

شناسایی آماری الگو
بخش دهم
(۰۱-۷۱۱-۱۰-۱۴۱)

مقدمه‌ای بر یادگیری عمیق


DNN



دانشگاه شهید بهشتی
پژوهشکده‌ی فضای مجازی
بهار ۱۳۹۶
احمد محمودی ازناوه

فهرست مطالب

- مقدمه‌ای بر یادگیری عمیق
- یادگیری خودآموخته
- یادگیری سلسله مراتبی خمیصه
- آشنایی با CNN
- مشکلات شبکه‌های عمیق



<https://www.macs.hw.ac.uk/~dwcorne/index.htm>

- «یادگیری عمیق» باعث ایجاد پیشرفت‌های چشمگیری در زمینه‌ی بینایی ماشین و پردازش صوت شده است.

<http://static.googleusercontent.com/media/research.google.com/en//pubs/archive/38131.pdf>

modeling technique	#params [10 ⁶]	WER		task	hours of training data	DNN-HMM	GMM-HMM with same data	GMM-HMM with more data
		Hub5'00-SWB	RT03S-FSH					
GMM, 40 mix DT 309h SI	29.4	23.6	27.4	Switchboard (test set 1)	309	18.5	27.4	18.6 (2000 hrs)
				Switchboard (test set 2)	309	16.1	23.6	17.1 (2000 hrs)
NN 1 hidden-layer×4634 units	43.6	26.0	29.4	English Broadcast News	50	17.5	18.8	
+ 2×5 neighboring frames	45.1	22.4	25.7	Bing Voice Search	24	30.4	36.2	
DBN-DNN 7 hidden layers×2048 units	45.1	17.1	19.6	(Sentence error rates)				
+ updated state alignment	45.1	16.4	18.6	Google Voice Input	5,870	12.3		16.0 (>>5,870hrs)
+ sparsification	15.2 nz	16.1	18.5	Youtube	1,400	47.6	52.3	
GMM 72 mix DT 2000h SA	102.4	17.1	18.6					

go here: <http://yann.lecun.com/exdb/mnist/>


From here:

<http://people.idsia.ch/~juergen/cvpr2012.pdf>


Dataset	Best result of others [%]	MCDNN [%]	Relative improv. [%]
MNIST	0.39	0.23	41
NIST SD 19	see Table 4	see Table 4	30-80
HWDB1.0 on.	7.61	5.61	26
HWDB1.0 off.	10.01	6.5	35
CIFAR10	18.50	11.21	39
traffic signs	1.69	0.54	72
NORB	5.00	2.70	46

یادگیری عمیق

Google Trends





یادگیری عمیق اخیراً بسیار مورد توجه قرار گرفته است و در بسیاری از زمینه‌های توانسته است بهبود چشمگیری نسبت به سایر روش‌ها به دست آورد.




یادگیری عمیق چیست؟



- یک شبکه‌ی عصبی با **چندین** لایه بین ورودی و خروجی
- این شبکه‌های از نمونه‌ی پردازش اطلاعات در مغز انسان تقلید می‌کند، چندین لایه که وظیفه‌ی استخراج ویژگی و شناسایی را به صورت همزمان انجام می‌دهند.
- شبکه‌های چند لایه سال‌هاست که شناخته شده‌اند، اما تنها ویژگی شبکه‌های عمیق داشتن **چندین** لایه‌ی مخفی نیست!



- شبکه‌ی عصبی با تعداد لایه‌های مخفی محدود به راحتی آموزش می‌بینند:




- اما در صورت افزایش تعداد لایه‌ها، الگوریتم‌های یادگیری کارایی لازم را نخواهند داشت.



یادگیری عمیق



- در واقع، مهمترین تفاوت فوت و فن‌هایی است که برای آموزش این شبکه‌ها به کار گرفته شده است.
- یکی از این شیوه‌ها یادگیری بی‌نظارت ***unsupervised feature learning*** خصیصه‌هاست.
- کنترل پارامترهای آزاد، نیز یکی از شیوه‌های مورد استفاده است.



آموزش در شبکه‌های چند لایه



مجموعه‌ی داده‌ها

<i>Fields</i>	<i>class</i>
1.4 2.7 1.9	0
3.8 3.4 3.2	0
6.4 2.8 1.7	1
4.1 0.1 0.2	0
etc ...	



آموزش در شبکه‌های چند لایه (ادامه...)



<i>Fields</i>	<i>class</i>
1.4 2.7 1.9	0
3.8 3.4 3.2	0
6.4 2.8 1.7	1
4.1 0.1 0.2	0
etc ...	



آموزش در شبکه‌های چند لایه (ادامه...)

<i>Fields</i>	<i>class</i>
1.4 2.7 1.9	0
3.8 3.4 3.2	0
6.4 2.8 1.7	1
4.1 0.1 0.2	0
etc ...	

مقداردهی اولیه وزن‌ها به صورت تصادفی



آموزش در شبکه‌های چند لایه (ادامه...)

اعمال ورودی‌ها

Fields *class*



1.4 2.7 1.9 0

3.8 3.4 3.2 0

6.4 2.8 1.7 1

4.1 0.1 0.2 0

etc ...



آموزش در شبکه‌های چند لایه (ادامه...)

محاسبه‌ی خروجی

Fields *class*



1.4 2.7 1.9 0

3.8 3.4 3.2 0

6.4 2.8 1.7 1

4.1 0.1 0.2 0

etc ...



آموزش در شبکه‌های چند لایه (ادامه...)

Fields *class*

1.4 2.7 1.9 0


3.8 3.4 3.2 0

6.4 2.8 1.7 1

4.1 0.1 0.2 0

etc ...


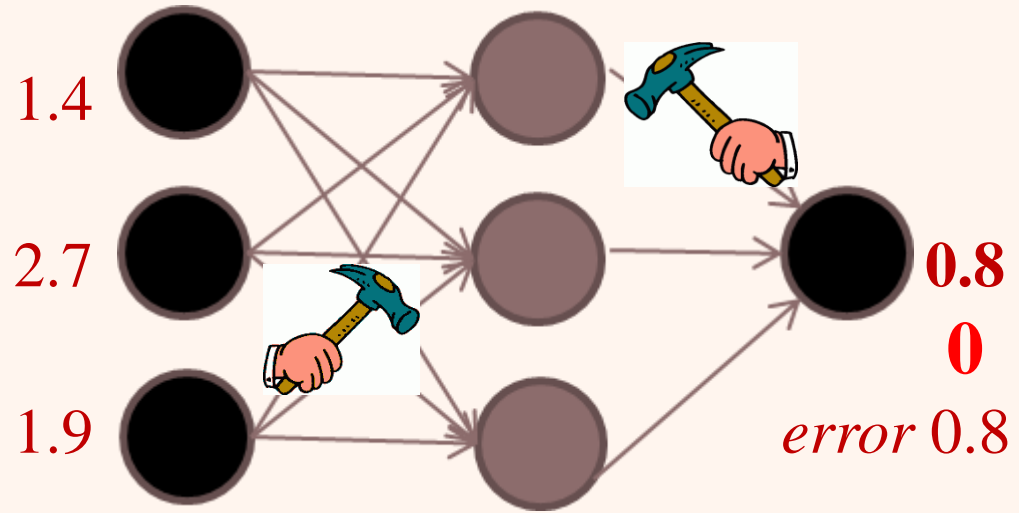
مقایسه با مقدار مطلوب



آموزش در شبکه‌های چند لایه (ادامه...)

<i>Fields</i>	<i>class</i>
1.4 2.7 1.9	0
3.8 3.4 3.2	0
6.4 2.8 1.7	1
4.1 0.1 0.2	0
etc ...	


تنظیم وزن‌ها براساس خطا



آموزش در شبکه‌های چند لایه (ادامه...)

اعمال ورودی‌ها

<i>Fields</i>	<i>class</i>
1.4 2.7 1.9	0
3.8 3.4 3.2	0
6.4 2.8 1.7	1
4.1 0.1 0.2	0
etc ...	



آموزش در شبکه‌های چند لایه (ادامه...)

مماسبتهی خروجی

Fields *class*


1.4 2.7 1.9 0

3.8 3.4 3.2 0

6.4 2.8 1.7 1

4.1 0.1 0.2 0

etc ...



آموزش در شبکه‌های چند لایه (ادامه...)

Fields *class*

1.4 2.7 1.9 0



3.8 3.4 3.2 0

6.4 2.8 1.7 1

4.1 0.1 0.2 0

etc ...


مقایسه با مقدار مطلوب



آموزش در شبکه‌های چند لایه (ادامه...)

<i>Fields</i>	<i>class</i>
1.4 2.7 1.9	0
3.8 3.4 3.2	0
6.4 2.8 1.7	1
4.1 0.1 0.2	0
etc ...	


تنظیم وزن‌ها براساس خطا



آموزش در شبکه‌های چند لایه

<i>Fields</i>	<i>class</i>
1.4 2.7 1.9	0
3.8 3.4 3.2	0
6.4 2.8 1.7	1
4.1 0.1 0.2	0
etc ...	

و به همین ترتیب ...




این روند هزاران بار و بلکه میلیون‌ها بار (بسته به پیچیدگی مدل) تکرار می‌شود. در روش ترتیبی هر بار داده‌ای به صورت تصادفی انتخاب شده و به شبکه اعمال می‌شود. وزن‌ها به گونه‌ای تنظیم می‌شوند که فضا کمینه شود.


تعداد زیاد پارامترهای آزاد می‌تواند منجر به کند شدن شبکه شود.

شبکه‌های پیچیده و مرز جداساز



- در صورت پیچیدگی شبکه‌ی عصبی مرز جداساز هم قابلیت بیشتری برای جداسازی دارد:



وزن‌های تصادفی اولیه





شبکه‌های پیچیده و مرز جداساز (ادامه...)




یک نمونه انتخاب و بر اساس آن وزن‌ها تنظیم می‌شوند

شبکه‌های پیچیده و مرز جداساز (ادامه...)



یک نمونه انتخاب و بر اساس آن وزن‌ها تنظیم می‌شوند



شبکه‌های پیچیده و مرز جداساز (ادامه...)



یک نمونه انتخاب و بر اساس آن وزن‌ها تنظیم می‌شوند





شبکه‌های پیچیده و مرز جداساز (ادامه...)



یک نمونه انتخاب و بر اساس آن وزن‌ها تنظیم می‌شوند


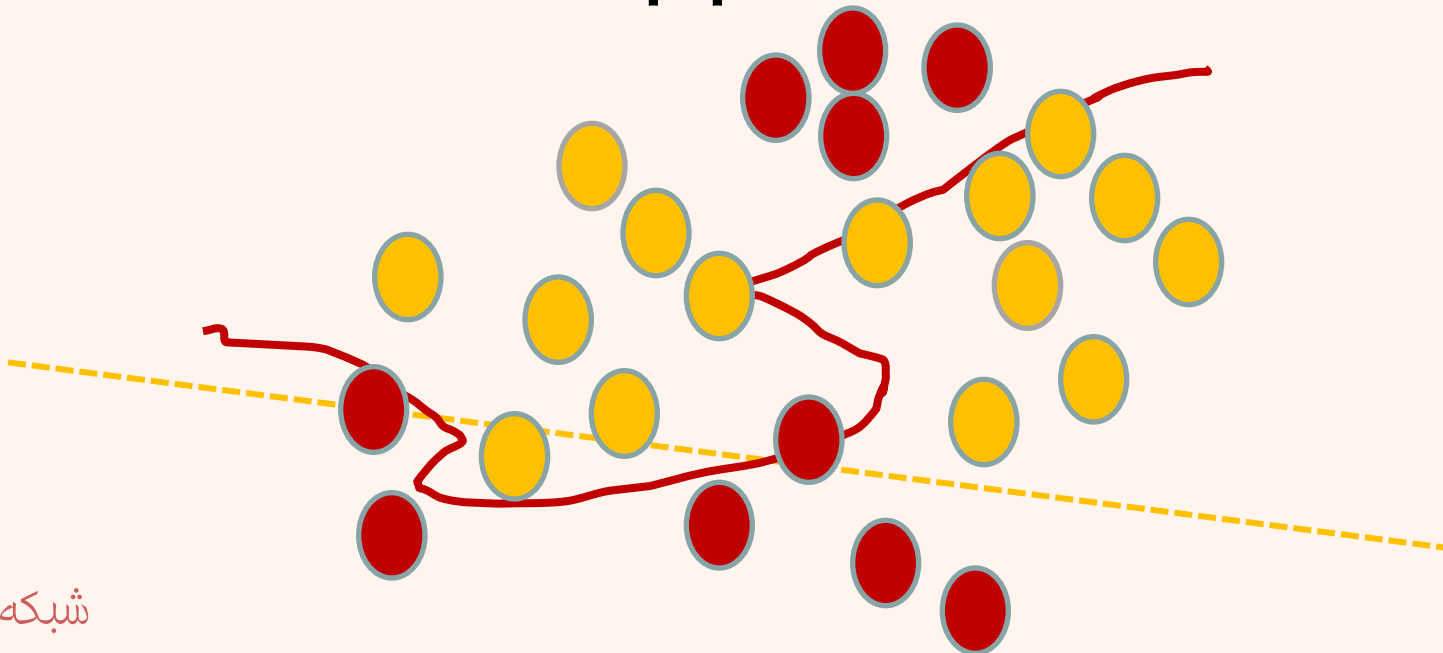
شبکه‌های پیچیده و مرز جداساز (ادامه...)

و درنهایت:




چند نکته


- وزن‌های آموزش دیده، **تفسیرپذیر** نیستند.
- یک شبکه‌ی **تک‌لایه** توانایی دسته‌بندی داده‌های جدایی‌پذیر خطی را دارد.
- می‌دانیم که یک شبکه‌ی عصبی با تنها **یک لایه‌ی مخفی** توانایی جداسازی پیچیده‌ترین اشکال را دارد.




نقش لایه‌های مخفی




پرسپترون





شبکه‌ی چندلایه




داده‌ی ورودی به لایه‌ی آخر





استخراج ویژگی



نقش نورون‌های لایه‌ی مخفی چیست؟




استخراج ویژگی (ادامه...)



وزن قوی


ارتباط ضعیف

بیانگر یک لبه قوی افقی





شبهه عصبی

63



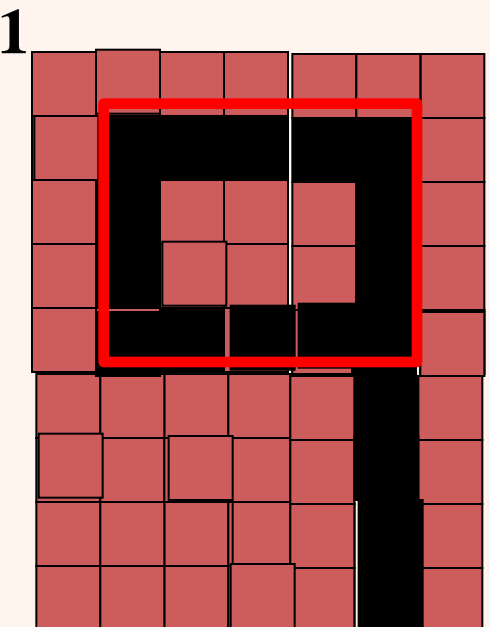
استخراج ویژگی (ادامه...)



وزن قوی


ارتباط ضعیف

یک ناحیه مدور در بالای صفحه



شبهه عصبی

63



استخراج ویژگی (ادامه...)





Figure 1.2: *Examples of handwritten digits from U.S. postal envelopes.*

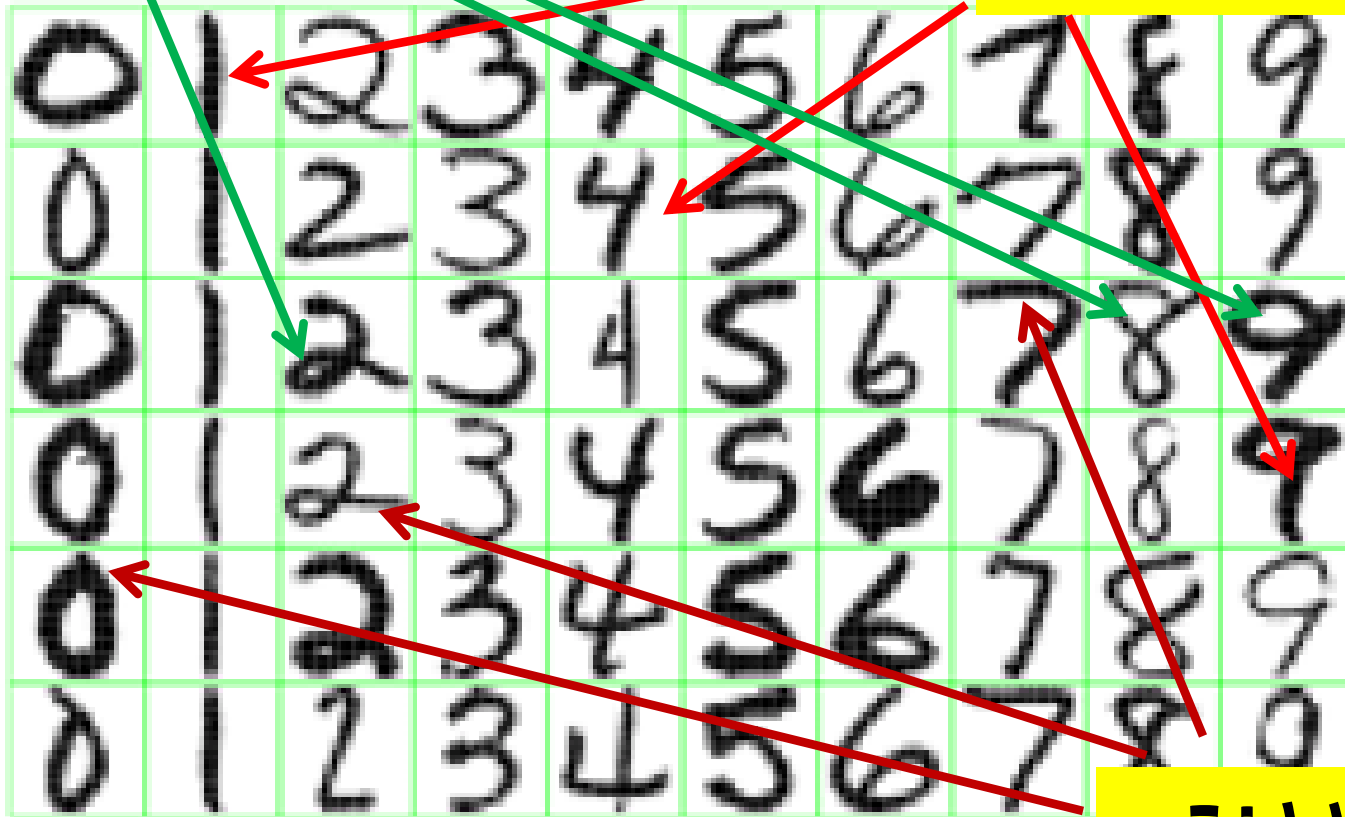
شبکه‌ی عصبی چه نوع فصیصه‌ای برای تشخیص کاراکتر یاد می‌گیرد؟



استخراج ویژگی (ادامه...)

دایره‌های کوچک

خطوط عمودی



خطوط افقی






Figure 1.2: Examples of handwritten digits from U.S. postal envelopes.

خصیصه‌های استخراج شده نسبت به مکان حساس هستند!


استخراج ویژگی (ادامه...)

- لایه‌های مخفی می‌توانند خصیصه‌های سطح بالا استخراج کنند.




استخراج ویژگی (ادامه...)


- در این حالت استفاده از چندین لایه‌ی مختلف توجیه‌پذیر است.




- درست مانند مغز




- لایه‌های مخفی باید بتوانند خصیصه‌های مناسب را استخراج کنند.




استخراج ویژگی (ادامه...)




لایه‌های نخست خوب
آموزش نمی‌بینند



مشکل بیش‌برازش




شیوه‌های نو برای آموزش



ابتدا این لایه آموزش می‌بینند

سپس این لایه و به
همین ترتیب


هر کدام از لایه‌های مخفی به صورت یک *auto-encoder* آموزش می‌بینند.
در واقع تلاش می‌شود داده‌های لایه‌ی قبل را به بهترین نحو توصیف کنند.



کتابخانه
موسسه

auto-encoder


auto-encoder از شیوه‌های استاندارد آموزش برای تنظیم وزن‌ها استفاده می‌کند به گونه‌ای که ورودی را بازتولید کند.



در این حالت تعداد نورون‌های لایه‌ی مخفی کمتر در نظر گرفته می‌شود، بدین ترتیب لایه‌ی مخفی برای استخراج فویسه آموزش می‌بیند.




شیوه‌های نو برای آموزش




لایه‌های میانی به عنوان auto-encoder آموزش می‌بینند.

لایه‌ی آخر برای دسته‌بندی مورد استفاده قرار می‌گیرد.



شبکه عصبی

انواع مختلفی از شبکه‌های عمیق وجود دارد،
autoencoderهای متفاوت، ساختار و شیوه‌های
آموزش مختلف در شبکه‌های مختلف استفاده
می‌شود.



یادگیری خودآموزته

self-taught Learning



یادگیری خودآموخته


- دلایلی وجود دارد که نشان می‌دهد مغز انسان از یک شیوهی یادگیری یکسان برای داده‌های مختلف استفاده می‌کند.

- در یک آزمایش سیگنال‌های بینایی موش فرما به بخش شنوایی مغزش هدایت شد و بخش شنوایی دیدن را آموخت!

Visual Projections Routed to the Auditory Pathway in Ferrets: Receptive Fields of Visual Neurons in Primary Auditory Cortex

Anna W. Roe,^a Sarah L. Pallas,^b Young H. Kwon, and Mriganka Sur


Department of Brain and Cognitive Sciences, Massachusetts Institute of Technology, Cambridge, Massachusetts 02139



اگر این شیوهی یادگیری کشف شود، می‌توان گفت به هدفمان رسیده‌ایم!

آموزش در مغز

- مغز انسان حدود 10^{14} ارتباط سیناپسی دارد.
- هر انسان در مرتبه‌ی 10^9 ثانیه زندگی می‌کند.
- اگر نمایش هر ارتباط سیناپسی به یک بیت امتیاج داشته باشد، برای استفاده از ظرفیت کل ذهن به نرخ آموزش 10^{14} در 10^9 ثانیه نیاز است.
- یعنی 10^5 بیت در ثانیه
- از این مثال می‌توان نتیجه گرفت ساختار مغز به صورت بی‌نظارت آموزش می‌بیند و بیشتر از داده‌های بدون برچسب استفاده می‌کند.



یادگیری بانظارت

مجموعه‌ی آموزشی




Cars

Motorcycles

داده‌های آزمایش



در صورتی که داده‌های آموزشی محدود باشد، ممکن یادگیری بانظارت خوب عمل نکند.



آموزش به شیوهی مغز

مجموعه‌ی آموزشی



Cars

Motorcycles

داده‌های آزمایش



تصاویر بدون برچسب



Self-taught Learning

آموزش به شیوهی مغز




Labeled Digits

+




Unlabeled English characters

?




Labeled Webpages

+




Unlabeled newspaper articles

?




Labeled Russian Speech

+



Unlabeled English speech



تاریخچه یادگیری ماشین

• یادگیری با نظارت (محدود بیست سال پیش)

Supervised learning



Cars



Motorcycles

• یادگیری نیمه نظارتی (محدود ده سال پیش)

Semi-supervised learning



Cars




Motorcycles



• انتقال یادگیری (محدود ده سال پیش)

Transfer learning



Bus

Tractor



Aircraft

Helicopter




Cars



Motorcycles

• هم‌اکنون: یادگیری خودآموز

Self-taught learning




Natural scenes



Car



Motorcycle



یادگیری خودآموخته


- مجموعه‌ی داده‌های آموزشی (برچسب‌خورده)

$$\{(x_l^{(i)}, y^{(i)})\}_{i=1}^m \quad x_l^{(i)} \in R^n, y^{(i)} \in \{1, \dots, T\}$$

- مجموعه‌ی داده‌های بدون برچسب

$$\{x_u^{(i)}\}_{i=1}^k \quad x_u^{(i)} \in R^n, k \gg m$$


- لزومی ندارد که داده‌های از یک نوع باشند.



یادگیری خودآموخته

- هر داده به صورت ترکیب خطی یک مجموعه بردار پایه نمایش داده می‌شود.


$$x \approx \sum_j a_j b_j \quad b_j \in R^n, a_j \in R$$



$x = 0.8 * b_{87} + 0.3 * b_{376} + 0.5 * b_{411}$

– از داده‌های بدون برچسب برای آموختن بردارهای پایه استفاده می‌شود. در واقع، داده‌های بدون برچسب برای ارائه‌ی یک فضا می‌سازد.

– پس از آن از داده‌های برچسب‌دار برای دسته‌بندی با نظارت استفاده می‌شود.




مثالی از بردارهای پایه


Natural images.




Learnt bases: "Edges"



Handwritten characters.



Learnt bases: "Strokes"

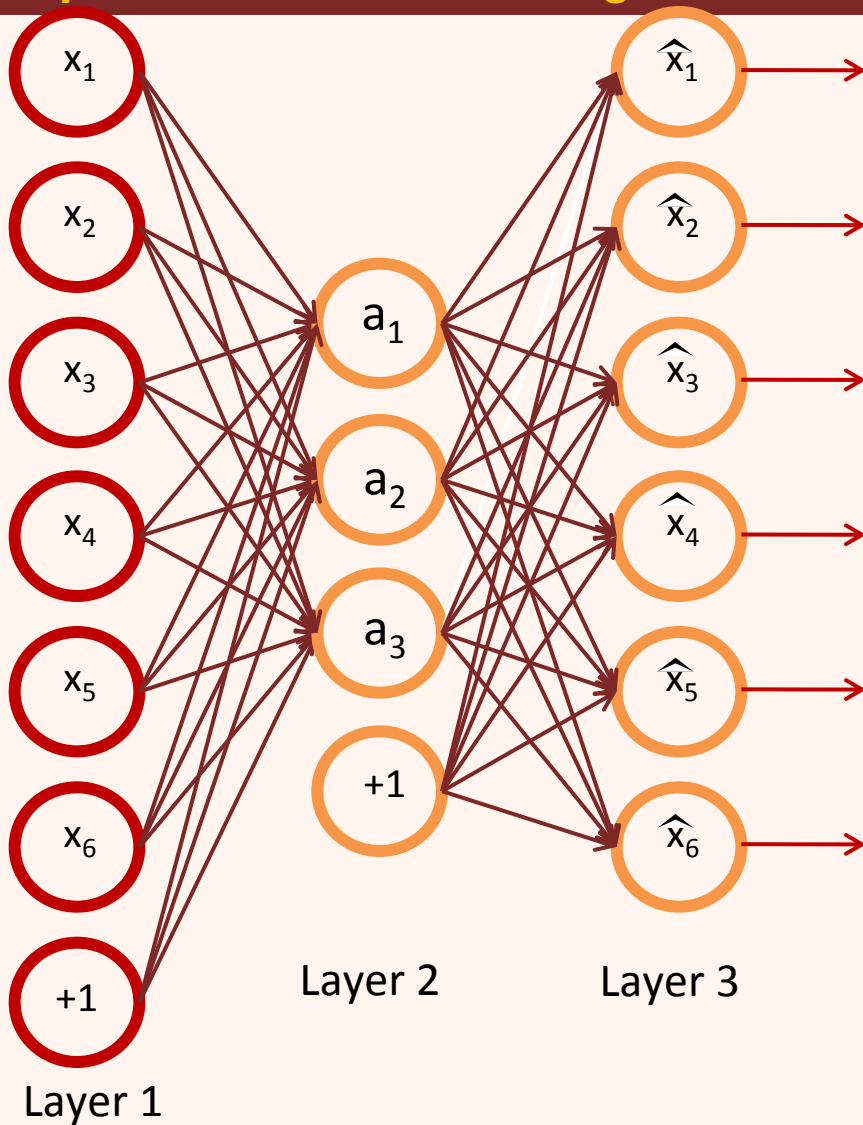


auto-encoder




auto-encoder

Unsupervised feature learning with a neural network


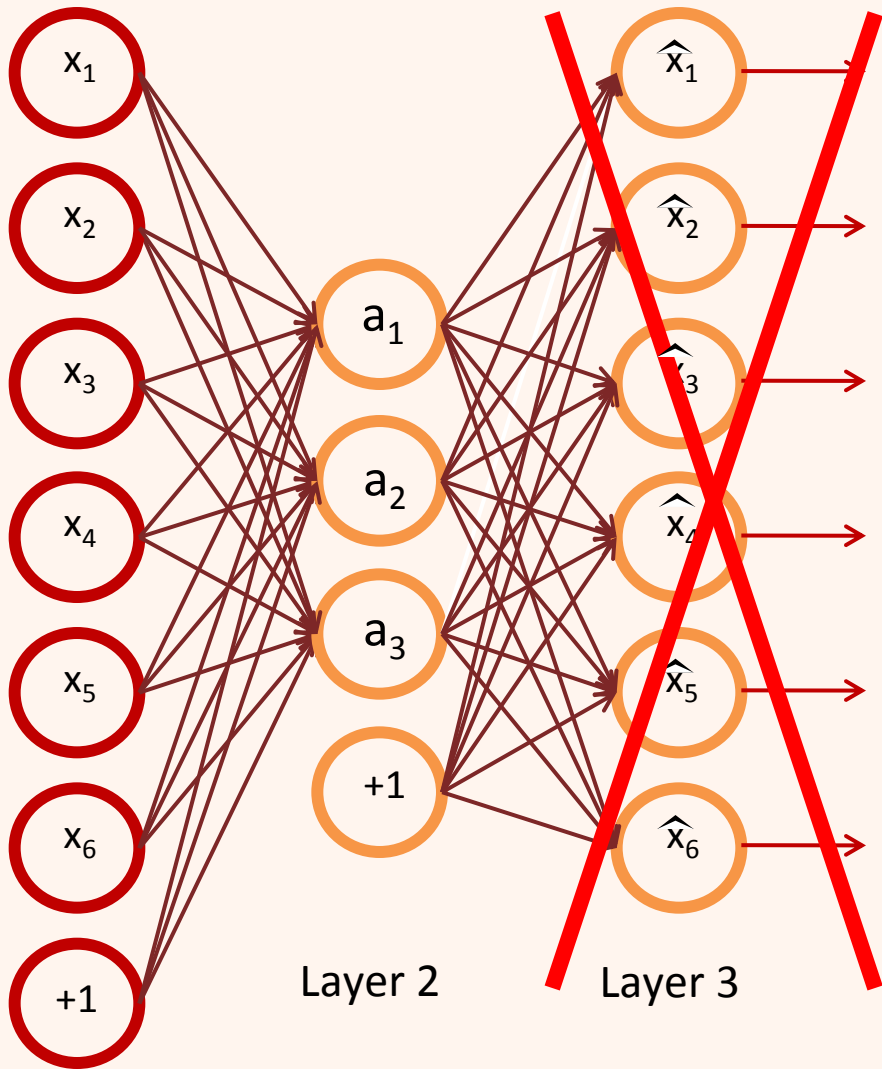


شبکه به
گونه‌ای آموزش می‌بیند که

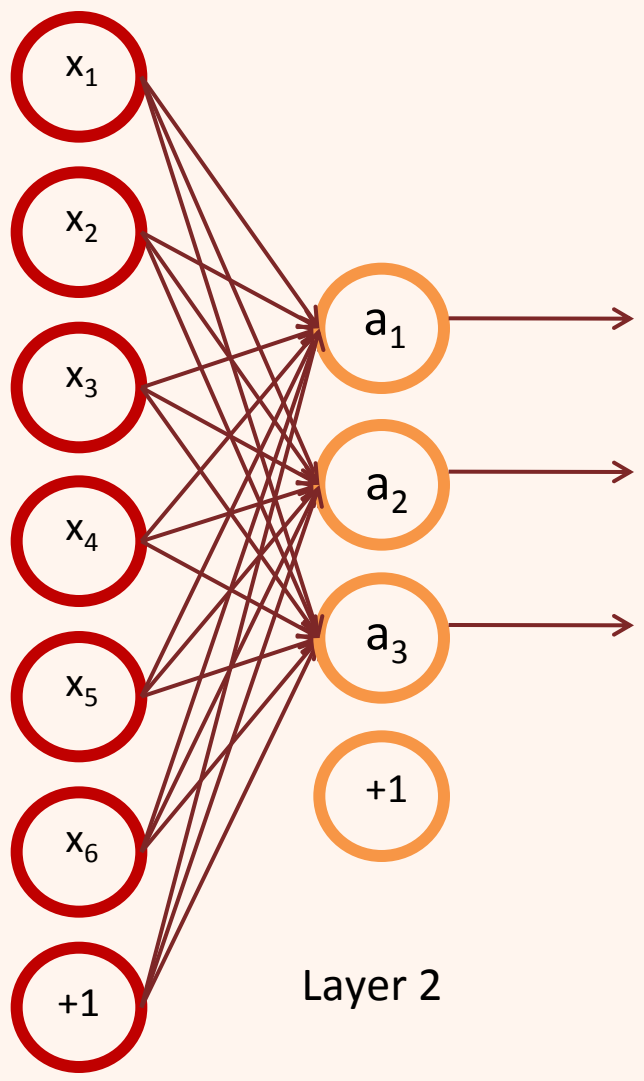
$$\hat{x} \approx x$$



auto-encoder




auto-encoder




$$\begin{bmatrix} a_1 \\ a_2 \\ a_3 \end{bmatrix}$$


نمایش جدید برای داده‌ها




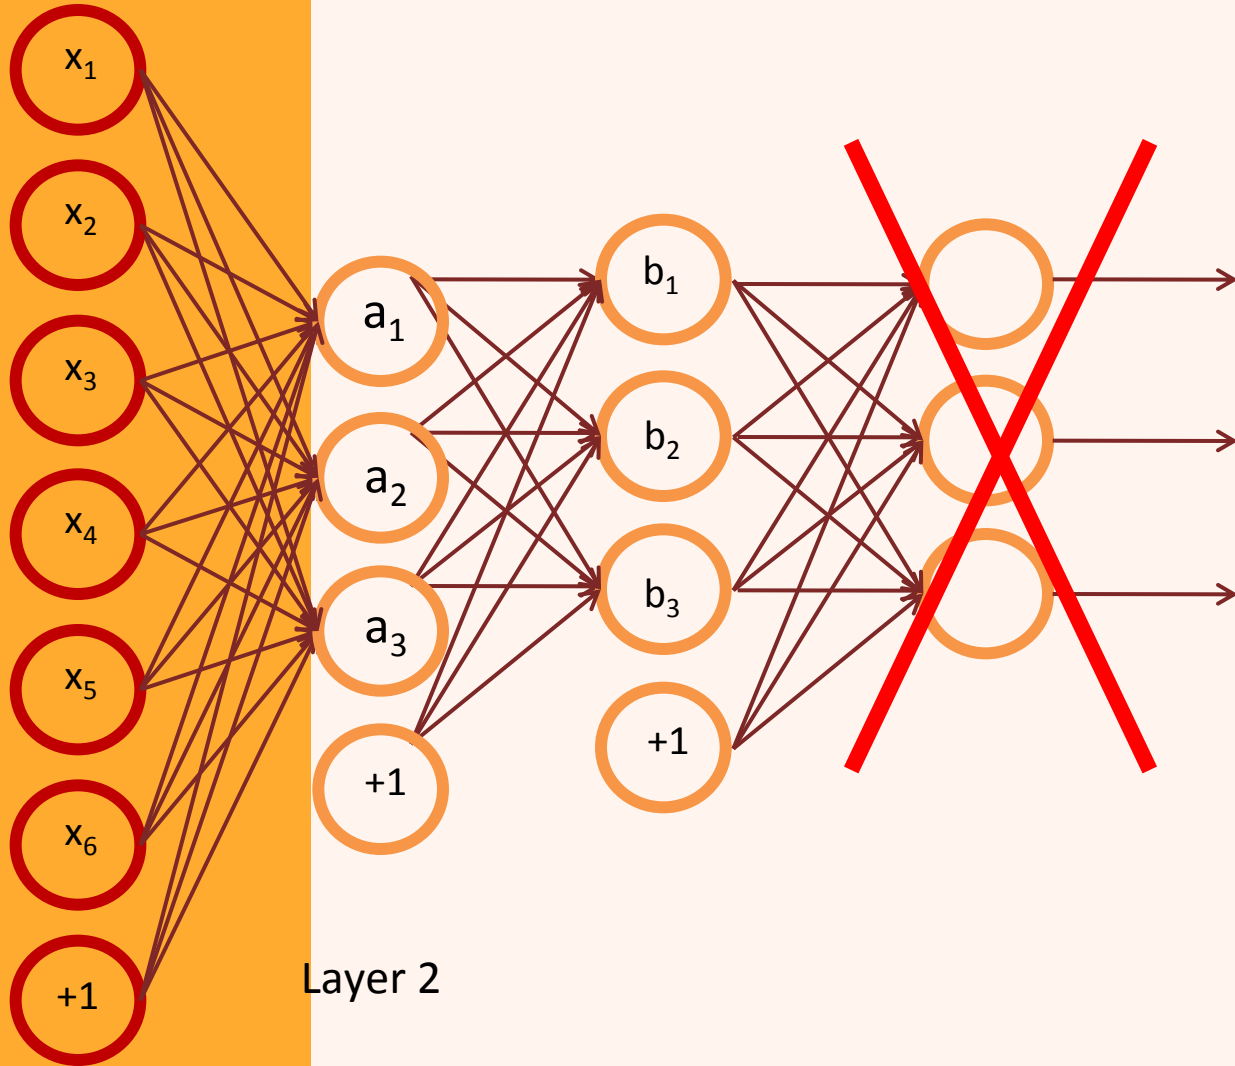
auto-encoder




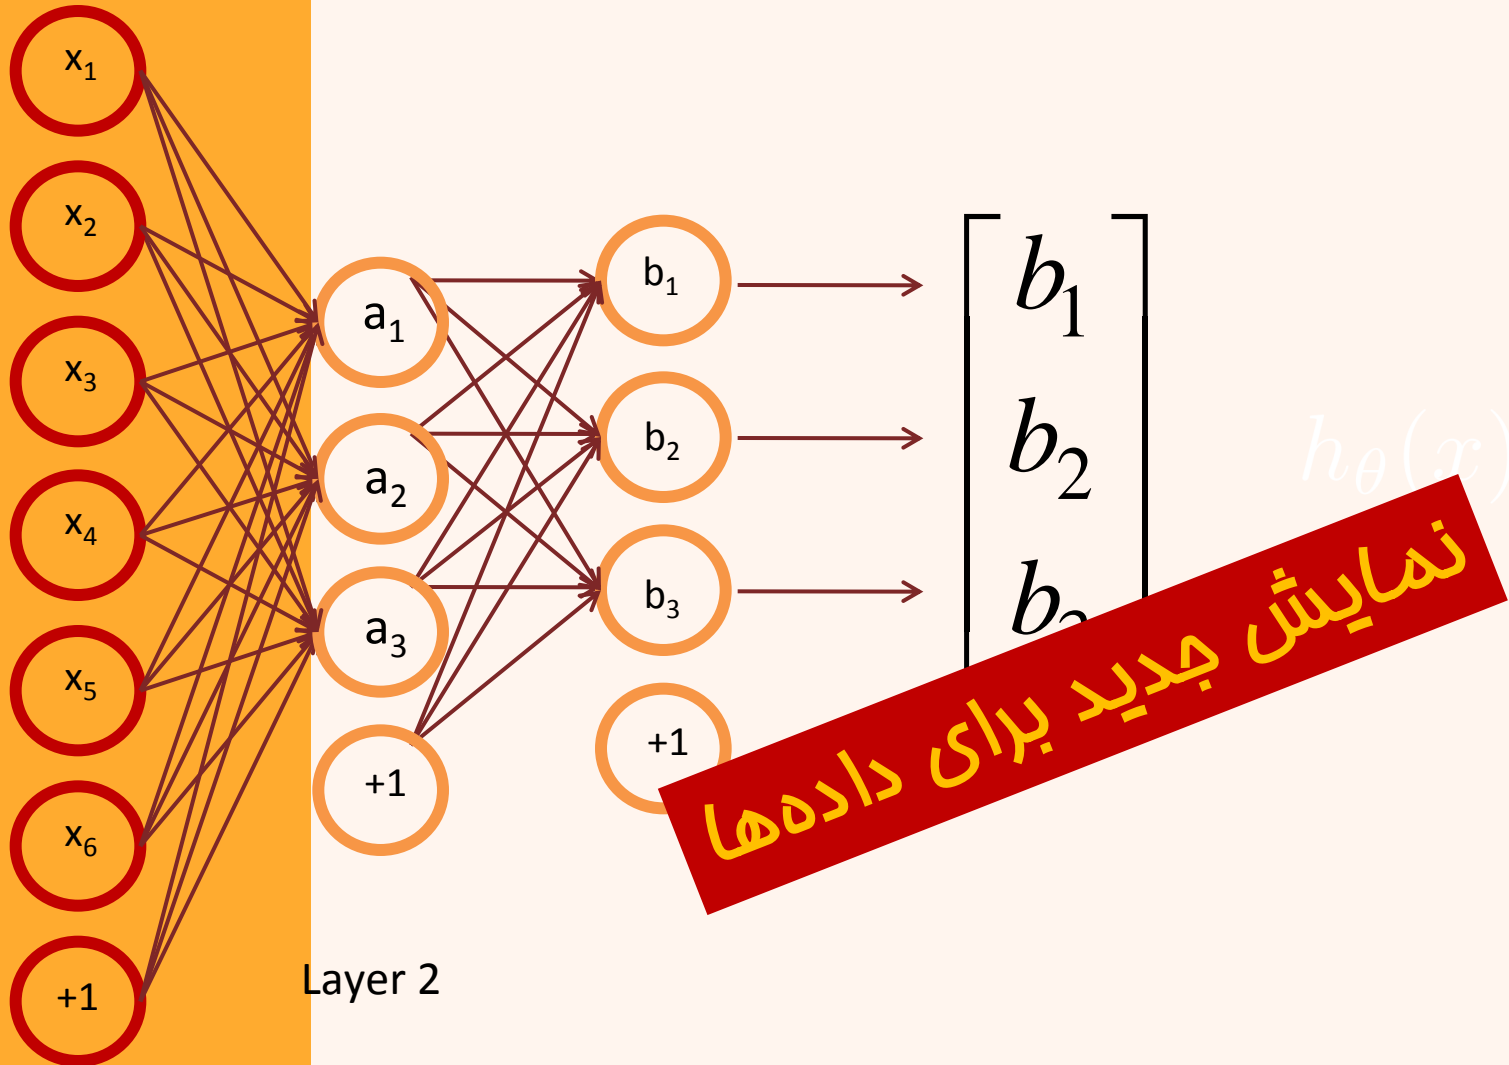
$$h_{\theta}(x)$$




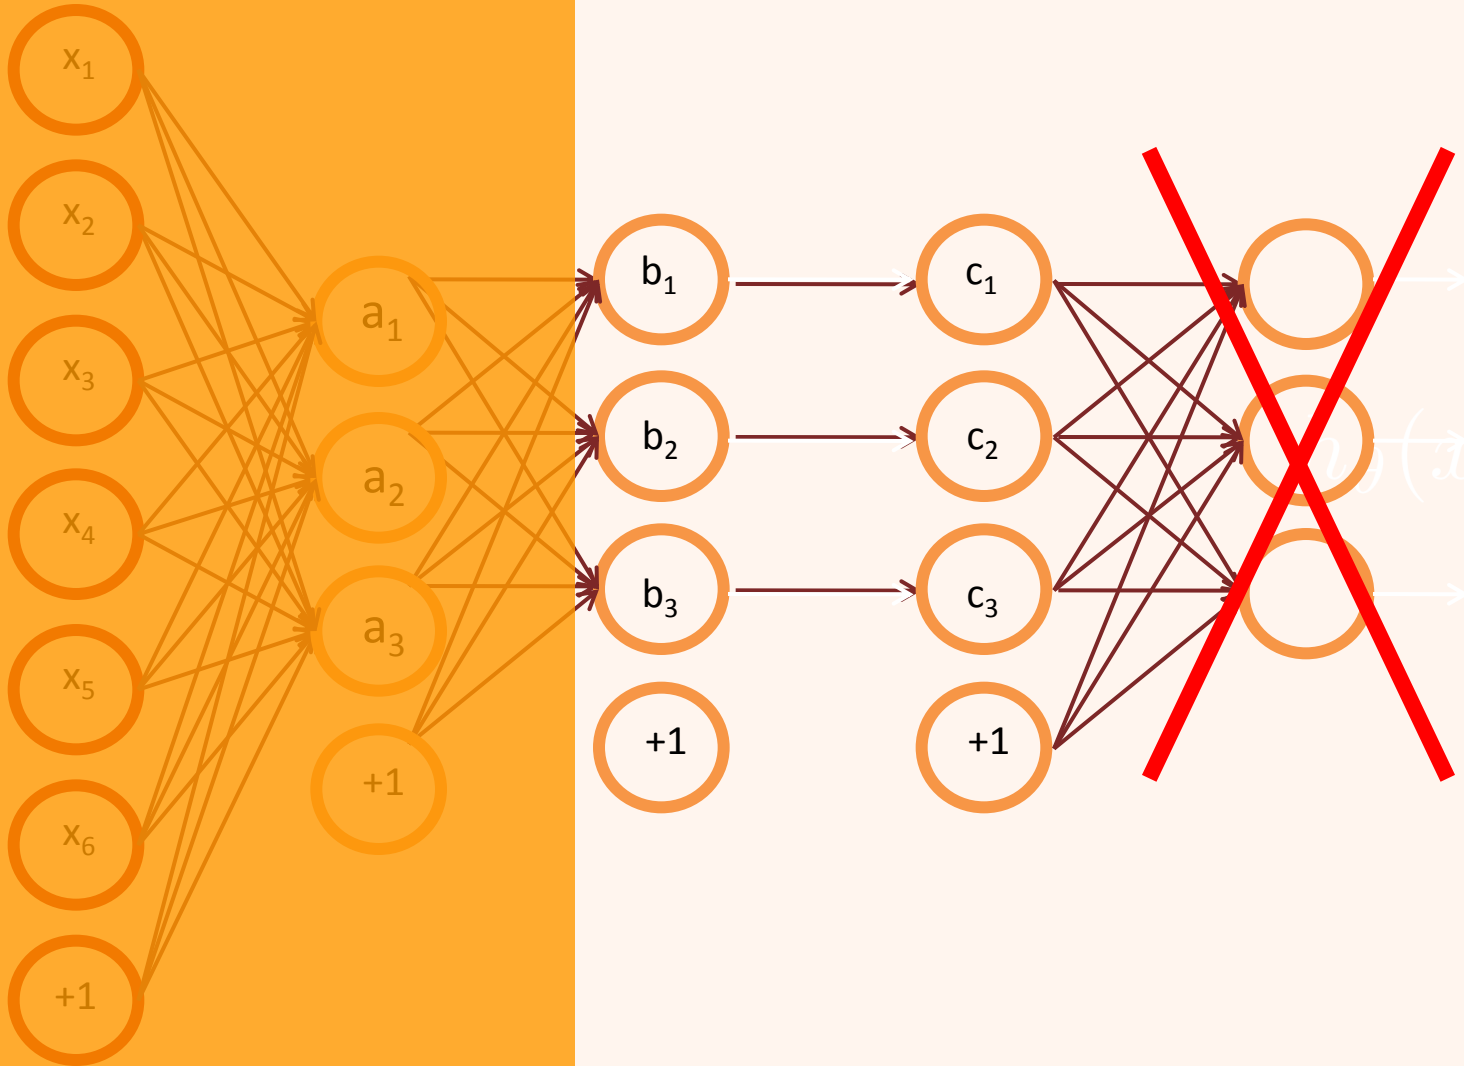
auto-encoder



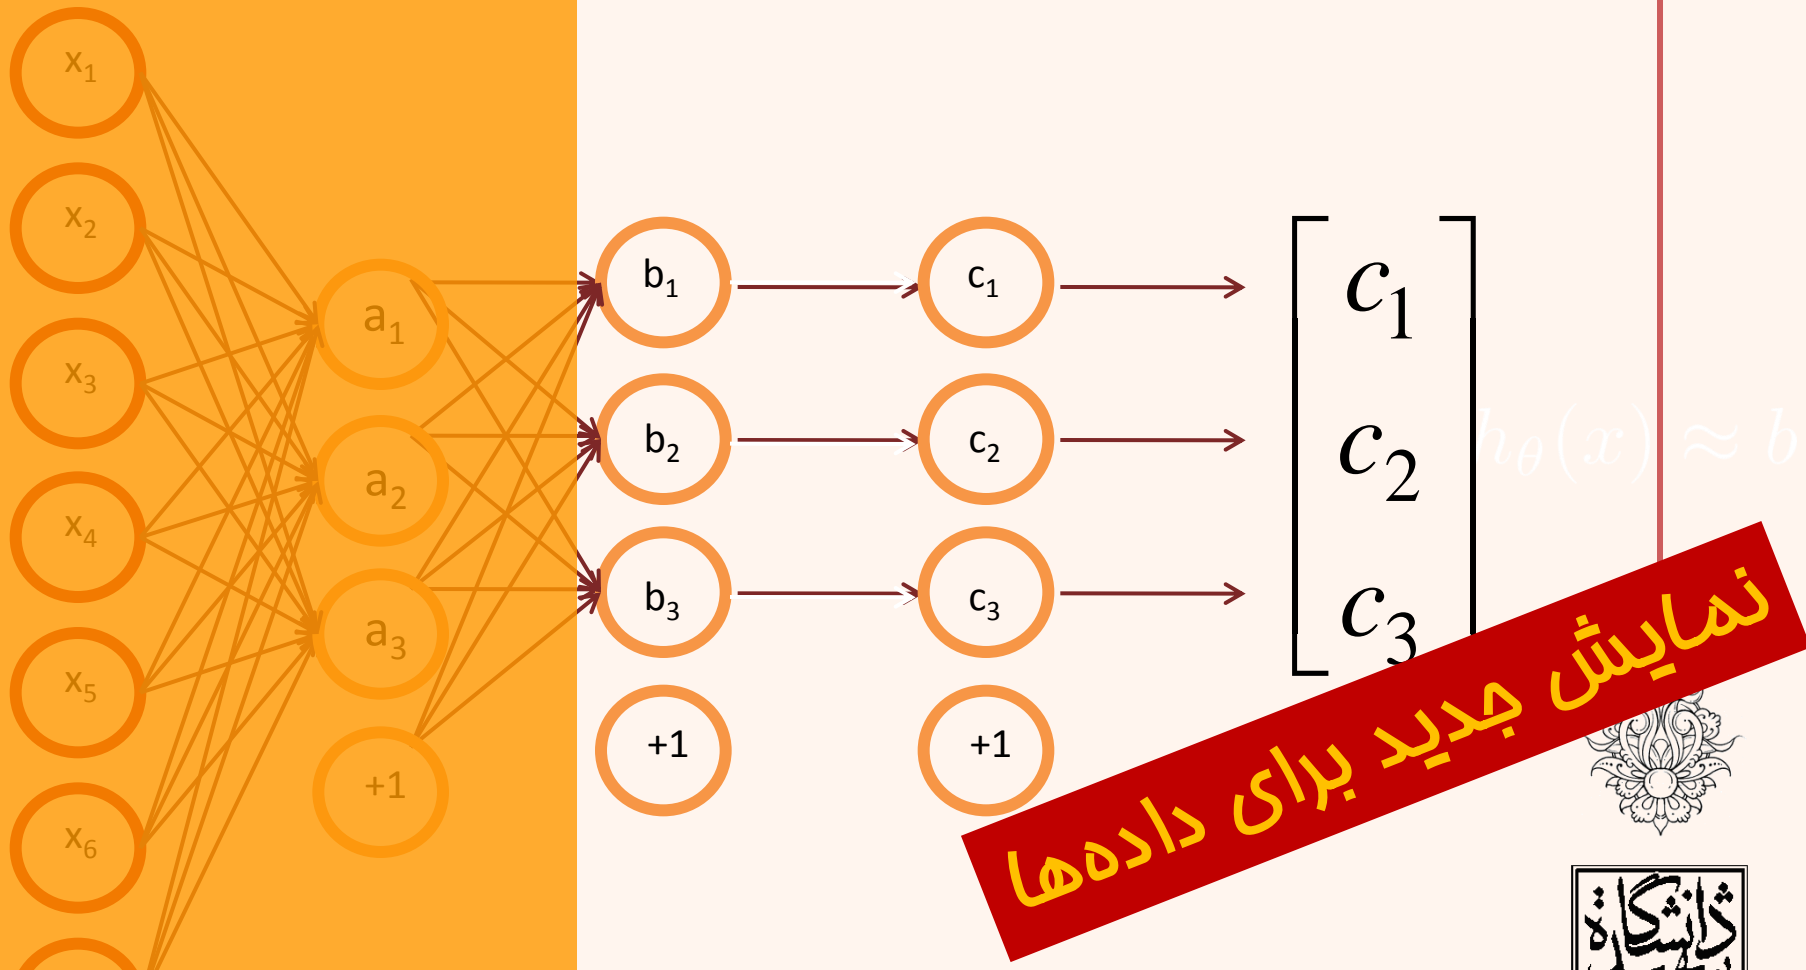
auto-encoder



auto-encoder




auto-encoder




فصیصه‌ی به دست آمده در لایه‌ی آخر برای دسته‌بندی مورد استفاده قرار می‌گیرد.

آموزش سلسله مراتبی خصیصه‌ها


object models




*object parts
(combination
of edges)*



edges



pixels













آموزش سلسله‌مراتبی خصیصه‌ها

Faces

Cars


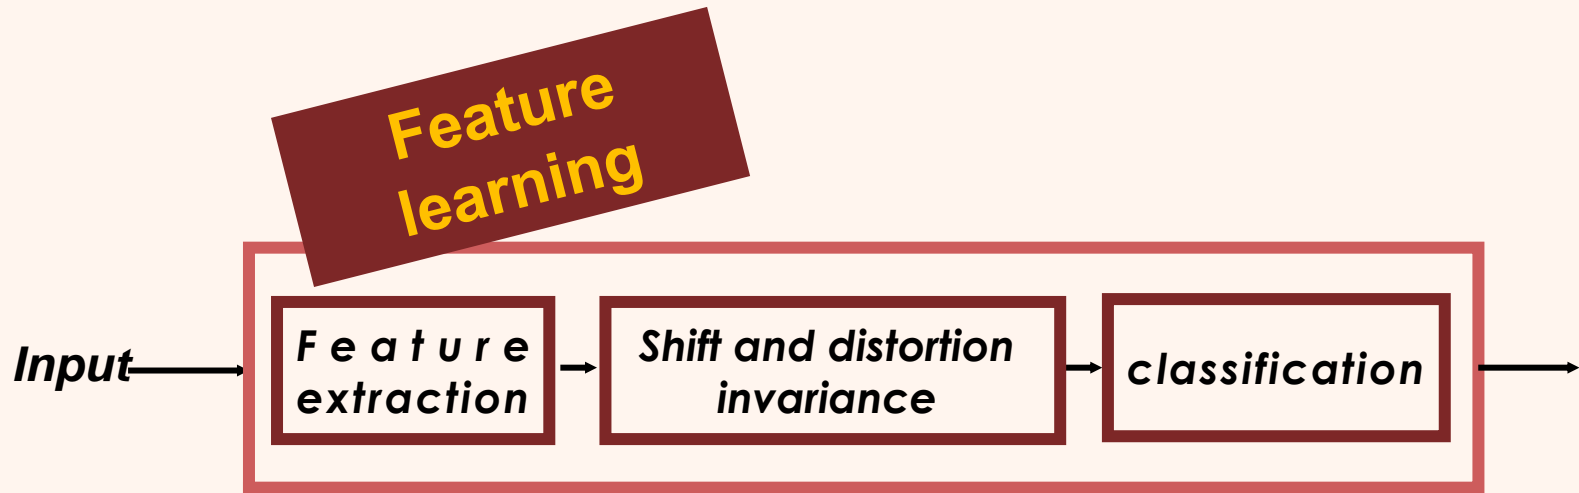

Elephants

Chairs



تراشگاه
سپیدی
بهشتی

استخراج خصیصه



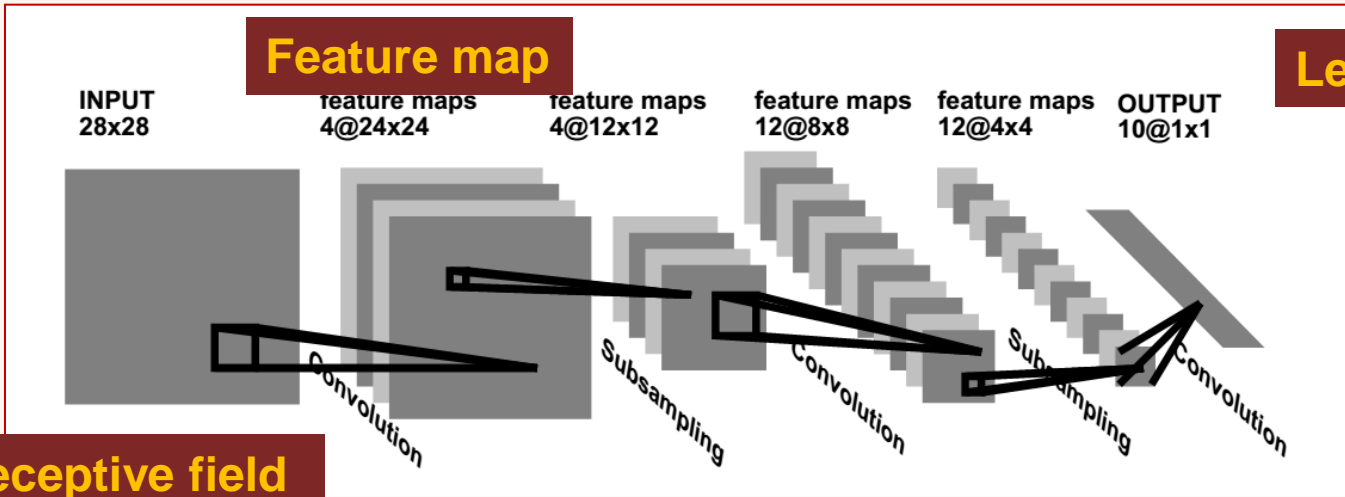
CNN



In 1995, Yann LeCun and Yoshua Bengio introduced the concept of convolutional neural networks.





Convolutional Neural Networks



LeNet1(3000/100000)



- این شبکه عمدتاً برای داده‌های دو بعدی طراحی شده است.
- برای داده‌هایی مناسب است که به صورت محلی ساختار منظمی دارند.
- اتصالات بین نورون‌ها به صورت محلی است.

Sparse Connectivity





- با توجه به این که وزن‌های متصل به لایه‌ی feature-map یکسان است، خصیصه‌های به دست آمده نسبت به جابجایی مقاوم است.
- از سوی دیگر این کار باعث می‌شود پارامترهای آزاد شبکه به شدت کاهش یابد.

Shared Weights



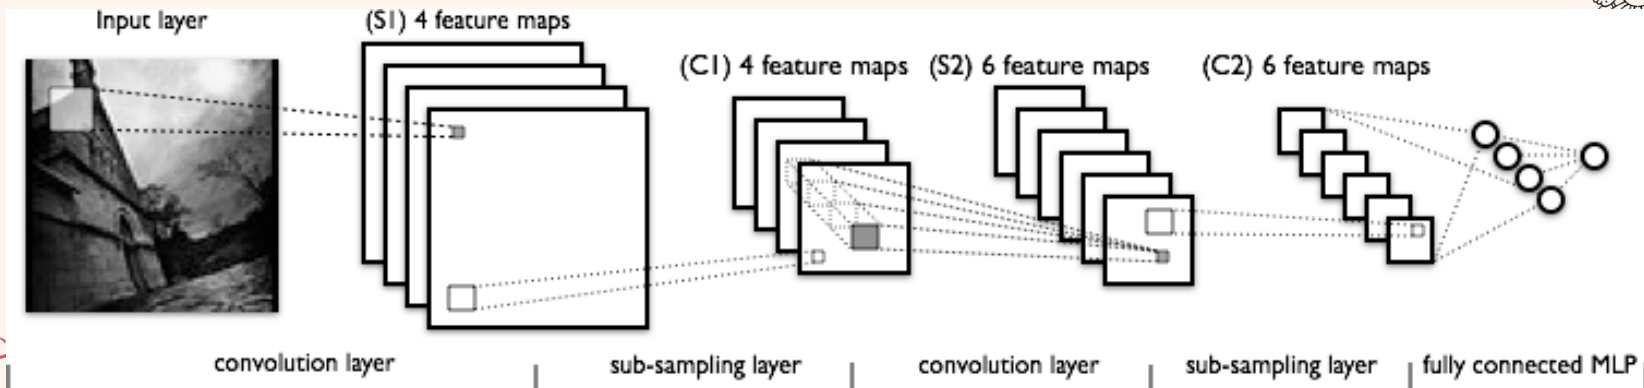
Convolutional Neural Networks

- در این حالت خروجی این لایه در مواردی که یک الگو تکرار شود، مقدار بالایی خواهد بود.
- در لایه‌های بعدی، براساس این خصیصه‌ها، خصیصه‌های جدید استخراج می‌شود.
- با توجه به مشابهت محاسباتی هر گره در این لایه با کانولوشن معمولی، شبک‌ی کانولوشنی نامیده شده‌اند.



Sub-Sampling (Pooling)

- عملاً لایه‌ی کانولوشن باعث می‌شود تعداد خصیصه‌ها افزایش یابد.
- در این لایه ابعاد با روش‌هایی چون میانگین‌گیری یا جایگزین کردن مقدار بیشینه کاهش می‌یابد.
- بدین ترتیب وابستگی خصیصه‌ی استخراج شده به مکان کاهش می‌یابد.



LeNet-5(60000/340000)





Fig. 2. Architecture of LeNet-5, a Convolutional Neural Network, here for digits recognition. Each plane is a feature map, i.e. a set of units whose weights are constrained to be identical.

Layer	Trainable Weights	Connections
C1	$(25+1)*6 = 156$	$(25+1)*6*28*28 = 122,304$
S2	$(1+1)*6 = 12$	$(4+1)*6*14*14 = 5880$ (2x2 links and bias)
C3	$6*(25*3+1) + 9*(25*4+1) + 1*(25*6+1) = 1516$	$1516*10*10 = 151,600$
S4	$16*2 = 32$	$16*5*5*5 = 2000$ (2x2 links and bias)
C5	$120*(5*5*16+1) = 48,120$	Same since fully connected MLP at this point
F6	$84*(120+1) = 10,164$	Same
Output	$10*(84+1) = 850$ (RBF)	Same



آموزش (پس انتشار خطا)


در این حالت قانون پس انتشار خطا به صورت زیر اصلاح می شود:

To constrain: $w_1 = w_2$
we need: $Dw_1 = Dw_2$

compute: $\frac{\partial E}{\partial w_1}$ and $\frac{\partial E}{\partial w_2}$


use $\frac{\partial E}{\partial w_1} + \frac{\partial E}{\partial w_2}$ for w_1 and w_2


تمام پارامترهای آزاد، با کمی الگوریتم پس انتشار خطا قابل آموزش می باشند.



آموزش (پس انتشار خطا)

- استفاده از پیش آموزش به صورت بی نظارت و سپس آموزش با الگوریتم پس انتشار خطا می تواند باعث افزایش کاری شود.
- بعد از فاز پیش آموزش (auto-encoder)، یک لایه به شبکه برای دسته بندی اضافه می شود.
- سپس شبکه با استفاده از شیوهی با نظارت همی وزن ها آموزش می بینند.






224×224×3

شبکه AlexNet

LSVRC-2010

برای دسته‌بندی ۱,۲ میلیون تصویر
 ۱۰۰۰ دسته‌ی مختلف
 ۶۵۰۰۰۰ نورون و ۶۰ میلیون پارامتر آزاد
 پنج لایه‌ی کانولوشن و سه لایه‌ی متصل
 ۳۷ و ۱۷ درصد خطای top5 و top1
 از drop out استفاده می‌کند.



A. Krizhevsky, I. Sutskever, and G. E. Hinton, "Imagenet classification with deep convolutional neural networks," in *Advances in neural information processing systems*, 2012, pp. 1097-1105.


شبکه عصبی

فرب شبكه‌هاى عميق



We demonstrated that deep neural networks have counter-intuitive properties both with respect to the semantic meaning of individual units and with respect to their discontinuities (Szegedy2013).


adversarial examples




Differences

image predicted incorrectly

correctly predicted sample






Differences


image predicted incorrectly

correctly predicted sample




تراشگاه
سپهر
بهشتی

فريب شبکه‌های عصبی عميق



Nguyen, A., J. Yosinski, and J. Clune. Deep neural networks are easily fooled: High confidence predictions for unrecognizable images. in 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2015.


فرب شبكه‌هاى عصبى عميق




king penguin




starfish




baseball




electric guitar




freight car



remote control



peacock



African grey



ژانك
بهرى

- Raina, R., et al., *Self-taught learning: transfer learning from unlabeled data*, in *Proceedings of the 24th international conference on Machine learning*. 2007, ACM: Corvalis, Oregon, USA. p. 759-766.
- Szegedy, C., et al., *Intriguing properties of neural networks*. *arXiv preprint arXiv:1312.6199*, 2013.
- Nguyen, A., J. Yosinski, and J. Clune. *Deep neural networks are easily fooled: High confidence predictions for unrecognizable images*. in *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2015.
- <https://www.macs.hw.ac.uk/~dwcorne/Teaching/dmml.htm>

