





فهرست

- ❖ دسته بندی و جداسازی خطی توسط شبکه عصبی
- ❖ فرآیند یادگیری
- ❖ انواع یادگیری ماشین
 - یادگیری با نظارت
 - یادگیری بدون نظارت
 - یادگیری تقویتی
- ❖ ارزیابی یادگیری
- ❖ شبکه هب (یادگیری با نظارت)

دسته بندی ساده



AND تركيب عطفى



x	y	$x \text{ AND } y = z$
0	0	0
0	1	0
1	0	0
1	1	1

$$Z = \begin{cases} 0 \\ 1 \end{cases}$$

$$x + y \leq 1.5$$

$$x + y > 1.5$$

دسته بندی 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 فعال سازی پله ای


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

- مرز تصمیم گیری (Decision Boundary) = مرز بین ناحیه ای که در آن $y_{in} > 0$ و ناحیه ای 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

تبيين عملکرد يك نورون در فضای m بعدی ورودی



تابع غیر خطی: سخت (پله‌ای)

$$y = \begin{cases} 1 & Y \geq 0 \\ 0 & Y < 0 \end{cases}$$


تابع فعالیت نورون: غیر خطی سخت

$$m = 1$$

مرز تصمیم یک نقطه است.

$$y = f(w_0 x_0 - \theta)$$

مرز تصمیم $w_0 x_0 - \theta = 0$ \rightarrow $x_0 = \theta / w_0$



تبيين عملکرد يك نورون در فضای m بعدی ورودی

تابع فعالیت نورون: غیر خطی سخت

$$m = 2$$

مرز تصمیم یک خط است که فضای ورودی را به دو طبقه تقسیم


$$y = f(w_1x_1 + w_2x_2 - \theta)$$

$$w_1x_1 + w_2x_2 - \theta = 0$$

مرز تصمیم
مثلاً:

$$Y = x_1 + x_2 - 1 = 0$$


$$w_1=1; w_2=1; \theta=1$$



تبيين عملکرد يك نورون در فضای m بعدی ورودی

تابع فعالیت نورون: غیر خطی سخت
 $m = 3$

مرز تصمیم یک صفحه است.



جدا سازی خطی


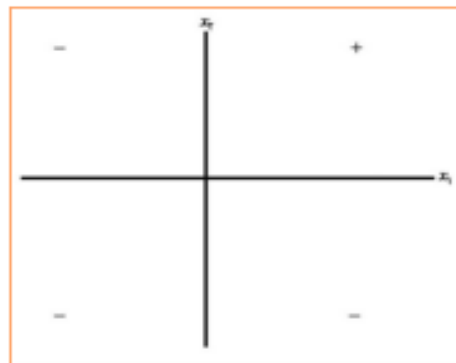
○ مسئله خطی تفکیک‌پذیر (Linearly Separable)

- 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


جدا سازی خطی

INPUT(x_1, x_2) **OUTPUT**

(1, 1)	+1
(1, -1)	-1
(-1, 1)	-1
(-1, -1)	-1



○ مثال: تابع AND




• مرز تصمیم گیری $b + w_1 x_1 + w_2 x_2 = 0$

• پاسخ $b = -1, w_1 = 1, w_2 = 1$


$$x_2 = -x_1 + 1$$

جدا سازی خطی



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

○ مثال: تابع OR



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


• مرز تصمیم گیری

$$x_2 = -x_1 - 1$$

• اگر وزن بایاس وجود نداشت، مرز تصمیم گیری باید از مبدأ عبور می کرد

جدا سازی خطی

○ مثال: تابع XOR



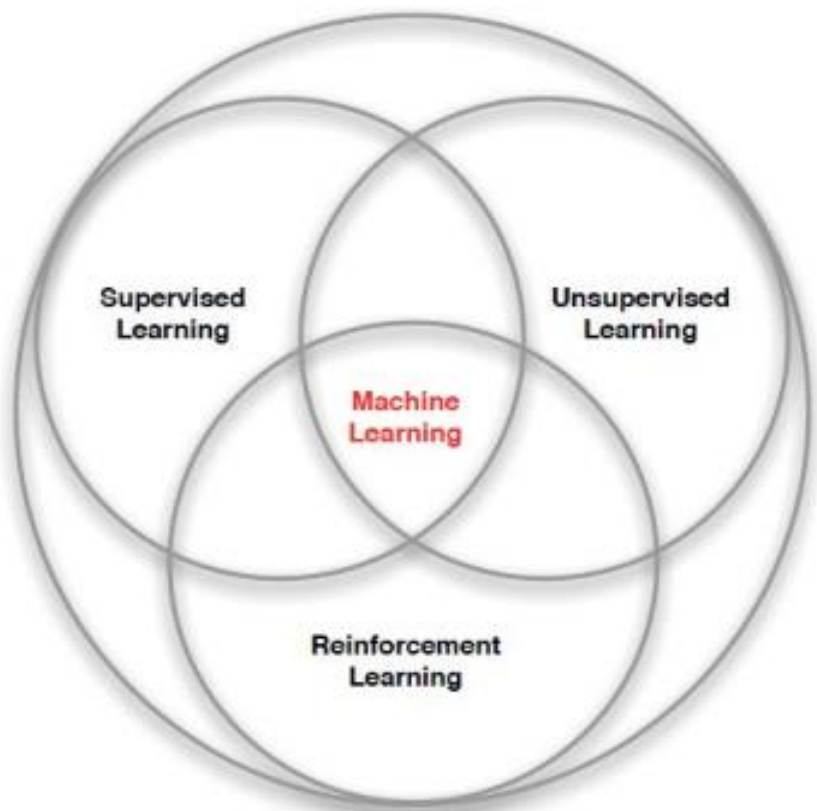
INPUT(x_1, x_2)	OUTPUT
(1, 1)	-1
(1, -1)	+1
(-1, 1)	+1
(-1, -1)	-1

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

فرآیند یادگیری

- سیستم یادگیرنده توسط محیط تحریک شود.
- قانون یادگیری با رجوع به نتیجه تحریک، پارامترهای سیستم یادگیری را تغییر دهد.
- سیستم یادگیرنده به خاطر تغییراتی که در ساختار داخلی آن اتفاق افتاده است، پاسخ مناسبتری به محیط بدهد.

انواع یادگیری ماشین



○ یادگیری ماشین

- یادگیری با نظارت
- یادگیری بدون نظارت
- یادگیری تقویتی

تدریس و یادگیری

یادگیری با نظارت

SUPERVISED LEARNING

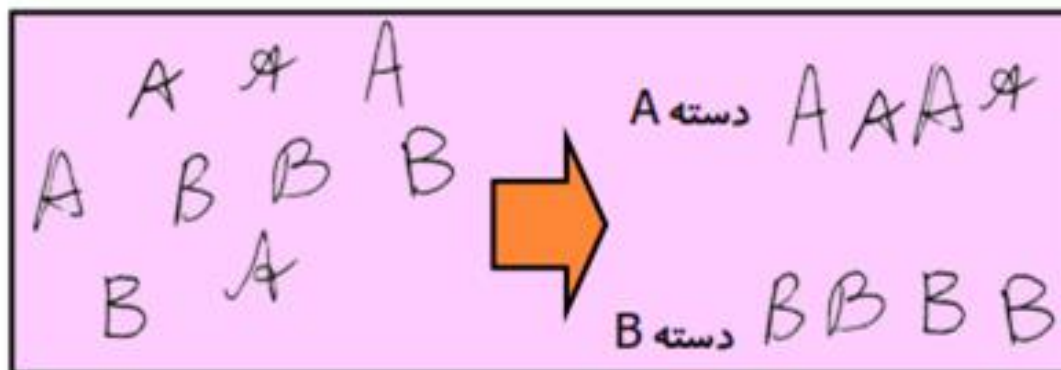
- در این حالت در هر تکرار الگوریتم یادگیری جواب مطلوب سیستم یادگیرنده از قبل آماده است.
– به عبارت دیگر الگوریتم به جواب مطلوب دسترسی دارد.
 - **مثلا** اگر هدف یادگیری تابع $y=x^2$ باشد، پاسخ مطلوب به ورودی ۰.۵ برابر ۰.۲۵ می باشد.
 - به طور کل جوابی را که سیستم یادگیر با وضعیت فعلی پارامترهایش می دهد، **جواب واقعی** در نظر می گیریم.
- بنابر این الگوریتم هم به جواب مطلوب و هم به جواب واقعی دسترسی دارد. یعنی **خطای یادگیری** که تفاوت این دو مقدار می باشد، در دسترس است.

یادگیری با نظارت

SUPERVISED LEARNING

○ یادگیری با نظارت (Supervised)

- داده‌های آموزش دارای برچسب هستند. برچسب‌ها بیانگر دسته هر داده هستند.
- دسته‌بندی (طبقه‌بندی) (Classification)
- نوعی از بازشناسی برای دسته‌بندی الگو
- دسته‌ها از قبل مشخص



کاربردهایی از یادگیری تحت نظارت

○ تحلیل‌ها و پیش‌بینی‌های مالی و تجاری

- پیش‌بینی بورس
- پیش‌بینی قیمت طلا

○ پزشکی

- تشخیص بیماری‌ها از روی تصاویر و سیگنال‌ها

• تشخیص بیماری‌ها از روی تصاویر و سیگنال‌ها

یادگیری بدون نظارت

UNSUPERVISED LEARNING

- در این حالت جواب مطلوب برای سیستم یادگیرنده موجود نیست.
- یعنی : عدم دسترسی به خطای یادگیری

سوال

- - چگونه می توان یک سیستم یادگیرنده را آموزش داد، اگر ندانیم که این سیستم قرار است چه کاری انجام دهد؟
- خواهیم دید که بیشتر الگوریتمهای بدون ناظر عمل خوشه بندی را انجام می دهند.
- یعنی می آموزند که الگوهای ورودی را به تعداد متناهی از گروهها تقسیم کنند.


یادگیری بدون نظارت

UNSUPERVISED LEARNING

○ خوشه‌بندی (Clustering)

- دسته‌بندی الگوها بر اساس شباهت

- دسته‌ها از قبل نامشخص

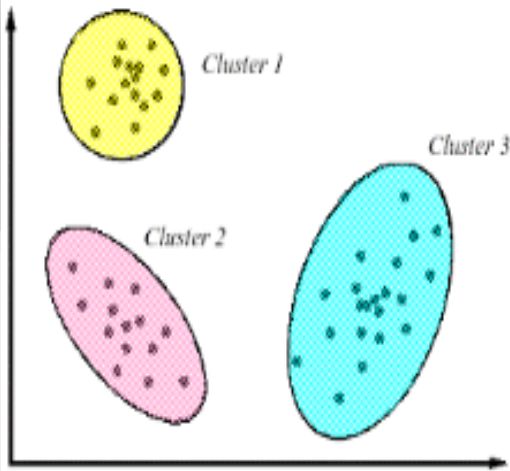


کاربردهایی از یادگیری بدون نظارت

- دسته‌بندی خودکار داده‌های حجیم
 - متون وب‌سایت
 - رفتار مشتری‌ها برای بازایابی هدف‌مند
- داده‌کاوی و استخراج دانش از داده‌ها
- کاهش ابعاد ویژگی‌ها
- قطعه‌بندی تصویر (Segmentation)

• قطعه‌بندی تصویر (Segmentation)

یادگیری بدون نظارت




روشها

- شبکه عصبی
 - نگاشت‌های خودسازمانده کوهونن (SOM)
 - نظریهٔ نوسان افقی (ART)
- K میانگین (K-means) و حالت فازی آن (FCM)
- روش‌های سلسله مراتبی

یادگیری بدون نظارت

یادگیری بدون ناظر در شبکه عصبی

- یادگیری خود سازمانده
- در این نوع یادگیری، هیچ سیگنالی که اطلاعاتی در مورد مطلوبیت جواب شبکه به خود شبکه وارد نماید موجود نیست.
- شبکه در اینجا بایستی تنها با ارائه صرف بردارهای ورودی، ارتباطات موجود بین الگوهای ورودی را پیدا کرده و در خروجی شبکه گد نماید.

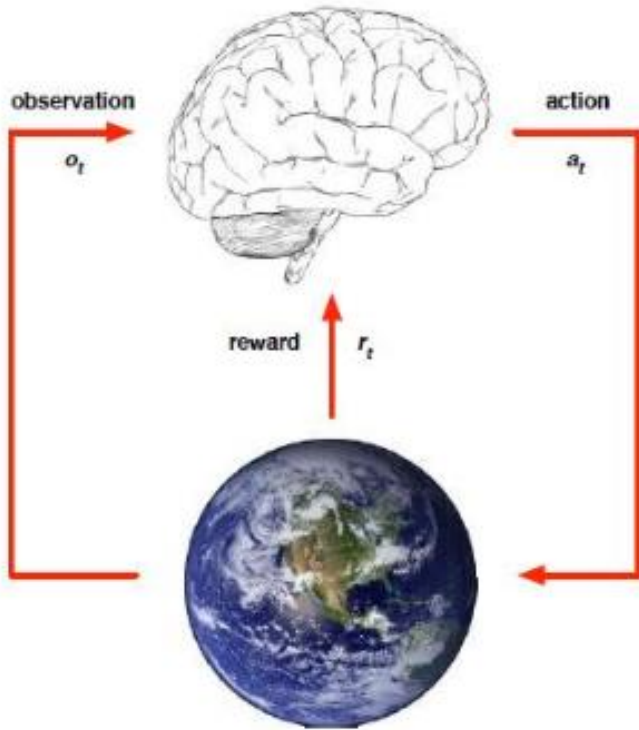


یادگیری تقویتی


REINFORCEMENT LEARNING

- یادگیری بر مبنای آزمون و خطا در تعامل با محیط
- انجام یک عمل (action) و دریافت بازخورد از محیط
- یادگیری بر اساس پاداش (Reward) و جریمه (Penalty)
- عدم وجود ناظر (supervisor)
- یادگیری در طول زمان

مراحل یک یادگیری تقویتی



- At each step t the agent:
 - Executes action a_t
 - Receives observation o_t
 - Receives scalar reward r_t
- The environment:
 - Receives action a_t
 - Emits observation o_t
 - Emits scalar reward r_t



ارزیابی سیستم های یادگیری

○ دقت/نرخ خطا

- درصد بازشناسی درست/نادرست دسته ها
- نرخ قبول اشتباه/رد اشتباه

○ سرعت پردازش

○ هزینه طراحی و ساخت

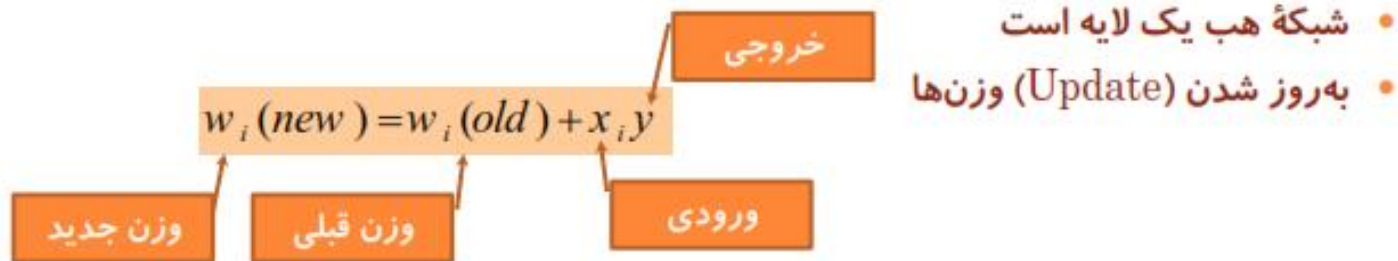
○ مقاوم بودن (Robustness)

شبکه هب (یادگیری با نظارت)

○ 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



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

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

الگوریتم شبکه هب

- 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


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

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

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

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

کاربرد شبکه هب (تابع AND)



تابع AND با ورودی‌ها و هدف‌های دودویی ...
• تغییر وزن

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

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

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

کاربرد شبکه هب (تابع AND)

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

• برای ورودی اول

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

مقدار اولیه

$$x_2 = -x_1 - 1$$

کاربرد شبکه هب (تابع AND)

○ تابع AND با ورودی‌ها و هدف‌های دودویی

• برای دومین، سومین و چهارمین ورودی


INPUT	TARGET	WEIGHT CHANGES	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
«غیرفعال»

استفاده از نمایش دودویی

پاسخ
نادرست



$$x_2 = -x_1 - 1$$

کاربرد شبکه هب (تابع AND)

○ تابع AND با ورودی‌های دودویی و مقادیر هدف دوقطبی

• اولین ورودی

INPUT
($x_1 \ x_2 \ 1$)

TARGET
 t

(1 1 1)
(1 0 1)
(0 1 1)
(0 0 1)

1
-1
-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)

$$x_2 = -x_1 - 1$$

• ارائه دومین، سومین و چهارمین

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

کاربرد شبکه هب (تابع AND)

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 دو قطبی ...

• 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 $(1 \ 1 \ 1)$ $(1 \ 1 \ 1)$

$$x_2 = -x_1 - 1$$




کاربرد شبکه هب (تابع AND)

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

$$x_2 = 0$$

• دومین ورودی




پاسخ درست برای
دو نمونه آموزش

کاربرد شبکه هب (تابع AND)

○ تابع AND برای ورودی‌ها و هدف‌های دو قطبی

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


• سومین ورودی



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

• چهارمین ورودی

$x_2 = -x_1 + 1$



نمایش داده ها در شبکه هب

○ شکل نمایش داده ها می تواند مسئله قابل حل را به مسئله ای غیر قابل حل تبدیل کند

• در قانون هب بسیار موثر است

○ برای برخی الگوها منجر به جواب درست نمی شود، 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 داده های گم شده (Missing Data) از داده های اشتباه (Mistaken Data)

○ مقادیر گم شده = «۰»

○ اشتباهات = قرینه مقدار ورودی از +۱ به -۱ و یا برعکس