



А.Крюков

Машинное обучение в астрофизике

Лекция 4

Светрочные сети



В предыдущих сериях

- Лекция 1. Что такое машинное обучение и сферы его применения в науке.
- Лекция 2. Основные понятия.
- Лекция 3. Метод обратного распространения ошибок.
- Лекция 4. Деревья решений.
- ➔ Лекция 5. Сверточные сети.



Анализ изображений

- Многие данные, в том числе научные, представляют из себя изображения или могут быть представлены в виде изображений.
 - Не обязательно это должны быть 2-х мерные картинки.
- Примеры научных изображений:
 - фотографии звездного неба;
 - данные с трековых детекторов частиц (3-х мерные «изображения»);
 - данные черенковских атмосферных телескопов;
 - поля температур в метеорологии



Анализ изображений

- Задачи анализа изображений
 - поиск и выделение объектов
 - например, треков частиц в детекторах.
 - извлечение физических характеристик явления
 - например, энергия космических лучей.
 - моделирование изображений
 - например, как замена Монте-Карло моделирования явлений.
 - предсказание поведения системы
 - например, фазовые переходы в физике твердого тела
 - чистка изображений от помех и/или восстановление недостающих участков
 - например, чистка случайных помех на фотографиях с длиной выдержкой в астрономии.



Полносвязанные сети и задачи анализа изображений

- Полносвязанные сети игнорируют информацию о расстоянии между элементами изображений.
 - как правило, соседние элементы в изображении сильнее скорелированы, чем далекие.
- Полносвязанные сети не учитывают симметрии, присущие изображениям.
 - трансляционная инвариантность - параллельный сдвиг объекта на изображении
- Глубокие и большие полносвязанные сети имеют огромное количество параметров
 - требуют большой объем оперативной памяти, повышенные требования в ЦПУ
 - повышенные требования к процедуре обучения
 - проблема недообучения и переобучения.




Сверточные сети

- Частично, все эти проблемы удастся решить при помощи сверточных нейронных сетей (Convolutional neural network, CNN)
- Основная идея — это применить к отдельным частям изображения одну и ту же небольшую матрицу — операция свертки.
- Достоинства:
 - требуется гораздо меньше параметров
 - учитывается трансляционная инвариантность
 - повышается устойчивость обучения
- Полносвязанные слои в нейронной сети по-прежнему используются в качестве классификатора или регрессора



Сверточный слой


- Изображение, как правило имеет вид $W \times H \times D$ матрицы, где W — ширина изображения в пикселях, H — высота, а D глубина. Например цветная VGA картинка имеет размер $640 \times 480 \times 3$.
- Каждый пиксел — это либо целое, либо действительное число в некотором диапазоне





Сверточный слой

- Изображение, как правило имеет вид $W \times H \times D$ матрицы, где W — ширина изображения в пикселях, H — высота, а D глубина. Например цветная VGA картинка имеет размер $640 \times 480 \times 3$.
- Каждый пиксел — это либо целое, либо действительное число в некотором диапазоне
- Добавим фильтр, например $5 \times 5 \times 3$, который мы будем двигать по изображению и выполнять операцию всертки.



Сверточный слой

- Операция конволютивной свертки это скалярное произведение кусочка изображения и фильтра:



$$\mathbf{y} = \mathbf{W}^T * \mathbf{x} + \mathbf{b}$$

- Или покомпонентно

$$y_{i,j}^l = \sum_{-d \leq a,b \leq d} W_{a,b} x_{i+a,j+b}^l$$

- Потом применяется нелинейная функция активации, которая почти всегда ReLU


$$z_{i,j}^l = h(y_{i,j}^l)$$





Сверточный слой


- Последовательно проходим по всему изображению





Сверточный слой


- Последовательно проходим по всему изображению





Сверточный слой


- Последовательно проходим по всему изображению





Сверточный слой

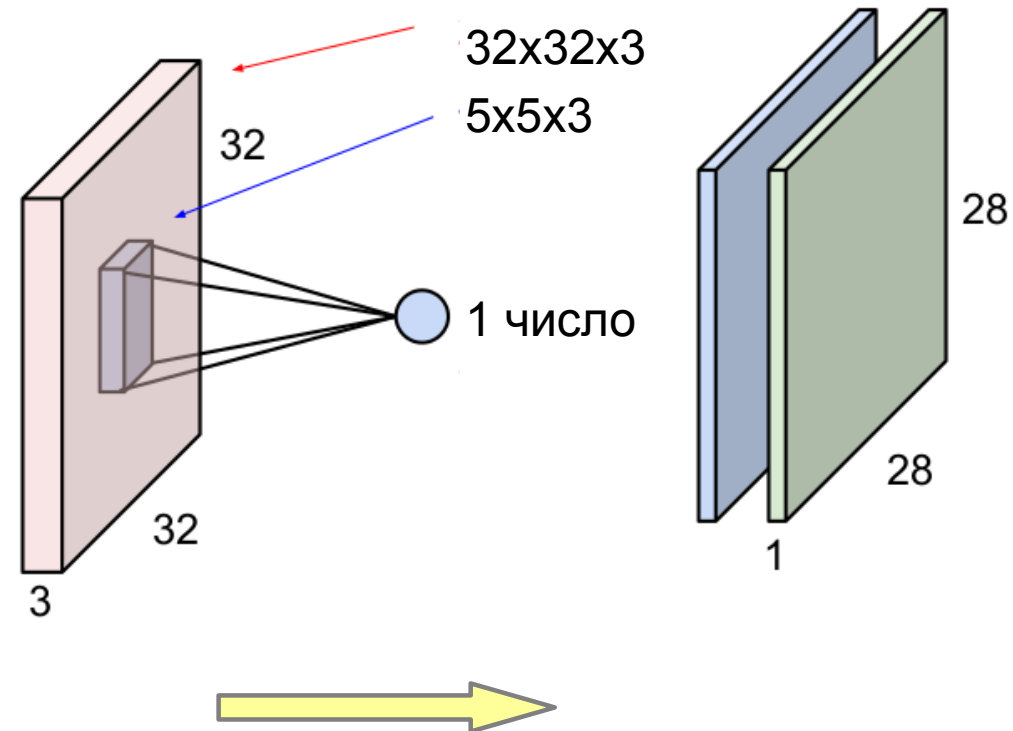
- Таким образом наше входное изображение отображается на более компактное изображение.





Сверточный слой


- Если мы возьмем два разных фильтра, то получим две разные карты активации.





Сверточный слой

- Таких карт может быть любое количество.






Сверточный слой

Что это нам дает?

- Устойчивость к переносам (трансляционная инвариантность) и т.п.
- И радикально сокращает число весов.
- По сути, свёрточная структура – это такая радикальная форма регуляризации





Сверточный слой

- Как сохранить размер картинки?
 - Добавим дополнительные нулевые пиксели вокруг - padding
 - Это позволит посчитать свертки и для граничных пикселей изображения.
- Какие еще есть варианты работы с фильтрами?
 - Сдвигать фильтр не на 1 пиксель, а на несколько — stride

0	0	0	0	0	0			
0								
0								
0								
0								



Сверточный слой

- Как сохранить размер картинки?
 - Добавим дополнительные нулевые пиксели вокруг - padding
 - Это позволит посчитать свертки и для граничных пикселей изображения.
- Какие еще есть варианты работы с фильтрами?
 - Сдвигать фильтр не на 1 пиксель, а на несколько — stride

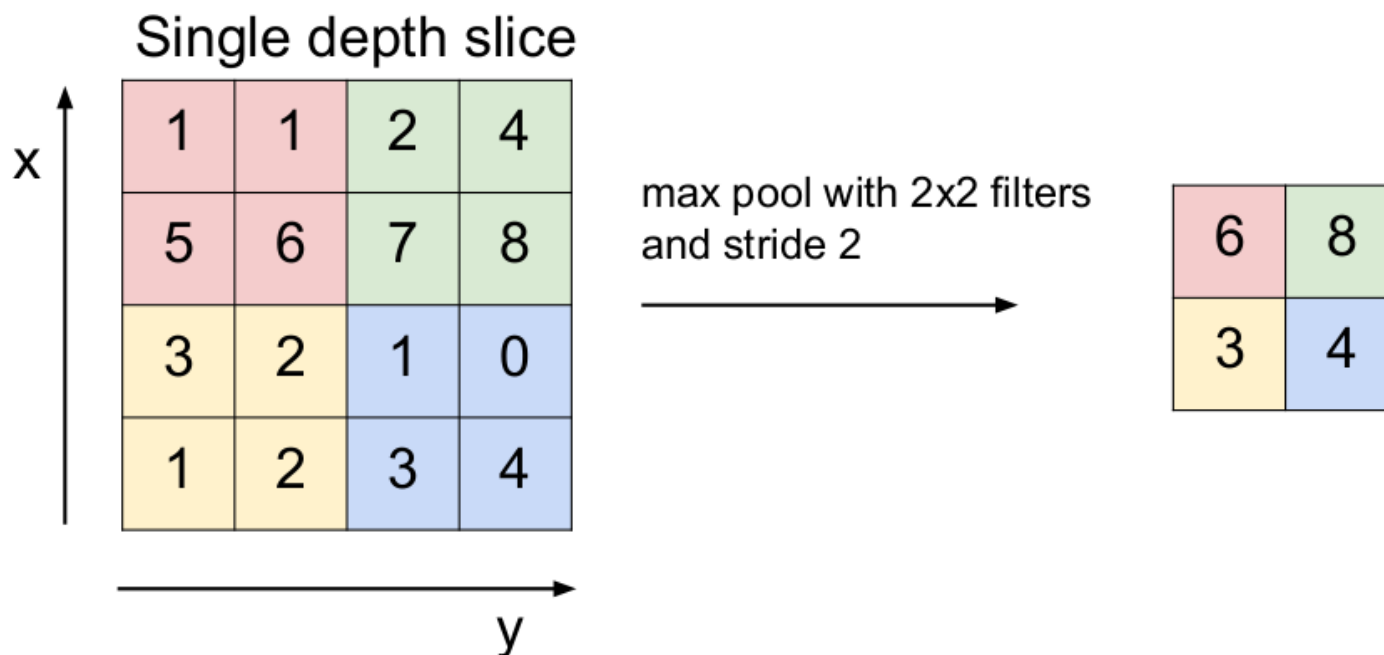
0	0	0	0	0	0			
0								
0								
0								
0								



Max pooling

- Обычно после сверточного слоя идет слой «max pooling».
 - Его задача уменьшить размер изображения:

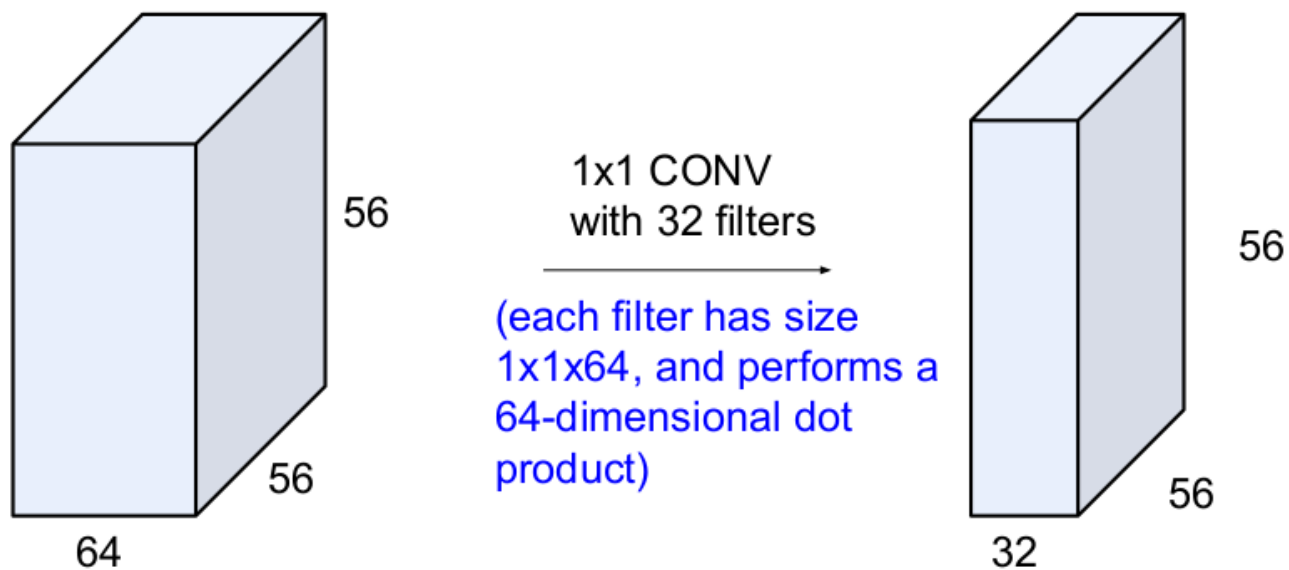
$$x_{i,j}^{l+1} = \max_{-d \leq a, b \leq d} z_{i+a, j+b}^l$$





1x1 свертки

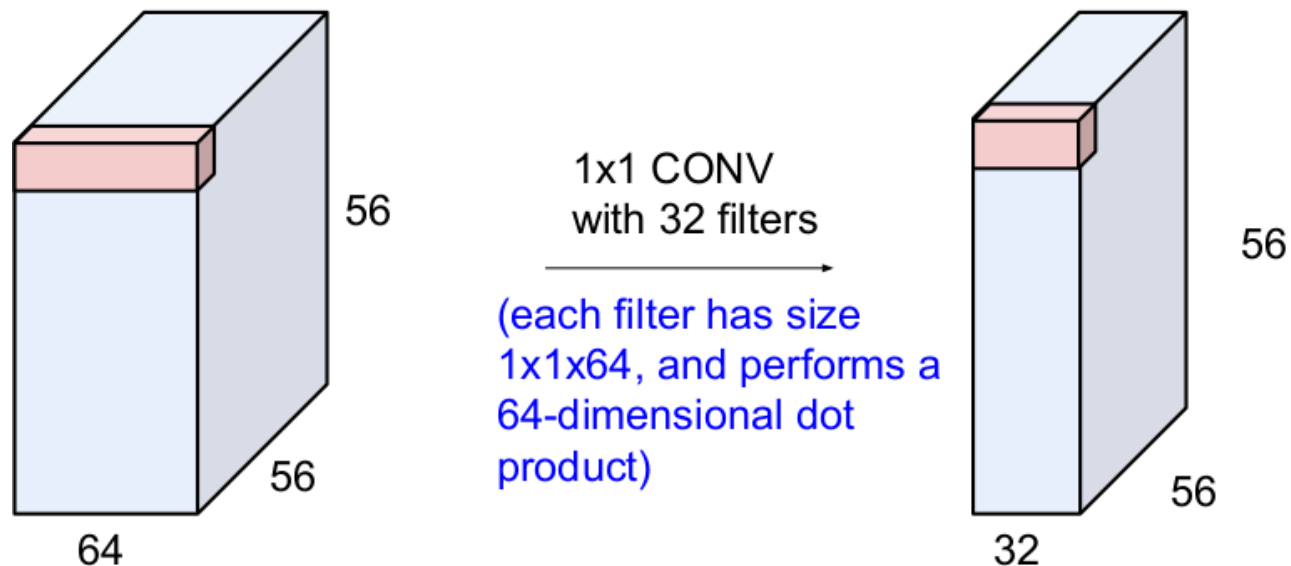
- Задача уменьшения размера изображения может быть решена с помощью 1x1 свертки





1x1 свертки



- Задача уменьшения размера изображения может быть решена с помощью 1x1 свертки





Сверточные архитектуры. VGG


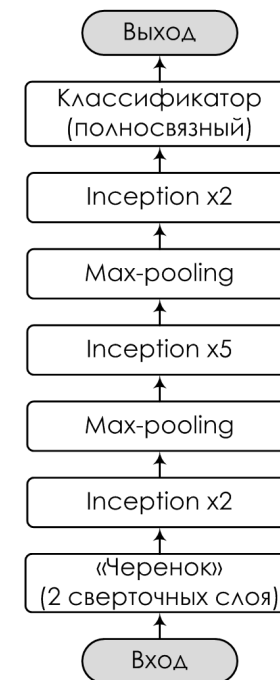
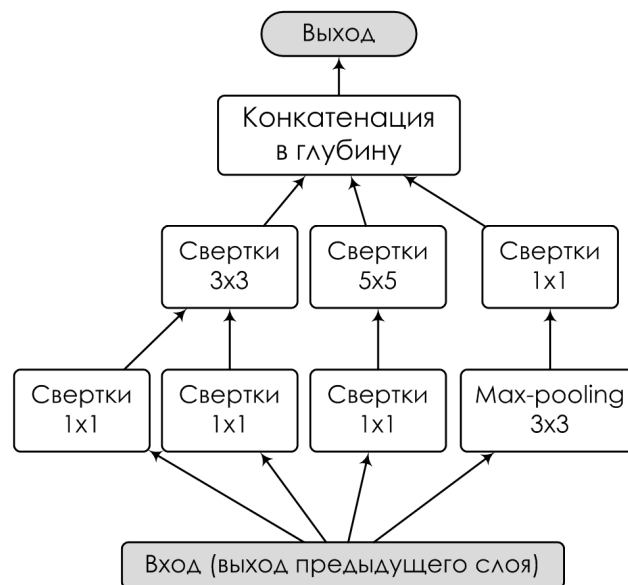
- VGG (Oxford Visual Geometry Group):
большие свёртки представляются как комбинации свёрток 3×3 .
 - снижает число весов, но делает сеть глубже.





Сверточные архитектуры. Inception

- Inception, разработанная командой GoogLeNet:
“сеть в сети” (network in network)
 - сократить число весов ещё больше
 - сократить дополнительные классификаторы
- Во второй версии (2015) свёртки $n \times n$ заменили на комбинации свёрток $n \times 1$ и $1 \times n$





Сверточные архитектуры. RESNET

- Остаточное обучение (residual learning):
 - будем обучать разности между очередным уровнем и предыдущим.
 - Тогда градиенты смогут беспрепятственно проходить дальше.

- Функция, реализуемая остаточным блоком, выглядит как


$$\mathbf{y}^{(k)} = F(\mathbf{x}^{(k)}) + \mathbf{x}^{(k)},$$

- где $\mathbf{x}^{(k)}$ — входной вектор слоя k , $F(\mathbf{x}^{(k)})$ — функция, которую вычисляет слой нейронов, а $\mathbf{y}^{(k)}$ — выход остаточного блока, который потом станет входом следующего слоя $\mathbf{x}^{(k+1)}$.
- Градиент будет проходить через этот блок беспрепятственно и не будет затухать:


$$\frac{\partial \mathbf{y}^{(k)}}{\partial \mathbf{x}^{(k)}} = 1 + \frac{\partial F(\mathbf{x}^{(k)})}{\partial \mathbf{x}^{(k)}}.$$




Варианты RESNET



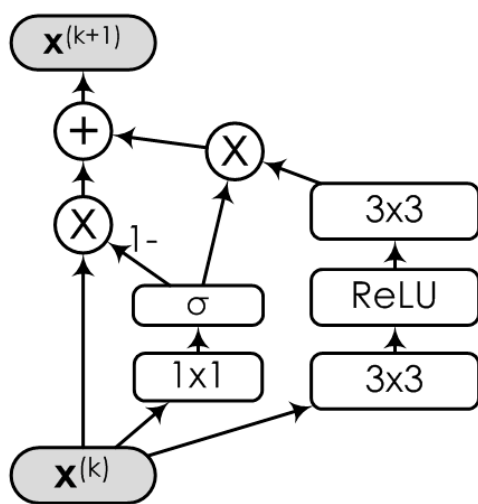
(a)




(b)




(б)



(г)



(Δ)




(e)




Рост глубины сверточных сетей

AlexNet, 8 layers
(ILSVRC 2012)



VGG, 19 layers
(ILSVRC 2014)



GoogleNet, 22 layers
(ILSVRC 2014)



ResNet, 152 layers
(ILSVRC 2015)





Материалы лекций:

https://theory.sinp.msu.ru/doku.php/ml_lectures