

# شبکه‌های عصبی مصنوعی


## شبکه‌های هب. پرسپترون و آدالاین

هادی ویسی

[veisi@sharif.edu](mailto:veisi@sharif.edu)

دانشگاه تهران - دانشکده علوم و فنون نوین

نیمسال دوم ۱۳۹۲-۱۳۹۱



## ○ جداسازی خطی

## ○ شبکه هب

- الگوریتم، کاربردها و مثال

## ○ شبکه پرسپترون

- ساختار، الگوریتم، کاربردها و مثال
- همگرایی قانون یادگیری

## ○ شبکه آدالاین

- ساختار، الگوریتم، کاربردها و مثال
- قانون دلتا
- قانون دلتای گسترش یافته
- شبکه مادالاین



## تعریف (یادآوری)

### ○ بازشناسی الگو (Pattern Recognition)

- پیوند الگو (Pattern Association)

- پیوند دادن الگوی ورودی با یک الگوی خروجی

- ورودی: تصویر چهره یک فرد — خروجی: مشخصات و خصوصیات وی

- دسته‌بندی یا طبقه‌بندی الگو (Pattern Classification)

- حالت ساده (دو دسته): هر الگوی ورودی (یک بردار) عضو یک دسته است یا نه

- حالت کلی ( $n$  دسته): هر الگو (بردار ورودی)، به یکی از  $n$  دسته تعلق دارد





## جداسازی خطی ...

### ○ مسئله دسته‌بندی ساده با شبکه عصبی

- الگوی ورودی عضو دسته مورد نظر باشد، پاسخ «بله» و اگر ورودی عضو آن دسته نباشد، پاسخ «خیر»

$$y_{in} = b + \sum_i x_i w_i$$

- تابع فعال‌سازی پله‌ای

$$f(y_{in}) = \begin{cases} 1 & \text{if } y_{in} \geq 0 \\ -1 & \text{if } y_{in} < 0 \end{cases}$$

- مرز تصمیم‌گیری (Decision Boundary) = مرز بین ناحیه‌ای که در آن  $y_{in} > 0$  و ناحیه‌ای که در آن  $y_{in} < 0$  است

$$b + \sum_i x_i w_i = 0$$

- پاسخ این معادله یک خط، یک صفحه و یا یک ابرصفحه است

- وابسته به تعداد واحدهای ورودی (ابعاد بردار ورودی)





## جداسازی خطی ...

### ○ مسئله خطی تفکیک‌پذیر (Linearly Separable)


- حل یک مسئله توسط شبکه‌های یک لایه پس از تنظیم وزن‌ها (و بایاس)
- تمام بردارهای ورودی آموزش که پاسخ صحیح برای آنها  $+1$  (عضویت در دسته) است، در یک طرف مرز تصمیم‌گیری و تمام بردارهای ورودی آموزش که پاسخ صحیح برای آنها  $-1$  (عدم عضویت در دسته) است در سمت دیگر مرز تصمیم‌گیری قرار می‌گیرند
- نشان داده شده است که شبکه‌ی یک لایه فقط می‌تواند مسائلی را حل کند که به صورت خطی تفکیک‌پذیر باشند
- شبکه‌های چندلایه‌ای که از توابع فعال‌سازی خطی استفاده می‌کنند، از شبکه‌های یک لایه قوی‌تر نیستند زیرا ترکیب چند تابع خطی نیز خطی است

# جداسازی خطی ...

INPUT( $x_1, x_2$ )	OUTPUT
(1, 1)	+1
(1, -1)	-1
(-1, 1)	-1
(-1, -1)	-1



○ مثال: تابع AND



• مرز تصمیم‌گیری  $b + w_1 x_1 + w_2 x_2 = 0$


• پاسخ  $b = -1, w_1 = 1, w_2 = 1$

$$x_2 = -x_1 + 1$$

# جداسازی خطی ...

## مثال: تابع OR


INPUT( $x_1, x_2$ )	OUTPUT
(1, 1)	+1
(1, -1)	+1
(-1, 1)	+1
(-1, -1)	-1



• مرز تصمیم‌گیری

$$b = 1, w_1 = 1, w_2 = 1$$


$$x_2 = -x_1 - 1$$



• اگر وزن بایاس وجود نداشت، مرز تصمیم‌گیری باید از مبدأ عبور می‌کرد

# جداسازی خطی

## مثال: تابع XOR

INPUT( $x_1, x_2$ )

(1, 1)

(1, -1)

(-1, 1)

(-1, -1)

OUTPUT

-1

+1

+1

-1

- حل؟
- فضای داده‌های ورودی به صورت خطی جدایی پذیر نیست.
- هیچ خط مستقیم نمی‌تواند نقاط مثبت و منفی را جدا کند

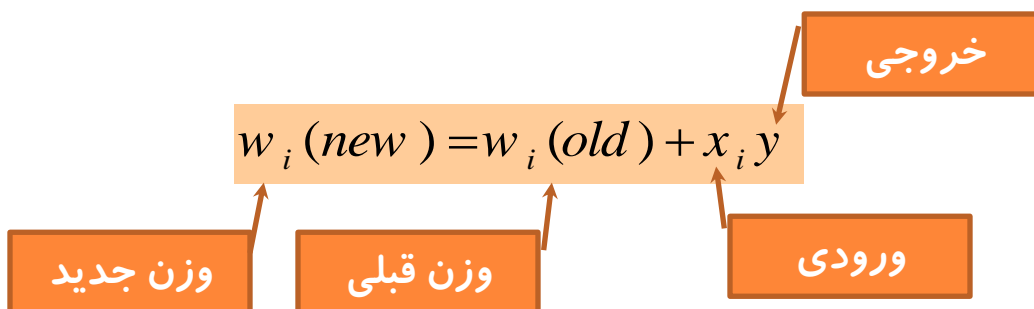


## شبکه هب ...

### اولین (و ساده‌ترین) قانون یادگیری برای شبکه عصبی

### ایده اصلی یادگیری هب

- یادگیری با تغییر استحکامات سیناپس‌های نرون‌ها (وزن‌های شبکه‌های عصبی) است
- اگر دو نرون متصل به هم به طور هم‌زمان «فعال» باشند، وزن بین آنها باید افزایش یابد
- هب درباره نرون‌هایی که به طور هم‌زمان برانگیخته نمی‌شوند، چیزی نمی‌گوید
- یادگیری قوی‌تر = اگر دو نرون به طور هم‌زمان «غیرفعال» باشند، وزن‌ها افزایش یابد



- شبکه هب یک لایه است
- به‌روز شدن (Update) وزن‌ها

• برای داده دودویی، اگر ورودی یا خروجی (یا هر دو) «غیرفعال» باشند، یادگیری صورت نمی‌گیرد



## شبکه هب: الگوریتم ...

- مرحله ۰ - به تمام وزن‌ها مقدار اولیه صفر بدهید  $w_i = 0 \quad (i = 1, \dots, n)$
- مرحله ۱ - برای هر بردار آموزش ورودی و خروجی هدف،  $s:t$ ، مراحل ۲ تا ۴ را انجام بده
- مرحله ۲ - فعال‌سازی‌های واحدهای ورودی را تعیین کن  $x_i = s_i \quad (i = 1, \dots, n)$
- مرحله ۳ - برای واحد خروجی فعال‌سازی را تعیین کن  $y = t$
- مرحله ۴ - وزن‌ها و بایاس را به‌روز کن

$$w_i(\text{new}) = w_i(\text{old}) + x_i y \quad (i = 1, \dots, n)$$

$$b(\text{new}) = b(\text{old}) + y$$

$$\mathbf{w}(\text{new}) = \mathbf{w}(\text{old}) + \mathbf{x} \cdot y \quad \Delta w = \mathbf{x} \cdot y \quad \Rightarrow \quad \mathbf{w}(\text{new}) = \mathbf{w}(\text{old}) + \Delta \mathbf{w}$$

داده‌های آموزشی فقط یک بار به شبکه نشان داده شده و آموزش به اتمام می‌رسد




## شبکه هب: کاربرد ...

INPUT			TARGET
$(x_1$	$x_2$	1)	
(1	1	1)	1
(1	0	1)	0
(0	1	1)	0
(0	0	1)	0

○ تابع AND با ورودی‌ها و هدف‌های دودویی ...

• تغییر وزن



$$\Delta w_1 = x_1 t, \quad \Delta w_2 = x_2 t, \quad \Delta b = 1.t = t$$

$$\mathbf{w}(\text{new}) = \mathbf{w}(\text{old}) + \Delta \mathbf{w}$$

$$x_1 = 1, \quad x_2 = 1, \quad b = 1, \quad t = 1$$

• برای ورودی اول

INPUT	TARGET	WEIGHT CHANGES	WEIGHTS
$(x_1 \quad x_2 \quad 1)$	$t$	$(\Delta w_1 \quad \Delta w_2 \quad \Delta b)$	$(w_1 \quad w_2 \quad b)$
(1 1 1)	1	(1 1 1)	(0 0 0)
(1 1 1)	1	(1 1 1)	(1 1 1)

مقدار اولیه

$$x_2 = -x_1 - 1$$

## شبکه هب: کاربرد ...

### ○ تابع AND با ورودی‌ها و هدف‌های دودویی

• برای دومین، سومین و چهارمین ورودی


INPUT	TARGET	WEIGHTCHANGES	WEIGHTS
$(x_1 \ x_2 \ 1)$	$t$	$(\Delta w_1 \ \Delta w_2 \ b)$	$(w_1 \ w_2 \ b)$
$(1 \ 0 \ 1)$	0	$(0 \ 0 \ 0)$	$(1 \ 1 \ 1)$
$(0 \ 1 \ 1)$	0	$(0 \ 0 \ 0)$	$(1 \ 1 \ 1)$
$(0 \ 0 \ 1)$	0	$(0 \ 0 \ 0)$	$(1 \ 1 \ 1)$

یادگیری رخ نمی‌دهد  
وزن‌ها تغییر نمی‌کند

الگوهایی با مقدار هدف صفر یا  
«غیر فعال»

استفاده از نمایش دودویی

پاسخ  
نادرست



$$x_2 = -x_1 - 1$$



## شبکه هب: کاربرد ...

### ○ تابع AND با ورودی‌های دودویی و مقادیر هدف دوقطبی

#### • اولین ورودی

INPUT ( $x_1$ $x_2$ 1)	TARGET $t$	INPUT ( $x_1$ $x_2$ 1)	TARGET $t$	WEIGHT CHANGES ( $\Delta w_1$ $\Delta w_2$ $\Delta b$ )	WEIGHTS ( $w_1$ $w_2$ $b$ )
(1 1 1)	1	( $x_1$ $x_2$ 1)	$t$	( $\Delta w_1$ $\Delta w_2$ $\Delta b$ )	( $w_1$ $w_2$ $b$ )
(1 0 1)	-1				(0 0 0)
(0 1 1)	-1	(1 1 1)	1	(1 1 1)	(1 1 1)
(0 0 1)	-1				

$$x_2 = -x_1 - 1$$

#### • ارائه دومین، سومین و چهارمین

INPUT ( $x_1$ $x_2$ 1)	TARGET $t$	WEIGHT CHANGES ( $\Delta w_1$ $\Delta w_2$ $b$ )	WEIGHTS ( $w_1$ $w_2$ $b$ )
(1 0 1)	-1	(-1 0 -1)	(0 1 0)
(0 1 1)	-1	(0 -1 -1)	(0 0 -1)
(0 0 1)	-1	(0 0 -1)	(0 0 -2)

پاسخ  
نادرست





# شبکه هب: کاربرد ...


INPUT	TARGET
$(x_1 \ x_2 \ 1)$	$t$
$(1 \ 1 \ 1)$	1
$(1 \ -1 \ 1)$	-1
$(-1 \ 1 \ 1)$	-1
$(-1 \ -1 \ 1)$	-1

○ تابع AND برای ورودی‌ها و هدف‌های دوقطبی ...

• اولین ورودی


INPUT	TARGET	WEIGHT CHANGES	WEIGHTS
$(x_1 \ x_2 \ 1)$	$t$	$(\Delta w_1 \ \Delta w_2 \ \Delta b)$	$(w_1 \ w_2 \ b)$
			$(0 \ 0 \ 0)$
$(1 \ 1 \ 1)$	1	$(1 \ 1 \ 1)$	$(1 \ 1 \ 1)$

$$x_2 = -x_1 - 1$$



INPUT	TARGET	WEIGHT CHANGES	WEIGHTS
$(x_1 \ x_2 \ 1)$	$t$	$(\Delta w_1 \ \Delta w_2 \ \Delta b)$	$(w_1 \ w_2 \ b)$
			$(1 \ 1 \ 1)$
$(1 \ -1 \ 1)$	-1	$(-1 \ 1 \ -1)$	$(0 \ 2 \ 0)$

$$x_2 = 0$$



• دومین ورودی

پاسخ درست برای  
دو نمونه آموزش


# شبکه هب: کاربرد ...

## تابع AND برای ورودی‌ها و هدف‌های دوقطبی

• سومین ورودی


INPUT	TARGET	WEIGHT CHANGES	WEIGHTS
$(x_1 \ x_2 \ 1)$	$t$	$(\Delta w_1 \ \Delta w_2 \ \Delta b)$	$(w_1 \ w_2 \ b)$
$(0 \ 2 \ 1)$	1	$(0 \ 0 \ 0)$	$(0 \ 2 \ 0)$
$(-1 \ 1 \ 1)$	-1	$(1 \ -1 \ -1)$	$(1 \ 1 \ -1)$

$$x_2 = -x_1 + 1$$



INPUT	TARGET	WEIGHT CHANGES	WEIGHTS
$(x_1 \ x_2 \ 1)$	$t$	$(\Delta w_1 \ \Delta w_2 \ \Delta b)$	$(w_1 \ w_2 \ b)$
$(0 \ 2 \ 1)$	1	$(0 \ 0 \ 0)$	$(0 \ 2 \ 0)$
$(-1 \ 1 \ 1)$	-1	$(1 \ -1 \ -1)$	$(1 \ 1 \ -1)$
$(-1 \ -1 \ 1)$	-1	$(1 \ 1 \ -1)$	$(2 \ 2 \ -2)$

$$x_2 = -x_1 + 1$$



• چهارمین ورودی

پاسخ  
درست



## شبکه هب: نمایش داده‌ها

○ شکل نمایش داده‌ها می‌تواند مسئله قابل حل را به مسئله‌ای غیرقابل حل تبدیل کند

- در قانون هب بسیار موثر است

- برای برخی الگوها منجر به جواب درست نمی‌شود، ممکن است برای نمایش متفاوتی از همان الگوها پاسخ درستی را نتیجه دهد



○ نمایش دوقطبی بهتر از نمایش دودویی است

- افزایش قابلیت تعمیم شبکه

- امکان تمایز داده‌های گم‌شده (Missing Data) از داده‌های اشتباه (Mistaken Data)

- مقادیر گم‌شده = «۰»


- اشتباهات = قرینه مقدار ورودی از  $+1$  به  $-1$ ، یا برعکس



## شبکه هب: مثال ...

### ○ بازشناسی نویسه (کاراکتر) - الگوهای ورودی دوبعدی ...

- یک شبکه هب برای تشخیص الگوی «X» از الگوی «O»




- یک مسئله دسته‌بندی الگو؟

- دسته «X» = خروجی مورد نظر و الگوی «O» = خروجی «غیر X»
- روش دیگر؟

- تبدیل الگوهای «O» و «X» به بردارهای ورودی؟

- مقدار ۱ برای هر «#» و مقدار -۱ برای هر «.»
- دوبعدی؟ پشت سرهم قرار دادن ردیف‌ها



- ساختار شبکه؟

- تعداد نرون‌های ورودی = برابر با تعداد ابعاد بردار الگوها = ۲۵



## شبکه هب: مثال ...

### ○ بازشناسی نویسه (کاراکتر) – الگوهای ورودی دوبعدی ...


#### • قابلیت تعمیم شبکه

○ تولید پاسخ منطقی شبکه برای الگوهای ورودی شبیه الگوهای آموزش اما نه کاملاً یکسان با آنها

#### • دو نوع تغییر در الگوی ورودی


##### ○ «اشتباهات در داده‌ها»

○ علامت يك يا چند مؤلفه بردار ورودی قرینه شده و از 1 به -1، یا برعکس، تغییر یافته است.



##### ○ «داده‌های گم‌شده»

○ يك يا چند مؤلفه بردار ورودی به جای مقدار 1 یا -1 مقدار صفر دارند



### • شبکه در برخورد با داده‌های گم‌شده عملکرد بهتری در مقایسه با اشتباهات دارد

○ در مورد داده‌های ورودی، «بهتر است که حدس نزنیم»!!



## شبکه پرسپترون ...

### ○ جزو معروف‌ترین شبکه‌های عصبی است

- حالت چند لایه آنها از پرکاربردترین شبکه‌های عصبی هستند
- بیشترین اثرگذاری بر شبکه‌های عصبی اولیه
- روزنبلات در سال ۱۹۶۲ و مینسکی و پاپرت در سال‌های ۱۹۶۹ و ۱۹۸۸

### ○ قانون یادگیری قوی‌تر نسبت به قانون هب

- یادگیری همراه با تکرار

○ در قانون هب، فقط یک بار (بدون تکرار) داده‌های آموزش به شبکه داده می‌شد


- یادگیری پرسپترون شبیه قانون هب، تفاوت عمده: وزن‌ها فقط زمانی تغییر می‌کند که پاسخ شبکه به ازای آن ورودی دارای خطا باشد
- خطا = خروجی محاسبه شده توسط شبکه با مقدار هدف یکی نباشد



# شبکه پرسپترون: ساختار ...

## ○ ساختار اولیه

- سه لایه نرون (واحدهای حسی، واحدهای پیونددهنده، و واحد پاسخ)
  - فقط وزن‌های بین لایه‌های دوم و سوم آموزش داده می‌شود
  - خروجی واحدهای پیونددهنده به واحدهای پاسخ یک بردار دودویی است
  - عملاً یک شبکه یک لایه است
- مدل تقریبی شبکه چشم



## ○ ساختار برای دسته‌بندی الگو

- متعلق بودن به دسته با پاسخ +۱
- متعلق نبودن با پاسخ -۱

## شبکه پرسپترون: الگوریتم ...

- مرحله ۰ - مقداردهی اولیه به وزن‌ها و بایاس (مقدار صفر)
- تعیین نرخ یادگیری  $0 < \alpha \leq 1$  (مقدار ۱)
- مرحله ۱ - تا زمانی که شرایط توقف برقرار نیست، مراحل ۲ تا ۶ را انجام دهید
- مرحله ۲ - انجام مراحل ۳ تا ۵ برای هر جفت داده آموزش  $s:t$
- مرحله ۳ - فعال‌سازی‌های واحدهای ورودی را مشخص کنید:  $x_i = s_i$
- مرحله ۴ - پاسخ واحد خروجی را محاسبه کنید:

الگوریتم  
تکراری

$$y_{in} = b + \sum_i x_i w_i$$

$$y = \begin{cases} 1 & \text{if } y_{in} > \theta \\ 0 & \text{if } -\theta \leq y_{in} \leq \theta \\ -1 & \text{if } y_{in} < -\theta \end{cases}$$



جانشینی بایاس و آستانه؟

۰ = ناحیه عدم تصمیم‌گیری ( $2\theta$ )

-۱ = عدم تعلق به دسته

۱ = تعلق به دسته



## شبکه پرسپترون: الگوریتم ...

- مرحله ۵- اگر خطایی رخ داده است، وزن‌ها و بایاس را به‌روز کنید.

اگر  $y \neq t$  است، آنگاه:  $w_i(new) = w_i(old) + \alpha x_i t$

$$b(new) = b(old) + \alpha t$$

به‌روز کردن  
مشروط وزن‌ها

$$w_i(new) = w_i(old)$$

$$b(new) = b(old)$$

در غیراین صورت:

- مرحله ۶- شرایط توقف را آزمایش کنید:

○ اگر در مرحله ۲ هیچ وزنی تغییر نکرد، الگوریتم را متوقف کنید، در غیراین صورت ادامه دهید.

خطا = برابر نبودن پاسخ شبکه و مقدار هدف

نرخ یادگیری




# شبکه پرسپترون: کاربرد ...

○ تابع AND با ورودی‌های **دودویی** و هدف‌های **دوقطبی** ...

- وزن‌های اولیه و بایاس را صفر؛ نرخ اولیه یادگیری = ۱؛ آستانه = ۰.۲.
- ارائه ورودی اول

				WEIGHT							
INPUT			NET	OUT	TARGET	CHANGES			WEIGHTS		
$(x_1$	$x_2$	$1)$	$y_{in}$	$y$	$t$	$(\Delta w_1$	$\Delta w_2$	$\Delta b)$	$(w_1$	$w_2$	$b)$
									$(0$	$0$	$0)$
$(1$	$1$	$1)$	$0$	$0$	$1$	$(1$	$1$	$1)$	$(1$	$1$	$1)$






# شبکه پرسپترون: کاربرد ...

○ تابع AND با ورودی‌های دودویی و هدف‌های دوقطبی ...

• ارائه دومین ورودی

INPUT	NET	OUT	TARGET	WEIGHT			WEIGHTS		
				CHANGES					
$(x_1 \ x_2 \ 1)$	$y_{in}$	$y$	$t$	$(\Delta w_1 \ \Delta w_2 \ \Delta b)$	$(w_1 \ w_2 \ b)$				
					$(1 \ 1 \ 1)$				
$(1 \ 0 \ 1)$	2	1	-1	$(-1 \ 0 \ -1)$	$(0 \ 1 \ 0)$				



$$x_2 = 0.2$$

$$x_2 = -0.2$$





# شبکه پرسپترون: کاربرد ...

## ○ تابع AND با ورودی‌های دودویی و هدف‌های دوقطبی ...

### • ارائه سومین ورودی

				WEIGHT							
INPUT			NET	OUT	TARGET	CHANGES			WEIGHTS		
$(x_1$	$x_2$	1)	$y_{in}$	$y$	$t$	$(\Delta w_1$	$\Delta w_2$	$\Delta b)$	$(w_1$	$w_2$	$b)$
									(0	1	0)
(0	1	1)	1	1	-1	(0	-1	-1)	(0	0	-1)

### • ارائه چهارمین ورودی

○ با توجه به برابر بودن پاسخ شبکه و مقدار هدف، وزن‌ها تغییری نمی‌کنند

						WEIGHT					
INPUT			NET	OUT	TARGET	CHANGES			WEIGHTS		
$(x_1$	$x_2$	$1)$	$y_{in}$	$y$	$t$	$(\Delta w_1$	$\Delta w_2$	$\Delta b)$	$(w_1$	$w_2$	$b)$
									$(0$	$0$	$-1)$
$(0$	$0$	$1)$	$-1$	$-1$	$-1$	$(0$	$0$	$0)$	$(0$	$0$	$-1)$

کامل شدن اولین دور  
آموزش (Epoch)




## شبکه پرسپترون: کاربرد ...

### ○ تابع AND با ورودی‌های دودویی و هدف‌های دوقطبی ...

- نیاز به تکرار؟؟ صحیح نبودن پاسخ برای اولین الگوی ورودی
- تکراری بودن فرآیند آموزش (Iterative)

- دومین دور آموزش - ارائه اولین ورودی

				WEIGHT							
INPUT			NET	OUT	TARGET	CHANGES			WEIGHTS		
$(x_1$	$x_2$	$1)$	$y_{in}$	$y$	$t$	$(\Delta w_1$	$\Delta w_2$	$\Delta b)$	$(w_1$	$w_2$	$b)$
									$(0$	$0$	$-1)$
$(1$	$1$	$1)$	$-1$	$-1$	$1$	$(1$	$1$	$1)$	$(1$	$1$	$0)$






# شبکه پرسپترون: کاربرد ...

○ تابع AND با ورودی‌های دودویی و هدف‌های دوقطبی ...

• دومین دور آموزش - ارائه دومین ورودی

						WEIGHT					
INPUT			NET	OUT	TARGET	CHANGES			WEIGHTS		
$(x_1$	$x_2$	$1)$	$y_{in}$	$y$	$t$	$(\Delta w_1$	$\Delta w_2$	$\Delta b)$	$(w_1$	$w_2$	$b)$
									$(1$	$1$	$0)$
$(1$	$0$	$1)$	$1$	$1$	$-1$	$(-1$	$0$	$-1)$	$(0$	$1$	$-1)$



$$x_2 - 1 = 0/2$$

$$x_2 - 1 = -0/2$$



## شبکه پرسپترون: کاربرد ...

### ○ تابع AND با ورودی‌های دودویی و هدف‌های دوقطبی ...

#### • دومین دور آموزش - ارائه سومین ورودی

○ پاسخ برای تمام ورودی‌ها منفی

						WEIGHT					
INPUT			NET	OUT	TARGET	CHANGES			WEIGHTS		
$(x_1$	$x_2$	1)	$y_{in}$	$y$	$t$	$(\Delta w_1$	$\Delta w_2$	$\Delta b)$	$(w_1$	$w_2$	$b)$
									(0	1	-1)
(0	1	1)	0	0	-1	(0	-1	-1)	(0	0	-2)

#### • دومین دور آموزش - ارائه چهارمین ورودی

○ پاسخ برای تمام ورودی‌ها منفی

				WEIGHT							
INPUT			NET	OUT	TARGET	CHANGES			WEIGHTS		
$(x_1$	$x_2$	$1)$	$y_{in}$	$y$	$t$	$(\Delta w_1$	$\Delta w_2$	$\Delta b)$	$(w_1$	$w_2$	$b)$
									$(0$	$0$	$-2)$
$(0$	$0$	$1)$	$-2$	$-1$	$-1$	$(0$	$0$	$0)$	$(0$	$0$	$-2)$

کامل شدن دومین دور  
آموزش (Epoch)



# شبکه پرسپترون: کاربرد ...

○ تابع AND با ورودی‌های **دودویی** و هدف‌های **دوقطبی** ...

• سومین دور آموزش

INPUT	NET	OUT	TARGET	WEIGHT			WEIGHTS		
				CHANGES					
$(x_1 \ x_2 \ 1)$	$y_{in}$	$y$	$t$	$(\Delta w_1 \ \Delta w_2 \ \Delta b)$			$(w_1 \ w_2 \ b)$		
							$(0 \ 0 \ -2)$		
$(1 \ 1 \ 1)$	-2	-1	1	$(1 \ 1 \ 1)$			$(1 \ 1 \ -1)$		
$(1 \ 0 \ 1)$	0	0	-1	$(-1 \ 0 \ -1)$			$(0 \ 1 \ -2)$		
$(0 \ 1 \ 1)$	-1	-1	-1	$(0 \ 0 \ 0)$			$(0 \ 1 \ -2)$		
$(0 \ 0 \ 1)$	-2	-1	-1	$(0 \ 0 \ 0)$			$(0 \ 1 \ -2)$		

• چهارمین دور آموزش

$(1 \ 1 \ 1)$	-1	-1	1	$(1 \ 1 \ 1)$	$(1 \ 2 \ -1)$
$(1 \ 0 \ 1)$	0	0	-1	$(-1 \ 0 \ -1)$	$(0 \ 2 \ -2)$
$(0 \ 1 \ 1)$	0	0	-1	$(0 \ -1 \ -1)$	$(0 \ 1 \ -3)$
$(0 \ 0 \ 1)$	-3	-1	-1	$(0 \ 0 \ 0)$	$(0 \ 1 \ -3)$



# شبکه پرسپترون: کاربرد ...

## ○ تابع AND با ورودی‌های دودویی و هدف‌های دوقطبی ...

• پنجمین، ششمین، .... دور آموزش

(1 1 1)	0	0	1	(1 1 1)	(3 3 -3)
(1 0 1)	0	0	-1	(-1 0 -1)	(2 3 -4)
(0 1 1)	-1	-1	-1	(0 0 0)	(2 3 -4)
(0 0 1)	-4	-1	-1	(0 0 0)	(2 3 -4)

• نهمین دور آموزش


• دهمین دور آموزش

○ عدم تغییر وزن‌ها = توقف الگوریتم

○ همگرایی وزن‌ها

(1 1 1)	1	1	1	(0 0 0)	(2 3 -4)
(1 0 1)	-2	-1	-1	(0 0 0)	(2 3 -4)
(0 1 1)	-1	-1	-1	(0 0 0)	(2 3 -4)
(0 0 1)	-4	-1	-1	(0 0 0)	(2 3 -4)

$$\begin{cases} 2x_1 + 3x_2 - 4 > 0, 2 \Rightarrow x_2 = -\frac{2}{3}x_1 + \frac{7}{5} \\ 2x_1 + 3x_2 - 4 < -0, 2 \Rightarrow x_2 = -\frac{2}{3}x_1 + \frac{19}{15} \end{cases}$$





# شبکه پرسپترون: کاربرد

## ○ تابع AND با ورودی‌ها و هدف‌های دوقطبی

- آستانه، بایاس و وزن‌های اولیه برابر با صفر؛ نرخ یادگیری برابر با ۱

INPUT	NET	OUT	TARGET	WEIGHT			WEIGHTS		
				CHANGES			CHANGES		
$(x_1 \ x_2 \ 1)$	$y_{in}$	$y$	$t$	$(\Delta w_1 \ \Delta w_2 \ \Delta b)$	$(w_1 \ w_2 \ b)$		$(\Delta w_1 \ \Delta w_2 \ \Delta b)$	$(w_1 \ w_2 \ b)$	
(1 1 1)	0	0	1	(1 1 1)	(1 1 1)		(1 1 1)	(1 1 1)	
(1 -1 1)	1	1	-1	(-1 1 -1)	(0 2 0)		(-1 1 -1)	(0 2 0)	
(-1 1 1)	2	1	-1	(1 -1 -1)	(1 1 -1)		(1 -1 -1)	(1 1 -1)	
(-1 -1 1)	-3	-1	-1	(0 0 0)	(1 1 -1)		(0 0 0)	(1 1 -1)	

- دور اول آموزش

(1 1 1)	1	1	1	(0 0 0)	(1 1 -1)
(1 -1 1)	-1	-1	-1	(0 0 0)	(1 1 -1)
(-1 1 1)	-1	-1	-1	(0 0 0)	(1 1 -1)
(-1 -1 1)	-3	-1	-1	(0 0 0)	(1 1 -1)

- دور دوم آموزش

- بهبود نتایج با تغییر نمایش دودویی به دوقطبی



# شبکه پرسپترون: مثال ...

## ○ بازشناسی نویسه ...

- تشخیص حرف A از حرف غیر A
- ۳ نوع فونت

○ ۳ نوع A = خروجی شبکه معادل با تعلق به دسته


○ ۱۸ نویسه غیر A = خروجی معادل با عدم تعلق به دسته

## • تعمیم برای سایر نویسه‌ها؟؟


○ یک شبکه جداگانه برای هر نویسه

○ شبکه‌ای با چندین (به تعداد نویسه‌ها) خروجی


ورودی با  
فونت شماره ۱



ورودی با  
فونت شماره ۲



ورودی با  
فونت شماره ۳





# شبکه پرسپترون: مثال ...

## ○ بازشناسی نویسه ...

- نمایش دوقطبی
- ۶۳ واحد ورودی (هر کدام یک پیکسل)
- ۷ واحد خروجی (هر کدام یک نویسه)



○ بردار خروجی برای نمونه‌های A

$$(A \dots) \Rightarrow (1, -1, -1, -1, -1, -1, -1)$$

○ بردار خروجی برای نمونه‌های B

$$(.B \dots) \Rightarrow (-1, 1, -1, -1, -1, -1, -1)$$

- دسته‌بندی درست داده‌های آموزش داده شده



# شبکه پرسپترون: مثال

○ بازشناسی نویسه ...

• ارزیابی شبکه با ورودی‌های نویزی


○ بردارهای ورودی شبیه به بردارهای آموزش

○ و نه دقیقاً مانند آنها


○ جایگزینی پیکسل «غیرفعال» با «فعال» = @

○ جایگزینی پیکسل «فعال» با «غیرفعال» = O


ورودی با  
فونت شماره ۱



ورودی با  
فونت شماره ۲



ورودی با  
فونت شماره ۳





# شبکه پرسپترون: همگرایی قانون یادگیری

## ○ قضیه

- اگر بردار وزن  $w^*$  وجود داشته باشد به طوری که برای تمام  $p$  ها داشته باشیم:

$$f(x(p) \cdot w^*) = t(p)$$

آنگاه برای هر بردار اولیه  $w$ ، قانون یادگیری پرسپترون به بردار وزنی نزدیک می‌شود (نه الزاماً منحصر به فرد و نه الزاماً  $w^*$ ) که برای تمام الگوهای آموزش پاسخ صحیحی می‌دهد و این کار در مراحل با تعداد متناهی انجام می‌شود.

○  $p$  = تعداد بردارهای ورودی آموزش

○  $x(p)$  = بردارهای ورودی آموزش

○  $t(p)$  = مقدار هدف معادل بردارهای ورودی آموزش (دوقطبی)

○  $f$  = تابع فعال‌سازی خروجی



## شبکه پرسپترون: نکات تکمیلی

### ○ مقداردهی نرخ یادگیری

- مقدار ثابت غیرمنفی
- مقدار  $1/\|x\|$ ؛ تا تغییر وزن یک بردار واحد باشد
- مقدار  $(x \cdot w) / \|x\|^2$

### ○ مقادیر اولیه وزن‌ها

- مقدار ثابت صفر
- یک الگوی آموزش اختیاری
- مقادیر تصادفی کوچکی



## شبکه آدالاین ...


### ○ آدالاین = نرون خط وفقی (ADaptive LInear Neuron)

- توسط ویدور و هاف در سال ۱۹۶۰
- دارای قانون یادگیری متفاوت با هب و پرسپترون
- قانون یادگیری = قانون دلتا = قانون میانگین مربعات کمینه (LMS) = قانون ویدرو-هاف
  - میانگین مربعات خطای بین مقدار خروجی شبکه و مقدار هدف در هر مرحله از آموزش کاهش یابد
- استفاده از فعال‌سازی‌های دوقطبی برای سیگنال‌های وروی و خروجی
- تابع فعال‌سازی خروجی = تابع همانی

## شبکه آدالاین: ساختار

### ○ ساختار مشابه با سایر شبکه‌های قبلی

- چند ورودی
- بایاس = ورودی برابر با ۱



- قابلیت توسعه به حالت چندلایه = شبکه مادالاین



## شبکه آدالاین: الگوریتم ...

- مرحله ۰ - مقداردهی اولیه به وزن‌ها (مقادیر تصادفی کوچک)  
مقداردهی به نرخ یادگیری
- مرحله ۱ - تا زمانی که شرایط توقف برقرار نیست، مراحل ۲ تا ۶ را انجام دهید.
- مرحله ۲ - برای هر جفت آموزش دوقطبی  $s:t$  مراحل ۳ تا ۵ را انجام دهید.
- مرحله ۳ - فعال‌سازی‌های واحدهای ورودی را مشخص کنید:  $x_i = s_i \quad i = 1, \dots, n$
- مرحله ۴ - مقدار ورودی شبکه را به واحد خروجی محاسبه کنید:  $y_{in} = b + \sum_i x_i w_i$
- مرحله ۵ - مقادیر وزن‌ها و بایاس را به‌روز کنید: 
$$\begin{cases} b(new) = b(old) + \alpha \cdot (t - y_{in}) \\ w_i(new) = w_i(old) + \alpha \cdot (t - y_{in}) \cdot x_i \end{cases}$$
- مرحله ۶ - شرایط توقف را آزمایش کنید:  
اگر بزرگ‌ترین تغییر وزنی که در مرحله ۲ رخ داده است از یک مقدار کوچک کم‌تر باشد، الگوریتم را متوقف کنید، وگرنه ادامه دهید.



## شبکه آدالاین: الگوریتم

### ○ تفاوت یادگیری آدالاین با یادگیری پرسپترون و هب

- تغییر وزن‌ها متناسب با میزان تفاوت پاسخ شبکه به یک ورودی و مقدار هدف متناظر این ورودی است.
- دربرگیرنده مفهوم خطا (که در یادگیری پرسپترون نیز وجود دارد)

### ○ نرخ یادگیری

- تاثیر بر سرعت و روند همگرایی الگوریتم
- نیاز به اختصاص مقدار مناسب
- دارای کران بالا از نظر تئوری
- روش: ابتدا مقدار را کوچک فرض کرده (مثلاً ۰.۱) و به مرور مقدار آن را بزرگ کنیم
- اگر مقدار خیلی بزرگی باشد، فرآیند یادگیری همگرا نخواهد بود
- اگر مقدار بسیار کوچکی باشد، یادگیری بسیار کند می‌شود





## شبکه آدالاین: کاربرد ...

○ تابع AND: ورودی‌های **دودویی**، هدف‌های **دوقطبی**

• شبکه بعد از آموزش

$x_1$	$x_2$	$t$
1	1	1
1	0	-1
0	1	-1
0	0	-1

$$w_1 = 1 \quad w_2 = 1 \quad w_0 = -\frac{3}{2}$$

$$x_1 + x_2 - \frac{3}{2} = 0$$

• مربعات خطا برای چهار الگوی آموزش با این وزن‌ها = ۱

$$e = E\{(\hat{t} - t)^2\} = \sum_{p=1}^4 [x_1(p)w_1 + x_2(p)w_2 + w_0 - t(p)]^2$$



## شبکه آدالاین: کاربرد ...

○ تابع AND: ورودی‌ها و هدف‌های دوقطبی

• شبکه بعد از آموزش

$$w_1 = \frac{1}{2} \quad w_2 = \frac{1}{2} \quad w_0 = -\frac{1}{2}$$

$$\frac{1}{2}x_1 + \frac{1}{2}x_2 - \frac{1}{2} = 0$$

• جواب یکسان با الگوریتم پرسپترون



# شبکه آدالاین: کاربرد

○ تابع AND NOT: ورودی‌ها و هدف‌های دوقطبی

$x_1$	$x_2$	$t$
1	1	-1
1	-1	1
-1	1	-1
-1	-1	-1

$$w_1 = \frac{1}{2} \quad w_2 = -\frac{1}{2} \quad w_0 = -\frac{1}{2}$$

○ تابع OR: ورودی‌ها و هدف‌های دوقطبی

$x_1$	$x_2$	$t$
1	1	1
1	-1	1
-1	1	1
-1	-1	-1

$$w_1 = \frac{1}{2} \quad w_2 = \frac{1}{2} \quad w_0 = \frac{1}{2}$$



# شبکه آدالاین: قانون یادگیری

## ○ قانون دلتا

- کمینه کردن خطای بین خروجی شبکه و مقدار هدف متناظر

• خطا = مربعات تفاضل  $E = (t - y_{in})^2$

$$y_{in} = \sum_{i=1}^n x_i w_i$$

- گرادیان تابع خطا = مشتق‌های جزئی خطا نسبت به هر یک از وزن‌ها
- گرادیان بیانگر جهت سریع‌ترین رشد خطا
- جهت مخالف گرادیان = سریع‌ترین کاهش خطا


$$-\frac{\partial E}{\partial w_I} = -2(t - y_{in}) \frac{\partial y_{in}}{\partial w_I} = -2(t - y_{in}) x_I$$

$$\Delta w_I = \alpha(t - y_{in}) x_I$$

## شبکه مادالاین ...

### ○ حالت چند لایه آدالاین

- ترکیب چندین واحد آدالاین در یک شبکه یک لایه با هم = عدم تغییر در فرآیند آموزش
- برای بیش از یک لایه = نیاز به آموزش متفاوت
- شبکه چند لایه = افزایش قابلیت‌های محاسباتی شبکه = حل مسائل پیچیده‌تر




### ○ ساختار

### ○ الگوریتم

- MRI = شیوه اصلی آموزش مادالاین
- آموزش وزن‌های لایه اول و ثابت گرفتن وزن‌های لایه دوم (محاسبه به صورت شهودی)
- MR II: روشی دیگر

# شبکه مادالاین: آموزش با MRI ...



## تعیین وزن ثابت

- به صورت شهودی
- شبیه سازی تابع OR با Y (y=z1 OR z2)


$$v_1 = \frac{1}{2} \quad v_2 = \frac{1}{2} \quad b_3 = \frac{1}{2}$$

- می‌تواند AND هم باشد

$$f(x) = \begin{cases} 1 & \text{if } x \geq 0; \\ -1 & \text{if } x < 0. \end{cases}$$

- تابع فعال‌سازی

## شبکه مادالاین: آموزش با MRI ...



### • مرحله ۰ - مقداردهی اولیه وزن‌ها

وزن‌های  $v_1$  و  $v_2$  و بایاس  $b_3$  به صورت شهودی (مشابه قبل) تعیین می‌شوند  
وزن‌های اولیه آدالاین با مقادیر کوچک تصادفی  
مقداردهی نرخ یادگیری مانند الگوریتم آدالاین (یک مقدار کوچک)

• مرحله ۱ - تا زمانی که شرایط توقف برقرار نیست، مراحل ۲ تا ۸ را انجام دهید.

• مرحله ۲ - برای هر جفت آموزش دوقطبی  $s:t$  مراحل ۳ تا ۷ را انجام دهید.

• مرحله ۳ - فعال‌سازی‌های واحدهای ورودی را تعیین کنید:  $x_i = s_i$

• مرحله ۴ - ورودی شبکه به هر واحد آدالاین مخفی را محاسبه کنید:


$$z\_in_1 = b_1 + x_1 w_{11} + x_2 w_{21} \quad z\_in_2 = b_2 + x_1 w_{12} + x_2 w_{22}$$

• مرحله ۵ - خروجی هر واحد آدالاین مخفی را تعیین کنید:  $z_1 = f(z\_in_1)$   $z_2 = f(z\_in_2)$

• مرحله ۶ - خروجی شبکه را تعیین کنید:  $y\_in = b_3 + z_1 v_1 + z_2 v_2$   $y = f(y\_in)$

• مرحله ۷ - خطا را تعیین کنید و وزن‌ها را به‌روز کنید:

## شبکه مادالاین: آموزش با MRI



### • مرحله ۷- خطا را تعیین کنید و وزن‌ها را به‌روز کنید:

○ اگر  $y=t$  است، به‌روز کردن وزن اجرا نمی‌شود،

○ در غیراین‌صورت:

○ اگر  $t=1$  بود، وزن‌های روی  $Z_j$  را به‌روز کنید، (واحدی که ورودی شبکه آن به صفر نزدیک‌تر است)

$$b_j(new) = b_j(old) + \alpha(1 - z_{in_j}) \quad w_{ij}(new) = w_{ij}(old) + \alpha(1 - z_{in_j})x_i$$

○ اگر  $t=-1$  بود، وزن‌های روی تمام واحدهای  $Z_k$  که ورودی شبکه مثبت دارند را به‌روز کنید،

$$b_k(new) = b_k(old) + \alpha(1 - z_{in_k}) \quad w_{ik}(new) = w_{ik}(old) + \alpha(1 - z_{in_k})x_i$$

### • مرحله ۸- شرایط توقف را آزمایش کنید.

○ اگر

○ تغییر وزن‌ها متوقف شده است یا به سطح قابل قبولی رسیده است یا

○ به‌روز شدن وزن‌ها در مرحله ۲ به سقف تعداد تکرارهای مشخص شده رسیده است

○ کار را متوقف کنید،

○ در غیراین‌صورت ادامه دهید.

به خاطر OR بودن خروجی





## شبکه مادالاین: آموزش با MR II ...

- مرحله ۰ - مقداردهی اولیه وزن‌ها و نرخ یادگیری

- مرحله ۱ - تا زمانی که شرایط توقف برقرار نیست، مراحل ۲ تا ۸ را انجام دهید.

- مرحله ۲ - برای هر جفت آموزش دوقطبی  $s:t$  مراحل ۳ تا ۷ را انجام دهید.

- مرحله ۳ تا ۶ - خروجی شبکه را همانند الگوریتم MRI محاسبه کنید.

- مرحله ۷ - خطا را مشخص کنید و در صورت لزوم وزن‌ها را به‌روز کنید:

- اگر  $t \neq y$ ، مراحل ۷-الف و ۷-ب را برای هر واحد مخفی که ورودی شبکه آن به اندازه کافی به صفر نزدیک است (مثلاً بین مقادیر ۰.۲۵ و -۰.۲۵)، انجام دهید. با واحدی شروع کنید که ورودی شبکه آن به صفر نزدیک‌تر است، سپس آن را برای دومین واحد نزدیک به صفر تکرار نموده و به همین ترتیب ..

- مرحله ۷-الف - خروجی واحد را تغییر دهید ( $+1$  به  $-1$ ، یا برعکس).

- مرحله ۷-ب - پاسخ شبکه را دوباره محاسبه کنید.

اگر خطا کاهش یافته است، وزن‌های این واحد را تنظیم کنید. از مقدار خروجی جدید به عنوان مقدار هدف استفاده شود و قانون دلتا به کار گرفته شود

- مرحله ۸ - شرایط توقف را آزمایش کنید.

- اگر تغییر وزن‌ها متوقف شده یا میزان تغییرات به سطح قابل قبولی رسیده است و یا اگر به سقف تعداد مشخص شده برای تکرارهای به‌روز شدن وزن در مرحله ۲ رسیده باشد، کار را متوقف کنید،

## شبکه مادالاین: کاربرد ...

### ○ مادالاین برای تابع XOR ...

- مرحله ۰ - وزن‌های اولیه  $Z_1$  و  $Z_2$  با مقادیر تصادفی کوچک  
وزن‌های  $Y$  تابع OR را می‌سازند، مقادیر این وزن‌ها

$$x_1 \text{ XOR } x_2 \leftrightarrow (x_1 \text{ ANDNOT } x_2) \text{ OR } (x_2 \text{ ANDNOT } x_1)$$

$$v_1 = \frac{1}{2} \quad v_2 = \frac{1}{2} \quad b_3 = \frac{1}{2}$$

نرخ یادگیری را نیز برابر ۰.۵ قرار می‌دهیم

**Weights into  $Z_1$**

$w_{11}$	$w_{21}$	$b_1$
0,05	0,2	0,3


**Weights into  $Z_2$**

$w_{12}$	$w_{22}$	$b_2$
0,1	0,2	0,15

**Weights into  $Y$**

$v_1$	$v_2$	$b_3$
0,5	0,5	0,5

- مرحله ۱ - آموزش را آغاز کنید.
- مرحله ۲ - برای جفت آموزشی اول،  $-1 : (1, 1)$ :



$x_1$	$x_2$	$t$
1	1	-1
1	-1	1
-1	1	1
-1	-1	-1

$w_{11}$	$w_{21}$	$b_1$	$w_{12}$	$w_{22}$	$b_2$	$v_1$	$v_2$	$b_3$
0,05	0,2	0,3	0,1	0,2	0,15	0,5	0,5	0,5

## شبکه مادالاین: کاربرد ...

### ○ مادالاین برای تابع XOR ...

• مرحله ۲- برای جفت آموزشی اول،  $(1,1): -1$  :

• مرحله ۳-  $x_1 = 1, x_2 = 1$

• مرحله ۴-  $z_{in_1} = 0,3 + 0,05 + 0,2 = 0,55$      $z_{in_2} = 0,15 + 0,1 + 0,2 = 0,45$

• مرحله ۵-  $z_1 = 1, z_2 = 1$

• مرحله ۶-  $y_{in} = 0,5 + 0,5 + 0,5 \Rightarrow y = 1$

• مرحله ۷-  $t \neq y$  پس خطایی پیش آمده است.

چون  $t = -1$  و هر دو واحد  $Z$  ورودی مثبت دارند، به روز کردن وزنهای واحد  $Z1$

$$b_1(new) = b_1(old) + \alpha(-1 - z_{in_1}) = 0,3 + (0,5)(-1,55) = -0,475$$

$$w_{11}(new) = w_{11}(old) + \alpha(-1 - z_{in_1})x_1 = 0,5 + (0,5)(-1,55) = -0,725$$

$$w_{21}(new) = w_{21}(old) + \alpha(-1 - z_{in_1})x_2 = 0,2 + (0,5)(-1,55) = -0,575$$

واحد  $Z2$

$$b_2(new) = b_2(old) + \alpha(-1 - z_{in_2}) = 0,15 + (0,5)(-1,45) = -0,575$$

$$w_{12}(new) = w_{12}(old) + \alpha(-1 - z_{in_2})x_1 = 0,1 + (0,5)(-1,45) = -0,625$$

$$w_{21}(new) = w_{21}(old) + \alpha(-1 - z_{in_2})x_2 = 0,2 + (0,5)(-1,45) = -0,525$$

ادامه به همین ترتیب  
وزنهای نهایی در تکرار چهارم

$w_{11} = -0,73$	$w_{12} = 1,27$
$w_{21} = 1,53$	$w_{22} = -1,33$
$b_1 = -0,99$	$b_2 = -1,09$

# شبکه مادالاین: کاربرد

## ○ مادالاین برای تابع XOR

• نمایش هندسی پاسخ




• پاسخ مثبت = اجتماع ناحیه‌هایی که هر یک از واحدهای مخفی یک پاسخ مثبت دارند

• مرز تصمیم‌گیری برای واحد مخفی Z1

$$x_2 = -\frac{w_{11}}{w_{21}}x_1 - \frac{b_1}{w_{21}} = \frac{0,73}{1,53}x_1 + \frac{0,99}{1,53} = 0,48x_1 + 0,65$$

• مرز تصمیم‌گیری برای واحد مخفی Z2

$$x_2 = -\frac{w_{12}}{w_{22}}x_1 - \frac{b_2}{w_{22}} = \frac{1,27}{1,33}x_1 + \frac{-1,09}{1,33} = 0,96x_1 - 0,82$$



## تمرین شماره ۱

○ ارائه شده بر روی وب سایت

• سوالات نظری + پیاده‌سازی

• تاریخ تحویل

