

# یادگیری عمیق

دکتر امین گلزاری اسکویی

[a.golzari@azaruniv.ac.ir](mailto:a.golzari@azaruniv.ac.ir)

[a.golzari@tabrizu.ac.ir](mailto:a.golzari@tabrizu.ac.ir)

<https://github.com/Amin-Golzari-Oskouei>



دانشگاه شهید مدنی آذربایجان

پاییز ۱۴۰۱

# فصل ۴

## اصول یادگیری ماشین

### مطالب این فصل

انواع دیگر یادگیری ماشین به غیر از دسته‌بندی و رگرسیون

روال‌های ارزیابی رسمی برای مدل‌های یادگیری ماشین

آماده‌سازی نمونه‌ها برای یادگیری عمیق

مهندسی ویژگی

نمونه مقابله با بیش‌برازش

گردش کار کلی برای حل مسائل یادگیری عمیق

## چهار شاخه یادگیری ماشین

یادگیری با ناظر

یادگیری بدون ناظر

یادگیری خودنظارتی

یادگیری تقویتی

## یادگیری با ناظر

✓ یادگیری با ناظر متداول‌ترین نوع یادگیری است.

✓ تمامی چهار مثالی که در این کتاب با آنها روبرو شده‌اید، مثال‌های متعارف یادگیری با ناظر هستند.

✓ نگاشت نمونه‌های ورودی به اهداف شناخته‌شده با استفاده از مجموعه‌ای از نمونه‌ها (که اغلب به وسیله انسان برچسب‌گذاری می‌شوند) است.

✓ دو دسته‌بندی مرسوم: دسته‌بندی و رگرسیون است.

✓ جمع‌آوری داده هزینه‌بر است.



## یادگیری با ناظر

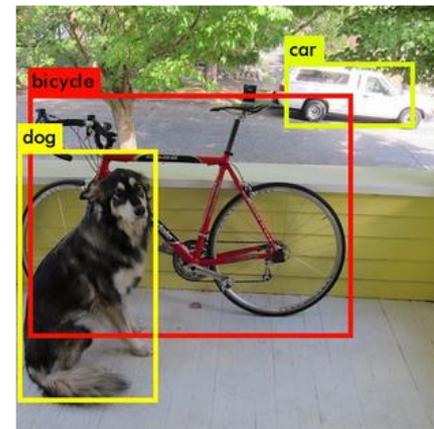
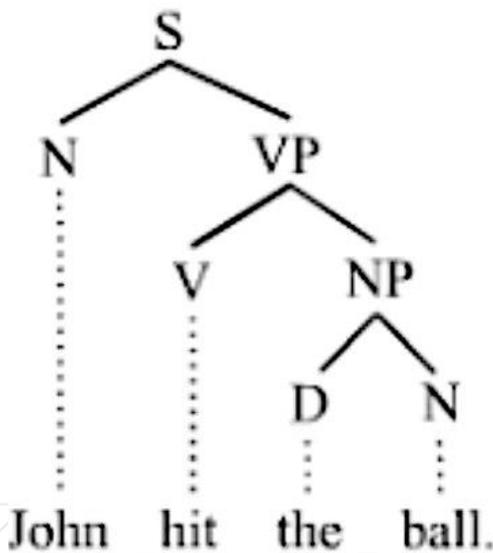
✓ مثال‌های فارق‌العاده از یادگیری با ناظر:

✓ پیش‌بینی عنوان برای توصیف یک تصویر

✓ تشخیص اشیا

✓ پیش‌بینی درخت نمودی

I think it's a man in a yellow flower and he seems 😊.

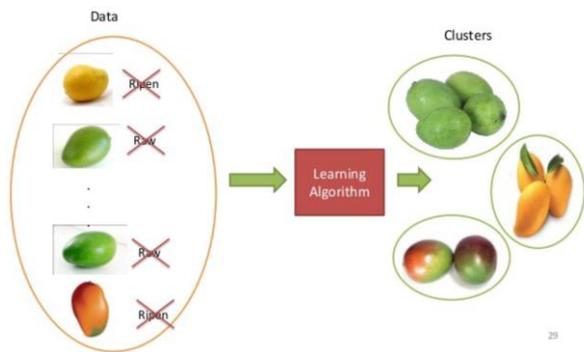


## یادگیری بدون ناظر

✓ یافتن تبدیل‌های جالب برای نمونه‌های ورودی بدون استفاده از برچسب نمونه‌ها.

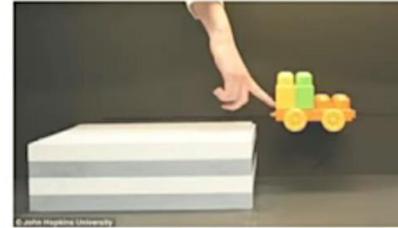
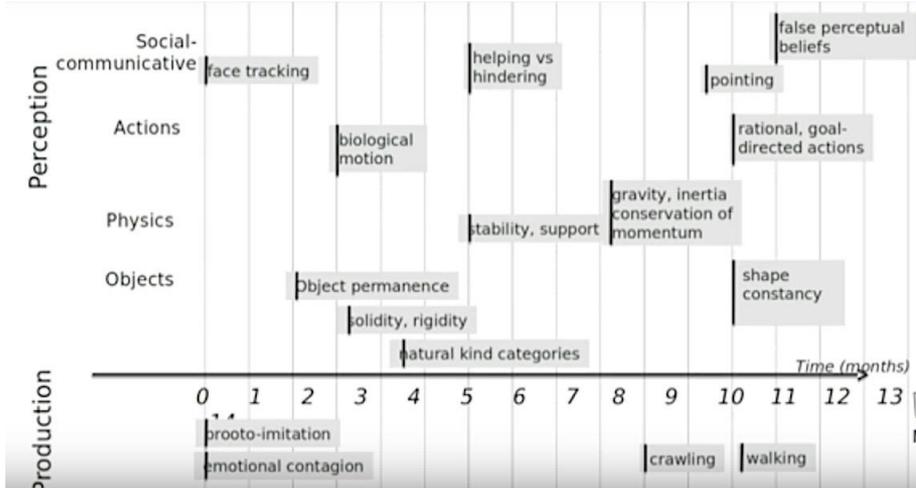
✓ یادگیری بدون ناظر بخش اصلی تحلیل نمونه‌ها است و اغلب گامی ضروری برای درک بهتر مجموعه داده قبل از آغاز حل مسئله‌ی یادگیری با ناظر است.

✓ بسیاری از محققان مانند Yann Lecun پیش‌بینی می‌کنند که مرز بعدی هوش مصنوعی در یادگیری بدون نظارت است.



29

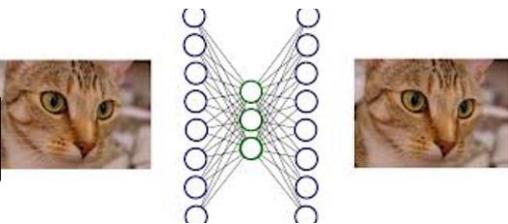
# یادگیری بدون ناظر



## یادگیری خودنظارتی

یادگیری خودنظارتی نوعی یادگیری با ناظر بدون برچسب‌های ایجاد شده به وسیله انسان است. به عنوان مثال:

○ خودکدهاها نمونه معروفی از یادگیری خودنظارتی هستند که در آن‌ها اهداف تولید شده همان ورودی‌های بدون تخریب هستند.



○ پیش‌بینی فریم بعدی در یک ویدیو با استفاده از فریم‌های قبلی

○ پیش‌بینی کلمه بعدی در یک متن با استفاده از کلمات قبلی

## یادگیری خودنظارتی



✓ توجه داشته باشید که تفاوت بین یادگیری‌های با ناظر، خودنظارتی و بدون ناظر ممکن است برخی مواقع مبهم باشد (مرز کاملاً مشخصی بین آنها قابل ترسیم نیست). یادگیری خودنظارتی را می‌توان هم به عنوان یادگیری با ناظر و هم به عنوان یادگیری بدون ناظر تعبیر و تفسیر نمود. تعبیر و تفسیر آن به در نظر گرفتن سازوکار یادگیری یا کاربرد آن بستگی دارد.

retrieved using 256 bit codes

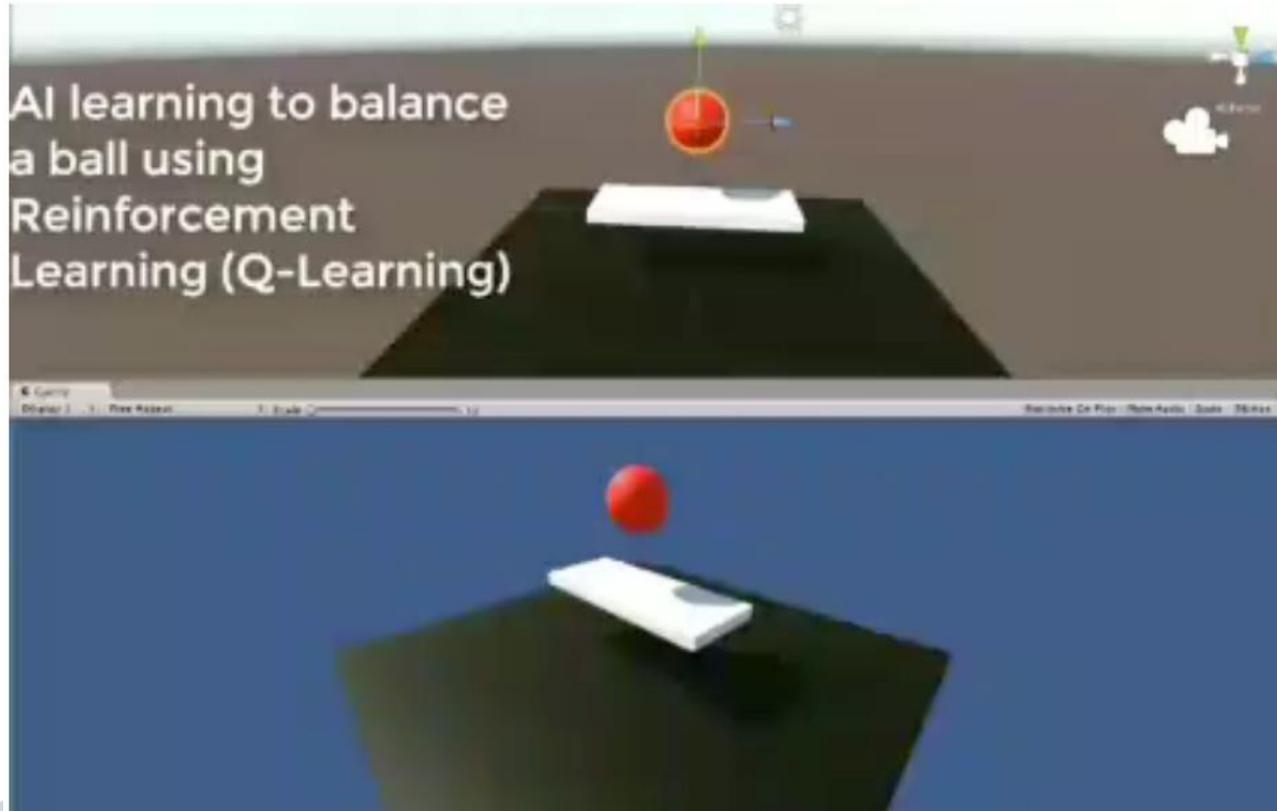


retrieved using Euclidean distance in pixel intensity space



## یادگیری تقویتی

- ✓ این شافه که برای مدت طولانی مهجور مانده بود، اخیراً بعد از موفقیت گوگل دیپ مایند در استفاده از آن برای یادگیری بازی‌های آتاری (و سپس یادگیری بازی گو در بالاترین سطح)، توجه بسیاری را به خود جلب کرده است.
- ✓ در یادگیری تقویتی، یک عامل بر اساس اطلاعات دریافتی از محیط، یاد می‌گیرد فعالیت‌هایی را انتخاب کند که بیشترین پاداش را برایش در پی داشته باشند.
- ✓ یادگیری تقویتی بیشتر یک موزه پژوهشی است و هیچ موفقیت عملی را خارج از محدوده بازی‌ها کسب نکرده است.



## ارزیابی مدل‌های یادگیری ماشین

در یادگیری ماشین، هدف به دست آوردن مدل‌هایی است که **تعمیم‌پذیر** هستند (روی نمونه‌هایی که هرگز ندیده‌اند فوب عمل می‌کنند) و بیش‌برازش مانع عمده آن است.

ما تنها می‌توانیم آنچه را که اطلاعات آن را دریافت می‌کنیم کنترل کنیم، بنابراین سنجش قابلیت تعمیم مدل از اهمیت زیادی برخوردار است.

ما عمدتاً به نمونه‌ی سنجش تعمیم مدل فوایم پرداخت: چگونه باید مدل‌های یادگیری ماشین را ارزیابی کنیم.

## ارزیابی مدل‌های یادگیری ماشین

ارزیابی مدل همواره به تقسیم نمونه‌ها به سه مجموعه خلاصه می‌شود: **آموزشی**، **اعتبارسنجی** و **آزمایش**. مدل را با نمونه‌های آموزشی، آموزش می‌دهیم و با نمونه‌های اعتبارسنجی، ارزیابی می‌کنیم. زمانی که مدل در بهترین حالت خود است، عملکردش را برای بار آخر روی نمونه‌های آزمایش، می‌سنجیم.

## ارزیابی مدل‌های یادگیری ماشین

شاید بپرسید چرا نباید فقط دو مجموعه آموزش و مجموعه آزمایش داشته باشیم؟

علت این است که توسعه یک مدل، همیشه دربرگیرنده تنظیم پیکربندی آن است: به عنوان مثال، انتخاب تعداد لایه‌ها و اندازه لایه‌ها (برای تمییز از پارامترها که وزن‌های شبکه هستند، ابر پارامترها نامیده می‌شوند). این تنظیم با استفاده از عملکرد مدل روی نمونه‌های اعتبارسنجی به عنوان سیگنال بازخورد صورت می‌گیرد. در حقیقت، این تنظیم، نوعی یادگیری است: یعنی جستجوی پیکربندی فوب در فضای پارامتر.

در نتیجه، تنظیم پیکربندی مدل بر اساس عملکرد آن روی مجموعه اعتبارسنجی می‌تواند به سرعت به **بیش‌برازش** مدل (روی مجموعه اعتبارسنجی) **(نشست اطلاعات)** منتهی شود، حتی اگر مدل هرگز مستقیماً روی آن آموزش ندیده باشد.



01000101101010000  
001011010100010000  
00010000

## ارزیابی مدل‌های یادگیری ماشین



در پایان، با مدلی روبرو خواهید بود که به طور غیر واقعی روی نمونه‌های اعتبارسنجی فوب عمل می‌کند، چراکه شما آن را به این صورت ارتقا داده و اصلاح کرده‌اید. اگر به غیر از نمونه‌های اعتبارسنجی، به عملکرد مدل روی نمونه‌های کاملاً جدید اهمیت می‌دهید، پس باید برای ارزیابی مدل از مجموعه داده‌ای کاملاً متفاوت، یعنی نمونه‌های آزمایش استفاده کنید که مدل هرگز ندیده است. مدل، هرگز نباید به هیچ اطلاعاتی حتی به صورت غیرمستقیم درباره مجموعه آزمایش دسترسی داشته باشد.

## ارزیابی مدل‌های یادگیری ماشین

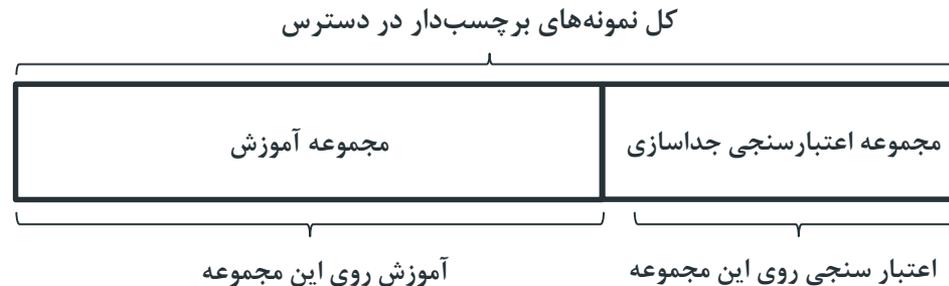
سه روش شناخته شده ارزیابی عبارتند از:

- اعتبارسنجی به روش جداسازی ساده
- اعتبارسنجی  $K$  بفتشی:
- اعتبارسنجی مکرر  $K$  بفتشی با درهم سازی

# ارزیابی مدل‌های یادگیری ماشین

اعتبارسنجی به روش جداسازی ساده:

یک بخش از نمونه‌ها را به عنوان مجموعه آزمایش جدا کنید. مدل را با استفاده از باقیمانده نمونه‌ها آموزش داده و روی مجموعه آزمایش ارزیابی کنید. همان‌طور که در بخش قبل مشاهده کردید، برای اجتناب از نشت اطلاعات نباید مدل را بر اساس مجموعه آزمایش تنظیم کنید، بنابراین نیاز به یک مجموعه اعتبارسنجی دارید.



# ارزیابی مدل‌های یادگیری ماشین

## اعتبارسنجی K بفش:

در این رویکرد، نمونه‌ها را به K بفش با اندازه یکسان تقسیم کنید. برای هر بفش  $i$ ، مدل را روی  $K-1$  بفش باقیمانده آموزش داده و آن را روی بفش  $i$  اعتبارسنجی کنید. بدین ترتیب، نتیجه نهایی اعتبارسنجی برابر با میانگین نتایج به دست آمده از K اعتبارسنجی خواهد بود.

این روش زمانی کارساز است که عملکرد مدل، واریانس قابل توجهی بر اساس تقسیم آموزش - آزمایش نشان دهد؛

تقسیم نمونه‌ها به ۳ بخش



## ارزیابی مدل‌های یادگیری ماشین

### اعتبارسنجی مکرر $K$ بخشی با درهم سازی:

- این اعتبارسنجی برای مواقعی است که نمونه‌های کمی در اختیار دارید و لازم است که ارزیابی شما از مدل تا حد ممکن دقیق باشد.
- این روش عبارت است از اعمال اعتبارسنجی  $K$  بخشی به دفعات مکرر با درهم سازی هر باره نمونه‌ها قبل از تقسیم کردن به  $K$  بخش.

## مواردی که باید به خاطر بسپارید

هنگام انتخاب روش اعتبارسنجی، به موارد زیر دقت کنید:

**نماینده مناسبی از نمونه‌ها:** انتظار دارید که هر دو مجموعه آموزش و آزمایش نماینده نمونه‌های موجود باشند. به عنوان مثال، اگر هنگام دسته‌بندی تصاویر ارقام از آرایه‌ای از نمونه‌هایی شروع کنید که بر اساس کلاسشان مرتب شده‌اند، انتخاب 80 درصد آرایه به عنوان مجموعه آموزش و 20 درصد باقیمانده به عنوان مجموعه آزمایش موجب خواهد شد که مجموعه آموزش تنها شامل کلاس‌های صفر تا 7 بوده و مجموعه آزمایش دربرگیرنده کلاس‌های 8 و 9 باشد. به نظر اشتباه مضمکی می‌آید، اما به طور باورنکردنی‌ای متداول است. به همین دلیل، اغلب قبل از تقسیم نمونه‌ها به بخش‌های آموزش و آزمایش باید آن‌ها را به صورت تصادفی بر بزنید.

## مواردی که باید به خاطر بسپارید

هنگام انتخاب روش اعتبارسنجی، به موارد زیر دقت کنید:

**ترتیب زمانی:** اگر می‌خواهید آینده را با نمونه‌های گذشته پیش‌بینی کنید (به عنوان مثال، هوای فردا، جابجایی سهام و غیره)، نباید قبل از تقسیم نمونه‌ها آن‌ها را به صورت تصادفی برهم بزنید، چراکه در این حالت نشئت زمانی ایجاد خواهد شد: مدل با استفاده از نمونه‌های آینده آموزش خواهد دید. در چنین موقعیت‌هایی، باید همواره اطمینان حاصل کنید که نمونه‌های آزمایش به لحاظ زمانی پس از نمونه‌های آموزشی قرار داشته باشند.

## مواردی که باید به خاطر بسپارید

هنگام انتخاب روش اعتبارسنجی، به موارد زیر دقت کنید:

**تکرار نمونه‌ها:** اگر برخی از نمونه‌ها چندین بار دیده می‌شوند (در نمونه‌های دنیای واقعی کاملاً متداول است)، بر زدن نمونه‌ها و تقسیم آن‌ها به مجموعه آموزش و اعتبارسنجی موجب تکرار نمونه‌ها بین مجموعه‌های آموزشی و اعتبارسنجی خواهد شد. در حال آزمایش روی نمونه‌های آموزشی خواهید بود که بدترین کار ممکن است! لذا از عدم وجود نمونه مشترک میان مجموعه آموزش و مجموعه اعتبارسنجی اطمینان حاصل کنید.

## پیش‌پردازش نمونه‌ها، مهندسی ویژگی و یادگیری ویژگی

هدف از پیش‌پردازش نمونه‌ها، آماده‌سازی نمونه‌های خام برای شبکه‌های عصبی است. پیش‌پردازش این موارد را در برمی‌گیرد: بردارسازی، نرمال‌سازی، مدیریت مقادیر ناموجود و استخراج ویژگی.

بسیاری از فنون پیش‌پردازش نمونه‌ها و مهندسی ویژگی حوزه محور هستند (به عنوان مثال، مختص نمونه‌های متنی یا نمونه‌های تصویری هستند).

## پیش‌پردازش نمونه‌ها، مهندسی ویژگی و یادگیری ویژگی

**بردارسازی:** تمامی ورودی‌ها و اهداف در شبکه عصبی باید تنسورهایی از نوع ممیز شناور (در موارد خاص، تنسورهای اعداد صحیح) باشند.

به عنوان مثال، در دو مثال پیشین دسته‌بندی متن، از بازنمایی متن به صورت لیست اعداد صحیح شروع کرده و از کدگذاری تک-یک برای تبدیلشان به تنسور داده float32 استفاده کردیم. در مثال‌های دسته‌بندی ارقام و پیش‌بینی قیمت مسکن، خود نمونه‌ها به صورت برداری بودند و نیازی به انجام این مرحله نبود.

**نرمال‌سازی مقدار:** بسیاری از فنون پیش‌پردازش نمونه‌ها و مهندسی ویژگی حوزه محور هستند (به عنوان مثال، مختص نمونه‌های متنی یا نمونه‌های تصویری هستند).

## پیش‌پردازش نمونه‌ها، مهندسی ویژگی و یادگیری ویژگی

**نرمال‌سازی مقدار:** برای تسهیل یادگیری شبکه، نمونه‌ها باید دارای مشخصات زیر باشند:

- دارای مقادیر کوچک باشند – عموماً، اکثر مقادیر باید در دامنه 0-1 باشند.
- همگن باشند – یعنی، مقادیر تمامی ویژگی‌ها باید تقریباً در دامنه یکسانی قرار بگیرند.

علاوه بر این، با وجود اینکه روش نرمال‌سازی دقیق زیر همیشه ضروری نیست، ولی استفاده از آن متداول بوده و می‌تواند مفید واقع شود:

- هر ویژگی را به طور مستقل نرمال‌سازی کنید تا میانگین صفر داشته باشد.
- هر ویژگی را به طور مستقل نرمال‌سازی کنید تا انحراف معیار آن برابر با 1 باشد.

## پیش‌پردازش نمونه‌ها، مهندسی ویژگی و یادگیری ویژگی

**مدیریت مقادیر ناموجود:** به طور کلی، در شبکه‌های عصبی، بهتر است مقادیر ناموجود به عنوان صفر وارد شوند؛ البته با این شرط که صفر یک مقدار معنادار نباشد.

توجه کنید که اگر برقی از مقادیر در میان نمونه‌های آزمایش ناموجود هستند، اما شبکه بدون آن‌ها آموزش دیده است، پس نادیده گرفتن آن‌ها را یاد نگرفته است! در چنین موقعیتی، باید به طور تصادفی نمونه‌های آموزشی با ورودی‌های ناموجود ایجاد کنید: برقی از نمونه‌های آموزشی را چند بار کپی کنید و برقی از ویژگی‌های آن‌ها را که فکر می‌کنید در نمونه‌های آزمایش موجود نیستند، حذف کنید.

## پیش‌پردازش نمونه‌ها، مهندسی ویژگی و یادگیری ویژگی

**مهندسی ویژگی:** مهندسی ویژگی فرایند استفاده از دانش فودمان در مورد نمونه‌ها و الگوریتم موجود یادگیری ماشین (در این مورد، شبکه عصبی) به منظور کارایی بهتر الگوریتم است.

نمونه‌های فام: ماتریسی از پیکسل‌ها



ویژگی‌های بهتر: مختصات عقربه‌های ساعت

$\{x1: 0.7, y1: 0.7\}$   
 $\{x2: 0.5, y2: 0.0\}$

$\{x1: 0.0, y2: 1.0\}$   
 $\{x2: -0.38, y2: 0.32\}$

ویژگی‌های بهتر از آن: زوایای عقربه‌های ساعت

theta1: 45, theta2: 0

theta1: 90, theta2: 140

## پیش‌پردازش نمونه‌ها، مهندسی ویژگی و یادگیری ویژگی

قبل از یادگیری عمیق، مهندسی ویژگی نقشی حیاتی داشت، چراکه الگوریتم‌های سنتی به اندازه‌ای مجهز به فضای فرضیه غنی نبودند که ویژگی‌های مفید را خودشان یاد بگیرند و در نتیجه نمونه‌ی ارائه‌شده به الگوریتم برای موفقیت آن ضروری بود.

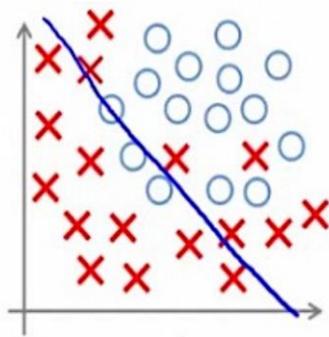
به عنوان مثال، قبل از اینکه شبکه‌های عصبی کانولوشنی در مسئله دسته‌بندی ارقام MNIST موفق عمل کنند، راه‌حل‌ها اساساً بر ویژگی‌هایی از قبیل تعداد حلقه‌ها در تصویر رقم، ارتفاع هر رقم در تصویر، هیستوگرام مقادیر پیکسل و غیره مبتنی بودند.

## پیش‌پردازش نمونه‌ها، مهندسی ویژگی و یادگیری ویژگی

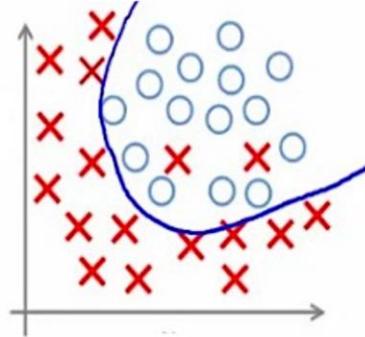
فوشبختانه، یادگیری عمیق در اکثر موارد نیاز به مهندسی ویژگی را مرتفع می‌سازد، چراکه شبکه‌های عصبی این توانایی را دارند که به طور خودکار ویژگی‌های مفید را از نمونه‌های خام استخراج کنند. آیا این بدین معنی است که استفاده از شبکه‌های عصبی عمیق نیاز به مهندسی ویژگی را مرتفع می‌سازد؟

- ویژگی‌های فوب این امکان را فراهم می‌سازند که مسائل را با استفاده از منابع کمتر و با ظرافت بیشتری حل کنید.
- ویژگی‌های فوب امکان حل مسئله با نمونه‌های بسیار کم را فراهم می‌آورند.

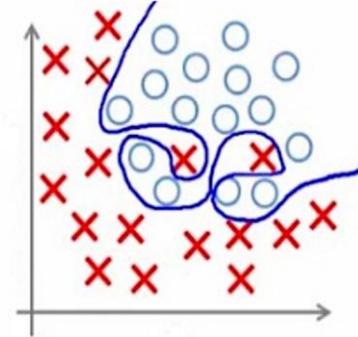
## بیش‌برازش و کم‌برازش



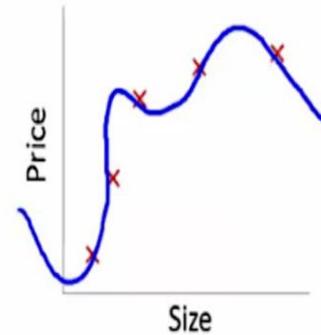
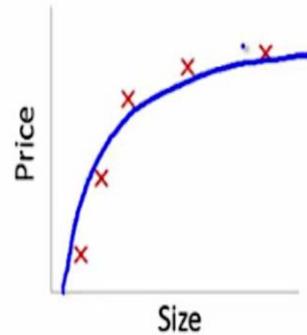
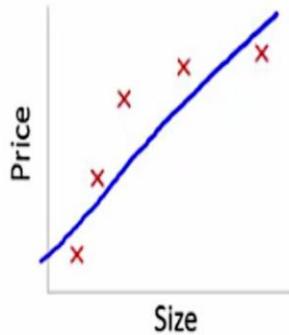
Under-fitting



Appropriate-fitting



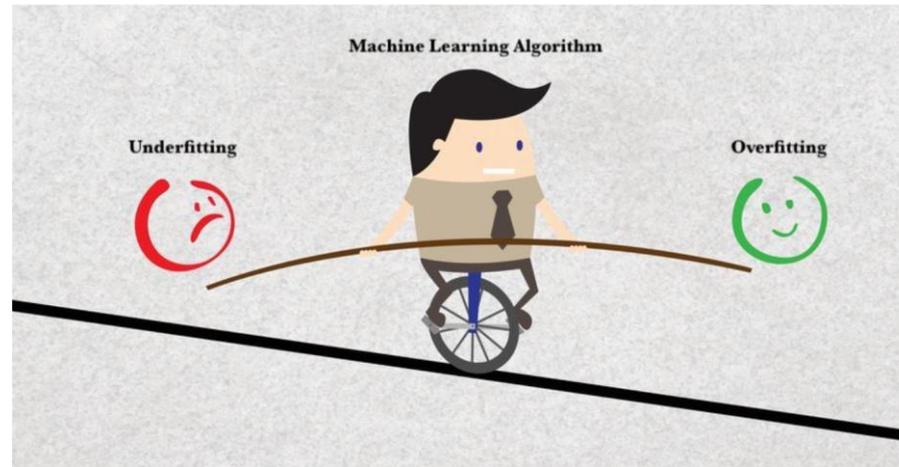
Over-fitting



Images courtesy of Andrew Ng

## بیش‌برازش و کم‌برازش

مسئله اساسی در یادگیری ماشین ایجاد توازن بین بهینه‌سازی و تعمیم است. . بهینه‌سازی به فرایند تنظیم مدل به منظور رسیدن به بهترین عملکرد ممکن (روی نمونه‌های آموزشی اطلاق می‌گردد. در حالی که تعمیم، نحوه عملکرد مدل آموزش دیده روی نمونه‌هایی است که هرگز ندیده است.



## بیش‌برازش و کم‌برازش



دو الگو در یک مجموعه داده وجود دارد:

الگوهای خاص این داده‌ها

الگوهای کلی برای همه داده‌های این نوع

به عبارتی:

کم‌برازش ناتوانی مدل در گرفتن الگوهای کلی است

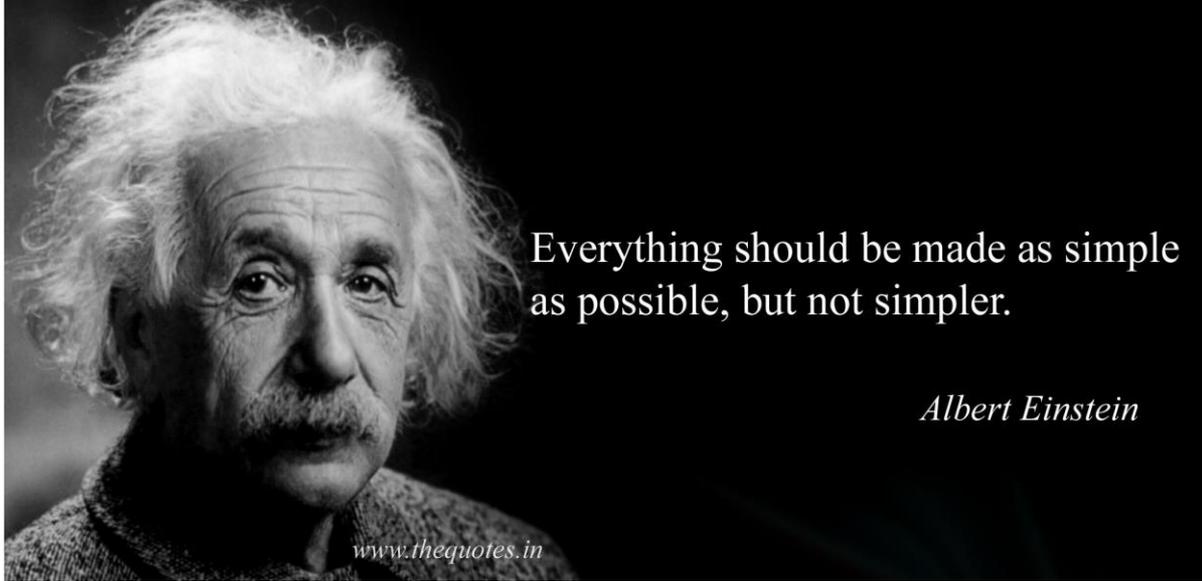
بیش‌برازش، گرفتن الگوهای خاص داده است

به عبارتی دیگر:

بیش‌برازش شبیه به داشتن حالات بیش از حد ضروری است. به عنوان مثال، فنجان‌ها باید دسته داشته باشند.

کم‌برازش شبیه به داشتن حالات کمتر از حد ضروری است. به عنوان مثال، فنجان‌ها نیازی به باز بودن در بالا ندارند.

## بیش برآزش و کم برآزش



Everything should be made as simple  
as possible, but not simpler.

*Albert Einstein*

[www.thequotes.in](http://www.thequotes.in)

## بیش‌برازش و کم‌برازش

هدف به دست آوردن قدرت تصمیم بالا است، اما شما تصمیم را کنترل نمی‌کنید؛ فقط می‌توانید مدل را بر اساس نمونه‌های آموزشی تنظیم نمایید.

بیش‌برازش به دلایل زیر رخ می‌دهد:

تعداد نمونه کم

مدل بیش از حد پیچیده

مشکل اصلی در یادگیری عمیق بیش‌برازش است.

## بیش‌برازش و کم‌برازش

بهترین راه‌حل برای جلوگیری از یادگیری الگوهای نامربوط یا گمراه‌کننده به وسیله مدل، فراهم کردن نمونه‌های آموزشی بیشتر است. مدلی که روی نمونه‌های بیشتری آموزش دیده باشد، طبیعتاً قابلیت تعمیم بهتری خواهد داشت.

زمانی که امکان استفاده از نمونه‌های زیاد وجود نداشته باشد، بهترین راه‌حل، تعدیل میزان اطلاعات ذخیره‌شده به وسیله مدل و یا ایجاد محدودیت در مورد اطلاعاتی است که مدل می‌تواند ذخیره نماید. اگر شبکه‌ای قابلیت یادگیری تعداد کمی الگو را داشته باشد، فرایند بهینه‌سازی آن را وادار به تمرکز روی برجسته‌ترین الگوها خواهد نمود که شانس بهتری برای تعمیم دارند.

فرایند مقابله با بیش‌برازش با این شیوه‌ها، **تنظیم** نامیده می‌شود.

## بیش‌برازش و کم‌برازش

برخی از متداول‌ترین فنون مقابله با بیش‌برازش (**تنظیم**):

○ کاهش اندازه شبکه

○ اضافه نمودن تنظیم وزن

○ حذف تصادفی



○ ممکن است با اصل تیغ اوکام آشنا باشید: اگر دو توضیح برای یک مسئله مشخص داده شده باشد، به احتمال زیاد ساده‌ترین توضیح صحیح است.

## کاهش اندازه شبکه

کاهش تعداد پارامترهای قابل یادگیری در مدل (که تعداد لایه‌ها و تعداد واحدها در هر لایه آن را معین می‌سازد).

در یادگیری عمیق، تعداد پارامترهای قابل یادگیری در مدل، اغلب به عنوان **ظرفیت** یاد می‌شود.

باید بین ظرفیت بیش از حد و ظرفیت ناکافی موازنه ایجاد شود.

متأسفانه، برای تعیین تعداد مناسب لایه‌ها یا اندازه مناسب برای هر لایه هیچ فرمول جادویی وجود ندارد.

## اضافه نمودن تنظیم وزن

در مورد مدل‌هایی که شبکه‌های عصبی یاد می‌گیرند اصل تیغ اوکام نیز صادق است: بیش‌برازش در مدل‌های ساده‌تر (با وزن‌های کوچک) بسیار کم‌تر از مدل‌های پیچیده است.

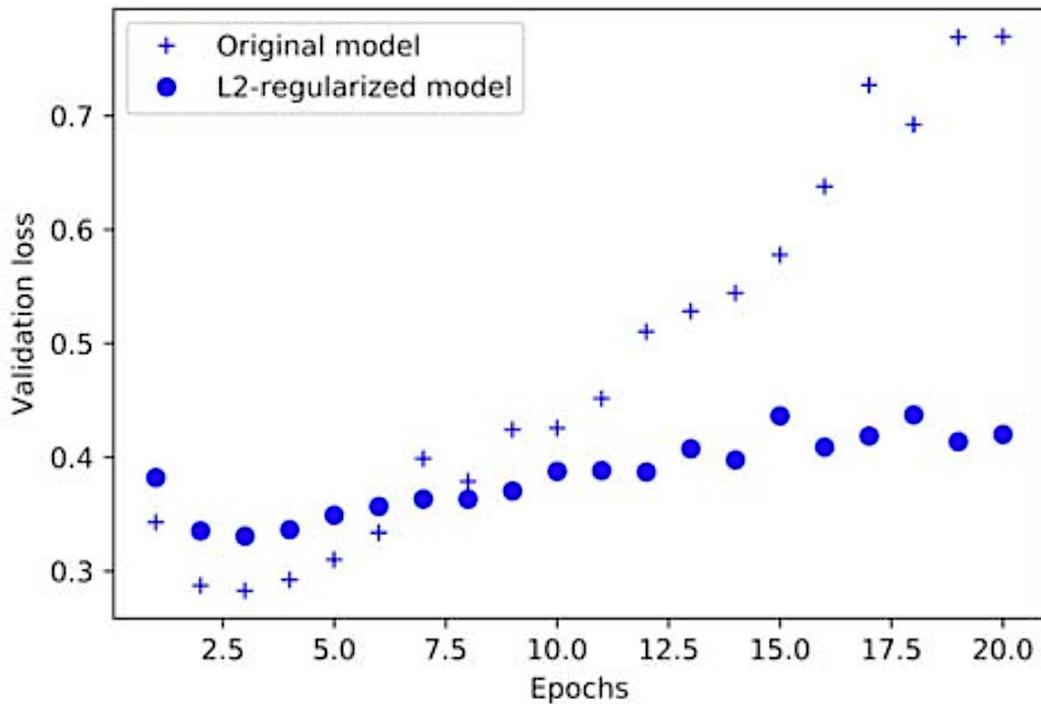
یکی از شیوه‌های معمول کنترل بیش‌برازش، محدود کردن پیچیدگی شبکه با محدود کردن وزن‌های آن به مقادیر کوچک است که موجب توزیع منظم‌تر مقادیر وزن می‌شود. این عمل تنظیم وزن نامیده می‌شود.

تنظیم وزن با اضافه کردن هزینه‌ای به تابع خطا شبکه انجام می‌شود که با داشتن وزن‌های بزرگ همراه است:

تنظیم L1: هزینه اضافه شده متناسب با مقدار مطلق مقادیر وزن‌ها  $(Loss + \lambda \sum |W|)$

تنظیم L2: هزینه اضافه شده متناسب با مربع مقادیر وزن‌ها  $(Loss + \lambda \sum W^2)$

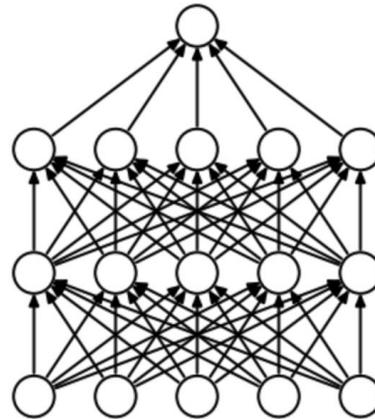
## اضافه نمودن تنظيم وزن



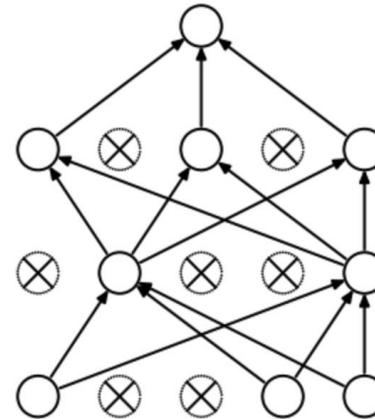
## اضافه نمودن حذف تصادفی

اعمال حذف تصادفی روی یک لایه عبارت از کنار گذاشتن تصادفی (صفر کردن) تعدادی از ویژگی‌های خروجی لایه در طول آموزش است.

نرخ حذف تصادفی برابر با کسر ویژگی‌هایی است که صفر شده‌اند و اغلب مقداری بین 0.2 و 0.5 دارد.



(a) Standard Neural Net



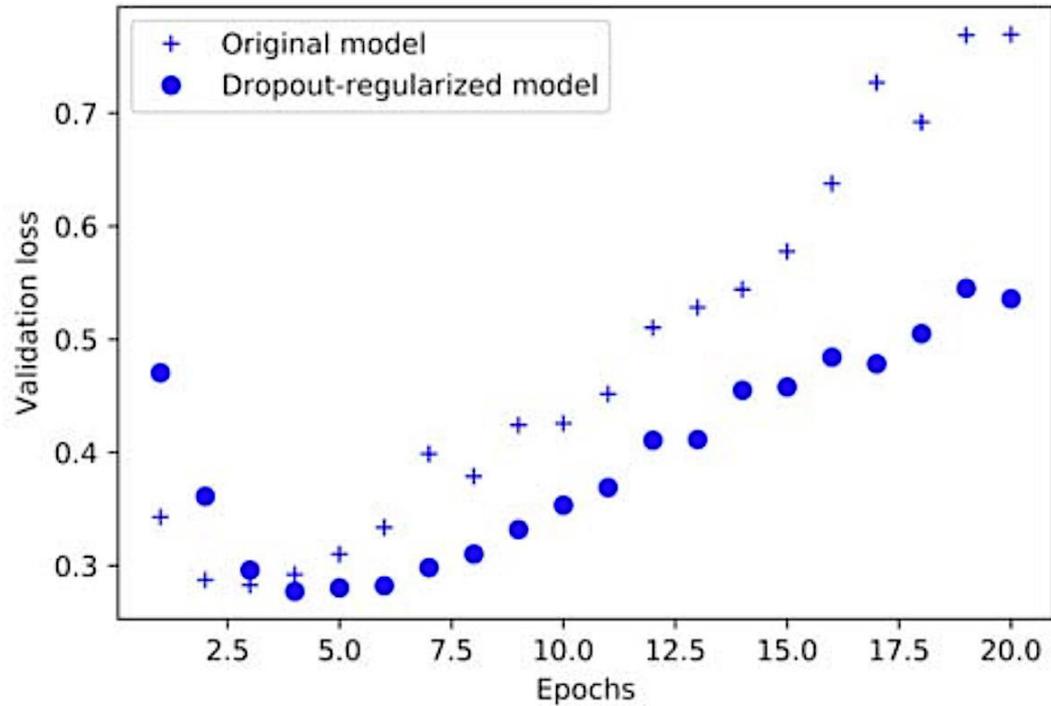
(b) After applying dropout.

## اضافه نمودن تنظیم وزن



ممکن است این روش عجیب و بی‌اساس به نظر برسد. چرا این کار به کاهش  
بیش‌برازش کمک می‌کند؟  
هیئت‌ون می‌گوید آنچه بیشتر از همه برای ما الهام‌بخش بود سازوکار ممانعت  
از کلاهبرداری بانک‌ها بود.

## اضافه نمودن حذف تصادفی



## روال جامع یادگیری ماشین

1- تعریف مسئله و فراهم نمودن مجموعه داده

2- انتخاب معیار موفقیت

3- تصمیم‌گیری در مورد روش ارزیابی

4- آماده‌سازی نمونه‌ها

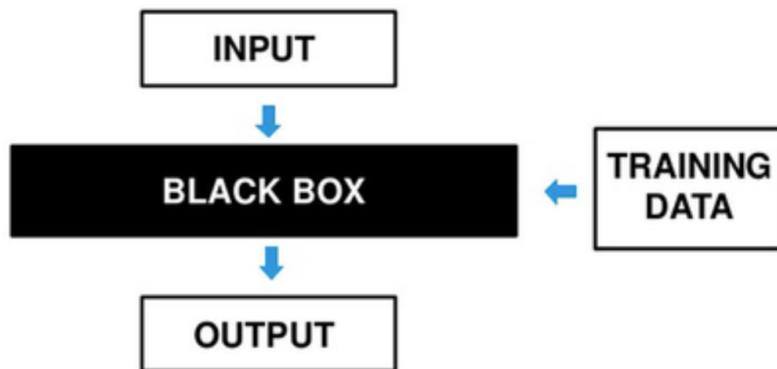
5- توسعه مدلی که بهتر از یک روش پایه عمل می‌کند

6- بالا بردن قدرت مدل: توسعه مدلی که بیش‌برازش دارد

7- تنظیم مدل و میزان کردن ابرپارامترها

## تعریف مسئله و فراهم نمودن مجموعه داده

نمونه‌های ورودی شما چه چیزهایی خواهند بود؟  
سعی دارید چه چیزی را پیش‌بینی کنید؟  
با چه نوع مسئله‌ای مواجه هستیم؟ (دسته‌بندی دودویی، رگرسیون، دسته‌بندی چند کلاسی، چند برچسبی)  
شناسایی نوع مسئله، راهنمای انتخاب معماری مدل، تابع هزینه و غیره است.



## تعریف مسئله و فراهم نمودن مجموعه داده

بدون شناخت ورودی‌ها و خروجی‌ها و اینکه از چه نمونه‌هایی استفاده خواهیم کرد، نمی‌توانیم به مرحله بعدی برویم. در این مرحله باید نسبت به فرضیه‌ای که می‌سازید آگاهی کامل داشته باشید:

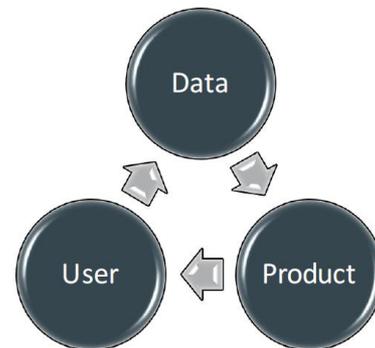
- در مورد اینکه با این ورودی‌ها می‌توان خروجی را پیش‌بینی نمود، فرضیه‌سازی می‌کنید.
- در مورد کافی بودن اطلاعات نمونه‌های در دسترس برای یادگیری رابطه بین ورودی‌ها و خروجی‌ها فرضیه‌سازی می‌کنید.

## تعريف مسئله و فراهم نمودن مجموعه داده



Andrew Ng: “Even though today I have a pretty good sense of how web search technology works, honestly have no idea how to build a small team to build a competitive nearly decent web search engine without access to that data asset.”

[https://www.youtube.com/watch?v=NKpuX\\_yzdYs](https://www.youtube.com/watch?v=NKpuX_yzdYs)



## تعریف مسئله و فراهم نمودن مجموعه داده

یک نوع از مسائل لاینحل که باید از آن‌ها مطلع باشید، مسائل ناپایدار هستند:

به عنوان مثال: فرض کنید می‌خواهید سیستم توصیه‌گر لباس بسازید، سیستم را با نمونه‌های تابستان آموزش داده و می‌خواهید تولید پیشنهادات را در زمستان شروع کنید. مشکل بزرگ این است که نوع لباس‌هایی که مردم می‌فرند از یک فصل به فصل دیگر متغیر است.

در این مورد، حرکت صمیغ، آموزش مجدد و مداوم مدل بر اساس نمونه‌های جدیدتر یا جمع‌آوری نمونه‌ها با مقیاس زمانی است که در آن مسئله پایدار است. برای مسائل دوره‌ای مانند فرید لباس، نمونه‌های چند سال برای کسب تخییرات فصلی کافی خواهد بود، اما فراموش نکنید که زمان سال متماً باید یکی از ورودی‌های مدل‌تان باشد.

## انتخاب معیار موفقیت

برای کنترل یک چیز باید بتوانید بر آن نظارت کنید. برای کسب موفقیت، نیاز است آن را تعریف کنید – صمت؟ دقت و نرخ فراخوانی؟ نرخ بقای مشتری؟

معیار شما برای موفقیت، راهنمای انتخاب **تابع هزینه** است: همان چیزی که مدل آن را بهینه خواهد کرد. این معیارها باید مستقیماً در راستای اهداف سطح بالای شما، مانند موفقیت کسب و کارتان باشند.

برای درک تنوع معیارهای موفقیت در یادگیری ماشین و نحوه ارتباط آنها با حوزه‌های مسائل مختلف، مرور رقابت‌های علوم داده در کگل مفید خواهد بود.

اهداف

معیار موفقیت

تابع فضا

## تصمیم‌گیری در مورد روش ارزیابی

پس از تعیین هدف، باید نمونه سنجش پیشرفت امور نیز تعیین گردد.

قبلاً سه نوع معمول روش‌های اعتبارسنجی را مرور کردیم:

- کنار گذاشتن مجموعه اعتبارسنجی جداسازی
- انجام اعتبارسنجی متقابل  $K$  بخشی
- انجام اعتبارسنجی مکرر  $K$  بخشی

فقط کافی است یکی از این روش‌ها را انتخاب کنید. در اکثر موارد، اولین گزینه جوابگو خواهد بود.

## آماده‌سازی نمونه‌ها

همان‌طور که قبلاً مشاهده کردید، نمونه‌ها باید به عنوان تانسور قالب‌بندی شوند.

مقادیر این تانسورها اغلب باید به بازه‌ای کوچک نگاشت شوند: به عنوان مثال در بازه  $[-1, 1]$  یا بازه  $[0, 1]$ .

در صورتی که ویژگی‌های مختلف دارای مقادیری در دامنه‌های مختلف هستند (نمونه‌های ناهمگن)، باید نمونه‌ها را نرمال‌سازی کنید.

ممکن است بخواهید مهندسی ویژگی را به ویژه برای مسائلی با نمونه‌های کم انجام دهید.

## توسعه مدلی که بهتر از یک روش پایه عمل می کند

هدف در این مرحله کسب قدرت (توان) آماری است؛ یعنی، ایجاد یک مدل کوچک که توانایی مقابله و شکست یک روش پایه ساده را داشته باشد. در مثال دسته بندی ارقام MNIST هر چیزی که دقت آن بزرگ تر از 0.1 باشد دارای قدرت آماری است؛ در مثال IMDB قدرت آماری متعلق به چیزی است که دقت آن بالای 0.5 است.

توجه داشته باشید که کسب قدرت آماری همواره مقدور نیست. اگر بعد از چندین معماری منطقی نتوانستید روش پایه تصادفی را شکست بدهید، این احتمال وجود دارد که پاسخ مدنظر برای سؤال شما در نمونه های ورودی وجود ندارد.

## توسعه مدلی که بهتر از یک روش پایه عمل می‌کند

با فرض اینکه همه چیز به خوبی پیش برود، لازم است برای ساخت اولین مدل عملی دست به سه انتخاب کلیدی بزنید:

○ فعال‌ساز آفرین لایه: محدودیت‌های مفیدی را به فروجی شبکه اعمال می‌کند.

○ تابع هزینه: باید با نوع مسئله‌ای که می‌خواهید حل کنید، همخوانی داشته باشد.

○ پیکربندی بهینه‌سازی: از چه بهینه‌سازی‌هایی استفاده خواهید کرد؟ نرخ یادگیری آن چقدر خواهد بود؟

## توسعه مدلی که بهتر از یک روش پایه عمل می کند



در مورد انتخاب تابع هزینه، باید بدانید که بهینه‌سازی معیاری که موفقیت مسئله را اندازه‌گیری می‌کند، همیشه به طور مستقیم امکان‌پذیر نیست. گاهی اوقات تبدیل معیار به تابع هزینه به هیچ عنوان کار ساده‌ای نیست. توابع هزینه لازم است تنها با داشتن زیردسته نمونه‌ها قابل محاسبه باشند (به طور ایده‌آل، تابع هزینه باید برای یک نمونه نیز قابل محاسبه باشد) و اینکه توابع هزینه باید مشتق‌پذیر باشند (در غیر این صورت برای آموزش شبکه نمی‌توانید از پس‌انتشار استفاده کنید).

## توسعه مدلی که بهتر از یک روش پایه عمل می کند

تابع هزینه	فعال سازی لایه آخر	نوع مسئله
binary_crossentropy	سیگموئید	دسته بندی دودویی
categorical_crossentropy	سافت مکس	دسته بندی یک برچسبی، چند کلاسی
binary_crossentropy	سیگموئید	دسته بندی چند برچسبی، چند کلاسی
mse	هیچ کدام	رگرسیون با مقادیر تصادفی
mse or binary_crossentropy	سیگموئید	رگرسیون مقادیر بین 0 و 1

## بالا بردن قدرت مدل: توسعه مدلی که بیش‌برازش دارد

بعد از دستیابی به مدلی با قدرت آماری، این سؤال پیش می‌آید که آیا مدل به اندازه کافی قدرتمند است؟ آیا لایه‌ها و پارامترهای کافی برای مدل‌سازی مسئله موردنظر را دارد؟

مدل آرمانی مدلی است که دقیقاً روی مرز بین کم‌برازش و بیش‌برازش و بین کم‌ظرفیتی و بیش‌ظرفیتی قرار می‌گیرد. برای دانستن جای این مرز، باید ابتدا از آن عبور کنید.

برای تعیین اندازه مدل موردنیاز، باید مدلی ایجاد کنید که بیش‌برازش داشته باشد. انجام این کار کاملاً آسان است:

- لایه‌هایی را اضافه کنید.
- لایه‌ها را بزرگ‌تر کنید.
- برای تکرار بیشتر آموزش دهید.

## تنظیم مدل و میزان کردن ابرپارامترها

این مرحله زمان برترین مرحله خواهد بود: مکرراً مدل را اصلاح خواهید کرد، آموزش خواهید داد و روی نمونه‌های اعتبارسنجی ارزیابی خواهید نمود (در این نقطه روی نمونه‌های آزمایش ارزیابی نخواهید کرد)، مجدداً آن را اصلاح کرده و این کارها را تا زمانی تکرار خواهید کرد که مدل به اندازه ممکن اصلاح گردد. مواردی که باید امتحان کنید به شرح زیر هستند:

- اضافه کردن مذف تصادفی
- امتحان معماری‌های مختلف: مذف و اضافه کردن لایه‌ها
- اضافه کردن تنظیم L1 و یا L2
- امتحان ابرپارامترهای مختلف (مانند تعداد واحدها برای هر لایه یا نرخ یادگیری بهینه‌ساز) برای یافتن پیکربندی بهینه
- تکرار اختیاری مهندسی ویژگی: اضافه کردن ویژگی‌های جدید یا حذف ویژگی‌هایی که ظاهراً فاقد اطلاعات مفید هستند.

OPTIMIZING  
TIME



## 4.4-overfitting-and-underfitting

# Presentation Time

ارائه ۲: دیتاست‌های  
رایج در حوزه‌های  
مختلف یادگیری عمیق  
(تصویر، متن، صوت).





# تشکر

## سوال؟

[a.golzari@azaruniv.ac.ir](mailto:a.golzari@azaruniv.ac.ir)

[a.golzari@tabrizu.ac.ir](mailto:a.golzari@tabrizu.ac.ir)

<https://github.com/Amin-Golzari-Oskouei>

