



## یادگیری عمیق

جلسه ۱۴، ۱۵ و ۱۶

# یادگیری عمیق برای بینایی کامپیووتری

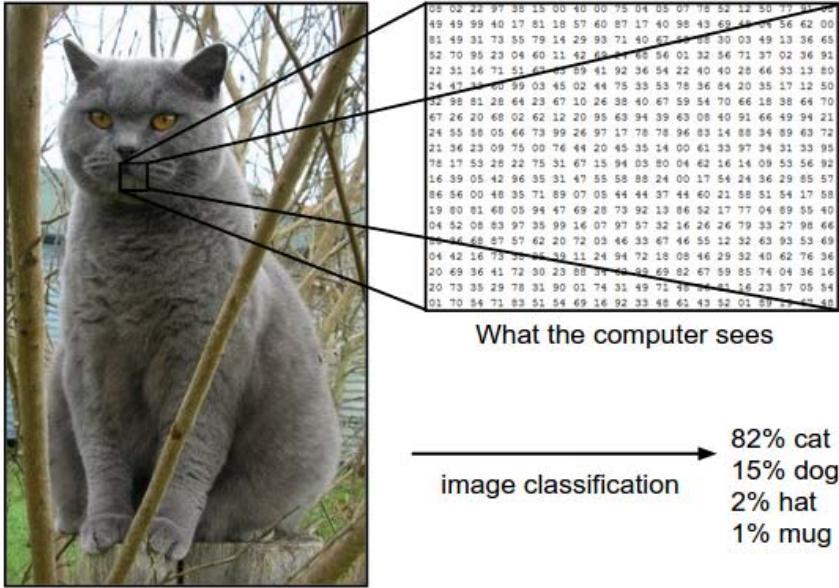
Deep Learning for Computer Vision

کاظم فولادی قلعه

دانشکده مهندسی، پردیس فارابی

دانشگاه تهران

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



Viewpoint variation



Scale variation



Deformation



Occlusion



Illumination conditions



Background clutter



Intra-class variation



یادگیری عمیق برای بینایی کامپیووتری

۱

# معرفی شبکه‌های عصبی کانولوشنال (convnets)

## شبکه‌های عصبی کانولوشنال

### CONVOLUTIONAL NEURAL NETWORKS (CONVNETS)

شبکه‌های عصبی کانولوشنال،  
مدلی از یادگیری عمیق هستند  
که تقریباً در عموم کاربردهای بینایی کامپیوتری مورد استفاده قرار می‌گیرند.

## شبکه‌های عصبی کانولوشنال

یک مثال کاربردی: بازشناسی ارقام دست‌نویس

The problem we're trying to solve here is to classify grayscale images of handwritten digits ( $28 \times 28$  pixels) into their **10 categories** (0 through 9).

8	9	0	1	2	3	4	7	8	9	0	1	2	3	4	5	6	7	8	6
4	2	6	4	7	5	5	4	7	8	9	2	9	3	9	3	8	2	0	5
0	1	0	4	2	6	5	3	5	3	8	0	0	3	4	1	5	3	0	8
3	0	6	2	7	1	1	8	1	7	1	3	8	9	7	6	7	4	1	6
7	5	1	7	1	9	8	0	6	9	4	9	9	3	7	1	9	2	2	5
3	7	8	2	3	4	5	6	7	8	9	0	1	2	3	4	5	6	7	0
1	2	3	4	5	6	7	8	9	8	1	0	5	5	1	9	0	4	1	9
3	8	4	7	7	8	5	0	6	5	5	3	3	3	9	8	1	4	0	6
1	0	0	6	2	1	1	3	2	8	8	7	8	4	6	0	2	0	3	6
8	7	1	5	9	9	3	2	4	9	4	6	5	3	2	3	5	9	4	1
6	5	0	1	2	3	4	5	6	7	8	9	0	1	2	3	4	5	6	7
8	9	0	1	2	3	4	5	6	7	8	9	6	4	2	6	4	7	5	5
4	7	8	9	2	9	3	9	3	8	2	0	9	8	0	5	6	0	1	0
4	2	6	5	5	5	4	3	4	1	5	3	0	8	3	0	6	2	7	1
1	8	1	7	1	3	8	5	4	2	0	9	7	6	7	4	1	6	8	4
7	5	1	2	6	7	1	9	8	0	6	9	4	9	9	6	2	3	7	1
9	2	2	5	3	7	8	0	1	2	3	4	5	6	7	8	0	1	2	3
4	5	6	7	8	0	1	2	3	4	5	6	7	8	7	2	1	2	1	3
9	9	8	5	3	7	0	7	7	5	7	9	9	4	7	0	3	4	1	4
4	7	5	8	1	4	8	4	1	8	6	4	4	6	3	5	7	2	5	9

# MNIST Dataset

A set of **60,000 training** images,  
plus **10,000 test** images,  
assembled by  
the National Institute of Standards and Technology  
(the NIST in MNIST)  
in the 1980s.

## شبکه‌های عصبی کانولوشنال

یک مثال کاربردی: بازشناسی ارقام دستنویس

### Instantiating a small convnet

```
from keras import layers
from keras import models
model = models.Sequential()
model.add(layers.Conv2D(32, (3, 3), activation='relu', input_shape=(28, 28, 1)))
model.add(layers.MaxPooling2D((2, 2)))
model.add(layers.Conv2D(64, (3, 3), activation='relu'))
model.add(layers.MaxPooling2D((2, 2)))
model.add(layers.Conv2D(64, (3, 3), activation='relu'))
```

نکته‌ی مهم:

یک convnet تانسورهایی با شکل  
(image\_height, image\_width, image\_channels)  
را به عنوان ورودی دریافت می‌کند.

## شبکه‌های عصبی کانولوشنال

یک مثال کاربردی: بازشناسی ارقام دستنویس: معماری convnet تا اینجا

```
>>> model.summary()
```

Layer (type)	Output Shape	Param #
<hr/>		
conv2d_1 (Conv2D)	(None, 26, 26, 32)	320
maxpooling2d_1 (MaxPooling2D)	(None, 13, 13, 32)	0
conv2d_2 (Conv2D)	(None, 11, 11, 64)	18496
maxpooling2d_2 (MaxPooling2D)	(None, 5, 5, 64)	0
conv2d_3 (Conv2D)	(None, 3, 3, 64)	36928
<hr/>		

Total params: 55,744

Trainable params: 55,744

Non-trainable params: 0

خروجی هر لایه‌ی Conv2D و MaxPooling2D یک تانسور سه‌بعدی با شکل **(height, width, channels)** است.

هرچه در عمیق شبکه پیش می‌رویم، بعدهای عرض و ارتفاع کوچکتر می‌شوند. تعداد کanal‌ها با اولین آرگومان لایه‌های Conv2D مشخص می‌شود.

## شبکه‌های عصبی کانولوشنال

یک مثال کاربردی: بازشناسی ارقام دست‌نویس: اضافه کردن پشت‌های از لایه‌های متراکم

### Adding a classifier on top of the convnet

```
model.add(layers.Flatten())
model.add(layers.Dense(64, activation='relu'))
model.add(layers.Dense(10, activation='softmax'))
```

آخرین تانسور با شکل

$(3, 3, 64)$

را به عنوان ورودی به یک شبکه‌ی طبقه‌بندی‌کننده‌ی مصل متراکم وارد می‌کنیم:  
پشت‌های از لایه‌های متراکم (Dense).

چون این طبقه‌بندی‌کننده بردارهای یک-بعدی را پردازش می‌کند،  
ابتدا تانسور سه-بعدی را تخت (flat) می‌کنیم.

## شبکه‌های عصبی کانولوشنال

یک مثال کاربردی: بازشناسی ارقام دستنویس: معماری convnet

```
>>> model.summary()
Layer (type)                  Output Shape                 Param #
=====
conv2d_1 (Conv2D)              (None, 26, 26, 32)       320
maxpooling2d_1 (MaxPooling2D)  (None, 13, 13, 32)       0
conv2d_2 (Conv2D)              (None, 11, 11, 64)       18496
maxpooling2d_2 (MaxPooling2D)  (None, 5, 5, 64)        0
conv2d_3 (Conv2D)              (None, 3, 3, 64)        36928
flatten_1 (Flatten)            (None, 576)             0
dense_1 (Dense)                (None, 64)              36928
dense_2 (Dense)                (None, 10)              650
=====
Total params: 93,322
Trainable params: 93,322
Non-trainable params: 0
```

اکنون یک طبقه‌بندی کننده‌ی ۱۰-طبقه‌ای با استفاده از ۱۰ خروجی با تابع فعالیت softmax داریم.

## شبکه‌های عصبی کانولوشنال

یک مثال کاربردی: بازشناسی ارقام دست نویس: آموزش شبکه

### Training the convnet on MNIST images

```
from keras.datasets import mnist
from keras.utils import to_categorical
(train_images, train_labels), (test_images, test_labels) = mnist.load_data()
train_images = train_images.reshape((60000, 28, 28, 1))
train_images = train_images.astype('float32') / 255
test_images = test_images.reshape((10000, 28, 28, 1))
test_images = test_images.astype('float32') / 255
train_labels = to_categorical(train_labels)
test_labels = to_categorical(test_labels)
model.compile(optimizer='rmsprop',
              loss='categorical_crossentropy',
              metrics=['accuracy'])
model.fit(train_images, train_labels, epochs=5, batch_size=64)
```

## شبکه‌های عصبی کانولوشنال

یک مثال کاربردی: بازشناسی ارقام دستنویس: آزمایش شبکه

```
>>> test_loss, test_acc = model.evaluate(test_images, test_labels)  
>>> test_acc  
0.9908000000000001
```

Whereas the **densely connected network** from chapter 2 had a test accuracy of **97.8%**,  
the basic **convnet** has a test accuracy of **99.3%**:

we decreased the error rate by 68% (relative).

## عمل کانولوشن

مقایسه‌ی لایه‌ی متصل متراکم با لایه‌ی کانولوشنال

### THE CONVOLUTION OPERATION

#### لایه‌ی کانولوشنال *Convolution Layer*

در فضای ویژگی ورودی خود  
الگوهای محلی را یاد می‌گیرند.

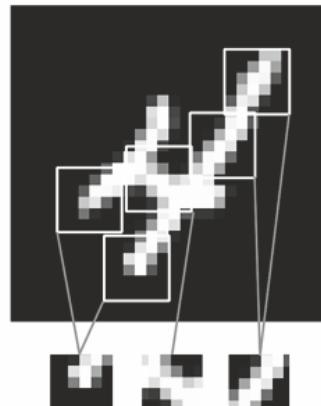
(در تصاویر، الگوها در پنجره‌های کوچک دو بعدی از  
ورودی یافت می‌شوند؛ مثلاً پنجره‌های  $3 \times 3$ )

#### لایه‌ی متصل متراکم *Densely Connected Layer*

در فضای ویژگی ورودی خود  
الگوهای سراسری را یاد می‌گیرند.

(مثلاً در MNIST الگوها حاوی همهٔ پیکسل‌ها هستند)

تصویرها می‌توانند به الگوهای محلی  
مانند لبه‌ها، بافت‌ها و ... شکسته شوند.



## عمل کانولوشن

دو ویژگی جالب ناشی از خصوصیت کلیدی convnet (یادگیری الگوهای محلی)

### THE CONVOLUTION OPERATION

پس از یادگیری یک الگو در قسمتی از تصویر، convnet می‌تواند آن الگو را در هر مکانی بازشناختی کند.

در حالی‌که شبکه‌ی **dense** باید الگو در مکان جدید را دوباره یاد بگیرد.

یادگیری الگوهای تغییرناپذیر در جایه‌جایی

*The patterns they learn are translation invariant*

۱

جهان بصری اساساً نسبت به تغییر مکان، نامتغیر است.

اولین لایه‌ی کانولوشنال الگوهای محلی کوچک مانند لبه‌ها را یاد می‌گیرد.

دومین لایه‌ی کانولوشنال الگوهای بزرگتر ساخته شده از ویژگی‌های اولین لایه را یاد خواهد گرفت و ...

این به convnet اجازه می‌دهد که مفاهیم بصری انتزاعی و پیچیده را به صورت افزایشی یاد بگیرد.

یادگیری سلسله‌مراتب فضایی الگوها

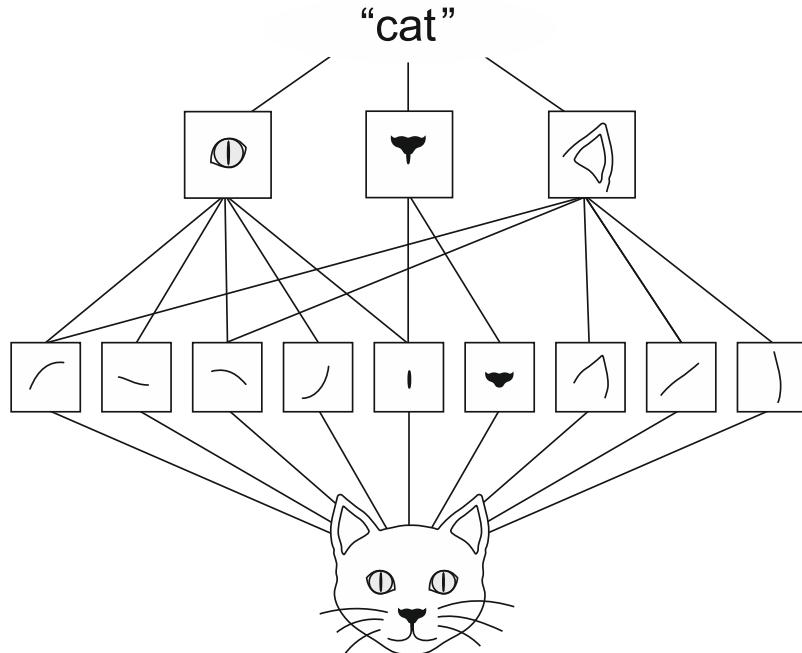
*They can learn spatial hierarchies of patterns*

۲

جهان بصری اساساً سلسله‌مراتبی فضایی است.

## عمل کانولوشن

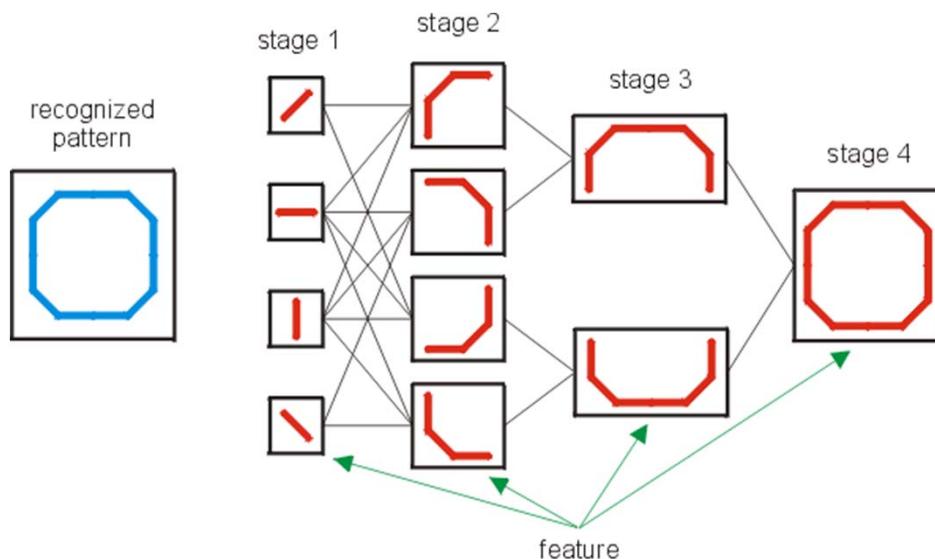
یادگیری سلسله مراتب فضایی الگوها: مثال



یک واژه‌ی دیداری (visual word)، یک سلسله مراتب فضایی از مازول‌های دیداری را شکل می‌دهد: لبه‌های فرامحلی در اشیای محلی (مانند چشمها یا گوش‌ها) ترکیب می‌شوند، که خود آنها در مفاهیم سطح بالاتر مانند «گربه» ترکیب می‌شوند.

## عمل کانولوشن

یادگیری سلسله مراتب فضایی الگوها: مثال: کارکرد نوعی لایه ها



1	1	1	0	0
0	1	1	1	0
0	0	1	1	1
0	0	1	1	0
0	1	1	0	0

Input

1	0	1
0	1	0
1	0	1

Filter / Kernel

1x1	1x0	1x1	0	0
0x0	1x1	1x0	1	0
0x1	0x0	1x1	1	1
0	0	1	1	0
0	1	1	0	0

Input x Filter

4		

Feature Map

1	1x1	1x0	0x1	0
0	1x0	1x1	1x0	0
0	0x1	1x0	1x1	1
0	0	1	1	0
0	1	1	0	0

Input x Filter

4	3	

Feature Map

1	1x1	1x0	0x1	0
0	1x0	1x1	1x0	0
0	0x1	1x0	1x1	1
0	0	1	1	0
0	1	1	0	0

4	3	

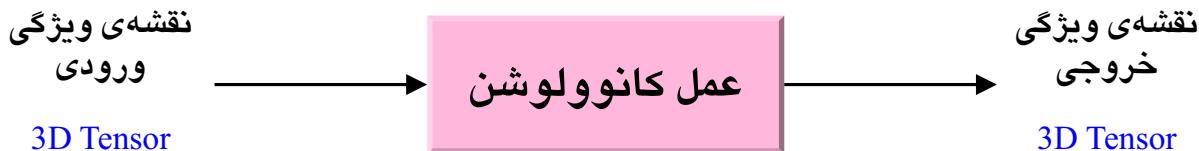
## عمل کانولوشن

### نقشه‌های ویژگی

#### FEATURE MAPS

کانولوشن‌ها روی تانسورهای سه-بعدی (نقشه‌های ویژگی) با دو محور فضایی [ارتفاع و عرض] و یک محور عمق [کanal] انجام می‌شود.

عملیات کانولوشن، پچهایی را از نقشه‌ی ویژگی ورودی خود استخراج می‌کند و تبدیل یکسانی را روی همه‌ی این پچ‌ها اعمال می‌کند تا یک نقشه‌ی ویژگی خروجی ایجاد شود.



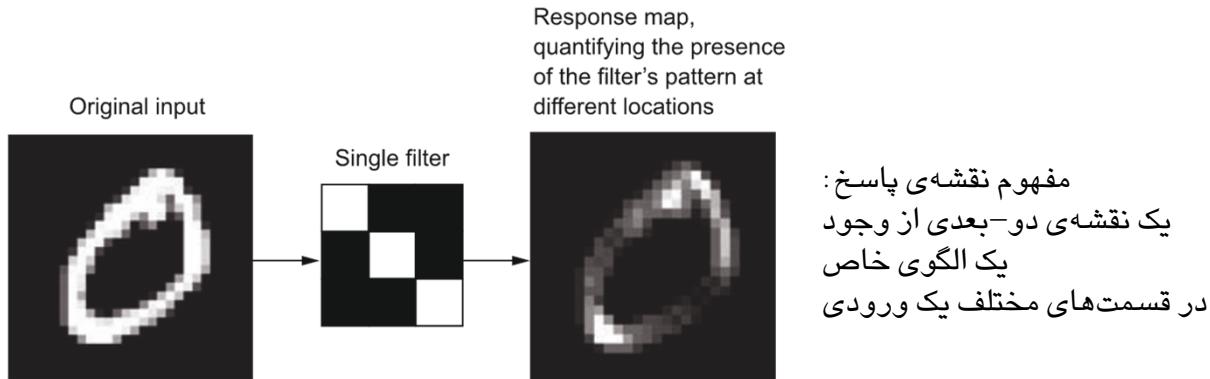
عمق نقشه‌ی ویژگی خروجی می‌تواند داخواه باشد، زیرا عمق خروجی یک پارامتر لایه است.

کanal‌های مختلف در خروجی بیان‌گر رنگ نیستند، بلکه متناظر با **فیلترها** هستند. فیلترها جنبه‌های مختلف داده‌های ورودی را کدگذاری می‌کنند: در سطح بالا، یک فیلتر می‌تواند مثلاً مفهوم «حضور یک چهره در ورودی» را کدگذاری کند.

## عمل کانولوشن

نقشه‌های ویژگی: مثال

### FEATURE MAPS



در مثال MNIST، اولین لایه کانولوشنی، یک نقشه‌ی ویژگی با اندازه‌ی (28,28,1) می‌گیرد و یک نقشه‌ی خروجی با اندازه‌ی (26,26,32) می‌دهد:

یعنی ۳۲ فیلتر را روی ورودی خودش محاسبه می‌کند.

هر یک از این ۳۲ کanal خروجی حاوی یک توری ۲۶\*۲۶ از مقادیر است که نقشه‌ی پاسخ آن فیلتر روی ورودی است؛ و پاسخ آن فیلتر در مکان‌های مختلف ورودی را مشخص می‌کند.

## عمل کانولوشن

پارامترهای کلیدی در تعریف عمل کانولوشن

**اندازه‌ی پچ‌ها**  
*Size of the patches*

معمولًاً  $3 \times 3$  یا  $5 \times 5$  است  
انتخاب  $3 \times 3$  معمول است.

۱

اندازه‌ی پچ‌های استخراج شده از ورودی‌ها

**عمق خروجی**  
*Depth of the output*

تعداد فیلترهایی که با عمل کانولوشن محاسبه می‌شود.  
در مثال: با عمق ۳۲ شروع شد و با عمق ۶۴ پایان یافت.

۲

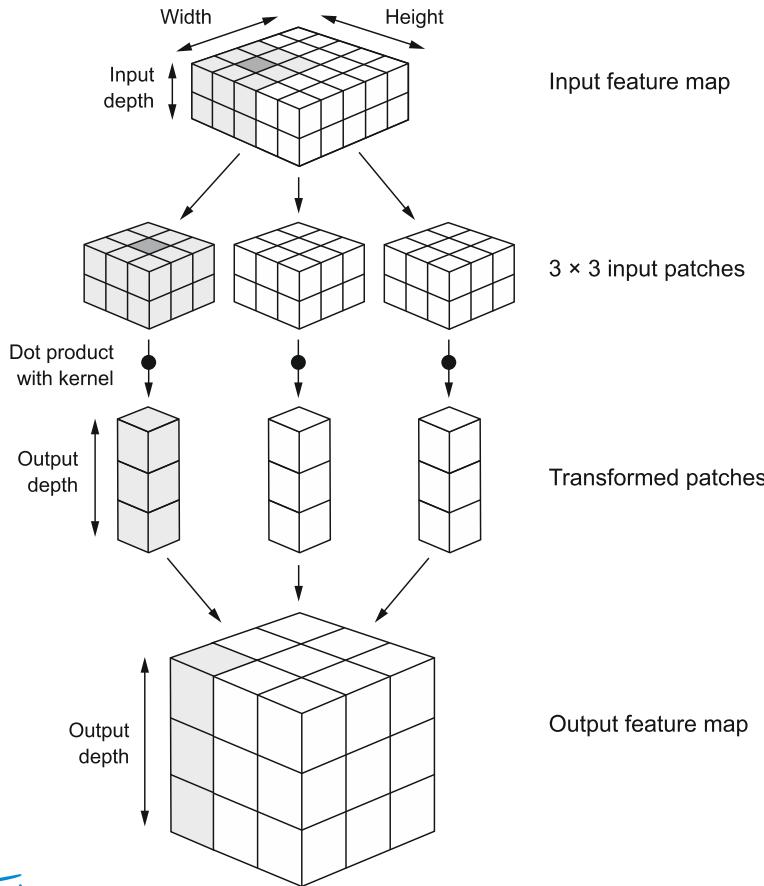
عمق نقشه‌ی ویژگی خروجی

`Conv2D(output_depth, (window_height, window_width))`

در Keras، این پارامترها اولین آرگومان‌هایی هستند که به لایه‌ی Conv2D گذر داده می‌شوند.

## عمل کانولوشن

### عملکرد



در کانولوشن:

- > پنجره‌های کوچک (مثلاً  $3 \times 3$ ) بر روی نقشه‌ی ویژگی ورودی سه-بعدی حرکت داده می‌شود، در هر مکان ممکن توقف می‌کند، و یک پج سه-بعدی از ویژگی‌های پیرامون خود به شکل زیر استخراج می‌کند:
- > سپس هر پج سه-بعدی تحت تبدیل قرار می‌گیرد (از طریق ضرب یک تانسوری با ماتریس وزن یادگیری شده که به آن هسته‌ی کانولوشن / convolution kernel گفته می‌شود). تا به یک بردار یک-بعدی به شکل **output\_depth** تبدیل شود.
- > سپس همه‌ی این بردارها به صورت فضایی در کنار هم قرار می‌گیرند تا یک نقشه‌ی خروجی سه-بعدی به شکل زیر ایجاد شود:

(**height**, **width**, **output\_depth**)

هر مکان در نقشه‌ی ویژگی خروجی، متناظر با همان مکان در نقشه‌ی ویژگی ورودی است.

## عمل کانولوشن

تفاوت عرض و ارتفاع در نقشه‌های ویژگی ورودی و خروجی

عرض و ارتفاع در نقشه‌ی ویژگی ورودی ممکن است با عرض و ارتفاع در نقشه‌ی ویژگی خروجی متفاوت باشد.

به دو دلیل:

می‌تواند از طریق پدگذاری روی نقشه‌ی ویژگی ورودی مقابله شود.

اثرات کناره  
*Border effects*



اندازه‌ی فاصله بین قرارگیری دو پنجره‌ی متواالی

اندازه‌ی قدم  
*Strides*

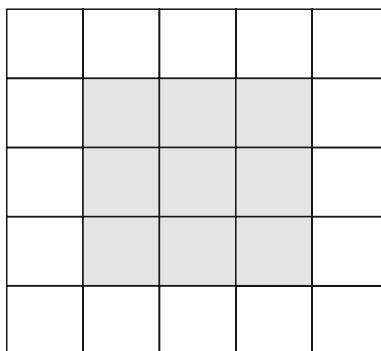


## عمل کانولوشن

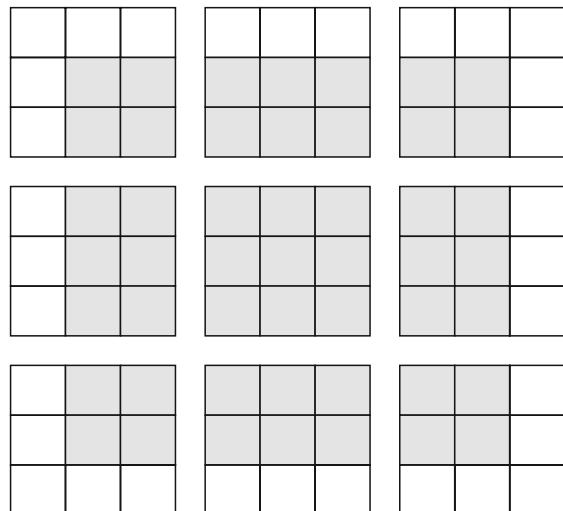
### اثرات کناره

#### BORDER EFFECTS

اگر یک نقشه‌ی ویژگی  $5 \times 5$  داشته باشیم،  
 تنها ۹ خانه وجود دارد که می‌توان یک پنجره‌ی  $3 \times 3$   
 را در آن جای داد.



پس یک توری  $3 \times 3$  تشکیل می‌شود  $\Leftarrow$   
نقشه‌ی ویژگی خروجی  $3 \times 3$  خواهد شد.



خروجی در هر بعد، ۲ واحد کوچکتر از ورودی می‌شود.

## عمل کانولوشن

### پدگذاری

#### PADDING

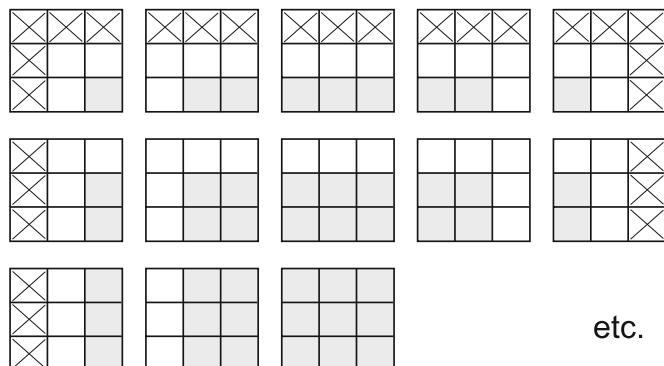
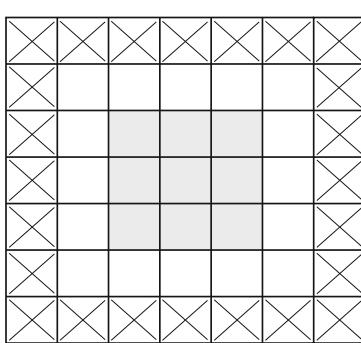
اگر بخواهیم نقشه‌ی ویژگی خروجی دارای ابعاد فضایی یکسان با نقشه‌ی ویژگی ورودی باشد، می‌توانیم از پدگذاری استفاده کنیم.

افزودن تعدادی سطر/ستون به هر یک از کناره‌های نقشه‌ی ویژگی

به‌طوری‌که جای‌دهی پنجره‌های کانولوشن بر روی هر خانه‌ی ورودی ممکن شود.

### پدگذاری

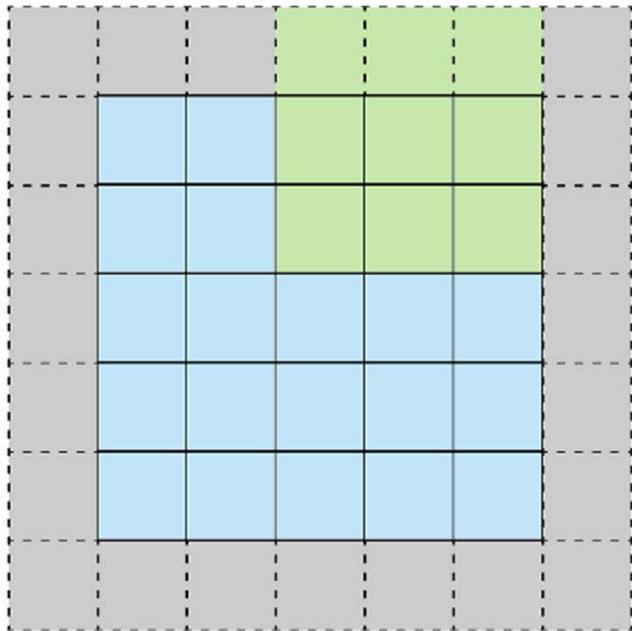
#### *Padding*



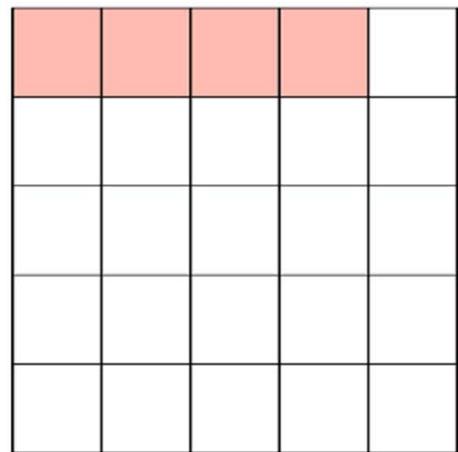
etc.

برای یک پنجره‌ی  $3 \times 3$ ، یک سطر به بالا و پایین و یک ستون به چپ و راست اضافه می‌کنیم.

برای یک پنجره‌ی  $5 \times 5$ ، دو سطر به بالا و پایین و دو ستون به چپ و راست اضافه می‌کنیم.



Stride 1 with Padding



Feature Map

## عمل کانولوشن

پدگذاری

### PADDING

در لایه‌های Conv2D در Keras پدگذاری از طریق آرگومان padding پیکربندی می‌شود.

`padding = "valid"`

بدون پدگذاری  
( فقط استفاده از مکان‌های مجاز )  
( مقدار پیش‌فرض )

`padding = "same"`

پدگذاری به‌گونه‌ای که  
عرض و ارتفاع خروجی مشابه  
عرض و ارتفاع ورودی باشد .

## عمل کانولوشن

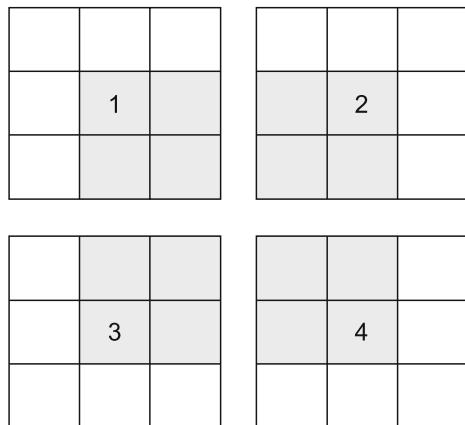
### اندازه قدم‌های کانولوشن

#### CONVOLUTION STRIDES

خانه‌های مرکزی پنجره‌های کانولوشن می‌توانند مجاور نباشند و اندازه‌ی قدم به جای ۱ می‌تواند بزرگ‌تر باشد.

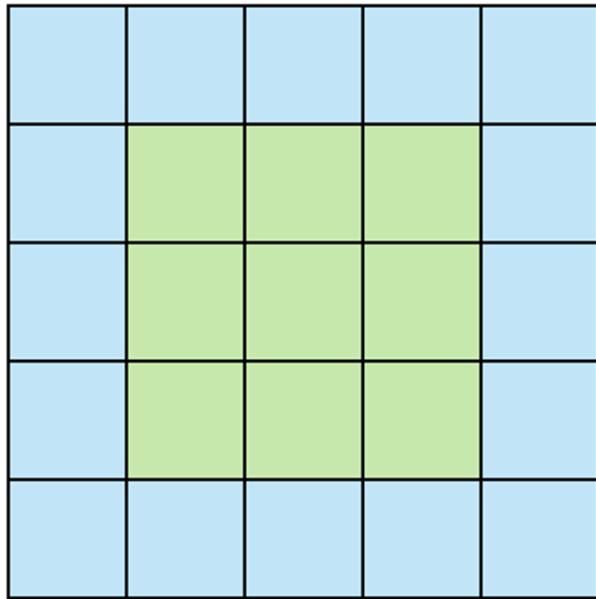
پنج‌های  
کانولوشنی  
 $3 \times 3$   
با اندازه قدم‌های  
 $2 \times 2$

	1		2	
	3		4	

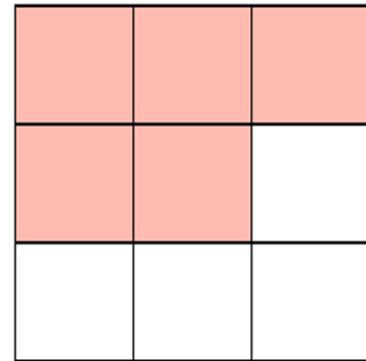


استفاده از اندازه قدم ۲ به معنی این است که عرض و ارتفاع نقشه‌ی ویژگی با فاکتور ۲ زیرنمونه‌برداری می‌شود.

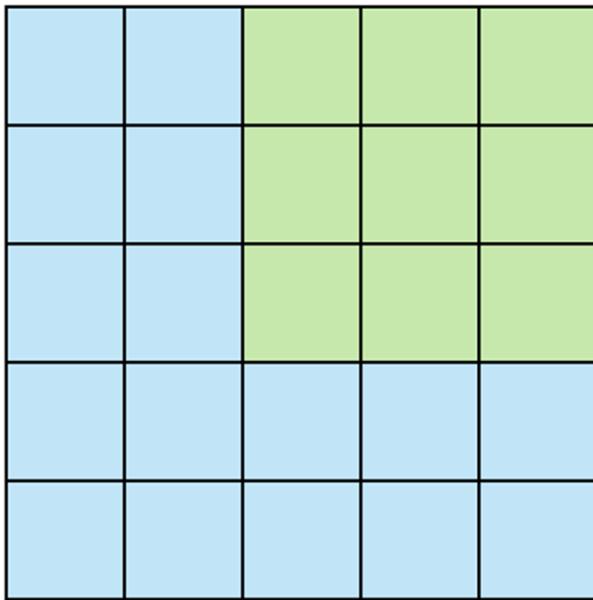
در عمل به ندرت از کانولوشن‌های strided استفاده می‌شود. برای زیرنمونه‌برداری نقشه‌های ویژگی معموماً از عملیات pooling استفاده می‌شود.



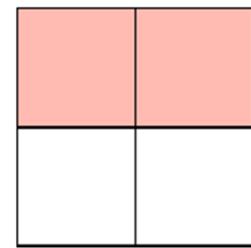
Stride 1



Feature Map



Stride 2



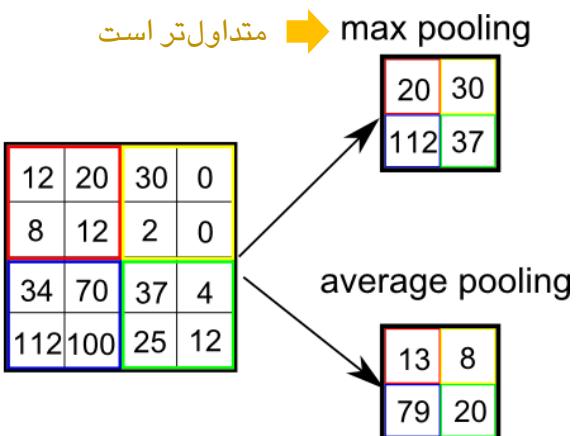
Feature Map

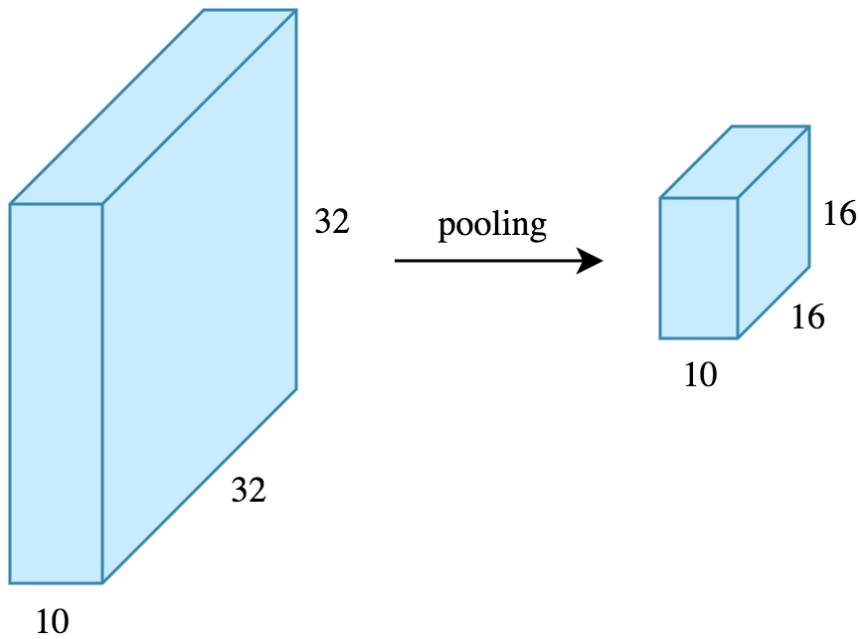
## عمل تلفیق

### POOLING OPERATION

عمل تلفیق از نظر مفهومی شبیه کانولوشن است، با این تفاوت که به جای یک تبدیل خطی یادگرفته شده بر روی بچهای محلی (هسته‌ی کانولوشن) تبدیل از طریق یک عملیات تانسوری ثابت (مثل ماکزیمم یا میانگین یا ...) انجام می‌شود.

همچنین تلفیق معمولاً با پنجرهای  $2 \times 2$  با اندازه قدم‌های ۲ انجام می‌شود  
 ⇐ موجب زیرنمونه‌برداری نقشه‌ی ویژگی با فاکتور ۲ می‌شود.





## عمل تلفیق

مثالی از یک شبکه‌ی کانولوشنال بدون استفاده از تلفیق

### POOLING OPERATION

اگر از عمل pooling در مدل استفاده نکنیم:

```
model_no_max_pool = models.Sequential()
model_no_max_pool.add(layers.Conv2D(32, (3, 3), activation='relu',
                                    input_shape=(28, 28, 1)))
model_no_max_pool.add(layers.Conv2D(64, (3, 3), activation='relu'))
model_no_max_pool.add(layers.Conv2D(64, (3, 3), activation='relu'))
```

```
>>> model_no_max_pool.summary()
```

Layer (type)	Output Shape	Param #
conv2d_4 (Conv2D)	(None, 26, 26, 32)	320
conv2d_5 (Conv2D)	(None, 24, 24, 64)	18496
conv2d_6 (Conv2D)	(None, 22, 22, 64)	36928
=====		
Total params: 55,744		
Trainable params: 55,744		
Non-trainable params: 0		

## عمل تلفیق

### POOLING OPERATION

اگر از  
تلفیق  
استفاده  
نکنیم

- فرآیند به سمت یادگیری سلسله مراتب فضایی ویژگی ها هدایت نمی شود.  
    <=> پنجره های لایه های بعدی، حاوی همان اطلاعات پنجره های لایه های قبل خواهند بود.
- نقشه هی ویژگی نهایی تعداد پارامتر های بسیار زیادی برای هر نمونه خواهد داشت.  
    <=> مشکل بیش برازش

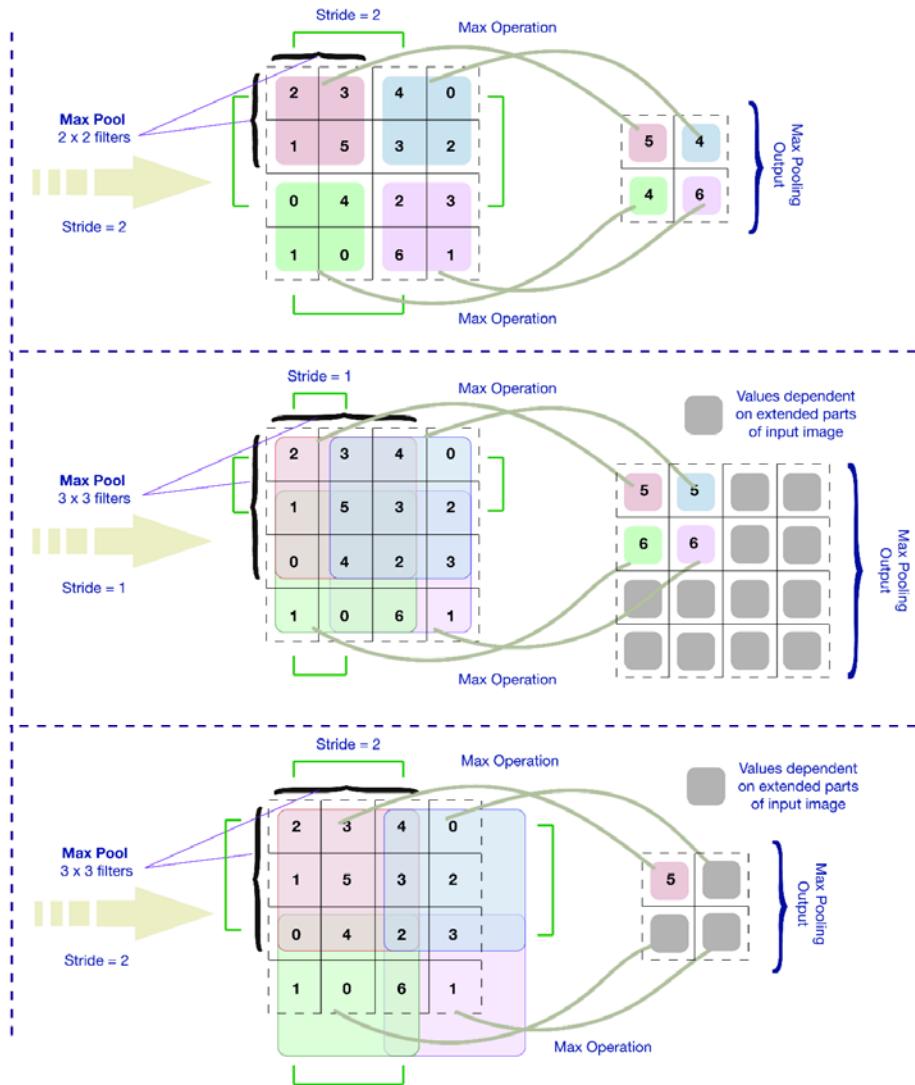
هدف از زیر نمونه برداری (downsampling)، کاهش تعداد ضرایب نقشه هی ویژگی برای پردازش است، و همچنین، القای سلسله مراتب های فیلتر فضایی با ایجاد لایه های کانولوشن متوالی.

عملکرد max-pooling از average-pooling در عمل بهتر است:

ویژگی ها متمایل هستند حضور فضایی برخی الگوها یا مفاهیم را بر روی کاشی های مختلف نقشه هی ویژگی کدگذاری کنند، و نگاه کردن به حضور ماقزیم ویژگی های مختلف نسبت به حضور میانگین آنها حاوی اطلاعات بیشتری است.

An example Image Portion  
for Max Pooling  
Numbers represent  
the pixel values

2	3	4	0
1	5	3	2
0	4	2	3
1	0	6	1



یادگیری عمیق برای بینایی کامپیووتری

۲

آموزش یک  
convnet  
از صفر  
بر روی یک  
مجموعه داده  
کوچک

## دورنما

استفاده از شبکه‌های عصبی کانولوشنال برای مسئله‌ی طبقه‌بندی تصاویر

### مسئله‌ی طبقه‌بندی تصویر سگ/گربه

مجموعه‌داده حاوی ۴۰۰۰ تصویر (۲۰۰۰ گربه، ۲۰۰۰ سگ)

مجموعه‌ی آزمایشی

Test Set

۱۰۰۰ تصویر

مجموعه‌ی اعتبارسنجی

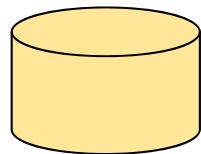
Validation Set

۱۰۰۰ تصویر

مجموعه‌ی آموزشی

Training Set

۲۰۰۰ تصویر



مشکل اصلی:  
بیش‌برازش

دقت طبقه‌بندی  
accuracy = 71%

آموزش مدل از صفر (بدون رگولاریزاسیون)  
*Training a Model from Scratch*



دقت طبقه‌بندی  
accuracy = 82%

استفاده از داده افزایی  
*Data Augmentation*



دقت طبقه‌بندی  
accuracy = 90 ~ 96%

استخراج ویژگی با شبکه‌ی پیش‌آموزش دیده  
*Feature Extraction with a Pretrained Network*



دقت طبقه‌بندی  
accuracy = 97%

تنظیم دقیق یک شبکه‌ی پیش‌آموزش دیده  
*Fine-Tuning a Pretrained Network*



## آموزش یک convnet از صفر بر روی یک مجموعه داده کوچک

### TRAINING A CONVNET FROM SCRATCH ON A SMALL DATASET

مجموعه داده‌ی کوچک می‌تواند حاوی چند صد تا ده‌ها هزار نمونه باشد.

یادگیری عمیق، معمولاً تنها زمانی کار می‌کند که مقدار زیادی داده وجود داشته باشد.  
چون یافتن ویژگی‌های مفید در داده‌های آموزشی بدون مهندسی ویژگی دستی زمانی محقق می‌شود که  
حجم زیادی نمونه‌ی آموزشی وجود داشته باشد.

این موضوع صحیح است به خصوص زمانی که نمونه‌های ورودی دارای ابعاد بسیار بالا باشند (مانند تصویر).

تعداد زیاد نمونه‌ها نسبی است  
و وابسته به اندازه و عمق شبکه‌ای است که می‌خواهیم آن را آموزش بدهیم.

از آنجا که شبکه‌های عصبی کانولوشنال  
ویژگی‌های محلی تغییرناپذیر تحت جایه‌جایی را یاد می‌گیرند،  
برای مسائل ادراکی بسیار کارآمد هستند.

آموزش یک شبکه‌ی عصبی کانولوشنال از صفر بر روی یک مجموعه داده‌ی بسیار کوچک،  
بدون نیاز به هرگونه مهندسی ویژگی سفارشی،  
با وجود کم بودن نسبی داده‌ها، هنوز می‌تواند نتایج معقولی تولید کند.

## قابلیت تغییر منظور در یادگیری عمیق

### REPURPOSABILITY

مدل‌های یادگیری عمیق، به طور ذاتی بسیار قابلیت تغییر منظور دارند.

مثلًاً می‌توان یک مدل طبقه‌بندی تصویر یا تبدیل گفتار به متن  
که بر روی یک مجموعه داده‌ی بزرگ-مقیاس آموزش داده شده است را گرفت  
و تنها با ایجاد کمی تغییر در آن،  
از آن در مسئله‌ی بسیار متفاوتی استفاده‌ی مجدد (reuse) کرد.

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

DOGS VS. CAT IMAGE CLASSIFICATION

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

مجموعه‌داده

### DOGS VS. CAT IMAGE CLASSIFICATION

نمونه‌هایی از مجموعه‌داده:  
نمونه‌ها از نظر اندازه، ظاهر  
و ... ناهمگن هستند.

تصاویر با رزولوشن متوسط  
با فرمت JPEG هستند.



You can download the original dataset from [www.kaggle.com/c/dogs-vs-cats/data](http://www.kaggle.com/c/dogs-vs-cats/data)

مجموعه‌داده حاوی ۲۵۰۰۰ تصویر (۱۲۵۰۰ گربه، ۱۲۵۰۰ سگ)

ایجاد یک مجموعه‌داده‌ی جدید از این مجموعه با سه زیرمجموعه:

مجموعه‌ی آزمایشی  
*Test Set*

۱۰۰۰ تصویر  
(۵۰ تا از هر کلاس)

مجموعه‌ی اعتبارسنجی  
*Validation Set*

۱۰۰۰ تصویر  
(۵۰ تا از هر کلاس)

مجموعه‌ی آموزشی  
*Training Set*

۲۰۰۰ تصویر  
(۱۰۰ تا از هر کلاس)

543 MB  
compressed

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

ایجاد کپی از تصاویر برای پوشش‌های آموزش، اعتبارسنجی و آزمایش (۱ از ۴)

### Copying images to training, validation, and test directories

```
import os, shutil
```

```
original_dataset_dir = '/Users/fchollet/Downloads/kaggle_original_data'
```

Path to the directory where the original dataset was uncompressed

```
base_dir = '/Users/fchollet/Downloads/cats_and_dogs_small'  
os.mkdir(base_dir)
```

Directory where you'll store your smaller dataset

```
train_dir = os.path.join(base_dir, 'train')  
os.mkdir(train_dir)  
validation_dir = os.path.join(base_dir, 'validation')  
os.mkdir(validation_dir)  
test_dir = os.path.join(base_dir, 'test')
```

Directories for the training, validation, and test splits

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

ایجاد کپی از تصاویر برای پوشش‌های آموزش، اعتبارسنجی و آزمایش (۲ از ۴)

```
train_cats_dir = os.path.join(train_dir, 'cats')
os.mkdir(train_cats_dir)
```

Directory with  
training cat pictures

```
train_dogs_dir = os.path.join(train_dir, 'dogs')
os.mkdir(train_dogs_dir)
```

Directory with  
training dog pictures

```
validation_cats_dir = os.path.join(validation_dir, 'cats')
os.mkdir(validation_cats_dir)
```

Directory with  
validation cat pics

```
validation_dogs_dir = os.path.join(validation_dir, 'dogs')
os.mkdir(validation_dogs_dir)
```

Directory with  
validation dog pics

```
test_cats_dir = os.path.join(test_dir, 'cats')
os.mkdir(test_cats_dir)
```

Directory with  
test cat pictures

```
test_dogs_dir = os.path.join(test_dir, 'dogs')
os.mkdir(test_dogs_dir)
```

Directory with  
test dog pictures

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

ایجاد کپی از تصاویر برای پوشه‌های آموزش، اعتبارسنجی و آزمایش (۳ از ۴)

```
fnames = ['cat.{}.jpg'.format(i) for i in range(1000)]
for fname in fnames:
    src = os.path.join(original_dataset_dir, fname)
    dst = os.path.join(train_cats_dir, fname)
    shutil.copyfile(src, dst)
```

Copies the first  
1,000 cat images  
to train\_cats\_dir

```
fnames = ['cat.{}.jpg'.format(i) for i in range(1000, 1500)]
for fname in fnames:
    src = os.path.join(original_dataset_dir, fname)
    dst = os.path.join(validation_cats_dir, fname)
    shutil.copyfile(src, dst)
```

Copies the next 500  
cat images to  
validation\_cats\_dir

```
fnames = ['cat.{}.jpg'.format(i) for i in range(1500, 2000)]
for fname in fnames:
    src = os.path.join(original_dataset_dir, fname)
    dst = os.path.join(test_cats_dir, fname)
    shutil.copyfile(src, dst)
```

Copies the next 500  
cat images to  
test\_cats\_dir



## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

ایجاد کپی از تصاویر برای پوشه‌های آموزش، اعتبارسنجی و آزمایش (۴ از ۴)

```
fnames = ['dog.{}.jpg'.format(i) for i in range(1000)]
for fname in fnames:
    src = os.path.join(original_dataset_dir, fname)
    dst = os.path.join(train_dogs_dir, fname)
    shutil.copyfile(src, dst)
```

Copies the first  
1,000 dog images  
to train\_dogs\_dir

```
fnames = ['dog.{}.jpg'.format(i) for i in range(1000, 1500)]
for fname in fnames:
    src = os.path.join(original_dataset_dir, fname)
    dst = os.path.join(validation_dogs_dir, fname)
    shutil.copyfile(src, dst)
```

Copies the next 500  
dog images to  
validation\_dogs\_dir

```
fnames = ['dog.{}.jpg'.format(i) for i in range(1500, 2000)]
for fname in fnames:
    src = os.path.join(original_dataset_dir, fname)
    dst = os.path.join(test_dogs_dir, fname)
    shutil.copyfile(src, dst)
```

Copies the next 500  
dog images to  
test\_dogs\_dir



## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

بررسی تعداد تصاویر هر کلاس در هر یک از مجموعه‌های آموزش، اعتبارسنجی و آزمایش

```
>>> print('total training cat images:', len(os.listdir(train_cats_dir)))
total training cat images: 1000
>>> print('total training dog images:', len(os.listdir(train_dogs_dir)))
total training dog images: 1000
>>> print('total validation cat images:', len(os.listdir(validation_cats_dir)))
total validation cat images: 500
>>> print('total validation dog images:', len(os.listdir(validation_dogs_dir)))
total validation dog images: 500
>>> print('total test cat images:', len(os.listdir(test_cats_dir)))
total test cat images: 500
>>> print('total test dog images:', len(os.listdir(test_dogs_dir)))
total test dog images: 500
```

چون تعداد نمونه‌ها از هر کلاس مساوی است،  
یک مسئله‌ی طبقه‌بندی دودویی متوازن (balanced binary classification) داریم  
و معیار موفقیت مناسب، دقت (accuracy) است.

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

### ساخت شبکه

#### BUILDING THE NETWORK

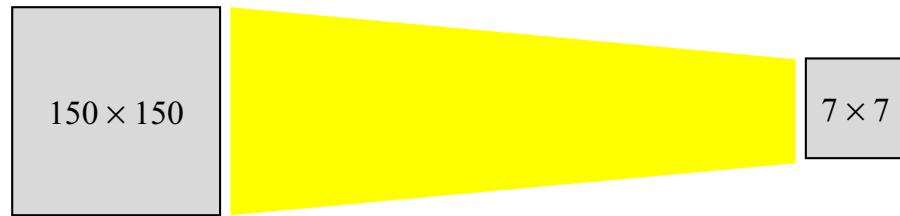
یک convnet را به صورت پشت‌های متناوب Conv2D (با تابع فعالیت relu) و MaxPooling2D می‌سازیم.

چون با تصاویر بزرگتری نسبت به MNIST سروکار داریم و مسئله پیچیده‌تر است،

باید شبکه‌ی بزرگتری ایجاد کنیم: تعداد مراحل conv + pool بیشتر؛

این کار موجب (۱) افزایش ظرفیت شبکه

و (۲) کاهش کافی اندازه‌ی نقشه‌های ویژگی تا رسیدن به لایه‌ی تخت‌سازی (Flatten) می‌شود.



چون با یک مسئله‌ی طبقه‌بندی دودویی سروکار داریم،  
در نهایت یک لایه‌ی Dense با یک واحد با تابع فعالیت sigmoid خواهیم داشت.

## شبکه‌های عصبی کانولوشنال

الگوی افزایش تدریجی عمق نقشه‌های ویژگی همزمان با کاهش اندازه‌ی آنها

در اکثر شبکه‌های عصبی کانولوشنال  
عمق نقشه‌های ویژگی در شبکه به تدریج افزایش می‌یابد،  
در حالی‌که اندازه‌ی نقشه‌های ویژگی به تدریج کاهش می‌یابد.

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

ساخت شبکه

### Instantiating a small convnet for dogs vs. cats classification

```
from keras import layers
from keras import models

model = models.Sequential()
model.add(layers.Conv2D(32, (3, 3), activation='relu',
                      input_shape=(150, 150, 3)))
model.add(layers.MaxPooling2D((2, 2)))
model.add(layers.Conv2D(64, (3, 3), activation='relu'))
model.add(layers.MaxPooling2D((2, 2)))
model.add(layers.Conv2D(128, (3, 3), activation='relu'))
model.add(layers.MaxPooling2D((2, 2)))
model.add(layers.Conv2D(128, (3, 3), activation='relu'))
model.add(layers.MaxPooling2D((2, 2)))
model.add(layers.Flatten())
model.add(layers.Dense(512, activation='relu'))
model.add(layers.Dense(1, activation='sigmoid'))
```

چون با یک مسئله‌ی طبقه‌بندی دودویی سروکار داریم، در نهایت یک لایه‌ی Dense با یک واحد با تابع فعالیت sigmoid خواهیم داشت. خروجی احتمال تعلق آنچه شبکه می‌بیند به یکی از کلاس‌ها را کدگذاری می‌کند.



## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

مشاهده‌ی تغییر ابعاد نقشه‌های ویژگی طی لایه‌های متوالی

```
>>> model.summary()
Layer (type)                  Output Shape                 Param #
=====
conv2d_1 (Conv2D)              (None, 148, 148, 32)    896
maxpooling2d_1 (MaxPooling2D)  (None, 74, 74, 32)      0
conv2d_2 (Conv2D)              (None, 72, 72, 64)      18496
maxpooling2d_2 (MaxPooling2D)  (None, 36, 36, 64)      0
conv2d_3 (Conv2D)              (None, 34, 34, 128)     73856
maxpooling2d_3 (MaxPooling2D)  (None, 17, 17, 128)     0
conv2d_4 (Conv2D)              (None, 15, 15, 128)     147584
maxpooling2d_4 (MaxPooling2D)  (None, 7, 7, 128)       0
flatten_1 (Flatten)            (None, 6272)             0
dense_1 (Dense)               (None, 512)              3211776
dense_2 (Dense)               (None, 1)                513
=====
Total params: 3,453,121
Trainable params: 3,453,121
Non-trainable params: 0
```

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

پیکربندی مدل برای آموزش

### Configuring the model for training

```
from keras import optimizers  
  
model.compile(loss='binary_crossentropy',  
              optimizer=optimizers.RMSprop(lr=1e-4),  
              metrics=['acc'])
```

چون از تابع فعالیت sigmoid در لایه‌ی آخر استفاده کردید،  
از تابع اتلاف binary cross entropy استفاده می‌کنیم.

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

پیش‌پردازش داده‌ها

### DATA PREPROCESSING

داده‌ها باید در قالب تانسورهای ممیزشناور پیش‌پردازش شده‌ی مناسب قرار بگیرند.

مراحل کار:

- 1) Read the picture files.
- 2) Decode the JPEG content to RGB grids of pixels.
- 3) Convert these into floating-point tensors.
- 4) Rescale the pixel values (between 0 and 255) to the [0, 1] interval  
(as you know, neural networks prefer to deal with small input values).

در Keras ماثولی برای پردازش تصویر وجود دارد که کارهای فوق را انجام می‌دهد:  
`keras.preprocessing.image`

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

پیش‌پردازش داده‌ها: استفاده از کتابخانه‌ی موجود در کراس برای خواندن تصاویر

### Using `ImageDataGenerator` to read images from directories

```
from keras.preprocessing.image import ImageDataGenerator

train_datagen = ImageDataGenerator(rescale=1./255)
test_datagen = ImageDataGenerator(rescale=1./255) Rescales all images  
by 1/255

train_generator = train_datagen.flow_from_directory(
    train_dir, # Target directory
    target_size=(150, 150) # Resizes all images to 150 × 150
    batch_size=20,
    class_mode='binary') # Because you use binary_crossentropy loss,  
# you need binary labels

validation_generator = test_datagen.flow_from_directory(
    validation_dir,
    target_size=(150, 150),
    batch_size=20,
    class_mode='binary')
```

## Understanding Python generators

A *Python generator* is an object that acts as an iterator: it's an object you can use with the `for ... in` operator. Generators are built using the `yield` operator.

Here is an example of a generator that yields integers:

```
def generator():
    i = 0
    while True:
        i += 1
        yield i

for item in generator():
    print(item)
    if item > 4:
        break
```

It prints this:

```
1
2
3
4
5
```

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

پیش‌پردازش داده‌ها: عملکرد مولد تصاویر

عملکرد هر یک از مولدات:

ایجاد دسته‌هایی حاوی ۲۰ نمونه از تصاویر RGB با ابعاد  $150 \times 150 \times 3$  (شکل: (20, 150, 150, 3)) و برچسب‌های دودویی (شکل: (20, 2))

```
>>> for data_batch, labels_batch in train_generator:  
>>> print('data batch shape:', data_batch.shape)  
>>> print('labels batch shape:', labels_batch.shape)  
>>> break  
data batch shape: (20, 150, 150, 3)  
labels batch shape: (20,)
```

چون مولد دسته‌ها (batches) را به صورت نامتناهی تولید می‌کند، به صورت بی‌پایان روی پوششی مقصد، حلقه می‌زند.  
برای همین باید حلقه‌ی تکرار را در نقطه‌ای شکست (break).

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

برازش مدل با استفاده از یک مولد دسته‌ای

حال نوبت برازش مدل با استفاده از داده‌های تولید شده توسط مدل است.

برای این کار از متدهای **fit\_generator** (معادل **fit** برای مولد داده) می‌کنیم.

آرگومان اول آن، یک مولد Python است (که یک دسته از ورودی‌ها و تارگت‌ها را به صورت نامحدود تولید می‌کند).

آرگومان دوم آن، تعداد نمونه‌هایی که باید از مولد استخراج شود را مشخص می‌کند.

In this case, batches are 20 samples, so it will take 100 batches until you see your target of 2,000 samples.

### Fitting the model using a batch generator

```
history = model.fit_generator(  
    train_generator,  
    steps_per_epoch=100,  
    epochs=30,  
    validation_data=validation_generator,  
    validation_steps=50)
```

### Saving the model

```
model.save('cats_and_dogs_small_1.h5')
```



## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

نمایش منحنی‌های اتلاف و دقت در حین آموزش

### Displaying curves of loss and accuracy during training

```
import matplotlib.pyplot as plt

acc = history.history['acc']
val_acc = history.history['val_acc']
loss = history.history['loss']
val_loss = history.history['val_loss']

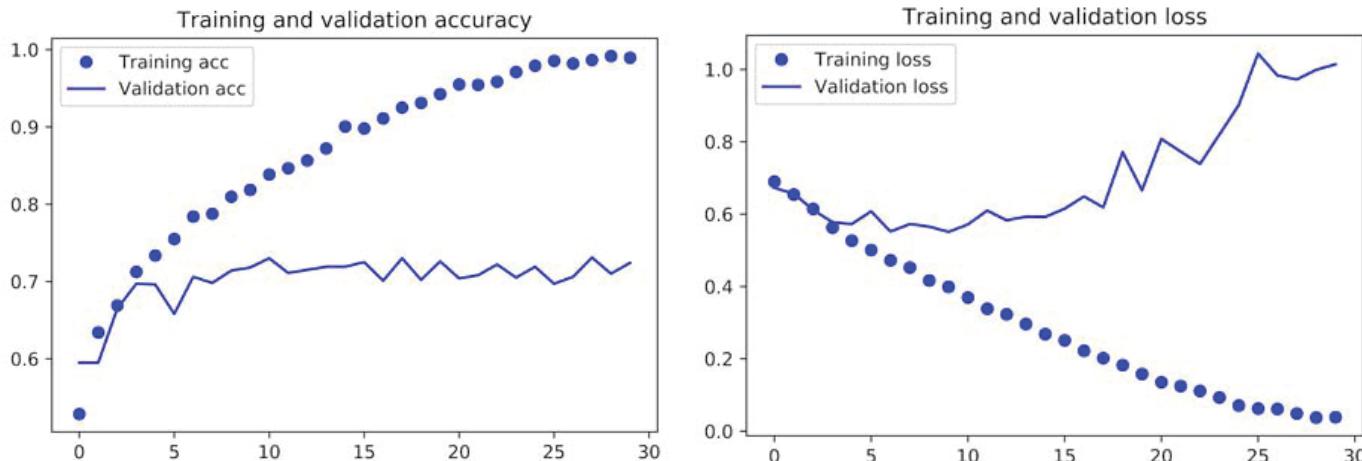
epochs = range(1, len(acc) + 1)

plt.plot(epochs, acc, 'bo', label='Training acc')
plt.plot(epochs, val_acc, 'b', label='Validation acc')
plt.title('Training and validation accuracy')
plt.legend()

plt.figure()
plt.plot(epochs, loss, 'bo', label='Training loss')
plt.plot(epochs, val_loss, 'b', label='Validation loss')
plt.title('Training and validation loss')
plt.legend()
plt.show()
```

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

نمودارهای اتلاف و دقت روی داده‌های آموزشی و اعتبارسنجی



هر دو نمودار، مشخصه‌ی بیش‌برازش هستند.

دقت روی داده‌های آموزشی به صورت خطی در طول زمان افزایش می‌یابد تا به نزدیک ۱۰۰٪ می‌رسد،  
اما دقت روی داده‌های اعتبارسنجی در حد ۷۲٪ می‌ماند.

اتلاف روی داده‌های اعتبارسنجی پس از ۵ اپک به نیم خود می‌رسد و ثابت می‌ماند،  
اما اتلاف روی داده‌های آموزشی به صورت خطی کاهش می‌یابد تا به نزدیک صفر می‌رسد.

با توجه به کم بودن نسبی نمونه‌های آموزشی، بیش‌برازش مهم‌ترین نگرانی ماست.

## استفاده از داده‌افزایی

### USING DATA AUGMENTATION

بیش‌برازش، در اثر بسیار کم بودن نمونه‌های یادگیری اتفاق می‌افتد؛ و باعث می‌شود نتوانیم مدلی را آموزش بدهیم که بتواند به داده‌های جدید تعمیم پیدا کند.

اگر بی‌نهایت داده داشته باشیم،  
مدل ما در معرض همهٔ جنبه‌های توزیع داده‌های موجود قرار می‌گیرد و هرگز بیش‌برازش نمی‌کند.

تولید داده‌های بیشتر از روی داده‌های آموزشی موجود،  
با افزودن نمونه‌ها از طریق چند تبدیل تصادفی که به نمونه‌های باورپذیر منجر شود.

**داده‌افزایی**  
*Data Augmentation*

هدف این است که:  
در زمان آموزش، مدل ما هرگز یک تصویر (دقیقاً ثابت) را دو مرتبه مشاهده نکند.  
این کمک می‌کند که مدل ما در معرض جنبه‌های بیشتری از داده‌ها قرار بگیرد و بهتر تعمیم بدهد.

داده‌افزایی، یک روش خاص بینایی کامپیوتری برای مقابله با بیش‌برازش در هنگام پردازش تصاویر با مدل‌های یادگیری عمیق است که تقریباً همیشه استفاده می‌شود.



## استفاده از داده‌افزایی

در پردازش تصویر

### Setting up a data augmentation configuration via `ImageDataGenerator`

```
datagen = ImageDataGenerator(  
    rotation_range=40,  
    width_shift_range=0.2,  
    height_shift_range=0.2,  
    shear_range=0.2,  
    zoom_range=0.2,  
    horizontal_flip=True,  
    fill_mode='nearest')
```

در Keras می‌توان تعدادی تبدیل تصادفی را برای اعمال روی تصاویر پیکربندی کرد:  
`ImageDataGenerator` instance با استفاده از

- `rotation_range` is a value in degrees (0–180), a range within which to randomly rotate pictures.
- `width_shift` and `height_shift` are ranges (as a fraction of total width or height) within which to randomly translate pictures vertically or horizontally.
- `shear_range` is for randomly applying shearing transformations.
- `zoom_range` is for randomly zooming inside pictures.
- `horizontal_flip` is for randomly flipping half the images horizontally—relevant when there are no assumptions of horizontal asymmetry (for example, real-world pictures).
- `fill_mode` is the strategy used for filling in newly created pixels, which can appear after a rotation or a width/height shift.



## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

استفاده از داده‌افزایی: نمایش چند تصویر آموزشی افزوده شده تصادفی

### Displaying some randomly augmented training images

```
from keras.preprocessing import image
fnames = [os.path.join(train_cats_dir, fname) for
          fname in os.listdir(train_cats_dir)]
img_path = fnames[3]
img = image.load_img(img_path, target_size=(150, 150))
x = image.img_to_array(img)
x = x.reshape((1,) + x.shape)

i = 0
for batch in datagen.flow(x, batch_size=1):
    plt.figure(i)
    imgplot = plt.imshow(image.array_to_img(batch[0]))
    i += 1
    if i % 4 == 0:
        break
plt.show()
```

Module with image preprocessing utilities

Chooses one image to augment

Reads the image and resizes it

Generates batches of randomly transformed images.  
Loops indefinitely, so you need to break the loop at some point!

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

استفاده از داده‌افزایی: نمایش چند تصویر آموزشی افزوده شده تصادفی



## استفاده از دیگر تکنیک‌های رگولاریزاسیون در کنار داده‌افزایی

اگر یک شبکه‌ی جدید را با استفاده از داده‌افزایی آموزش بدهیم،  
شبکه هرگز دو ورودی یکسان را نخواهد دید.  
اما

ورودی‌هایی که شبکه می‌بیند، **دارای همبستگی شدیدی میان یکدیگر** هستند.  
زیرا داده‌ها از تعداد اندکی از داده‌های اصلی آمده‌اند  
(اطلاعات جدیدی تولید نشده است، بلکه تنها اطلاعات موجود مجدداً مخلوط شده‌اند)



برای رهایی از بیش‌برازش، ممکن است داده‌افزایی کافی نباشد.

پس برای مقابله‌ی بیشتر با بیش‌برازش، باید از دیگر روش‌های رگولاریزاسیون نیز استفاده کنیم.  
(مثلًاً یک لایه‌ی Dropout دقیقاً قبل از طبقه‌بندی‌کننده‌ی متصل متر acum قرار می‌دهیم.)

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

تعریف یک شبکه‌ی عصبی کانولوشنال جدید که شامل dropout است

### Defining a new convnet that includes dropout

```
model = models.Sequential()
model.add(layers.Conv2D(32, (3, 3), activation='relu',
                      input_shape=(150, 150, 3)))
model.add(layers.MaxPooling2D((2, 2)))
model.add(layers.Conv2D(64, (3, 3), activation='relu'))
model.add(layers.MaxPooling2D((2, 2)))
model.add(layers.Conv2D(128, (3, 3), activation='relu'))
model.add(layers.MaxPooling2D((2, 2)))
model.add(layers.Conv2D(128, (3, 3), activation='relu'))
model.add(layers.MaxPooling2D((2, 2)))
model.add(layers.Flatten())
model.add(layers.Dropout(0.5))
model.add(layers.Dense(512, activation='relu'))
model.add(layers.Dense(1, activation='sigmoid'))

model.compile(loss='binary_crossentropy',
              optimizer=optimizers.RMSprop(lr=1e-4),
              metrics=['acc'])
```

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

آموزش یک شبکه‌ی عصبی کانولوشنال با استفاده از مولدهای داده‌افزایی (۱ از ۲)

شبکه‌ای را آموزش می‌دهیم که از داده‌افزایی و dropout استفاده می‌کند:

### Training the convnet using data-augmentation generators

```
train_datagen = ImageDataGenerator(  
    rescale=1./255,  
    rotation_range=40,  
    width_shift_range=0.2,  
    height_shift_range=0.2,  
    shear_range=0.2,  
    zoom_range=0.2,  
    horizontal_flip=True,)  
  
test_datagen = ImageDataGenerator(rescale=1./255)  
  
train_generator = train_datagen.flow_from_directory(  
    train_dir,    # Target directory  
    target_size=(150, 150),  # Resizes all images to 150 × 150  
    batch_size=32,  
    class_mode='binary')
```

Note that the validation data shouldn't be augmented!

Because you use binary\_crossentropy loss, you need binary labels.

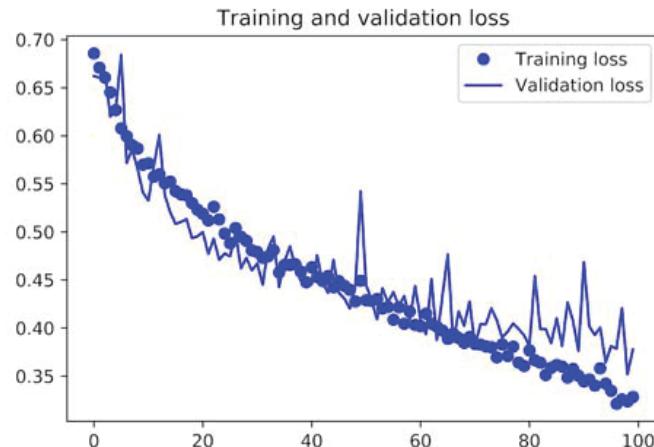
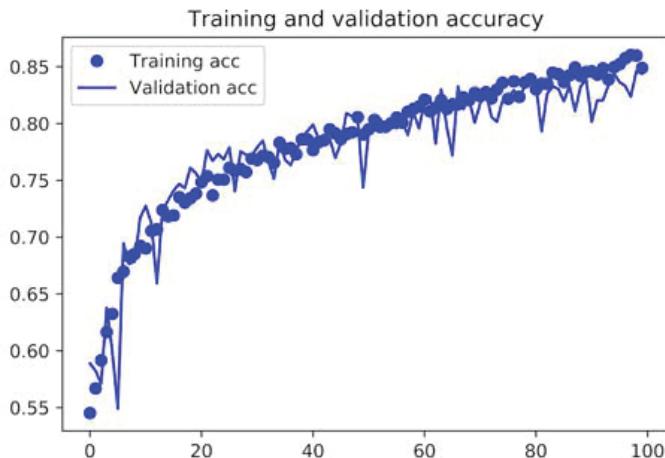
## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

آموزش یک شبکه‌ی عصبی کانولوشنال با استفاده از مولدهای داده‌افزایی (۲ از ۲)

```
validation_generator = test_datagen.flow_from_directory(  
    validation_dir,  
    target_size=(150, 150),  
    batch_size=32,  
    class_mode='binary')  
  
history = model.fit_generator(  
    train_generator,  
    steps_per_epoch=100,  
    epochs=100,  
    validation_data=validation_generator,  
    validation_steps=50)  
  
model.save('cats_and_dogs_small_2.h5') # Saving the model
```

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

نمودارهای اتلاف و دقت روی داده‌های آموزشی و اعتبارسنجی (با داده‌افزایی)



در اثر داده‌افزایی و dropout دیگر بیش‌برازش وجود ندارد.  
منحنی‌های آموزش به‌طور نزدیکی منحنی‌های اعتبارسنجی را دنبال می‌کنند.

در اینجا به دقت %۸۲ رسیده‌ایم.  
(حدود %۱۵ بهبود نسبت به مدل رگولاریزه نشده)

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

بهبود نتایج با استفاده از سایر تکنیک‌های رگولاریزاسیون

با استفاده‌ی بیشتر از تکنیک‌های رگولاریزاسیون،  
و با تنظیم پارامترهای شبکه  
(مانند تعداد فیلترها در هر لایه‌ی کانولوشن، تعداد لایه‌ها در شبکه و ...)  
ممکن است بتوانیم به دقت‌های بهتر در حد ۸۶٪ یا ۸۷٪ برسیم.

اما

از آنجا که داده‌ها بسیار کم هستند، با آموزش شبکه از صفر، دقت بالاتری حاصل نمی‌شود.

یادگیری عمیق برای بینایی کامپیوتری

۳

# استفاده از یک convnet پیشآموزش دیده

## استفاده از یک convnet پیشآموزش دیده

یادگیری انتقالی با CNN

### USING A PRETRAINED CONVNET (TRANSFER LEARNING WITH CNN)

یک روی کرد معمول و بسیار مؤثر در یادگیری عمیق بر روی مجموعه داده های کوچک از تصاویر، استفاده از یک شبکه‌ی پیشآموزش دیده است.

یک شبکه‌ی پیشآموزش دیده،

یک شبکه‌ی ذخیره شده است که قبلاً بر روی یک مجموعه داده بزرگ آموزش دیده است.  
(معمولًاً بر روی وظیفه‌ی طبقه‌بندی تصاویر بزرگ-مقیاس)

اگر مجموعه داده اصلی به اندازه کافی بزرگ (large) و به اندازه کافی عمومی (general) باشد، آن‌گاه سلسله مراتب فضایی ویژگی‌های یادگرفته شده توسط آن شبکه‌ی پیشآموزش دیده، می‌تواند به طور مؤثری به عنوان یک مدل عام (generic) از دنیای بصری عمل کند.

==  
== ویژگی‌های آن می‌توانند برای مسائل متعدد و متفاوت بینایی کامپیوتری مفید باشد، حتی اگر کلاس‌های مسئله‌ی جدید کاملاً متفاوت با کلاس‌های وظیفه‌ی اصلی شبکه باشد.

برای مثال،

ممکن است یک شبکه را بر روی ImageNet آموزش دهیم (کلاس‌ها: عمدتاً حیوانات و اشیای روزمره)، و سپس از این شبکه برای منظور متفاوتی (مانند شناسایی مبلمان در تصاویر) استفاده کنیم.

این ویژگی «قابلیت حمل ویژگی‌های یادگیری شده بین مسائل مختلف» یکی از مزایای کلیدی یادگیری عمیق، در مقایسه با روی کردهای قدیمی‌تر کم‌عمق یادگیری است؛ و یادگیری عمیق را برای مسائل با داده‌های کوچک بسیار مؤثر می‌کند.

## مسئله‌ی طبقه‌بندی تصویر سگ / گربه

با استفاده از یک convnet پیش‌آموزش دیده

برای مسئله‌ی طبقه‌بندی تصویر سگ / گربه

یک convnet بزرگ را در نظر می‌گیریم که با مجموعه داده‌ی ImageNet آموزش یافته است:  
(۱,۴ میلیون تصویر برچسب‌دار با ۱۰۰۰ کلاس مختلف)

حاوی کلاس‌های مختلف از جمله گونه‌های مختلف گربه‌ها و سگ‌ها  $\Leftarrow$  انتظار داریم در این مسئله هم به خوبی عمل کند.

### VGG16

Karen Simonyan and Andrew Zisserman,  
“Very Deep Convolutional Networks for Large-Scale Image Recognition,”  
arXiv (2014), <https://arxiv.org/abs/1409.1556>.

## شبکه‌های عصبی کانولوشنال

روش‌های استفاده از یک مدل پیش‌آموزش دیده

استخراج ویژگی  
*Feature Extraction*

تنظیم دقیق  
*Fine-tuning*

۱

۲

روش‌های  
استفاده از  
یک مدل  
پیش‌آموزش دیده

## شبکه‌های عصبی کانولوشنال

روش‌های استفاده از یک مدل پیش‌آموزش دیده: استخراج ویژگی

### FEATURE EXTRACTION

استفاده از بازنمایی‌های یادگرفته شده توسط یک شبکه‌ی قبلی، برای استخراج ویژگی‌ها از نمونه‌های جدید

استخراج ویژگی  
*Feature Extraction*

۱

تنظیم دقیق  
*Fine-tuning*

۲

روش‌های  
استفاده از  
یک مدل  
پیش‌آموزش دیده

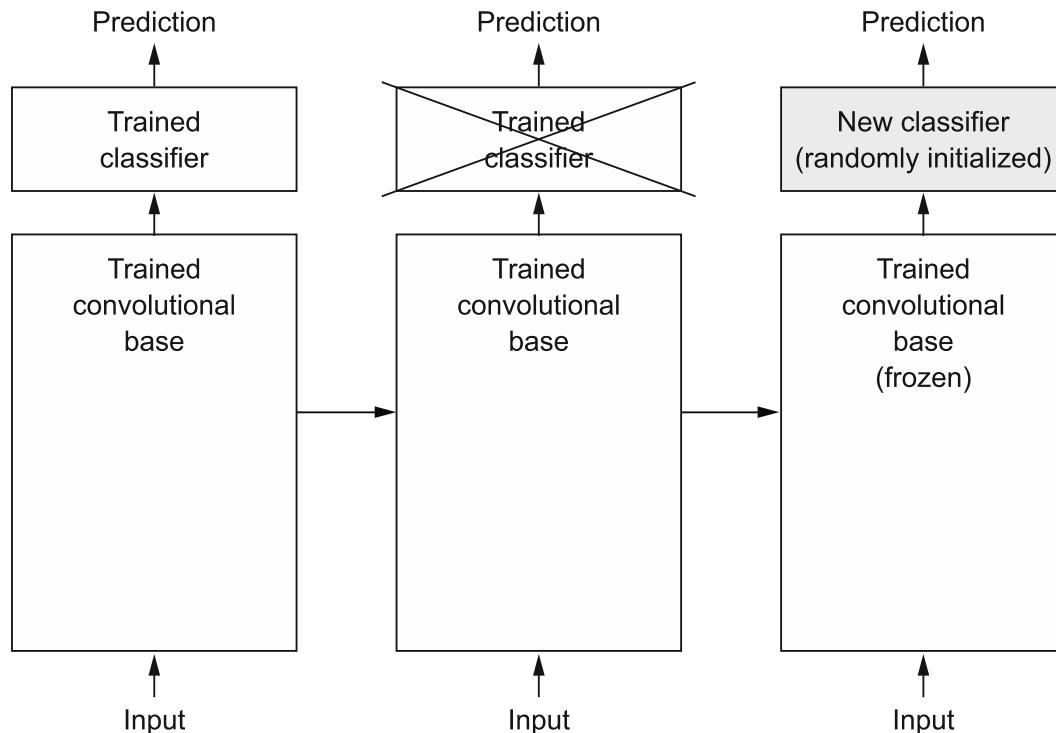
این ویژگی‌ها سپس به یک طبقه‌بندی‌کننده‌ی جدید که از صفر آموزش داده می‌شود، داده می‌شوند.

شروع با یک توالی از لایه‌های کانولوشنال و پولینگ (پایه‌ی کانولوشنال مدل: convolutional base) و پایان با یک طبقه‌بندی‌کننده‌ی متصل متراکم (convnet) می‌شود. از دو بخش تشکیل شده‌اند:

در استفاده از convnet‌ها، استخراج ویژگی با گرفتن پایه‌ی کانولوشنال از شبکه‌ی قبلی آموزش دیده، وارد کردن داده‌های جدید به آن، و آموزش یک طبقه‌بندی‌کننده‌ی جدید بر بالای خروجی آن انجام می‌شود.

## شبکه‌های عصبی کانولوشنال

روش‌های استفاده از یک مدل پیش‌آموزش دیده: استخراج ویژگی



## شبکه‌های عصبی کانولوشنال

روش‌های استفاده از یک مدل پیش‌آموزش دیده: استخراج ویژگی: دلایل استفاده از پایه‌ی کانولوشنال

چرا تنها پایه‌ی کانولوشنال را مورد استفاده‌ی مجدد قرار می‌دهیم؟  
آیا نمی‌توانیم طبقه‌بندی‌کننده‌ی متصل متراکم بالای آن را هم مورد استفاده‌ی مجدد قرار دهیم؟

در حالت کلی، از انجام چنین کاری اجتناب می‌کنیم.  
زیرا:

بازنمایی‌های یادگیری شده توسط پایه‌ی کانولوشنال احتمالاً **عامتر** هستند  
و بنابراین بیشتر قابل استفاده‌ی مجدد هستند.  
اما

بازنمایی‌های یادگیری شده توسط طبقه‌بندی‌کننده‌ی متصل متراکم لزوماً **خاص** مجموعه کلاس‌هایی هستند  
که مدل بر روی آنها آموزش دیده است.

همچنین بازنمایی‌های یافت شده در لایه‌های متصل متراکم،  
دیگر حاوی هیچ اطلاعاتی در مورد مکان قرارگیری اشیا در تصویر ورودی نیستند.

(لایه‌های تمام‌اً متصل از مفهوم فضارها می‌شوند، در حالی که مکان شیء همچنان توسط نقشه‌های ویژگی کانولوشنال توصیف می‌شوند.)

## شبکه‌های عصبی کانولوشنال

روش‌های استفاده از یک مدل پیش‌آموزش دیده: استخراج ویژگی: عمومیت ویژگی‌ها در پایه‌ی کانولوشنال

سطح عمومیت (و در نتیجه قابلیت استفاده‌ی مجدد) بازنمایی‌های استخراج شده  
توسط لایه‌های خاص کانولوشنال،  
وابسته به عمق لایه در آن مدل است.

لایه‌های اولیه‌ی مدل: استخراج نقشه‌های ویژگی محلی و شدیداً عمومی (لبه‌های دیداری، رنگ‌ها، بافت‌ها و ...)  
لایه‌های سطوح بالاتر: مفاهیم انتزاعی‌تر (چشم گربه، گوش سگ، ...)



اگر مجموعه‌داده‌ی جدید با مجموعه‌داده‌ی اصلی آموزش دیده تفاوت زیادی داشته باشد،  
ممکن است بهتر باشد به جای استفاده از کل پایه‌ی کانولوشنال،  
 تنها از چند لایه‌ی اول آن برای استخراج ویژگی استفاده کنیم.

## مسئله‌ی طبقه‌بندی تصویر سگ / گربه

استفاده از ویژگی‌های استخراج شده روی ImageNet

از آنجایی که کلاس‌های موجود در ImageNet حاوی چند کلاس سگ و گربه است، احتمالاً استفاده مجدد از اطلاعات موجود در لایه‌های متصل متراکم مدل اصلی سودمند خواهد بود، اما ما از آن استفاده نمی‌کنیم

تا حالت کلی تری را پوشش دهیم که در آن کلاس‌های مسئله‌ی جدید با کلاس‌های مدل اصلی همپوشانی ندارد.

برای پیاده‌سازی عملی، از پایه‌ی کانولوشنال شبکه‌ی **VGG16** استفاده می‌کنیم که روی ImageNet آموزش یافته است تا ویژگی‌های جالب از تصاویر سگ و گربه را استخراج کند. سپس یک طبقه‌بندی کننده‌ی Dogs vs. Cats را در بالای این ویژگی‌ها آموزش می‌دهیم.

نمونه مدل‌های پیش‌آموزش دیده روی ImageNet موجود در ماژول `keras.application`

Xception

Inception V3

ResNet50

**VGG16**

VGG19

MobileNet

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

استفاده از ویژگی‌های استخراج شده روی ImageNet: ایجاد نمونه‌ای از پایه‌ی کانولوشنال VGG16

### Instantiating the VGG16 convolutional base

```
from keras.applications import VGG16

conv_base = VGG16(weights='imagenet',
                  include_top=False,
                  input_shape=(150, 150, 3))
```

سه آرگومان این سازنده:

- **weights** specifies the weight checkpoint from which to initialize the model.
- **include\_top** refers to including (/not) the densely connected classifier on top of the network.  
By default, this densely connected classifier corresponds to the 1,000 classes from ImageNet. Because you intend to use your own densely connected classifier (with only two classes: cat and dog), you don't need to include it.
- **input\_shape** is the shape of the image tensors that you'll feed to the network.  
This argument is purely optional: if you don't pass it, the network will be able to process inputs of any size.

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

استفاده از ویژگی‌های استخراج شده روی ImageNet: جزئیات معماری پایه‌ی کانولوشنال VGG16

Layer (type)	Output Shape	Param #	
input_1 (InputLayer)	(None, 150, 150, 3)	0	
block1_conv1 (Convolution2D)	(None, 150, 150, 64)	1792	
block1_conv2 (Convolution2D)	(None, 150, 150, 64)	36928	
block1_pool (MaxPooling2D)	(None, 75, 75, 64)	0	
block2_conv1 (Convolution2D)	(None, 75, 75, 128)	73856	
block2_conv2 (Convolution2D)	(None, 75, 75, 128)	147584	
block2_pool (MaxPooling2D)	(None, 37, 37, 128)	0	
block3_conv1 (Convolution2D)	(None, 37, 37, 256)	295168	
block3_conv2 (Convolution2D)	(None, 37, 37, 256)	590080	
block3_conv3 (Convolution2D)	(None, 37, 37, 256)	590080	
block3_pool (MaxPooling2D)	(None, 18, 18, 256)	0	
block4_conv1 (Convolution2D)	(None, 18, 18, 512)	1180160	
block4_conv2 (Convolution2D)	(None, 18, 18, 512)	2359808	
block4_conv3 (Convolution2D)	(None, 18, 18, 512)	2359808	
block4_pool (MaxPooling2D)	(None, 9, 9, 512)	0	
block5_conv1 (Convolution2D)	(None, 9, 9, 512)	2359808	
block5_conv2 (Convolution2D)	(None, 9, 9, 512)	2359808	
block5_conv3 (Convolution2D)	(None, 9, 9, 512)	2359808	
block5_pool (MaxPooling2D)	(None, 4, 4, 512)	0	
<hr/>			
Total params: 14,714,688			
Trainable params: 14,714,688			
Non-trainable params: 0			

شکل نهایی نقشه‌ی ویژگی به صورت (4, 4, 512) است.  
در بالای این ویژگی باید یک طبقه‌بندی‌کننده‌ی متصل متراکم قرار بگیرد.

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

استفاده از ویژگی‌های استخراج شده روی ImageNet: دو مسیر برای ادامه کار

مسیر اول

اجرای پایه‌ی کانولوشنال روی مجموعه داده،  
ضبط کردن خروجی آن به صورت یک آرایه‌ی NumPy بر روی دیسک، و  
استفاده از این داده‌ها به عنوان ورودی به یک طبقه‌بندی کننده‌ی متصل متراکم

☺ اجرای این راه حل سریع و ارزان است،  
زیرا تنها به یک بار اجرای پایه‌ی کانولوشنال روی هر تصویر ورودی نیاز دارد  
و پایه‌ی کانولوشنال، پرهزینه‌ترین بخش این خط لوله است.  
🚫 این تکنیک امکان استفاده از داده‌افزایی را نمی‌دهد.

مسیر دوم

گسترش مدل موجود با اضافه کردن لایه‌های Dense به بالای آن، و  
اجرای کل مدل به صورت انتها به انتها بر روی داده‌های ورودی

☺ این تکنیک امکان استفاده از داده‌افزایی را می‌دهد،  
زیرا هر تصویر ورودی در هر زمان که توسط مدل دیده می‌شود، از پایه‌ی کانولوشنال می‌گذرد.  
🚫 این تکنیک کنتر و پرهزینه‌تر است.

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

روش سریع استخراج ویژگی بدون داده‌افزایی: استخراج ویژگی با استفاده از پایه‌ی کانولوشنال پیش‌آموزش دیده (۱ از ۲)

### FAST FEATURE EXTRACTION WITHOUT DATA AUGMENTATION

با اجرای نمونه‌ها از مولد `ImageDataGenerator` شروع می‌کنیم تا تصاویر را به صورت آرایه‌های Numpy به همراه برچسب آنها استخراج کند. سپس ویژگی‌ها را با فراخوانی متده `predict` از مدل `conv_base` از این تصاویر استخراج می‌کنیم.

### Extracting features using the pretrained convolutional base

```
import os
import numpy as np
from keras.preprocessing.image import ImageDataGenerator

base_dir = '/Users/fchollet/Downloads/cats_and_dogs_small'
train_dir = os.path.join(base_dir, 'train')
validation_dir = os.path.join(base_dir, 'validation')
test_dir = os.path.join(base_dir, 'test')

datagen = ImageDataGenerator(rescale=1./255)
batch_size = 20
```

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

روش سریع استخراج ویژگی بدون داده‌افزایی: استخراج ویژگی با استفاده از پایه‌ی کانولوشنال پیش‌آموزش دیده (۲ از ۲)

```
def extract_features(directory, sample_count):
    features = np.zeros(shape=(sample_count, 4, 4, 512))
    labels = np.zeros(shape=(sample_count))
    generator = datagen.flow_from_directory(
        directory,
        target_size=(150, 150),
        batch_size=batch_size,
        class_mode='binary')
    i = 0
    for inputs_batch, labels_batch in generator:
        features[i * batch_size : (i + 1) * batch_size] = features_batch
        labels[i * batch_size : (i + 1) * batch_size] = labels_batch
        i += 1
        if i * batch_size >= sample_count:
            break
    return features, labels
```

Note that because generators yield data indefinitely in a loop, you must break after every image has been seen once.

```
train_features, train_labels = extract_features(train_dir, 2000)
validation_features, validation_labels = extract_features(validation_dir, 1000)
test_features, test_labels = extract_features(test_dir, 1000)
# Flatten features
train_features = np.reshape(train_features, (2000, 4 * 4 * 512))
validation_features = np.reshape(validation_features, (1000, 4 * 4 * 512))
test_features = np.reshape(test_features, (1000, 4 * 4 * 512))
```

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

روش سریع استخراج ویژگی بدون داده‌افزایی: تعریف و آموزش طبقه‌بندی کننده‌ی متصل متراکم

حال طبقه‌بندی کننده‌ی متصل متراکم را تعریف می‌کنیم،  
از dropout برای رگولاریزاسیون استفاده می‌کنیم و آن را با داده‌ها و برچسب‌های اخیراً ذخیره شده آموزش می‌دهیم.

### Defining and training the densely connected classifier

```
from keras import models
from keras import layers
from keras import optimizers

model = models.Sequential()
model.add(layers.Dense(256, activation='relu', input_dim=4 * 4 * 512))
model.add(layers.Dropout(0.5))
model.add(layers.Dense(1, activation='sigmoid'))

model.compile(optimizer=optimizers.RMSprop(lr=2e-5),
              loss='binary_crossentropy',
              metrics=['acc'])

history = model.fit(train_features, train_labels,
                      epochs=30,
                      batch_size=20,
                      validation_data=(validation_features, validation_labels))
```

آموزش بسیار سریع است، زیرا تنها با دو لایه‌ی Dense سروکار داریم.

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

روش سریع استخراج ویژگی بدون داده‌افزایی: رسم نتایج

### Plotting the results

```
import matplotlib.pyplot as plt

acc = history.history['acc']
val_acc = history.history['val_acc']
loss = history.history['loss']
val_loss = history.history['val_loss']

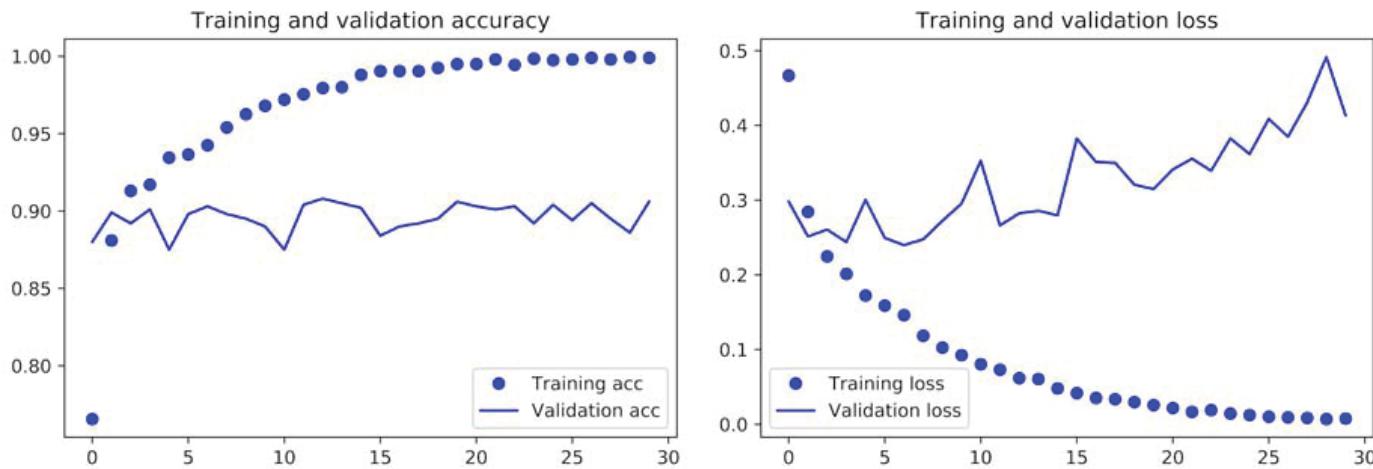
epochs = range(1, len(acc) + 1)

plt.plot(epochs, acc, 'bo', label='Training acc')
plt.plot(epochs, val_acc, 'b', label='Validation acc')
plt.title('Training and validation accuracy')
plt.legend()

plt.figure()
plt.plot(epochs, loss, 'bo', label='Training loss')
plt.plot(epochs, val_loss, 'b', label='Validation loss')
plt.title('Training and validation loss')
plt.legend()
plt.show()
```

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

روش سریع استخراج ویژگی بدون داده‌افزایی: نمودارهای اتلاف و دقت روی داده‌های آموزشی و اعتبارسنجی



در اینجا به دقتی حدود ۹۰٪ روی داده‌های اعتبارسنجی رسیده‌ایم  
(بسیار بهتر از آنچه در مدل کوچک آموزش داده شده از صفر رسیدیم)  
اما

تقریباً از نقطه‌ی شروع با بیش‌برازش مواجه شده‌ایم؛  
با وجود اینکه از dropout با نرخ تقریباً بالایی استفاده کرده‌ایم.  
زیرا: این تکنیک از داده‌افزایی استفاده نکرده است.

و داده‌افزایی برای جلوگیری از بیش‌برازش در حالتی که با مجموعه‌داده‌های کوچک تصویری کار می‌کنیم ضروری است.

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

روش استخراج ویژگی با داده‌افزایی

### FEATURE EXTRACTION WITH DATA AUGMENTATION

این روش کنتر و پرهزینه‌تر است،  
اما اجازه می‌دهد در حین آموزش از داده‌افزایی استفاده کنیم:  
مدل conv\_base را گسترش می‌دهیم و آن را به صورت انتها به انتها روی ورودی‌ها اجرا می‌کنیم.

### Adding a densely connected classifier on top of the convolutional base

```
from keras import models
from keras import layers
model = models.Sequential()
model.add(conv_base)
model.add(layers.Flatten())
model.add(layers.Dense(256, activation='relu'))
model.add(layers.Dense(1, activation='sigmoid'))
```

چون مدل‌ها دقیقاً مانند لایه‌ها رفتار می‌کنند،  
می‌توان یک مدل را به مدل Sequential اضافه نمود، دقیقاً مانند اضافه کردن یک لایه.

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

روش استخراج ویژگی با داده‌افزایی: جزئیات مدل

```
>>> model.summary()
Layer (type)          Output Shape         Param #
=====
vgg16 (Model)         (None, 4, 4, 512)    14714688
flatten_1 (Flatten)   (None, 8192)        0
dense_1 (Dense)       (None, 256)         2097408
dense_2 (Dense)       (None, 1)           257
=====
Total params: 16,812,353
Trainable params: 16,812,353
Non-trainable params: 0
```

مشاهده می‌شود که پایه‌ی کانولوشنال حدود ۱۵ میلیون پارامتر دارد که بسیار زیاد است.  
طبقه‌بندی‌کننده‌ای که در بالا اضافه شده است، حدود ۲ میلیون پارامتر دارد.

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

روش استخراج ویژگی با داده‌افزایی: انجامد پایه‌ی کانولوشنال

جلوگیری از به‌هنگام‌سازی وزن‌های آن لایه در حین آموزش

انجمناد یک لایه  
Freezing a Layer

پیش از کامپایل کردن و شروع آموزش مدل، بسیار مهم است که پایه‌ی کانولوشنال را منجمد کنیم. اگر این کار را نکنیم بازنمایی‌هایی که قبلًا توسط پایه‌ی کانولوشنال یاد گرفته شده‌اند، در حین آموزش تغییر می‌یابند، زیرا لایه‌های Dense در بالا به صورت تصادفی مقداردهی اولیه شده‌اند و تغییر وزن‌های بسیار بزرگی را در شبکه منتشر می‌کنند که به‌طور مؤثر، بازنمایی‌های یادگرفته‌شده‌ی قبلی را تخریب می‌کنند.

```
>>> print('This is the number of trainable weights '
       'before freezing the conv base:', len(model.trainable_weights))
This is the number of trainable weights before freezing the conv base: 30
>>> conv_base.trainable = False
>>> print('This is the number of trainable weights '
       'after freezing the conv base:', len(model.trainable_weights))
This is the number of trainable weights after freezing the conv base: 4
```

با تنظیمات فوق، تنها وزن‌های دو لایه‌ی Dense که اضافه شده‌اند آموزش می‌یابند؛ در مجموع ۴ تانسور وزن خواهیم داشت (برای هر لایه ۲ تا: ماتریس وزن اصلی و بردار بایاس)

وقتی آموزش‌پذیری وزن را پس از کامپایل کردن مدل تغییر می‌دهیم، باید آن مدل را مجددًا کامپایل کنیم. و گرنه این تغییرات نادیده گرفته می‌شوند.



## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

روش استخراج ویژگی با داده‌افزایی: آموزش مدل انتها به انتها با یک پایه‌ی کانولوشنال منجمد (۱ از ۲)

### Training the model end to end with a frozen convolutional base

```
from keras.preprocessing.image import ImageDataGenerator
from keras import optimizers
```

```
train_datagen = ImageDataGenerator(
    rescale=1./255,
    rotation_range=40,
    width_shift_range=0.2,
    height_shift_range=0.2,
    shear_range=0.2,
    zoom_range=0.2,
    horizontal_flip=True,
    fill_mode='nearest')
```

```
test_datagen = ImageDataGenerator(rescale=1./255) ←
```

```
train_generator = train_datagen.flow_from_directory(
    train_dir,
    target_size=(150, 150),
    batch_size=20,
    class_mode='binary') ←
```

Note that the validation data shouldn't be augmented!

Because you use binary\_crossentropy loss, you need binary labels.

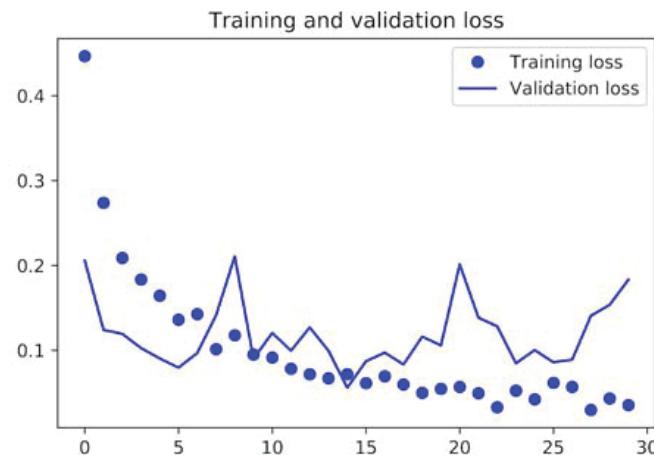
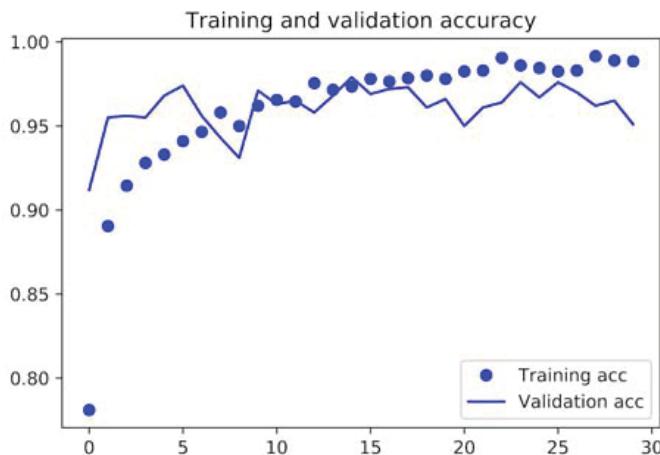
## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

روش استخراج ویژگی با داده‌افزایی: آموزش مدل انتهای بیانی با یک پایه‌ی کانولوشنال منجمد (۲ از ۲)

```
validation_generator = test_datagen.flow_from_directory(  
    validation_dir,  
    target_size=(150, 150),  
    batch_size=20,  
    class_mode='binary')  
  
model.compile(loss='binary_crossentropy',  
              optimizer=optimizers.RMSprop(lr=2e-5),  
              metrics=['acc'])  
  
history = model.fit_generator(  
    train_generator,  
    steps_per_epoch=100,  
    epochs=30,  
    validation_data=validation_generator,  
    validation_steps=50)
```

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

روش استخراج ویژگی با داده‌افزایی: نمودارهای اتلاف و دقت روی داده‌های آموزشی و اعتبارسنجی



در اینجا به دقتی حدود ۹۶٪ روی داده‌های اعتبارسنجی رسیده‌ایم  
(بسیار بهتر از آنچه در مدل کوچک آموزش داده شده از صفر رسیدیم)

## شبکه‌های عصبی کانوولوشنال

روش‌های استفاده از یک مدل پیش‌آموزش دیده: تنظیم دقیق

استخراج ویژگی  
Feature Extraction

۱

روش‌های  
استفاده از  
یک مدل  
پیش‌آموزش دیده

تنظیم دقیق  
Fine-tuning

۲

خارج ساختن تعدادی از لایه‌های بالایی مدل از حالت انجاماد و آموزش توأم آن همراه با لایه‌های اضافه شده به مدل

این روش مکملی برای روش استخراج ویژگی است.

تعداد کمی از لایه‌های بالایی مدل منجمد شده‌ای که برای استخراج ویژگی‌ها به کار رفت را از انجاماد خارج می‌کنیم، و هم بخشی از مدل که اخیراً اضافه شده (در اینجا طبقه‌بندی‌کننده‌ی تمام‌متصل) و هم این لایه‌های بالایی را توأم‌اً مورد آموزش قرار می‌دهیم.

این تکنیک، بازنمایی‌های انتزاعی‌تر مدل استفاده‌ی مجدد را اندکی تنظیم می‌کند تا آنها را به مسئله‌ی مورد نظر مربوط‌تر نماید.

## شبکه‌های عصبی کانولوشنال

روش‌های استفاده از یک مدل پیش‌آموزش دیده: تنظیم دقیق

منجمد کردن پایه‌ی کانولوشنال ضروری است

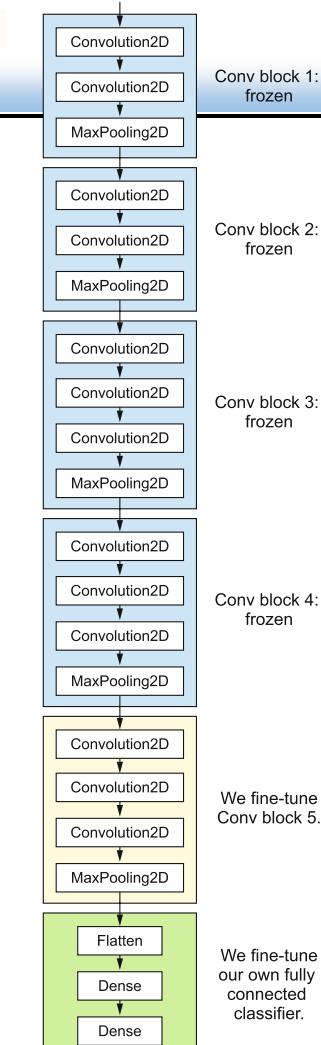
تا بتوان طبقه‌بندی کننده‌ی بالایی را که به صورت تصادفی مقداردهی اولیه شده است را مورد آموزش قرار داد.

به همین دلیل، تنظیم دقیق لایه‌های بالایی پایه‌ی کانولوشنال تنها در زمانی امکان‌پذیر است که طبقه‌بندی کننده‌ی بالایی از قبل آموزش یافته باشد.

اگر این طبقه‌بندی کننده از قبل آموزش یافته باشد،

آن‌گاه سیگنال خطا‌ی که در حین آموزش در شبکه منتشر می‌شود، بسیار بزرگ خواهد بود و بازنمایی‌هایی که قبلاً توسط لایه‌های دقیقاً تنظیم شده یاد گرفته شده‌اند، نابود خواهند شد.

بر این اساس، مراحل تنظیم دقیق یک شبکه به صورت زیر است:



۱) اضافه کردن شبکه‌ی سفارشی خود به بالای شبکه‌ی پایه‌ی هم‌اکنون آموزش دیده

۲) منجمد کردن شبکه‌ی پایه

۳) آموزش بخشی که اخیراً اضافه شده است

۴) خارج کردن برخی لایه‌های شبکه‌ی پایه از انجام

۵) آموزش توأم این لایه‌ها و بخش سفارشی

مراحل  
تنظیم دقیق  
(Fine-Tuning)  
یک شبکه

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

تنظیم دقیق: جزئیات مدل پایه‌ی کانولوشنال

```
>>> conv_base.summary()
Layer (type)          Output Shape         Param #
=====
input_1 (InputLayer)   (None, 150, 150, 3)  0
block1_conv1 (Convolution2D) (None, 150, 150, 64) 1792
block1_conv2 (Convolution2D) (None, 150, 150, 64) 36928
block1_pool (MaxPooling2D)  (None, 75, 75, 64)  0
block2_conv1 (Convolution2D) (None, 75, 75, 128) 73856
block2_conv2 (Convolution2D) (None, 75, 75, 128) 147584
block2_pool (MaxPooling2D)  (None, 37, 37, 128)  0
block3_conv1 (Convolution2D) (None, 37, 37, 256) 295168
block3_conv2 (Convolution2D) (None, 37, 37, 256) 590080
=====
```

block3_conv3 (Convolution2D)	(None, 37, 37, 256)	590080
block3_pool (MaxPooling2D)	(None, 18, 18, 256)	0
block4_conv1 (Convolution2D)	(None, 18, 18, 512)	1180160
block4_conv2 (Convolution2D)	(None, 18, 18, 512)	2359808
block4_conv3 (Convolution2D)	(None, 18, 18, 512)	2359808
block4_pool (MaxPooling2D)	(None, 9, 9, 512)	0
block5_conv1 (Convolution2D)	(None, 9, 9, 512)	2359808
block5_conv2 (Convolution2D)	(None, 9, 9, 512)	2359808
block5_conv3 (Convolution2D)	(None, 9, 9, 512)	2359808
block5_pool (MaxPooling2D)	(None, 4, 4, 512)	0

Total params: 14714688

اضافه کردن شبکه‌ی سفارشی خود به بالای شبکه‌ی پایه‌ی هم‌اکنون آموختش دیده

منجمد کردن شبکه‌ی پایه

آموختش بخشی که اخیراً اضافه شده است

خارج کردن برخی لایه‌های شبکه‌ی پایه از انجماد

آموختش توازن این لایه‌ها و بخش سفارشی

- (۱) اضافه کردن شبکه‌ی سفارشی خود به بالای شبکه‌ی پایه‌ی هم‌اکنون آموختش دیده
- (۲) منجمد کردن شبکه‌ی پایه
- (۳) آموختش بخشی که اخیراً اضافه شده است
- (۴) خارج کردن برخی لایه‌های شبکه‌ی پایه از انجماد
- (۵) آموختش توازن این لایه‌ها و بخش سفارشی

از اینجا ادامه می‌دهیم

مراحل  
تنظیم دقیق  
(Fine-Tuning)  
یک شبکه

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

تنظیم دقیق: غیرمنجذب‌سازی مدل پایه و سپس انجام برش لایه‌های آن

سه لایه‌ی کانولوشنال آخر را مورد تنظیم دقیق قرار می‌دهیم:  
یعنی همه‌ی لایه‌های `block4_pool` باید منجذب شوند و  
لایه‌های `block5_conv1`, `block5_conv2`, `block5_conv3` باید آموزش‌پذیر باشند.

چرا تعداد لایه‌ی بیشتری را مورد تنظیم دقیق قرار نمی‌دهیم?  
چرا کل پایه‌ی کانولوشنال را مورد تنظیم دقیق قرار نمی‌دهیم?  
اگر چه می‌توانیم، اما دو موضوع وجود دارد:

○ لایه‌های اول در پایه‌ی کانولوشنال، ویژگی‌های عامتر و قابل استفاده‌ی مجدد را کدگذاری می‌کنند،  
در حالی‌که لایه‌های بالاتر ویژگی‌های خاص‌تر را کدگذاری می‌کنند.

مفیدتر است که ویژگی‌های خاص‌تر را تنظیم دقیق کنیم، زیرا آنها هستند که نیاز به تغییر منظور برای مسئله‌ی جدید دارند.  
در تنظیم دقیق لایه‌های پایین‌تر افت بازدهی سریعی وجود دارد.

○ هرچه تعداد پارامتر بیشتری وارد آموزش شود، ریسک بیش‌برازش بیشتر می‌شود.  
پایه‌ی کانولوشنال ۱۵ میلیون پارامتر دارد، پس تلاش برای آموزش آن روی مجموعه‌داده‌ی کوچک ریسک زیادی دارد.

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

تنظیم دقیق: منجمدسازی تا یک لایه‌ی خاص

تنها دو تا سه لایه‌ی بالایی در پایه‌ی کانولوشنال را مورد تنظیم دقیق قرار می‌دهیم.

از ادامه‌ی مثال قبلی کار را دنبال می‌کنیم:

### Freezing all layers up to a specific one

```
conv_base.trainable = True

set_trainable = False
for layer in conv_base.layers:
    if layer.name == 'block5_conv1':
        set_trainable = True
    if set_trainable:
        layer.trainable = True
    else:
        layer.trainable = False
```

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

تنظیم دقیق: تنظیم دقیق مدل

از بهینه‌ساز RMSprop با یک نرخ یادگیری بسیار کوچک برای تنظیم دقیق استفاده می‌کنیم.  
دلیل: محدود کردن بزرگی تغییراتی که روی بازنمایی‌های سه لایه‌ی آخر انجام می‌شود.  
اگر به روزرسانی‌ها بسیار بزرگ باشند، ممکن است به این بازنمایی‌ها صدمه بزنند.

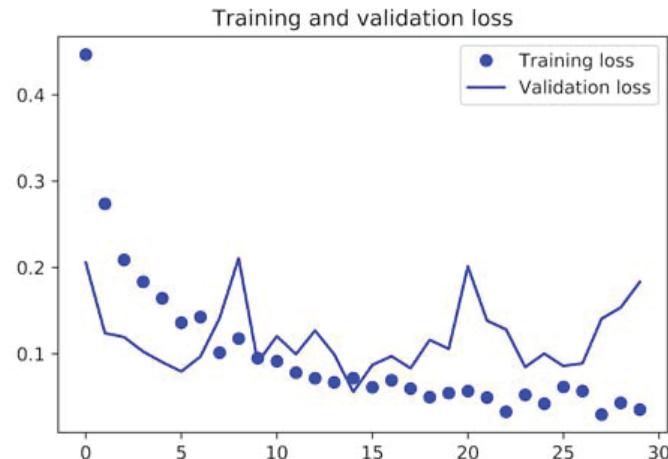
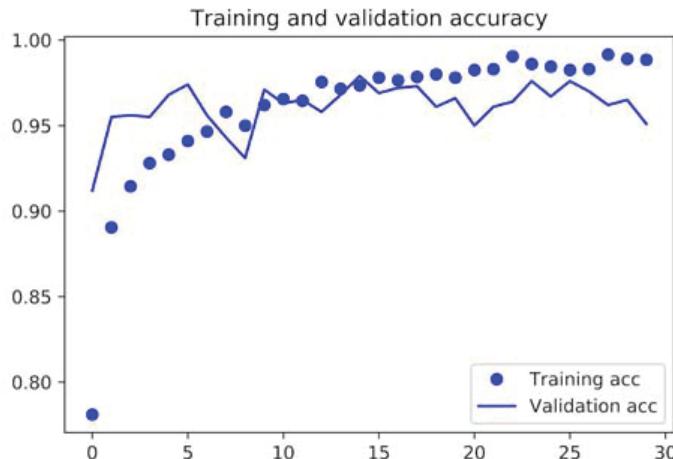
### Fine-tuning the model

```
model.compile(loss='binary_crossentropy',
              optimizer=optimizers.RMSprop(lr=1e-5),
              metrics=['acc'])

history = model.fit_generator(
    train_generator,
    steps_per_epoch=100,
    epochs=100,
    validation_data=validation_generator,
    validation_steps=50)
```

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

تنظیم دقیق: نمودارهای اتلاف و دقت روی داده‌های آموزشی و اعتبارسنجی



منحنی‌ها بسیار نویزی به نظر می‌رسند.

برای خواناتر کردن آنها، می‌توانیم آنها را هموار کنیم:  
با جایگزین کردن هر مقدار اتلاف و دقت با متوسط متحرک نمایی آن کمیت‌ها.

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

تنظیم دقیق: تابعی برای هموارسازی منحنی‌ها

### Smoothing the plots

```
def smooth_curve(points, factor=0.8):
    smoothed_points = []
    for point in points:
        if smoothed_points:
            previous = smoothed_points[-1]
            smoothed_points.append(previous * factor + point * (1 - factor))
        else:
            smoothed_points.append(point)
    return smoothed_points

plt.plot(epochs, smooth_curve(acc), 'bo', label='Smoothed training acc')
plt.plot(epochs, smooth_curve(val_acc), 'b', label='Smoothed validation acc')
plt.title('Training and validation accuracy')
plt.legend()
plt.figure()

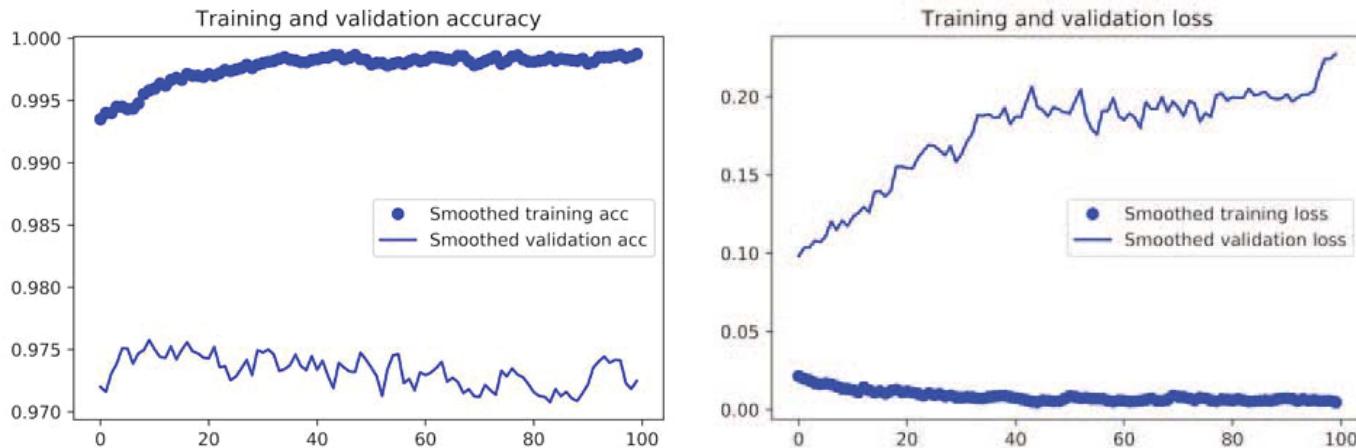
plt.plot(epochs, smooth_curve(loss), 'bo', label='Smoothed training loss')
plt.plot(epochs, smooth_curve(val_loss), 'b', label='Smoothed validation loss')
plt.title('Training and validation loss')
plt.legend()

plt.show()
```



## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

تنظیم دقیق: نمودارهای اتلاف و دقت روی داده‌های آموزشی و اعتبارسنجی (پس از هموارسازی)



%۹۷ بهبود در دقت دیده می‌شود: از %۹۶ به %۹۷.

منحنی اتلاف هیچ بهبود واقعی را نشان نمی‌دهد (در واقع، رو به بدتر شدن است)،  
اما چرا دقت پایدار شده است یا بهبود می‌یابد اگر اتلاف در حال کاهش نیست?  
پاسخ ساده است:

آنچه نمایش داده می‌شود، متوسط نقطه به نقطه‌ی مقادیر اتلاف است،  
اما آنچه برای دقت مهم است، توزیع مقادیر اتلاف است، نه مقادیر متوسط آن.  
زیرا مقدار دقت نتیجه‌ی حاصل از یک سطح آستانه‌ی دودویی از احتمال کلاسی است که توسط مدل پیش‌بینی شده است. ممکن است مدل همچنان در حال بهبود باشد حتی اگر موضوع این در متوسط اتلاف منعکس نشده باشد.

## مسئله‌ی طبقه‌بندی تصویر سگ/گربه

تنظیم دقیق: ارزیابی مدل با داده‌های آزمایشی

```
test_generator = test_datagen.flow_from_directory(
    test_dir,
    target_size=(150, 150),
    batch_size=20,
    class_mode='binary')

test_loss, test_acc = model.evaluate_generator(test_generator, steps=50)
print('test acc:', test_acc)
```

در اینجا به دقت ۹۷٪ روی داده‌های آزمایشی رسیده‌ایم.

در مسابقه‌ی اصلی kaggle با این مجموعه داده،  
این یکی از نتایج برتر بوده است.

اما ما در اینجا با استفاده از تکنیک‌های پیشرفته‌ی یادگیری عمیق،  
توانستیم با استفاده از بخش کوچکی از داده‌های آموزشی موجود (حدود ۱۰٪ آنها) به این نتیجه برسیم؛  
که بسیار بالارزش است.

## یادگیری عمیق برای بینایی کامپیوتروی

### خلاصه

#### WRAPPING UP

Here's what you should take away from the exercises in the past two sections:

- ❖ **Convnets** are the best type of **machine-learning models** for **computer-vision** tasks.  
It's possible to train one from scratch even on a very small dataset, with decent results.
- ❖ On a small dataset, **overfitting** will be the main issue.  
**Data augmentation** is a powerful way to fight overfitting when you're working with image data.
- ❖ It's easy to **reuse** an existing convnet on a new dataset via **feature extraction**.  
This is a valuable technique for working with small image datasets.
- ❖ As a complement to feature extraction, you can use **fine-tuning**, which adapts to a new problem some of the representations previously learned by an existing model.  
This pushes performance a bit further.



یادگیری عمیق برای بینایی کامپیووتری

۴

# تصویرسازی آنچه convnet ها می‌گیرند

## تصویرسازی آنچه convnet ها می یاد کنند

### VISUALIZING WHAT CONVNETS LEARN

اغلب گفته می شود مدل های یادگیری عمیق، «جعبه سیاه» هستند: یادگیری بازنمایی هایی که استخراج آنها دشوار است و ارائه آنها به شکل خوانا برای انسان دشوار است.

این موضوع تا حدی برای برخی مدل های یادگیری عمیق درست است،  
اما برای شبکه های عصبی کانولوشنال قطعاً درست نیست:

بازنمایی های یادگرفته شده توسط convnet ها برای تصویرسازی بسیار مناسب است،  
عمدتاً به این دلیل که آنها **بازنمایی های مفاهیم دیداری** هستند.

## تصویرسازی آنچه convnet ها می‌گیرند

### روش‌های تصویرسازی

فهرست گسترده‌ای از تکنیک‌ها برای تصویرسازی و تفسیرگری بازنمایی‌های convnet ارائه شده است.

#### سه روش مفیدتر و دردسترس‌تر برای تصویرسازی بازنمایی‌های شبکه‌های عصبی کانولوشنال

مفید برای فهم اینکه لایه‌های متوالی شبکه چگونه ورودی خود را تبدیل می‌کنند؛ برای اخذ ایده‌های اولیه در مورد معنای فیلترهای منفرد شبکه

**تصویرسازی خروجی‌های میانی شبکه (فعالیت‌های میانی)**  
*Visualizing intermediate convnet outputs (intermediate activations)*

مفید برای فهم دقیق اینکه هر فیلتر در شبکه، چه معانیم یا چه الگوهای دیداری را می‌پذیرد

**تصویرسازی فیلترهای شبکه**  
*Visualizing convnets filters*

مفید برای فهم اینکه کدام بخش‌های یک تصویر به عنوان تعلق به یک کلاس داده شده شناسایی می‌شوند  $\Leftarrow$  امکان مکان‌یابی اشیا در تصویر

**تصویرسازی نقشه‌های گرمایی فعالیت کلاس در یک تصویر**  
*Visualizing heatmaps of class activation in an image*

۱

۲

۳

## روش‌های مصورسازی: مصورسازی فعالیت‌های میانی

### VISUALIZING INTERMEDIATE ACTIVATIONS

**تصویرسازی فعالیت‌های میانی:**

نمایش نقشه‌های ویژگی خروجی

که توسط لایه‌های گوناگون کانولولوشن و پولینگ در شبکه به‌ازای یک ورودی خاص ایجاد می‌شوند.

(خروجی یک لایه اغلب فعالیت / activation function نامیده می‌شود: خروجیتابع فعالیت

این روش به ما نمایی در مورد چگونگی تجزیه‌ی ورودی به فیلترهای مختلف یادگیری شده توسط شبکه می‌دهد.

می‌خواهیم نقشه‌های ویژگی دارای سه بعد را مصورسازی کنیم:

width, height, and depth (channels)

هر کاتال ویژگی‌های نسبتاً مستقلی را کدگذاری می‌کند؛

بنابراین، روش مناسب برای مصورسازی این نقشه‌های ویژگی،

رسم مستقل محتوای هر یک از آنها به صورت یک تصویر دو-بعدی است.

## روش‌های مصورسازی: مصورسازی فعالیت‌های میانی

### مثال

از مدل ذخیره شده در مثال‌های قبلی استفاده می‌کنیم:

```
>>> from keras.models import load_model
>>> model = load_model('cats_and_dogs_small_2.h5')
>>> model.summary() <1> As a reminder.
```

Layer (type)	Output Shape	Param #
conv2d_5 (Conv2D)	(None, 148, 148, 32)	896
maxpooling2d_5 (MaxPooling2D)	(None, 74, 74, 32)	0
conv2d_6 (Conv2D)	(None, 72, 72, 64)	18496
maxpooling2d_6 (MaxPooling2D)	(None, 36, 36, 64)	0
conv2d_7 (Conv2D)	(None, 34, 34, 128)	73856
maxpooling2d_7 (MaxPooling2D)	(None, 17, 17, 128)	0
conv2d_8 (Conv2D)	(None, 15, 15, 128)	147584
maxpooling2d_8 (MaxPooling2D)	(None, 7, 7, 128)	0
flatten_2 (Flatten)	(None, 6272)	0
dropout_1 (Dropout)	(None, 6272)	0
dense_3 (Dense)	(None, 512)	3211776
dense_4 (Dense)	(None, 1)	513

Total params: 3,453,121  
Trainable params: 3,453,121  
Non-trainable params: 0

## روش‌های مصورسازی: مصورسازی فعالیت‌های میانی

پیش‌پردازش یک تصویر تنها

یک تصویر (تصویر یک گربه) را باز می‌کنیم (از مجموعه‌ی آزمایشی نه آموزشی)

### Preprocessing a single image

```
img_path = '/Users/fchollet/Downloads/cats_and_dogs_small/test/cats/cat.1700.jpg'

from keras.preprocessing import image ←
import numpy as np

img = image.load_img(img_path, target_size=(150, 150))
img_tensor = image.img_to_array(img)
img_tensor = np.expand_dims(img_tensor, axis=0)
img_tensor /= 255. ←

<1> Its shape is (1, 150, 150, 3)
print(img_tensor.shape)
```

Preprocesses the image  
into a 4D tensor

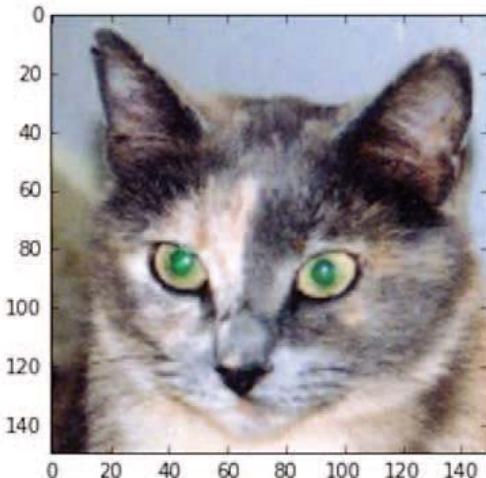
Remember that the  
model was trained on  
inputs that were  
preprocessed this way.

## روش‌های مصورسازی: مصورسازی فعالیت‌های میانی

نمایش تصویر آزمایشی

## Displaying the test picture

```
import matplotlib.pyplot as plt  
  
plt.imshow(img_tensor[0])  
plt.show()
```



## روش‌های مصورسازی: مصورسازی فعالیت‌های میانی

نمونه‌سازی یک مدل از یک تانسور ورودی و لیستی از تانسورهای خروجی

برای استخراج نقشه‌های ویژگی که می‌خواهیم به آنها نگاه کنیم، یک مدل Keras درست می‌کنیم که دسته‌ای از تصاویر را به عنوان ورودی دریافت می‌کند، و فعالیت‌های تمام لایه‌های کانولوشنی و پولینگ را در قالب خروجی ثبت می‌کند.

از کلاس `Model` در Keras استفاده می‌کنیم.

یک نمونه از مدل با استفاده از دو آرگومان ساخته می‌شود:

- ۱) یک تانسور ورودی (یک لیست از تانسورهای ورودی)
  - ۲) یک تانسور خروجی (یک لیست از تانسورهای خروجی)
- مدل حاصل، ورودی‌های مشخص شده را به خروجی مشخص شده نگاشت می‌دهد.
- یک مدل می‌تواند چند خروجی داشته باشد.

### Instantiating a model from an input tensor and a list of output tensors

```
from keras import models
```

```
layer_outputs = [layer.output for layer in model.layers[:8]]
```

```
activation_model = models.Model(inputs=model.input, outputs=layer_outputs)
```

Extracts the outputs of  
the top eight layers

Creates a model that will return  
these outputs, given the model input

## روش‌های مصورسازی: مصورسازی فعالیت‌های میانی

اجرای مدل برای تعیین مقادیر فعالیت‌ها

وقتی یک ورودی تصویری به این مدل داده می‌شود، این مدل مقادیر فعالیت لایه‌ها در مدل اصلی را برمی‌گرداند.  
 (در اینجا با یک مدل دارای یک ورودی و ۸ خروجی سروکار داریم)

### Running the model in predict mode

```
activations = activation_model.predict(img_tensor)
```

Returns a list of five Numpy arrays:  
 one array per layer activation

به عنوان مثال، فعالیت اولیه‌ی لایه‌ی کانولوشنی برای ورودی تصویر گربه  
 به صورت زیر است:

```
>>> first_layer_activation = activations[0]
>>> print(first_layer_activation.shape)
(1, 148, 148, 32)
```

که یک نقشه‌ی ویژگی  $148 \times 148$  با تعداد ۳۲ کanal است.

## روش‌های مصورسازی: مصورسازی فعالیت‌های میانی

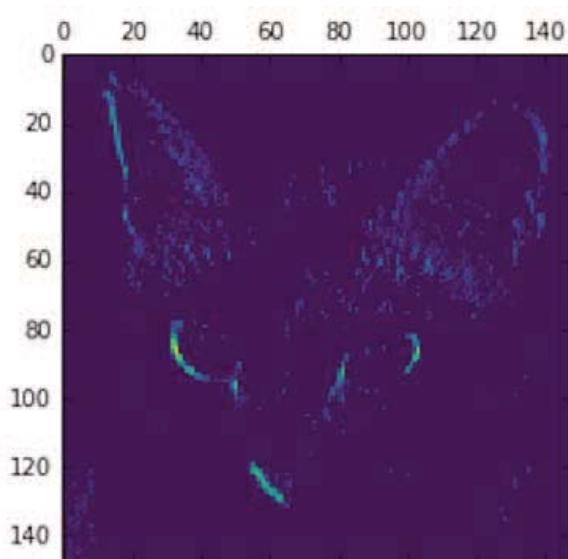
تصویرسازی کanal چهارم فعالیت لایه اول کانولوشنی

### Visualizing the fourth channel

```
import matplotlib.pyplot as plt
plt.matshow(first_layer_activation[0, :, :, 4], cmap='viridis')
```

کanal ۴ از یک نقشه‌ی ویژگی  $148 \times 148$

به نظر می‌رسد این کanal یک آشکارساز لبه‌ی قطری (diagonal edge detector) را کدگذاری می‌کند.



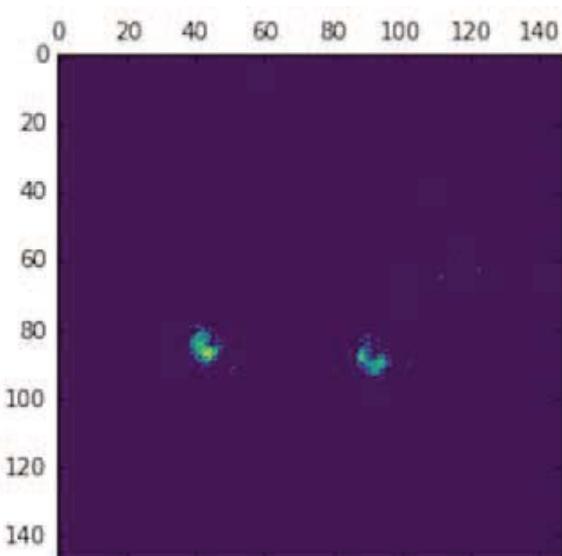
## روش‌های مصورسازی: مصورسازی فعالیت‌های میانی

تصورسازی کanal هفتم فعالیت لایه‌ی اول کانولوشنی

### Visualizing the seventh channel

```
plt.matshow(first_layer_activation[0, :, :, 7], cmap='viridis')
```

کanal 7 از یک نقشه‌ی ویژگی  $148 \times 148$



به نظر می‌رسد این کanal یک آشکارساز نقاط سبز روشن (bright green dot) را کدگذاری می‌کند.  
(مفید برای کدگذاری چشم‌های گربه)

## روش‌های مصورسازی: مصورسازی فعالیت‌های میانی

رسم مصورسازی کامل همهٔ کانال‌ها در همهٔ فعالیت‌های میانی در شبکه (۱ از ۲)

همهٔ کانال‌ها در هر یک از هشت نقشهٔ فعالیت شبکه را استخراج و رسم می‌کنیم.

### Visualizing every channel in every intermediate activation

```
layer_names = []
for layer in model.layers[:8]:
    layer_names.append(layer.name)

Names of the layers, so you can have them as part of your plot

images_per_row = 16
Displays the feature maps

for layer_name, layer_activation in zip(layer_names, activations): ←
    n_features = layer_activation.shape[-1] Number of features in the feature map

    size = layer_activation.shape[1] The feature map has shape (1, size, size, n_features).

    n_cols = n_features // images_per_row Tiles the activation channels in this matrix
    display_grid = np.zeros((size * n_cols, images_per_row * size))
```

## روش‌های مصورسازی: مصورسازی فعالیت‌های میانی

رسم مصورسازی کامل همهٔ کانال‌ها در همهٔ فعالیت‌های میانی در شبکه (۲ از ۲)

```

for col in range(n_cols):
    for row in range(images_per_row):
        channel_image = layer_activation[0,
                                         :, :,
                                         col * images_per_row + row]
    channel_image -= channel_image.mean()
    channel_image /= channel_image.std()
    channel_image *= 64
    channel_image += 128
    channel_image = np.clip(channel_image, 0, 255).astype('uint8')
    display_grid[col * size : (col + 1) * size, ←
                  row * size : (row + 1) * size] = channel_image
scale = 1. / size
plt.figure(figsize=(scale * display_grid.shape[1],
                   scale * display_grid.shape[0]))
plt.title(layer_name)
plt.grid(False)
plt.imshow(display_grid, aspect='auto', cmap='viridis')

```

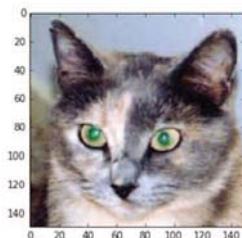
**Post-processes the feature to make it visually palatable**

**Tiles each filter into a big horizontal grid**

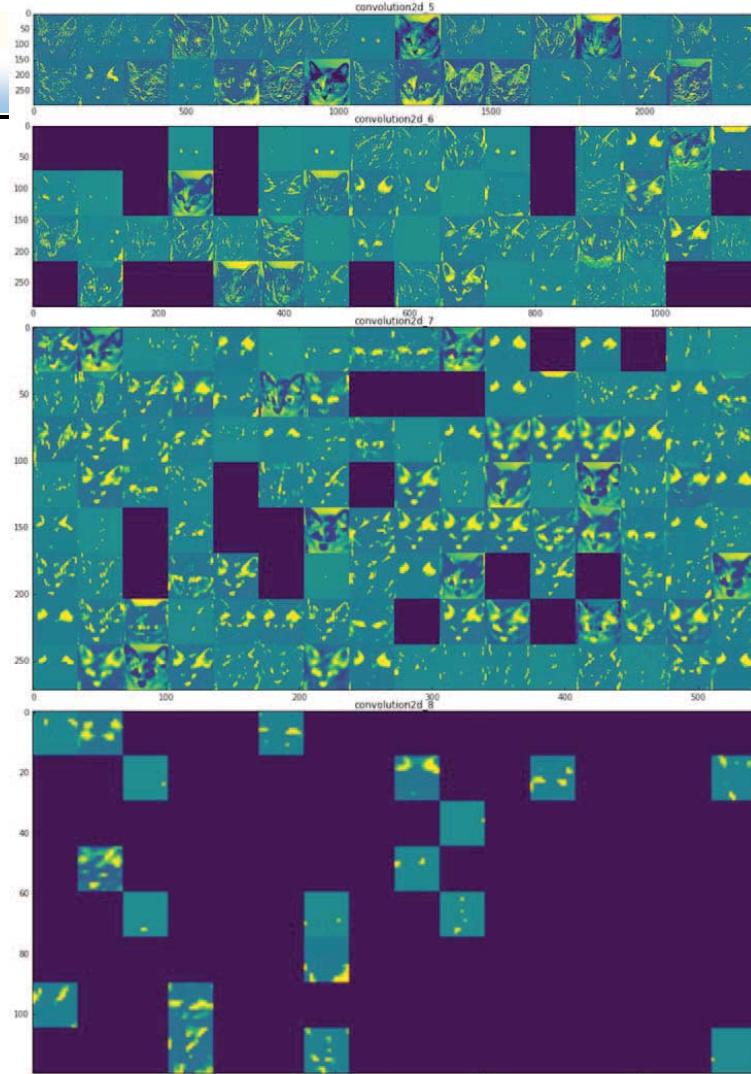
**Displays the grid**

## تصویرسازی فعالیت‌های میانی

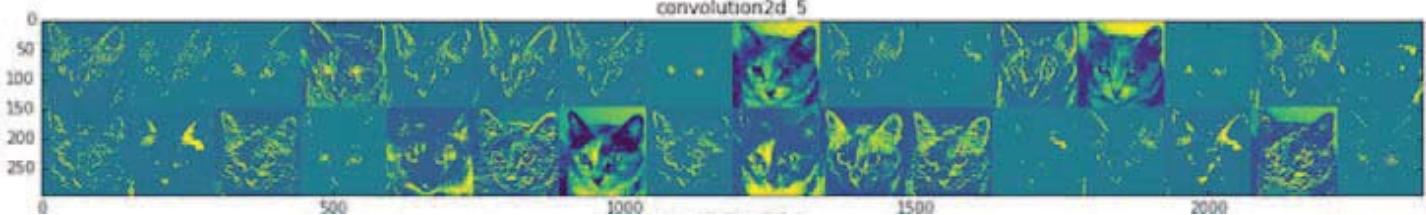
همه کانال‌های همه فعالیت‌ها



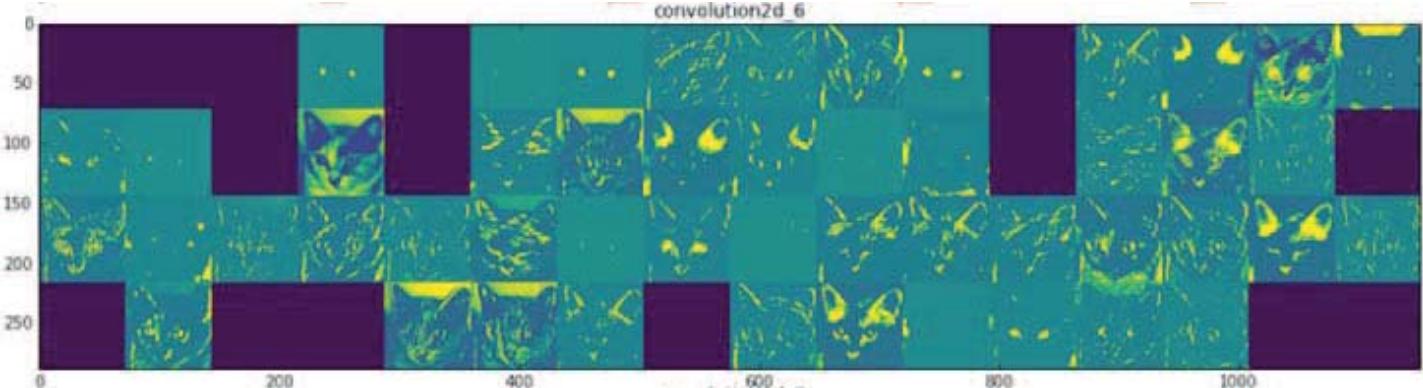
برای این تصویر ورودی



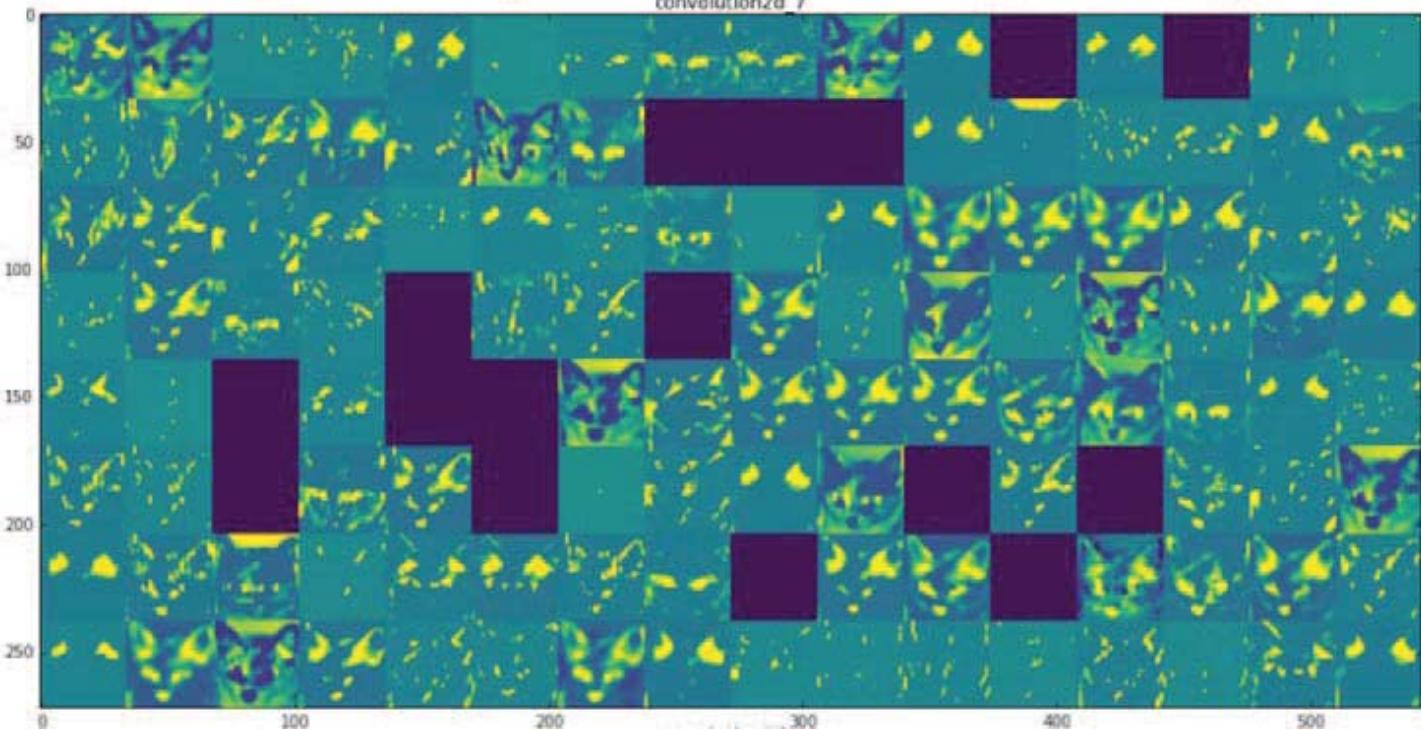
convolution2d 5



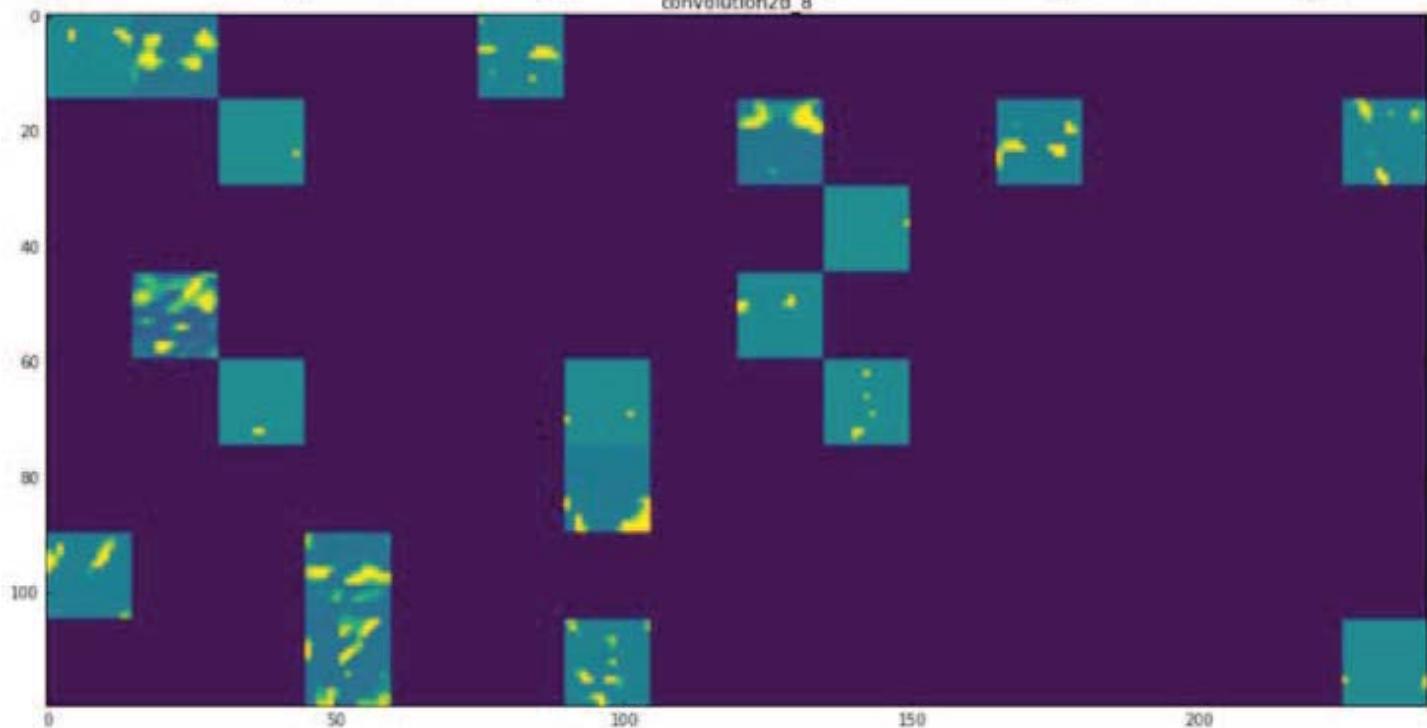
convolution2d\_6



convolution2d\_7



convolution2d\_8



## روش‌های مصورسازی: مصورسازی فعالیت‌های میانی

### نکات

#### نکات قابل توجه:

- **لایه‌ی اول به عنوان گرایه‌ای** از انواع آشکارسازهای لبه عمل می‌کند.  
در این مرحله، فعالیت‌ها تقریباً همه‌ی اطلاعات موجود در تصویر اولیه را حفظ می‌کنند.
- **هرچه بالاتر می‌رویم، فعالیت‌ها به طور افزایشی انتزاعی‌تر می‌شوند و به طور بصری کمتر تفسیرپذیرند.**  
فعالیت شروع به کدگاری مفاهیم سطح بالاتر مانند «گوش گربه» و «چشم گربه» می‌کنند.  
بازنمایی‌های بالاتر به طور افزایشی اطلاعات کمتری در مورد محتوای بصری تصویر حمل می‌کنند،  
بلکه اطلاعات بیشتری مرتبط با کلاس آن تصویر حمل می‌کنند.
- **خلوت شدن فعالیت‌ها با عمق لایه افزایش می‌یابند.**  
در اولین لایه، همه‌ی فیلترها به وسیله‌ی تصویر ورودی فعال می‌شوند.  
اما در لایه‌های بعدی، تعداد بیشتری از فیلترها خالی می‌شوند.  
(یعنی: الگوی کد شده توسط آن فیلتر در تصویر ورودی یافت نمی‌شود.)

## روش‌های مصورسازی: مصورسازی فعالیت‌های میانی

### نتایج

یک مشخصه‌ی سراسری مهم بازنمایی‌های یادگیری شده توسط شبکه‌های عصبی عمیق را مشاهده کردیم: ویژگی‌های استخراج شده توسط یک لایه، متناسب با عمق آن لایه، انتزاعی‌تر می‌شوند.

فعالیت‌های لایه‌های بالاتر حامل اطلاعات کمتر و کمتری در مورد ورودی خاص مشاهده شده هستند.  
فعالیت‌های لایه‌های بالاتر حامل اطلاعات بیشتر و بیشتری در مورد تارگت (کلاس) ورودی خاص هستند.

یک شبکه‌ی عصبی عمیق، به صورت مؤثر به عنوان یک  
**خط لوله‌ی تقطیر اطلاعات**  
(information distillation pipeline)  
عمل می‌کند.

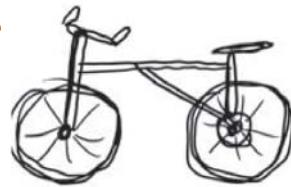
داده‌های خام (مثلًاً تصاویر RGB) وارد آن می‌شوند  
و به طور مکرر تبدیل می‌شوند تا اطلاعات نامرتب (مثل ظاهر بصری خاص تصویر) از آن فیلتر شود  
و اطلاعات مفید بزرگنمایی و تصفیه می‌شود (مثل کلاس تصویر).

## روش‌های مصورسازی: مصورسازی فعالیت‌های میانی

مقایسه با ادراک بصری انسان از جهان



تلash‌ها برای رسم  
یک دوچرخه از حافظه



یک دوچرخه‌ی شماتیک  
باید شبیه این باشد.



عملکرد **خط لوله‌ی تقطیر اطلاعات** قابل مقایسه با شیوه‌ی ادراک بصری انسان‌ها از جهان است:

یک انسان پس از مشاهده‌ی یک صحنه به مدت چند ثانیه،

می‌تواند به خاطر بیاورد که کدام اشیای انتزاعی در آن صحنه موجود بوده‌اند (دوچرخه، درخت، ...)

اما نمی‌تواند ظاهر خاص (جزئیات) این اشیا را به خاطر بیاورد.

مغز ما یاد گرفته است که ورودی‌های بصری خود را کاملاً انتزاعی کند

(تا آن را به مفاهیم بصری سطح بالا تبدیل کند و همزمان جزئیات بصری نامربوط را فیلتر و حذف کند)

و باعث می‌شود یادآوری کیفیت چیزهای اطراف ما بسیار دشوار شود.

## روش‌های مصورسازی: مصورسازی فیلترهای شبکه

### VISUALIZING CONVNET FILTERS

روش ساده‌ی دیگر برای معاینه‌ی فیلترهای یادگیری شده توسط شبکه‌های عصبی کانولوشنال:  
**نمایش الگوی بصری‌ای که هر فیلتر باید به آن پاسخ دهد.**

این کار را می‌توان با **جستجوی افزایش گرادیان** در فضای ورودی  
 با هدف ماکزیمم‌سازی پاسخ به یک فیلتر خاص انجام داد:  
 از یک تصویر ورودی خالی شروع می‌کنیم،  
 تصویر ورودی حاصل، آن است که فیلتر انتخاب شده ماکزیمم پاسخ را به آن بدهد.

لازم است یک تابع اتلاف بسازیم که مقدار یک فیلتر داده شده در یک لایه‌ی کانولوشنی داده شده را ماکزیمم کند؛  
 و سپس از الگوریتم کاهش گرادیان تصادفی استقاده کنیم تا  
 مقادیر تصویر ورودی را به گونه‌ای تنظیم کند که این مقدار فعالیت را ماکزیمم کند.

## روش‌های مصورسازی: مصورسازی فیلترهای شبکه

### تعریف تابع اتلاف

یک تابع اتلاف برای برای فعالیت فیلتر صفر در لایه‌ی `block3_conv1` از شبکه‌ی VGG16 که بر روی ImageNet پیش‌آموزش دیده است.

### Defining the loss tensor for filter visualization

```
from keras.applications import VGG16
from keras import backend as K

model = VGG16(weights='imagenet',
                include_top=False)

layer_name = 'block3_conv1'
filter_index = 0

layer_output = model.get_layer(layer_name).output
loss = K.mean(layer_output[:, :, :, filter_index])
```

## روش‌های مصورسازی: مصورسازی فیلترهای شبکه

محاسبه‌ی گرادیان اتلاف نسبت به ورودی

برای پیاده‌سازی الگوریتم کاهش گرادیان،  
به گرادیان تابع اتلاف بر حسب ورودی مدل نیاز داریم.  
برای این کار، از تابع gradients که در ماژول backend در Keras موجود است استفاده می‌کنیم.

### Obtaining the gradient of the loss with regard to the input

```
grads = K.gradients(loss, model.input)[0]
```

The call to gradients returns a list  
of tensors (of size 1 in this case).  
Hence, you keep only the first  
element -which is a tensor.

## روش‌های مصورسازی: مصورسازی فیلترهای شبکه

### ترفند نرمال‌سازی گرادیان

یک ترفند غیربدیهی برای کمک به پیش روی هموار فرآیند کاهش گرادیان، نرمال‌سازی تانسور از طریق تقسیم آن بر نرم L<sup>2</sup> آن (جذر میانگین مربعات مقادیر موجود در تانسور) است.  
 \* این کار تضمین می‌کند که بزرگی به روزرسانی‌ها تصویر و رودی همیشه در بازه‌ی ثابتی بماند.

### Gradient-normalization trick

```
grads /= (K.sqrt(K.mean(K.square(grads))) + 1e-5)
```

Add 1e-5 before dividing  
to avoid accidentally  
dividing by 0.

## روش‌های مصورسازی: مصورسازی فیلترهای شبکه

### واکنشی مقادیر خروجی با توجه به مقادیر ورودی

به روشهای برای محاسبهٔ مقدار تانسور اتلاف و تانسور گرادیان آن با توجه به تصویر ورودی نیاز داریم.

تابع `iterate` تابعی است که یک تانسور `Numpy` (لیستی از تانسورها با اندازهٔ ۱) را دریافت می‌کند و لیستی از دو تانسور `Numpy` (مقدار اتلاف و مقدار گرادیان آن) را برمی‌گرداند.

یک تابع `Keras` در `backend` می‌نویسیم:

### Fetching Numpy output values given Numpy input values

```
iterate = K.function([model.input], [loss, grads])

import numpy as np
loss_value, grads_value = iterate([np.zeros((1, 150, 150, 3))])
```

## روش‌های مصورسازی: مصورسازی فیلترهای شبکه

ماکزیمم‌سازی محلی با استفاده از کاهش گرادیان تصادفی

در این مرحله، یک حلقه‌ی پایتون برای انجام کاهش گرادیان تصادفی می‌نویسیم:

### Loss maximization via stochastic gradient descent

**Starts from a gray image with some noise**

```
input_img_data = np.random.random((1, 150, 150, 3)) * 20 + 128.
```

**step = 1. Magnitude of each gradient update**

```
for i in range(40):
    loss_value, grads_value = iterate([input_img_data])
```

**Computes the loss value and gradient value**

```
input_img_data += grads_value * step
```

**Adjusts the input image in the direction that maximizes the loss**

**Runs  
gradient  
ascent  
for 40  
steps**

## روش‌های مصورسازی: مصورسازی فیلترهای شبکه

### تبدیل تانسور به تصویر

تانسور تصویر حاصل، یک تانسور ممیز شناور با شکل (3, 150, 150, 1) است. ممکن است مقادیر آن اعداد صحیح بازه‌ی [0, 255] نباشد. پس باید این تانسور را پس‌پردازش کنیم تا به یک تصویر قابل نمایش تبدیل شود.

### Utility function to convert a tensor into a valid image

```
def deprocess_image(x):
    x -= x.mean()
    x /= (x.std() + 1e-5)
    x *= 0.1

    x += 0.5
    x = np.clip(x, 0, 1)

    x *= 255
    x = np.clip(x, 0, 255).astype('uint8')
    return x
```

**Normalizes the tensor:  
centers on 0, ensures  
that std is 0.1**

**Clips to [0, 1]**

**Converts to an RGB array**

## روش‌های مصورسازی: مصورسازی فیلترهای شبکه

تابع کامل برای دریافت نام لایه + اندیس فیلتر و تولید تصویر الگوی ماکریم‌کننده‌ی آن فیلتر

### Function to generate filter visualizations

Builds a loss function that maximizes the activation  
of the nth filter of the layer under consideration

```
def generate_pattern(layer_name, filter_index, size=150):
    layer_output = model.get_layer(layer_name).output
    loss = K.mean(layer_output[:, :, :, :, filter_index])
```

```
grads = K.gradients(loss, model.input)[0]
```

Computes the gradient of the input  
picture with regard to this loss

```
grads /= (K.sqrt(K.mean(K.square(grads))) + 1e-5)
```

Normalization trick:  
normalizes the gradient

```
iterate = K.function([model.input], [loss, grads])
```

Returns the loss and grads  
given the input picture

```
input_img_data = np.random.random((1, size, size, 3)) * 20 + 128.
```

Starts from a gray image with some noise

```
step = 1.
```

```
for i in range(40):
```

```
    loss_value, grads_value = iterate([input_img_data])
```

```
    input_img_data += grads_value * step
```

Runs gradient  
ascent for 40  
steps

```
img = input_img_data[0]
```

```
return deprocess_image(img)
```



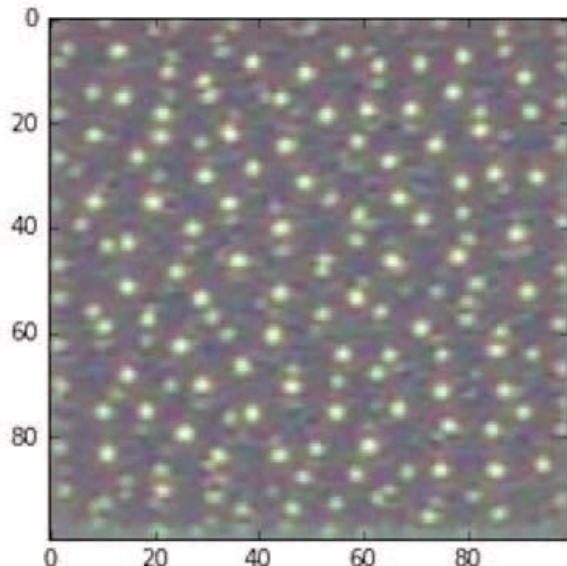
## روش‌های مصورسازی: مصورسازی فیلترهای شبکه

مثال

```
>>> plt.imshow(generate_pattern('block3_conv1', 0))
```

الگویی که کانال صفر در لایه‌ی  
block3\_conv1  
ماکزیم پاسخ را به آن می‌دهد.

به نظر می‌رسد فیلتر صفر در این لایه،  
مسئول الگوی  
polka-dot pattern  
است.



## روش‌های مصورسازی: مصورسازی فیلترهای شبکه

تولید یک توری از همه‌ی الگوهای پاسخ فیلتر در یک لایه

برای سادگی، فقط ۶۴ فیلتر اول در هر لایه و اولین لایه‌ی هر بلوک کانولوشنی را بررسی می‌کنیم.

### Generating a grid of all filter response patterns in a layer

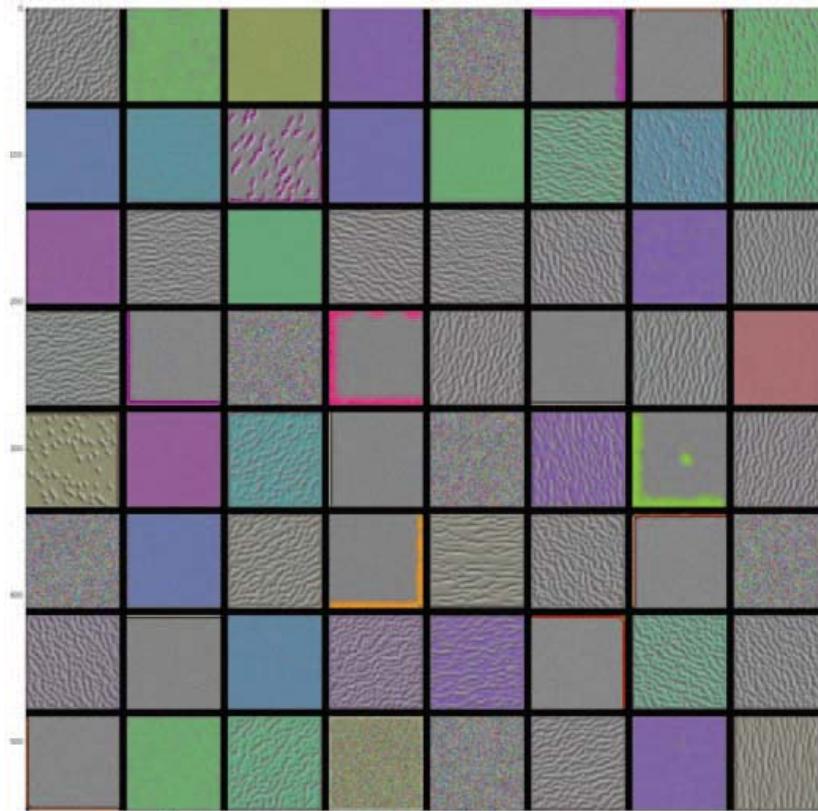
```
layer_name = 'block1_conv1'
size = 64
margin = 5

results = np.zeros((8 * size + 7 * margin, 8 * size + 7 * margin, 3))

for i in range(8): Iterates over the rows of the results grid
    for j in range(8): Iterates over the columns of the results grid
        filter_img = generate_pattern(layer_name, i + (j * 8), size=size)
Generates the pattern for filter i + (j * 8) in layer_name
        horizontal_start = i * size + i * margin
        horizontal_end = horizontal_start + size
        vertical_start = j * size + j * margin
        vertical_end = vertical_start + size
        results[horizontal_start: horizontal_end,
               vertical_start: vertical_end, :] = filter_img
Puts the result in the square (i, j) of the results grid

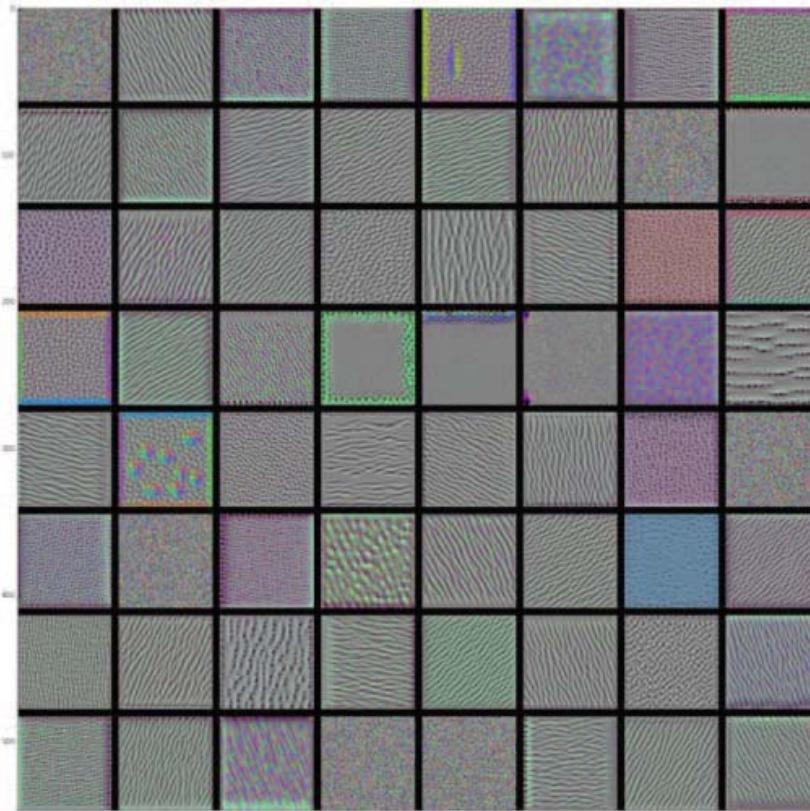
plt.figure(figsize=(20, 20))
plt.imshow(results) Displays the results grid
```

## روش‌های مصورسازی: مصورسازی فیلترهای شبکه

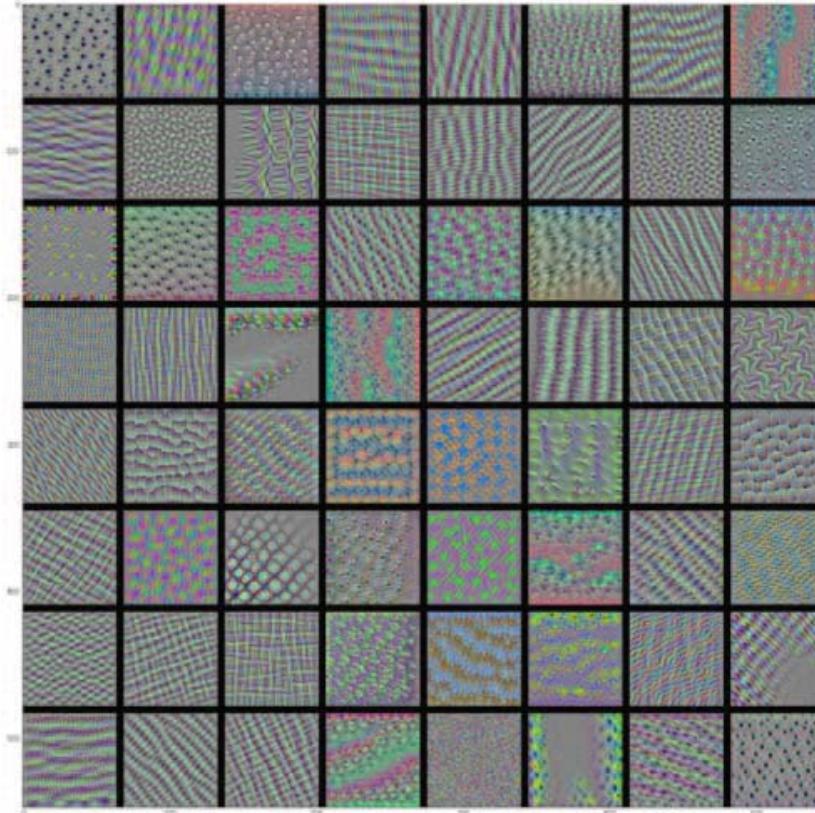
الگوهای فیلتر برای لایه‌ی `block1_conv1`

## روش‌های مصورسازی: مصورسازی فیلترهای شبکه

الگوهای فیلتر برای لایه‌ی block2\_conv1

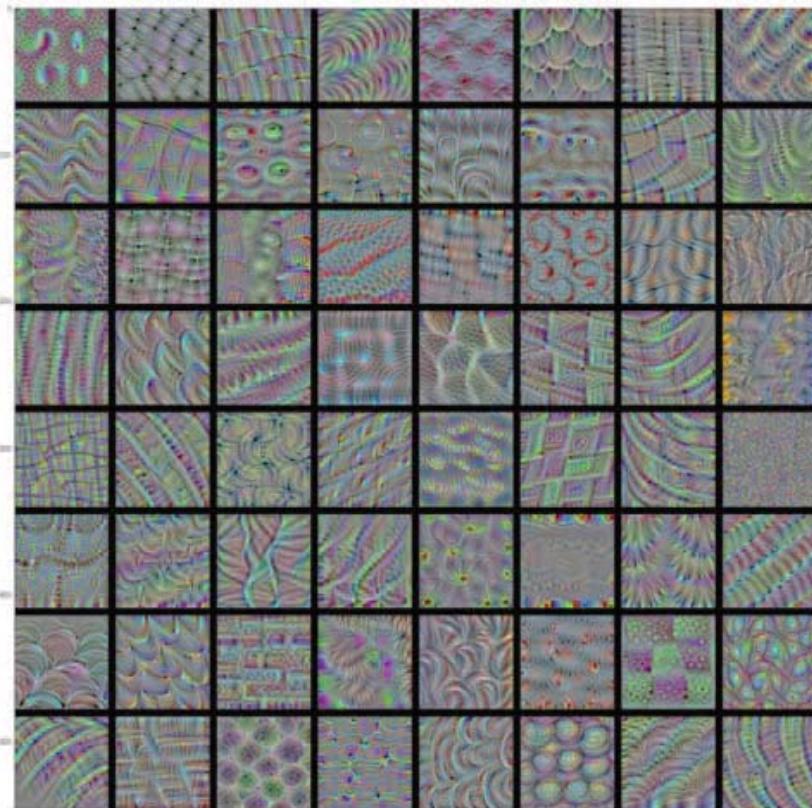


## روش‌های مصورسازی: مصورسازی فیلترهای شبکه

الگوهای فیلتر برای لایه‌ی `block3_conv1`

## روش‌های مصورسازی: مصورسازی فیلترهای شبکه

الگوهای فیلتر برای لایه‌ی block4\_conv1



## روش‌های مصورسازی: مصورسازی فیلترهای شبکه

### نکات

تصورسازی فیلترها، به ما چیزهای زیادی در مورد اینکه لایه‌های convnet دنیا را چگونه می‌بینند، می‌گوید.

هر لایه در یک convnet گردایه‌ای از فیلترها را یاد می‌گیرد؛ به‌گونه‌ای که ورودی‌های آنها را می‌توان به صورت ترکیبی از آن فیلترها بیان کرد. (مشابه تبدیل فوریه که سیگنال ورودی را به مجموعه‌ای از توابع سینوسی تجزیه می‌کند.)

فیلترها در این بانک‌های فیلتر convnet، به صورت افزایشی پیچیده و پالایش شده می‌شوند:

- فیلترهای مربوط به لایه‌ی اول در مدل (block1\_conv1) به کدگذاری لبه‌های جهت‌دار ساده و رنگ‌ها می‌پردازند (در برخی موارد، لبه‌های رنگی).
- فیلترهای مربوط به بلوک دوم در مدل (block2\_conv1) به کدگذاری بافت‌های ساده‌ی مرکب از لبه‌ها و رنگ‌ها می‌پردازند.
- فیلترهای مربوط به لایه‌های بالاتر شروع به شبیه‌سازی بافت‌های یافته شده در تصاویر طبیعی (مانند پرها، چشم‌ها، برگ‌ها و ...) می‌کنند.

## روش‌های مصورسازی: مصورسازی نقشه‌های گرمایی فعالیت کلاس

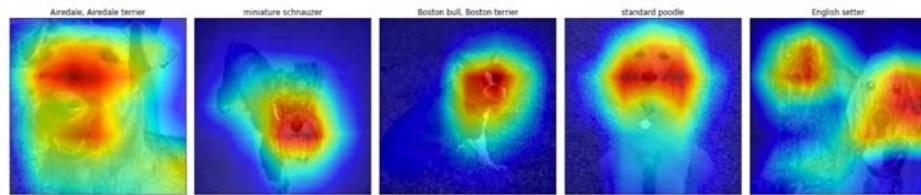
### VISUALIZING HEATMAPS OF CLASS ACTIVATION

#### تکنیک نقشه‌های گرمایی:

به ما کمک می‌کند تا متوجه شویم کدام‌پک از بخش‌های یک تصویر داده شده باعث می‌شود تا یک شبکه‌ی عصبی کانولوشنال تصمیم‌گیری نهایی برای طبقه‌بندی را انجام دهد.

- اشکال‌زدایی از فرآیند تصمیم‌گیری یک convnet (به ویژه در مورد خطای طبقه‌بندی)
- مکان‌یابی اشیای خاص در یک تصویر

کاربردهای  
نقشه‌های گرمایی



## روش‌های مصورسازی: مصورسازی نقشه‌های گرمایی فعالیت کلاس

تصویرسازی نقشه‌ی فعالیت کلاسی

### CLASS ACTIVATION MAP (CAM) VISUALIZATION

رده‌ی عمومی تکنیک‌ها: **تصویرسازی نقشه‌ی فعالیت کلاسی (CAM)**  
تهیی‌ی نقشه‌های گرمایی فعالیت کلاسی بر روی تصاویر ورودی.

یک توری دو-بعدی از امتیاز‌های مرتبط با یک کلاس خروجی خاص،  
که برای هر مکان در هر تصویر ورودی محاسبه می‌شود  
و نشان می‌دهد که هر مکان نسبت به کلاس مورد بررسی چه قدر اهمیت دارد.

**نقشه‌ی فعالیت کلاسی**  
*Class Activation Map (CAM)*

برای نمونه:

با داشتن تصویری که به یک شیکه‌ی بازشناسی سگ/گربه وارد می‌شود،  
تصویرسازی CAM این امکان را می‌دهد که

یک نقشه‌ی گرمایی برای کلاس «گربه» تولید کنیم: نشان‌دهنده‌ی اینکه بخش‌های گربه-مانند تصویر کدام‌ها هستند و  
یک نقشه‌ی گرمایی برای کلاس «سگ» تولید کنیم: نشان‌دهنده‌ی اینکه بخش‌های سگ-مانند تصویر کدام‌ها هستند.



## روش‌های مصورسازی: مصورسازی نقشه‌های گرمایی فعالیت کلاس

تصورسازی نقشه‌ی فعالیت کلاسی: پیاده‌سازی با الگوریتم Grad-CAM

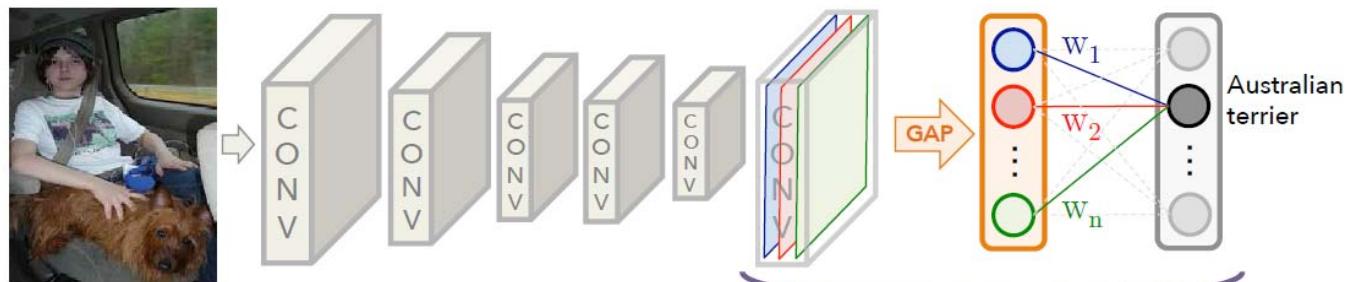
### CLASS ACTIVATION MAP (CAM) VISUALIZATION: GRAD-CAM ALGORITHM

پیاده‌سازی خاص مصورسازی نقشه‌ی فعالیت کلاسی: الگوریتم Grad-CAM:

نقشه‌ی ویژگی خروجی یک لایه‌ی کانولوشنی برای یک تصویر ورودی دریافت می‌شود، هر کanal در آن نقشه‌ی ویژگی به وسیله‌ی گرادیان آن کلاس نسبت به آن کanal وزن دهی می‌شود.

یک نقشه‌ی فضایی، این مسئله که  
 «تصویر ورودی، کانال‌های مختلف را با چه شدتی فعال می‌کند؟»  
 را بر اساس زیر وزن دهی می‌کند:  
 «اهمیت هر کanal در رابطه با هر کلاس چه قدر است»  
 که در نتیجه یک نقشه‌ی فضایی از این کمیت حاصل می‌شود:  
 «تصویر ورودی، آن کلاس را با چه شدتی فعال می‌کند؟»

**Ref:** R.R. Selvaraju, et al. "Grad-cam: Visual explanations from deep networks via gradient-based localization,"  
<https://arxiv.org/abs/1610.02391>, (2016)



### Class Activation Mapping

$$W_1 * \text{Heatmap}_1 + W_2 * \text{Heatmap}_2 + \dots + W_n * \text{Heatmap}_n = \text{Class Activation Map (Australian terrier)}$$

The diagram shows the mathematical representation of the Class Activation Mapping process. It consists of four heatmaps (W1, W2, ..., Wn) and their corresponding activation maps for the "Australian terrier" class. The heatmaps are represented as blue squares with red/orange highlights, and the activation maps are represented as blue squares with yellow/orange highlights. The equation shows the weighted sum of these heatmaps resulting in the final Class Activation Map for the "Australian terrier" class.

## روش‌های مصورسازی: مصورسازی نقشه‌های گرمایی فعالیت کلاس

مثال

:Grad-CAM مثال پیاده‌سازی مصورسازی نقشه‌ی فعالیت کلاسی: الگوریتم

با استفاده از شبکه‌ی پیش‌آموزش دیده‌ی VGG16

### Loading the VGG16 network with pretrained weights

```
from keras.applications.vgg16 import VGG16  
  
model = VGG16(weights='imagenet')
```

Note that you include the densely connected classifier on top; in all previous cases, you discarded it.

## روش‌های مصورسازی: مصورسازی نقشه‌های گرمایی فعالیت کلاس

مثال: تصویر آزمایشی ورودی



تصویر دو فیل آفریقایی

## روش‌های مصورسازی: مصورسازی نقشه‌های گرمایی فعالیت کلاس

مثال: پیش‌پردازش تصویر آزمایشی ورودی

باید تصویر به تصویری تبدیل شود که برای مدل VGG16 قابل خواندن باشد:  
 تصویر را بارگذاری می‌کنیم، اندازه‌ی آن را به  $224 \times 224$  تبدیل می‌کنیم  
 و آن را به یک تانسور ممیزشناور ۳۲ بیتی Numpy تبدیل می‌کنیم.

### Preprocessing an input image for VGG16

```
from keras.preprocessing import image
from keras.applications.vgg16 import preprocess_input, decode_predictions
import numpy as np
```

**Local path to the target image**

```
img_path = '/Users/fchollet/Downloads/creative_commons_elephant.jpg'
```

**Python Imaging Library (PIL)  
image of size 224 × 224**

```
x = image.img_to_array(img) float32 Numpy array of shape (224, 224, 3)
```

```
x = np.expand_dims(x, axis=0) Adds a dimension to transform the array  
into a batch of size (1, 224, 224, 3)
```

```
x = preprocess_input(x) Preprocesses the batch (this does  
channel-wise color normalization)
```

## روش‌های مصورسازی: مصورسازی نقشه‌های گرمایی فعالیت کلاس

مثال: اجرای شبکه روی تصویر آزمایشی

شبکه‌ی پیش‌آموزش دیده را روی تصویر آزمایشی اجرا می‌کنیم و بردار پیش‌بینی آن را در قالب قابل خواندن برای انسان کدگذاری می‌کنیم:

```
>>> preds = model.predict(x)
>>> print('Predicted:', decode_predictions(preds, top=3)[0])
Predicted: [ ('n02504458', 'African_elephant', 0.92546833),
 ('n01871265', 'tusker', 0.070257246),
 ('n02504013', 'Indian_elephant', 0.0042589349)]
```

سه کلاس برتر پیش‌بینی شده برای این تصویر:  
فیل آفریقایی، فیل عاج‌دار، فیل هندی

- African elephant (with 92.5% probability)
- Tusker (with 7% probability)
- Indian elephant (with 0.4% probability)

این شبکه، این تصویر را حاوی تعداد نامعینی فیل آفریقایی بازشناسی کرده است. درایه‌ای در بردار پیش‌بینی که دارای ماکزیمم فعال شدگی است، آن است که متناظر با «فیل آفریقایی» است (در اندیس ۳۸۶).

```
>>> np.argmax(preds[0])
386
```

## روش‌های مصورسازی: مصورسازی نقشه‌های گرمایی فعالیت کلاس

مثال: اجرای فرآیند Grad-CAM

برای مصورسازی بخش‌هایی از تصویر که بیشترین شباهت را به «فیل آفریقایی» دارد، یک فرآیند Grad-CAM را اجرا می‌کنیم.

### Setting up the Grad-CAM algorithm

```

african_elephant_output = model.output[:, 386]           "African elephant" entry in the prediction vector

last_conv_layer = model.get_layer('block5_conv3')          Output feature map of the block5_conv3 layer, the
                                                               last convolutional layer in VGG16

grads = K.gradients(african_elephant_output, last_conv_layer.output)[0] Gradient of the
                                                               "African elephant"
                                                               class with regard to
                                                               the output feature
                                                               map of block5_conv3

pooled_grads = K.mean(grads, axis=(0, 1, 2))             Vector of shape (512,), where each entry is the mean
                                                               intensity of the gradient over
                                                               a specific feature-map channel

iterate = K.function([model.input],                         Lets you access the values of the
                                                               quantities you just defined:
                                                               pooled_grads and the output feature map
                                                               of block5_conv3, given a sample image

                                                               pooled_grads_value, conv_layer_output_value = iterate([x])

for i in range(512):                                     Values of these two quantities, as Numpy
                                                               arrays, given the sample image of two elephants
                                                               conv_layer_output_value[:, :, i] *= pooled_grads_value[i] Multiplies each channel in the
                                                               feature-map array by "how important
                                                               this channel is" with regard to the
                                                               "elephant" class

heatmap = np.mean(conv_layer_output_value, axis=-1)        The channel-wise mean of the resulting feature
                                                               map is the heatmap of the class activation.

```

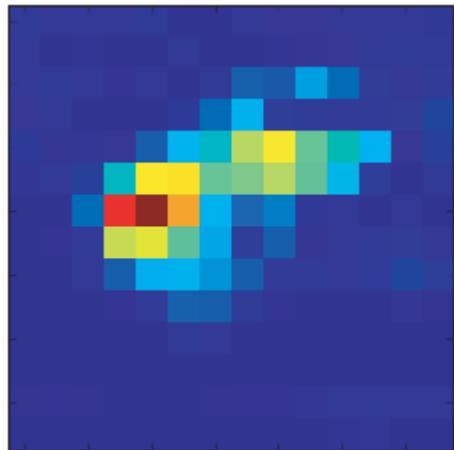
## روش‌های مصورسازی: مصورسازی نقشه‌های گرمایی فعالیت کلاس

مثال: پسپردازش نقشه‌ی گرمایی

به منظور مصورسازی، نقشه‌ی گرمایی را بین صفر و یک نرمال‌سازی می‌کنیم.

### Heatmap post-processing

```
heatmap = np.maximum(heatmap, 0)
heatmap /= np.max(heatmap)
plt.matshow(heatmap)
```



## روش‌های مصورسازی: مصورسازی نقشه‌های گرمایی فعالیت کلاس

مثال: قرار دادن نقشه‌ی گرمایی روی تصویر اصلی

از OpenCV برای تولید تصویری که نقشه‌ی گرمایی را روی تصویر اصلی قرار می‌دهد، استفاده می‌کنیم.

### Superimposing the heatmap with the original picture

```
import cv2
img = cv2.imread(img_path)      Uses cv2 to load the  
original image
heatmap = cv2.resize(heatmap, (img.shape[1], img.shape[0])) Resizes the heatmap to  
be the same size as the  
original image
heatmap = np.uint8(255 * heatmap) Converts the heatmap to RGB
heatmap = cv2.applyColorMap(heatmap, cv2.COLORMAP_JET) Applies the heatmap to  
the original image
superimposed_img = heatmap * 0.4 + img 0.4 here is a heatmap intensity factor.
cv2.imwrite('/Users/fchollet/Downloads/elephant_cam.jpg', superimposed_img) Saves the image to disk
```

## روش‌های مصورسازی: مصورسازی نقشه‌های گرمایی فعالیت کلاس

مثال: قرار دادن نقشه‌ی گرمایی روی تصویر اصلی: نتیجه



## روش‌های مصورسازی: مصورسازی نقشه‌های گرمایی فعالیت کلاس

مثال: قرار دادن نقشه‌ی گرمایی روی تصویر اصلی: نتیجه



این تکنیک مصورسازی به دو پرسش مهم پاسخ می‌دهد:

- چرا شبکه فکر کرده است این تصویر حاوی «فیل آفریقایی» است؟
- فیل آفریقایی در چه مکانی از این تصویر واقع شده است؟

به طور خاص، جالب توجه است که گوش‌های فیل کوچک قوی‌ترین فعال‌شدگی را دارند؛ احتمالاً این دلیلی است که شبکه بر اساس آن می‌تواند بگوید فرق فیل آفریقایی با فیل هندی در چیست.

## یادگیری عمیق برای بینایی کامپیوتوรی

### خلاصه

- ❖ Convnets are the best tool for attacking **visual-classification** problems.
- ❖ Convnets work by learning a **hierarchy of modular patterns and concepts** to represent the visual world.
- ❖ The representations they learn are **easy to inspect**—convnets are the opposite of black boxes!
- ❖ You're now capable of training your own convnet from scratch to solve an image-classification problem.
- ❖ You understand how to use **visual data augmentation** to fight overfitting.
- ❖ You know how to use a pretrained convnet to do **feature extraction** and **fine-tuning**.
- ❖ You can generate **visualizations of the filters** learned by your convnets, as well as **heatmaps** of class activity

یادگیری عمیق برای بینایی کامپیووتری

۵

## منابع

## منبع اصلی

*Deep Learning  
with Python*

FRANCOIS CHOLLET



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

**Chapter 5***Deep learning  
for computer vision***This chapter covers**

- Understanding convolutional neural networks (convnets)
- Using data augmentation to mitigate overfitting
- Using a pretrained convnet to do feature extraction
- Fine-tuning a pretrained convnet
- Visualizing what convnets learn and how they make classification decisions

This chapter introduces convolutional neural networks, also known as *convnets*, a type of deep-learning model almost universally used in computer vision applications. You'll learn to apply convnets to image-classification problems—in particular those involving small training datasets, which are the most common use case if you aren't a large tech company.