

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



## یادگیری عمیق

جلسه ۲۸

# نتیجه‌گیری: حال و آینده‌ی یادگیری عمیق

**Conclusions: Present and Future of Deep Learning**

کاظم فولادی قلعه  
دانشکده مهندسی، پردیس فارابی  
دانشگاه تهران

<http://courses.fouladi.ir/deep>

نتیجه گیری: حال و آینده ی یادگیری عمیق



مرور  
مفاهیم  
کلیدی

## رویکردهای گوناگون به هوش مصنوعی

### VARIOUS APPROACHES TO AI

#### هوش مصنوعی

*Artificial Intelligence*

حوزه‌ای گسترده و قدیمی  
«هرگونه تلاش برای خودکارسازی فرآیندهای شناختی»: خودکارسازی تفکر  
\* از امور ابتدایی مانند صفحه‌گسترده تا امور بسیار پیشرفته مانند ربات انسان‌نما

#### یادگیری ماشینی

*Machine Learning*

زیرحوزه‌ی خاصی از هوش مصنوعی  
هدف: توسعه‌ی خودکار برنامه‌هایی (مدل) که صرفاً در اثر قرارگیری در معرض  
داده‌های آموزشی حاصل می‌شوند.  
\* یادگیری: فرآیند تبدیل داده به برنامه [عمری طولانی با اوج‌گیری از دهه‌ی ۱۹۹۰]

#### یادگیری عمیق

*Deep Learning*

یکی از شاخه‌های متعدد یادگیری ماشینی  
مدل‌ها زنجیره‌های طولانی از توابع هندسی هستند که یکی پس از دیگری اعمال می‌شوند.  
این عملیات در قالب ماژول‌هایی به نام لایه ساختاردهی شده‌اند.  
\* مدل‌های یادگیری عمیق، پشته‌هایی از لایه‌ها/گراف‌هایی از لایه‌ها هستند.  
لایه‌ها از طریق وزن‌ها پارامتریزه می‌شوند: وزن‌ها = پارامترهای یادگیرنده طی آموزش  
دانایی یک مدل در وزن‌های آن ذخیره می‌شود.  
فرآیند یادگیری = یافتن مقادیر خوب برای این وزن‌ها

## آنچه باعث خاص بودن یادگیری عمیق در حوزه‌ی یادگیری ماشینی است

### WHAT MAKES DEEP LEARNING SPECIAL WITHIN THE FIELD OF MACHINE LEARNING

با وجود اینکه یادگیری عمیق تنها یکی از رویکردهای متعدد یادگیری ماشینی است، اما با آن قابل مقایسه نیست: یادگیری عمیق یک موفقیت چشمگیر است.

یادگیری عمیق تنها در عرض چند سال به پیشرفت‌های شگرفی در طیف وسیعی از وظایف دست یافته است که از گذشته به عنوان مسائل بسیار دشوار برای کامپیوترها شناخته می‌شدند؛ مانند حوزه‌ی **ادراک ماشینی**. استخراج اطلاعات مفید از تصاویر، ویدئو، صدا و ...

با داشتن داده‌های آموزشی کافی (به ویژه داده‌های آموزشی برچسب‌خورده توسط انسان به طور مناسب)، استخراج و دریافت از داده‌های ادراکی تقریباً مشابه هر چیزی که انسان می‌تواند درک کند، امکان‌پذیر می‌شود.

گاهی گفته می‌شود «یادگیری عمیق مسئله‌ی ادراک را حل کرده است»: اگرچه این امر تنها برای تعریف نسبتاً محدودی از ادراک صدق می‌کند.

## سومین تابستان هوش مصنوعی

یادگیری عمیق به دلیل موفقیت‌های تکنیکی بی‌مانند خود، تاکنون به‌تنهایی سومین و بزرگ‌ترین تابستان هوش مصنوعی را به ارمغان آورده است: دوره‌ای از توجهات بسیار زیاد، سرمایه‌گذاری بالا و تبلیغات در زمینه‌ی هوش مصنوعی.

در تقابل شدید با تابستان‌های قبلی هوش مصنوعی، یادگیری عمیق ارزش تجاری هنگفتی را برای برخی از شرکت‌های بزرگ تکنولوژی فراهم کرده است: بازشناسی گفتار در سطح انسان، دستیاران هوشمند، طبقه‌بندی تصاویر در سطح انسان، ترجمه‌ی ماشینی بسیار بهبود یافته این تبلیغات ممکن است (و احتمالاً) کاهش یابند اما اثرات پایدار اقتصادی و تکنولوژیک یادگیری عمیق ماندگار است. یادگیری عمیق با اینترنت قابل مقایسه است: ممکن است چند سالی سروصدای زیادی در مورد آن ایجاد شود، اما در مدت طولانی‌تر همچنان یک تحول عظیم باقی خواهد ماند که اقتصاد و زندگی ما را دستخوش تغییر خواهد کرد. یادگیری عمیق چیزی کمتر از یک انقلاب نیست.

## چگونه در مورد یادگیری عمیق فکر کنیم؟

### HOW TO THINK ABOUT DEEP LEARNING

جالبترین چیز در مورد یادگیری عمیق:  
میزان سادگی آن

تمام آنچه نیاز داریم:  
مدلهای پارامتری به اندازهی کافی بزرگ، که  
با الگوریتم کاهش گرادیانی برای نمونه‌های متعدد و کافی  
آموزش یافته باشد.

## چگونه در مورد یادگیری عمیق فکر کنیم؟

در یادگیری عمیق همه چیز یک بردار است

در یادگیری عمیق، همه چیز یک **بردار** است:  
یک نقطه در فضای هندسی

ورودی‌های مدل (متن، تصویر و ...) و **تارگت‌ها** ابتدا **بردار سازی** می‌شوند:  
انتقال به **فضای برداری ورودی** و **فضای برداری تارگت**

هر لایه روی داده‌هایی که از آن عبور می‌کند، یک **تبدیل هندسی ساده** اعمال می‌کند.

در مجموع، زنجیره‌ی لایه‌ها در مدل، یک **تبدیل هندسی پیچیده** را تشکیل می‌دهد  
که به یک سری از تبدیل‌های ساده‌تر تقسیم می‌شود.

این تبدیل تلاش می‌کند تا نگاشت فضای ورودی به فضای تارگت را به صورت یک نقطه در هر زمان انجام دهد.  
این تبدیل، با وزن‌های آن لایه پارامتری سازی می‌شود.

این وزن‌ها به صورت تکراری و بر اساس کیفیت کنونی اجرای مدل، به روزرسانی می‌شوند.  
یک ویژگی کلیدی این تبدیل هندسی: **باید مشتق پذیر باشد.**

(چون می‌خواهیم پارامترها را از طریق کاهش گرادیانی یاد بگیریم)؛

یعنی: **تبدیل هندسی از ورودی‌ها به خروجی‌ها باید هموار و پیوسته باشد.**

## چگونه در مورد یادگیری عمیق فکر کنیم؟

تعبیر شهودی تبدیل هندسی پیچیده در شبکه‌های عصبی عمیق

تجسم سه‌بعدی فرآیند اعمال تبدیل هندسی پیچیده بر داده‌های ورودی:

فرض می‌کنیم شخصی تلاش می‌کند تا

**یک توپ کاغذی مچاله شده را صاف کند:**

توپ کاغذی مچاله شده یک منیفولد از داده‌های ورودی است که مدل با آنها شروع می‌کند. هر حرکتی که توسط شخص روی توپ کاغذی انجام می‌شود، شبیه به یک تبدیل هندسی ساده است که توسط یک لایه انجام می‌شود. توالی کامل حرکت‌های لازم برای صاف کردن، معادل با تبدیل پیچیده‌ی کل مدل است.

مدل‌های یادگیری عمیق:

ماشین‌های ریاضیاتی برای مسطح کردن منیفولدهای پیچیده از داده‌های با ابعاد بالا



## چگونه در مورد یادگیری عمیق فکر کنیم؟

جادوی یادگیری عمیق

جادوی یادگیری عمیق:  
تبدیل معنا به بردارها، به فضاهاى هندسى  
و سپس یادگیری تدریجی تبدیل‌های هندسی پیچیده  
برای نگاشت یک فضا به فضای دیگر

تمام آنچه نیاز داریم:  
فضاهایی دارای ابعاد به اندازه‌ی کافی بالا  
برای تسخیر کامل روابط یافت شده در داده‌های اصلی

## چگونه در مورد یادگیری عمیق فکر کنیم؟

### اتصال‌گرایی

### CONNECTIONISM

ایده‌ی محوری:

**معنا از روابط دوبه‌دوی میان چیزها حاصل می‌شود.**  
(میان کلمات در یک زبان، میان پیکسل‌ها در یک تصویر و ...)  
**و این روابط را می‌توان از طریق یک تابع فاصله به دست آورد.**

اینکه آیا مغز معنا را از طریق فضا‌های هندسی پیاده‌سازی می‌کند، پرسش کاملاً جداگانه‌ای است.

از دیدگاه محاسباتی، کار با فضا‌های برداری مؤثر است،  
اما ساختارهای داده‌ای مختلفی را می‌توان برای هوش به تصویر کشید: به ویژه گراف‌ها.

شبکه‌های عصبی، در ابتدا از ایده‌ی استفاده از گراف‌ها به عنوان روشی برای کدگذاری معنا شکل گرفتند  
(منشأ نام‌گذاری به شبکه‌های عصبی)

**حوزه‌ی پژوهشی این زمینه، «اتصال‌گرایی» نام دارد.**

## چگونه در مورد یادگیری عمیق فکر کنیم؟

نام‌های جایگزین برای «شبکه‌های عصبی»

شبکه‌های عصبی، در ابتدا از ایده‌ی استفاده از گراف‌ها به عنوان روشی برای کدگذاری معنا شکل گرفتند (منشأ نام‌گذاری به شبکه‌های عصبی)  
ولی امروزه نام شبکه‌ی عصبی صرفاً به دلایل تاریخی ماندگار شده است.  
این نام بسیار گمراه‌کننده است، زیرا آنها نه از نوع عصبی هستند و نه از نوع شبکه.  
به ویژه آنکه به سختی می‌توان شبکه‌های عصبی را به مغز ربط داد!

یادگیری بازنمایی‌های لایه‌ای

*Layered Representations Learning*

یادگیری بازنمایی‌های سلسله‌مراتبی

*Hierarchical Representations Learning*

مدل‌های مشتق‌پذیر عمیق

*Deep Differentiable Models*

تبدیل‌های هندسی زنجیره‌وار

*Chained Geometric Transforms*

نام‌های مناسب‌تر  
برای

شبکه‌های عصبی  
*Neural Networks*

## تکنولوژی‌های تواناساز کلیدی

عوامل محرک کلیدی انقلاب یادگیری عمیق

### KEY ENABLING TECHNOLOGIES

طی دو دهه: شروع با الگوریتم پس‌انتشار و سپس بعد از سال ۲۰۱۲ با سرعتی بیشتر

نوآوری‌های الگوریتمی تدریجی

آموزش مدل‌های بزرگ با مقدار زیادی داده. محصول جانبی اینترنت و رشد فضاهای ذخیره‌سازی

دسترس‌پذیری حجم بزرگی از داده‌های ادراکی

به‌ویژه GPUهای شرکت NVIDIA. در ابتدا برای بازی و سپس انواع مخصوص یادگیری عمیق

دسترس‌پذیری سخت‌افزارهای محاسباتی سریع و شدیداً موازی با قیمت پایین

زبان CUDA، چارچوب‌های کاری Tensorflow و Keras

یک پشته‌ی پیچیده از لایه‌های نرم‌افزاری



## تکنولوژی‌های تواناساز کلیدی

آینده

در آینده

یادگیری عمیق نه تنها توسط متخصصان (پژوهشگران، دانشجویان و مهندسان) استفاده خواهد شد، بلکه به ابزاری در جعبه ابزار هر توسعه دهنده‌ای تبدیل می‌شود.  
(مانند تکنولوژی فعلی وب)  
**همه نیازمند ساخت برنامه‌های کاربردی هوشمند خواهند بود.**

دقیقاً همان گونه که امروز هر کسب و کاری به یک وبسایت نیاز دارد، در آینده هر محصولی باید داده‌های تولید شده توسط کاربر را به شیوه‌ای هوشمندانه معنادار کند.

تحقق این آینده، ما را ملزم به ساختن ابزارهایی می‌کند که اساساً به کارگیری یادگیری عمیق را آسان ساخته و آن را برای هر برنامه نویسی دسترس پذیر می‌کند.  
(Keras!)

## گردش کار جامع یادگیری ماشینی

### THE UNIVERSAL MACHINE-LEARNING WORKFLOW

دسترسی به ابزاری بسیار قدرتمند برای ایجاد مدل‌هایی که هر فضای ورودی را به هر فضای تارگت نگاشت کند، عالی و مطلوب است.

اما بخش دشوار گردش کار یادگیری ماشینی اغلب مربوط به هر چیزی است که پیش از طراحی و آموزش مدل‌های یادگیری ماشین مطرح می‌شود. (برای مدل‌های مولد، مسائل بعد از آن را نیز شامل می‌شود.)

درک دامنه‌ی یادگیری ماشینی، برای توانایی مشخص‌سازی اینکه

**برای پیش‌بینی چه چیزی تلاش می‌کنیم،**

**چه داده‌هایی باید در نظر گرفته شود،**

**و میزان موفقیت چگونه سنجش می‌شود؛**

پیش‌نیازی برای هر کاربرد موفق یادگیری ماشینی است

و ابزارهای پیشرفته‌ای مثل تنسورفلو و کراس در این مورد کمکی نمی‌کنند.

## گردش کار جامع یادگیری ماشینی

THE UNIVERSAL MACHINE-LEARNING WORKFLOW

## معماری‌های کلیدی شبکه

KEY NETWORK ARCHITECTURES

هر نوع از این شبکه‌ها برای مدالیت‌های خاصی از ورودی مناسب است.. هر معماری، فرضیاتی را در مورد ساختار داده‌ها کدگذاری می‌کند: یک فضای فرضیه که جستجو برای یافتن یک مدل خوب در آن انجام می‌شود.

اینکه آیا معماری مورد نظر روی داده‌های مورد نظر کار خواهد کرد یا نه، کاملاً وابسته به تطابق میان ساختار داده‌ها و معماری شبکه است.

انواع مختلف شبکه را می‌توان به سادگی مانند قطعات لگو با هم ترکیب کرد تا شبکه‌های بزرگتر چندمدالی حاصل شود.  
(لایه‌های یادگیری عمیق مانند قطعات لگو برای پردازش اطلاعات هستند.)



## معماری‌های کلیدی شبکه

انواع داده‌ها و شبکه‌های مناسب برای آنها

### KEY NETWORK ARCHITECTURES

شبکه‌های متصل متراکم (لایه‌های Dense)	داده‌های برداری <i>Vector Data</i>
شبکه‌های کانولوشنال دو-بعدي	داده‌های تصویری <i>Image Data</i>
شبکه‌های کانولوشنال یک-بعدي (ترجیح) یا RNNها	داده‌های صوتی (مانند شکل موج) <i>Sound Data (e.g. waveform)</i>
شبکه‌های کانولوشنال یک-بعدي (ترجیح) یا RNNها	داده‌های متنی <i>Text Data</i>
RNNها (ترجیح) یا شبکه‌های کانولوشنال یک-بعدي	داده‌های سری زمانی <i>Timeseries Data</i>
RNNها یا شبکه‌های کانولوشنال یک-بعدي RNNها در صورتی ترجیح دارند که ترتیب داده‌ها شدیداً معنادار باشد.	دیگر انواع داده‌های دنباله‌ای <i>Other Types of Sequence Data</i>
شبکه‌های کانولوشنال سه-بعدي (در صورت نیاز به دریافت اثرات حرکت) یا ترکیبی از شبکه‌های CNN دو بعدي (استخراج ویژگی در سطح فریم) + RNN یا CNN یک-بعدي (پردازش دنباله‌های زمانی حاصل)	داده‌های ویدئویی <i>Video Data</i>
شبکه‌های کانولوشنال سه-بعدي	داده‌های حجمی <i>Volumetric Data</i>

نگاشت مدالیت‌های ورودی و معماری مناسب شبکه

## معماری‌های کلیدی شبکه

### شبکه‌های متصل متراکم

#### DENSELY CONNECTED NETWORKS

یک شبکه‌ی متصل متراکم، پشته‌ای از لایه‌های Dense است که برای پردازش داده‌های برداری (بچهایی از بردارها) در نظر گرفته می‌شوند.

این شبکه‌ها هیچ ساختار خاصی را برای عناصر ویژگی ورودی فرض نمی‌کنند (مانند مجموعه).

**وجه تسمیه‌ی «متصل متراکم»:** واحدهای یک لایه به تمام واحدهای لایه‌ی دیگر متصل می‌شود.

لایه‌ی متصل متراکم، تلاش می‌کند تا روابط بین هر دو ویژگی ورودی را نگاشت کند (برخلاف یک لایه‌ی کانولوشنی دوبعدی که تنها روابط محلی را در نظر دارد).

شبکه‌های متصل متراکم پرکاربردترین شبکه‌ها برای **داده‌های رده‌ای / categorical** هستند. (مواردی که ویژگی‌های ورودی، لیستی از خصیصه‌ها هستند، مانند مسئله‌ی پیش‌بینی قیمت مسکن)

شبکه‌های متصل متراکم در بیشتر شبکه‌ها برای مرحله‌ی **طبقه‌بندی نهایی** یا **رگرسیون** استفاده می‌شوند.

## معماری‌های کلیدی شبکه

شبکه‌های متصل متراکم برای طبقه‌بندی دودویی

### DENSELY CONNECTED NETWORKS: BINARY CLASSIFICATION

برای انجام طبقه‌بندی دودویی،  
پشته‌ی لایه‌ها را با یک لایه‌ی Dense دارای یک واحد تنها با تابع فعالیت sigmoid خاتمه می‌دهیم  
و از binary\_crossentropy به عنوان تابع اتلاف استفاده می‌کنیم.  
تارگت‌ها باید 0 یا 1 باشند.

```
from keras import models
from keras import layers
model = models.Sequential()
model.add(layers.Dense(32, activation='relu', input_shape=(num_input_features,)))
model.add(layers.Dense(32, activation='relu'))
model.add(layers.Dense(1, activation='sigmoid'))
model.compile(optimizer='rmsprop', loss='binary_crossentropy')
```

## معماری‌های کلیدی شبکه

شبکه‌های متصل متراکم برای طبقه‌بندی رده‌ای تک-برچسپی

### DENSELY CONNECTED NETWORKS: SINGLE-LABEL CATEGORICAL CLASSIFICATION

برای انجام طبقه‌بندی رده‌ای تک-برچسپی (هر نمونه دقیقاً متعلق به یک کلاس است نه بیشتر)،  
پشته‌ی لایه‌ها را با یک لایه‌ی Dense دارای چند واحد برابر با تعداد کلاس‌ها با تابع فعالیت softmax خاتمه می‌دهیم.  
اگر کدگذاری تارگت‌ها one-hot بود از categorical\_crossentropy به‌عنوان تابع اتلاف استفاده می‌کنیم.  
اگر کدگذاری تارگت‌ها با اعداد صحیح بود از sparse\_categorical\_crossentropy استفاده می‌کنیم.

```
model = models.Sequential()
model.add(layers.Dense(32, activation='relu', input_shape=(num_input_features,)))
model.add(layers.Dense(32, activation='relu'))
model.add(layers.Dense(num_classes, activation='softmax'))
model.compile(optimizer='rmsprop', loss='categorical_crossentropy')
```

## معماری‌های کلیدی شبکه

شبکه‌های متصل متراکم برای طبقه‌بندی رده‌ای چند-برچسپی

### DENSELY CONNECTED NETWORKS: MULTIPLE-LABEL CATEGORICAL CLASSIFICATION

برای انجام طبقه‌بندی رده‌ای چند-برچسپی (هر نمونه می‌تواند متعلق به چند کلاس باشد)،  
پشته‌ی لایه‌ها را با یک لایه‌ی Dense دارای چند واحد برابر با تعداد کلاس‌ها با تابع فعالیت sigmoid خاتمه می‌دهیم.  
و از binary\_crossentropy به عنوان تابع اتلاف استفاده می‌کنیم.  
کدگذاری تارگت‌ها باید به صورت k-hot باشد.

```
model = models.Sequential()
model.add(layers.Dense(32, activation='relu', input_shape=(num_input_features,)))
model.add(layers.Dense(32, activation='relu'))
model.add(layers.Dense(num_classes, activation='sigmoid'))
model.compile(optimizer='rmsprop', loss='binary_crossentropy')
```

## معماری‌های کلیدی شبکه

شبکه‌های متصل متراکم برای رگرسیون

### DENSELY CONNECTED NETWORKS: REGRESSION

برای انجام رگرسیون برداری از مقادیر پیوسته،  
پشته‌ی لایه‌ها را با یک لایه‌ی Dense دارای چند واحد برابر با تعداد کمیت‌های مورد نظر برای پیش‌بینی  
با تابع فعالیت خطی (بدون مشخص کردن تابع فعالیت) خاتمه می‌دهیم.  
و از  $\text{mean\_squared\_error (MSE)}$  یا  $\text{mean\_absolute\_error (MAE)}$  به‌عنوان تابع اتلاف استفاده می‌کنیم.

```
model = models.Sequential()
model.add(layers.Dense(32, activation='relu', input_shape=(num_input_features,)))
model.add(layers.Dense(32, activation='relu'))
model.add(layers.Dense(num_values))
model.compile(optimizer='rmsprop', loss='mse')
```

## معماری‌های کلیدی شبکه

### شبکه‌های کانولوشنال

#### CONVNETS

لایه‌های کانولوشنی با اعمال یک تبدیل هندسی یکسان به مکان‌های فضایی مختلف (تکه / patch) الگوهای محلی فضایی را مورد ملاحظه و بررسی قرار می‌دهند.

این کار موجب تولید بازنمایی‌های تغییرناپذیر نسبت به جابه‌جایی / translation invariant می‌شود و باعث می‌شود لایه‌های کانولوشنی از لحاظ داده‌ای بسیار کارآمد و ماژولار شوند.

این ایده را می‌توان به فضاهایی با هر تعداد بعد اعمال کرد:  
یک-بعدي (دنباله‌ها)، دو-بعدي (تصاویر)، سه-بعدي (حجم‌ها) و ...

لایه‌ی Conv1D برای پردازش دنباله‌ها (به‌خصوص متن، نه سری‌های زمانی حساس به ترتیب)  
لایه‌ی Conv2D برای پردازش تصاویر  
لایه‌ی Conv3D برای پردازش حجم‌ها

## معماری‌های کلیدی شبکه

شبکه‌های کانولوشنال: لایه‌ها

### CONVNETS

شبکه‌های کانولوشنال از پشته‌هایی از لایه‌های کانولوشنی و تلفیق تشکیل می‌شوند.

لایه‌های تلفیق امکان نمونه‌گیری رو به پایین فضایی روی داده‌ها را فراهم می‌کنند، که برای نگهداری نقشه‌های ویژگی در اندازه‌ی معقول همزمان با رشد تعداد ویژگی‌ها لازم است؛ و به لایه‌های کانولوشنی بعدی اجازه می‌دهد که گستره‌ی فضایی بزرگتری از ورودی‌ها را مشاهده کنند.

شبکه‌های کانولوشنال اغلب با یک لایه‌ی Flatten،  
یا با یک لایه‌ی تلفیق سراسری Global Pooling  
خاتمه می‌یابند که نقشه‌های ویژگی فضایی را به بردارها تبدیل می‌کنند.  
سپس لایه‌های Dense قرار می‌گیرند تا طبقه‌بندی یا رگرسیون انجام شود.



## معماری‌های کلیدی شبکه

شبکه‌های کانولوشنال: لایه‌ی کانولوشن جداپذیر عمقی

### CONVNETS

بسیار محتمل است که کانولوشن‌های معمولی به زودی عمدتاً یا کاملاً با هم‌ارزی جایگزین شوند که سریع‌تر و از لحاظ بازنمایی کارآمدتر است:

### کانولوشن جداپذیر عمقی *Depthwise Separable Convolution*

لایه‌ی **SeparableConv2D**

متعاقباً برای ورودی‌های یک-بعدی، دو-بعدی و سه-بعدی

هنگامی که در حال ساختن یک شبکه‌ی جدید از ابتدا هستیم، استفاده از کانولوشن جداپذیر عمقی قطعاً روش مناسبی است.

لایه‌ی **SeparableConv2D** را می‌توان به عنوان یک جایگزین **Conv2D** به کار گرفت که منتهی به یک شبکه‌ی کوچک‌تر و سریع‌تر می‌شود که وظیفه‌اش را بهتر انجام می‌دهد.

## معماری‌های کلیدی شبکه

شبکه‌های کانولوشنال: مثال

### CONVNETS

یک شبکه‌ی طبقه‌بندی تصویر نوعی با استفاده از کانولوشن جداپذیر عمقی (طبقه‌بندی رده‌ای):

```

model = models.Sequential()
model.add(layers.SeparableConv2D(32, 3, activation='relu',
                                  input_shape=(height, width, channels)))
model.add(layers.SeparableConv2D(64, 3, activation='relu'))
model.add(layers.MaxPooling2D(2))

model.add(layers.SeparableConv2D(64, 3, activation='relu'))
model.add(layers.SeparableConv2D(128, 3, activation='relu'))
model.add(layers.MaxPooling2D(2))

model.add(layers.SeparableConv2D(64, 3, activation='relu'))
model.add(layers.SeparableConv2D(128, 3, activation='relu'))
model.add(layers.GlobalAveragePooling2D())

model.add(layers.Dense(32, activation='relu'))
model.add(layers.Dense(num_classes, activation='softmax'))

model.compile(optimizer='rmsprop', loss='categorical_crossentropy')

```

## معماری‌های کلیدی شبکه

## شبکه‌های عصبی بازگشتی

RNNs

شبکه‌های عصبی بازگشتی (RNNها)  
از طریق پردازش دنباله‌هایی از ورودی‌ها (یک گام زمانی در هر زمان)  
و دستکاری یک حالت سرتاسری کار می‌کنند.

(**حالت / state**: یک بردار یا مجموعه‌ای از بردارها: یک نقطه در فضای هندسی حالت‌ها)

در مورد دنباله‌هایی که در آنها الگوهای مورد نظر نسبت به جابه‌جایی زمانی تغییرناپذیر نیستند،  
استفاده از RNN به 1D-CNN ترجیح داده می‌شود.  
(مانند داده‌های سری‌های زمانی که در آنها گذشته‌ی نزدیک مهم‌تر از گذشته‌ی دور است)

## معماری‌های کلیدی شبکه

### شبکه‌های عصبی بازگشتی

#### RNNs

سه لایه‌ی RNN موجود در کراس:

SimpleRNN, GRU, LSTM

برای بیشتر اهداف عملی از GRU یا LSTM استفاده می‌کنیم:  
LSTM قدرتمندتر از GRU است اما پرهزینه‌تر است؛  
GRU جایگزین ساده‌تر و ارزان‌تری است.

## معماری‌های کلیدی شبکه

شبکه‌های عصبی بازگشتی: پشته‌گذاری لایه‌ها

### RNNs

برای پشته‌گذاری لایه‌های RNN بر روی یکدیگر، هر لایه قبل از آخرین لایه در پشته باید دنباله‌ی کامل خروجی‌های خود را برگرداند. (هر گام زمانی ورودی متناظر با یک گام خروجی است.)

اگر هیچ لایه‌ی RNN بیشتری را به پشته اضافه نکنیم، آن‌گاه یک روش معمول این است که تنها خروجی آخر که حاوی اطلاعاتی درباره‌ی کل دنباله است، برگردانده شود.

## معماری‌های کلیدی شبکه

شبکه‌های عصبی بازگشتی: مثال

### RNNs

یک لایه‌ی تنه‌ای RNN برای طبقه‌بندی دودویی دنباله‌های برداری:

```
model = models.Sequential()
model.add(layers.LSTM(32, input_shape=(num_timesteps, num_features)))
model.add(layers.Dense(num_classes, activation='sigmoid'))
model.compile(optimizer='rmsprop', loss='binary_crossentropy')
```

چند لایه‌ی پشت‌گذاری شده‌ی RNN برای طبقه‌بندی دودویی دنباله‌های برداری:

```
model = models.Sequential()
model.add(layers.LSTM(32, return_sequences=True,
input_shape=(num_timesteps, num_features)))
model.add(layers.LSTM(32, return_sequences=True))
model.add(layers.LSTM(32))
model.add(layers.Dense(num_classes, activation='sigmoid'))
model.compile(optimizer='rmsprop', loss='binary_crossentropy')
```

## فضای امکان‌ها

با یادگیری عمیق چه چیزهایی می‌توانیم بسازیم؟

### THE SPACE OF POSSIBILITIES

ساخت مدل‌های یادگیری عمیق مانند بازی با قطعات لگو است.

با فرض اینکه داده‌های آموزشی مناسبی در اختیار داریم و اینکه نگاشت را می‌توان از طریق یک تبدیل هندسی پیوسته با پیچیدگی قابل قبول انجام داد، می‌توان لایه‌ها را روی هم قرار داد، تا اساساً هر چیزی به هر چیز دیگر نگاشت شود.

مثال‌هایی از کاربردهای یادگیری عمیق  
در وظایفی فراتر از وظایف ساده: طبقه‌بندی و رگرسیون:  
بر اساس مدالیته‌های ورودی و خروجی.

(تعداد اندکی از این وظایف مرزهای امکان‌پذیری را گسترش داده‌اند:  
اگرچه برای تمام این وظایف می‌توان مدلی را آموزش داد، اما در برخی موارد احتمالاً تعمیم‌پذیری پایین است)

## فضای امکان‌ها

نگاشت داده‌های برداری به داده‌های برداری

THE SPACE OF POSSIBILITIES

مراقبت‌های سلامتی پیش‌بینی‌کننده

*Predictive healthcare*

نگاشت سوابق پزشکی بیمار به پیش‌بینی وضعیت بیمار در آینده

هدف‌گذاری رفتاری




*Behavioral targeting*

نگاشت مجموعه‌ای از ویژگی‌های وبسایت با داده‌هایی در مورد مدت زمانی که یک کاربر در آن سپری می‌کند.

کنترل کیفیت محصول

*Product quality control*

نگاشت مجموعه‌ای از ویژگی‌های مربوط به نمونه‌ای از یک محصول تولیدی با احتمال شکست آن تا سال بعد

نگاشت داده‌های برداری به داده‌های برداری  
*Mapping vector data to vector data*



## فضای امکان‌ها

نگاشت داده‌های تصویری به داده‌های برداری

THE SPACE OF POSSIBILITIES

دستیار پزشک

*Doctor assistant*

نگاشت اسلایدهای تصاویر پزشکی به پیش‌بینی وجود یک تومور

وسایل نقلیه‌ی خودران

*Self-driving vehicle*

نگاشت فریم‌های ویدئوی حاصل از دوربین داشبورد به فرمان‌های گردش فرمان

هوش مصنوعی بازی‌های تخته‌ای

*Board game AI*

نگاشت وضعیت بازی‌های تخته‌ای (مانند شطرنج و Go) به حرکت بعدی بازیکن

همیار رژیم

*Diet helper*

نگاشت تصاویر یک ظرف غذا به شمارش کالری آن

پیش‌بینی سن

*Age prediction*

نگاشت عکس‌های سلفی به سن آن شخص

نگاشت داده‌های تصویری به داده‌های برداری  
*Mapping image data to vector data*

## فضای امکان‌ها

نگاشت داده‌های سری زمانی به داده‌های برداری

THE SPACE OF POSSIBILITIES

پیش‌بینی وضع هوا

*Weather prediction*

نگاشت سری زمانی داده‌های آب‌وهوا در یک توری از مکان‌ها به وضع هوای هفته‌ی بعد در یک مکان خاص

واسط‌های مغز-کامپیوتر




*Brain-computer interfaces*

نگاشت سری زمانی داده‌های مگنتوانسفالوگرافی (MEG) به فرمان‌های کامپیوتر

هدف‌گذاری رفتاری

*Behavioral targeting*

نگاشت سری زمانی تعاملات کاربر در یک وبسایت به احتمال انجام خرید توسط آن کاربر

نگاشت داده‌های تصویری به داده‌های برداری  
*Mapping timeseries data to vector data*

## فضای امکان‌ها

نگاشت متن به متن

THE SPACE OF POSSIBILITIES

پاسخگویی باهوش

*Smart reply*

نگاشت ایمیل‌ها به پاسخ‌های یک خطی ممکن

پاسخ دادن به پرسش‌ها




*Answering questions*

نگاشت پرسش‌های اطلاعات عمومی به پاسخ‌ها

خلاصه‌سازی

*Summarization*

نگاشت یک مقاله‌ی طولانی به یک خلاصه‌ی کوتاه از آن مقاله



نگاشت متن به متن

*Mapping text to text*

## فضای امکان‌ها


نگاشت تصاویر به متن

THE SPACE OF POSSIBILITIES

توضیح‌نویسی

*Captioning*

نگاشت تصاویر به توضیح‌های کوتاه توصیف‌کننده‌ی محتوای تصاویر



نگاشت تصاویر به متن

*Mapping images to text*

## فضای امکان‌ها

نگاشت متن به تصاویر

THE SPACE OF POSSIBILITIES

تولید تصویر شرطی

*Conditioned image generation*

نگاشت یک متن کوتاه توضیحی به تصاویر که با آن توضیح مطابقت دارند.

تولید / انتخاب لوگو

*Logo generation/selection*

نگاشت نام و توصیف یک شرکت به لوگوی آن شرکت

نگاشت متن به تصاویر  
*Mapping text to images*

## فضای امکان‌ها

نگاشت تصاویر به تصاویر

THE SPACE OF POSSIBILITIES

سوپر-رزولوشن

*Super-resolution*

نگاشت تصاویر کوچک‌شده از نظر اندازه به نسخه‌های رزولوشن بالاتر از همان تصاویر

سنجش عمق دیداری

*Visual depth sensing*

نگاشت تصاویر محیط‌های داخلی به نقشه‌های پیش‌بینی عمق

نگاشت تصاویر به تصاویر  
*Mapping images to images*

## فضای امکان‌ها


نگاشت تصاویر و متن به متن

THE SPACE OF POSSIBILITIES

پاسخ به پرسش دیداری

*Visual QA*

نگاشت تصاویر و پرسش‌های زبان طبیعی در مورد محتوای تصاویر به پاسخ‌های زبان طبیعی



نگاشت تصاویر و متن به متن

*Mapping images and text to text*

## فضای امکان‌ها

نگاشت ویدئو و متن به متن

THE SPACE OF POSSIBILITIES

پاسخ به پرسش ویدئویی

*Video QA*

نگاشت ویدئوهای کوتاه و پرسش‌های زبان طبیعی در مورد محتوای ویدئوها به پاسخ‌های زبان طبیعی

نگاشت ویدئو و متن به متن  
*Mapping video and text to text*



نتیجه‌گیری: حال و آینده‌ی یادگیری عمیق

# ۲

## محدودیت‌های یادگیری عمیق

## محدودیت‌های یادگیری عمیق

وظایف نیازمند استدلال برای مدل‌های یادگیری عمیق دست‌نیافتنی است

### THE LIMITATIONS OF DEEP LEARNING

فضای کاربردهایی که می‌توانند با یادگیری عمیق پیاده‌سازی شوند، نزدیک به بی‌نهایت است.

در عین حال، بسیاری از کاربردها کاملاً خارج از دسترس تکنیک‌های امروزی یادگیری عمیق است -- حتی با داشتن حجم وسیعی از داده‌های حاشیه‌نویسی شده توسط انسان.

برای مثال:

می‌توان یک مجموعه داده از میلیون‌ها توصیف ویژگی از یک محصول نرم‌افزاری به زبان انگلیسی تهیه کرد که توسط یک مدیر محصول نوشته شده است و متناظر با آنها کدهای منبع توسعه داده شده توسط یک تیم از مهندسان برای برآورده‌سازی این نیازمندی‌ها تهیه کرد. با وجود این داده‌ها، نمی‌توانیم یک مدل یادگیری عمیق را آموزش بدهیم که توصیف یک محصول را بخواند و پایگاه کد متناسب را تولید کند.

در حالت کلی، هرچیزی که نیازمند استدلال است (مانند برنامه‌نویسی یا اعمال یک روش علمی، برنامه‌ریزی بلندمدت و دستکاری الگوریتمی داده‌ها) برای مدل‌های یادگیری عمیق دست‌نیافتنی است و مهم نیست که چه میزان داده در اختیار آنها قرار می‌دهید.

برای مثال:

حتی یادگیری یک الگوریتم مرتب‌سازی با یک شبکه‌ی عصبی عمیق بسیار دشوار است.

## محدودیت‌های یادگیری عمیق

منشأ محدودیت‌های یادگیری عمیق

### THE LIMITATIONS OF DEEP LEARNING

یک مدل یادگیری عمیق تنها زنجیره‌ای از تبدیلات هندسی ساده و پیوسته است که یک فضای برداری را به یک فضای برداری دیگر نگاشت می‌دهد.

با فرض اینکه یک تبدیل پیوسته‌ی قابل یادگیری از  $X$  به  $Y$  وجود داشته باشد، منیفولد داده‌های  $X$  به منیفولد دیگر  $Y$  نگاشت می‌یابد.

یک مدل یادگیری عمیق می‌تواند به عنوان نوعی برنامه تفسیر شود، اما برعکس، بیشتر برنامه‌ها را نمی‌توان به صورت یک مدل یادگیری عمیق بیان کرد.



برای بیشتر وظایف، یا هیچ شبکه‌ی عصبی عمیقی برای حل مسئله وجود ندارد، یا حتی اگر وجود داشته باشد، ممکن است قابل یادگیری نباشد:

تبدیل هندسی متناظر ممکن است بسیار پیچیده باشد یا ممکن است داده‌های مناسبی برای یادگیری آن وجود نداشته باشد.

## محدودیت‌های یادگیری عمیق

### THE LIMITATIONS OF DEEP LEARNING

بالا بردن مقیاس تکنیک‌های کنونی یادگیری عمیق، از طریق ایجاد پشته‌ای از لایه‌های بیشتر و به‌کارگیری داده‌های آموزشی بیشتر، تنها قادر است به صورت سطحی و موقتی برخی از این مشکلات را کاهش دهد.

این کار نمی‌تواند به حل این مشکلات اساسی‌تر بپردازد که «مدل‌های یادگیری عمیق در آنچه می‌توانند بازنمایی کنند، محدود هستند» و اینکه «بیشتر برنامه‌هایی که دوست داریم یادگیری شوند، نمی‌توانند به صورت تغییر شکل تدریجی هندسی و پیوسته از یک چندتایی داده‌ای بیان شوند.»

## محدودیت‌های یادگیری عمیق

ریسک انسان‌انگاری مدل‌های یادگیری ماشینی

### THE RISK OF ANTHROPOMORPHIZING MACHINE-LEARNING MODELS

یک ریسک واقعی در هوش مصنوعی معاصر،  
عدم تفسیر صحیح آنچه مدل‌های یادگیری عمیق انجام می‌دهند،  
و برآورد مبالغه‌آمیز از توانایی‌های آنهاست.

یک ویژگی بنیادی انسان‌ها: نظریه‌ی ذهن ما:  
تمایل ما به افکندن قصدها، باورها و دانایی بر روی چیزهای اطراف ما.

مثلاً: رسم یک چهره‌ی خندان بر روی یک سنگ بلافاصله آن را در ذهن ما به یک سنگ «شاد» تبدیل می‌کند.

اعمال این ویژگی به یادگیری عمیق، به این معنی است که:  
وقتی می‌توانیم یک مدل را تا حدی با موفقیت آموزش بدهیم تا توضیحاتی برای توصیف تصاویر تولید کند،  
به سمت این باور هدایت می‌شویم که آن مدل، محتویات تصویر و توضیحاتی که تولید می‌کند را «درک» می‌کند!

هنگامی که مشاهده می‌کنیم اندکی انحراف از نوع تصاویر ارائه شده در داده‌ها  
سبب می‌شود مدل توضیحات کاملاً نامربوطی تولید کند، شگفت‌زده می‌شویم.

## محدودیت‌های یادگیری عمیق

ریسک انسان‌انگاری مدل‌های یادگیری ماشینی



The boy is holding a baseball bat.

مثالی از شکست یک سیستم توضیح‌گذاری روی تصاویر مبتنی بر یادگیری عمیق

## محدودیت‌های یادگیری عمیق

### مثال‌های تخصصی

### ADVERSARIAL EXAMPLES

#### مثال‌های تخصصی:

نمونه‌هایی که به یک شبکه‌ی یادگیری عمیق وارد می‌شوند و به‌گونه‌ای طراحی شده‌اند که مدل را فریب بدهند تا آنها را به اشتباه طبقه‌بندی کند.

از طریق افزایش گرادیانی در فضای ورودی،

می‌توانیم ورودی‌هایی را تولید کنیم که فعالیت برخی فیلترهای شبکه‌ی کانولوشنال را ماکزیمم کند.  
به‌طور مشابه،

از طریق افزایش گرادیانی، می‌توانیم یک تصویر را اندکی تغییر دهیم تا به‌ازای یک کلاس خاص، پیش‌بینی آن ماکزیمم شود.

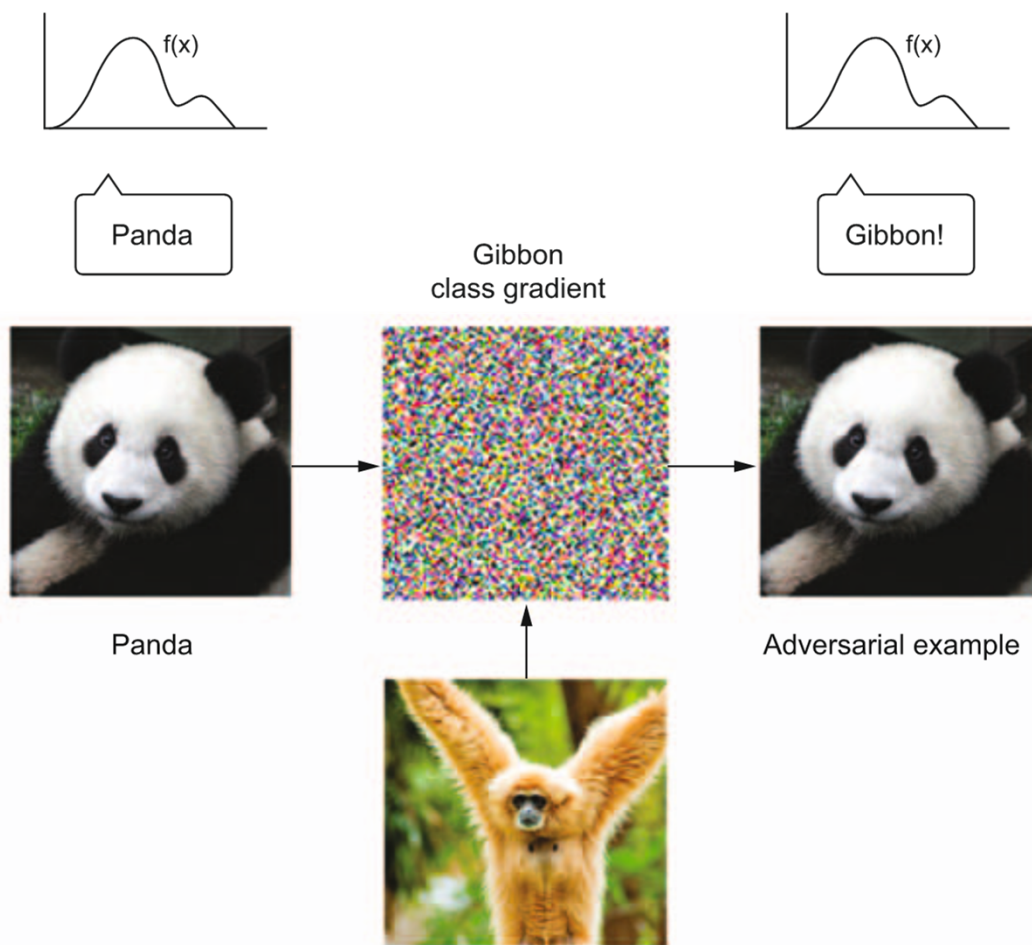
این به‌دلیل شکنندگی مدل‌های یادگیری عمیق

و تفاوت بین نگاشت ورودی-به-خروجی آنها و ادراک انسانی ماست.

## محدودیت‌های یادگیری عمیق

مثال‌های تخصصی: مثال

### ADVERSARIAL EXAMPLES



با داشتن تصویری از یک پاندا و افزودن گرادیان تصویر یک گیبون (میمون دست‌دراز) می‌توانیم به یک شبکه‌ی عصبی برای طبقه‌بندی پاندا به‌عنوان یک گیبون دست پیدا کنیم!



## محدودیت‌های یادگیری عمیق

خلاصه اینکه:

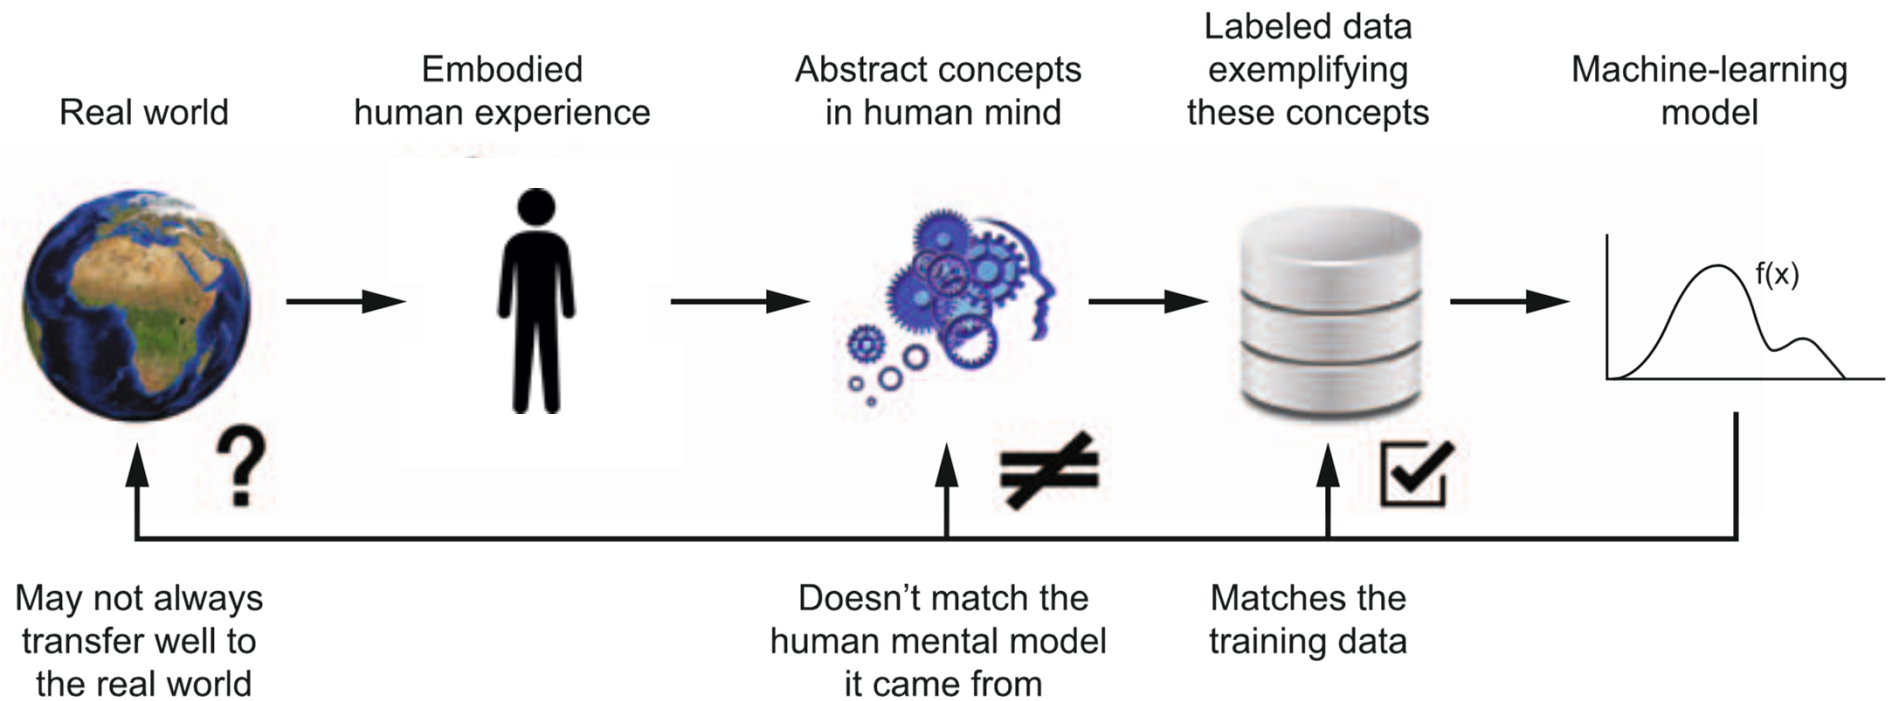
مدل‌های یادگیری عمیق هیچ درکی از ورودی خود ندارند  
(حداقل به شیوه‌ای مانند حس انسان).

درک ما از تصاویر، صداها و زبان ریشه در تجربه‌ی حسی و حرکتی ما به عنوان انسان دارد.  
مدل‌های یادگیری ماشینی هیچ‌گونه دسترسی به این تجربه‌ها ندارند  
و بنابراین نمی‌توانند ورودی‌های خود را به روشی قابل قیاس با روش انسان درک کنند.

با حاشیه‌نویسی تعداد بسیار زیادی از نمونه‌های آموزشی و وارد کردن آنها به مدل  
این مدل‌ها را وادار به یادگیری یک تبدیل هندسی می‌کنیم که  
داده‌ها را به مفاهیم انسانی نگاشت می‌کند (بر روی مجموعه‌ی خاصی از مثال‌ها).  
اما این نگاشت طرحی ساده از مدل اصلی موجود در ذهن ماست.  
(مدلی که از تجارب ما به عنوان عامل‌های بدن‌دار / embodied agents توسعه یافته است).  
مانند یک تصویر تیره و تار در یک آینه.

## محدودیت‌های یادگیری عمیق

مدل‌های کنونی یادگیری ماشینی مانند یک تصویر تیره و تار در یک آینه



## محدودیت‌های یادگیری عمیق

به‌عنوان یک فرد حرفه‌ای در یادگیری عمیق:

هرگز در دام این باور گرفتار نشوید که شبکه‌های عصبی وظیفه‌ای که انجام می‌دهند را درک می‌کنند.

آنها درکی از آن ندارند (حداقل به‌شیوه‌ای که برای ما قابل درک باشد).  
شبکه‌های عصبی در یک وظیفه‌ی متفاوت و بسیار محدودتر از  
وظیفه‌ای که ما قصد آموزش آنها را داشتیم، آموزش یافته‌اند:

**وظیفه‌ی نگاشت ورودی‌های آموزشی به تارگت‌های آموزشی به‌صورت نقطه به نقطه.**

اگر چیزی به شبکه نشان داده شود که از داده‌های آموزشی دور باشد،  
شبکه به‌گونه‌ای مهمل شکست می‌خورد.

## محدودیت‌های یادگیری عمیق

تعمیم محلی در مقابل تعمیم حداکثری

### LOCAL GENERALIZATION VS. EXTREME GENERALIZATION

بین روش ساده‌ی تغییر شکل تدریجی هندسی از ورودی به خروجی (روش مدل‌های یادگیری عمیق) و روش تفکر و یادگیری انسان تفاوت وجود دارد:

انسان‌ها از تجربه‌های **ضمنی** می‌آموزند  
(به‌جای آموختن از نمونه‌های آموزشی مستقیم که به آنها داده می‌شود)؛  
ماهیت **بازنمایی‌های زیربنایی** انسان‌ها نیز متفاوت است.

## محدودیت‌های یادگیری عمیق

تعمیم محلی در مقابل تعمیم حداکثری

### LOCAL GENERALIZATION VS. EXTREME GENERALIZATION

توانایی انسان‌ها از **نگاشت محرک‌های آنی به پاسخ‌های آنی** بسیار گسترده‌تر است.  
(شیوه‌ی یک شبکه‌ی عمیق یا شاید یک حشره)

انسان‌ها مدل‌های انتزاعی و پیچیده‌ای از وضعیت کنونی خود، از خود و افراد دیگر در ذهن نگهداری می‌کنند و می‌توانند از این مدل‌ها برای پیش‌بینی ویژگی‌های مختلف و ممکن استفاده کنند و طرح‌ریزی بلندمدت انجام دهند.  
می‌توانند مفاهیم شناخته شده را با یکدیگر ادغام کنند تا چیزی به دست آید که تاکنون تجربه نکرده‌اند.  
(مثلاً تصویر اسبی که کلاه به سردارد!)

این توانایی برای مدیریت فرضیه‌ها،  
به‌منظور گسترش فضای مدل ذهنی خود به فراتر از آنچه می‌توانیم مستقیماً تجربه کنیم،  
برای انجام **انتزاع و استدلال**، تعریف‌کننده‌ی مشخصه‌ی شناخت انسانی است:  
**تعمیم حداکثری.**

توانایی و فوق‌یابی با موقعیت‌های جدیدی که قبلاً هرگز تجربه نشده‌اند،  
با استفاده از داده‌های اندک یا حتی بدون هیچ داده‌ای.

**تعمیم حداکثری**  
*Extreme Generalization*

## محدودیت‌های یادگیری عمیق

### تعمیم محلی در مقابل تعمیم حداکثری

تعمیم حداکثری، در تضاد شدید با کاری است که شبکه‌های عمیق انجام می‌دهند: **تعمیم محلی**.

نگاشت از ورودی به خروجی که توسط یک شبکه‌ی عمیق انجام می‌شود، در صورتی که ورودی‌های جدید حتی کمی با ورودی‌های مورد استفاده در زمان آموزش متفاوت باشند، به سرعت معنای خود را از دست می‌دهد.

به عنوان مثال: مسئله‌ی یادگیری پارامترهای مناسب برای پرتاب موشک جهت فرود آمدن بر روی کره‌ی ماه؛

اگر از یک شبکه‌ی عمیق برای این کار استفاده کنیم، باید هزاران یا حتی میلیون‌ها آزمایش پرتاب را به آن تزریق کنیم: لزوم قراردادن مدل در معرض یک نمونه‌گیری متراکم از فضای ورودی برای یادگیری یک نگاشت قابل اطمینان از فضای ورودی به فضای خروجی.

در مقابل انسان از قدرت انتزاعی خود برای رویارویی با مدل‌های فیزیکی (علم موشک‌سازی) استفاده می‌کند و طی یک یا چند آزمایش، راه‌حل دقیقی را استخراج می‌کند که موشک را روی کره‌ی ماه فرود آورد.

## محدودیت‌های یادگیری عمیق

### تعمیم محلی در مقابل تعمیم حداکثری

تعمیم حداکثری، در تضاد شدید با کاری است که شبکه‌های عمیق انجام می‌دهند: **تعمیم محلی**.

نگاشت از ورودی به خروجی که توسط یک شبکه‌ی عمیق انجام می‌شود، در صورتی که ورودی‌های جدید حتی کمی با ورودی‌های مورد استفاده در زمان آموزش متفاوت باشند، به سرعت معنای خود را از دست می‌دهد.

مثال دیگر: مسئله‌ی کنترل بدن یک انسان برای جابه‌جایی بدون خطر در شهر (و بدون برخورد با خودروها)؛

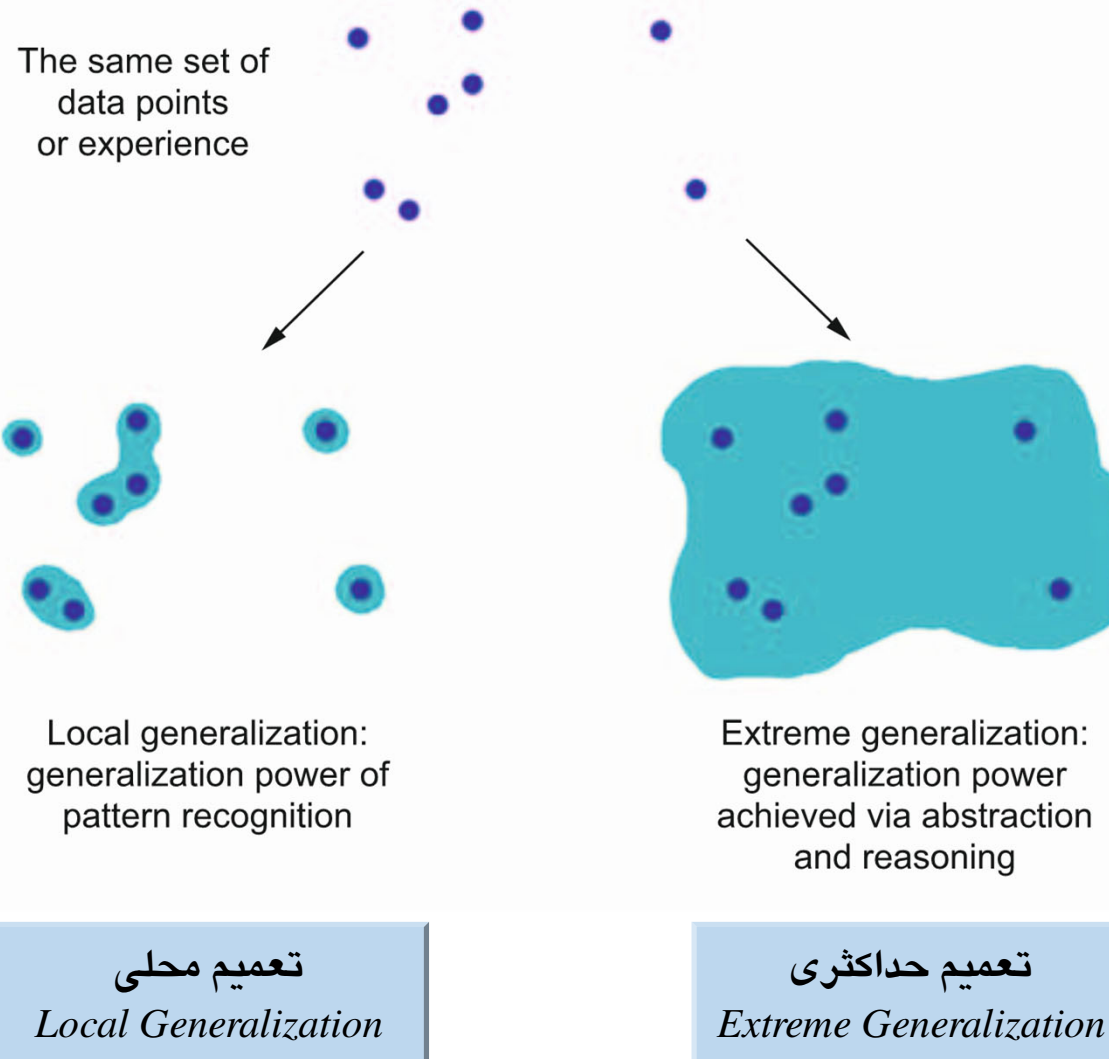
اگر از یک شبکه‌ی عمیق برای این کار استفاده کنیم، این شبکه باید هزاران بار در شرایط مختلف جان خود را از دست بدهد تا به این نتیجه برسد که خودروها خطرناک هستند! و رفتار اجتنابی مناسب را در خود توسعه دهد. اگر شبکه در شهری جدید قرار داده شود، مجبور می‌شود بخش زیادی از دانسته‌های خود را مجدداً یادگیری کند.

در مقابل انسان‌ها می‌توانند بدون اینکه لازم باشد حتی یک بار جان خود را از دست بدهند، رفتارهای امن و بدون خطر را یادگیرند: باز هم به کمک توان مدل‌سازی انتزاعی از شرایط فرضی.

## محدودیت‌های یادگیری عمیق

تعمیم محلی در مقابل تعمیم حداکثری

### LOCAL GENERALIZATION VS. EXTREME GENERALIZATION





## محدودیت‌های یادگیری عمیق

تعمیم محلی در مقابل تعمیم حداکثری

خلاصه اینکه:

با وجود پیشرفت در زمینه‌ی **ادراک ماشینی**،  
هنوز از هوش مصنوعی در سطح انسان (Human-Level AI) دور هستیم.

مدل‌های ما تنها می‌توانند

\* تعمیم‌های محلی را اجرا کنند و

\* به موقعیت‌های جدید که باید مشابه داده‌های گذشته باشد وفق پیدا کنند.

در حالی که قوه‌ی شناخت انسان قادر به تعمیم حداکثری (حتی بی‌نهایت) است

و به سرعت با شرایط کاملاً جدید وفق می‌یابد

و برای موقعیت‌های آینده طرح‌ریزی بلندمدت می‌کند.

## محدودیت‌های یادگیری عمیق

جمع‌بندی

### WRAPPING UP

تاکنون، تنها موفقیت واقعی یادگیری عمیق، توانایی نگاشت فضای  $X$  به فضای  $Y$  با استفاده از یک تبدیل هندسی پیوسته و با دریافت مقادیر زیادی از داده‌های حاشیه‌نویسی شده توسط انسان است.

انجام خوب همین، اساساً یک تغییردهنده‌ی بازی برای هر صنعتی است، اما هنوز راهی طولانی برای هوش مصنوعی در سطح انسان وجود دارد.

برای رفع برخی از محدودیت‌های مورد بحث و برای ایجاد هوش مصنوعی در سطح قابل رقابت با انسان:

**باید از نگاشت ساده و مستقیم ورودی به خروجی دور شویم و به سراغ استدلال و انتزاع برویم.**

یک بستر مناسب احتمالی برای مدل‌سازی انتزاعی مفاهیم و شرایط مختلف، بستر برنامه‌های کامپیوتری است. مدل‌های یادگیری ماشینی را می‌توان به صورت برنامه‌های قابل یادگیری تعریف کرد. در حال حاضر تنها برنامه‌هایی را می‌توانیم یاد بگیریم که به زیرمجموعه‌ای خاص و محدود از همه‌ی برنامه‌های ممکن تعلق دارند.

JUDEA PEARL  
*WINNER OF THE TURING AWARD*  
AND DANA MACKENZIE

THE  
BOOK OF  
WHY



THE NEW SCIENCE  
OF CAUSE AND EFFECT

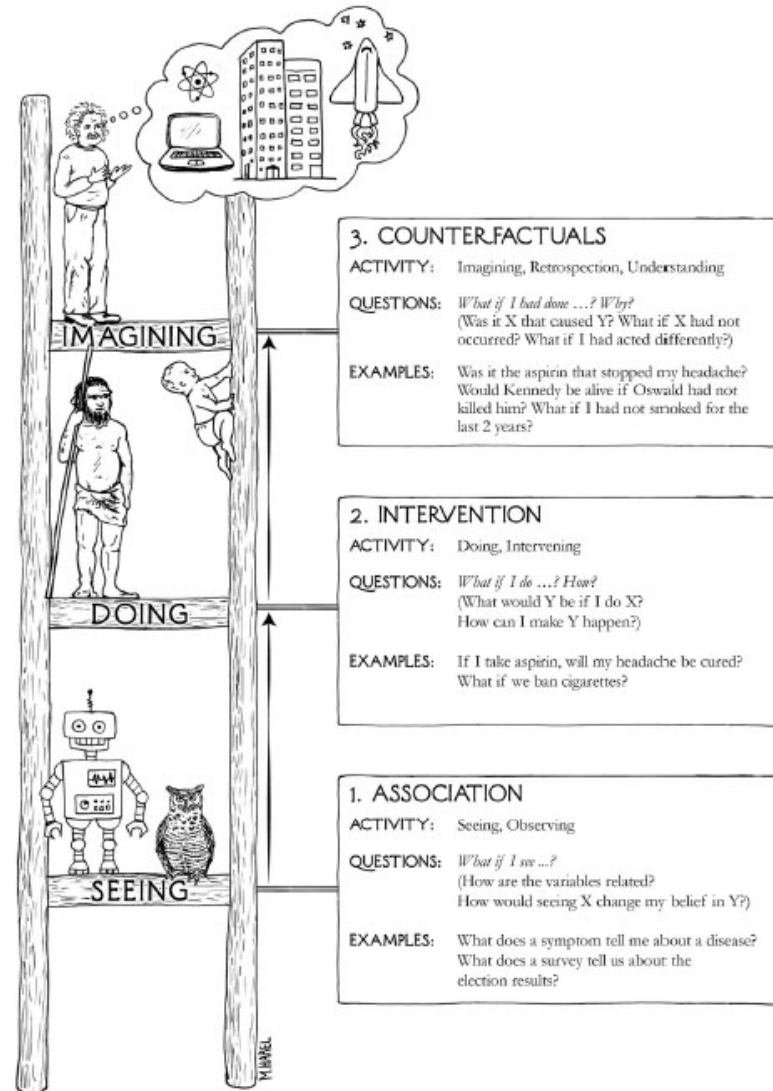



FIGURE 1.2. The Ladder of Causation, with representative organisms at each level. Most animals, as well as present-day learning machines, are on the first rung, learning from association. Tool users, such as early humans, are on the second rung if they act by planning and not merely by imitation. We can also use experiments to learn the effects of interventions, and presumably this is



### 3. COUNTERFACTUALS

**ACTIVITY:** Imagining, Retrospection, Understanding

**QUESTIONS:** *What if I had done ...? Why?*  
(Was it X that caused Y? What if X had not occurred? What if I had acted differently?)

**EXAMPLES:** Was it the aspirin that stopped my headache?  
Would Kennedy be alive if Oswald had not killed him? What if I had not smoked for the last 2 years?

### 2. INTERVENTION

**ACTIVITY:** Doing, Intervening

**QUESTIONS:** *What if I do ...? How?*  
(What would Y be if I do X?  
How can I make Y happen?)

**EXAMPLES:** If I take aspirin, will my headache be cured?  
What if we ban cigarettes?

### 1. ASSOCIATION

**ACTIVITY:** Seeing, Observing

**QUESTIONS:** *What if I see ...?*  
(How are the variables related?  
How would seeing X change my belief in Y?)

**EXAMPLES:** What does a symptom tell me about a disease?  
What does a survey tell us about the election results?

نتیجه گیری: حال و آینده ی یادگیری عمیق

۳

آینده ی  
یادگیری  
عمیق

## آینده‌ی یادگیری عمیق

جهت‌های اصلی امیدبخش

### THE FUTURE OF DEEP LEARNING

ساخته‌شده از عناصر ابتدایی بسیار قوی‌تر نسبت به لایه‌های مشتق‌پذیر کنونی  $\Leftarrow$  دستیابی به استدلال و انتزاع (عدم وجود آنها نقطه‌ضعف اساسی مدل‌های کنونی است.)

مدل‌های نزدیک به برنامه‌های کامپیوتری همه‌منظوره

که به مدل‌ها امکان می‌دهند از تبدیلات مشتق‌پذیر دور شوند.


صورت‌های جدید یادگیری برای امکان‌پذیر کردن استدلال و انتزاع

کار انسان‌ها نباید این باشد که دائماً در حال انجام تنظیمات دستی باشند.

مدل‌هایی با نیاز به مداخله‌ی کمتر از سوی مهندسان انسانی

مانند سیستم‌های فرایادگیری با استفاده از زیرروال‌های برنامه‌ای پیمان‌های و قابل استفاده‌ی مجدد

به‌کارگیری مجدد سیستماتیک و گسترده‌تر ویژگی‌ها و معماری‌های از پیش یادگیری شده



## آینده‌ی یادگیری عمیق

THE FUTURE OF DEEP LEARNING

مسیرهای امیدبخش آینده،  
مختص صورت یادگیری بانظارت نیست  
(که تا کنون پایه و اساس یادگیری عمیق بوده است)؛  
بلکه آنها را می‌توان به هر صورتی از یادگیری ماشینی  
(یادگیری بدون نظارت، یادگیری خود-نظارتی و یادگیری تقویتی)  
اعمال کرد.

اساساً چندان مهم نیست که برچسب‌های شما از کجا می‌آیند و  
حلقه‌ی آموزشی شما به چه شکلی است.  
شاخه‌های متفاوت یادگیری ماشینی، عناصر مختلف یک سازه هستند.



## آینده‌ی یادگیری عمیق

مدل‌ها به‌عنوان برنامه‌ها

### MODELS AS PROGRAMS

یک توسعه‌ی دگرگون‌کننده‌ی اساسی که می‌توانیم در حوزه‌ی یادگیری ماشینی انتظار داشته باشیم، تغییر مسیر از مدل‌هایی که صرفاً **بازشناسی الگو** انجام می‌دهند و تنها می‌توانند به **تعمیم محلی** دست پیدا کنند، به سمت مدل‌هایی است که دارای **قدرت استدلال و انتزاع** هستند و می‌توانند به **تعمیم حداکثری** دست پیدا کنند.

برنامه‌های کنونی هوش مصنوعی، قادر به انجام شکل‌های ابتدایی استدلال هستند، که همگی توسط برنامه‌نویسان انسانی برنامه‌نویسی می‌شوند: مانند نرم‌افزاری که متکی بر الگوریتم‌های جستجو، دست‌کاری گراف و منطق صوری است.

در نرم‌افزار AlphaGo متعلق به Google DeepMind، بخش زیادی از هوش مشاهده شده، توسط برنامه‌نویسان خبره برنامه‌نویسی شده است (مانند جستجوی درختی مونت کارلو)؛ یادگیری از داده‌ها فقط در زیرماژول‌های تخصصی (شبکه‌های ارزش و شبکه‌های سیاست) انجام می‌شود.

اما در آینده ممکن است این سیستم‌های هوش مصنوعی بدون نیاز به مداخله‌ی انسانی به‌طور کامل یادگیری شوند.

## آینده‌ی یادگیری عمیق

مدل‌ها به عنوان برنامه‌ها: مثال

### MODELS AS PROGRAMS

RNN‌ها نسبت به شبکه‌های پیش‌خور دارای چند محدودیت کمتر هستند:

RNN‌ها کمی بیش از تبدیلات هندسی محض هستند:

تبدیلات هندسی که به صورت تکراری داخل یک حلقه‌ی for به کار گرفته می‌شوند.

حلقه‌ی زمانی for خود توسط برنامه‌نویسان انسانی کدنویسی می‌شود: یک فرض پیش‌ساخته‌ی این شبکه.

طبیعتاً RNN‌ها هنوز در آنچه می‌توانند ارائه دهند محدود هستند:

(۱) هر مرحله‌ی اجرا، یک تبدیل هندسی مشتق‌پذیر است؛

(۲) اطلاعات از طریق نقاط یک فضای هندسی پیوسته (بردارهای حالت) از یک مرحله به مرحله‌ی دیگر می‌روند.

حال یک شبکه‌ی عصبی را تصور می‌کنیم که به شیوه‌ای مشابه با عناصر ابتدایی برنامه‌نویسی ارتقا یافته است:

به جای یک حلقه‌ی for کدنویسی شده با حافظه‌ی هندسی کدنویسی شده،

شبکه شامل مجموعه‌ی بزرگ‌تری از عناصر ابتدایی برنامه‌نویسی است که مدل در دستکاری و تغییر آنها

برای توسعه‌ی عملکرد پردازش خود آزاد است؛ مانند:

شاخه‌های if، دستورهای while، ایجاد متغیر، ذخیره‌سازی در دیسک برای حافظه‌ی طولانی مدت،

عملگرهای مرتب‌سازی، ساختارهای داده‌ای پیشرفته (کدها، گراف‌ها، جداول درهم‌سازی، ...)، ...

فضای برنامه‌هایی که چنین شبکه‌ای می‌تواند ارائه بدهد،

بسیار وسیع‌تر از فضایی است که می‌توان توسط مدل‌های کنونی یادگیری عمیق ارائه داد

و برخی از این برنامه‌ها می‌توانند به یک توان تعمیم‌دهی برتر دست بیابند.

## آینده‌ی یادگیری عمیق

ما از یک سو از هوش مصنوعی الگوریتمی کدنویسی شده (نرم افزارهای کدنویسی شده‌ی دستی) و از سوی دیگر از هوش هندسی یادگیری شده (یادگیری عمیق) دور خواهیم شد.

در عوض،

ترکیبی از ماژول‌های الگوریتمی صوری (که قابلیت‌های استدلال و انتزاع را فراهم می‌کنند) و ماژول‌های هندسی (که قابلیت‌های شهود غیرصوری و بازشناسی الگو را فراهم می‌کنند) در اختیار خواهیم داشت.

کل سیستم با میزان اندکی از مشارکت کاربر انسانی یا بدون آن یادگیری خواهد شد.

## آینده‌ی یادگیری عمیق

سنتز برنامه‌ی عصبی

### NEURAL PROGRAM SYNTHESIS

یک زیرحوزه‌ی مرتبط با هوش مصنوعی که به نظر می‌رسد در سطح وسیعی در حال اوج گیری است:  
**سنتز برنامه / program synthesis**

سنتز برنامه: تولید خودکار برنامه‌های ساده از طریق به‌کارگیری یک الگوریتم جستجو (مثل جستجوی ژنتیکی مانند آنچه در برنامه‌نویسی ژنتیک داریم) به‌منظور کاوش در یک فضای بزرگ از برنامه‌های ممکن است.

این جستجو و کاوش زمانی متوقف می‌شود که برنامه‌ای پیدا شود که با مشخصات لازم مطابقت داشته باشد، و این مشخصات معمولاً به‌صورت مجموعه‌ای از دوتایی‌های ورودی-خروجی ارائه می‌شوند:  
**یادآور یادگیری ماشینی:**

با در نظر گرفتن داده‌های آموزشی که به‌صورت مجموعه‌ای از دوتایی‌های ورودی-خروجی ارائه می‌شوند، برنامه‌ای را می‌یابیم که ورودی‌ها را به خروجی‌ها مطابقت می‌دهد و می‌تواند به ورودی‌های جدید تعمیم پیدا کند.

تفاوت: به‌جای یادگیری مقادیر پارامترها در یک برنامه‌ی کدنویسی شده (یک شبکه‌ی عصبی)، کد منبع را از طریق یک فرآیند جستجوی گسسته تولید می‌کنیم.

## آینده‌ی یادگیری عمیق

انتظار می‌رود در سال‌های آینده موجی از توجهات به «سنتز برنامه‌ی عصبی» جلب شود؛ به‌ویژه ظهور یک زیرحوزه‌ی تقاطعی بین یادگیری عمیق و سنتز برنامه.

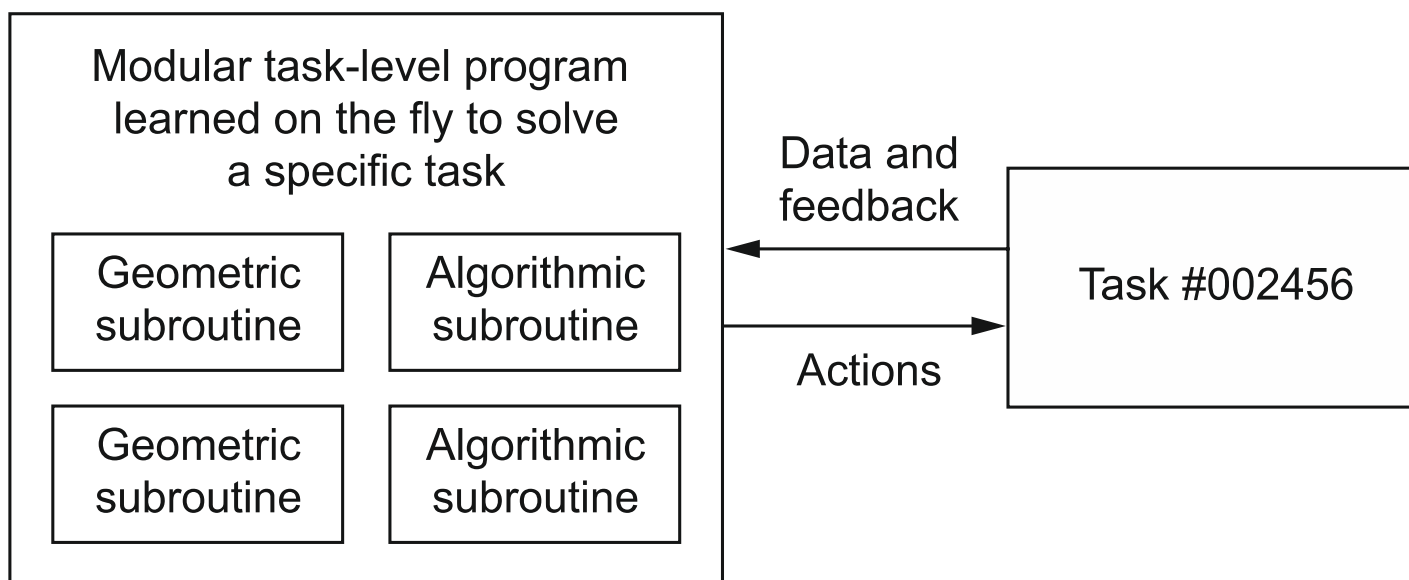
که در آن به‌جای تولید برنامه‌ها با یک زبان همه‌منظوره، شبکه‌هایی عصبی (جریان هندسی پردازش داده‌ها) را تولید خواهیم کرد که با یک مجموعه‌ی غنی از عناصر ابتدایی برنامه‌نویسی الگوریتمی (مانند حلقه‌های for و ...) تقویت می‌شوند.

این روش احتمالاً در مقایسه با روش تولید مستقیم کد منبع، بسیار سودمندتر و دنبال‌پذیرتر است

و دامنه‌ی مسائلی که می‌توانند با یادگیری ماشینی حل شوند را گسترش می‌دهد: «فضای برنامه‌هایی که ما می‌توانیم با داشتن داده‌های آموزشی مناسب به‌طور خودکار تولید کنیم».

RNN‌های امروزی را می‌توان به‌عنوان اجداد پیشین این مدل‌های ترکیبی الگوریتمی-هندسی در نظر گرفت.

## آینده‌ی یادگیری عمیق



یک برنامه‌ی یادگیری شده متکی بر هر دوی  
عناصر ابتدایی هندسی (بازشناسی الگو، شهود) و  
عناصر ابتدایی الگوریتمیک (استدلال، جستجو، حافظه)

## آینده‌ی یادگیری عمیق

فراتر از پس‌انتشار و لایه‌های مشتق‌پذیر

### BEYOND BACKPROPAGATION AND DIFFERENTIABLE LAYERS

اگر مدل‌های یادگیری ماشینی شباهت بیشتری به برنامه‌ها پیدا کنند،  
آن‌گاه عمدتاً مشتق‌پذیر نخواهند بود:

این برنامه‌ها همچنان از لایه‌های هندسی پیوسته به‌عنوان زیرروال استفاده خواهند کرد که مشتق‌پذیر خواهند بود،  
اما مدل به‌عنوان یک کلیت مشتق‌پذیر نخواهد بود.  
⇐ استفاده از پس‌انتشار برای تنظیم مقادیر وزن‌ها در یک شبکه‌ی ثابت و کدنویسی شده  
نمی‌تواند روش انتخابی برای آموزش مدل در آینده باشد.



باید نحوه‌ی آموزش کارآمد سیستم‌های مشتق‌ناپذیر را کشف کنیم.

روی‌کرده‌های کنونی:

الگوریتم‌های ژنتیک، استراتژی‌های تطوری، روش‌های خاص یادگیری تقویتی، ADDM

طبیعی است که کاهش گرادینانی راه به‌جایی نمی‌برد:  
اطلاعات گرادینان همواره برای بهینه‌سازی توابع پارامتری مشتق‌پذیر مفید خواهند بود،  
اما مدل‌های ما بلندپروازانه‌تر از توابع پارامتری مشتق‌پذیر محض هستند،  
⇐ برای توسعه‌ی خودکار آنها (یادگیری در یادگیری ماشین) به‌چیزی بیش از پس‌انتشار نیاز داریم.

## آینده‌ی یادگیری عمیق

ناکارآمدی محاسباتی پس‌انتشار

پس‌انتشار به صورت انتها به انتها است که برای یادگیری تبدیل‌های زنجیره‌ای خوب، عالی اما از نظر محاسباتی ناکارآمد است: زیرا از ماژولار بودن شبکه‌های عمیق به طور کامل بهره‌برداری نمی‌کند.

دستور کلی برای کارآمدتر کردن:  
وارد کردن ویژگی‌های پیمان‌های بودن و سلسله‌مراتبی بودن.

⇐ می‌توانیم با معرفی ماژول‌های مجزای آموزشی با یک سازوکار همگام‌سازی میان آنها که به صورت سلسله‌مراتبی سازمان‌دهی شده‌اند، پس‌انتشار را کارآمدتر کنیم.

این استراتژی تا حدی در کار اخیر DeepMind بر روی گرادیان‌های سنتز شده منعکس شده است. انتظار داریم در آینده فعالیت‌های بیشتری در این راستا انجام شود.

### آینده‌ی قابل تجسم:

رشد مدل‌هایی که در کل مشتق‌پذیر نیستند اما دارای بخش‌های مشتق‌پذیر هستند: آموزش مدل کلی با یک فرآیند جستجوی کارآمد بدون استفاده از گرادیان‌ها و آموزش بخش‌های مشتق‌پذیر با بهره‌گیری از گرادیان‌ها و یک نسخه‌ی کارآمدتر از پس‌انتشار با سرعتی بالاتر



## آینده‌ی یادگیری عمیق

یادگیری ماشینی خودکار شده

### AUTOMATED MACHINE LEARNING

در آینده به جای آنکه معماری مدل‌ها توسط مهندسان به صورت دستی ایجاد شود، یادگیری خواهد شد.

یادگیری معماری‌ها به همراه استفاده از مجموعه‌های غنی‌تری از عناصر ابتدایی برنامه‌نویسی و مدل‌های یادگیری ماشینی برنامه-مانند به پیش می‌رود.

## آینده‌ی یادگیری عمیق

یادگیری ماشینی خودکار شده

در حال حاضر بخش زیادی از کار یک مهندس در یادگیری عمیق،  
**دست‌کاری و آماده‌سازی داده‌ها / Data Mugging** با اسکریپت‌های پایتون  
و سپس تنظیم معماری و هایپرپارامترهای شبکه  
به‌منظور رسیدن به یک مدل کاری یا یک مدل جدید است.

**خودکارسازی بخش Data Mugging** دشوار است،  
زیرا اغلب نیازمند دانش مربوط به این حوزه و  
نیز درک سطح بالا از خواسته‌ی مهندس است.

**اما تنظیم هایپرپارامترها** یک روال جستجوی ساده است و  
در این مورد می‌دانیم که مهندس می‌خواهد به چه چیزی دست پیدا کند:  
این هدف توسط تابع اتلاف شبکه‌ی مورد تنظیم تعریف می‌شود.  
تجربه‌ی عملی متداول: استفاده از سیستم‌های AutoML

## آینده‌ی یادگیری عمیق

یادگیری ماشینی خودکار شده: سیستم‌های AutoML

### AUTOML SYSTEMS

در پایه‌ای‌ترین سطح، یک سیستم AutoML می‌تواند موارد زیر را تنظیم کند:  
تعداد لایه‌ها در پشته، ترتیب لایه‌ها در پشته، تعداد واحدها و تعداد فیلترها در هر لایه

این کار معمولاً با کتابخانه‌هایی مانند Hyperopt انجام می‌شود.

با نگاه بلندپروازانه‌تر:

یادگیری معماری مناسب از صفر با کمترین قیدها تا حد ممکن  
برای مثال از طریق یادگیری تقویتی یا الگوریتم‌های ژنتیک

**جهت مهم دیگر در AutoML:**

**یادگیری توأم معماری و وزن‌های مدل؛**

از آنجا که آموزش یک مدل جدید از صفر

در هر زمانی که یک معماری اندک متفاوت را آزمایش می‌کنیم فوق‌العاده ناکارآمد است،

یک سیستم AutoML واقعاً قدرتمند می‌تواند معماری‌ها را همزمان با تنظیم ویژگی‌های مدل از طریق پس‌انتشار روی داده‌های آموزشی evolve کند.

## آینده‌ی یادگیری عمیق

زنجیره‌ی خلق ارزش

### VALUE-CREATION CHAIN

با ظهور سیستم‌های AutoML کار مهندسان یادگیری عمیق تمام نمی‌شود:  
مهندسان به سمت **زنجیره‌ی خلق ارزش حرکت خواهند کرد.**

مهندسان تلاش بیشتری را صرف ایجاد توابع اتلاف پیچیده خواهند کرد  
تا واقعاً نمایانگر اهداف تجاری و درک تاثیر مدل‌های آن بر اکوسیستم‌های دیجیتالی باشند  
که در آن به کار گرفته می‌شوند  
(برای مثال، کاربرانی که پیش‌بینی‌های مدل را مصرف می‌کنند و داده‌های آموزشی مدل را تولید می‌کنند).

## آینده‌ی یادگیری عمیق

یادگیری مادام‌العمر و استفاده‌ی مجدد زیرروال‌های ماژولار: ضرورت استفاده‌ی مجدد

### LIFELONG LEARNING AND MODULAR SUBROUTINE REUSE

اگر مدل‌ها پیچیده‌تر شوند و بر روی عناصر ابتدایی الگوریتمیک غنی‌تر ساخته شوند، در این صورت این پیچیدگی افزایش یافته نیازمند استفاده‌ی مجدد بیشتر بین وظایف خواهد بود (به جای آموزش یک مدل جدید از صفر هر زمان که وظیفه‌ی جدید یا مجموعه داده‌ی جدیدی داریم).

بسیاری از مجموعه داده‌ها حاوی اطلاعات کافی برای توسعه‌ی مدلی جدید و پیچیده از صفر نیستند و استفاده از اطلاعات حاصل از مجموعه داده‌هایی که قبلاً با آنها مواجه شده‌ایم ضروری خواهد بود.

آموزش مدل‌ها از صفر در هر وظیفه‌ی جدیدی ناکارآمد است؛  
به دلیل همپوشانی گسترده میان وظایف کنونی و وظایفی که قبلاً با آنها روبه‌رو شده‌ایم.

(مانند اینکه هر وقت کتاب جدیدی را باز می‌کنیم، زبان را از صفر یاد نمی‌گیریم – که غیرممکن است.)

## آینده‌ی یادگیری عمیق

یادگیری مادام‌العمر و استفاده‌ی مجدد زیرروال‌های ماژولار: مزیت آموزش مدل توأم

یک مشاهده‌ی قابل توجه:

آموزش یک مدل واحد به‌طور همزمان برای انجام چند وظیفه که ارتباط کمی با هم دارند، منتهی به مدلی می‌شود که در هر یک از آن وظایف بهتر عمل می‌کند.

برای مثال: آموزش یک مدل عصبی ترجمه‌ی ماشینی برای انجام دو وظیفه‌ی ترجمه‌ی انگلیسی به آلمانی و ترجمه‌ی فرانسوی به ایتالیایی منجر به مدلی می‌شود که در هر دو وظیفه بهتر عمل می‌کند.

مثال دیگر: آموزش یک مدل طبقه‌بندی تصویر به‌طور همزمان با یک مدل بخش‌بندی تصویر که در پایه‌ی کانوولوشنی مشترک هستند، منجر به مدلی می‌شود که در هر دو وظیفه بهتر عمل می‌کند.

### دلیل شهودی:

همواره سطحی از همپوشانی اطلاعاتی بین وظایفی که ظاهراً با هم ارتباطی ندارند، وجود دارد و یک مدل توأم نسبت به مدلی که تنها در آن وظیفه‌ی خاص آموزش یافته است، به میزان اطلاعات بیشتری درباره‌ی هر یک از آن وظایف دسترسی دارد.

## آینده‌ی یادگیری عمیق

یادگیری مادام‌العمر و استفاده‌ی مجدد زیرروال‌های ماژولار

در حال حاضر، وقتی بحث استفاده‌ی مجدد از مدل در وظایف گوناگون طرح می‌شود، از وزن‌های پیش‌آموزش‌دیده‌ی مدل‌ها استفاده می‌کنیم.

در آینده انتظار می‌رود نسخه‌ی تعمیم‌یافته‌ای از استفاده‌ی مجدد متداول شود: نه تنها از ویژگی‌هایی که قبلاً یادگیری شده‌اند (وزن‌های زیرمدل) استفاده خواهیم کرد، بلکه معماری‌های مدل‌ها و روال‌های آموزش را نیز به کار خواهیم گرفت.

با شبیه‌تر شدن مدل‌ها به برنامه‌ها،

شروع به استفاده‌ی مجدد از زیرروال‌های برنامه‌ای / program subroutines مانند توابع و کلاس‌های موجود در زبان‌های برنامه‌نویسی انسانی خواهیم کرد.

## آینده‌ی یادگیری عمیق

یادگیری مادام‌العمر و استفاده‌ی مجدد زیرروال‌های ماژولار: سیستم‌های فرایادگیری

### META-LEARNING SYSTEMS

مثال: فرآیند امروزی توسعه‌ی نرم‌افزار:

وقتی که مهندس یک مسئله‌ی خاص را حل می‌کند (برای مثال، کوئری‌های HTTP در پایتون)، آن را به صورت یک کتابخانه‌ی انتزاعی قابل استفاده‌ی مجدد بسته‌بندی می‌کند.

مهندسانی که در آینده با مسئله‌ی مشابهی روبه‌رو می‌شوند، می‌توانند به جستجوی کتابخانه‌های موجود بپردازند، یکی از آنها را دانلود کنند و آن را در پروژه‌ی خود استفاده کنند.

به همین شیوه،

**در سیستم‌های فرایادگیری / meta-learning systems** آینده،

سیستم‌ها قادر خواهند بود با غربال‌گری یک کتابخانه‌ی جهانی از بلوک‌های سطح بالای قابل استفاده‌ی مجدد، برنامه‌های جدیدی را ایجاد کنند.

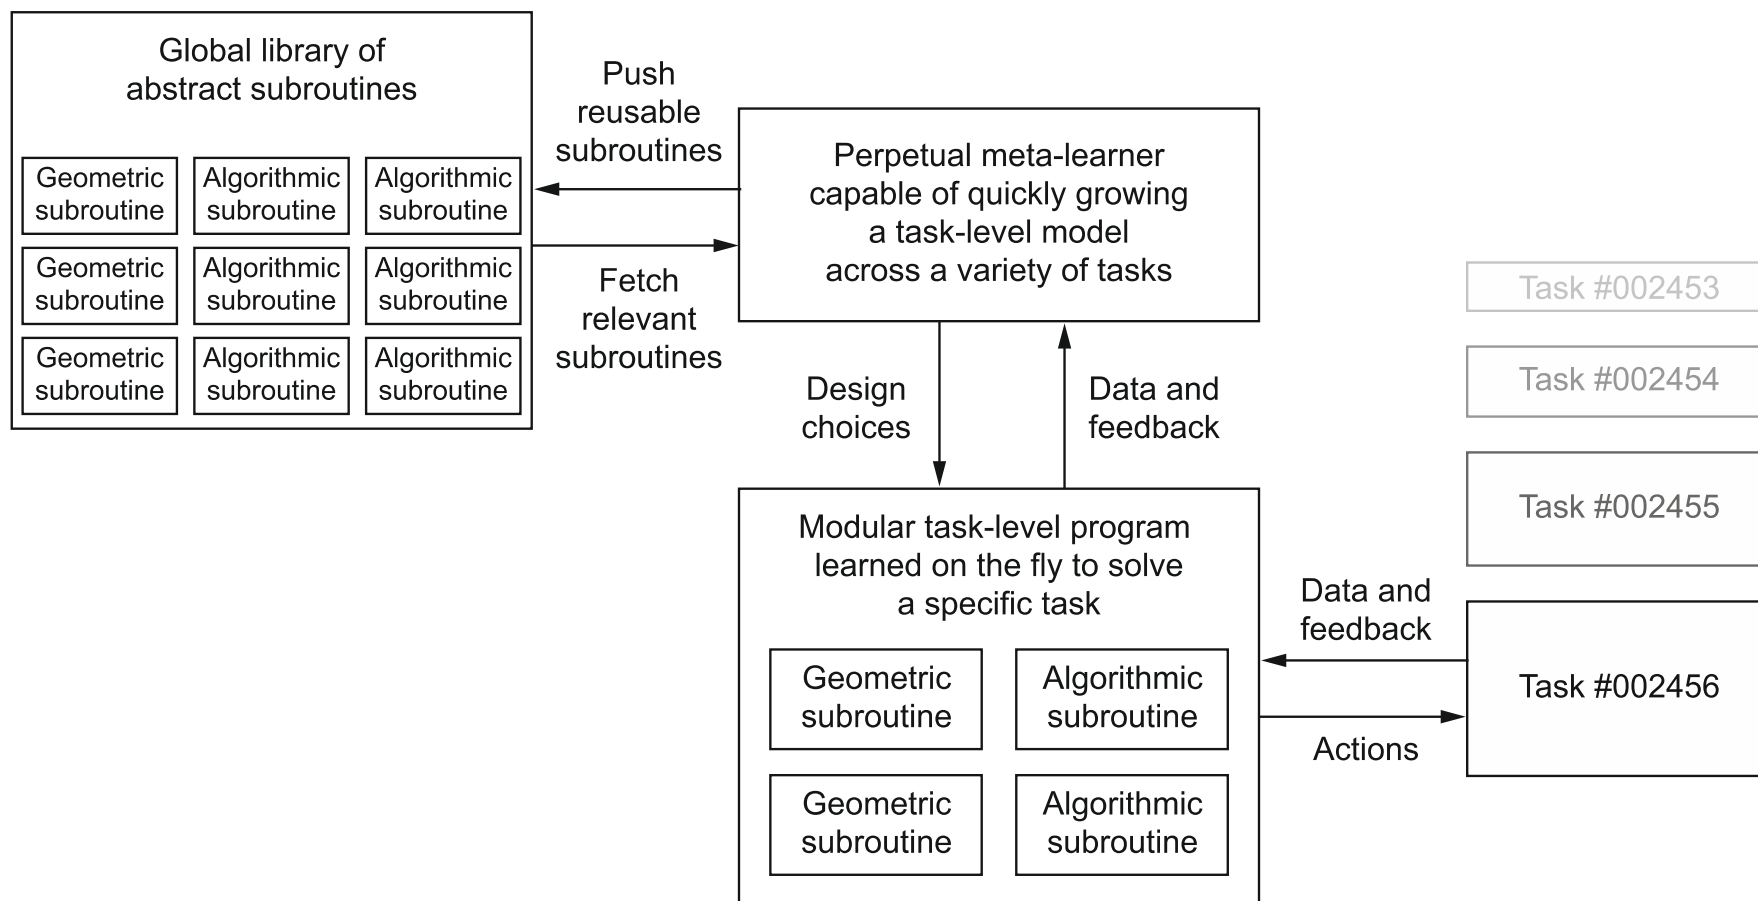
هنگامی که سیستم مشغول توسعه‌ی زیرروال‌های برنامه‌ی مشابه برای چند وظیفه‌ی مختلف است، می‌تواند یک نسخه‌ی انتزاعی و قابل استفاده‌ی مجدد از آن زیرروال را بیابد و آن را در کتابخانه‌ی جهانی ذخیره کند. این فرآیند بخش **انتزاع** را پیاده‌سازی خواهد کرد: یکی از اجزای اصلی برای دستیابی به **تعمیم حداکثری**. می‌توان گفت زیرروالی که در وظایف و دامنه‌های مختلف سودمند واقع می‌شود جنبه‌ای از حل مسئله را **انتزاعی** می‌کند. این تعریف از انتزاع مشابه با مفهوم انتزاع در مهندسی نرم‌افزار است. این زیرروال‌ها می‌توانند **هندسی** (ماژول‌های یادگیری عمیق با بازنمایی‌های پیش‌آموزش دیده) یا **الگوریتمیک** (نزدیک‌تر به کتابخانه‌های مورد استفاده در مهندسی نرم‌افزار معاصر) باشند.



## آینده‌ی یادگیری عمیق

یادگیری مادام‌العمر و استفاده‌ی مجدد زیرروال‌های ماژولار: سیستم‌های فرایادگیری

### META-LEARNING SYSTEMS



یک **فرایادگیرنده** با قابلیت توسعه‌ی سریع مدل‌های خاص-وظیفه با استفاده از عناصر ابتدایی قابل استفاده‌ی مجدد (هم الگوریتمیک و هم هندسی) ← امکان دستیابی به تعمیم حداکثری

## آینده‌ی یادگیری عمیق

### چشم‌انداز طولانی‌مدت

#### THE LONG-TERM VISION

قابلیت‌هایی فراتر از تبدیلات هندسی روی داده‌های ورودی؛  
مدل‌های ذهنی انتزاعی که انسان‌ها از خود و محیط دارند؛  
تعمیم‌پذیری بیشتر به دلیل ماهیت الگوریتمی غنی

مثل سیستم AlphaGo (که نیازمند میزان زیادی مهندسی  
نرم‌افزار دستی و تصمیم‌گیری طراحی توسط انسان بود):  
نمونه‌ای زود هنگام از ترکیب AI نمادین و AI هندسی

نه از طریق کدنویسی توسط مهندسان انسانی؛  
کتابخانه‌ای که از طریق یادگیری مدل‌های دارای کارایی بالا  
در هزاران وظیفه و مجموعه داده‌ی پیشین تکامل یافته است.

با در نظر گرفتن یک وظیفه یا شرایط جدید، سیستم قادر  
خواهد بود تا مدل کاری جدیدی گردآوری کند که از داده‌های  
بسیار اندکی استفاده می‌کند ...

نباید انتظار داشته باشیم یک ربات تکینه‌ی آخرالزمانی  
به وجود آید: این یک تخیل محض و ناشی از دنباله‌ی درازی  
از سوء تفاهم‌ها در مورد هوش و تکنولوژی است.


شبیه‌تر شدن مدل‌ها به برنامه‌ها ⇐  
شبیه‌تر بودن برنامه‌ها به مدل ذهنی انسان ⇐  
قابلیت تعمیم بیشتر

ترکیب ماژول‌های الگوریتمی (قابلیت‌های استدلال  
صوری، جستجو، انتزاع) با ماژول‌های هندسی  
(قابلیت‌های شهود غیر صوری، بازشناسی الگو)

رشد خودکار مدل‌ها با استفاده از بخش‌های  
ماژولار ذخیره شده در یک کتابخانه‌ی جهانی از  
زیرروال‌های قابل استفاده‌ی مجدد ⇐ انتزاعی‌سازی

دستیابی به شکلی از تعمیم‌دهی حداکثری مانند  
انسان توسط کتابخانه‌ی جهانی و سیستم  
مربوطه برای رشد و توسعه‌ی مدل

دستیابی به «هوش عمومی مصنوعی: AGI»:  
سیستمی که دائماً در حال رشد مدل یادگیری  
است ...



نتیجه‌گیری: حال و آینده‌ی یادگیری عمیق

۴

به روز ماندن  
در  
یادگیری  
عمیق

## به‌روزماندن در یادگیری عمیق

### STAYING UP TO DATE IN A FAST-MOVING FIELD

تاریخ طولانی و آهسته‌ی یادگیری عمیق به دهه‌ها قبل برمی‌گردد،  
اما تنها چند سال از حوزه‌ی یادگیری عمیق جدید می‌گذرد:  
با یک رشد چشمگیر در منابع مالی و فعالان پژوهشی از سال ۲۰۱۳ تاکنون ...

توصیه‌هایی برای به‌روزماندن در این رشته:

<https://kaggle.com>


تمرین با مسائل دنیای واقعی با استفاده از Kaggle

<https://arxiv.org>  
<http://arxiv-sanity.com>  
<https://scholar.google.com>

خواندن آخرین توسعه‌ها بر روی arXive

<https://keras.io>  
<https://github.com/fchollet/keras>  
<https://kerasteam.slack.com>  
<https://blog.keras.io>

کاوش در اکوسیستم Keras




## بهروزماندن در یادگیری عمیق

تمرین با مسائل دنیای واقعی با استفاده از Kaggle

### PRACTICE ON REAL-WORLD PROBLEMS USING KAGGLE

<https://kaggle.com>

تمرین با مسائل دنیای واقعی با استفاده از Kaggle



One effective way to acquire real-world experience is to try your hand at machine learning competitions on Kaggle (<https://kaggle.com>).

**The only real way to learn is through practice and actual coding**

—that’s the philosophy of this book, and Kaggle competitions are the natural continuation of this. On Kaggle, you’ll find an array of constantly renewed data-science competitions, many of which involve deep learning, prepared by companies interested in obtaining novel solutions to some of their most challenging machine-learning problems. Fairly large monetary prizes are offered to top entrants.

Most competitions are won using either the **XGBoost** library (for shallow machine learning) or **Keras** (for deep learning). So you’ll fit right in! By participating in a few competitions, maybe as part of a team, you’ll become more familiar with the practical side of some of the advanced best practices described in this book, especially hyperparameter tuning, avoiding validation-set overfitting, and model ensembling.

## به روز ماندن در یادگیری عمیق

تمرین با مسائل دنیای واقعی با استفاده از Kaggle

### PRACTICE ON REAL-WORLD PROBLEMS USING KAGGLE

بر اساس مشاهده‌ی رقابت‌های یادگیری ماشین در Kaggle:

ماشین‌های بوستینگ گرادیانی

*Gradient Boosting Machines*

برای داده‌های ساخت‌یافته

یادگیری عمیق

*Deep Learning*

برای مسائل ادراکی

dmlc  
**XGBoost**

**K** Keras

پیروزی در بیشتر رقابت‌ها، با استفاده از دو کتابخانه‌ی فوق حاصل شده است.


## به روز ماندن در یادگیری عمیق

خواندن آخرین توسعه‌ها بر روی arXiv

[READ ABOUT THE LATEST DEVELOPMENTS IN ARXIV](#)

<https://arxiv.org>  
<http://arxiv-sanity.com>  
<https://scholar.google.com>

خواندن آخرین توسعه‌ها بر روی arXiv



Deep-learning research, in contrast with some other scientific fields, takes places completely in the open.

Papers are made publicly and freely accessible as soon as they're finalized, and a lot of related software is open source.

arXiv (<https://arxiv.org>)—pronounced “archive” (the X stands for the Greek chi)—is an open-access preprint server for physics, mathematics, and computer science research papers. It has become the de facto way to stay up to date on the bleeding edge of machine learning and deep learning. The large majority of deep-learning researchers upload any paper they write to arXiv shortly after completion.

This allows them to plant a flag and claim a specific finding without waiting for a conference acceptance (which takes months), which is necessary given the fast pace of research and the intense competition in the field.

It also allows the field to move extremely fast:

all new findings are immediately available for all to see and to build on.

## به روز ماندن در یادگیری عمیق

خواندن آخرین توسعه‌ها بر روی arXiv

### [READ ABOUT THE LATEST DEVELOPMENTS IN ARXIVE](#)

An important downside is that the sheer quantity of new papers posted every day on arXiv makes it impossible to even skim them all; and the fact that they aren't peer reviewed makes it difficult to identify those that are both important and high quality.

It's difficult, and becoming increasingly more so, to find the signal in the noise.

Currently, there isn't a good solution to this problem.

But some tools can help: an auxiliary website called

**arXiv Sanity Preserver** (<http://arxiv-sanity.com>)

serves as a recommendation engine for new papers and can help you keep track of new developments within a specific narrow vertical of deep learning.

Additionally, you can use Google Scholar (<https://scholar.google.com>) to keep track of publications by your favorite authors.




## به روز ماندن در یادگیری عمیق

کاوش در اکوسیستم Keras

### EXPLORE THE KERAS ECOSYSTEM

<https://keras.io>  
<https://github.com/fchollet/keras>  
<https://kerasteam.slack.com>  
<https://blog.keras.io>

کاوش در اکوسیستم Keras



With about 200,000 users as of November 2017 and growing fast, Keras has a large ecosystem of tutorials, guides, and related open source projects:

- Your main reference for working with Keras is the online documentation at <https://keras.io>. The Keras source code can be found at <https://github.com/fchollet/keras>.
- You can ask for help and join deep-learning discussions on the Keras Slack channel: <https://kerasteam.slack.com>.
- The Keras blog, <https://blog.keras.io>, offers Keras tutorials and other articles related to deep learning.
- You can follow François Chollet on Twitter: [@fchollet](https://twitter.com/fchollet).

## کلام پایانی

### FINAL WORDS

به یادگیری، پرسش و پژوهش ادامه دهید.  
**هرگز متوقف نشوید.**

حتی با وجود پیشرفت‌هایی که تاکنون حاصل شده است،  
بسیاری از پرسش‌های اساسی در هوش مصنوعی بدون پاسخ مانده است  
و حتی بسیاری از پرسش‌ها هنوز به درستی مطرح نشده‌اند.

نتیجه گیری: حال و آینده ی یادگیری عمیق

۵

منابع

# Deep Learning with Python

FRANÇOIS CHOLLET

  
MANNING  
SHELTER ISLAND

François Chollet,  
**Deep Learning with Python**,  
Manning Publications, 2018.

## Chapter 9

# Conclusions

### **This chapter covers**

- Important takeaways from this book
- The limitations of deep learning
- The future of deep learning, machine learning, and AI
- Resources for learning further and working in the field

You've almost reached the end of this book. This last chapter will summarize and review core concepts while also expanding your horizons beyond the relatively basic notions you've learned so far. Understanding deep learning and AI is a journey, and finishing this book is merely the first step on it. I want to make sure you realize this and are properly equipped to take the next steps of this journey on your own.

We'll start with a bird's-eye view of what you should take away from this book. This should refresh your memory regarding some of the concepts you've learned. Next, we'll present an overview of some key limitations of deep learning. To use a tool appropriately, you should not only understand what it *can* do but also be aware of what it *can't* do. Finally, I'll offer some speculative thoughts about the future evolution of the fields of deep learning, machine learning, and AI. This should be especially interesting to you if you'd like to get into fundamental research. The chapter ends with a short list of resources and strategies for learning further about AI and staying up to date with new advances.