1} w_i x_i = \sum_{i=1}^p w_i x_i + b = W \cdot X + b = W \cdot X - \theta = v - \theta$$



بر این مثال تابع فعالیت برش سخت:

که نسبت به ورودی خالص و واقعی v ،

به شکل زیر خواهد بود:

15 $\hat{v} = v + b = v - \theta$

$\hat{v} = 0 \Rightarrow v - \theta = 0 \Rightarrow v = \theta$

16 $y = g(v) = f(v - \theta)$

$v = W \cdot X = \sum_{i=1}^p w_i x_i$

$\theta = -b$


واقعی همانند مجازی

در $v > \theta$ ، $y = 1$

در $v < \theta$ ، $y = 0$

در $v = \theta$ ، $y = 0.5$

بنابراین مقادیر بایاس عملاً آستانه‌ی تریگ نورون را تعیین می‌دهد و تنظیم می‌کند. بایاس را می‌توان یک تابعی داخلی برای هر یک از نورون‌های مصنوعی دانست که مسئول آن شکل تابع فعالیت آن القی و تنظیم می‌نماید. این آستانه‌ی تریگ (شکل تابع فعالیت) هر نورون اما در اکثر سیستم‌های آموزش آن تنظیم می‌شود و بهینه‌سازی می‌گردد. تریگ به یادگیرنده بایاس می‌تواند از درختی‌های نورون شبکه‌ی 1-1




آموزش شبکه عصبی می‌تواند از دو نوعی که هدف موجود (در صورت وجود) استفاده کرد که در این صورت شبکه عصبی را با نظر گویند (Supervisory). در غیر این صورت شبکه را بدون نظر (بدون معلم راهنما) Unsupervisory می‌نامند.

- لیست به میرا اجزا یا گره‌های وازروف و آموزش یا گره‌های مجهز تقسیم درختی شبکه
- ✓ شبکه عصبی را می‌توان به دسته‌های زیر تقسیم بندی کرد:
 - ✓ ساختار اجزا (گره‌های): بدون فیدبک، استاتیکی، پایداری، اینرسی.
 - ✓ آموزش (گره‌های): با نظر و با معلم و بدون نظر و معلم.
 - ✓ طراحی مستقیم: Direct Design → در M
- * اماطلاً به جمله دارم.

شبکه عصبی - جلد پنجم ۱۰، ۸، ۹۸

پرسش: شبکه عصبی با تابع فعالیت جوش سخت و دارای بایاس.



$$y = \text{hardlim}(\hat{W} \cdot \hat{X}) = \begin{cases} 1 & \hat{W} \cdot \hat{X} \geq 0 \\ 0 & \text{o th.} \end{cases}$$

بایاس $x_{p+1} = 1$