Лаборатория компьютерной
графики и мультимедиа
ВМК МГУ имени М.В. Ломоносова

Курс «Компьютерное зрение»

«Базовые свёрточные архитектуры»

Антон Конушин и Тимур Мамедов

2025 год

План лекции

- Визуализация работы нейросети
- Понятие о нейросетевых признаках и базовых моделях
- AlexNet, VGG, Inception
- ResNet-модели и SkipConnections, репараметризация
- Как обучить мощную модель?
- Архитектуры для мобильных моделей
- Насколько хороша ImageNet?

Визуализация работы нейросети

Что происходит внутри сети?

Мы умеем обучать нейросеть для классификации изображений

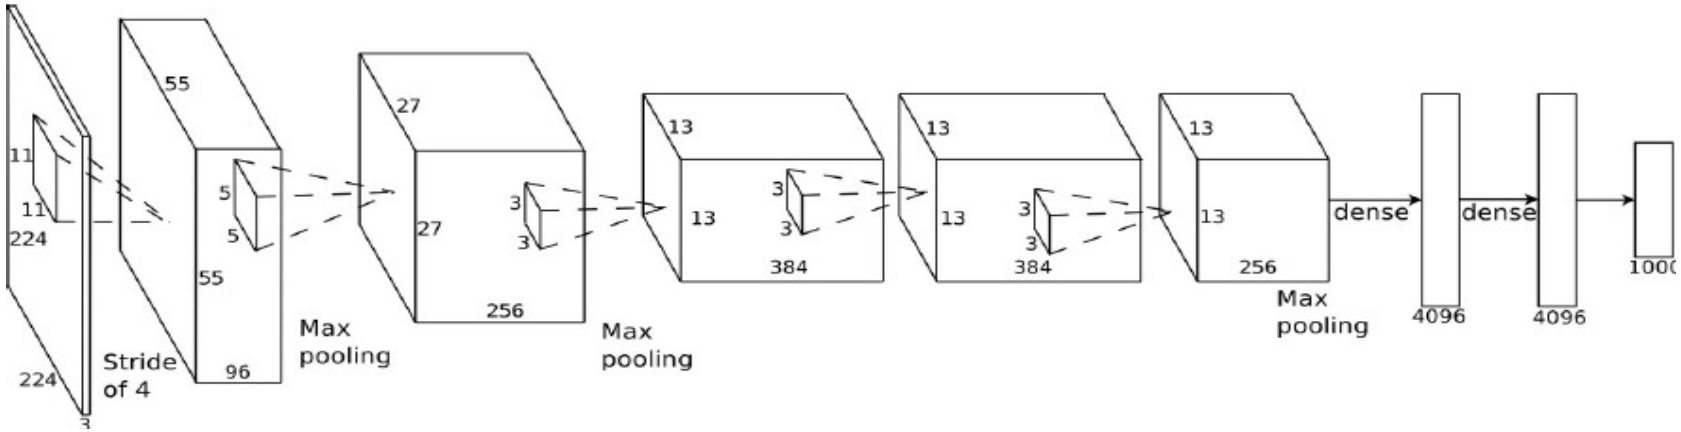

Что происходит внутри неё? Что будем визуализировать?

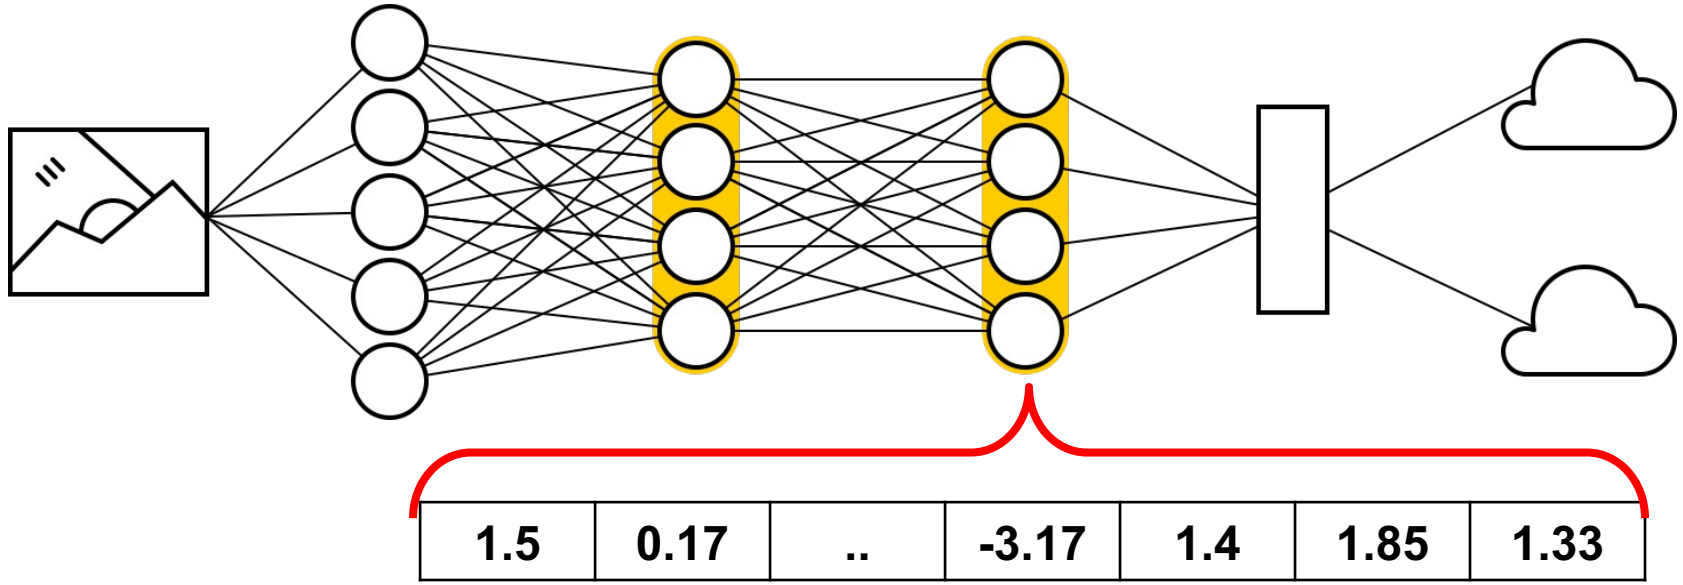

Визуализация работы нейросети

Визуализация фильтров

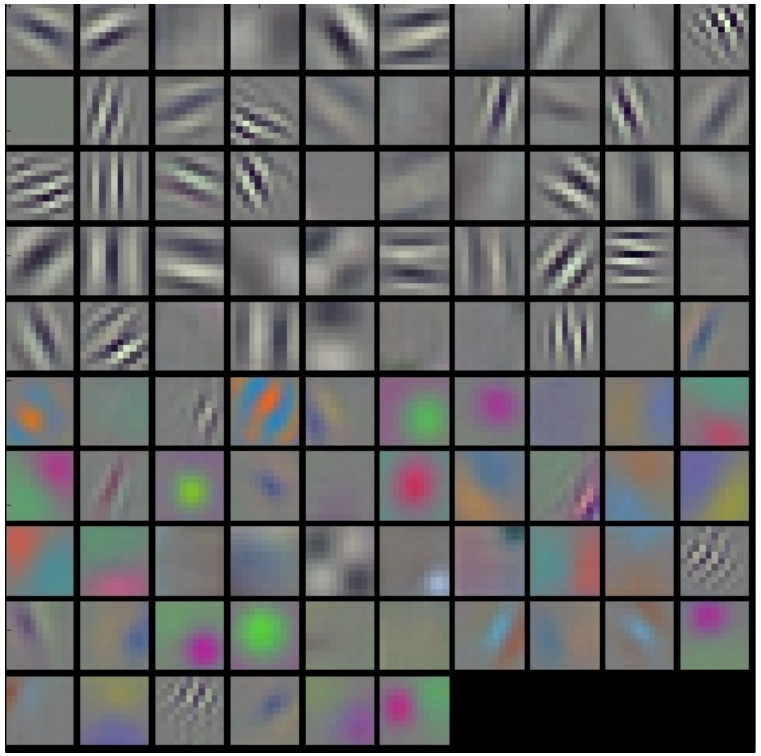

Слой conv1

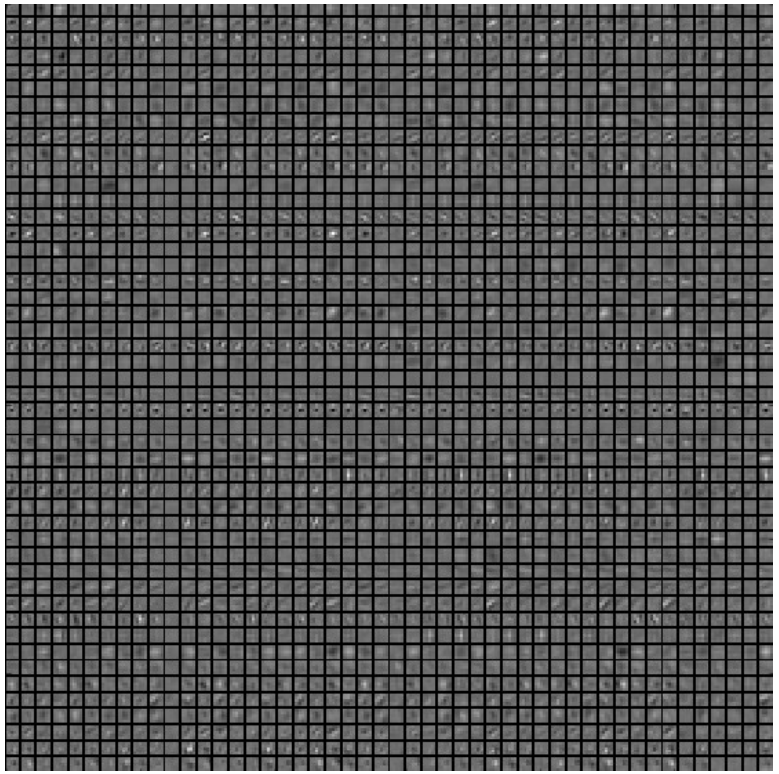

Слой conv2

http://cs231n.github.io/understanding-cnn/

Рецептивное поле и визуализация

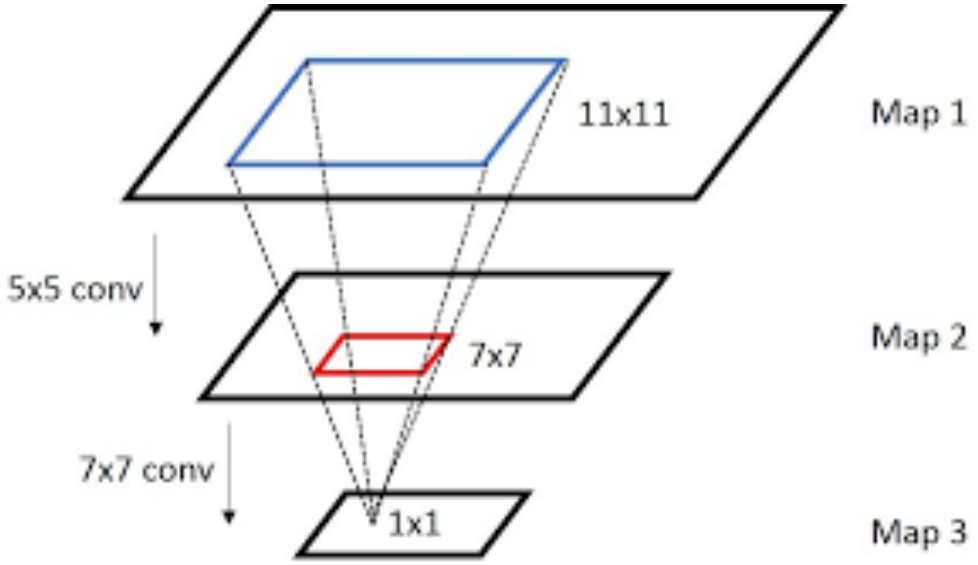

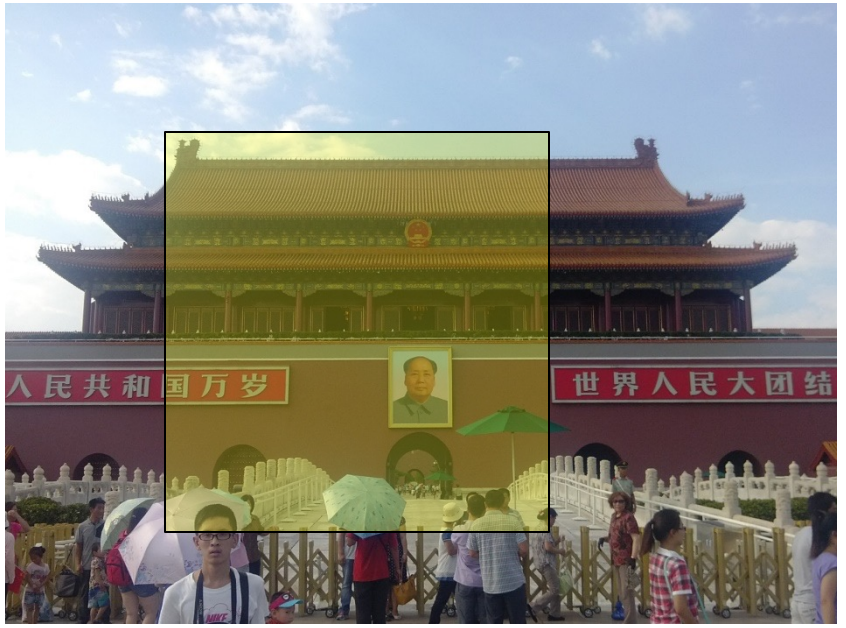

- Напоминание – рецептивное поле, это область изображения, от которой зависит выход этого нейрона
- Запишем, какие фрагменты вызывают наиболее сильный отклик конкретного нейрона сети

Слой 1: Top-9 фрагментов

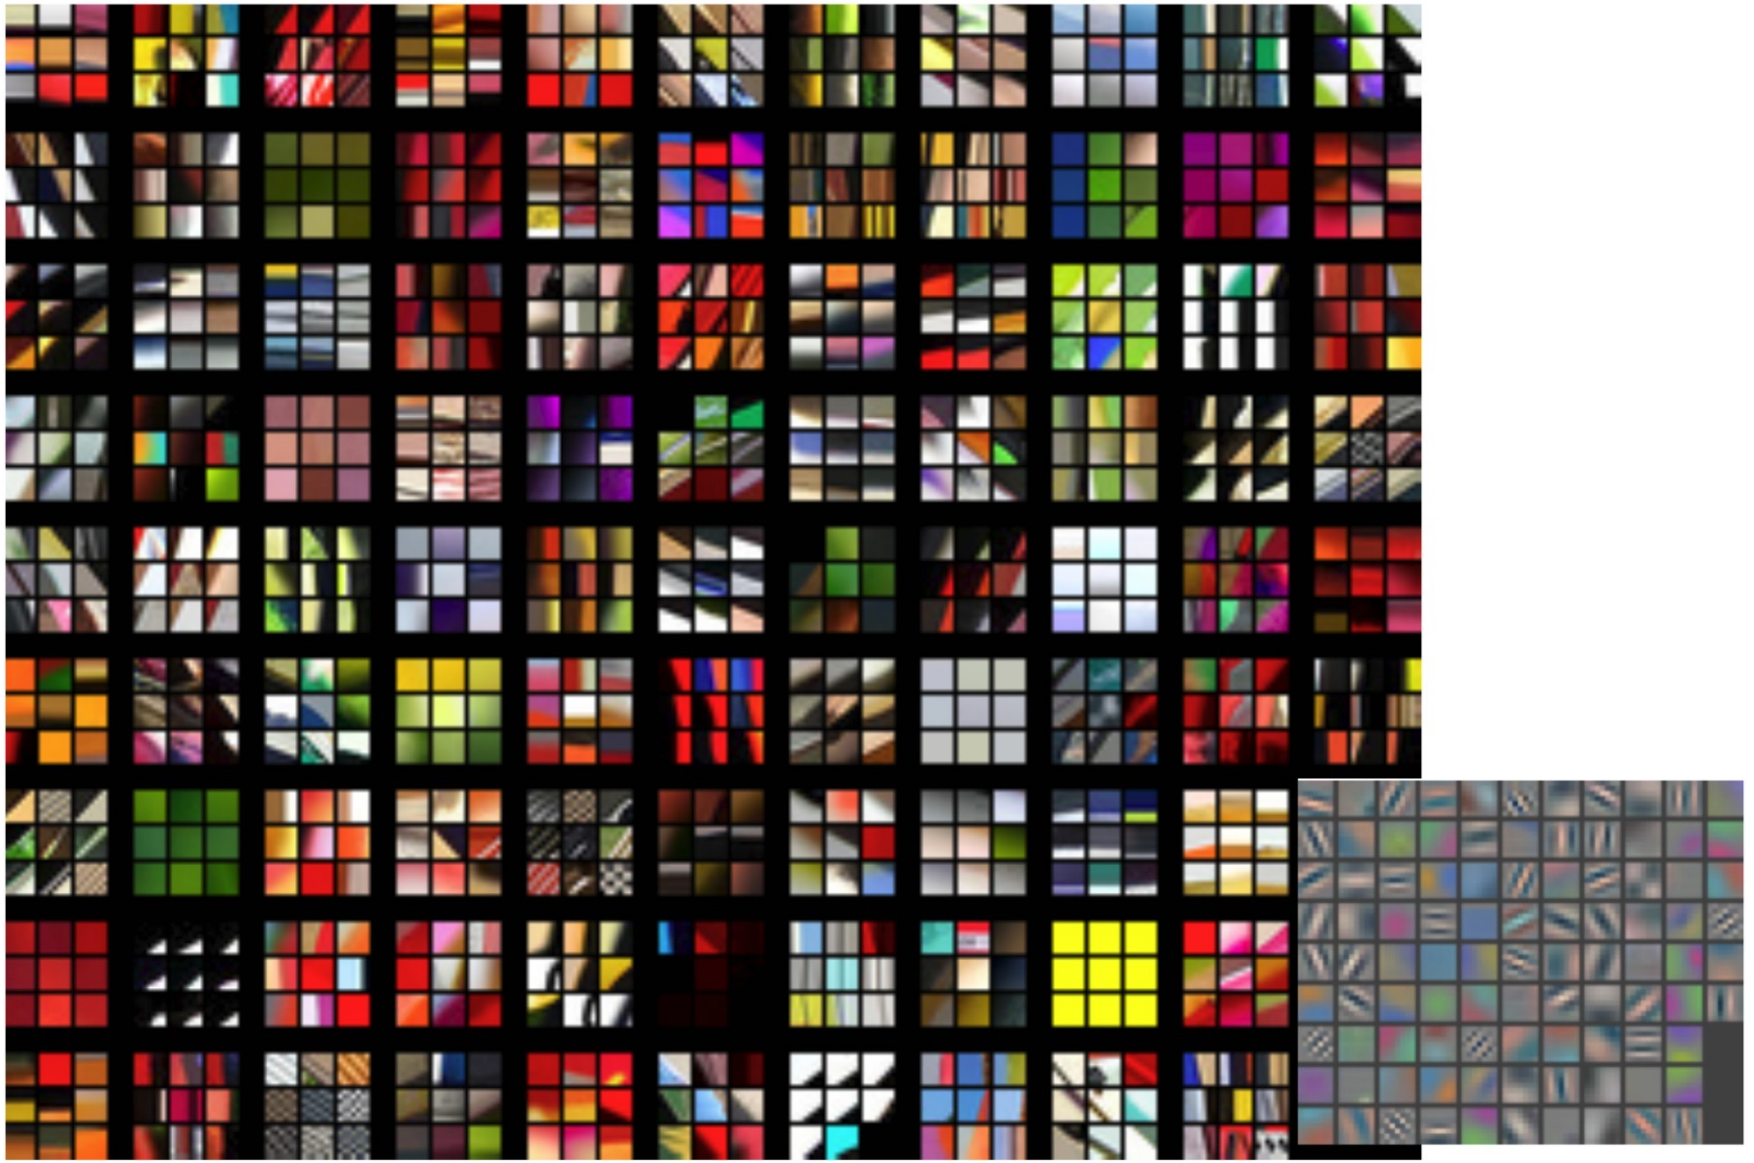

Слой 2: Топ-9 фрагментов

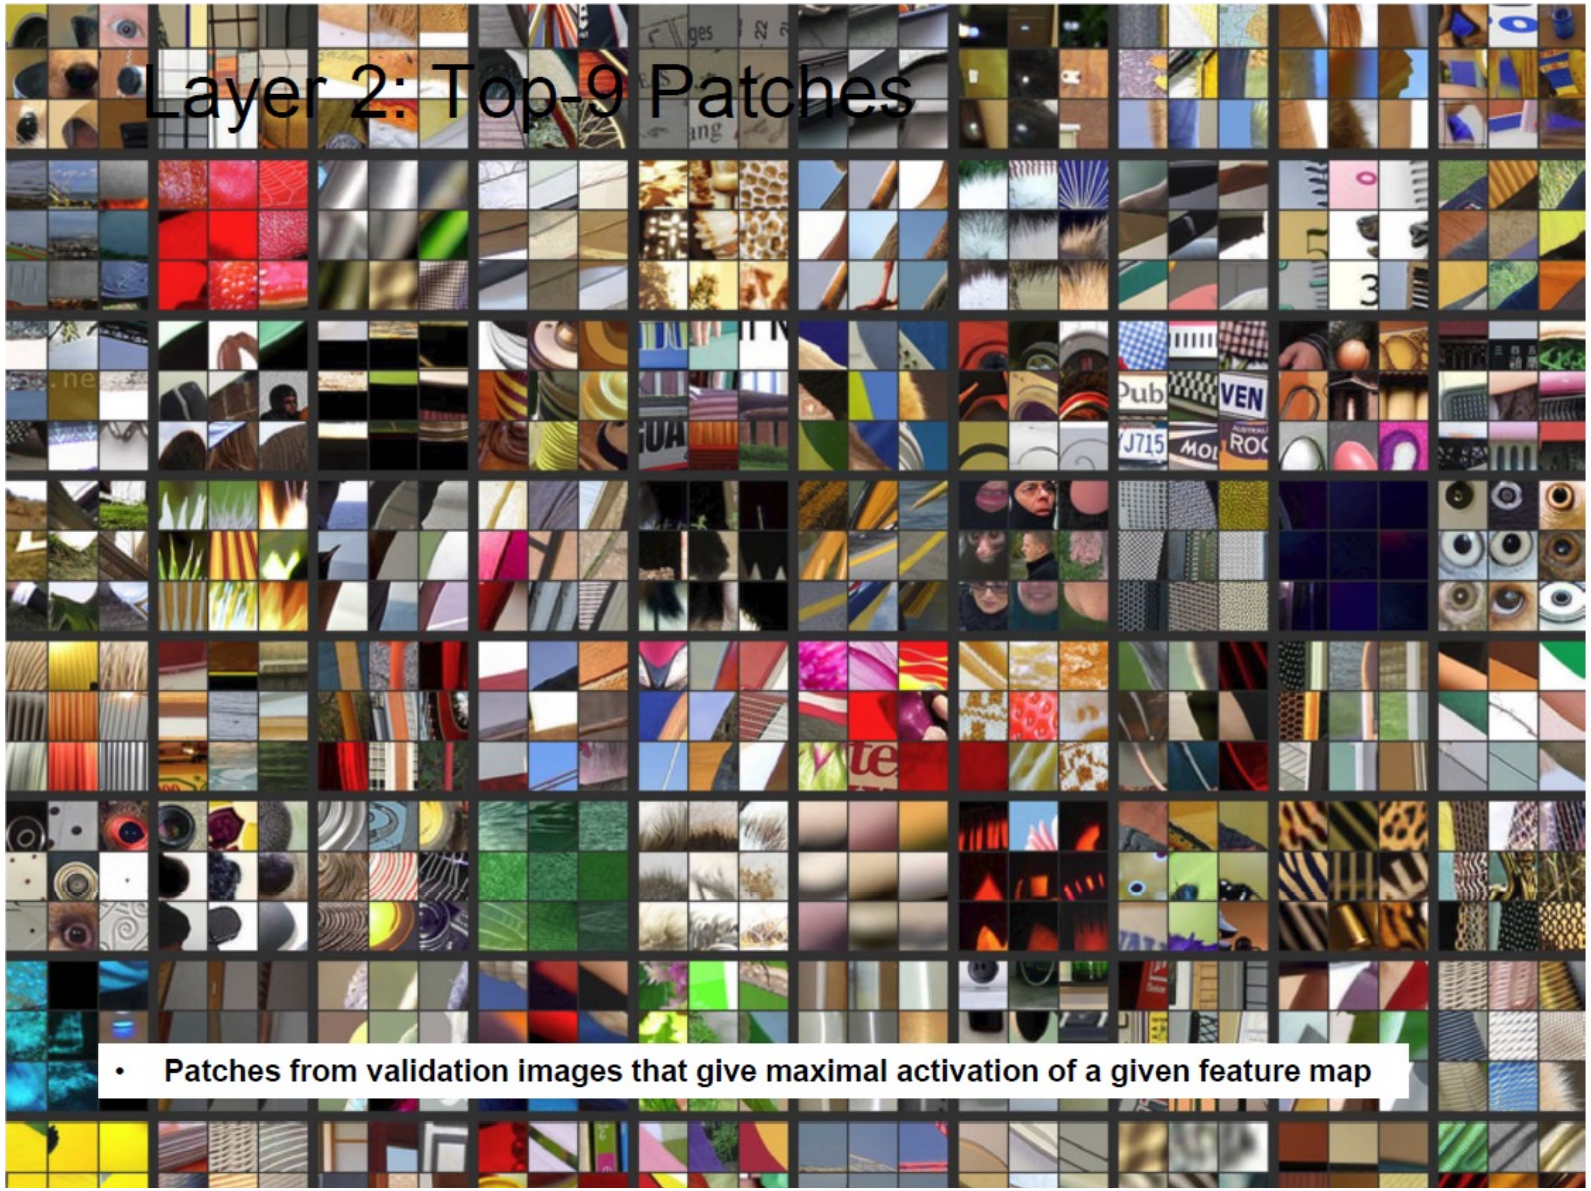

Слой 3: Топ-9 фрагментов

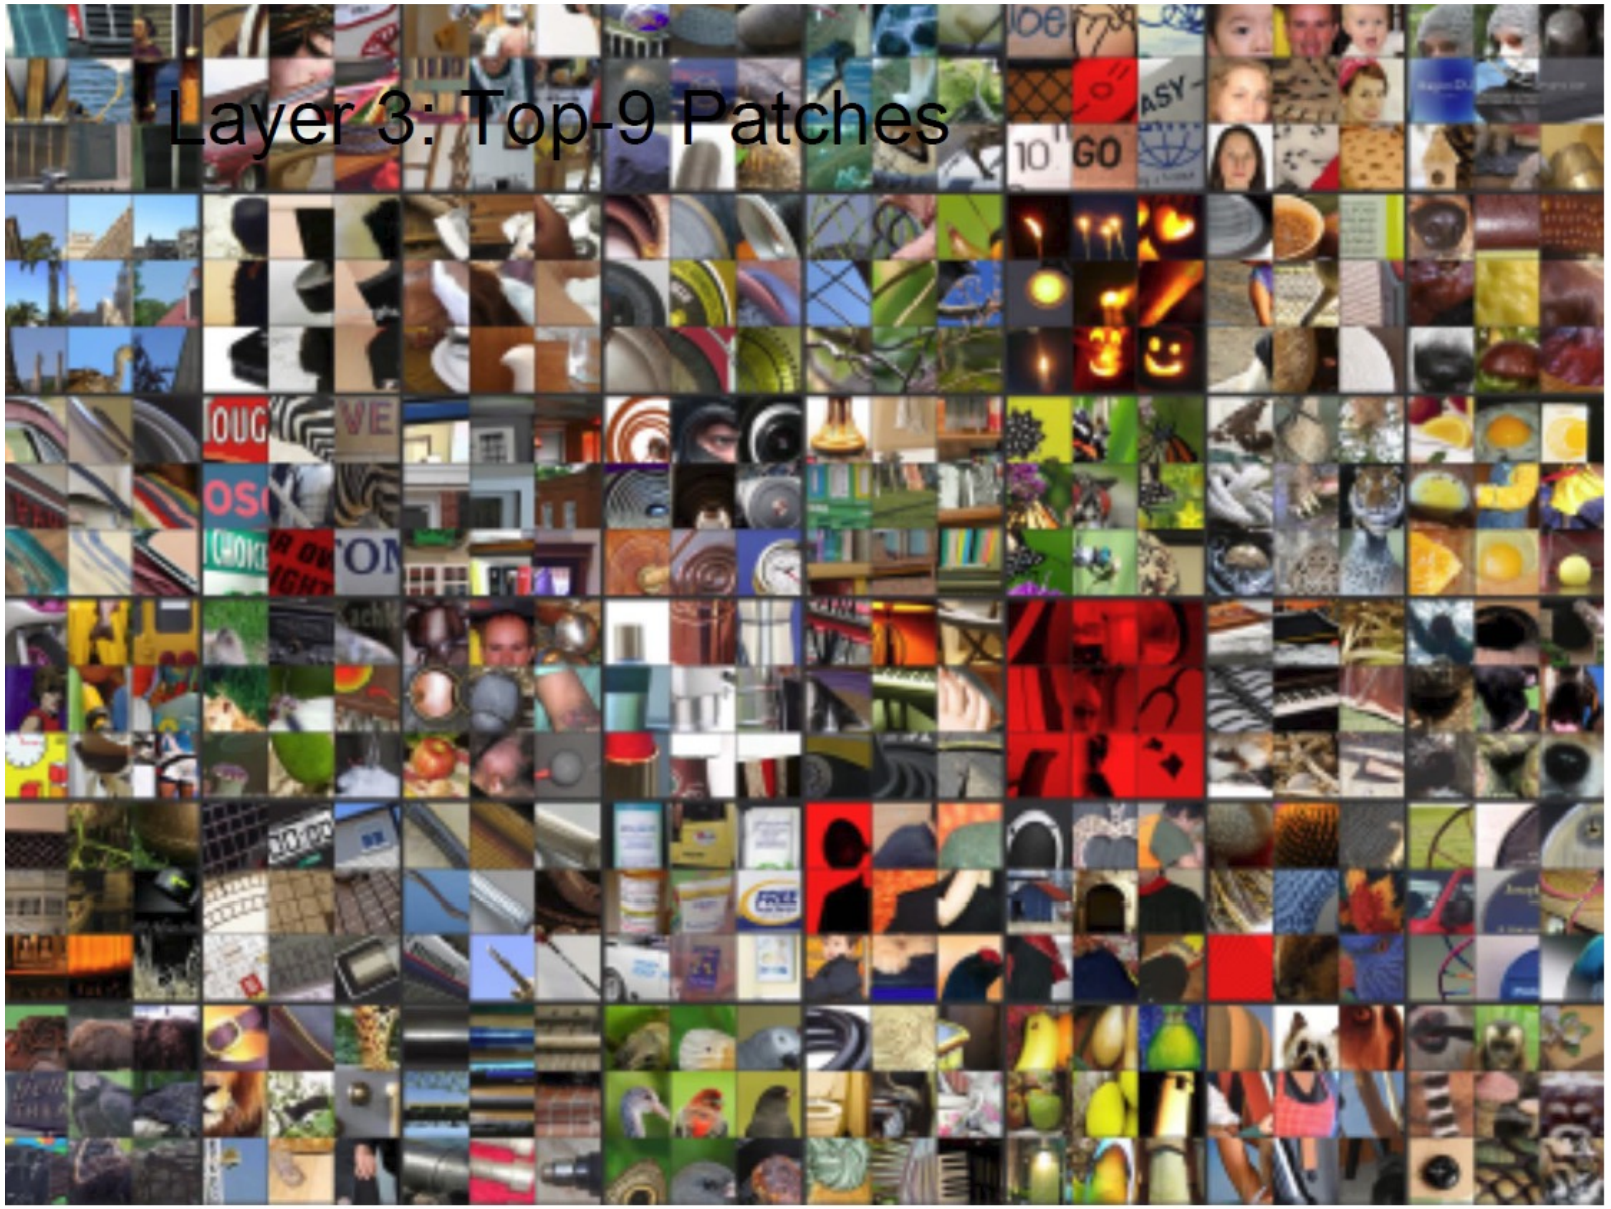

Слой 4: Топ-9 фрагментов

Слой 5: Топ-9 фрагментов

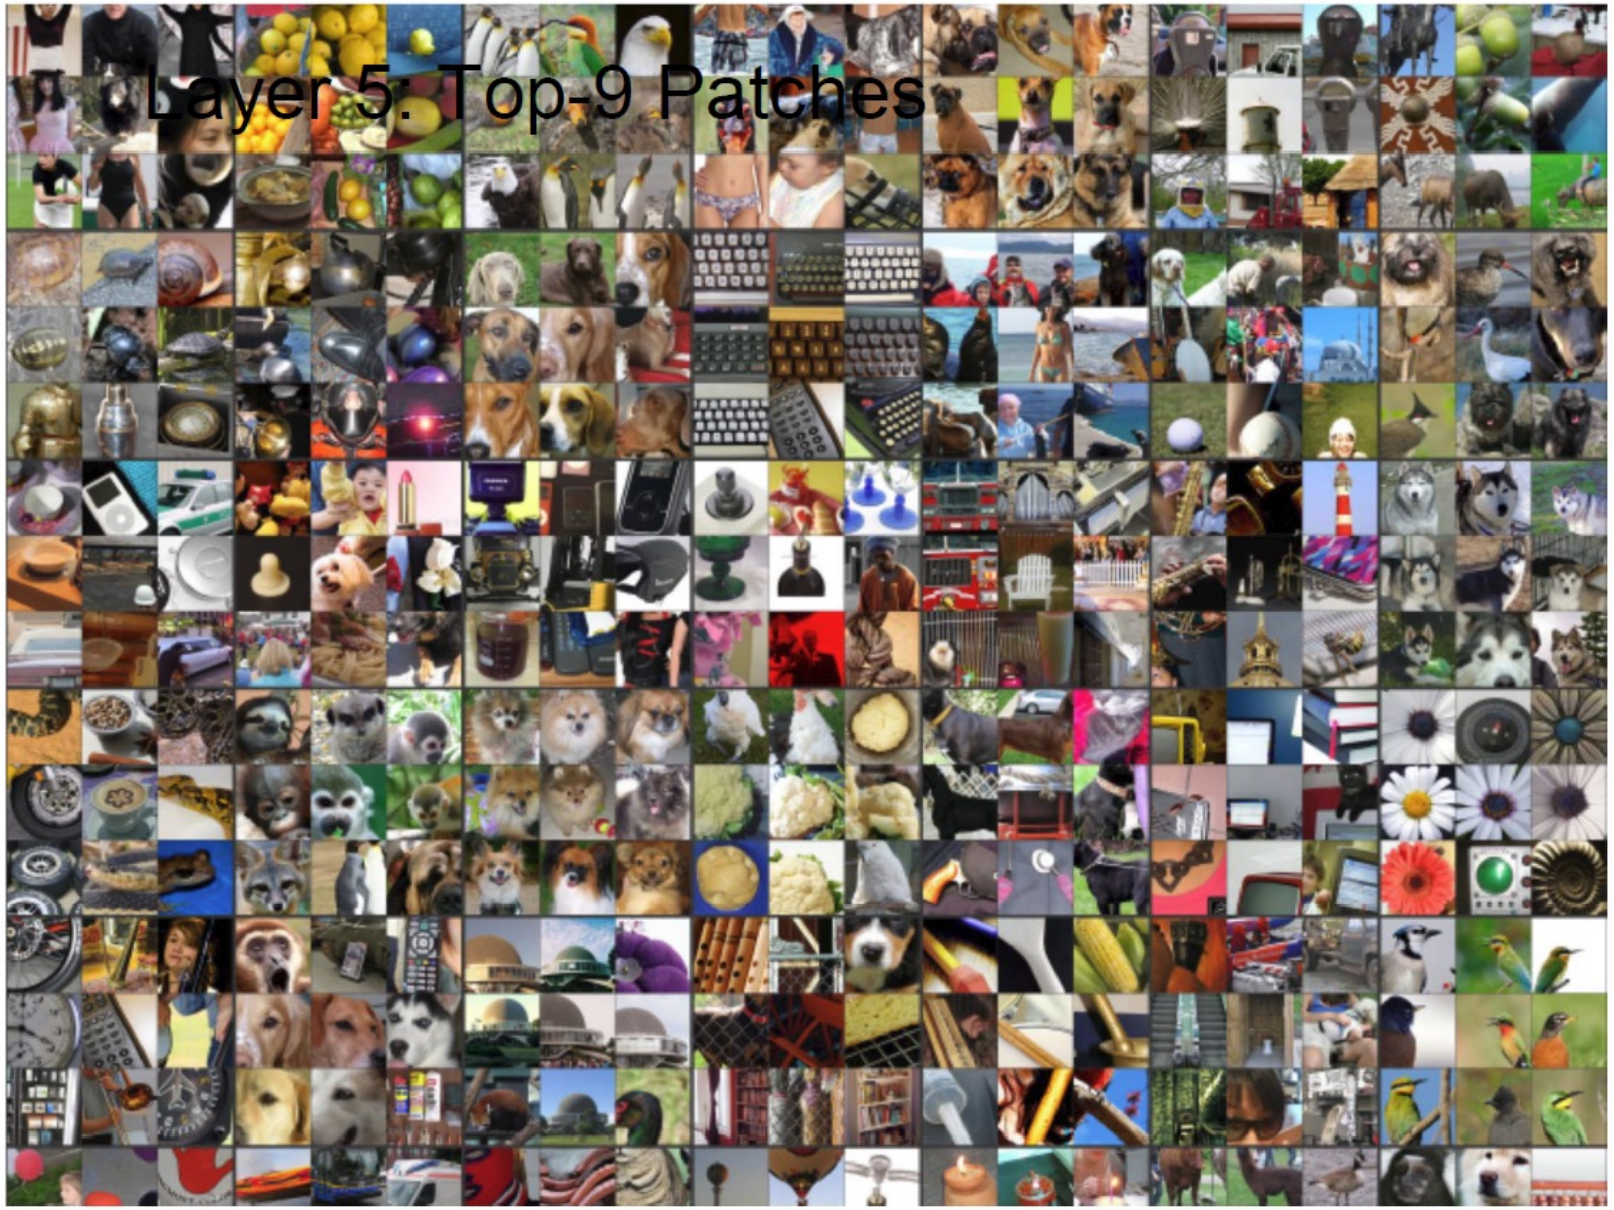

Визуализация работы нейросети

Изображения, на которых достигается максимальный отклик фильтра

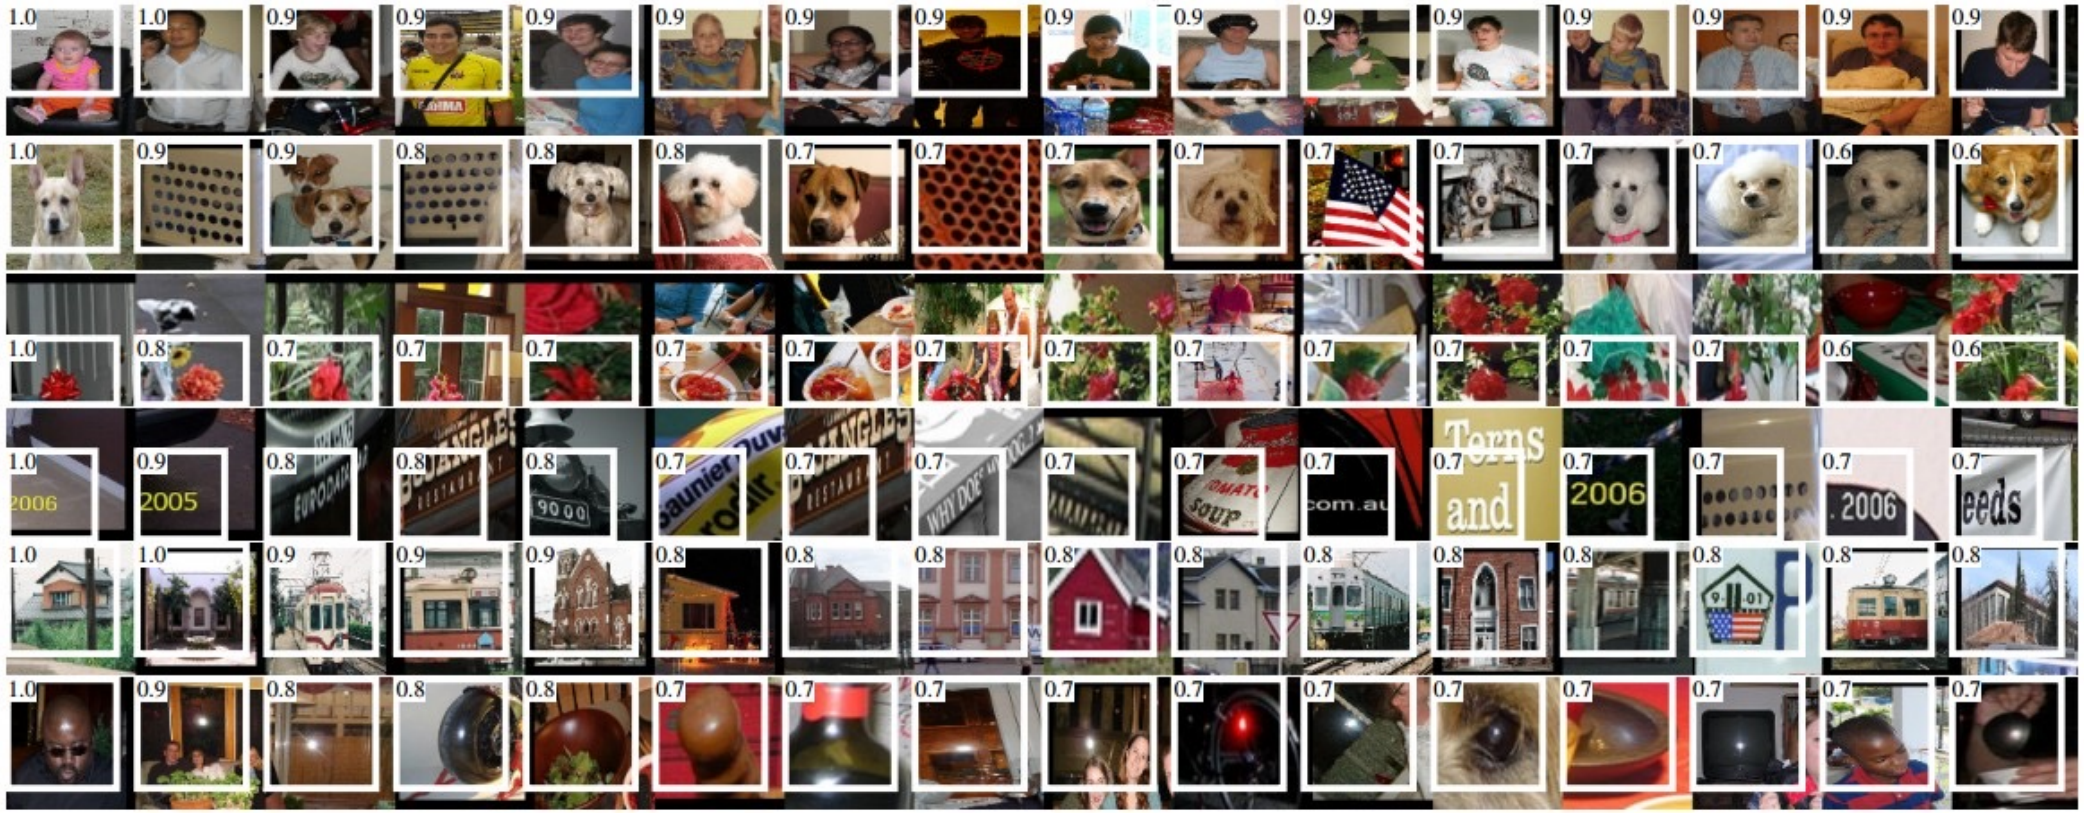

Фильтры слоя pool5

http://cs231n.github.io/understanding-cnn/

Эволюция признаков

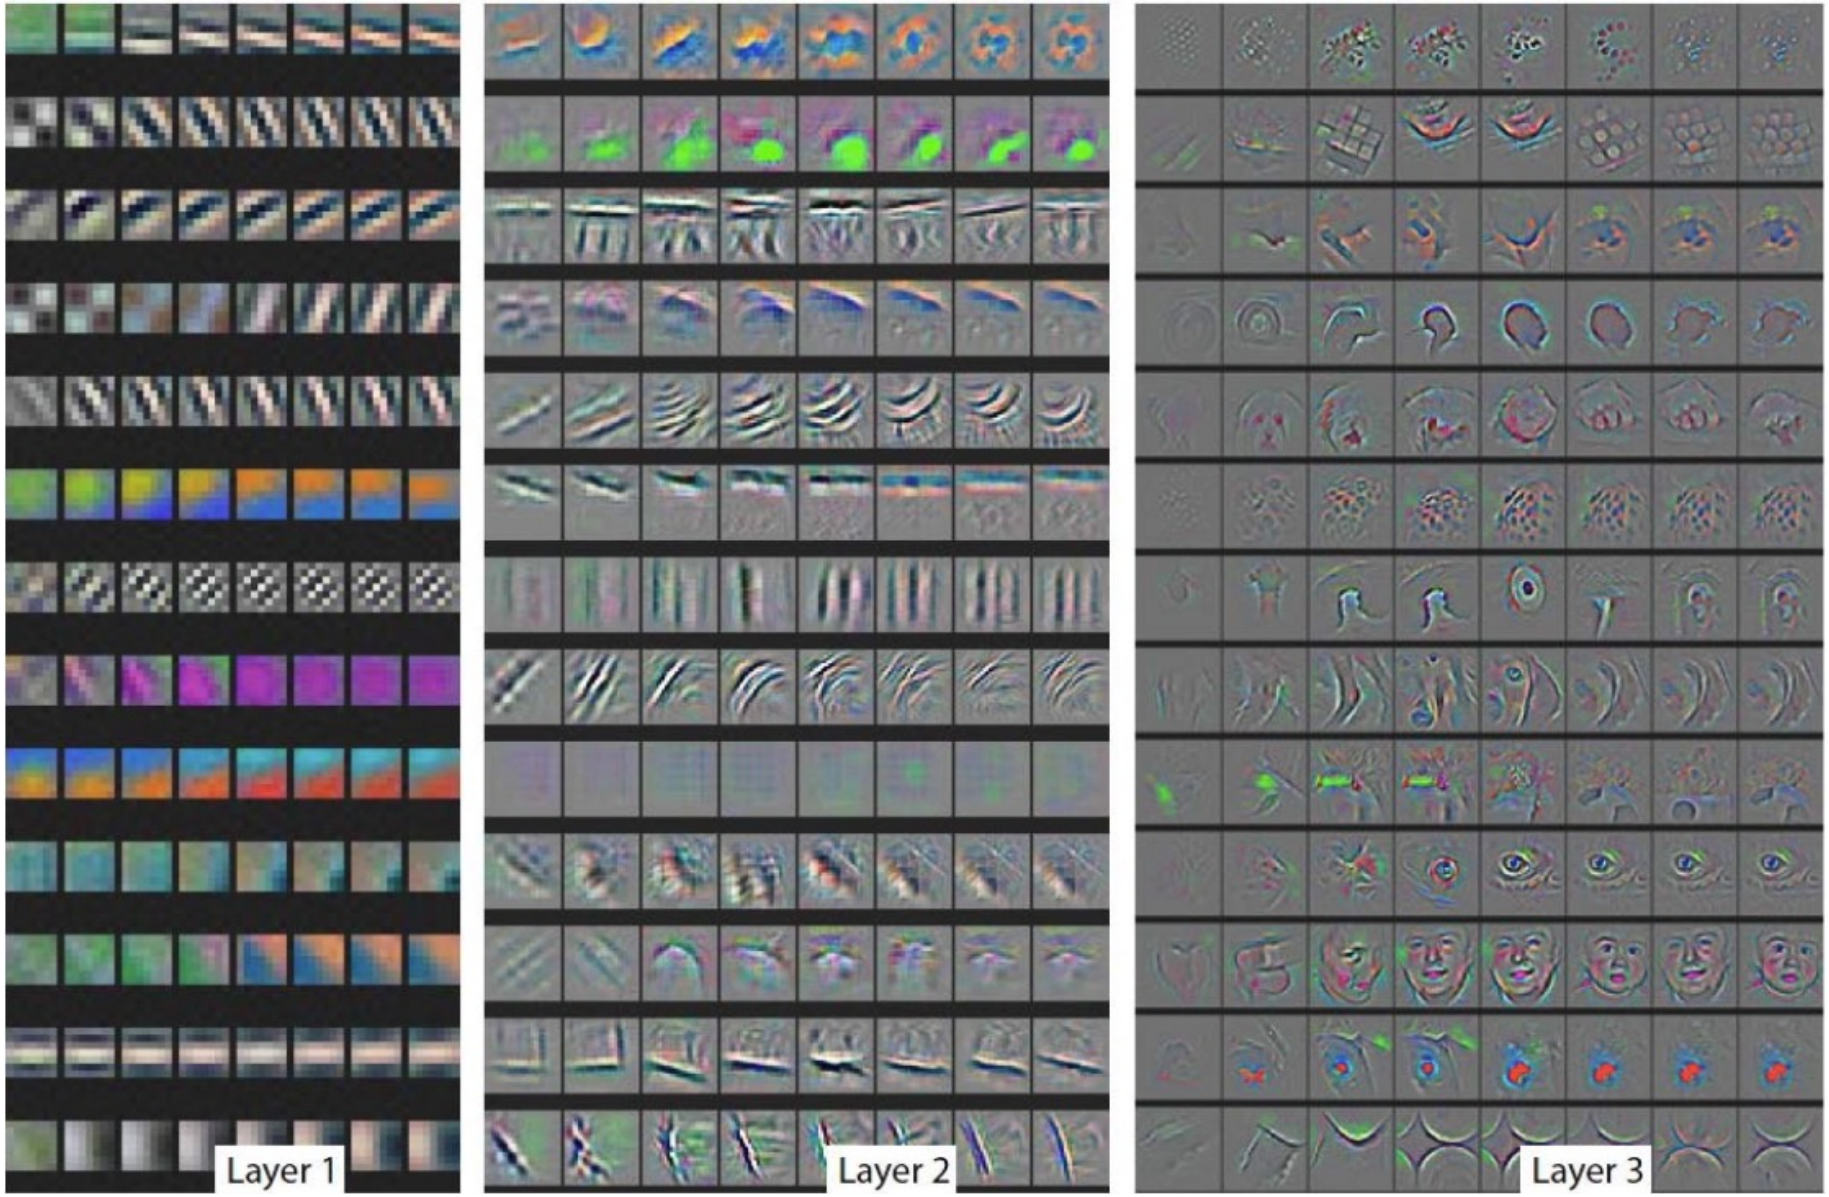

Выход слоя как вектор-признак

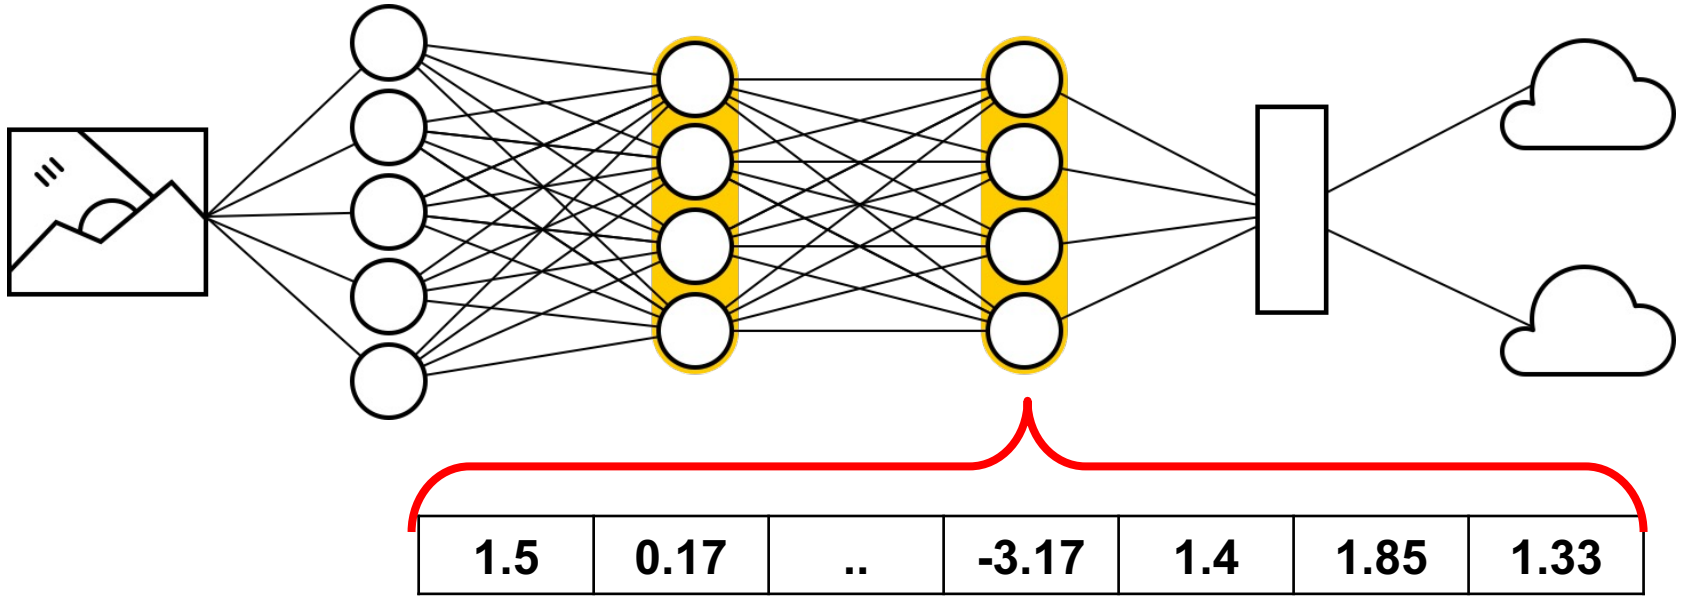

- Мы увидели, что отдельные нейроны каждого слоя несут важное семантическое значение
- Совокупность выходов слоя можно рассматривать как вектор-признак изображения
- Есть способы анализа вектор-признаков в совокупности

t-SNE

- Можем вычислить L2 расстояние между выходами full6 или full7 слоёв
- Воспользуемся отображением точек из 4096-мерного пространства на 2х мерное, сохраняющее L2 расстояния (приближенно)
- Визуализируем изображения
- Видим, что близкие по смыслу изображения оказываются близки друг к другу

http://cs.stanford.edu/people/karpathy/cnnembed/

UMAP визуализация

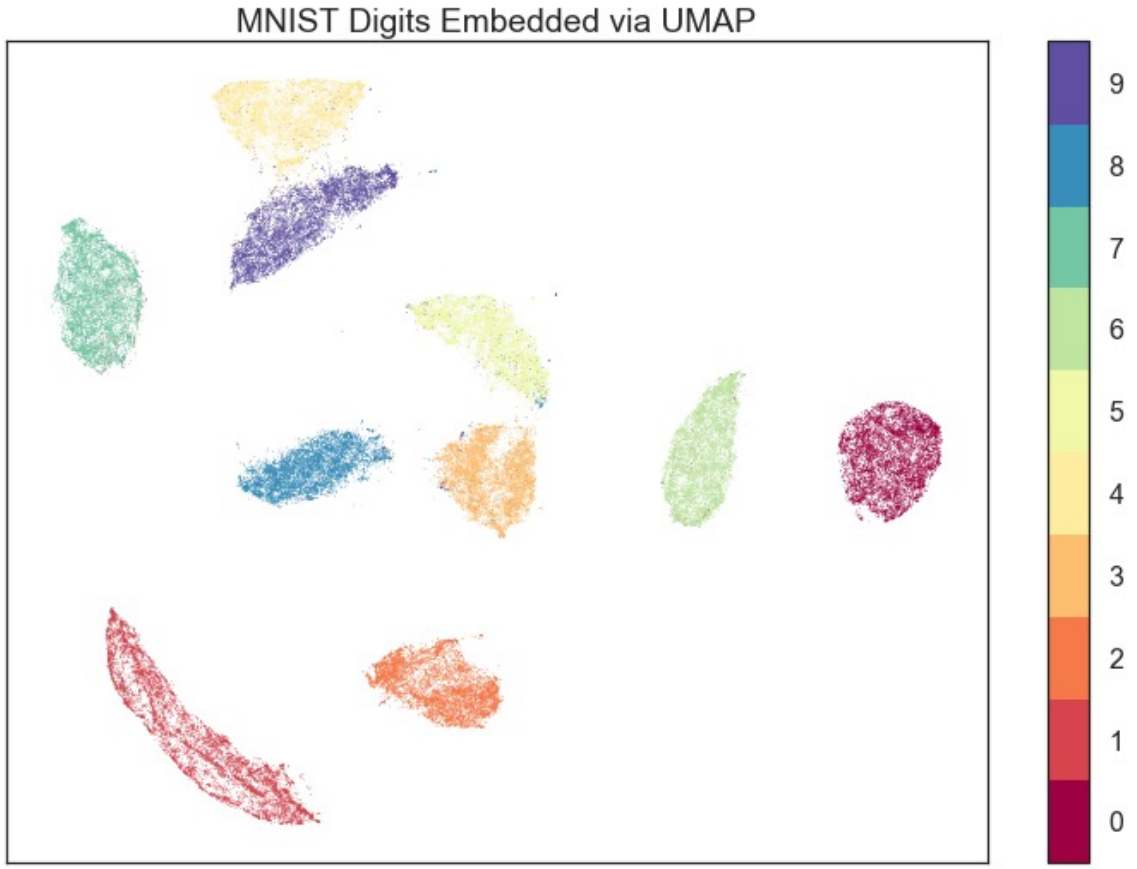

https://github.com/lmcinnes/umap

UMAP визуализация

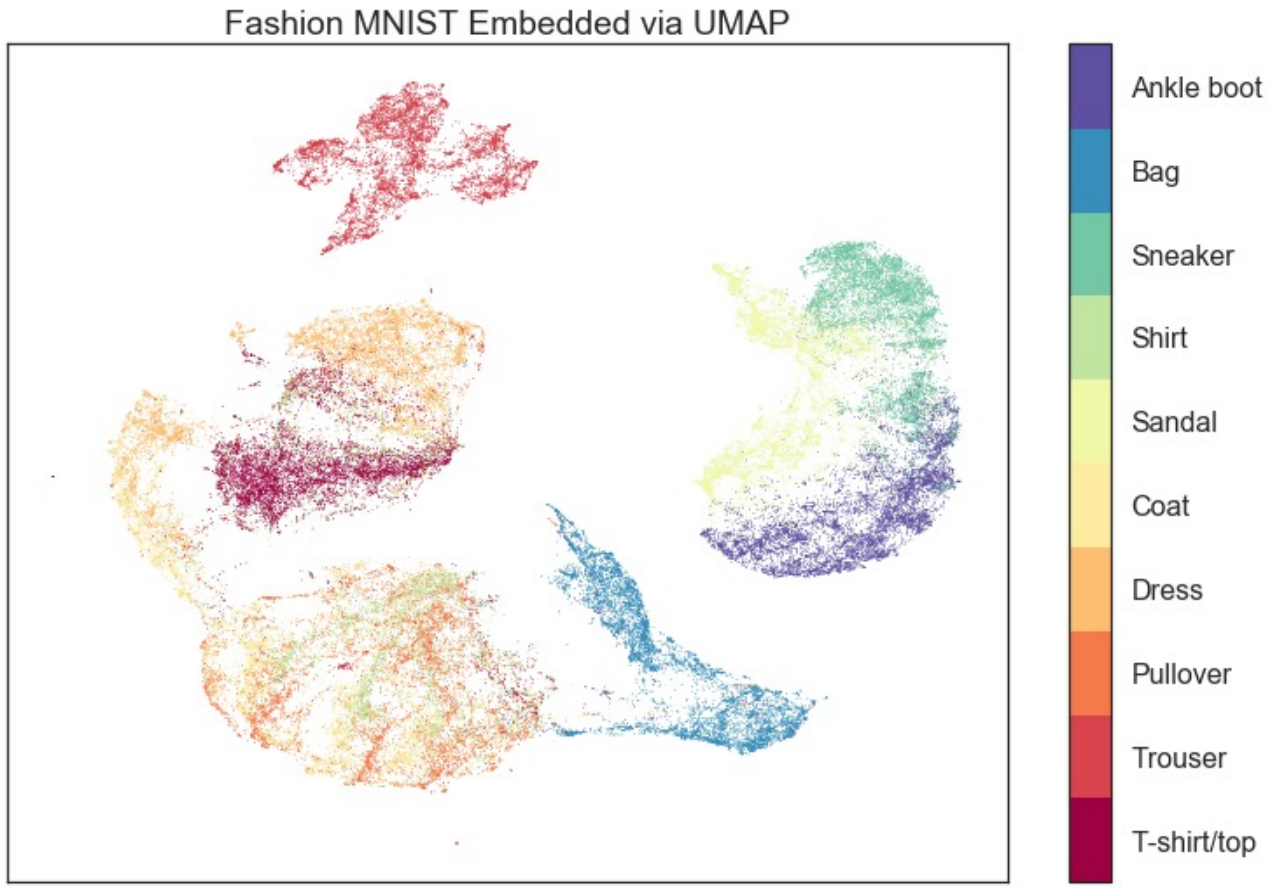

https://github.com/lmcinnes/umap

Выводы

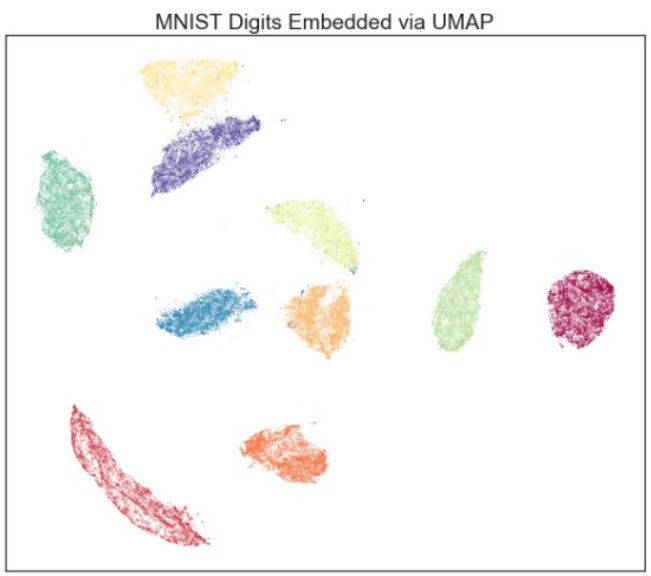

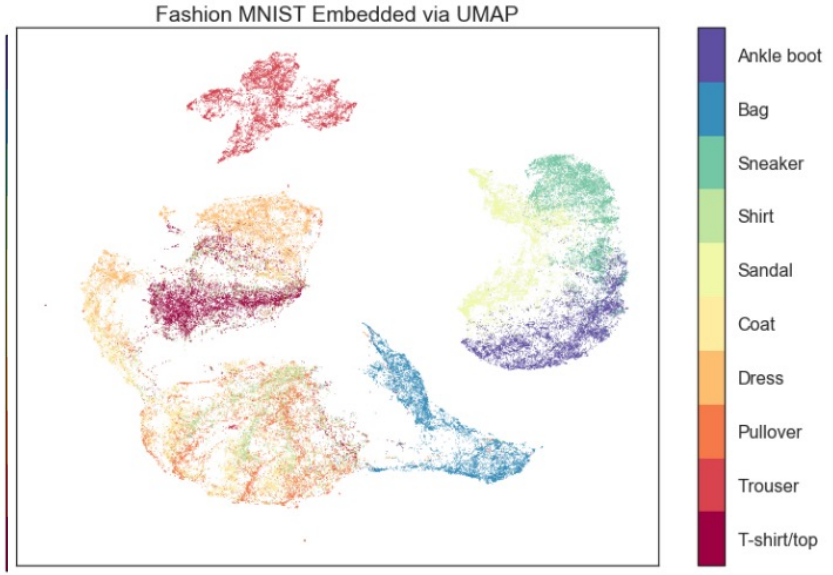

- Нейросеть обучается отображать изображения в вектор-признаки, кодирующие семантическую «похожесть» изображений.
- Близкие и визуально похожие друг на друга объекты оказываются близки по нейросетевым вектор-признакам.
- Вектор-признаки объектов разных классов далеки друг от друга

Нейросетевые признаки и базовые архитектуры

Нейросетевые признаки

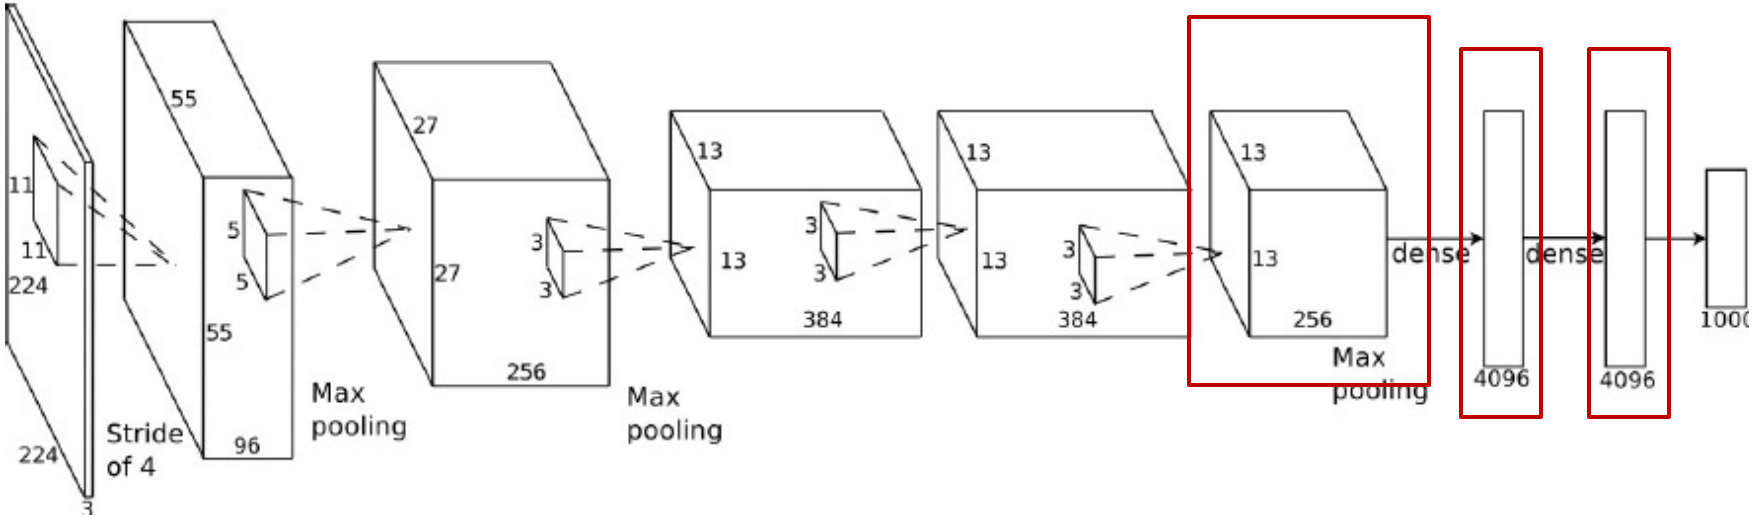

- Можно использовать выходы выбранного слоя нейросети как вектор-признак
- Можно обучить сеть на одних данных (ImageNet) и применять её на других для вычисления признаков, обучая поверх классификатор

Donahue et. al.DeCAF: A Deep Convolutional Activation Feature for Generic Visual Recognition, 2013

Перенос на другие датасеты

	$DeCAF_5$	$DeCAF_6$	$DeCAF_7$
LogReg	63.29 ± 6.6	84.30 ± 1.6	84.87 ± 0.6
LogReg with Dropout	-	86.08 ± 0.8	85.68 ± 0.6
SVM	77.12 ± 1.1	84.77 ± 1.2	83.24 ± 1.2
SVM with Dropout	-	$\mathbf{86.91 \pm 0.7}$	85.51 ± 0.9
Yang et al. (2009)		84.3	
Jarrett et al. (2009)		65.5	

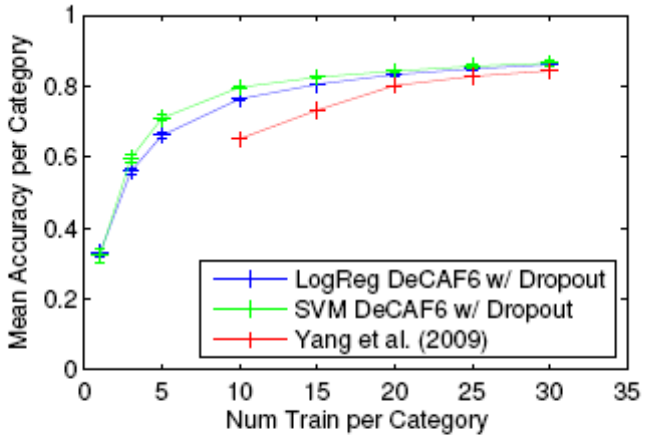

Figure 4. Left: average accuracy per class on Caltech-101 with 30 training samples per class across three hidden layers of the network and two classifiers. Our result from the training protocol/classifier combination with the best validation accuracy – SVM with Layer 6 (+ dropout) features – is shown in **bold**. Right: average accuracy per class on Caltech-101 at varying training set sizes.

- Обучили нейросеть для классификации изображений ImageNe
- Используем для извлечения признаков на других коллекциях, например, Caltech 101

Donahue et. al.DeCAF: A Deep Convolutional Activation Feature for Generic Visual Recognition, 2013

Fine-graded classification

Method	Part info	mean Accuracy
Sift+Color+SVM[45]	✗	17.3
Pose pooling kernel[49]	✓	28.2
RF[47]	✓	19.2
DPD[50]	✓	51.0
Poof[5]	✓	56.8
CNN-SVM	✗	53.3
CNNaug-SVM	✗	**61.8**
DPD+CNN(DeCaf)+LogReg[10]	✓	**65.0**

Table 3: **Results on CUB 200-2011 Bird dataset.** The table distinguishes between methods which use part annotations for training and sometimes for evaluation as well and those that do not. [10] generates a pose-normalized CNN representation using DPD [50] detectors which significantly boosts the results to **64.96**.

- Возьмём нейросеть, обученную для классификации ImageNet
- Применим её для получения вектор-признаков изображений
  Обучаем классификатор поверх этих признаков
- Profit!

Ali Sharif Razavian Hossein Azizpour Josephine Sullivan Stefan Carlsson
CNN Features off-the-shelf: an Astounding Baseline for Recognition. 2014

Дообучение (fine-tuning)

Возьмём сеть A, обученную на одной коллекции (например, ImageNet)

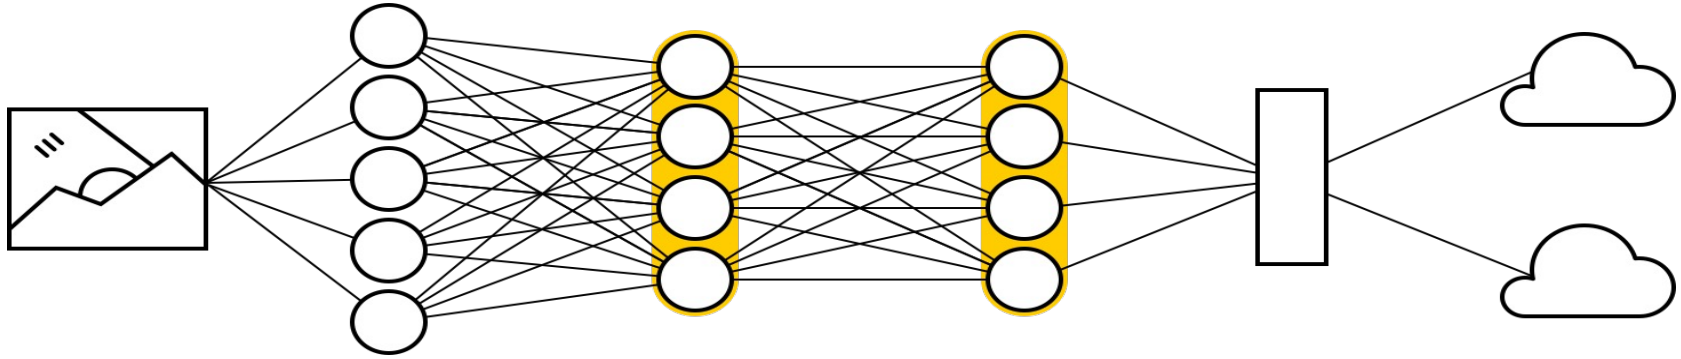

Заменим в ней последний слой (классификатор)

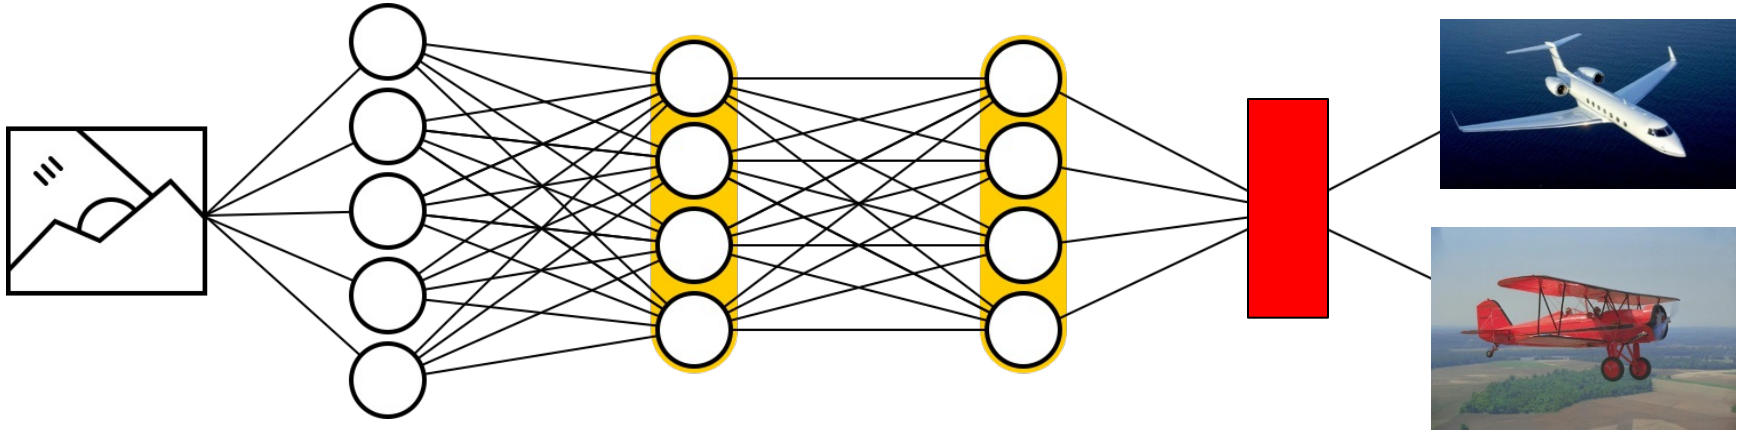

Обучим («дообучим») эту сеть на новой коллекции для решения новой задачи

Плюсы дообучения

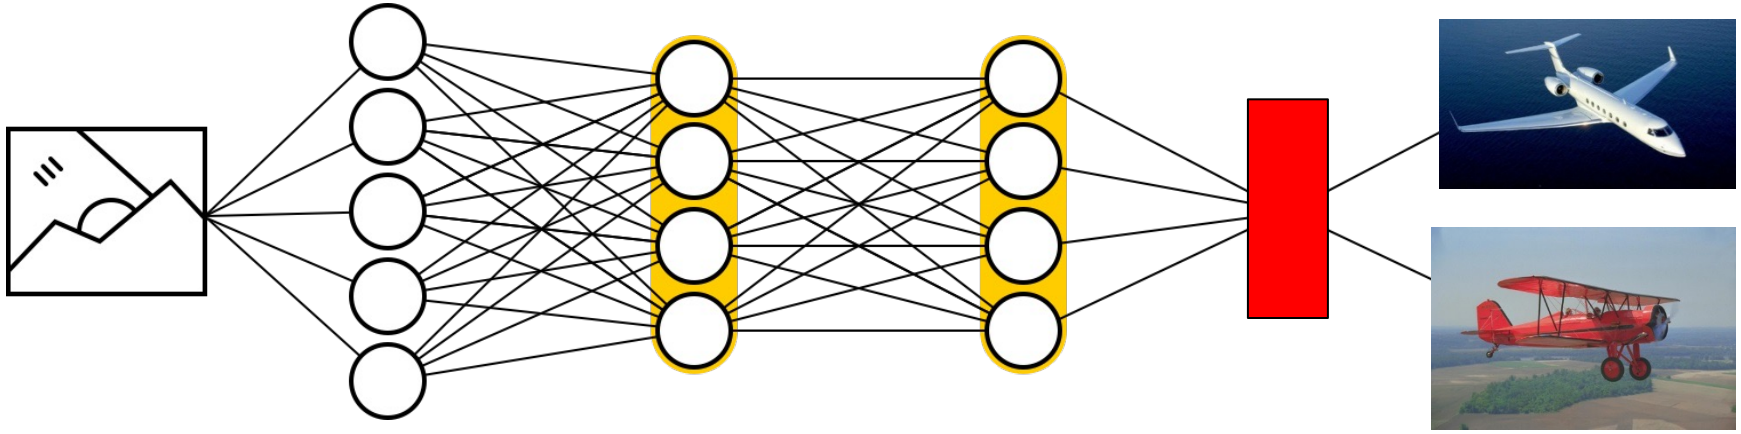

- Вторая коллекция может быть недостаточного размера для обучения нейросети «с нуля» (from scratch)
- Предобучение на большой и разнообразной коллекции может «хорошо» инициализировать новую сеть, и дообучится она быстрее и лучше

Идея «базовой» архитектуры

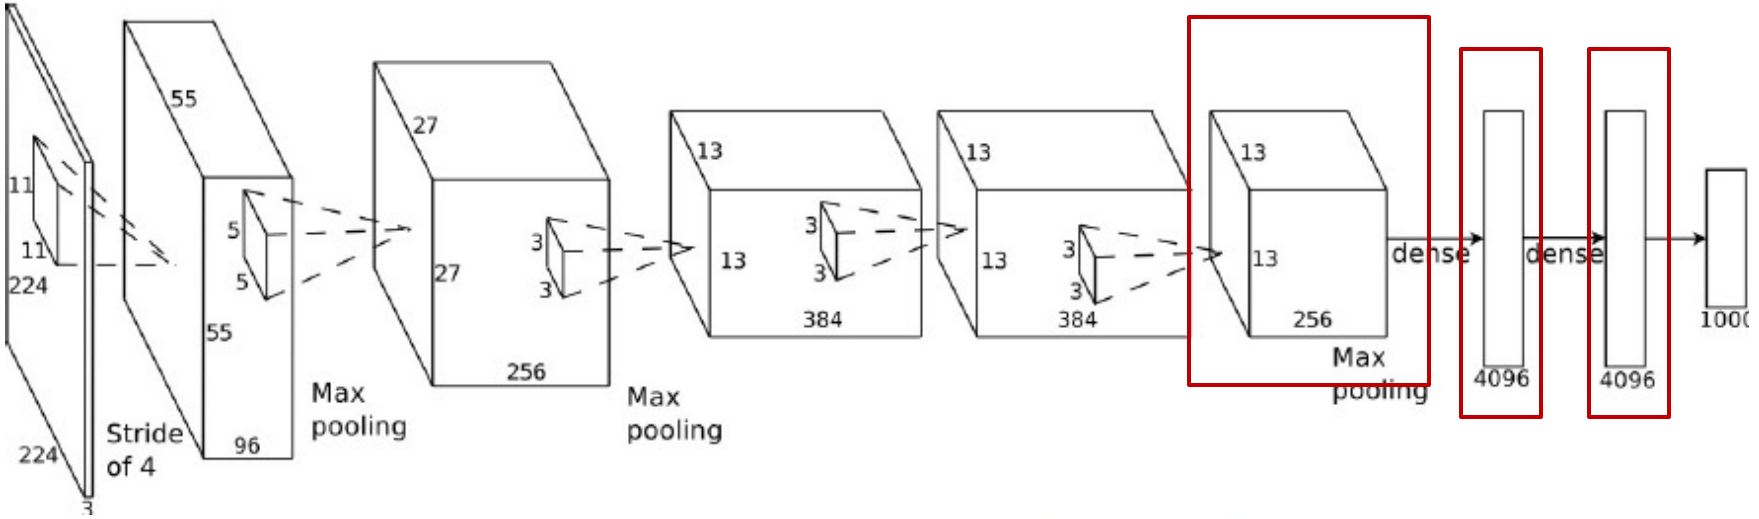

- Можем обучать нейросети-классификаторы на больших коллекциях («базовые сети»), использовать их как основу для решения новых задач (дообучением)
- Создали коллекции моделей (zoo – зоопарки)
- Пока в основном обучают на ImageNet

Развитие базовых архитектур

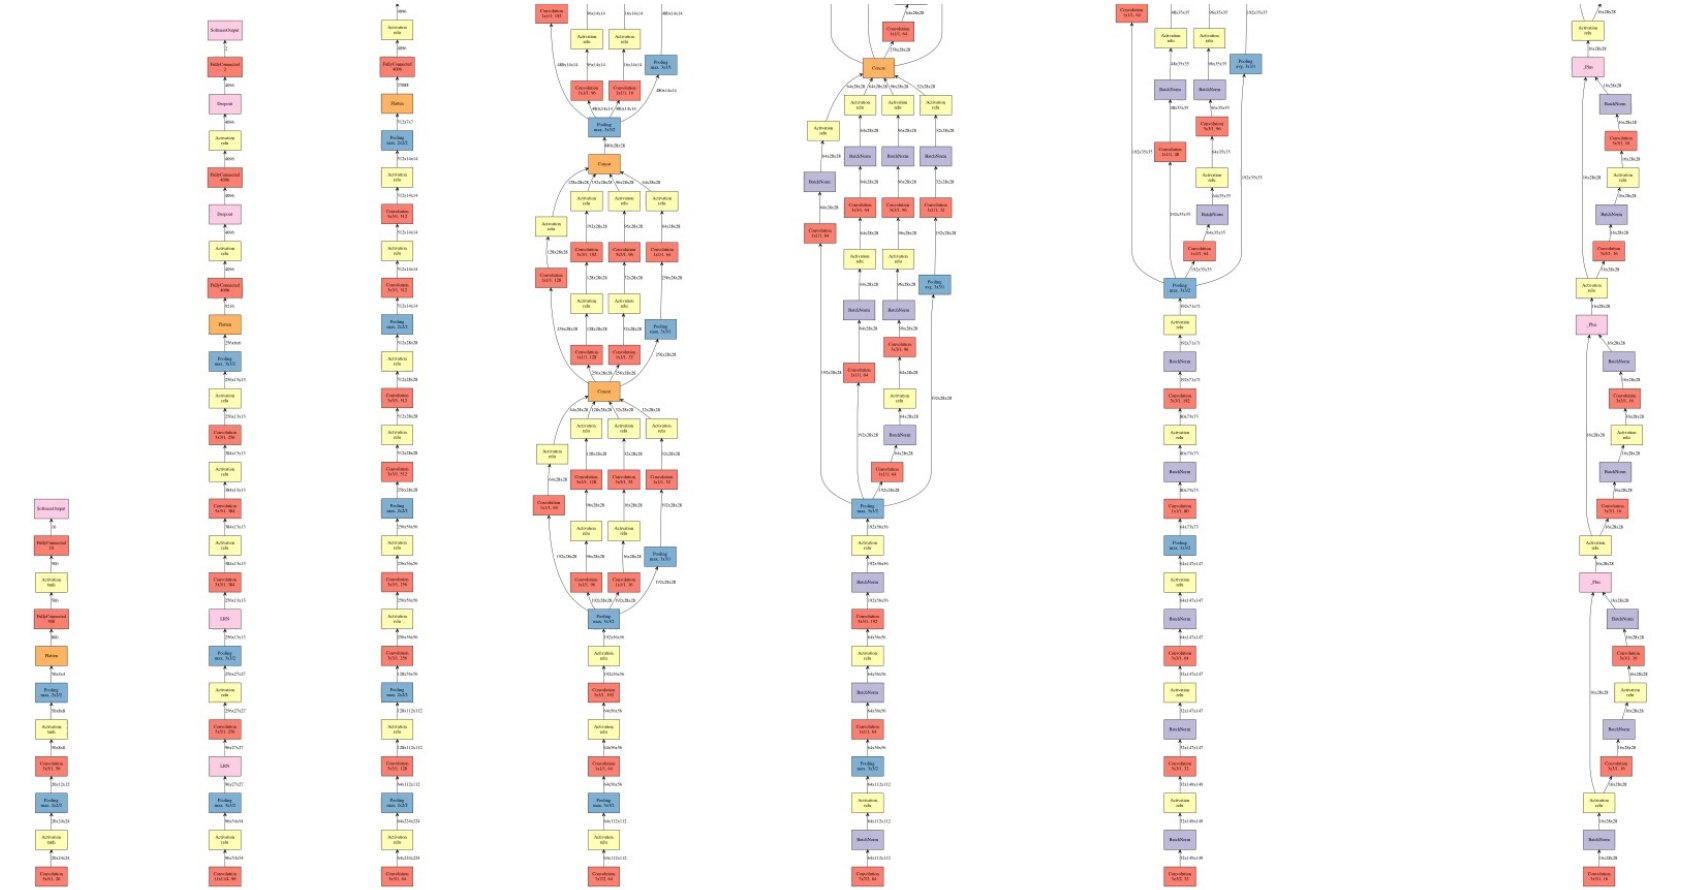

1998 2012 2014 2014 02.2015 12.2015 12.2015

Развитие базовых архитектур

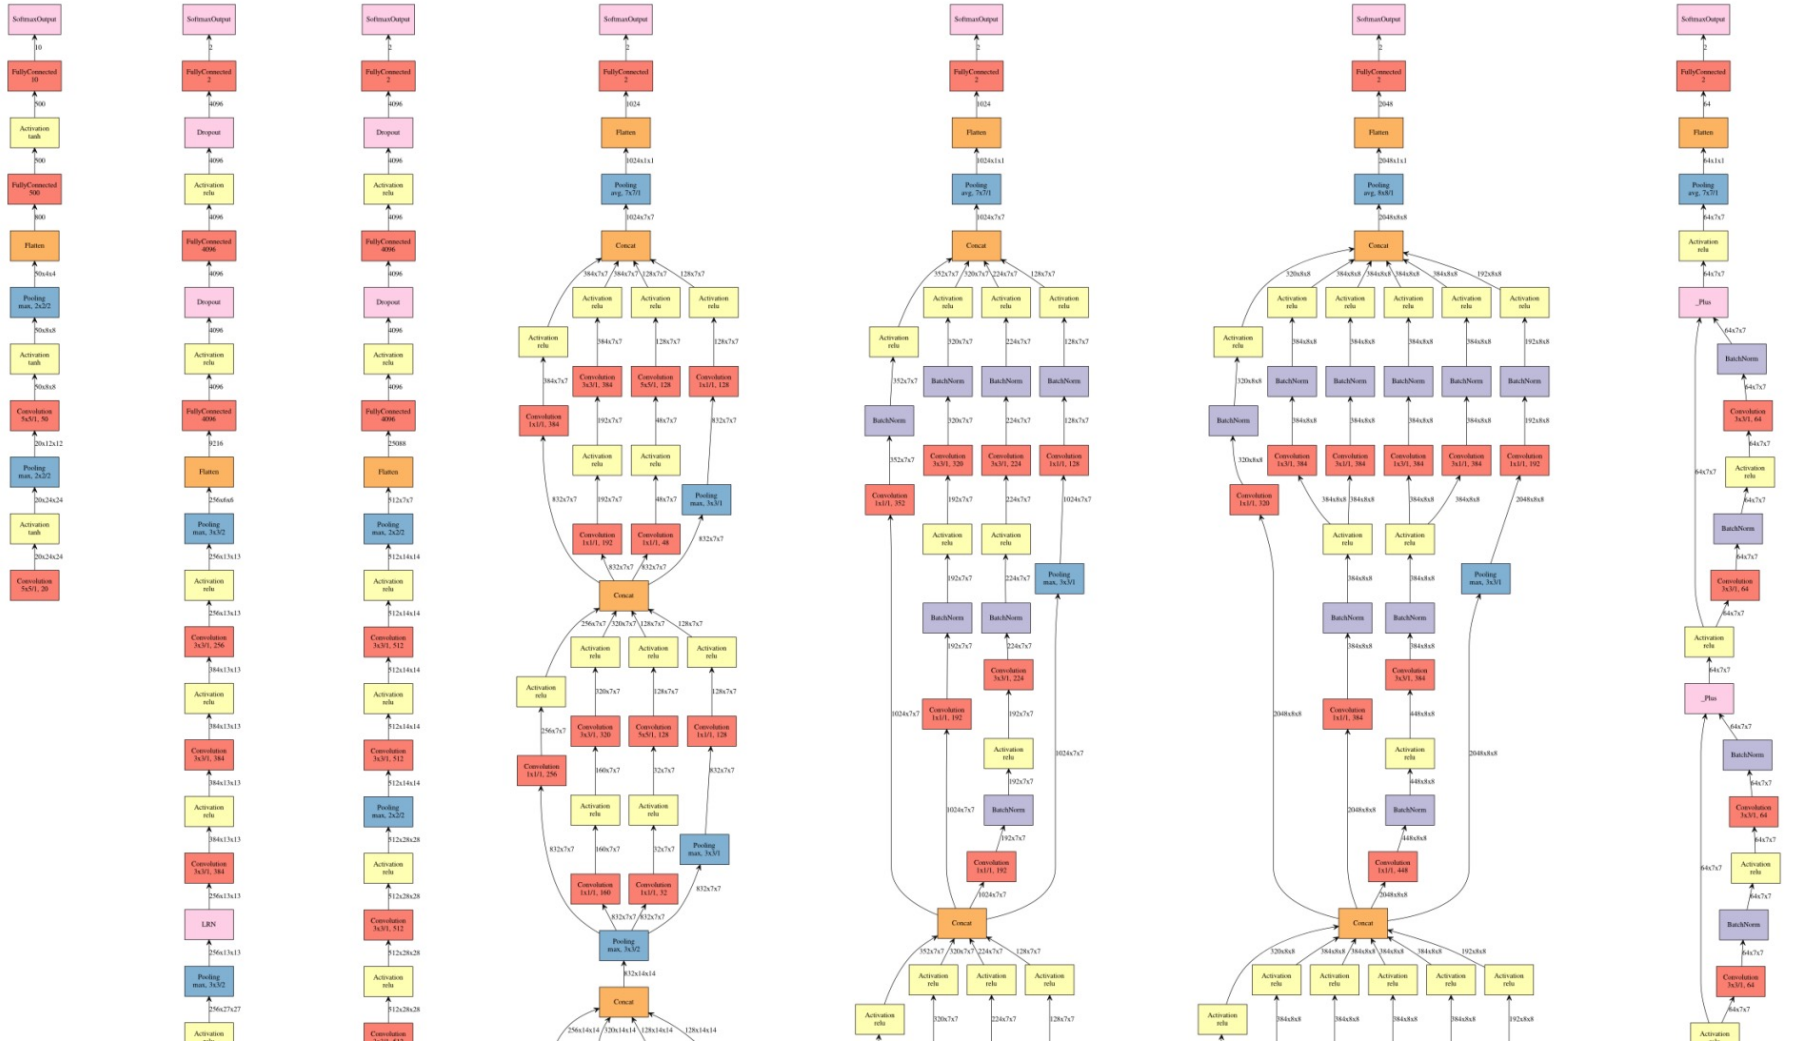

Первые базовые модели: AlexNet, VGG, Inception

AlexNet

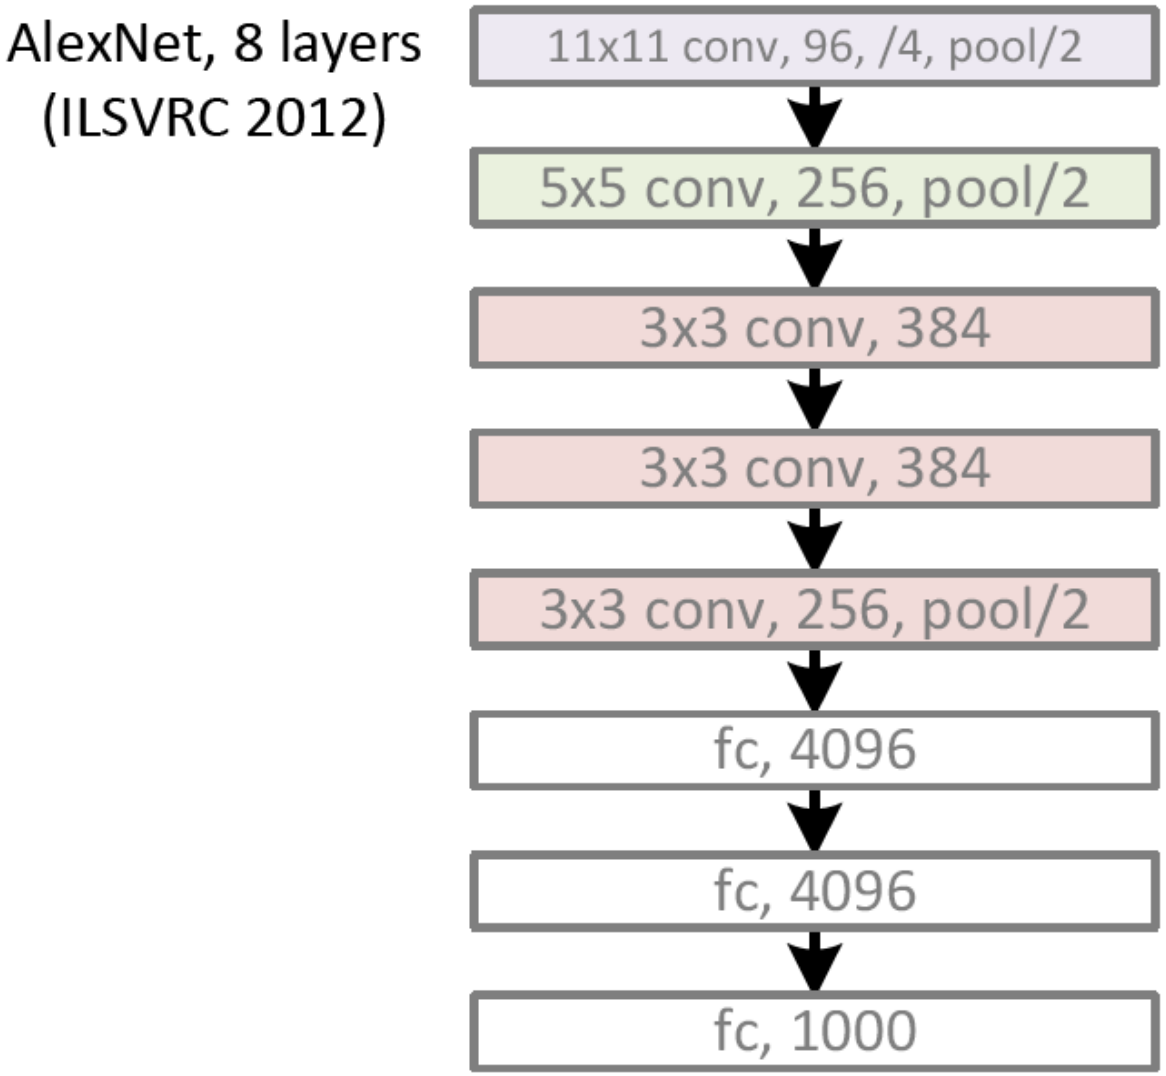

Krizhevsky A., Sutskever I., Hinton, G. E. ImageNet Classification with Deep Convolutional Neural Networks // NIPS 2012

Применение AlexNet

- На вход нейросеть принимает изображение фиксированного размера 224x224 пиксела. Можем ли мы подать другое?
- Как быть с изображениями других размеров?
- 2 варианта действий:

Масштабировать к разным разрешениям, пр. [256;512]xN случайно и вырезать фиксированные (image crop)

Приводить к фиксированному разрешению (image warp)

- Схема применения

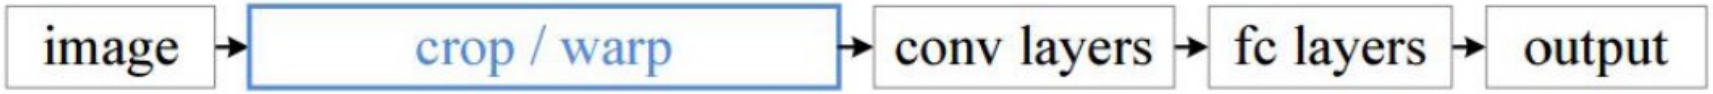

Применение моделей

- Вариант 1
  - Применить к фиксированному изображению, как сказали раньше
- Вариант 2
  - Применить несколько раз к разным версиям изображения
- Вариант 3
  - Применить ко всем фрагментам заданного разрешения, т.е. «просканировать» изображение

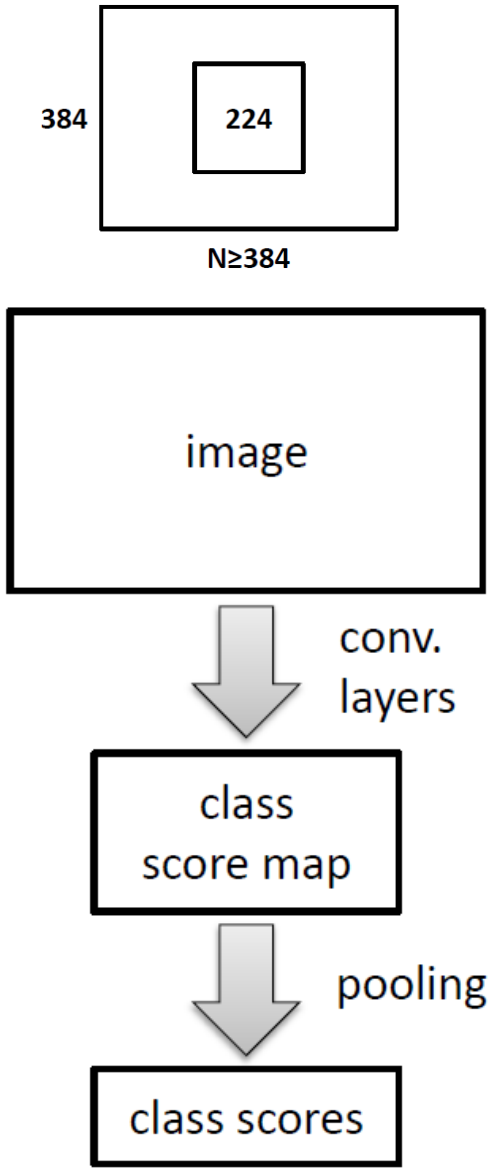

Spatial Pyramid Pooling (SPP)

Идея: преобразовать выходы свёрточного слоя (признаки) произвольного разрешения к вектор-признаку фиксированной длины

Spatial Pyramid Pooling (SPP)

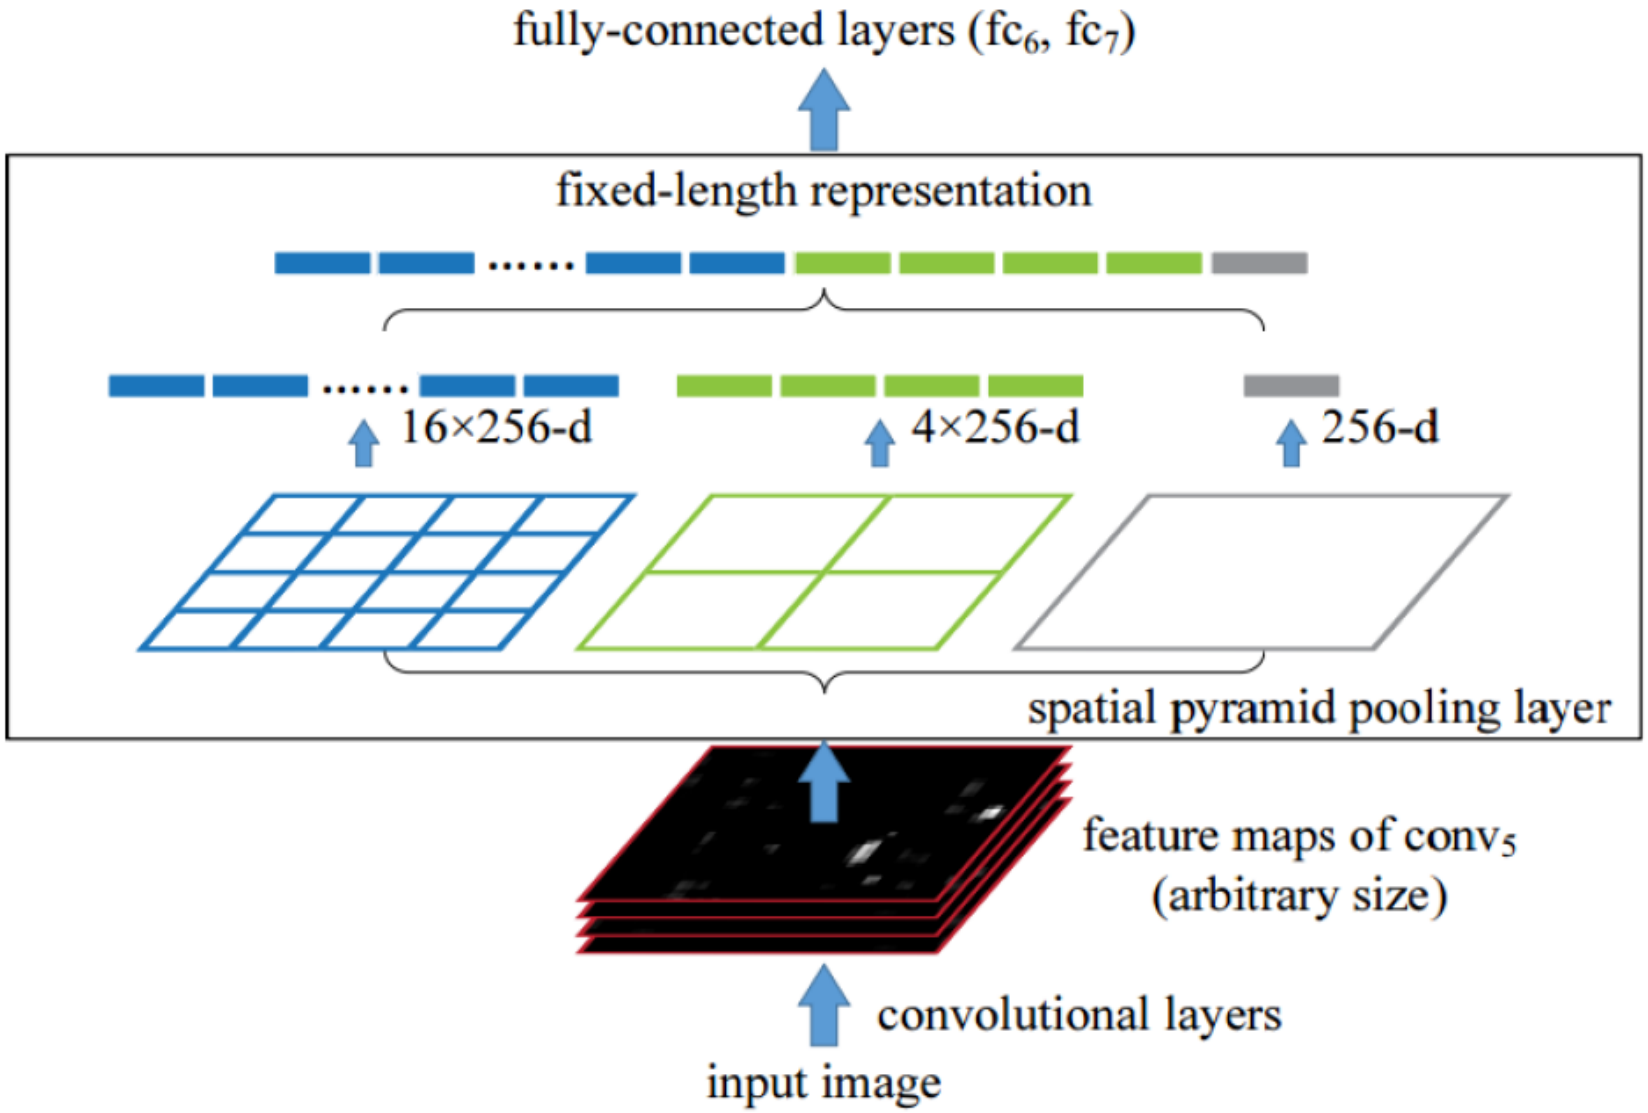

Average Pooling

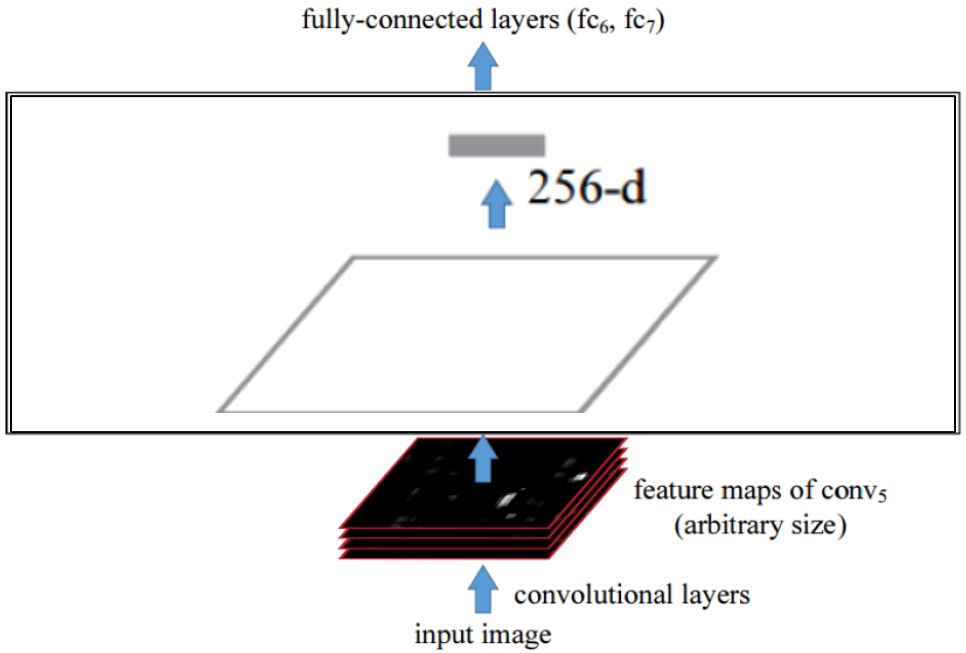

- Можно обойтись без пирамиды, ограничившись только Average Pooling по всему слою
- Тогда у нас получится вектор признак длиной равной числу свёрток на последнем уровне
- Для ряда задач этого оказывается достаточно

Модель VGG (Visual Geometry Group)

Идеи:

- Исследовать рост качества за счёт увеличения глубины нейросети
- Использовать только маленькие 3x3 свёртки
- Stride 1 в свёртках чтобы не терять информацию
- ReLU активация
- Нет нормализации
- Уменьшение разрешения через maxpooling
- Число фильтров x2 при уменьшении разрешения в 2 раза

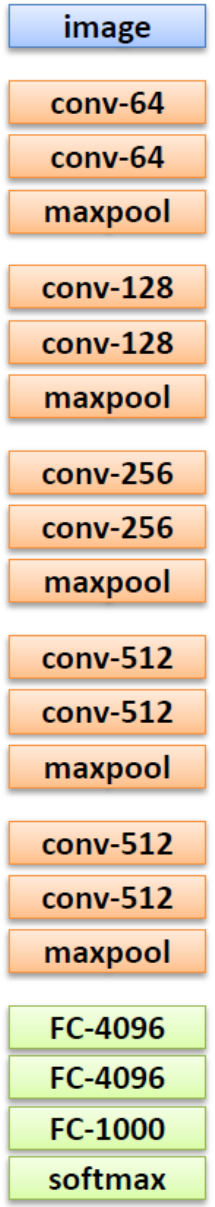

K. Simonyan, A. Zisserman Very Deep Convolutional Networks for Large-Scale Image Recognition . ICLR 2015

Свёртки 3x3

- Стек свёрток позволяет обеспечить бОльшее рецептивное поле (reception field)
  - 5x5 для 2-х свёрток
  - 7x7 для 3-х свёрток
- БОльшая нелинейность за счёт ReLU активаций
- Меньше параметров
  - 18x (2 3x3) vs 25x (5x5)
  - 27x (3 3x3) vs 49x (7x7)

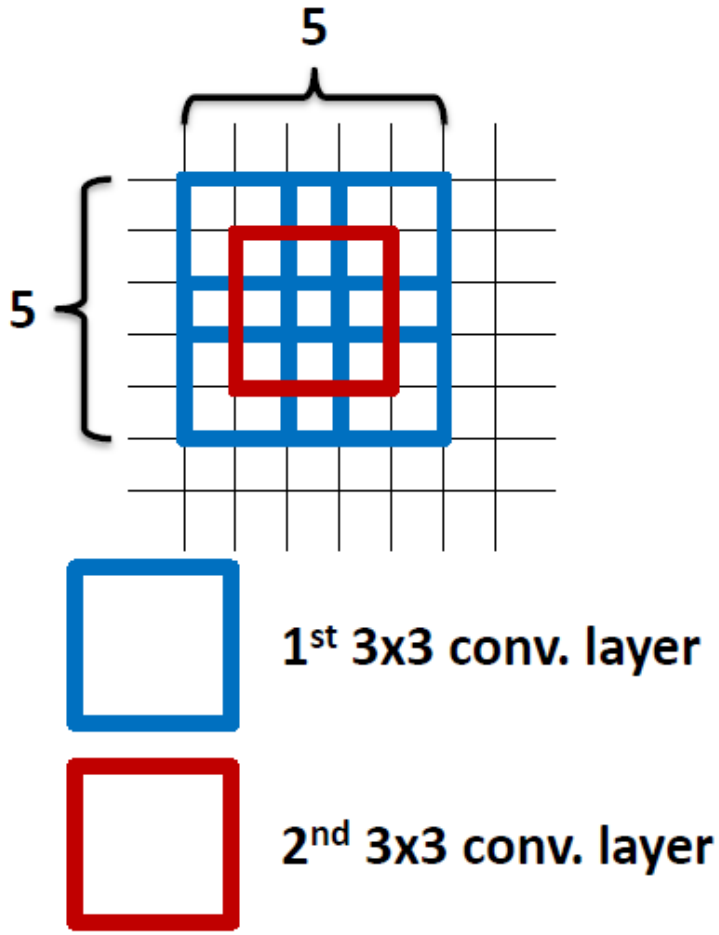

Исследование вариантов

A	A-LRN	B	C	D	E
11 weight layers	11 weight layers	13 weight layers	16 weight layers	16 weight layers	19 weight layers
input (224 × 224 RGB image)					
conv3-64	conv3-64 **LRN**	conv3-64 **conv3-64**	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64
maxpool					
conv3-128	conv3-128	conv3-128 **conv3-128**	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128
maxpool					
conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256 **conv1-256**	conv3-256 conv3-256 **conv3-256**	conv3-256 conv3-256 conv3-256 **conv3-256**
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 **conv1-512**	conv3-512 conv3-512 **conv3-512**	conv3-512 conv3-512 conv3-512 **conv3-512**
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 **conv1-512**	conv3-512 conv3-512 **conv3-512**	conv3-512 conv3-512 conv3-512 **conv3-512**
maxpool					
FC-4096					
FC-4096					
FC-1000					
soft-max					

D - VGG-16

E - VGG-19

Архитектура Inception и идея ветвей

Построим нейросеть из модулей более сложной структуры, чем просто набор свёрточных слоёв VGG

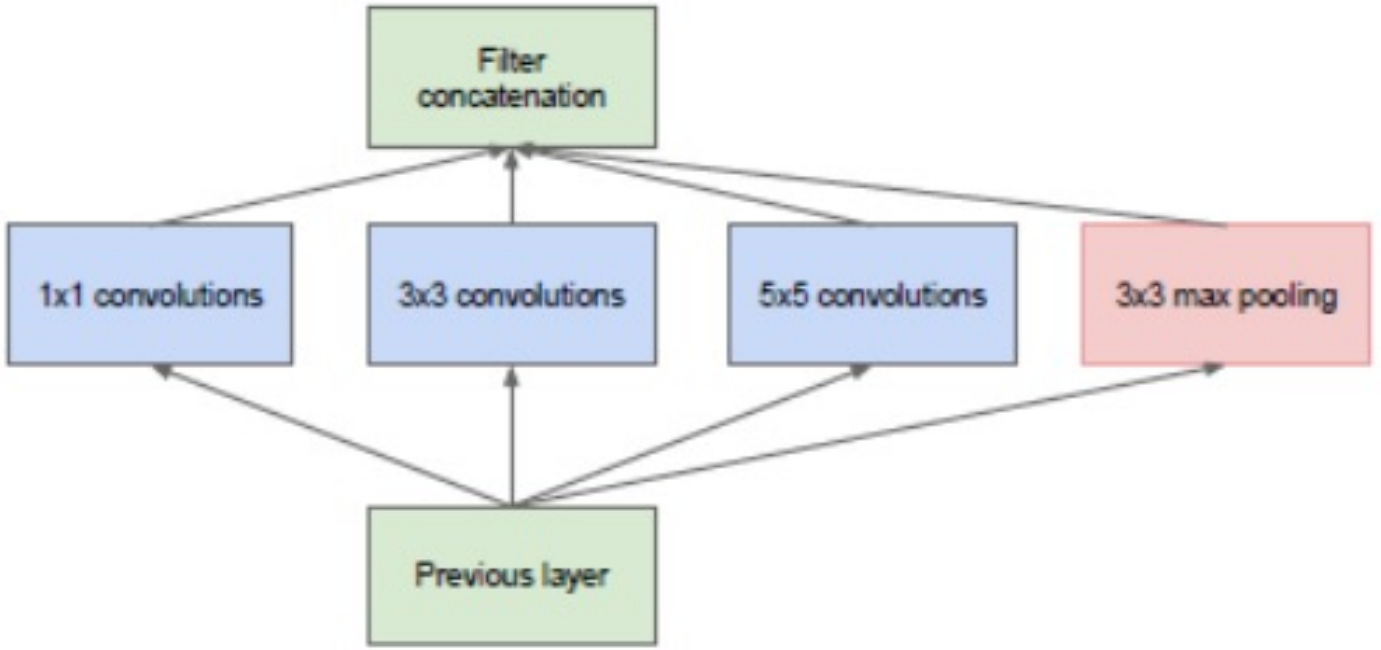

В чём смысл применять одновременно свёртки разных размеров?

Christian Szegedy et. al. Going deeper with convolutions. CVPR 2015

Использование свёрток 1x1

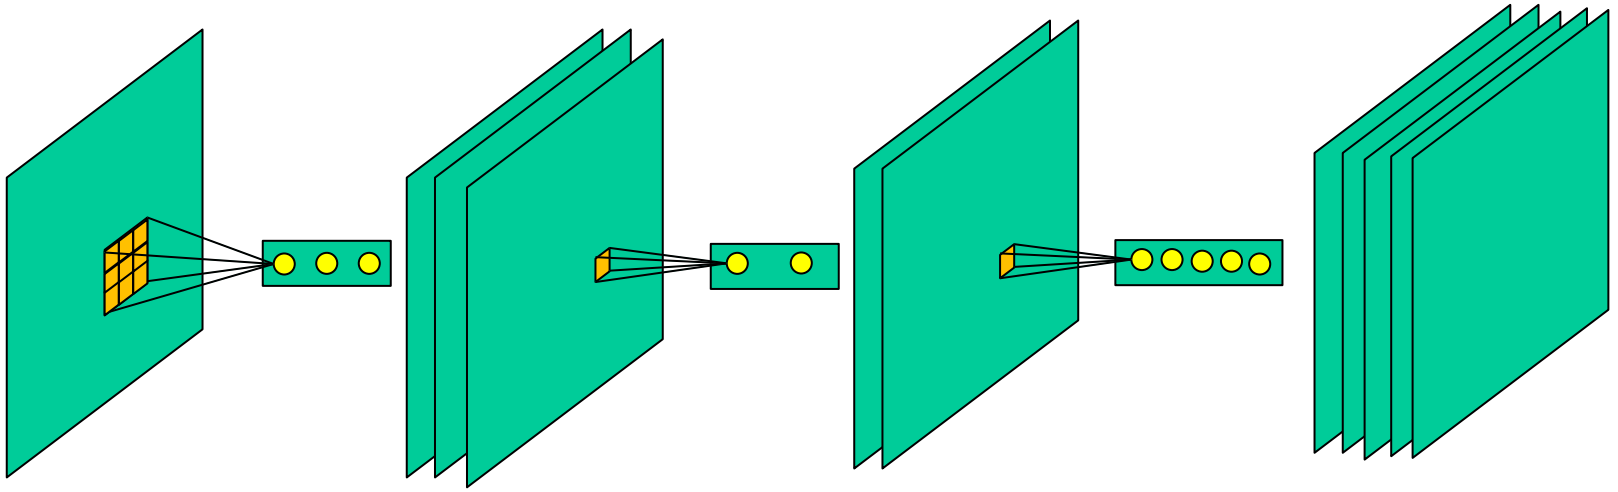

- Как трактовать свёртку 1x1?
  - Отображение вектора длины n (толщина входного слоя = число свёрток предыдущего слоя) на вектор длины k (число свёрток 1x1)
  - Или как набор «локальных классификаторов»
- Можем управлять «глубиной» тензора, регулируя k - число свёрток 1x1, по сравнению с n – глубиной предыдущего тензора
  - K < N, значит мы уменьшили до k глубину тензора (сжали)
  - K > N, значим мы увиличили глубину тензора

Модуль Inception

Добавим 1x1 свёртки для повышения производительности

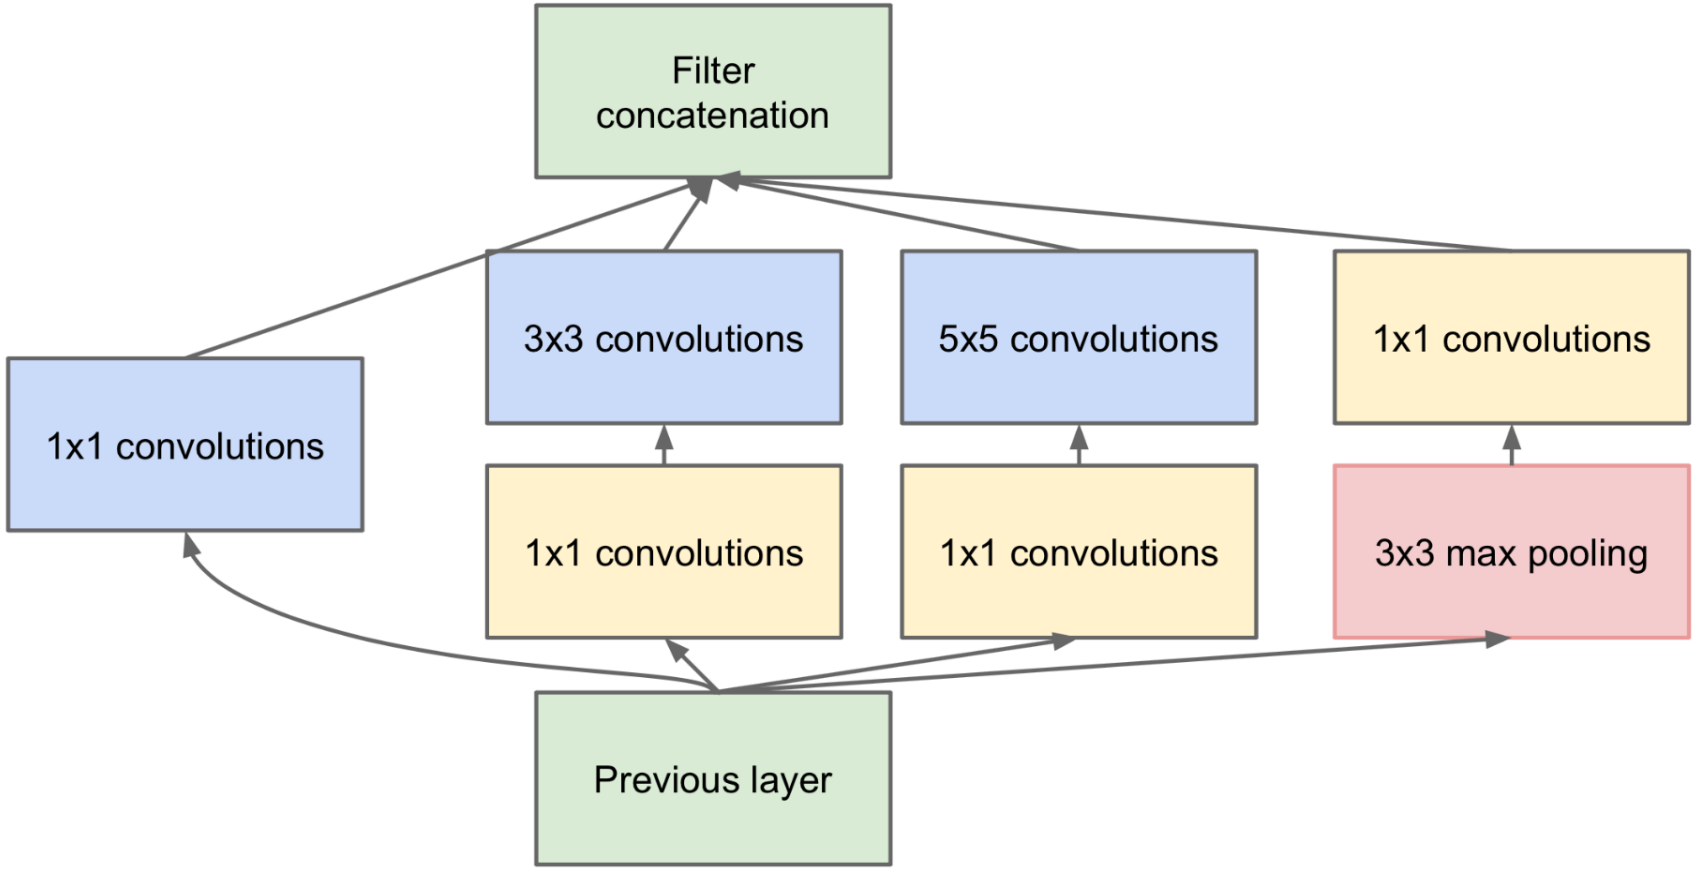

Christian Szegedy et. al. Going deeper with convolutions. CVPR 2015

Архитектура Inception

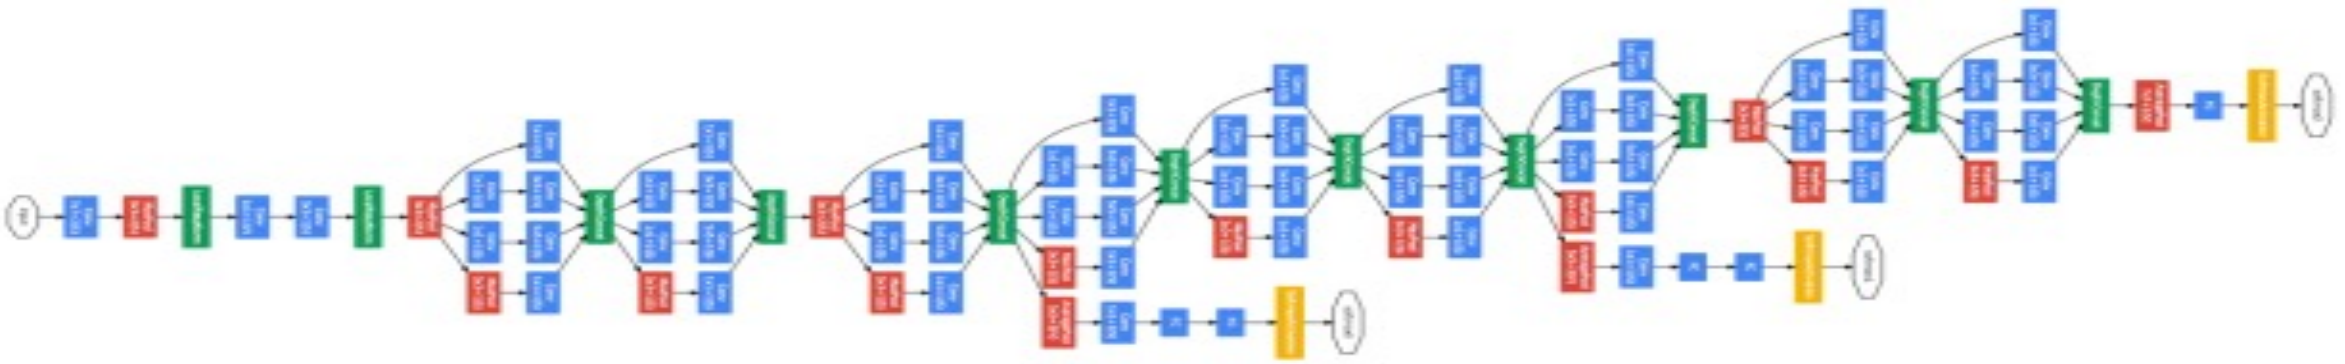

- Глубокая сеть
- Inception-модули
- Несколько уровней supervision

Christian Szegedy et. al. Going deeper with convolutions. CVPR 2015

ResNet, Skip Connection и репараметризация

Проблема глубины

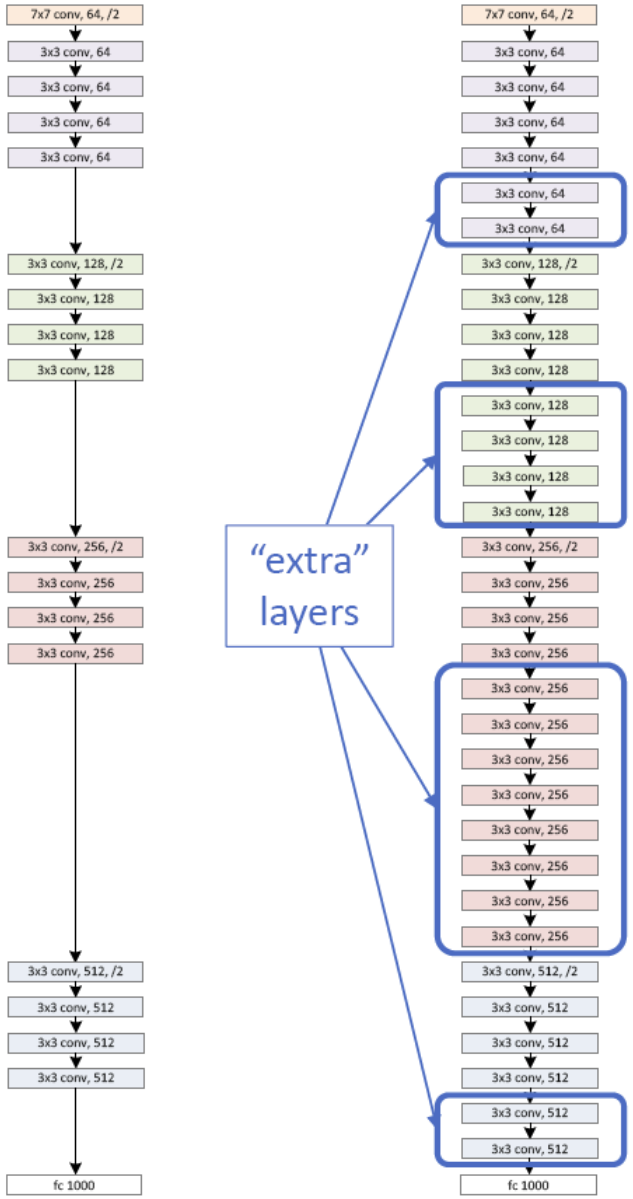

- Дальнейшее увеличение числа слоёв приводило к падению качества итоговой модели

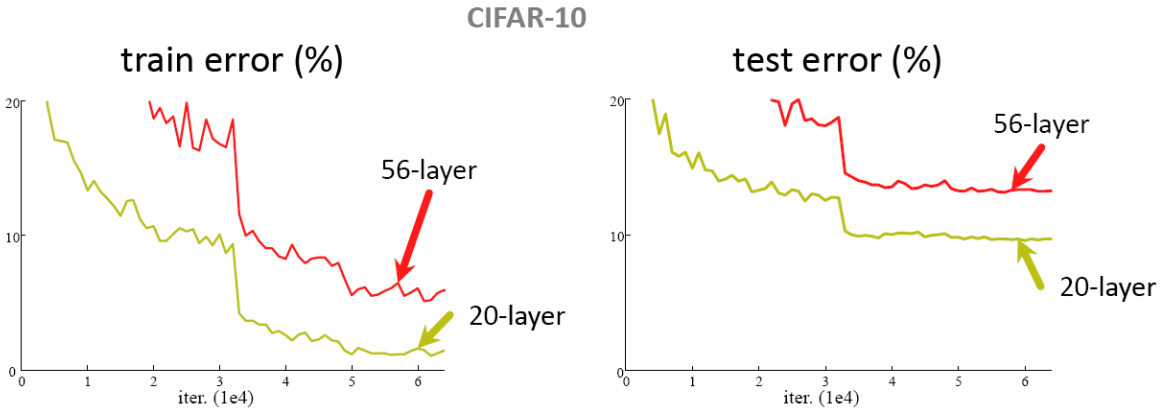

- При этом можно добавить «единичные» слои к сети, оставив ту же самую функцию и качество
- Значит, проблема в обучении сети

Residual net и skip-connections

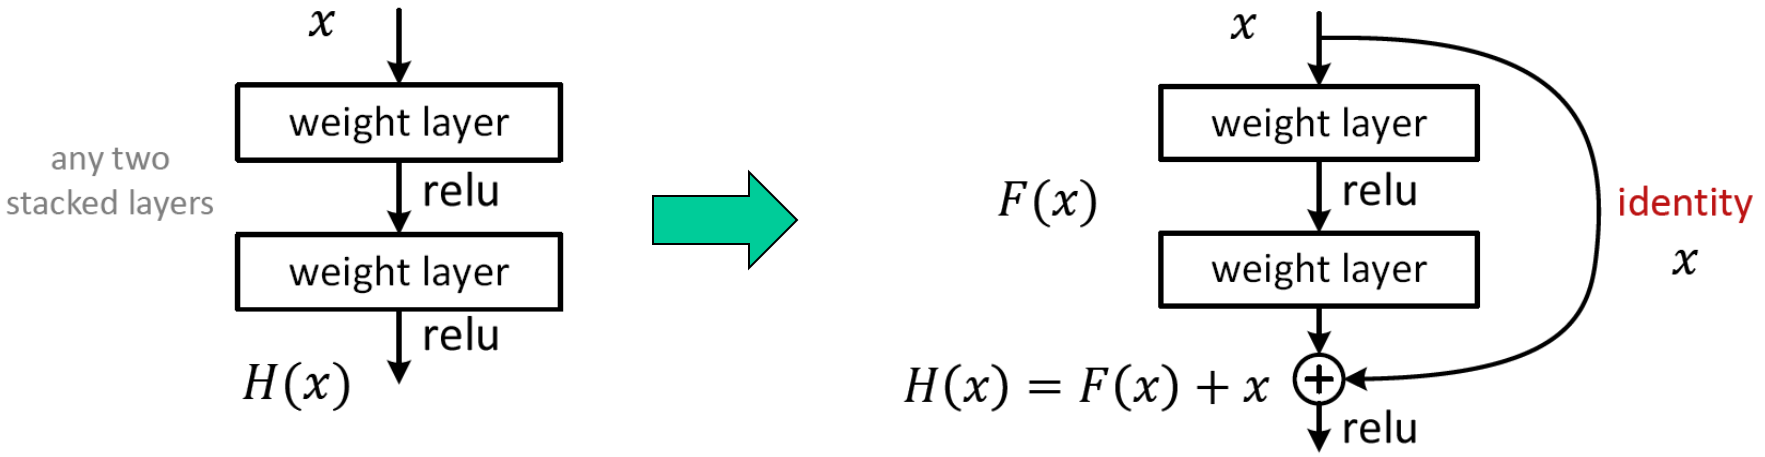

- Добавим обходной путь (skip-connection) к блоку
- Будем учить не преобразование, а добавку (пертурбацию) к тождественному преобразования
  - Если единичное преобразование оптимально, тогда мы его сохраняем
  - Небольшие флуктуации оказывается обучать проще
- Также градиенты будут «обходить» блок и передаваться на предыдущий напрямую

ResNet

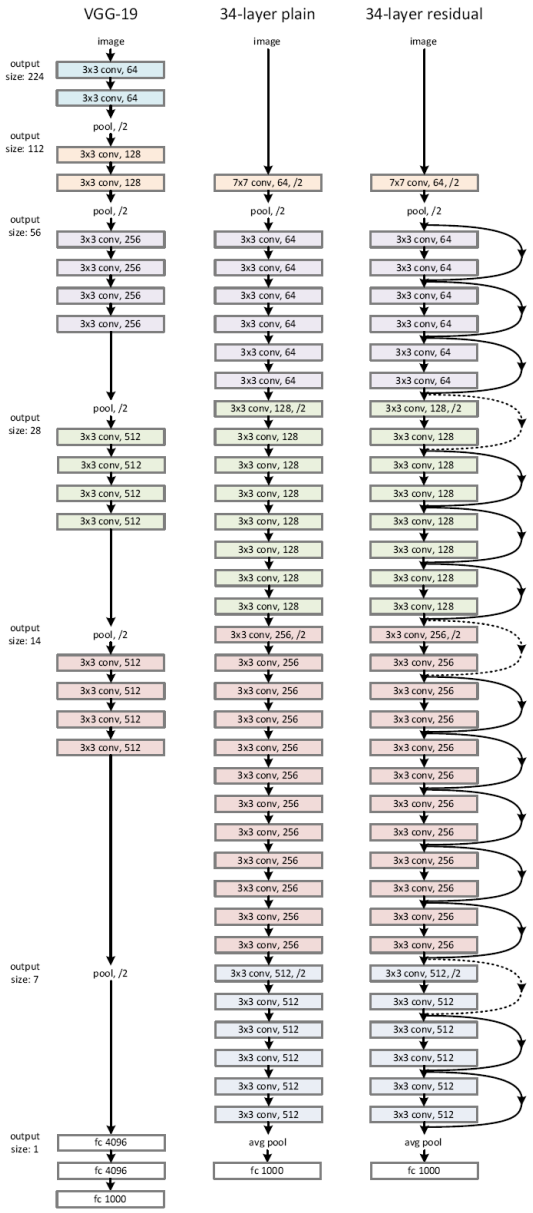

Базовая модель

- Свёртки 3x3
- Subsampling через свёртку с шагом 2

• Residual net

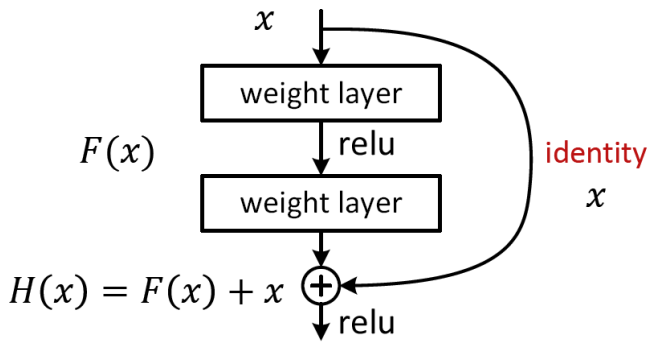

При изменении размеров тензоров пробуют варианты:

- Добавление нулями
- Линейная проекция
- Шаг 2

Повышение производительности

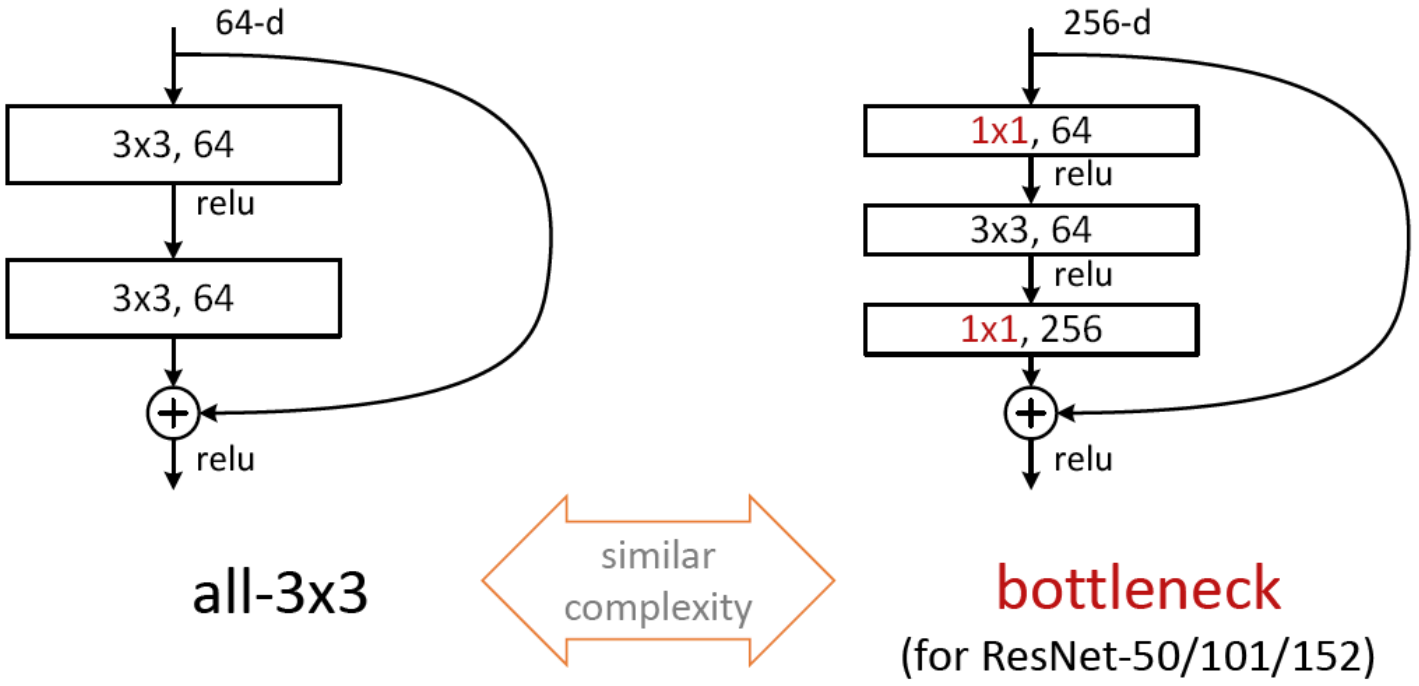

- Понижение размерности (256->64) за счёт 1x1 свёрток
- Свёртка 3x3 на тензоре меньшей глубины
- Повышение размерности свёртками 1x1

Результаты на ImageNet

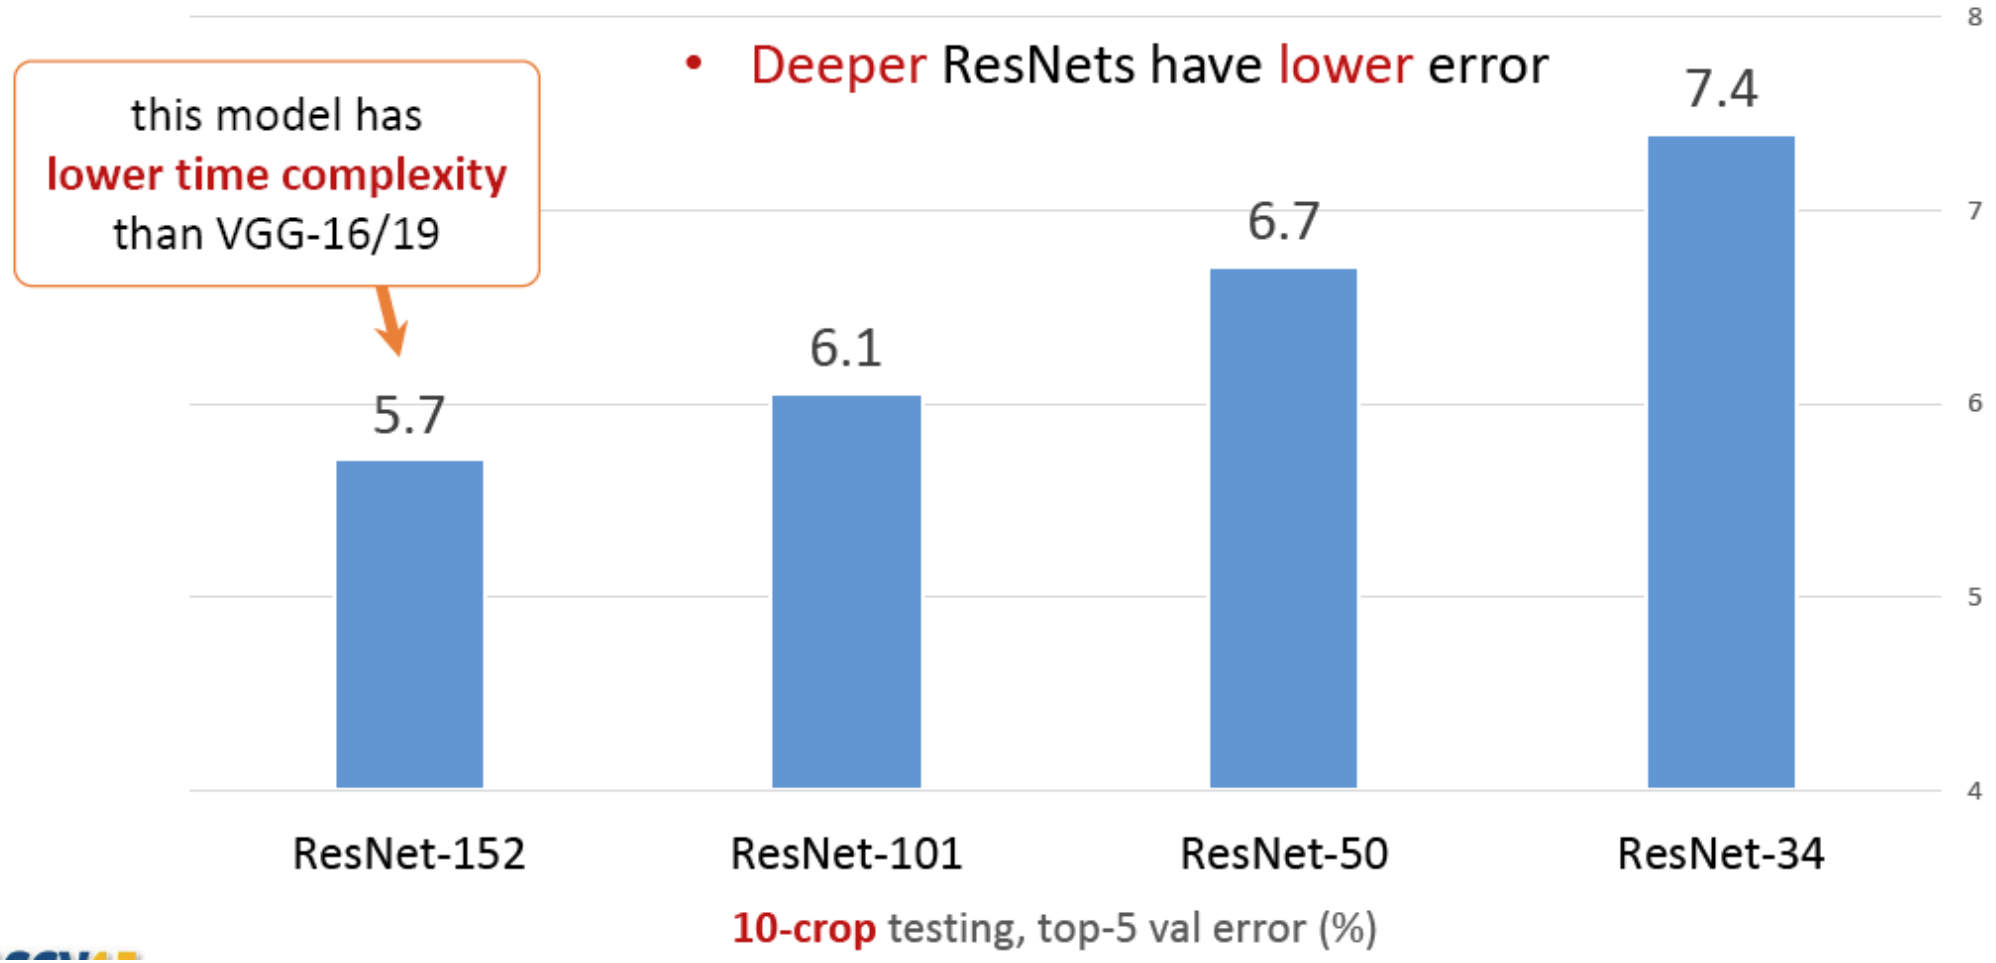

Результаты на ImageNet

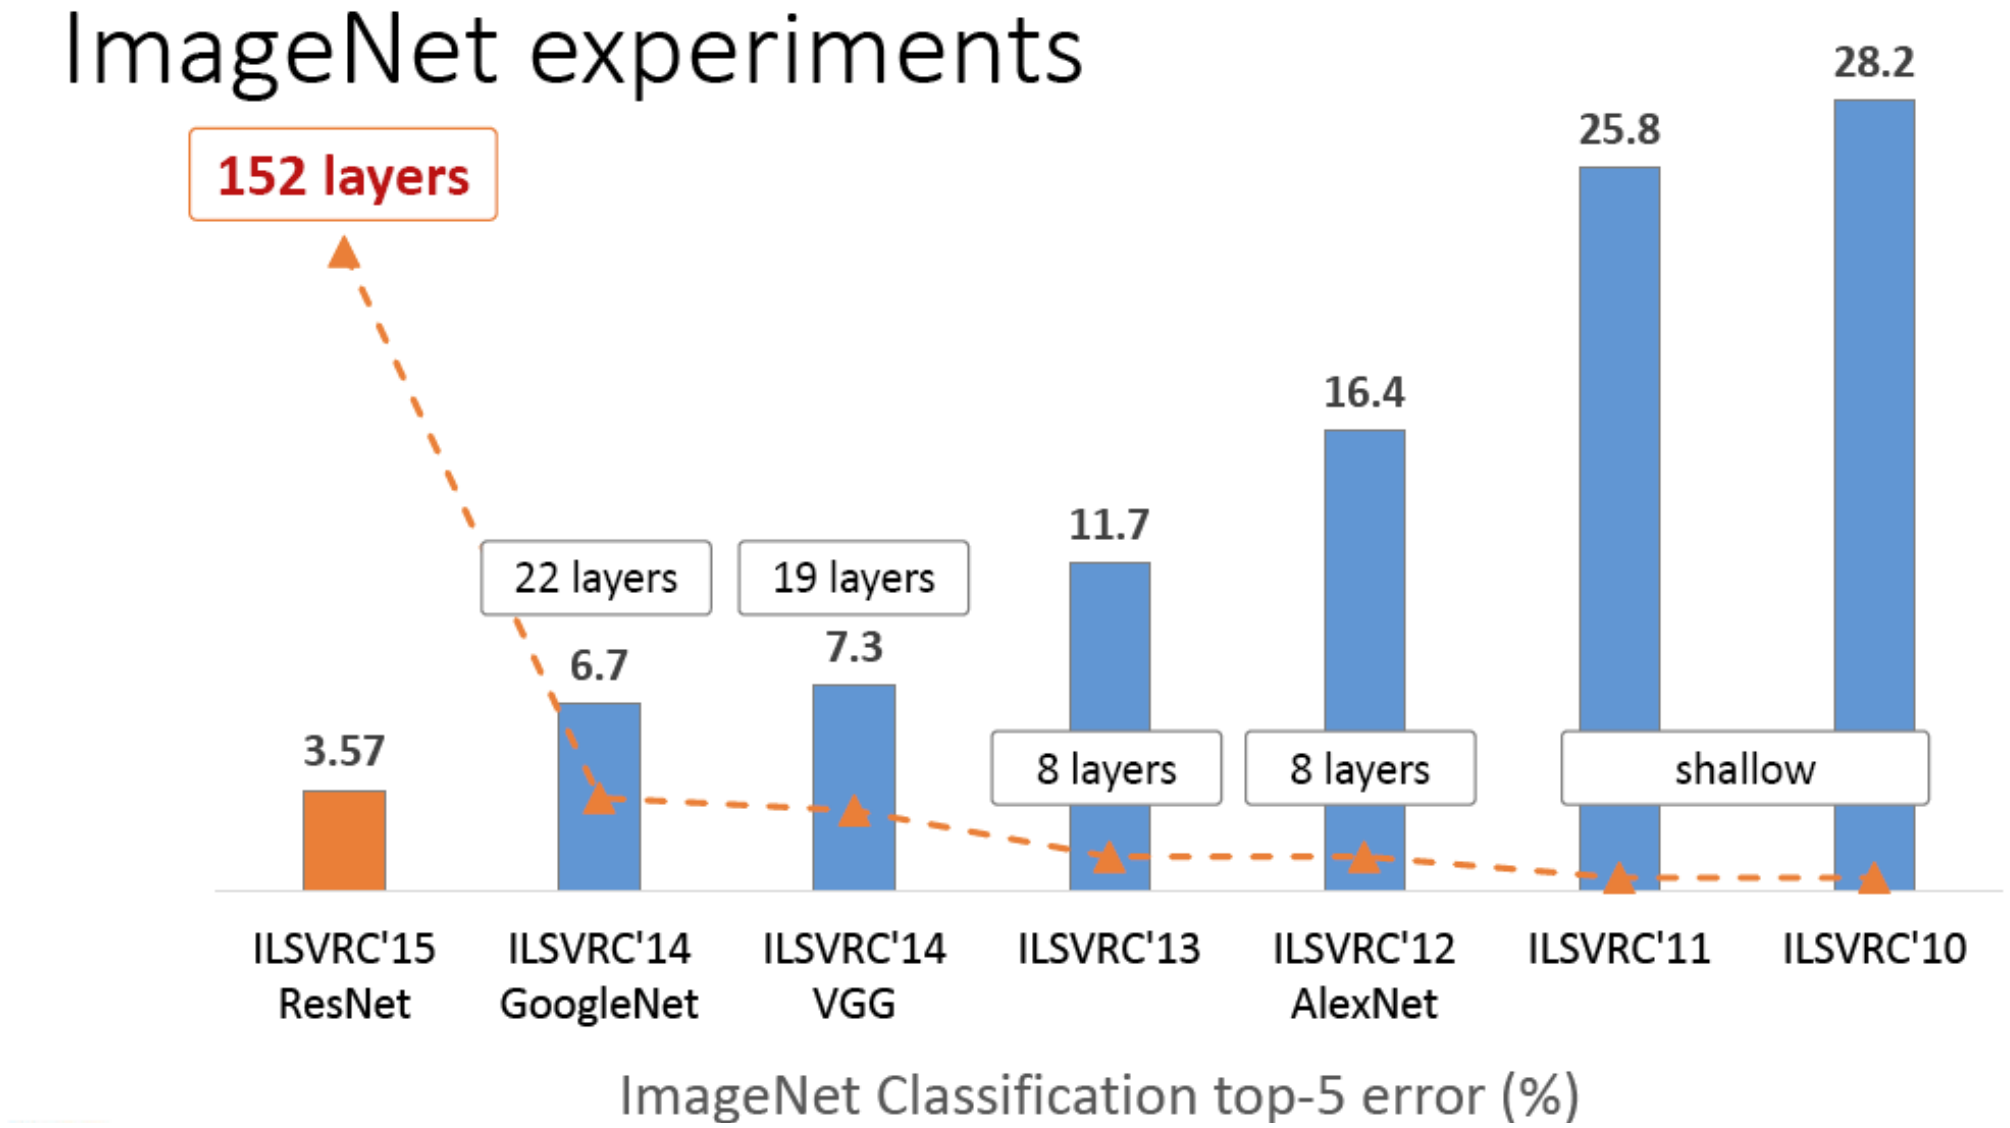

ResNeXt

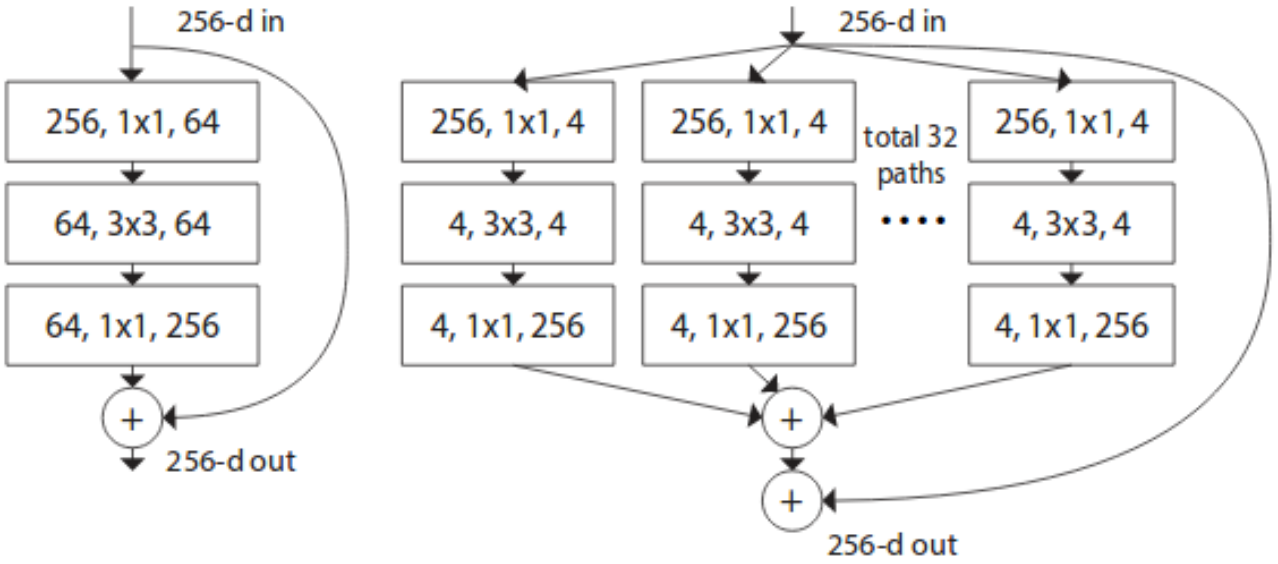

Figure 1. **Left**: A block of ResNet [14]. **Right**: A block of ResNeXt with cardinality = 32, with roughly the same complexity. A layer is shown as (# in channels, filter size, # out channels).

stage	output	ResNet-50	**ResNeXt-50 (32×4d)**
conv1	112×112	7×7, 64, stride 2	7×7, 64, stride 2
conv2	56×56	3×3 max pool, stride 2	3×3 max pool, stride 2
		$\begin{bmatrix} 1\times1, 64 \\ 3\times3, 64 \\ 1\times1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1\times1, 128 \\ 3\times3, 128, C=32 \\ 1\times1, 256 \end{bmatrix} \times 3$
conv3	28×28	$\begin{bmatrix} 1\times1, 128 \\ 3\times3, 128 \\ 1\times1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1\times1, 256 \\ 3\times3, 256, C=32 \\ 1\times1, 512 \end{bmatrix} \times 4$
conv4	14×14	$\begin{bmatrix} 1\times1, 256 \\ 3\times3, 256 \\ 1\times1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1\times1, 512 \\ 3\times3, 512, C=32 \\ 1\times1, 1024 \end{bmatrix} \times 6$
conv5	7×7	$\begin{bmatrix} 1\times1, 512 \\ 3\times3, 512 \\ 1\times1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1\times1, 1024 \\ 3\times3, 1024, C=32 \\ 1\times1, 2048 \end{bmatrix} \times 3$
	1×1	global average pool 1000-d fc, softmax	global average pool 1000-d fc, softmax
# params.		$\mathbf{25.5}\times10^6$	$\mathbf{25.0}\times10^6$
FLOPs		$\mathbf{4.1}\times10^9$	$\mathbf{4.2}\times10^9$

Table 1. (**Left**) ResNet-50. (**Right**) ResNeXt-50 with a 32×4d template (using the reformulation in Fig. 3(c)). Inside the brackets are the shape of a residual block, and outside the brackets is the number of stacked blocks on a stage. "C=32" suggests grouped convolutions [24] with 32 groups. *The numbers of parameters and FLOPs are similar between these two models.*

Xie et. al. Aggregated Residual Transformations for Deep Neural Networks. 2016

Squeeze-and-excitation blocks

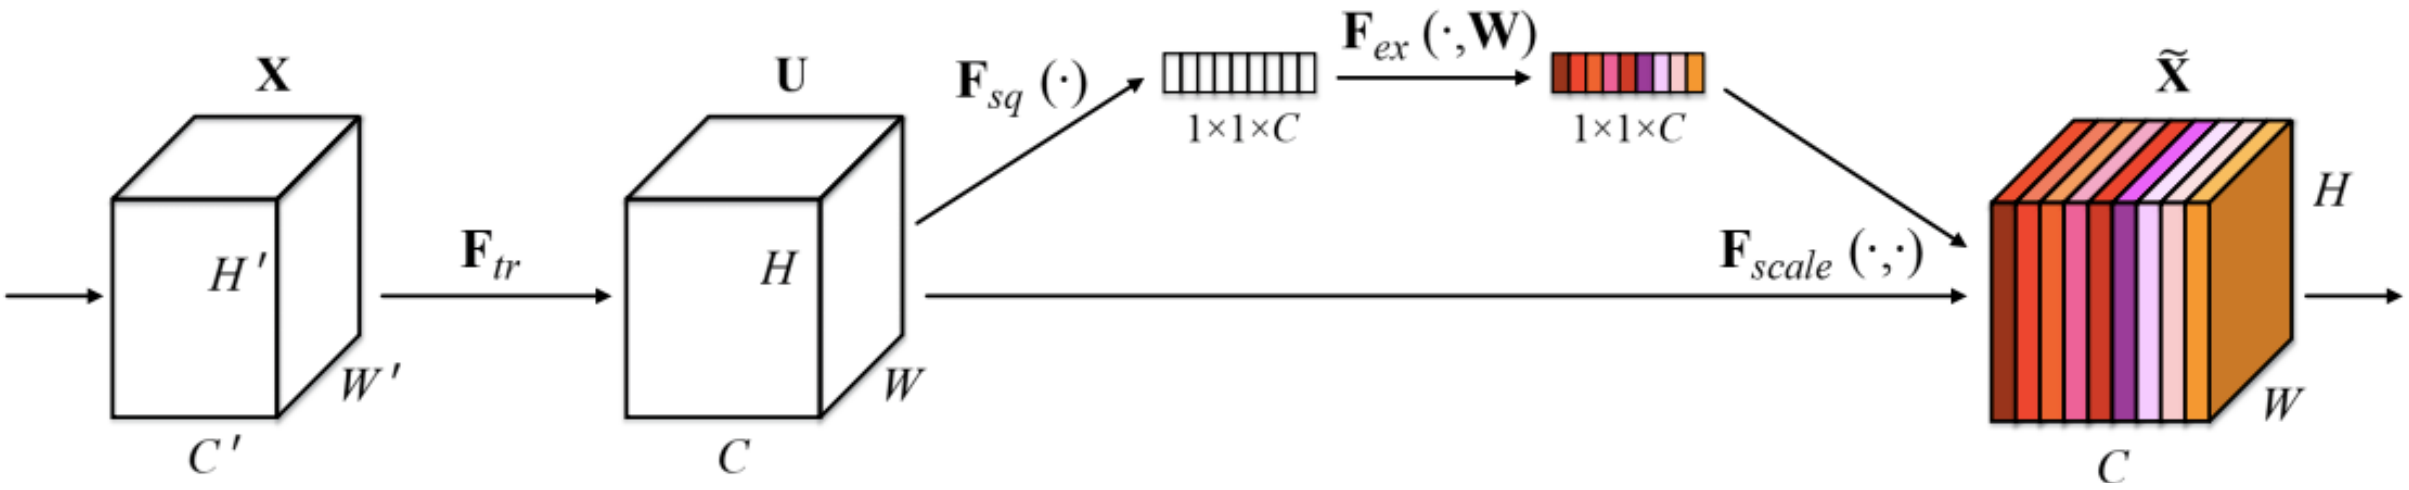

- Вариант «attention»
- Подчёркиваем определённые признаки (каналы)

	original		re-implementation			SENet		
	top-1 err.	top-5 err.	top-1 err.	top-5 err.	GFLOPs	top-1 err.	top-5 err.	GFLOPs
ResNet-50 [9]	24.7	7.8	24.80	7.48	3.86	$23.29_{(1.51)}$	$6.62_{(0.86)}$	3.87
ResNet-101 [9]	23.6	7.1	23.17	6.52	7.58	$22.38_{(0.79)}$	$6.07_{(0.45)}$	7.60
ResNet-152 [9]	23.0	6.7	22.42	6.34	11.30	$21.57_{(0.85)}$	$5.73_{(0.61)}$	11.32
ResNeXt-50 [43]	22.2	-	22.11	5.90	4.24	$21.10_{(1.01)}$	$5.49_{(0.41)}$	4.25
ResNeXt-101 [43]	21.2	5.6	21.18	5.57	7.99	$20.70_{(0.48)}$	$5.01_{(0.56)}$	8.00
BN-Inception [14]	25.2	7.82	25.38	7.89	2.03	$24.23_{(1.15)}$	$7.14_{(0.75)}$	2.04
Inception-ResNet-v2 [38]	$19.9^{\dagger}$	$4.9^{\dagger}$	20.37	5.21	11.75	$19.80_{(0.57)}$	$4.79_{(0.42)}$	11.76

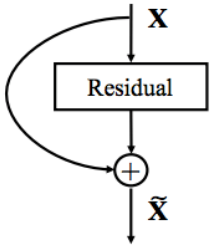

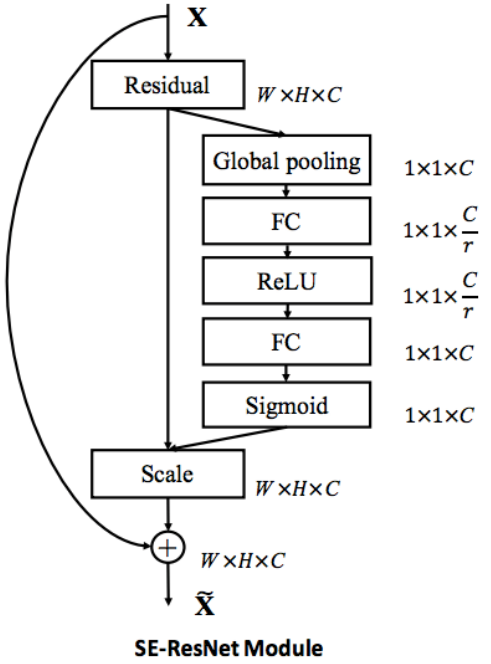

Проблема теоретической сложности

- Теоретическая вычислительная сложность плохо коррелирует с реальной производительностью модели
- Например, VGG-16 требует в 8.4x раз больше FLOPS, чем EfficientNet-B3 (о ней далее), но работает в 1.8 раз быстрее на GPU
- Поэтому у VGG-16 практическая «вычислительная плотность» (computational density) в 15 раз выше, чем у EfficientNet
- Почему так происходит?

Практическая производительность

- Разные блоки с разной эффективностью реализуются
  - Winograd Convolution обеспечивает высокую эффективность для 3x3 свёрток
- Разная степень параллелизма
  - Каждый новый тип операции в блоке влечёт дополнительные расходы (overhead) и повышает фрагментацию
- Доступ к памяти (MAC) очень затратен по времени
- Дополнительные затраты памяти в процессе работы также снижают практическую производительность

Kernel size	Theoretical FLOPs (B)	Time usage (ms)	Theoretical TFLOPS
1×1	420.9	84.5	9.96
3×3	3788.1	198.8	**38.10**
5×5	10522.6	2092.5	10.57
7×7	20624.4	4394.3	9.38

Вычислительная плотность разных свёрток

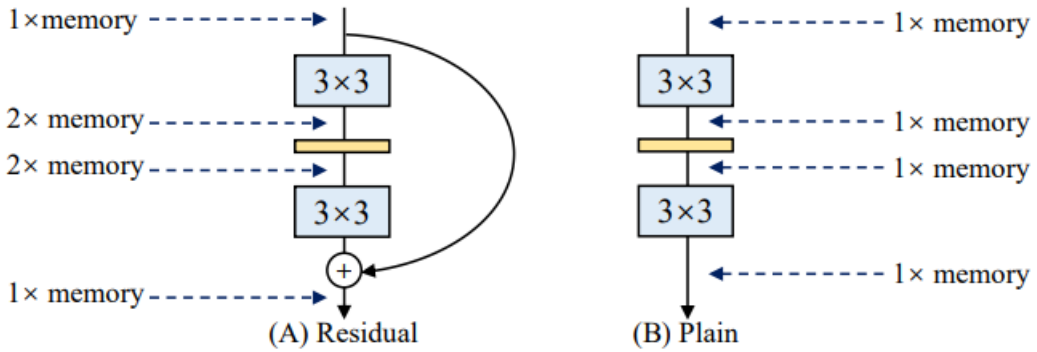

Затраты памяти при вычислении обходных путей

Репараметризация сетей

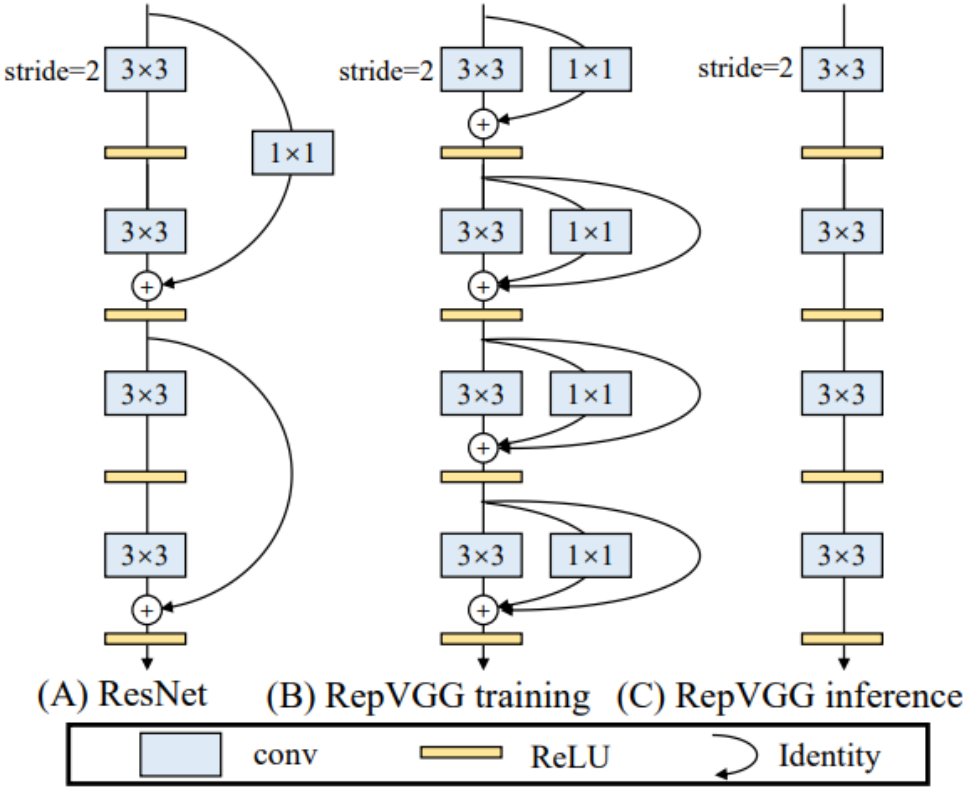

Учим модель с ветками, а затем объединяем в одну метку для инференса

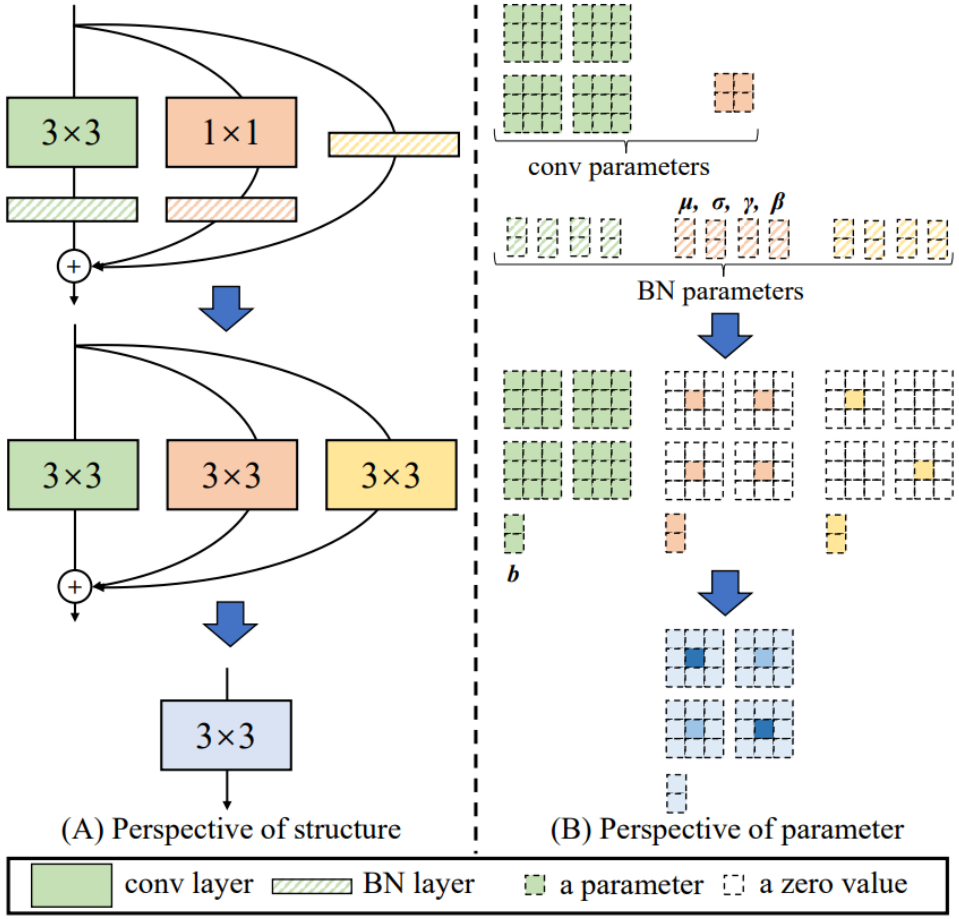

Визуализация репараметризации набора веток в одну свёртку

[RepVGG: Making VGG-style ConvNets Great Again (CVPR-2021)]

Как обучить мощную модель?

Процесс обучения играет большую роль

Модификация процесса обучения может повысить точность ResNet-50 с ~76% до ~82% на ImageNet

Основные идеи:

- Продвинутая аугментация изображений
- Трюки в процессе обучения
  - Warmup
  - Cosine/linear decay learning rate
  - Exponential Moving Average (EMA)
- Дистилляция нейросети

CutMix

	ResNet-50	Mixup [48]	Cutout [3]	CutMix
Image				
Label	Dog 1.0	Dog 0.5 Cat 0.5	Dog 1.0	Dog 0.6 Cat 0.4
ImageNet Cls (%)	76.3 (+0.0)	77.4 (+1.1)	77.1 (+0.8)	**78.6** **(+2.3)**
ImageNet Loc (%)	46.3 (+0.0)	45.8 (-0.5)	46.7 (+0.4)	**47.3** **(+1.0)**
Pascal VOC Det (mAP)	75.6 (+0.0)	73.9 (-1.7)	75.1 (-0.5)	**76.7** **(+1.1)**

Yun et.al. CutMix: Regularization Strategy to Train Strong Classifiers with Localizable Features. https://arxiv.org/abs/1905.04899 (Naver)

Дистилляция

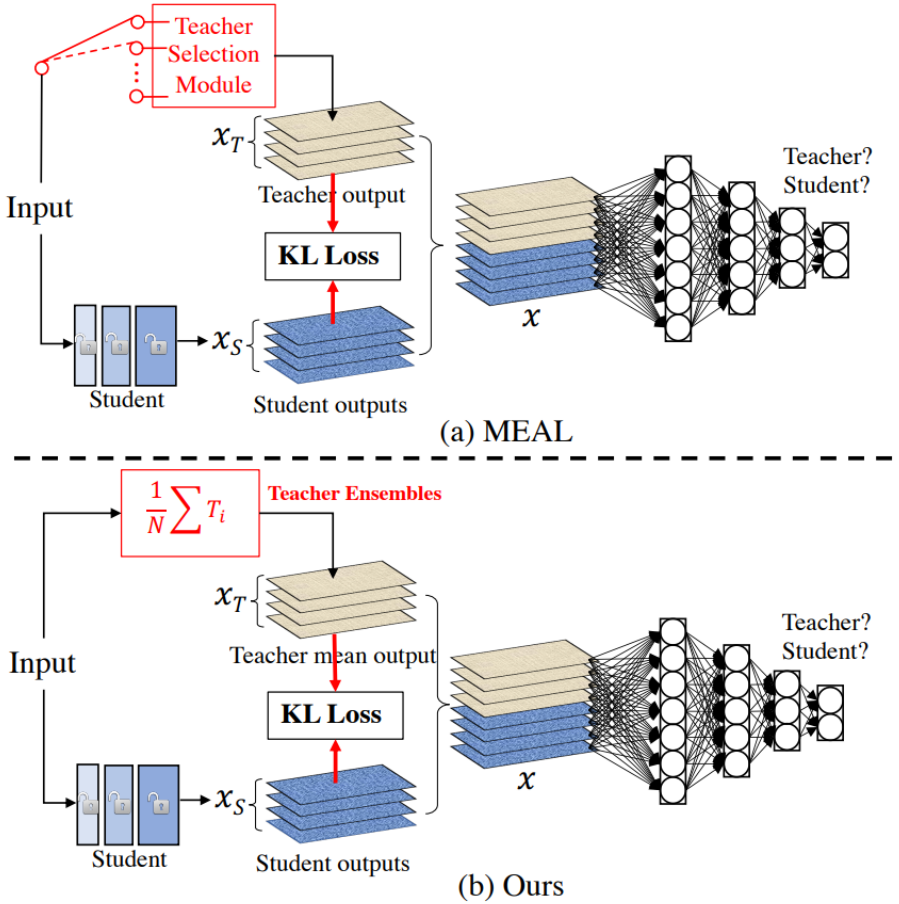

Figure 1. An illustration of the comparison between MEAL [18] and our method. We use an ensemble of all teacher networks instead of the teacher selection module as adopted in MEAL.

- Дистилляция – обучения сети студента так, чтобы его выходы были похожи на сеть-учителя
- Есть множество методов дистилляции
- Пример – MEAL V2
  - Берём комитет мощных учителей
  - Усредняем их выходы
  - Требуем от ученика похожести выходов на учителя
  - Добавляем классификатор учитель/ученик по признакам, градиент

Zhiqiang Shen, Marios Savvides "MEAL V2: Boosting Vanilla ResNet-50 to 80%+ Top-1 Accuracy on ImageNet without Tricks» NeurIPS 2020 workshop.

Результаты

Network	Resolution	#Params	Top-1 (%)	Top-5 (%)
ResNet-50	224	25.6M	76.51	93.20
ResNet-50 + DropBlock, (kp=0.9) [5]	224	25.6M	78.13	94.02
ResNet-50 + DropBlock (kp=0.9) [5] + label smoothing (0.1)	224	25.6M	78.35	94.15
ResNet-50 + MEAL [18]	224	25.6M	78.21	94.01
ResNet-50 + Ours (MEAL V2)	224	25.6M	**80.67**	**95.09**
ResNet-50 + FixRes [22]	384	25.6M	79.0	94.6
ResNet-50 + FixRes (*) [22]	384	25.6M	79.1	94.6
ResNet-50 + Ours (MEAL V2)	380	25.6M	**81.72**	**95.81**
ResNet-50 + FixRes [22] + CutMix	320	25.6M	79.7	94.9
ResNet-50 + FixRes [22] + CutMix (*)	320	25.6M	79.8	94.9
ResNet-50 + Ours (MEAL V2) + CutMix	**224**	25.6M	**80.98**	**95.35**

Zhiqiang Shen, Marios Savvides "MEAL V2: Boosting Vanilla ResNet-50 to 80%+ Top-1 Accuracy on ImageNet without Tricks» NeurIPS 2020 workshop.

Быстрые свёрточные модели

SqueezeNet

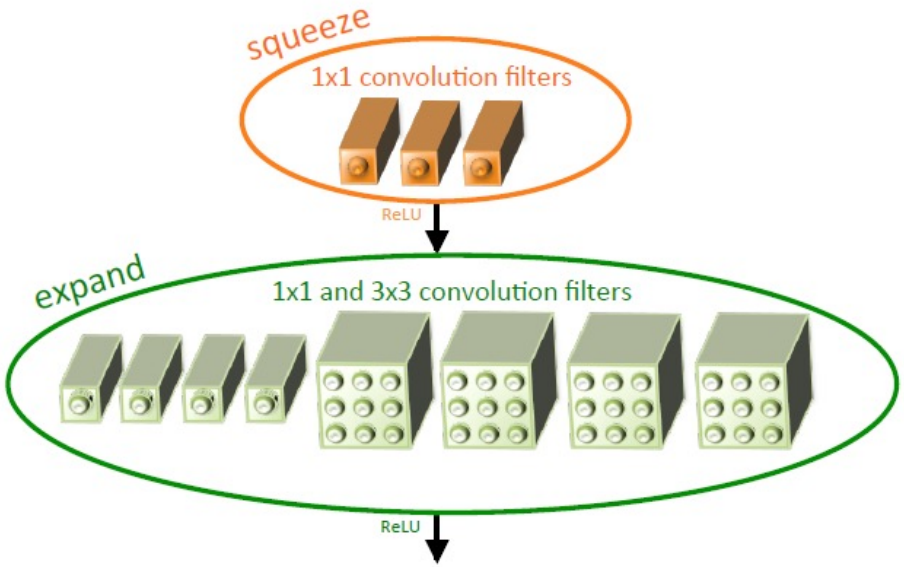

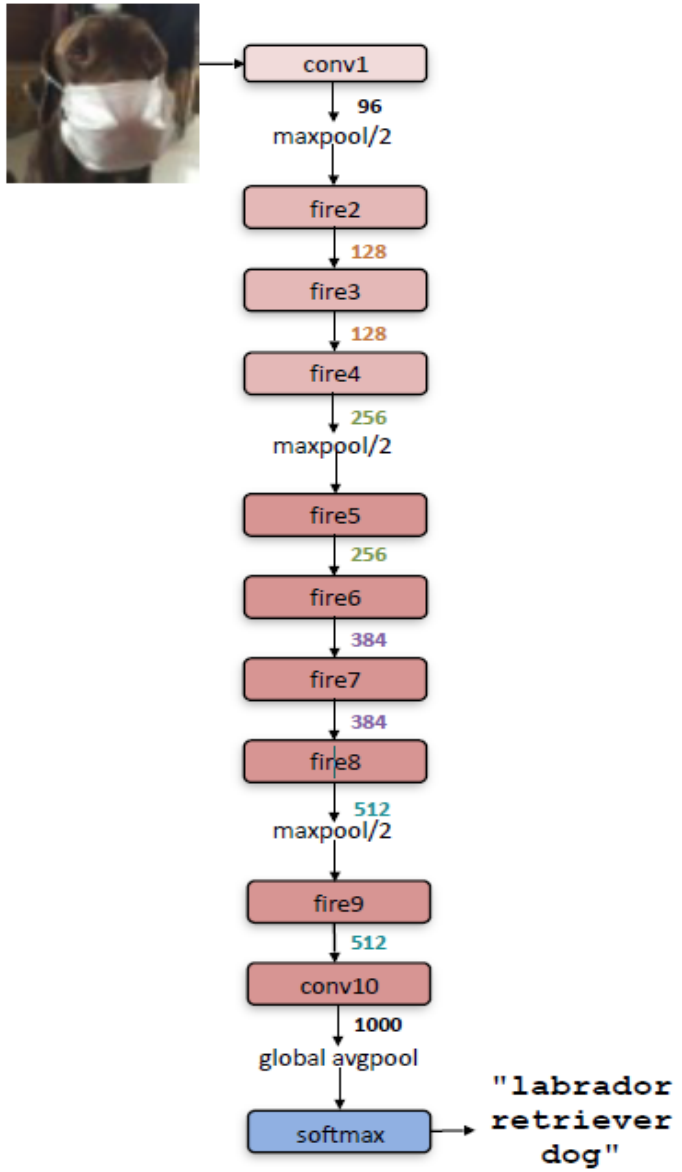

- Активно использовать 1x1 свёртки для уменьшения числа параметров
- «Сжимать» мы будем для того, чтобы на вход 3x3 фильтрам подавать меньше данных

Forrest N. Iandola et.al. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size. ArXiv 2016

Факторизация свёртки

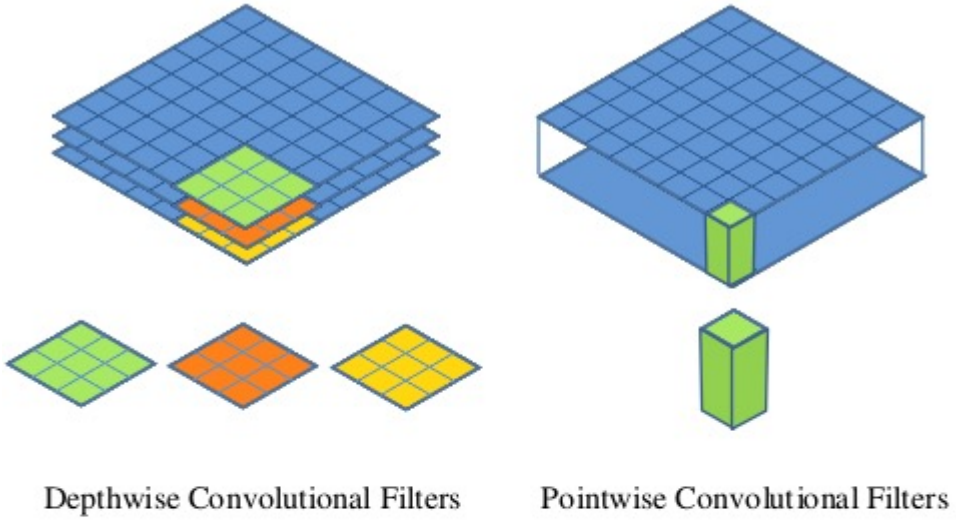

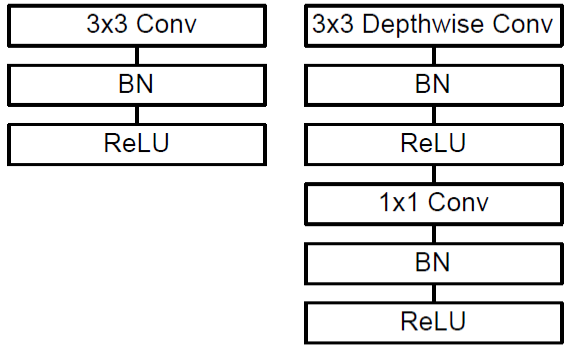

Figure 3. Left: Standard convolutional layer with batchnorm and ReLU. Right: Depthwise Separable convolutions with Depthwise and Pointwise layers followed by batchnorm and ReLU.

- Факторизуем свёртку в «послойную» (deepwise) и поточечную (pointwise)
- Сложность обычного свёрточного слоя:

  $D_k \cdot D_k \cdot M \cdot N \cdot D_f \cdot D_f$, где D_k - разрешение входа, M – число каналов входа, N – число каналов выхода и D_f - разрешение выхода

- Сложность комбинации depthwise convolution + pointwise convolution::

$$D_K \cdot D_K \cdot M \cdot D_F \cdot D_F + M \cdot N \cdot D_F \cdot D_F$$

MobileNet

Table 6. MobileNet Width Multiplier

Width Multiplier	ImageNet Accuracy	Million Mult-Adds	Million Parameters
1.0 MobileNet-224	70.6%	569	4.2
0.75 MobileNet-224	68.4%	325	2.6
0.5 MobileNet-224	63.7%	149	1.3
0.25 MobileNet-224	50.6%	41	0.5

Table 7. MobileNet Resolution

Resolution	ImageNet Accuracy	Million Mult-Adds	Million Parameters
1.0 MobileNet-224	70.6%	569	4.2
1.0 MobileNet-192	69.1%	418	4.2
1.0 MobileNet-160	67.2%	290	4.2
1.0 MobileNet-128	64.4%	186	4.2

Table 8. MobileNet Comparison to Popular Models

Model	ImageNet Accuracy	Million Mult-Adds	Million Parameters
1.0 MobileNet-224	70.6%	569	4.2
GoogleNet	69.8%	1550	6.8
VGG 16	71.5%	15300	138

Table 4. Depthwise Separable vs Full Convolution MobileNet

Model	ImageNet Accuracy	Million Mult-Adds	Million Parameters
Conv MobileNet	71.7%	4866	29.3
MobileNet	70.6%	569	4.2

- VGG-подобная архитектура с факторизованными свёртками

Howard et.al. MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications. https://arxiv.org/abs/1704.04861

MobileNetV2

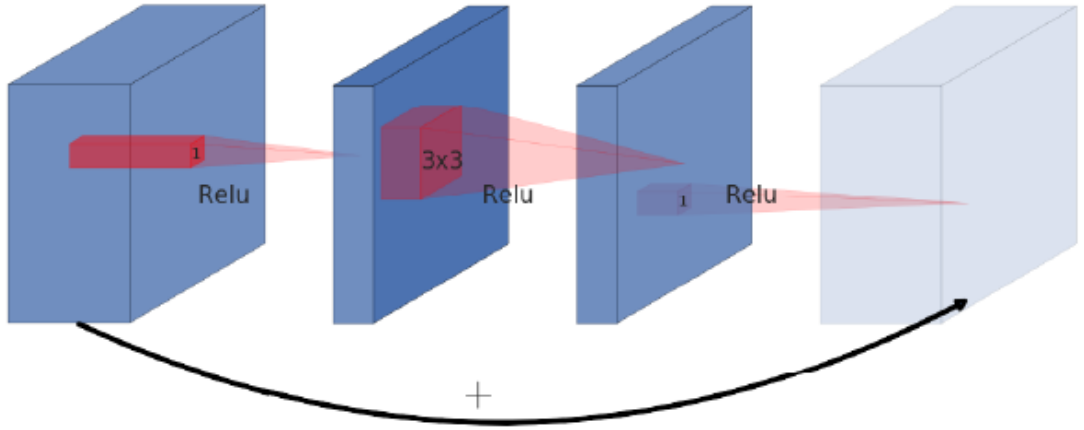

Обычный residual block

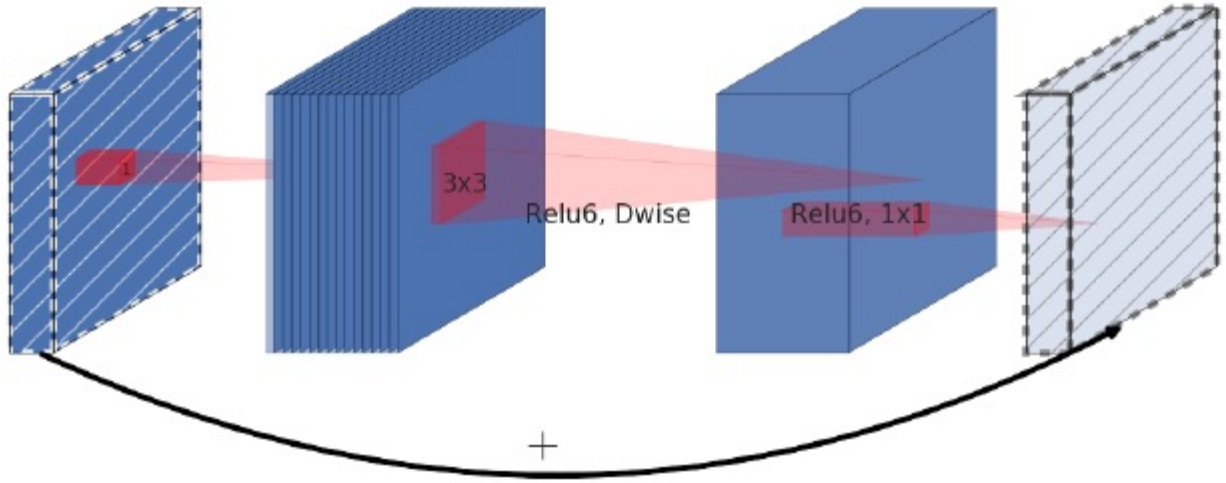

Инвертированный residual block

В чём разница?

https://arxiv.org/abs/1801.04381

EfficientNet

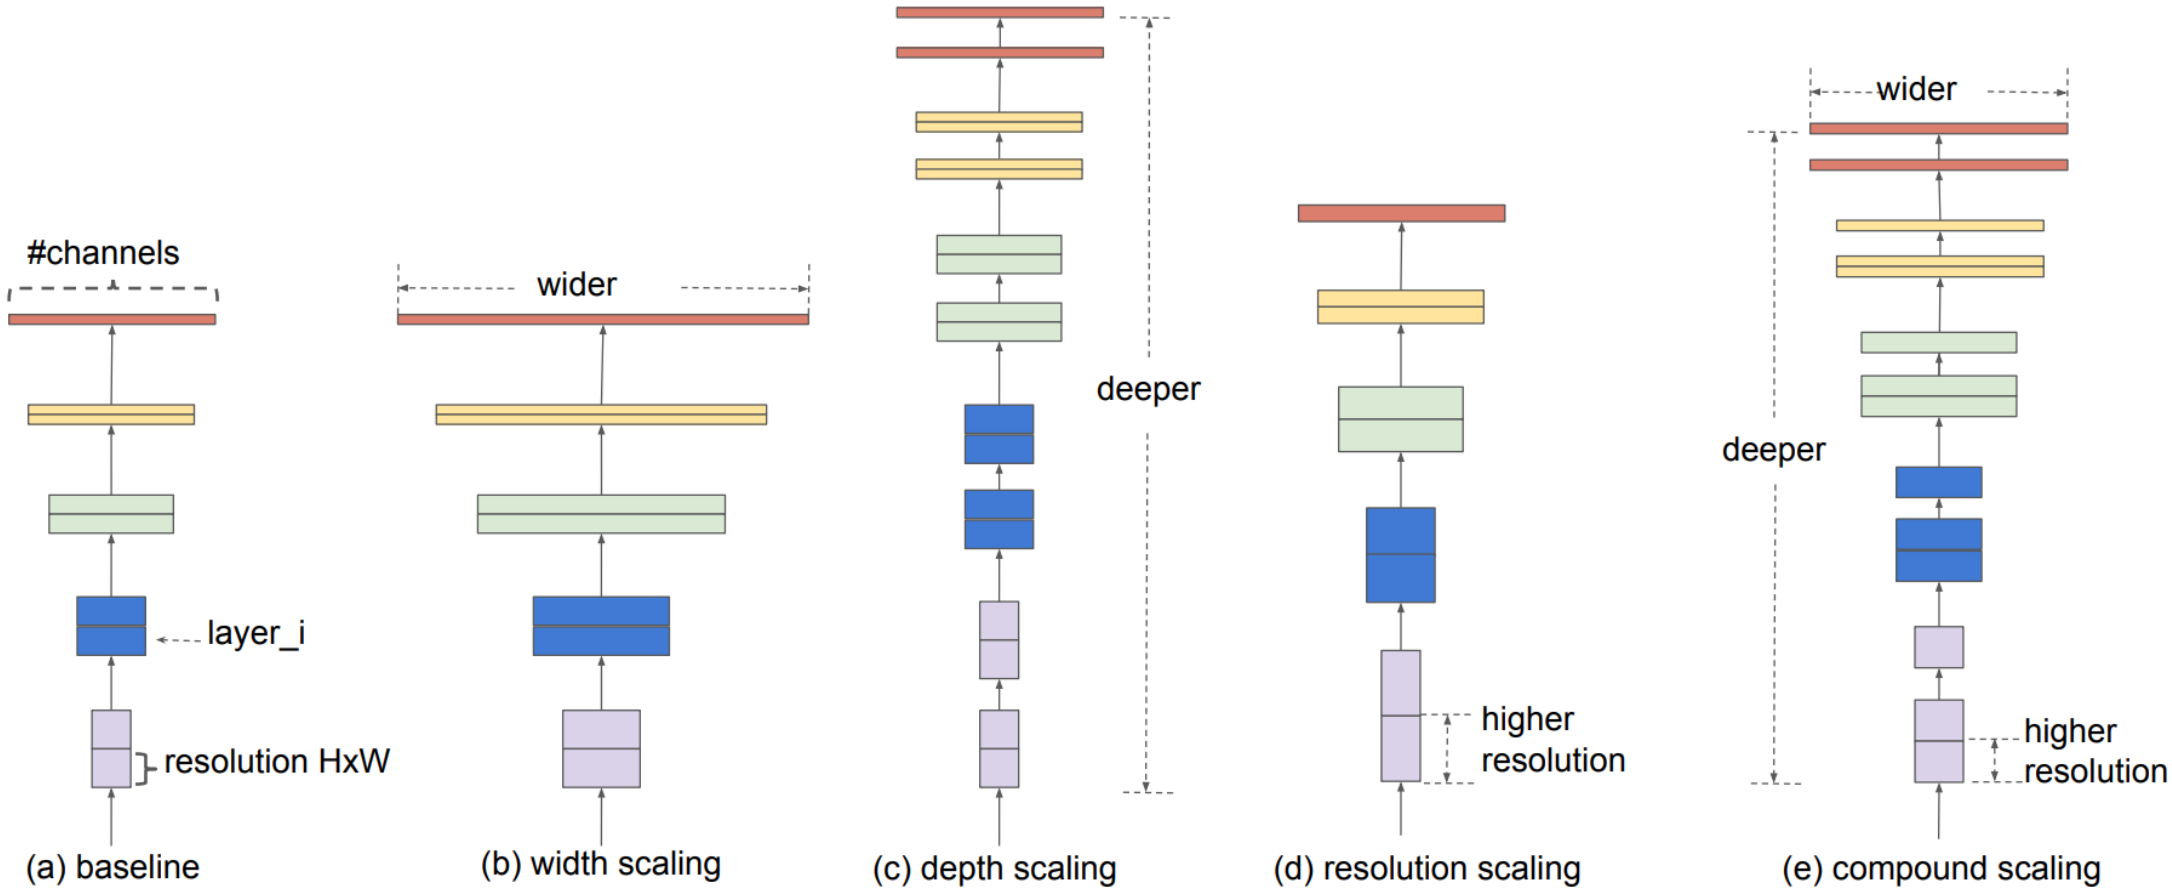

Выделяем коэффицент масштабирования для пропорционального увеличения сложности всех элементов

Tan and Le, EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. https://arxiv.org/abs/1905.11946

EfficientNet

$$\text{depth: } d = \alpha^\phi$$
$$\text{width: } w = \beta^\phi$$
$$\text{resolution: } r = \gamma^\phi$$
$$\text{s.t. } \alpha \cdot \beta^2 \cdot \gamma^2 \approx 2$$
$$\alpha \geq 1, \beta \geq 1, \gamma \geq 1$$

Stage i	Operator $\hat{\mathcal{F}}_i$	Resolution $\hat{H}_i \times \hat{W}_i$	#Channels $\hat{C}_i$	#Layers $\hat{L}_i$
1	Conv3x3	224×224	32	1
2	MBConv1, k3x3	112×112	16	1
3	MBConv6, k3x3	112×112	24	2
4	MBConv6, k5x5	56×56	40	2
5	MBConv6, k3x3	28×28	80	3
6	MBConv6, k5x5	28×28	112	3
7	MBConv6, k5x5	14×14	192	4
8	MBConv6, k3x3	7×7	320	1
9	Conv1x1 & Pooling & FC	7×7	1280	1

Tan and Le, EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. https://arxiv.org/abs/1905.11946

Семейство EfficientNetB0-B7

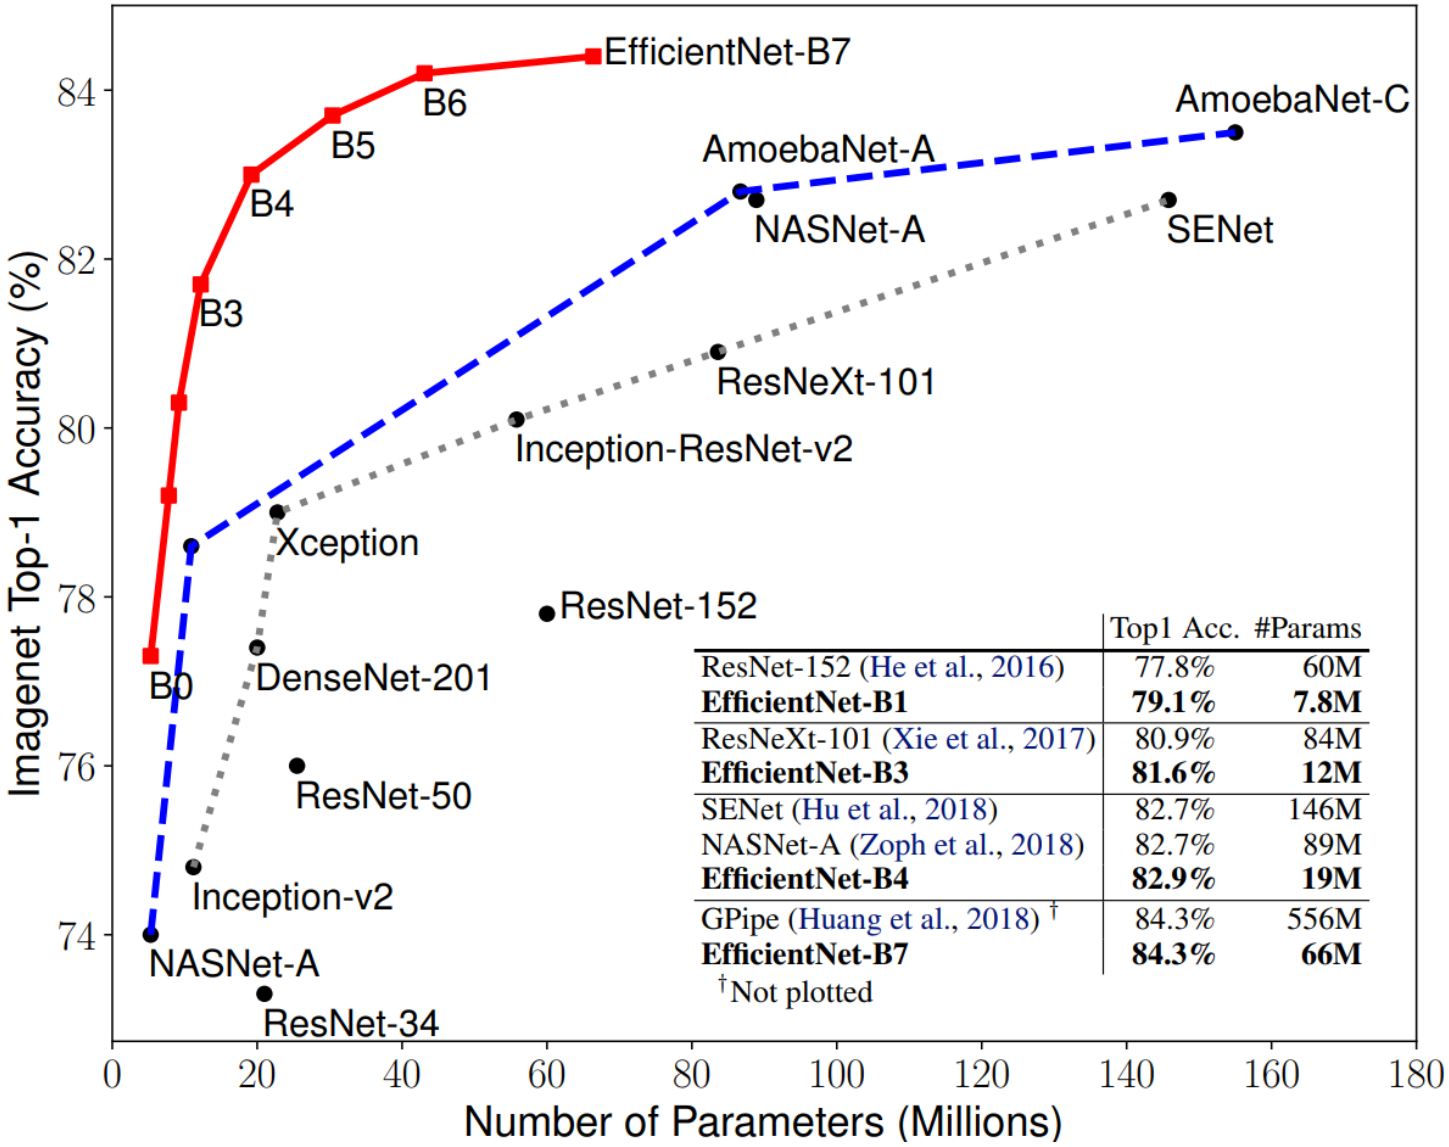

	Top1 Acc.	#Params
ResNet-152 (He et al., 2016)	77.8%	60M
EfficientNet-B1	**79.1%**	**7.8M**
ResNeXt-101 (Xie et al., 2017)	80.9%	84M
EfficientNet-B3	**81.6%**	**12M**
SENet (Hu et al., 2018)	82.7%	146M
NASNet-A (Zoph et al., 2018)	82.7%	89M
EfficientNet-B4	**82.9%**	**19M**
GPipe (Huang et al., 2018) †	84.3%	556M
EfficientNet-B7	**84.3%**	**66M**

†Not plotted

MobileOne

- Тщательное измерение влияния разных факторов на время инференса именно на мобильных устройствах
- Ветки, сложные функции активации, размер изображения резко снижают производительность
- Берём MobileNetV1, учим с ветками + репараметризация
- Учим хорошо, со всеми трюками + дистилляцияей

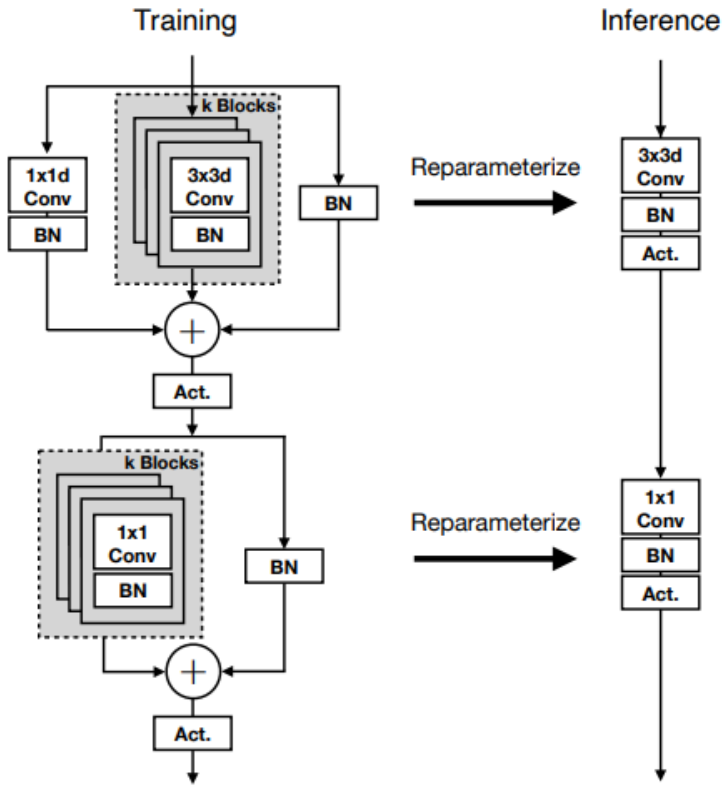

Базовый блок, похожий на MobileNetV1 + skip connection + репараметризация

Activation Function	Latency (ms)
ReLU [1]	1.53
GELU [27]	1.63
SE-ReLU [32]	2.10
SiLU [15]	2.54
Dynamic Shift-Max [36]	57.04
DynamicReLU-A [6]	273.49
DynamicReLU-B [6]	242.14

Table 2. Comparison of latency on mobile device of different activation functions in a 30-layer convolutional neural network.

Kumar et.al. MobileOne: An Improved One millisecond Mobile Backbone. CVPR 2023

MobileOne

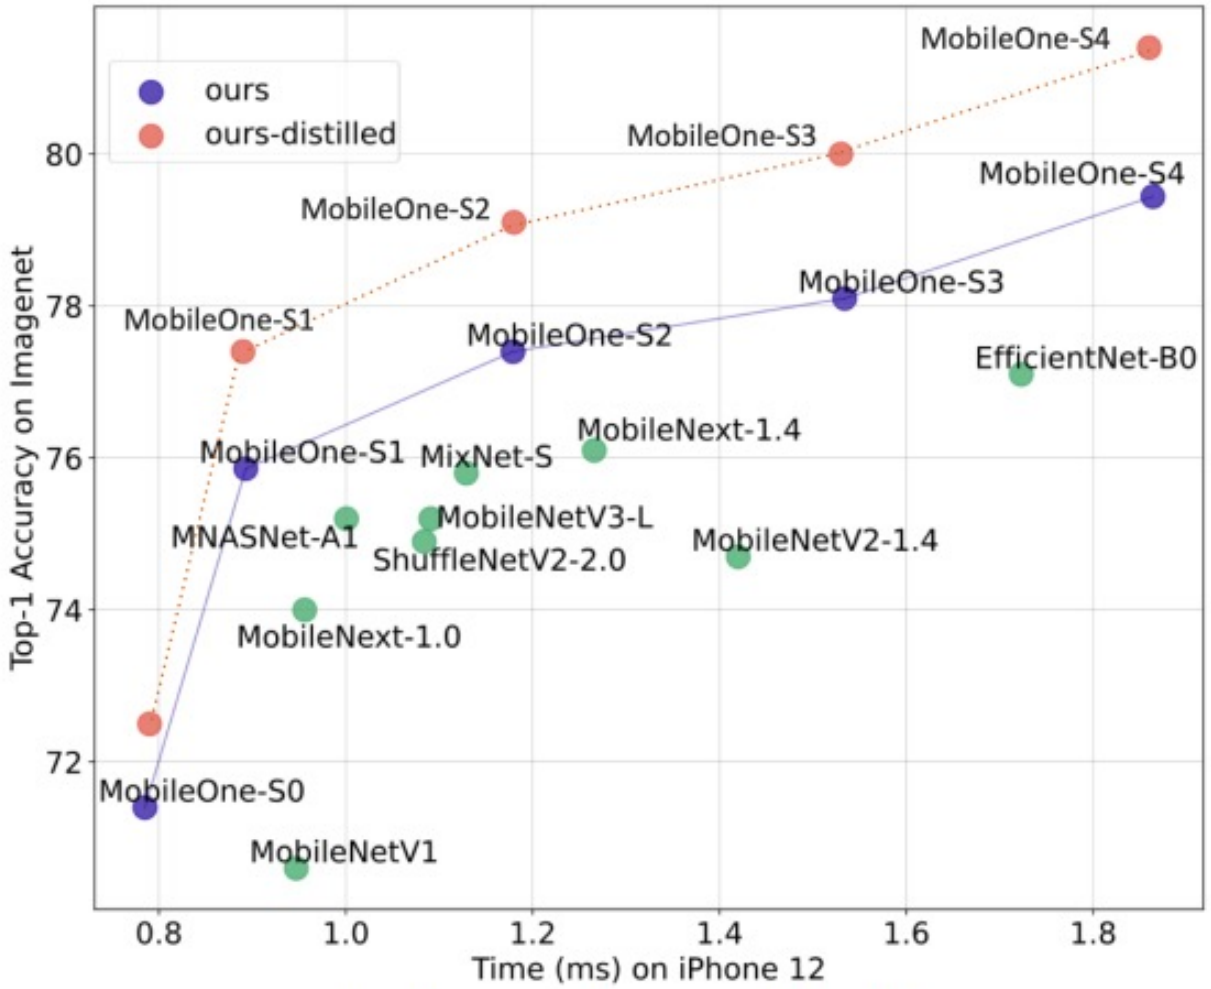

(a) Top 1 accuracy vs Latency on iPhone 12.

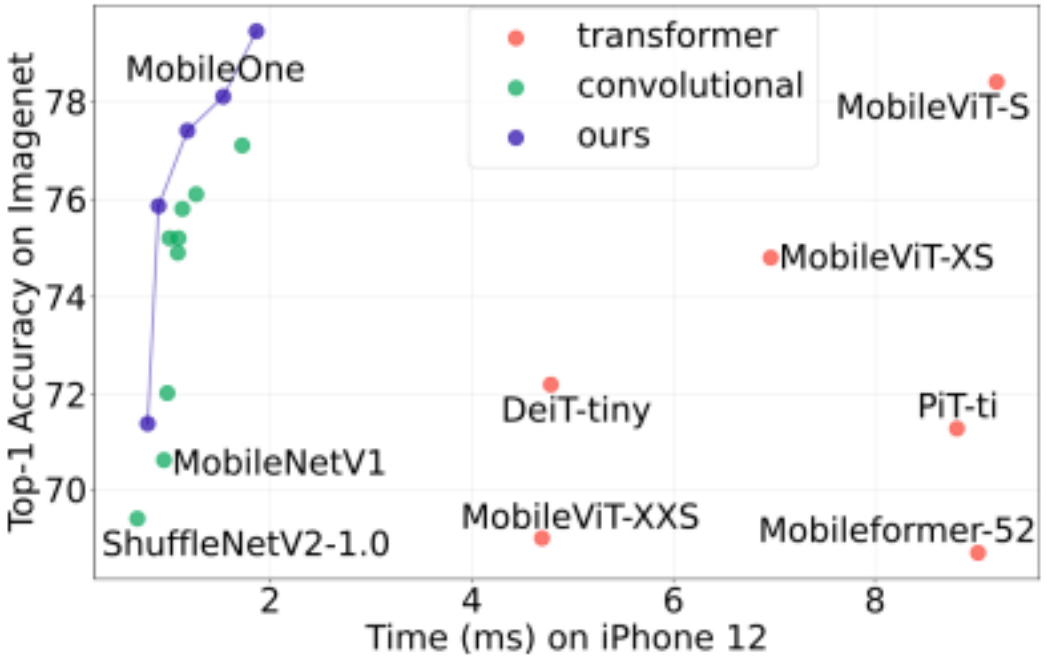

(b) Zoomed out (a)

Эффективные свёрточные сети пока обходят трансформеные модели на мобильных устройствах

[Kumar et.al. MobileOne: An Improved One millisecond Mobile Backbone. CVPR 2023]

Насколько хороша ImageNet?

Примеры работы

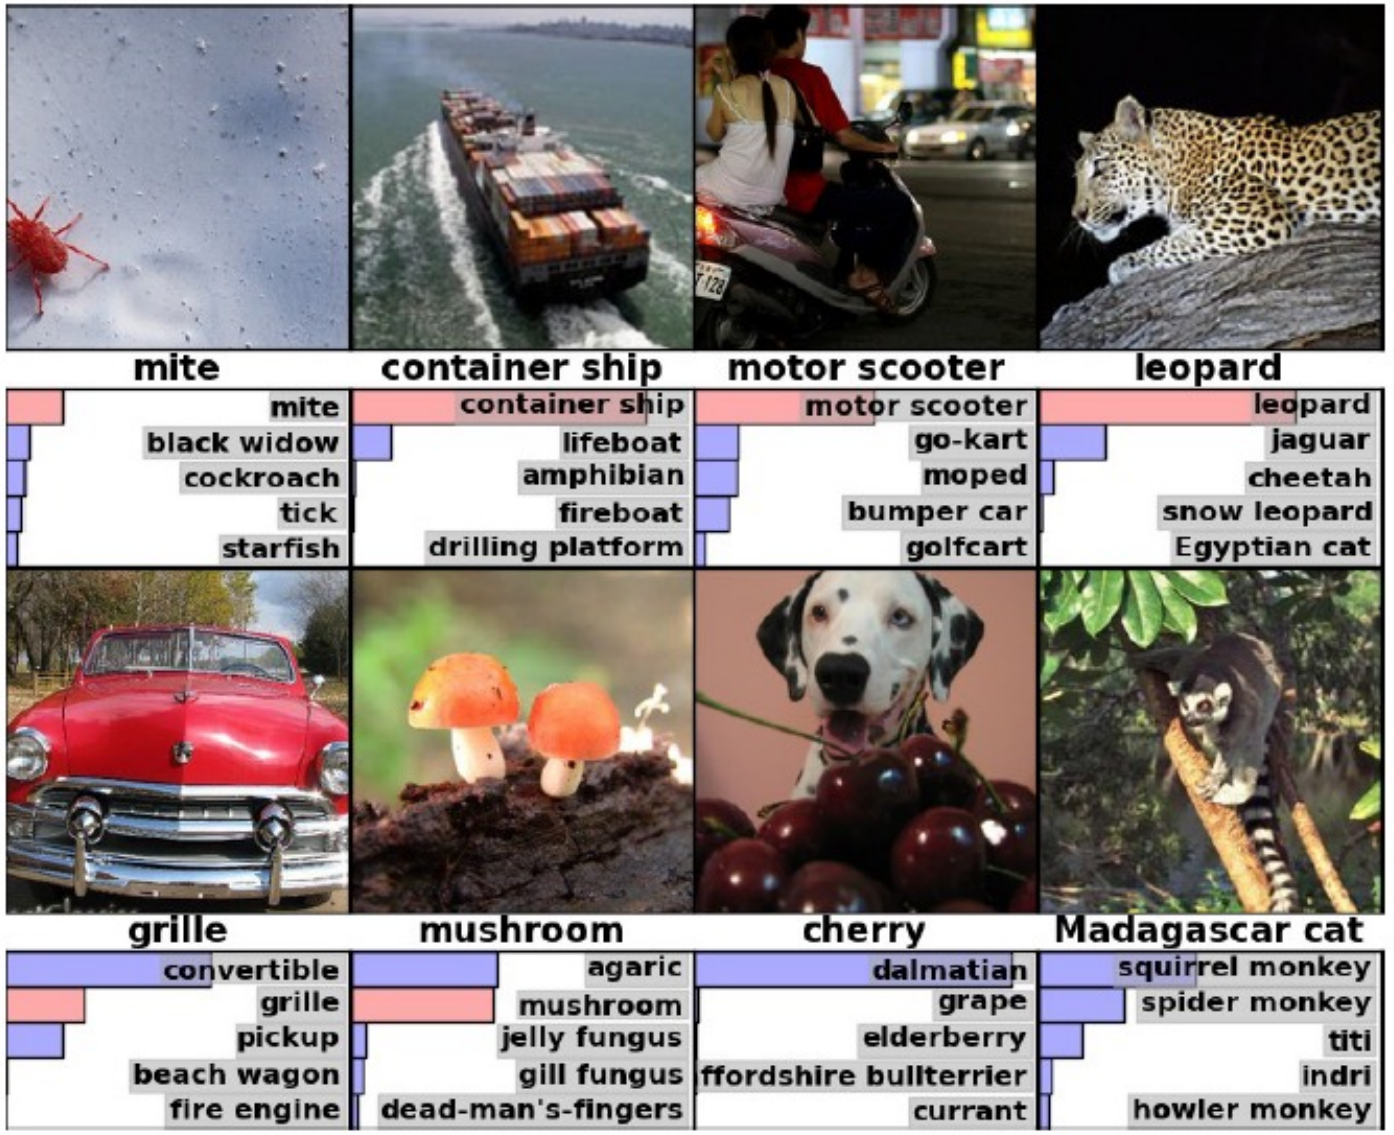

Проблемы ImageNet

Old label: pier
ReaL: dock; pier; speedboat; sandbar; seashore

Old label: hammer
ReaL: screwdriver; hammer; power drill; carpenter's kit

Old label: monitor
ReaL: mouse; desk; desktop computer; lamp; studio couch; monitor; computer keyboard

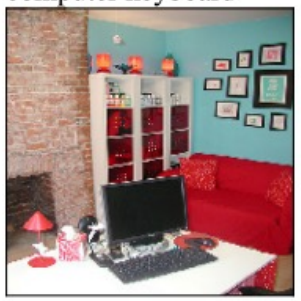

Old label: zucchini
ReaL: broccoli; zucchini; cucumber; orange; lemon; banana

Old label: ant
ReaL: ant; ladybug

Old label: quill
ReaL: feather boa

Old label: water jug
ReaL: water bottle

Old label: chain
ReaL: necklace

Old label: purse
ReaL: wallet

Old label: passenger car
ReaL: school bus

Old label: sunglass
ReaL: sunglass; sunglasses

Old label: sunglasses
ReaL: sunglass; sunglasses

Old label: laptop
ReaL: notebook; laptop; computer keyboard

Old label: notebook
ReaL: notebook; laptop; computer keyboard

Old label: laptop
ReaL: notebook; laptop

Переоценка последних методов

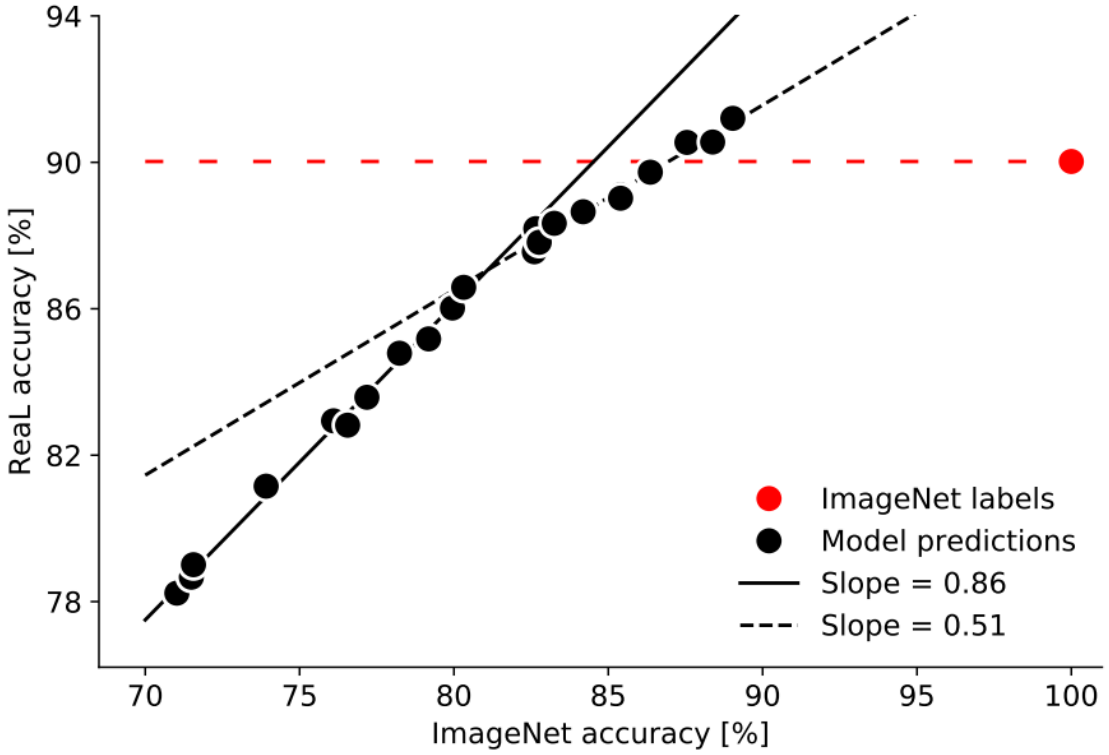

Figure 4: Comparing progress on ReaL accuracy and the original ImageNet accuracy. We measured the association between both metrics by regressing ImageNet accuracy onto ReaL accuracy for the first (solid line) and second half (dashed line) of the models in our pool.

Возможность улучшения

Table 2: Top-1 accuracy (in percentage) on ImageNet with our proposed sigmoid loss and clean label set. Median accuracy from three runs is reported for all the methods. Either sigmoid loss or clean label set leads to consistent improvements over baseline. Using both achieves the best performance. The improvement of our proposed method is more pronounced with longer training schedules.

	Model	ImageNet accuracy			ReaL accuracy		
		90 epochs	270 epochs	900 epochs	90 epochs	270 epochs	900 epochs
ResNet-50	Baseline	76.0	76.9 (+0.9)	75.9 (-0.1)	82.5	82.9 (+0.4)	81.6 (-0.9)
	+ Sigmoid	76.3 (+0.3)	77.8 (+1.8)	76.9 (+0.9)	83.0 (+0.5)	83.9 (+1.4)	82.7 (+0.2)
	+ Clean	76.4 (+0.4)	77.8 (+1.8)	77.4 (+1.4)	82.8 (+0.3)	83.7 (+1.2)	83.3 (+0.8)
	+ Both	76.6 (+0.6)	78.2 (+2.2)	**78.5** (+2.5)	83.1 (+0.6)	**84.3** (+1.8)	84.1 (+1.6)
ResNet-152	Baseline	78.0	78.3 (+0.3)	77.1 (-0.9)	84.1	83.8 (-0.3)	82.3 (-1.8)
	+ Sigmoid	78.5 (+0.5)	78.7 (+0.7)	77.4 (-0.6)	84.6 (+0.5)	84.3 (+0.2)	82.7 (-1.4)
	+ Clean	78.6 (+0.6)	79.6 (+1.6)	79.0 (+1.0)	84.4 (+0.3)	85.0 (+0.9)	84.4 (+0.3)
	+ Both	78.7 (+0.7)	**79.8** (+1.8)	79.3 (+1.3)	84.6 (+0.5)	**85.2** (+1.1)	84.5 (+0.4)

Beyer et. al. Are we done with ImageNet? https://arxiv.org/pdf/2006.07159.pdf

Использование других данных

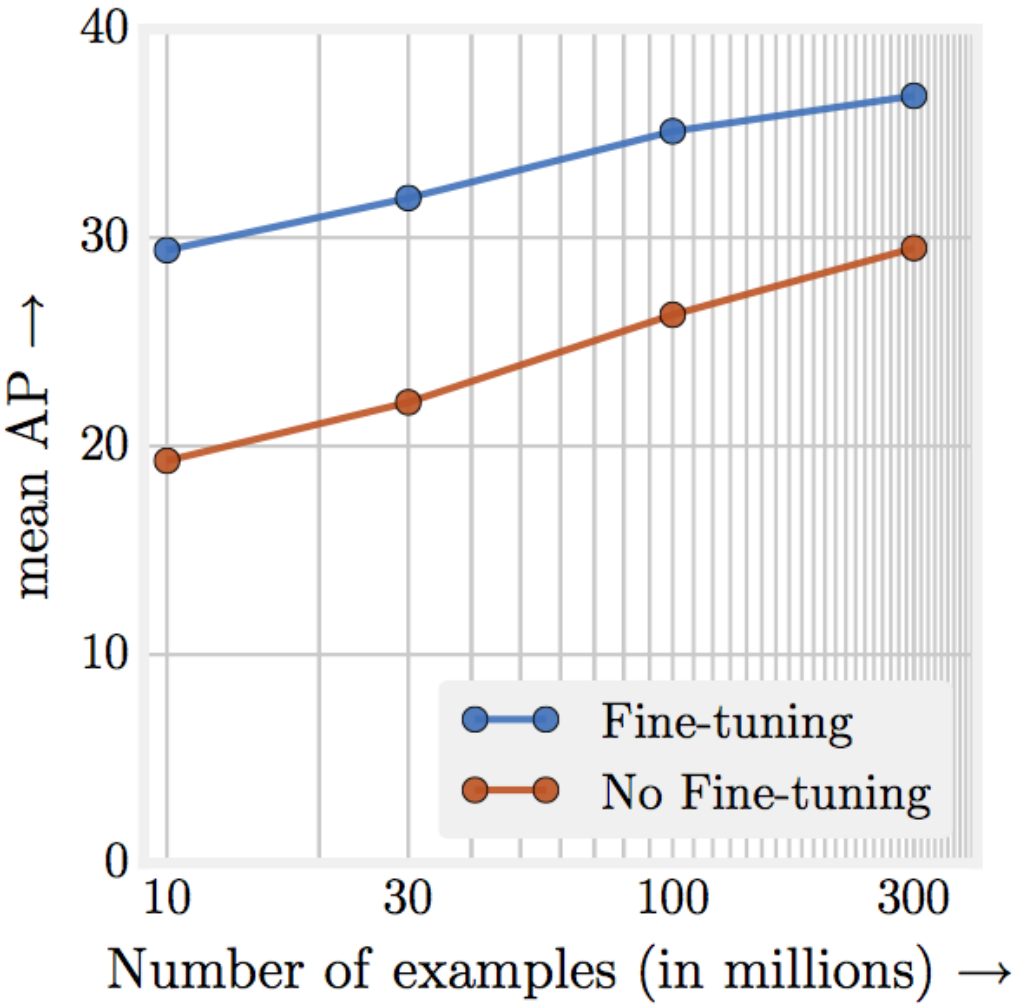

Precision on MS COCO

- JFT-300M by Google
- 300M изображений,, 1B меток 18291 категорий
- После фильтрации осталось 375M меток, но всё равно ~20% ошибок
- Обучение ResNet-101 на 50 x K80 в течение месяца
- Полученную модель использовали как предобученную для решения других задач

Chen Sun et. al. Revisiting Unreasonable Effectiveness of Data in Deep Learning Era. https://arxiv.org/abs/1707.02968

Резюме базовых классификаторов

- Основные принципы построения архитектур
  - Строим глубокие модели из похожих блоков
  - Большие свёртки можно приближать последовательностью свёрток 3x3
  - Свёртки 1x1 позволяют управлять «толщиной» слоя и уменьшать вычислительную сложность
  - Можно обработать данные параллельно в нескольких ветвях и затем объединить
  - Residual-связи (или skip-connections) позволяют снизить проблему затухания градиента и обучать очень глубокие сети, но на инференсе их лучше убирать
  - Развиваем attention и факторизуем свёртки
- Обучить лучше на больших коллекциях, использовать хитрые (и странные) аугментации и аккуратно чистить тестовые данные