

Глубокие нейросети со структурированным выводом: обзор результатов и открытых проблем

Виктор Лемпицкий
СколТех



Семинар НМУ, 17/12/2016

План

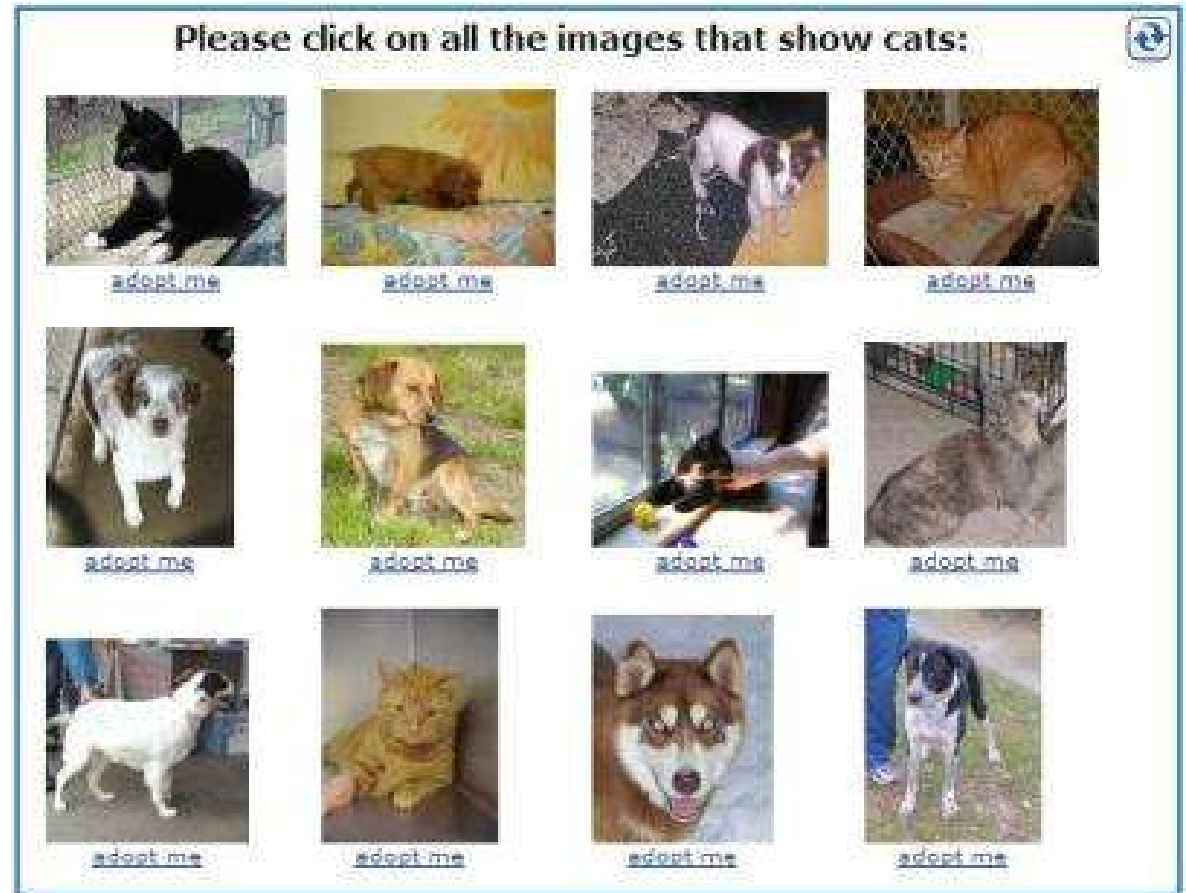
1. «Стандартные» свёрточные сети
2. «Практическая» оптимизация
3. Синтезирующие сети с простыми функциями потерь
4. Синтез через повторение статистик
5. Играющие сети (adversarial networks)

План

1. «Стандартные» свёрточные сети
2. «Практическая» оптимизация
3. Синтезирующие сети с простыми функциями потерь
4. Синтез через повторение статистик
5. Играющие сети (adversarial networks)

2006

CAPTCHA



Компьютерное зрение= 60%

$$0.6^{12} = 0.00217$$

2014



Completed • Swag • 215 teams

Dogs vs. Cats

Wed 25 Sep 2013 – Sat 1 Feb 2014 (8 months ago)

Dashboard

Private Leaderboard - Dogs vs. Cats

This competition has completed. This leaderboard reflects the final standings.

See someone's

#	Δ1w	Team Name <small>* in the money</small>	Score ⓘ	Entries	Last Submission UTC (Best – Last)
1	—	Pierre Sermanet *	0.98914	5	Sat, 01 Feb 2014 21:43:19 (-)
2	↑26	orchid *	0.98309	17	Sat, 01 Feb 2014 23:52:30
3	—	Owen	0.98171	15	Sat, 01 Feb 2014 17:04:40 (-)
4	new	Paul Covington	0.98171	3	Sat, 01 Feb 2014 23:05:20
5	↓3	Maxim Milakov	0.98137	24	Sat, 01 Feb 2014 18:20:58

$$0.989^{12} = 0.875$$

“Глубокие нейросети со структурированным выводом”

2014

Microsoft Research

Search M

[Our research](#)

[Connections](#)

[Careers](#)

[About us](#)

[All](#)

[Downloads](#)

[Events](#)

[Groups](#)

[News](#)

[People](#)

[Projects](#)


[Publications](#)

ASIRRA



After 8 years of operation, Asirra is shutting down effective October 1, 2014. Thank you to all of our users!

Сверточная нейросеть



Операции (слои):



- обобщенные свертки
- макс-пулинг
- поэлементные нелинейности
- умножение на матрицу («полносвязный слой»)

Два типа переменных:

- Активации («карты», «нейроны», «представление»)
- Параметры слоёв («фильтры», «ядра»)


“Глубокие нейросети со структурированным выводом”

Представления внутри нейросети



“Глубокие нейросети со структурированным выводом”


Производная сложной функции



$$\frac{dz}{dy} = \begin{bmatrix} \frac{\partial g}{\partial y_1}(y_1, y_2) \\ \frac{\partial g}{\partial y_2}(y_1, y_2) \end{bmatrix}$$

$$\frac{\partial z}{\partial x_1} = \frac{\partial z}{\partial y} \cdot \frac{\partial y_1}{\partial x_1} + \frac{\partial z}{\partial y_2} \cdot \frac{\partial y_2}{\partial x_1}$$

Производная сложной функции



$$\frac{\partial z}{\partial x_1} = \frac{\partial z}{\partial y_1} \cdot \frac{\partial y_1}{\partial x_1} + \frac{\partial z}{\partial y_2} \cdot \frac{\partial y_2}{\partial x_1}$$

$$\frac{\partial z}{\partial x_2} = \frac{\partial z}{\partial y_1} \cdot \frac{\partial y_1}{\partial x_2} + \frac{\partial z}{\partial y_2} \cdot \frac{\partial y_2}{\partial x_2}$$

Производная сложной функции

$$\frac{\partial z}{\partial x_1} = \frac{\partial z}{\partial y} \cdot \frac{\partial y_1}{\partial x_1} + \frac{\partial z}{\partial y_2} \cdot \frac{\partial y_2}{\partial x_1}$$

$$\frac{\partial z}{\partial x_2} = \frac{\partial z}{\partial y} \cdot \frac{\partial y_1}{\partial x_2} + \frac{\partial z}{\partial y_2} \cdot \frac{\partial y_2}{\partial x_2}$$

$$\frac{dz}{dx} \begin{bmatrix} \frac{\partial z}{\partial x_1} \\ \frac{\partial z}{\partial x_2} \end{bmatrix} = \begin{bmatrix} \frac{\partial y_1}{\partial x} & \frac{\partial y_2}{\partial x} \\ \frac{\partial y_1}{\partial x_2} & \frac{\partial y_2}{\partial x_2} \end{bmatrix} \begin{bmatrix} \frac{\partial z}{\partial y_1} \\ \frac{\partial z}{\partial y_2} \end{bmatrix}$$

Производная сложной функции

$$\frac{dz}{dx} \begin{pmatrix} \frac{\partial z}{\partial x_1} \\ \frac{\partial z}{\partial x_2} \end{pmatrix} = \begin{bmatrix} \frac{\partial y_1}{\partial x} & \frac{\partial y_2}{\partial x} \\ \frac{\partial y_1}{\partial x_2} & \frac{\partial y_2}{\partial x_2} \end{bmatrix} \begin{pmatrix} \frac{\partial z}{\partial y_1} \\ \frac{\partial z}{\partial y_2} \end{pmatrix}$$

$$\frac{dz}{dx} = \left(\frac{dy}{dx} \right)^T \frac{dz}{dy}$$

Обратное распространение

$$\frac{dz}{dw_3} = \frac{dx^3}{dw_3}^T \cdot \frac{dz}{dx^3}$$


$$\frac{dz}{dx^2} = \frac{dx^3}{dx^2}^T \cdot \frac{dz}{dx^3}$$

$$\frac{dz}{dw_2} = \frac{dx^2}{dw_2}^T \cdot \frac{dz}{dx^2}$$


$$\frac{dz}{dx^1} = \frac{dx^2}{dx^1}^T \cdot \frac{dz}{dx^2}$$

$$\frac{dz}{dw_1} = \frac{dx^1}{dw_1}^T \cdot \frac{dz}{dx^1}$$

$$\frac{dz}{dx^0} = \frac{dx^1}{dx^0}^T \cdot \frac{dz}{dx^1}$$



Обучение обратным распространением



[Leibnitz;
L'Hopital 1696]



$$(f \circ g)'(x) = g'(x) \cdot f'(g(x))$$

Операции (слои):

обобщенные свертки

макс-пулинг

поэлементные нелинейности

умножение на матрицу

Определение новых слоев



Каждый слой определяется:

- прямым распространением: $y = f(x)$
- обратным распространением:

$$z(x) \quad z(f(x; w)) \quad y = f(x; w)$$

$$\frac{dz}{dx} = \frac{dy^T}{dx} \cdot \frac{dz}{dy}$$


$$\frac{dz}{dw} = \frac{dy^T}{dw} \cdot \frac{dz}{dy}$$

ООП и глубокое обучение

```
abstract class Layer {  
    params w,dzdw;  
    virtual y = forward(x);  
    virtual dzdx = backward(dzdy,x,y);  
    // should compute dzdw as well  
  
    void update (tau) {  
        w = w+tau*dzdw;  
    }  
};
```

На практике нужно использовать векторные и матричные операции

Обобщенная свертка




$$V(x, y, t) = \sum_{i=x-\delta}^{x+\delta} \sum_{j=y-\delta}^{y+\delta} \sum_{s=1}^S K(i - x + \delta, j - y + \delta, s, t) U(i, j, s)$$

- Локально-линейное преобразование
- «Самый важный» слой в компьютерном зрении


Идея сверточного слоя

[Image credit: Arturo Deza]



$$V(x, y, t) = \sum_{i=x-\delta}^{x+\delta} \sum_{j=y-\delta}^{y+\delta} \sum_{s=1}^S K(i - x + \delta, j - y + \delta, s, t) U(i, j, s)$$

Сверточная нейросеть



Операции (слои):
обобщенные свертки
макс-пулинг
поэлементные нелинейности
умножение на матрицу

2012: Image-net

IMAGENET

www.image-net.org

14,197,122 изображений,
21841 классов

Statistics of high level categories

High level category	# synset (subcategories)	Avg # images per synset	Total # images
amphibian	94	591	56K
animal	3822	732	2799K
appliance	51	1164	59K
bird	856	949	812K
covering	946	819	774K
device	2385	675	1610K
fabric	262	690	181K
fish	566	494	280K
flower	462	735	339K
food	1495	670	1001K
fruit	309	607	188K

(большей
частью работа
идет с
подмножеством
1000x1000)

Image-net

Soccer, association football

A football game in which two teams of 11 players try to kick or head a ball into the opponents' goal

1395
pictures

90.76%
Popularity
Percentile



Numbers in brackets: (the number of synsets in the subtree).

- ImageNet 2011 Fall Release (32326)
 - plant, flora, plant life (4486)
 - geological formation, formation (1)
 - natural object (1112)
 - sport, athletics (176)
 - rowing, row (2)
 - funambulism, tightrope walking
 - judo (0)
 - blood sport (10)
 - gymnastics, gymnastic exercis
 - water sport, aquatics (19)
 - track and field (5)
 - outdoor sport, field sport (17)
 - contact sport (18)
 - boxing, pugilism, fisticuffs (
 - wrestling, rassling, grapplir
 - ice hockey, hockey, hockey
 - football, football game (5)
 - rugby, rugby football, rug
 - professional football (0)
 - American football, Amer
 - soccer, association foot
 - team sport (0)
 - racing (7)
 - athletic game (70)
 - riding, horseback riding, equita
 - archery (0)
 - cycling (3)
 - sledding (3)
 - skatino (6)

Treemap Visualization

Images of the Synset

Downloads



*Images of children synsets are not included. All images shown are thumbnails. Images may be subject to copyright.

Prev 1 2 3 4 5 6 7 8 9 10 ... 39 40 Next

Image-net

Flying lemur, flying cat, colugo

Arboreal nocturnal mammal of southeast Asia and the Philippines resembling a lemur and having a fold of skin on each side from neck to tail that is used for long gliding leaps

45
pictures

61.09%
Popularity
Percentile

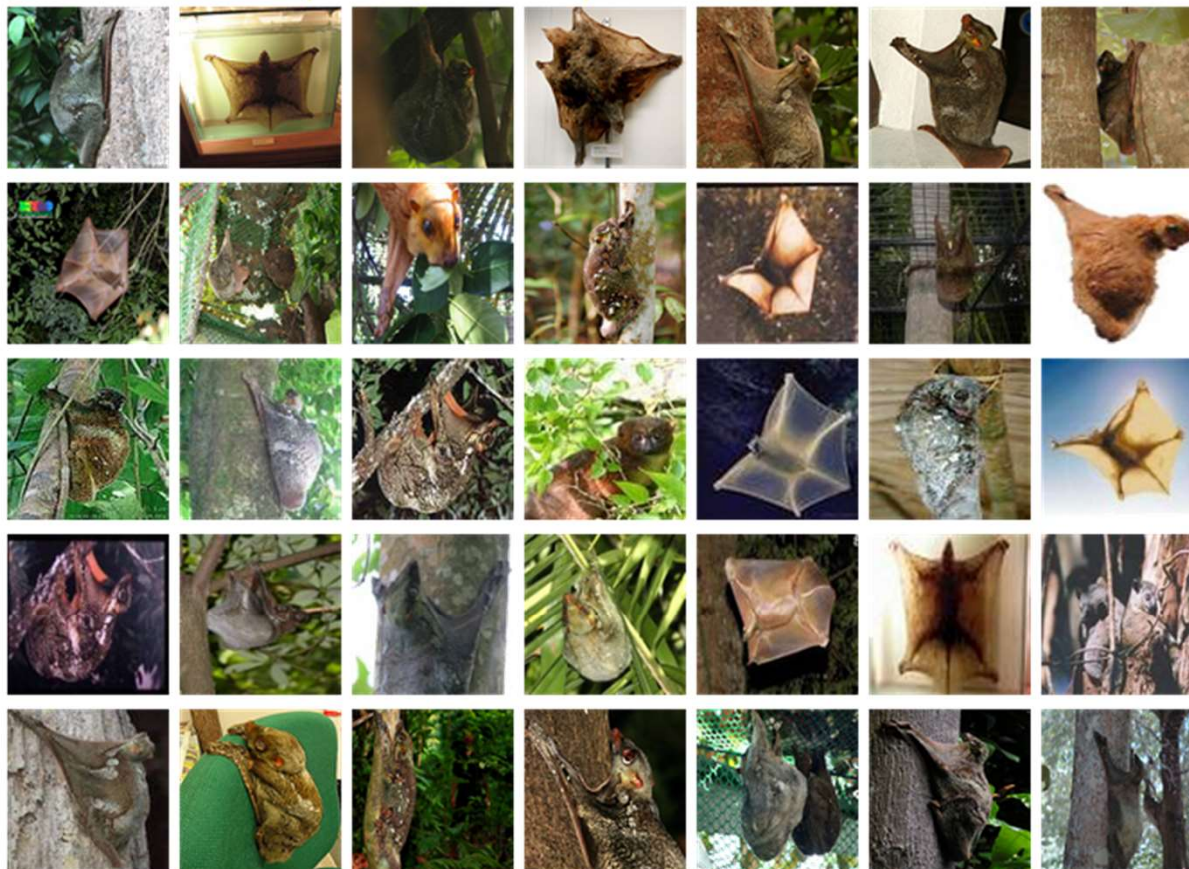


- ... biped (0)
- ... predator, predatory animal (1)
- ... larva (49)
- ... acrodont (0)
- ... feeder (0)
- ... stunt (0)
- ... chordate (3087)
- ... tunicate, urochordate, urochordate (1)
- ... cephalochordate (1)
- ... vertebrate, craniate (3077)
- ... mammal, mammalian (3143)
- ... fossorial mammal (3)
- ... placental, placental mammal (1715)
- ... lagomorph, gnawing mammal (1)
- ... primate (104)
- ... flying lemur, flying squirrel, Cynocephalus (45)
- ... tree shrew (1)
- ... proboscidean, proboscidean (1)
- ... aardvark, ant bear (1)
- ... Fissipedia (0)
- ... carnivore (365)
- ... plantigrade mammal (1)
- ... ungulate, ungulate (1)
- ... aquatic mammal (1)
- ... Ungulata (0)
- ... Ungulata (0)
- ... digitigrade mammal (1)
- ... ungulate, hoofed mammal (1)
- ... edentate (21)
- ... bat, chiropteran (1)
- ... pachyderm (10)
- ... pangolin, scaly anteater (1)

Treemap Visualization

Images of the Synset


Downloads



*Images of children synsets are not included. All images shown are thumbnails. Images may be subject to copyright.

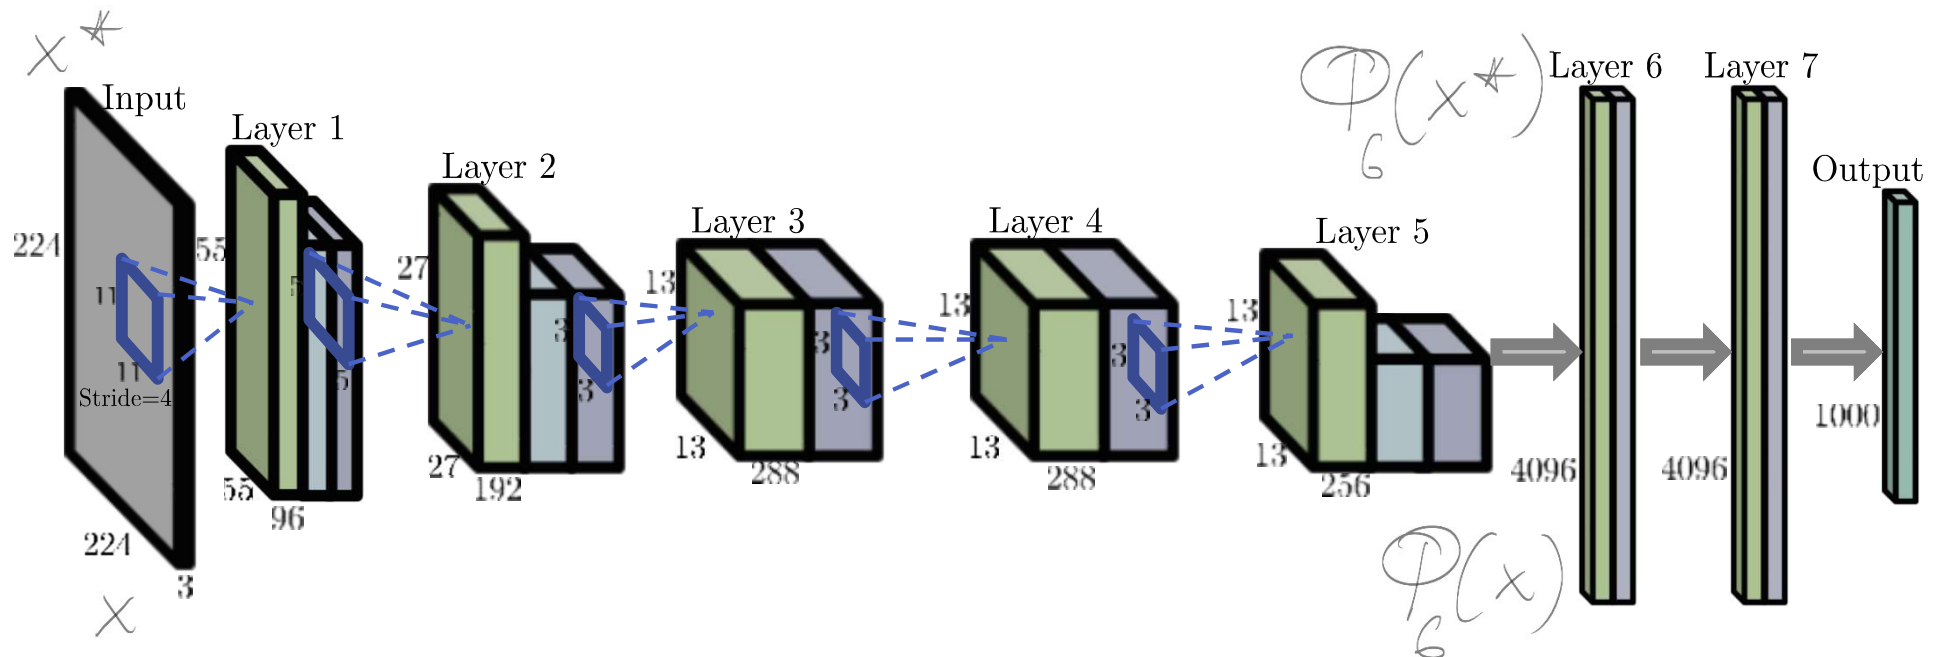
Prev 1 2 Next

Текущее состояние



- Практически достигнут уровень мозга в задаче классификации (изображение -> метка класса)
- Метка класса -> изображение = ?

Синтез через подсчет прообразов



$$\hat{X} = \arg\min_x Z(x) = \arg\min_x \|\Phi_G(x^*) - \Phi_G(x)\|^2 + \lambda R(x)$$

«Стандартная» регуляризация:



$$\sum \left((x_{i,j-1} - x_{i,j})^2 + (x_{i+1,j} - x_{i,j})^2 \right)^{\beta/2}$$

[Mahendran & Vedaldi CVPR15]

Синтез через подсчет прообразов


$$\hat{x} = \operatorname{argmin} \|\Phi(x^*) - \Phi(x)\|^2 + \lambda R(x)$$

[Mahendran & Vedaldi CVPR15]



“Глубокие нейросети со структурированным выводом”

Generating images by Inverting CNNs









[Mahendran & Vedaldi CVPR15]

$$x^* = \arg \min_x \| \Phi(x^*) - \Phi(x) \|^2 + \lambda R(x)$$

“Глубокие нейросети со структурированным выводом”


Синтез иллюзий для нейросети



[Szegedy, Zaremba, Sutskever, Bruna, Erhan, Goodfellow, Fergus 2014]

“Глубокие нейросети со структурированным выводом”

Синтез иллюзий для нейросети



$$\hat{r} = \arg \min_c |r| + L(x+r, k)$$

Вывод: негладкость $\Phi(x)$

[Szegedy, Zaremba, Sutskever, Bruna, Erhan, Goodfellow, Fergus 2014]

“Глубокие нейросети со структурированным выводом”

Иллюзии биологических нейросетей



“Глубокие нейросети со структурированным выводом”

План

1. «Стандартные» свёрточные сети
2. **«Практическая» оптимизация**
3. Синтезирующие сети с простыми функциями потерь
4. Синтез через повторение статистик
5. Играющие сети (adversarial networks)

Стохастический градиентный спуск

$$\begin{aligned}v[t] &= -\alpha[t] \nabla(E, w[t]) \\w[t+1] &= w[t] + v[t]\end{aligned}$$

где

$$\nabla(E, w[t]) = \frac{dE^{c(t)}}{dw} \Big|_{w[t]}$$

- $i(t)$ обычно соответствует случайной перестановке данных
- Один проход по всем данным обычно называется *эпохой*

Stochastic gradient descent (SGD)

$$\begin{aligned}v[t] &= -\alpha[t] \nabla(E, w[t]) \\w[t+1] &= w[t] + v[t]\end{aligned}$$

- Один проход по всем данным обычно называется *эпохой*
- Популярный выбор для $\alpha[t]$:
 - константа, напр. $\alpha[t] = 0.0001$
 - Кусочно-постоянный, напр. $\alpha[t]$ снижается в 10 раз каждые N эпох
 - гармоническое, напр. $\alpha[t] = 0.001 / ([t/N] + 10)$

Пакетный градиентный спуск

Градиент:

$$\frac{dE}{dw} = \frac{1}{N} \sum_{i=1}^N d\ell(x_i, y_i; w)$$

Пакет (батч, минибатч):

$$\{b_1, b_2, \dots, b_{N_b}\} \subset 1 \dots N$$

Пакетный градиентный спуск:


$$\frac{dE}{dw} = \frac{1}{N_b} \sum_{i=1}^{N_b} d\ell(x_{b(i)}, y_{b(i)}; w)$$

Причины для пакетирования?

$$\frac{dE}{dw} = \frac{1}{N_b} \sum_{i=1}^{N_b} d\ell(x_{b(i)} y_{b(i)} w)$$

- Менее шумная аппроксимация, «лучше» сходимость
- **Главная причина:** параллелизм современных архитектур

Проблемы стохастического спуска



- ..примерно те же, что у градиентного спуска

Улучшение СГС с помощью момента

- ...напоминает сопряженные градиенты (комбинируем градиент и предыдущее направление):

$$\begin{aligned}v[t] &= -\alpha[t] \nabla(E, w[t]) \\w[t+1] &= w[t] + v[t]\end{aligned}$$



$$\begin{aligned}v[t+1] &= \mu v[t] - \alpha[t] \nabla(E, w[t]) \\w[t+1] &= w[t] + v[t+1]\end{aligned}$$

Типичное значение $\mu = 0.9$

Скольльзящее экспоненициальное окно

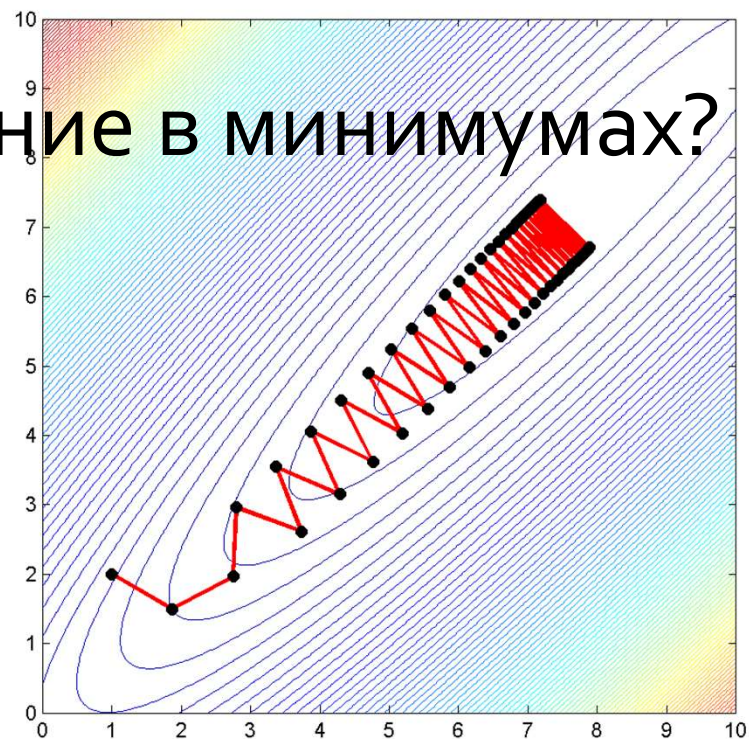
$$\begin{aligned}v[t+1] &= \mu v[t] - \alpha[t] \nabla (E, w[t]) \\w[t+1] &= w[t] + v[t+1]\end{aligned}$$

$$\begin{aligned}v[t+1] &= \mu v[t] - \alpha[t] \nabla (E, w[t]) = \\&= \mu^2 v[t-1] - \mu \alpha[t-1] \nabla (E, w[t-1]) \\&\quad - \alpha[t] \nabla (f, w[t]) = \\&= \mu^3 v[t-2] - \mu^2 \alpha[t-2] \nabla (E, w[t-2]) \\&\quad - \mu \alpha[t-1] \nabla (E, w[t-1]) - \alpha[t] \nabla (E, w[t]) = \\&= \mu^{k+1} v[t-k] + \sum_{i=0}^k \mu^i \alpha[t-i] \nabla (E, w[t-i])\end{aligned}$$

Причины улучшения

$$V[t+1] = \sum_{i=0}^k \mu^i \alpha[t-i] \nabla(E, w[t-i])$$

- Сглаживание шума СГС (~увеличение пакетов)
- **Сглаживание осцилляций, присущих ГС**
- Предотвращает застревание в минимумах?



Метод Нестерова

$$\begin{aligned}v[t+1] &= \mu v[t] - \alpha[t] \nabla(E, w[t]) \\w[t+1] &= w[t] + v[t+1]\end{aligned}$$

Еще до подсчета градиента знаем,
что: $w[t+1] \approx w[t] + \mu v[t]$

Считаем градиент в более «актуальном»
месте:

$$\begin{aligned}v[t+1] &= \mu v[t] - \alpha[t] \nabla(E, w[t] + \mu v[t]) \\w[t+1] &= w[t] + v[t+1]\end{aligned}$$

Adagrad method [Duchi et al. 2011]

Идея: корректировать движение по градиенту

$$g[t+1] = g[t] + \nabla(E, w[t]) \odot \nabla(E, w[t])$$


$$w[t+1] = w[t] - \frac{\alpha}{\sqrt{g[t] + \varepsilon}} \odot \nabla(E, w[t])$$

(Полу)-автоматическая подстройка скорости (уменьшение со временем)

Adagrad method [Duchi et al. 2011]

$$g[t+1] = g[t] + \nabla(E, w[t]) \odot \nabla(E, w[t])$$

$$w[t+1] = w[t] - \frac{\alpha}{\sqrt{g[t] + \varepsilon}} \odot \nabla(E, w[t])$$



RMSPROP [Hinton 2012]

Схоже с Adagrad, но накопление
заменяется экспоненциальным окном:

$$g[t+1] = \mu g[t] + (1 - \mu) \nabla(E, w[t]) \odot \nabla(E, w[t])$$

$$w[t+1] = w[t] - \frac{\alpha[t]}{\sqrt{g[t] + \epsilon}} \odot \nabla(E, w[t])$$

Adadelta [Zeiler 2012]

Идея: ускорение вдоль «монотонно»
улучшающихся измерений

$$g[t+1] = \mu g[t] + (1 - \mu) \nabla(E, w[t]) \odot \nabla(E, w[t])$$

$$w[t+1] = w[t] - \frac{\sqrt{d[t] + \epsilon}}{\sqrt{g[t] + \epsilon}} \odot \nabla(E, w[t])$$

$$d[t+1] = \mu d[t] + (1 - \mu) (w[t+1] - w[t]) \odot (w[t+1] - w[t])$$

Adadelta [Zeiler 2012]

$$g[t+1] = \mu g[t] + (1 - \mu) \nabla(E, w[t]) \odot \nabla(E, w[t])$$

$$w[t+1] = w[t] - \frac{\sqrt{d[t]} + \epsilon}{\sqrt{g[t]} + \epsilon} \odot \nabla(E, w[t])$$

$$d[t+1] = \mu d[t] + (1 - \mu) (w[t+1] - w[t]) \odot (w[t+1] - w[t])$$

- Полезное свойство:
правильные размерности

ADAM [Kingma & Ba 2015]


ADAM = “ADaptive Moment Estimation”

$$v[t+1] = \beta v[t] + (1 - \beta) \nabla(E, w[t])$$



$$g[t+1] = \mu g[t] + (1 - \mu) \nabla(E, w[t]) \odot \nabla(E, w[t])$$

$$w[t+1] = w[t] - \alpha[t] \frac{1 - \beta}{1 - \mu} \frac{1}{\sqrt{g[t] + \epsilon}} \odot v[t]$$

ADAM [Kingma & Ba 2015]



ADAM [Kingma & Ba 2015]



Сравнение: логистическая регрессия




Image credit: Alec Redford

“Глубокие нейросети со структурированным выводом”

Функция Бигля




Image credit: Alec Redford

“Глубокие нейросети со структурированным выводом”

Уход из седловой точки




Image credit: Alec Redford


Current state

- Выбор оптимизатора и параметров по-прежнему нетривиально (обычно начинаем с ADAM)
- Существенное улучшение за счет слоёв, которые улучшают/обуславливают градиенты и активации (batch normalization, weight normalization, layer normalization...)

План

1. «Стандартные» свёрточные сети
2. «Практическая» оптимизация
3. **Синтезирующие сети с простыми функциями потерь**
4. Синтез через повторение статистик
5. Играющие сети (adversarial networks)

Текущее состояние




- Практически достигнут уровень мозга в задаче классификации (изображение -> метка класса)
- Метка класса -> изображение = ?

Зачем нужно синтезировать изображения?

Зачем нужно синтезировать изображения с помощью нейросетей:

1. Fun
2. Понимание как (не) работают глубокие нейросети
3. Компьютерная графика
4. Редактирование изображений
5. Чтобы улучшить компьютерное зрение (через *порождающие модели*)

Порождающая модель в мозгу



“Глубокие нейросети со структурированным выводом”

«Разворот» сверточных сетей


Исходные изображения:



Каждое изображение аннотировано
типом и углом зрения

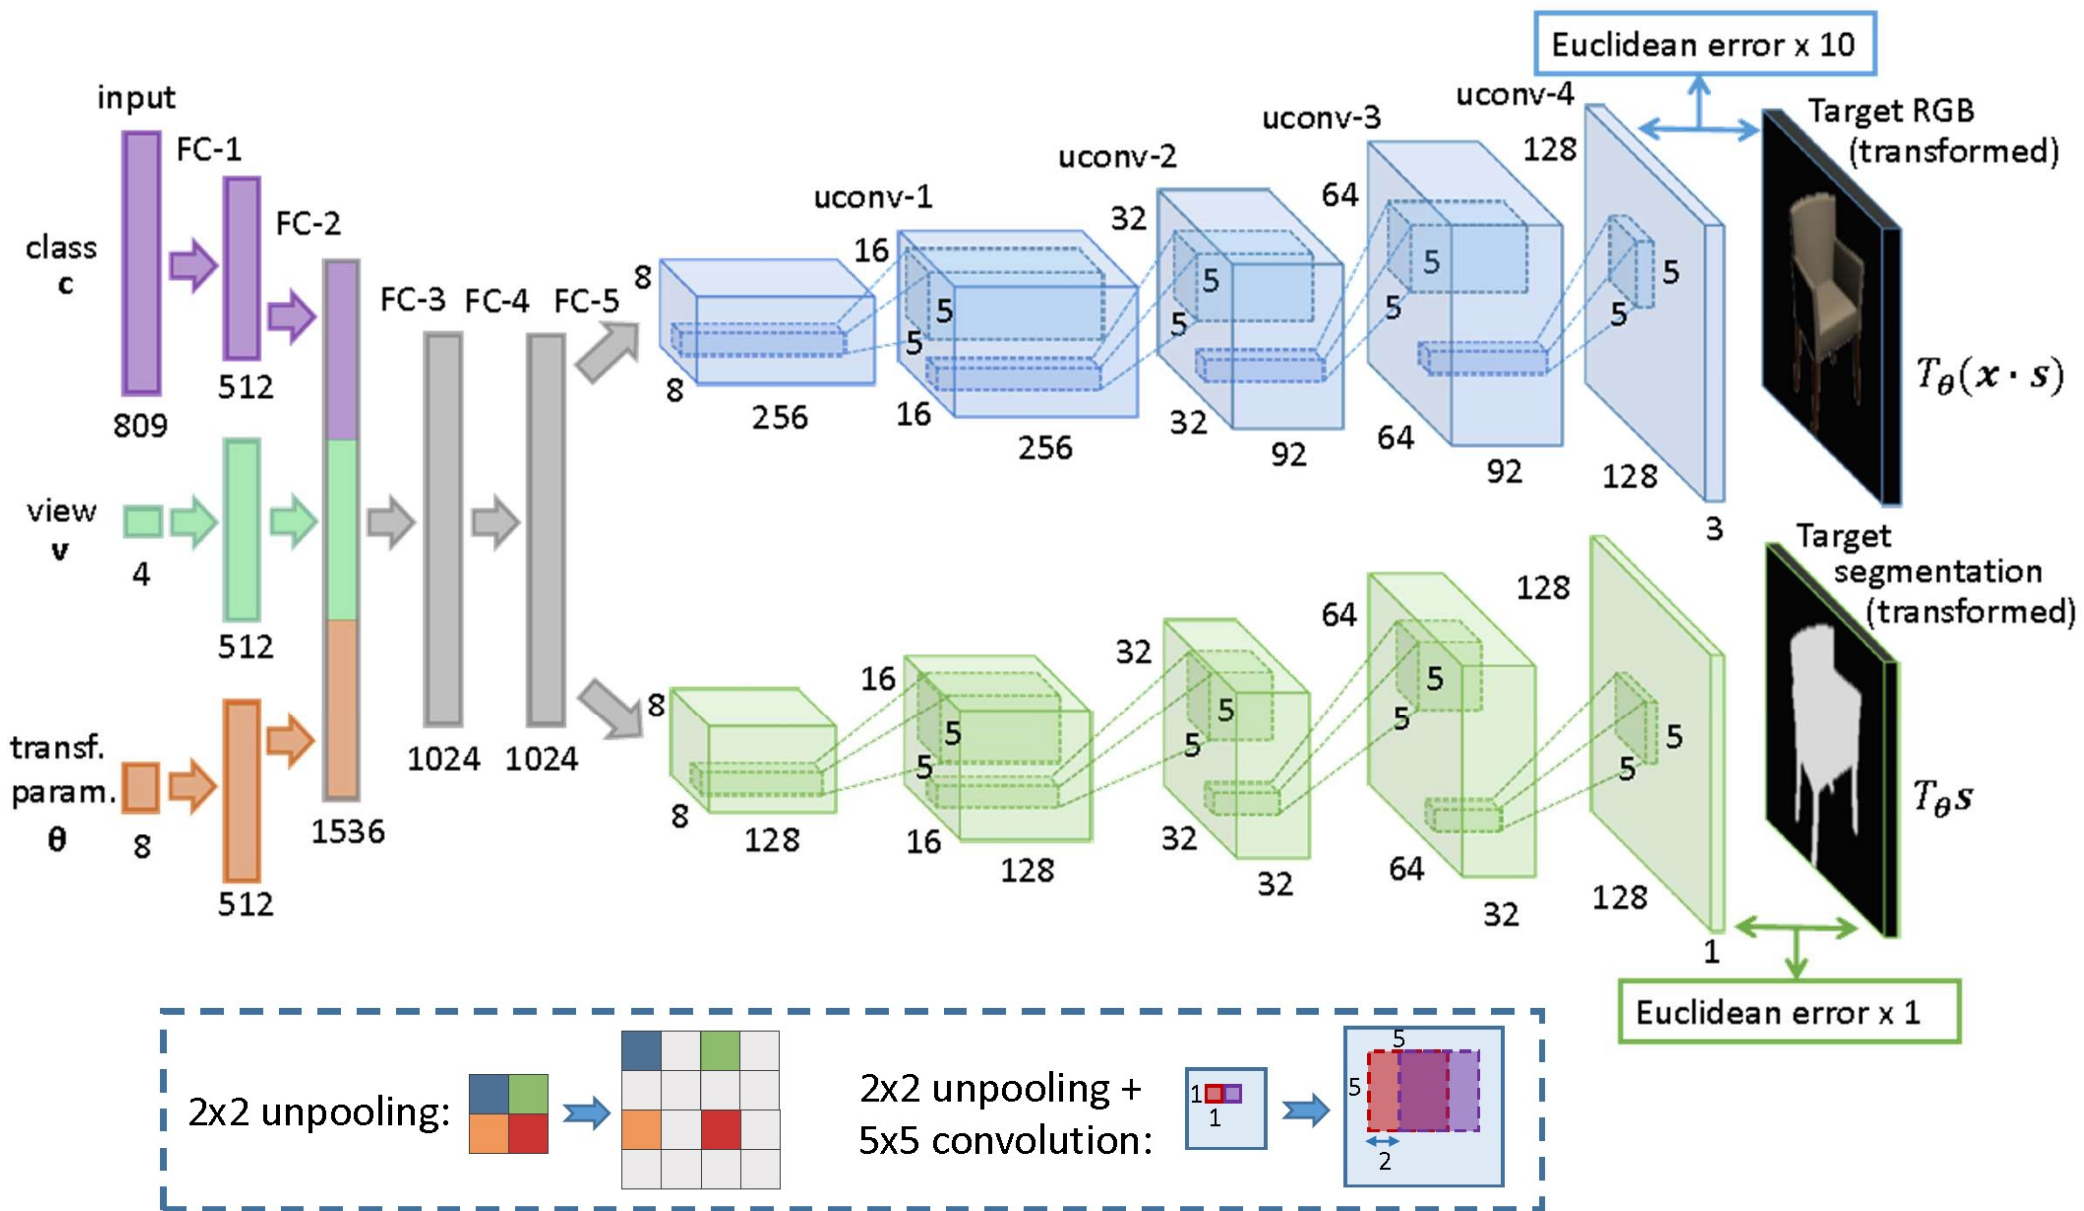
[Dosovitskiy, Springenberg, Brox CVPR 2015]

Сеть до разворота



тип стула
угол зрения
и т.п.

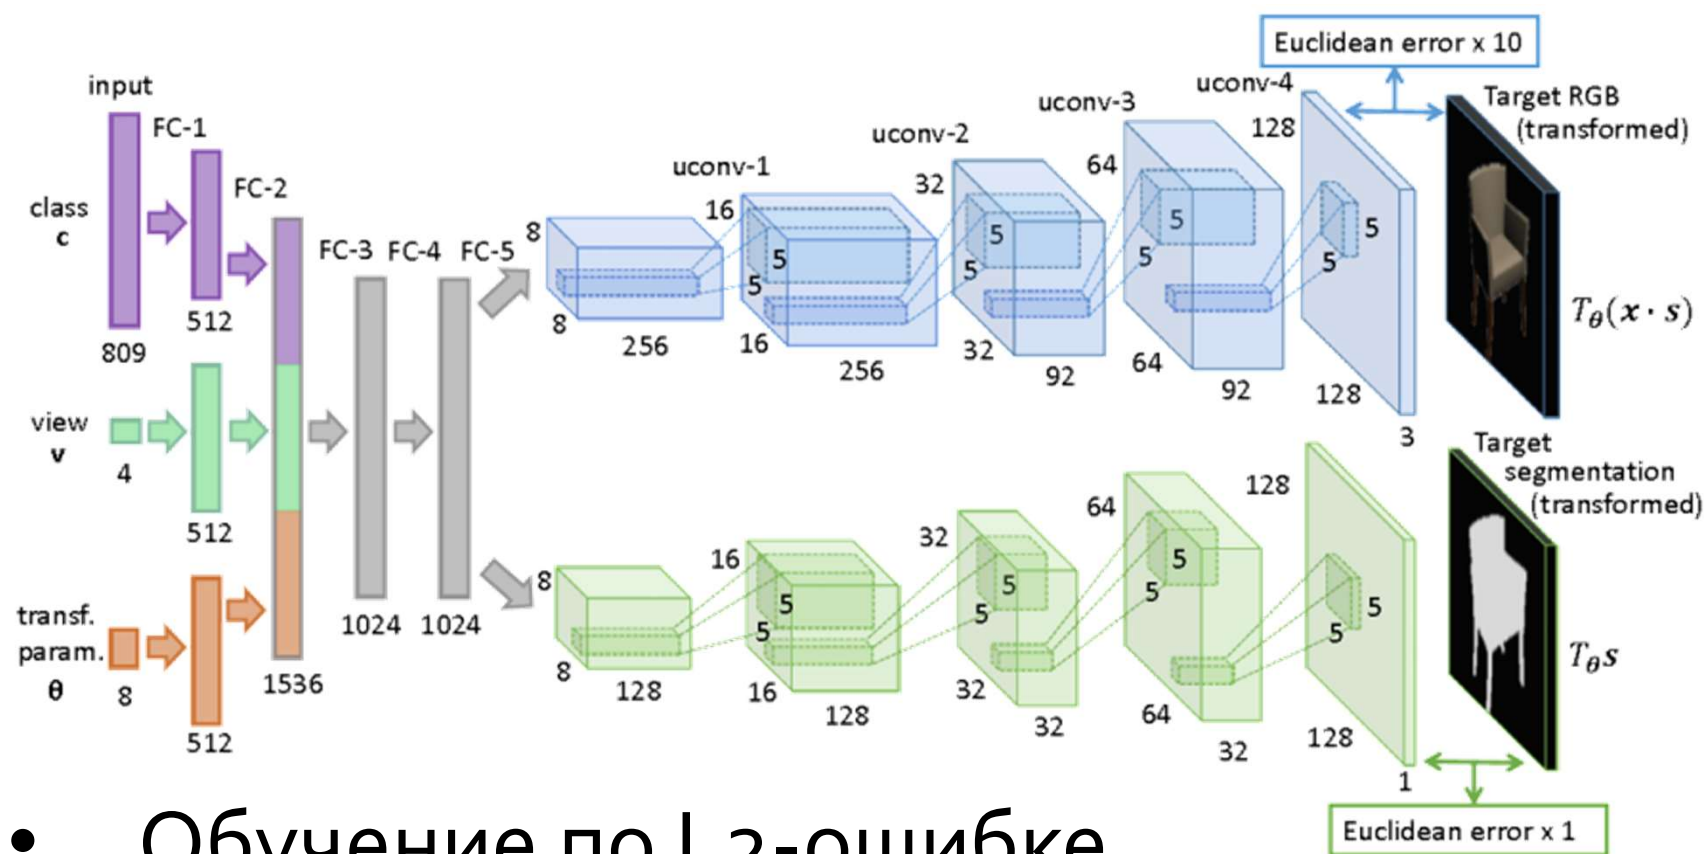
Развернутая сеть



[Dosovitskiy, Springenberg, Brox CVPR 2015]

“Глубокие нейросети со структурированным выводом”



Развернутая сеть



- Обучение по L2-ошибке
- «Размножение» тренировочных данных
- Обучение маски даёт дополнительную регуляризацию

[Dosovitskiy, Springenberg, Brox CVPR 2015]

Развернутая сеть


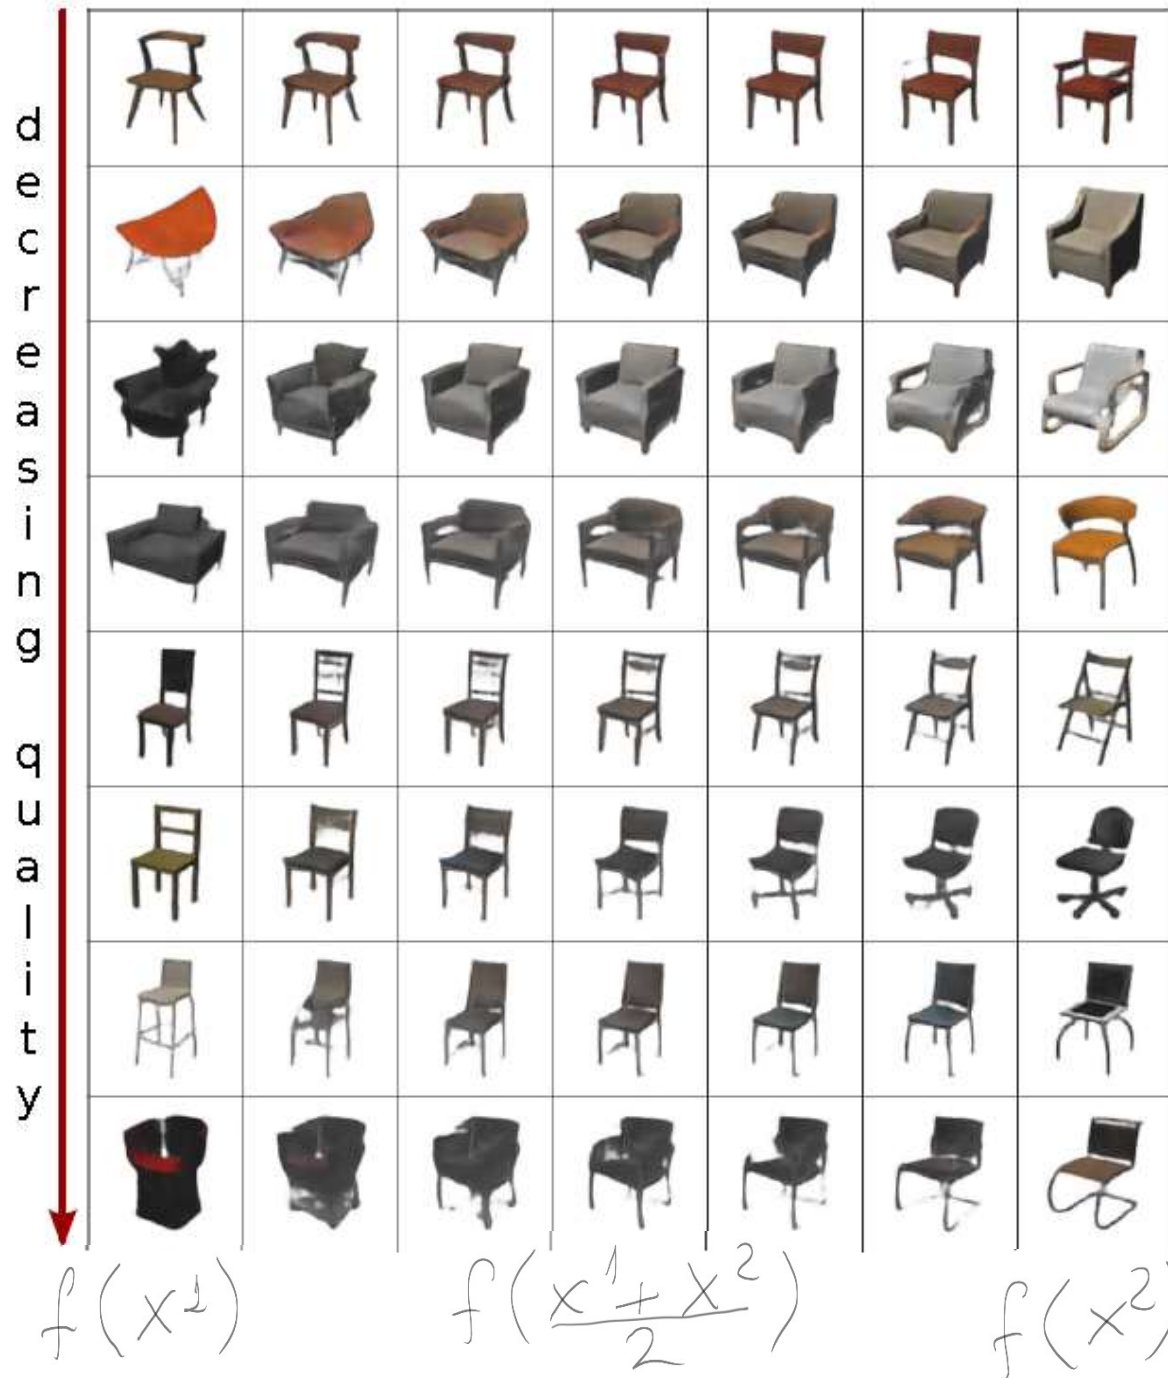


Изменение
одного
«нейрона»

[Dosovitskiy, Springenberg, Brox CVPR 2015]





“Глубокие нейросети со структурированным выводом”

Развернутая сеть







[Dosovitskiy, Springenberg, Brox CVPR 2015]

Практическое применение: gaze correction





“Глубокие нейросети со структурированным выводом”

Обучение с учителем – вещь тяжелая





“Глубокие нейросети со структурированным выводом”

Редактирование через поля смещений



in




out



in

out

Наблюдение: значительная часть преобразования может быть задана *полем смещений*:



$I(x, y)$

GT

$O(x, y)$

$[u(x, y) \ v(x, y)]$

$O(x, y)$

$I(x + u(x, y), y + v(x, y))$



Поля смещений хорошо обобщаются!

DeepWarp

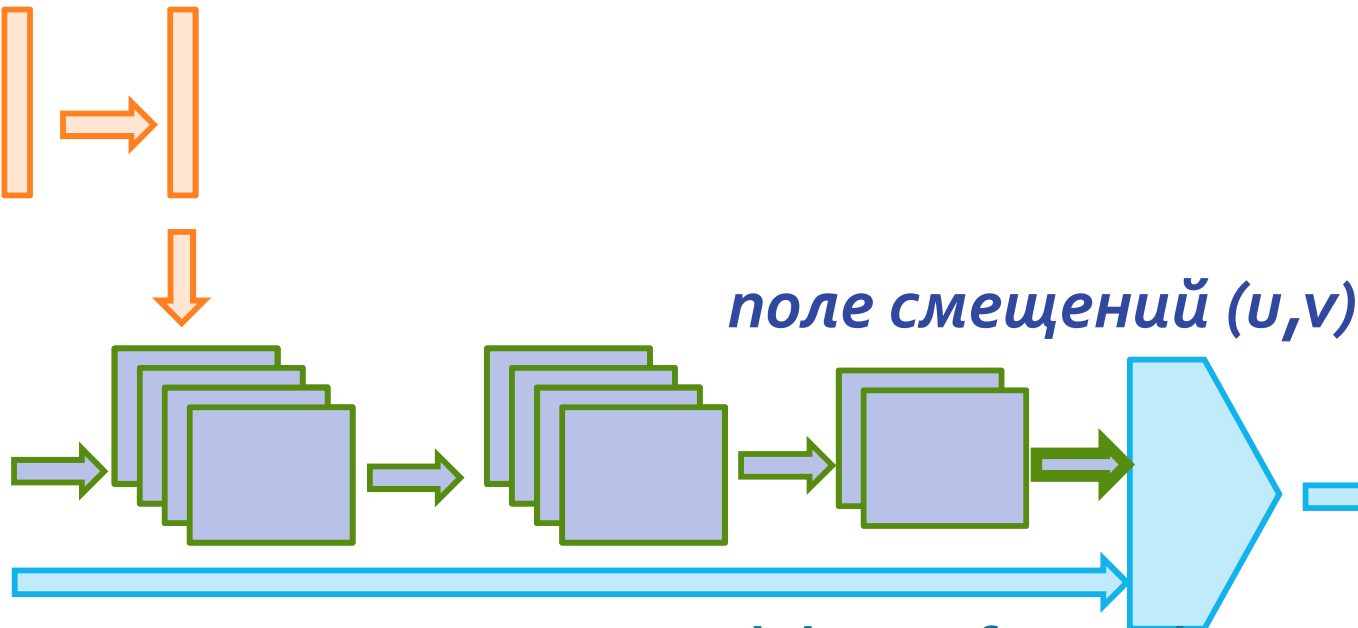
Идея: глубокая сеть учится
предсказывать поле смещений

Угол

перенаправления



$T(x,y)$




поле смещений (u,v)

Spatial transformer layer
[Jaderberg et al. NIPS15]



L2-loss

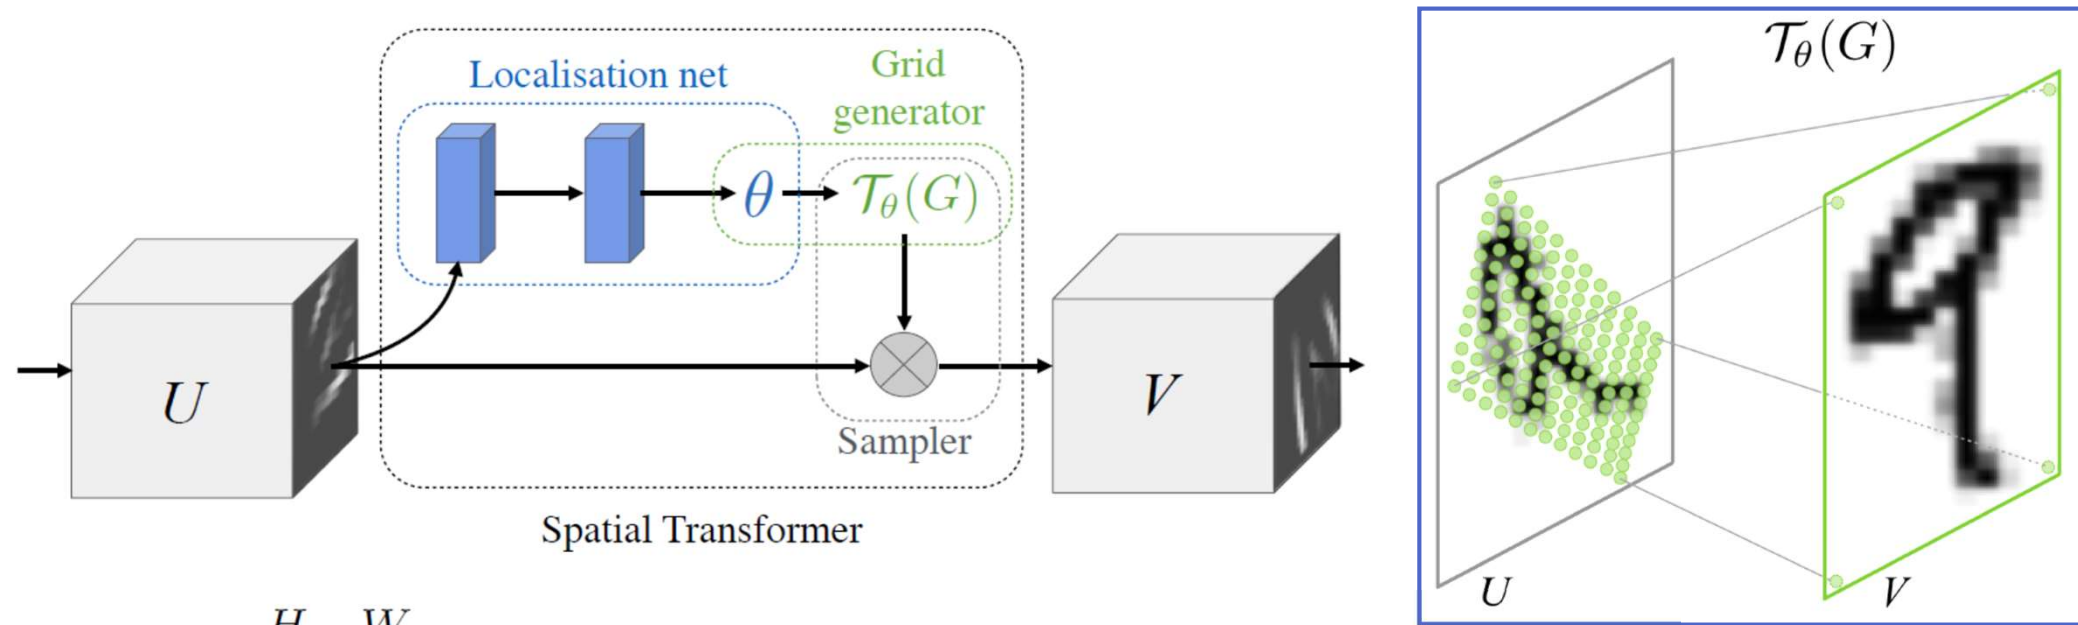


$O(x,y)$

$I(x + u(x,y), y + v(x,y))$

[Ganin, Kononenko, Sungatullina, Lempitsky, 2016]

Spatial transformer nets [Jaderberg et al.2015]



$$V_i^c = \sum_n^H \sum_m^W U_{nm}^c \max(0, 1 - |x_i^s - m|) \max(0, 1 - |y_i^s - n|)$$

$$\frac{\partial V_i^c}{\partial U_{nm}^c} = \sum_n^H \sum_m^W \max(0, 1 - |x_i^s - m|) \max(0, 1 - |y_i^s - n|)$$


$$\frac{\partial V_i^c}{\partial x_i^s} = \sum_n^H \sum_m^W U_{nm}^c \max(0, 1 - |y_i^s - n|) \begin{cases} 0 & \text{if } |m - x_i^s| \geq 1 \\ 1 & \text{if } m \geq x_i^s \\ -1 & \text{if } m < x_i^s \end{cases}$$

DeepWarp



Идея: глубокая сеть учится
предсказывать поле смещений

Угол


перенаправления




$T(x, y)$



поле смещений (u, v)



Spatial transformer layer
[Jaderberg et al. NIPS15]



GT

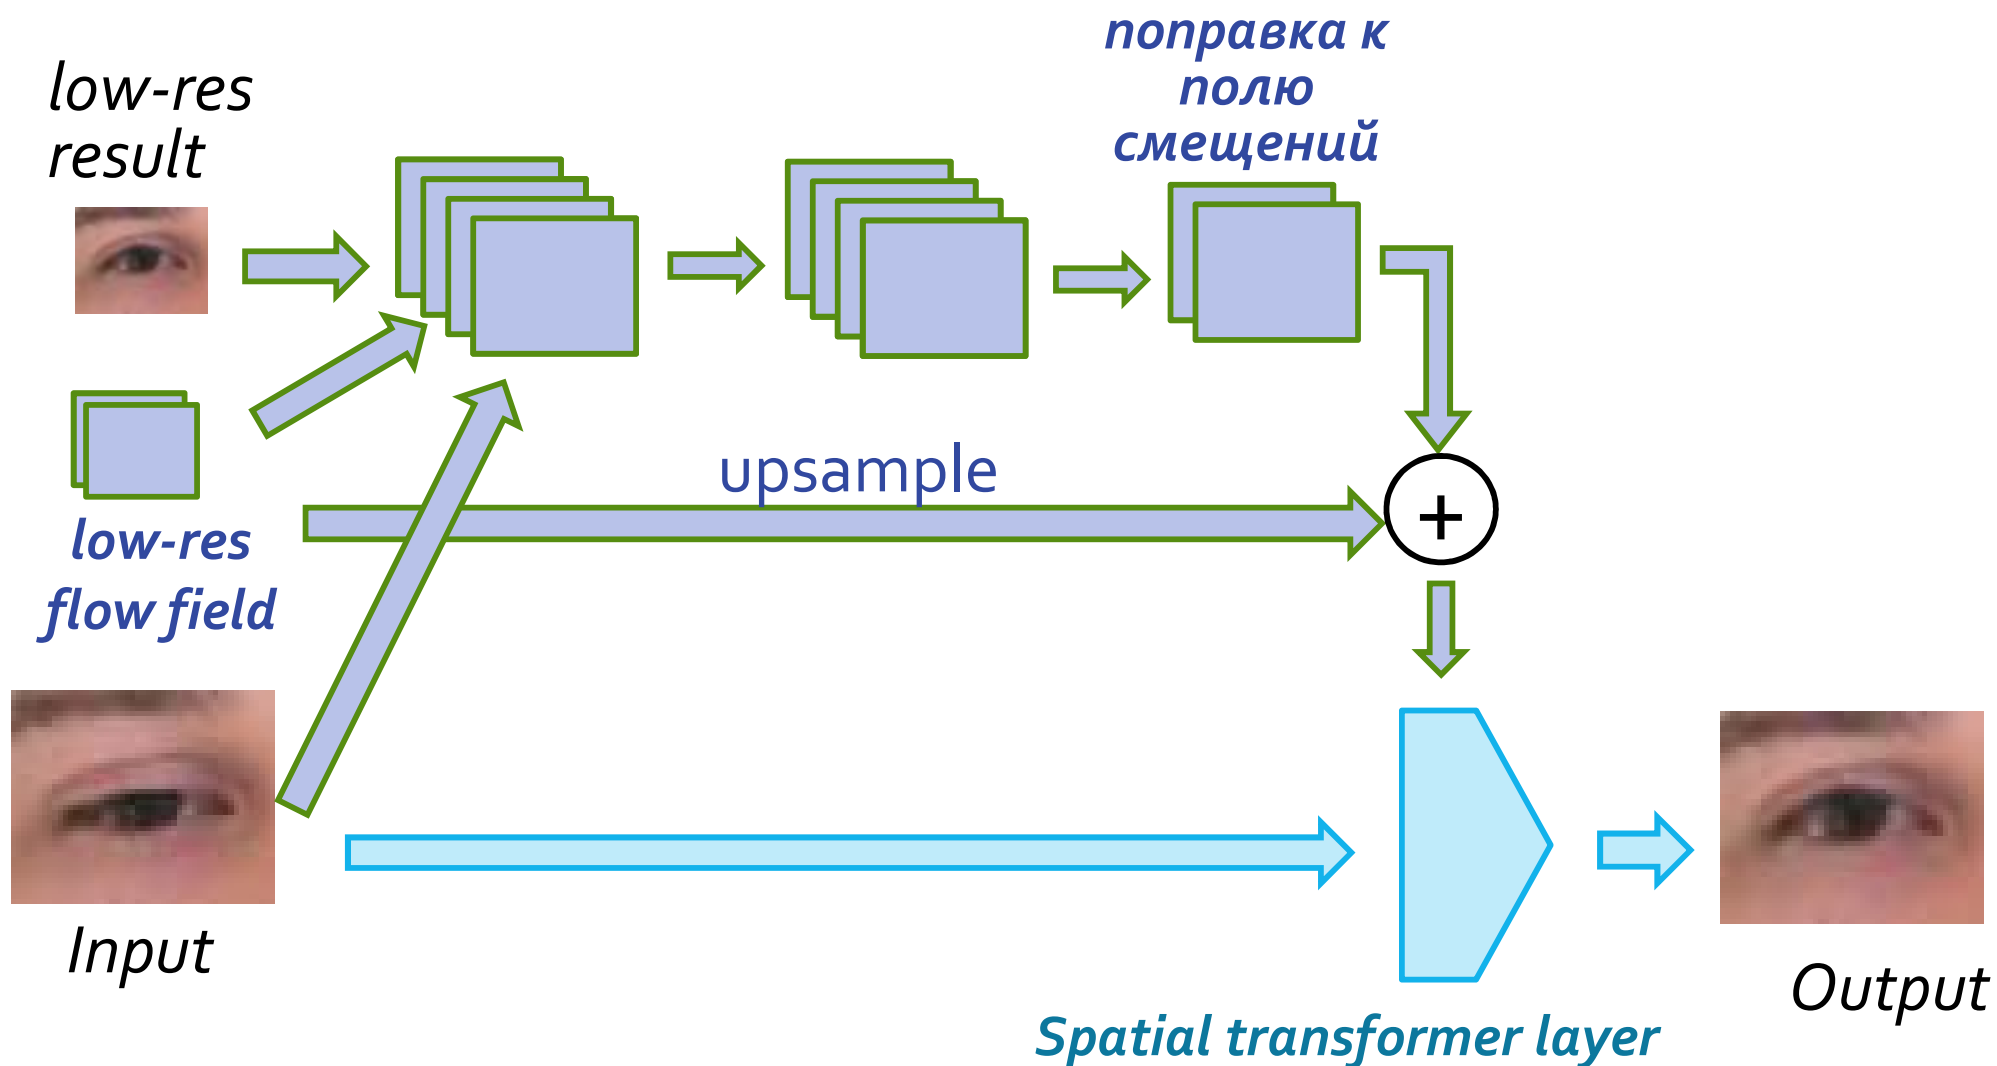
L2-loss

$O(x, y)$

$I(x + u(x, y), y + v(x, y))$

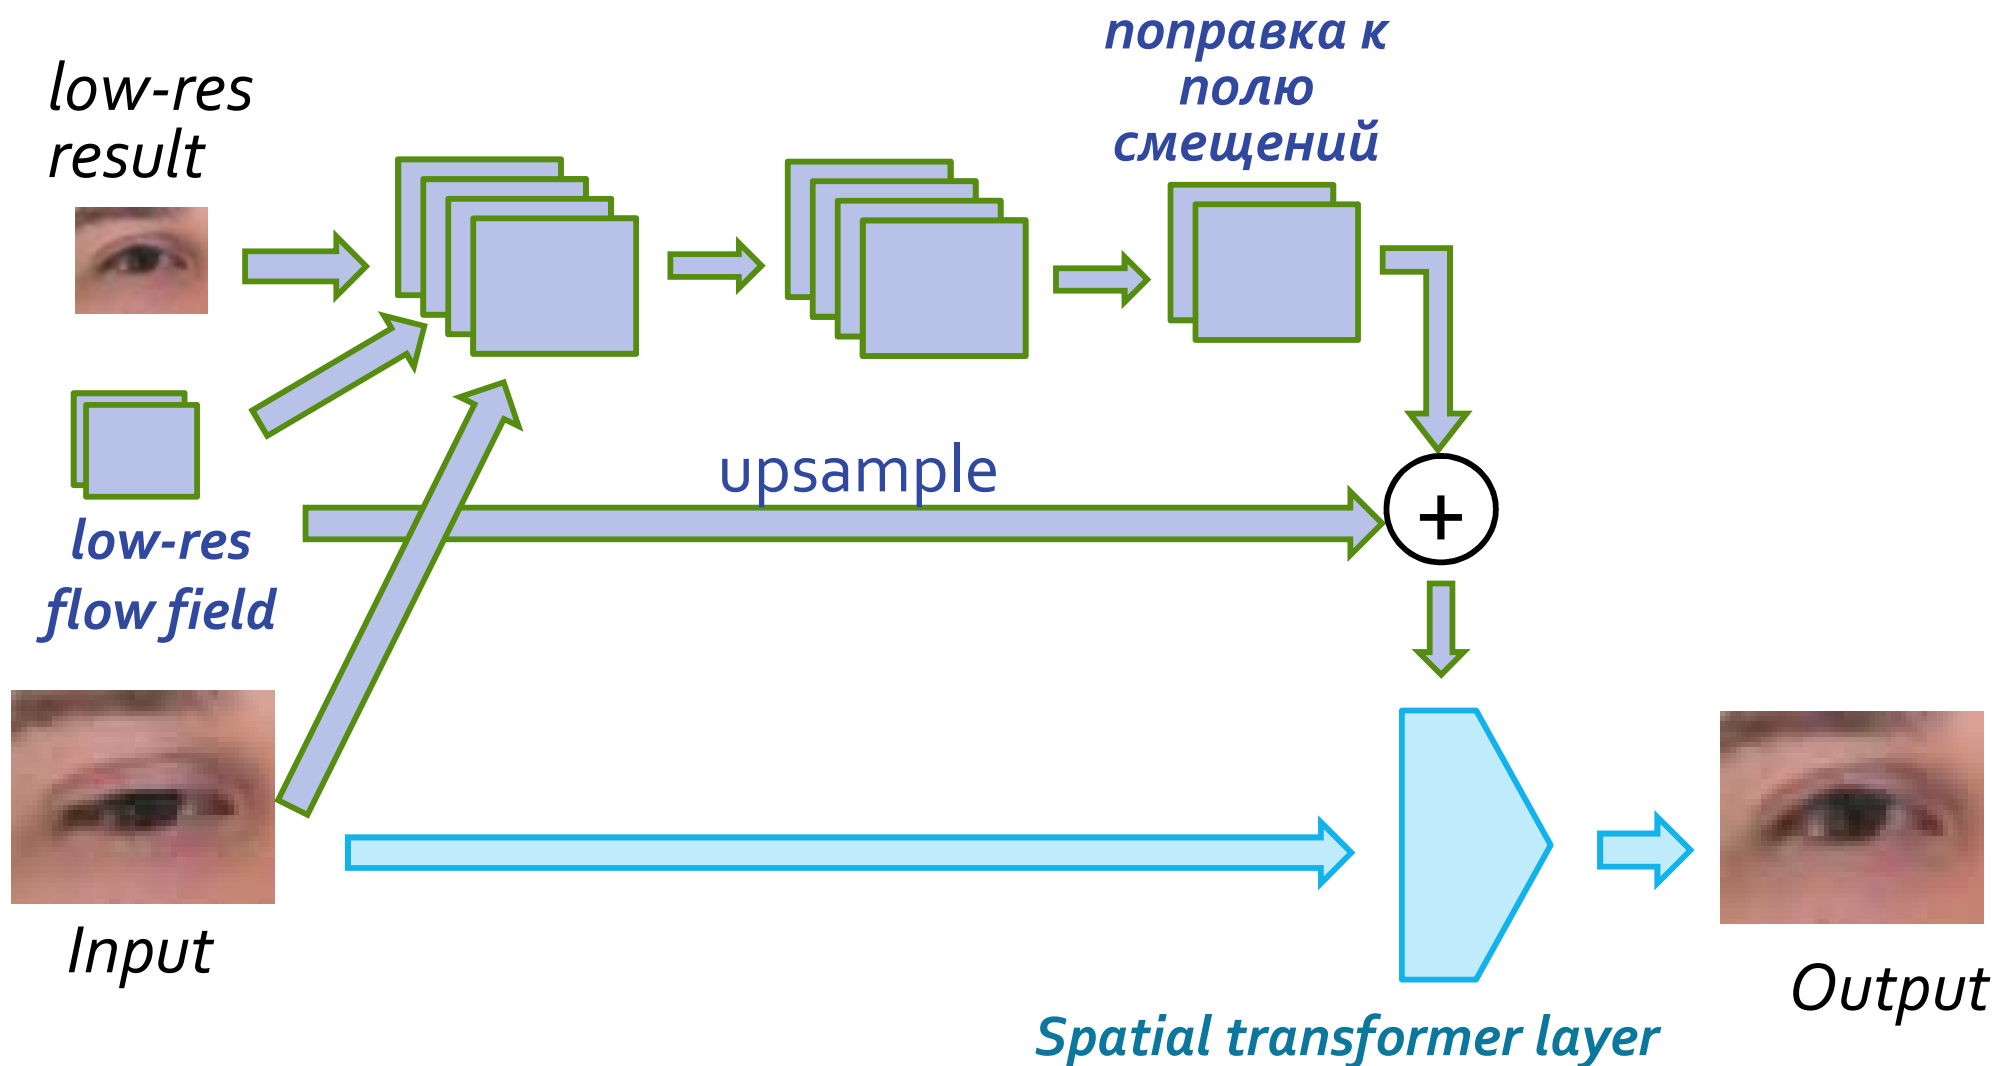
[Ganin, Kononenko, Sungatullina, Lempitsky, 2016]

Второй «уровень» сети



[Ganin, Kononenko, Sungatullina, Lempitsky, 2016]

Второй «уровень» сети



[Ganin, Kononenko, Sungatullina, Lempitsky, 2016]

Третий «уровень» сети

Третий уровень принимает на вход карты признаков и результат предыдущих уровней и предсказывает мультипликативную поправку:


Input

CFW

+ LCM

Mask


GT



Все три этапа обучаются вместе

Вертикальное перенаправление

15 градусов вверх




15 градусов вниз

[Ganin, Kononenko, Sungatullina, Lempitsky, 2016]

“Глубокие нейросети со структурированным выводом”

Еще примеры




[Ganin, Kononenko, Sungatullina, Lempitsky, 2016]

“Глубокие нейросети со структурированным выводом”

План

1. «Стандартные» свёрточные сети
2. «Практическая» оптимизация
3. Синтезирующие сети с простыми функциями потерь
- 4. Синтез через повторение статистик**
5. Играющие сети (adversarial networks)

Задача «безусловной» генерации



$$x \sim P(x)$$


- Научиться получать новые примеры
- (Научиться оценивать вероятности)

Moment-matching nets [Li et al. 2015]

$$\mathcal{L}_{\text{MMD}^2} = \left\| \frac{1}{N} \sum_{i=1}^N \phi(x_i) - \frac{1}{M} \sum_{j=1}^M \phi(y_j) \right\|^2 \quad (1)$$

$$= \frac{1}{N^2} \sum_{i=1}^N \sum_{i'=1}^N \phi(x_i)^\top \phi(x_{i'}) - \frac{2}{NM} \sum_{i=1}^N \sum_{j=1}^M \phi(x_i)^\top \phi(y_j) + \frac{1}{M^2} \sum_{j=1}^M \sum_{j'=1}^M \phi(y_j)^\top \phi(y_{j'}) \quad (2)$$

$$\mathcal{L}_{\text{MMD}^2} = \frac{1}{N^2} \sum_{i=1}^N \sum_{i'=1}^N k(x_i, x_{i'}) - \frac{2}{NM} \sum_{i=1}^N \sum_{j=1}^M k(x_i, y_j) + \frac{1}{M^2} \sum_{j=1}^M \sum_{j'=1}^M k(y_j, y_{j'}) \quad (3)$$



Moment-matching nets [Li et al. 2015]

Algorithm 1: GMMN minibatch training


Input : Dataset $\{\mathbf{x}_1^d, \dots, \mathbf{x}_N^d\}$, prior $p(\mathbf{h})$, network $f(\mathbf{h}; \mathbf{w})$ with initial parameter $\mathbf{w}^{(0)}$

Output: Learned parameter \mathbf{w}^*

```
1 while Stopping criterion not met do
2   |   Get a minibatch of data  $\mathbf{X}^d \leftarrow \{\mathbf{x}_{i_1}^d, \dots, \mathbf{x}_{i_b}^d\}$ 
3   |   Get a new set of samples  $\mathbf{X}^s \leftarrow \{\mathbf{x}_1^s, \dots, \mathbf{x}_b^s\}$ 
4   |   Compute gradient  $\frac{\partial \mathcal{L}_{\text{MMD}}}{\partial \mathbf{w}}$  on  $\mathbf{X}^d$  and  $\mathbf{X}^s$ 
5   |   Take a gradient step to update  $\mathbf{w}$ 
6 end
```

Use mixture of several Gaussian kernels with different bandwidths


Moment-matching nets [Li et al. 2015]



(a) GMMN MNIST samples




(b) GMMN TFD samples



Синтез текстур


Ключевой вопрос: какие статистики описывают текстуру?



похожи

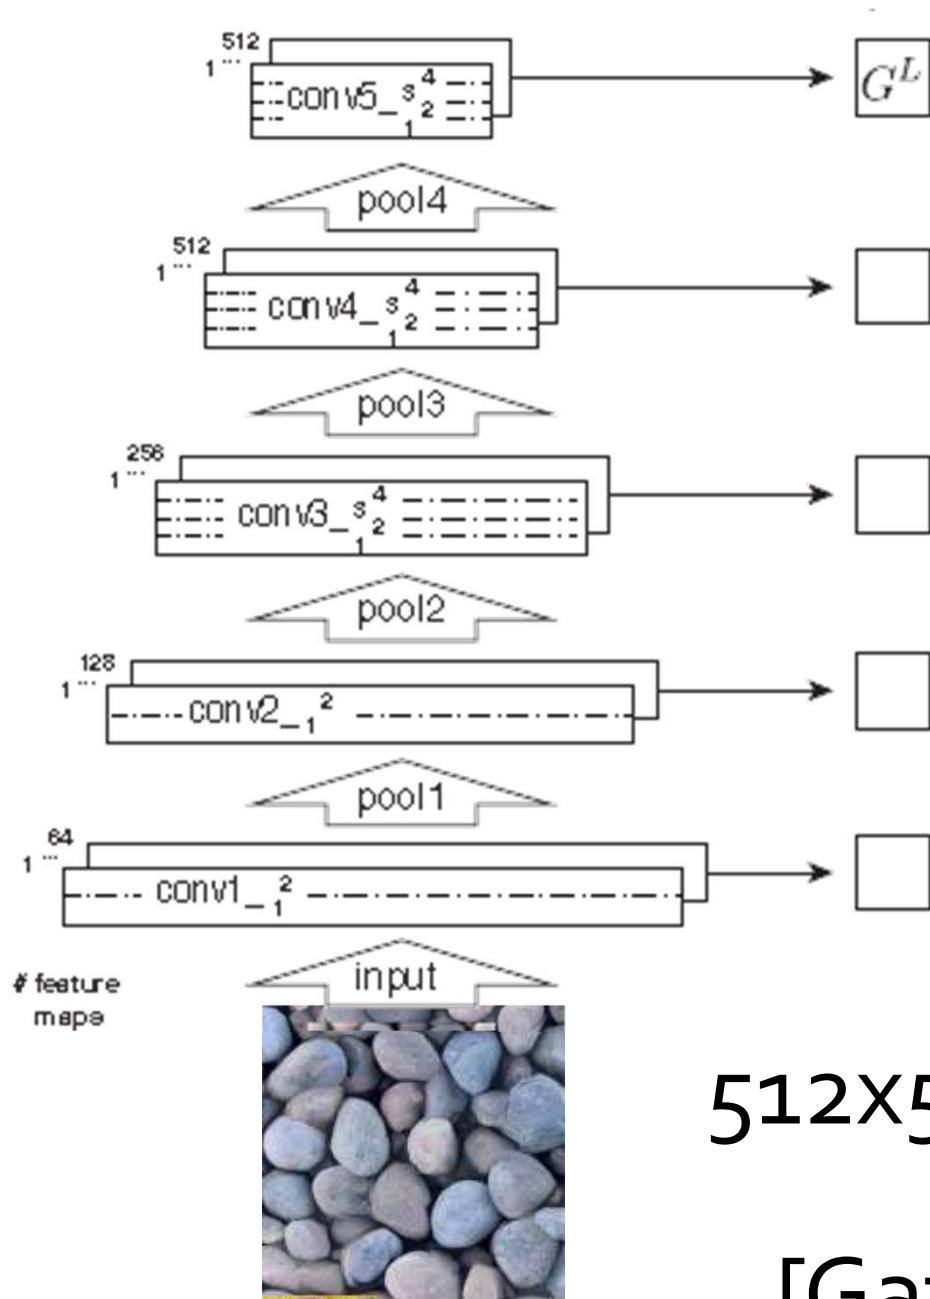


различны



- Попиксельная разность?
- Гистограммы цветов?
- Нужны статистики более высоких порядков!

Статистики, порождаемые нейросетью



$$X \xrightarrow{\Phi^l} \{F_i^l\}$$

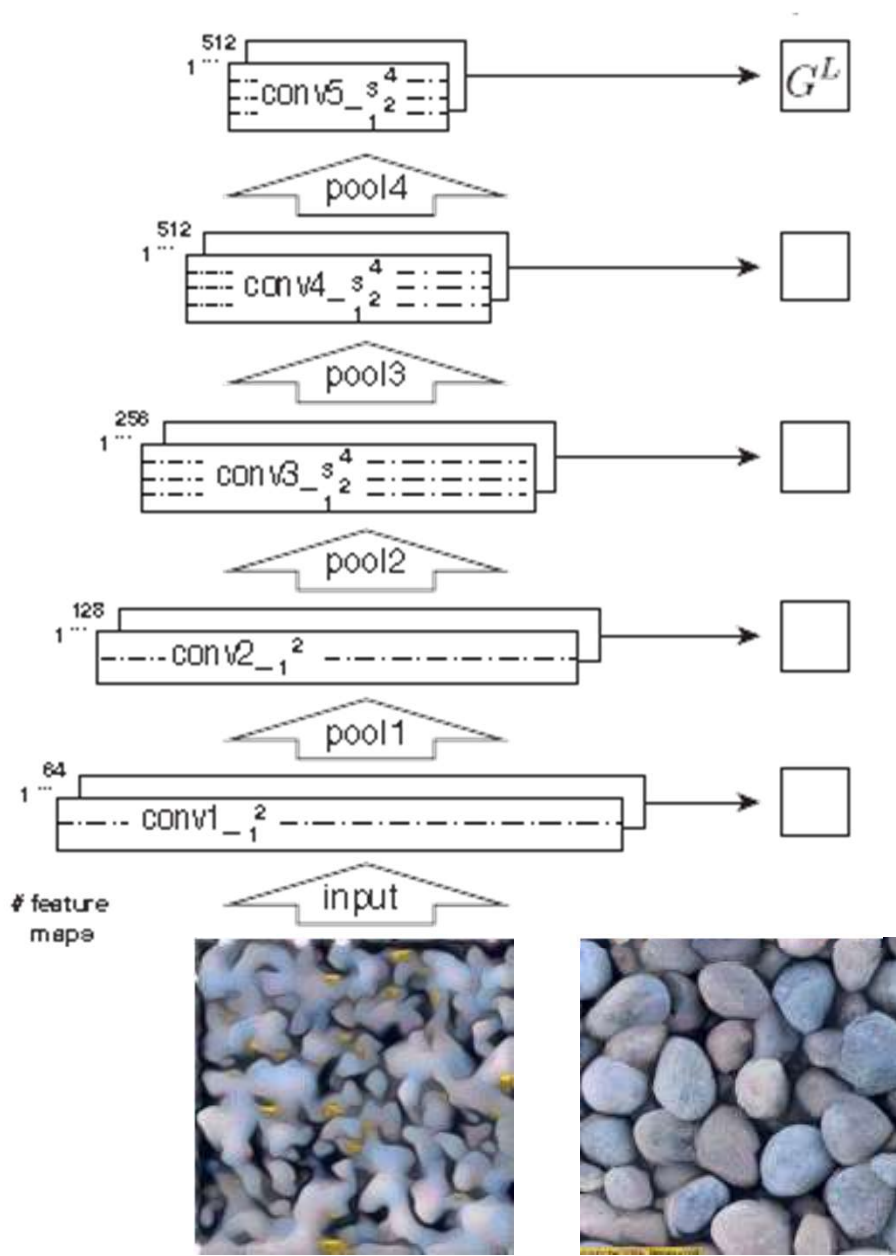
Матрица Грамма:

$$[G^l]$$
$$G_{ij}^l = \sum_k F_{i,k}^l \cdot F_{j,k}^l$$

512x512-мерный дескриптор

[Gatys, Ecker, Bethge 2015]

Синтез текстур методом прообразов



$$X^* \rightarrow \phi_\ell(x^*) \rightarrow G(x^*)$$

$$X \rightarrow \phi_\ell(x) \rightarrow G(x)$$

$$L(x) = \|G(x) - G(x^*)\|_F^2$$

$$X^{t+1} \leftarrow X^t - \alpha_t \frac{dL(x^t)}{dx}$$


\times

\times^*

[Gatys, Ecker, Bethge 2015]

Image generation by optimization

$$x^* = \arg \min_x \mathcal{L}(x)$$



[Gatys, Ecker, Bethge 2015]

Текстуры, созданные методом прообразов

Synthesised



Source



Synthesised



Source



[Gatys, Ecker, Bethge 2015]

“Глубокие нейросети со структурированным выводом”

Текстуры, созданные методом прообразов

Synthesised



Source



[Gatys, Ecker, Bethge 2015]

“Глубокие нейросети со структурированным выводом”

Текстуры, созданные методом прообразов

Synthesised



Source



[Gatys, Ecker, Bethge 2015]

“Глубокие нейросети со структурированным выводом”

Texture network

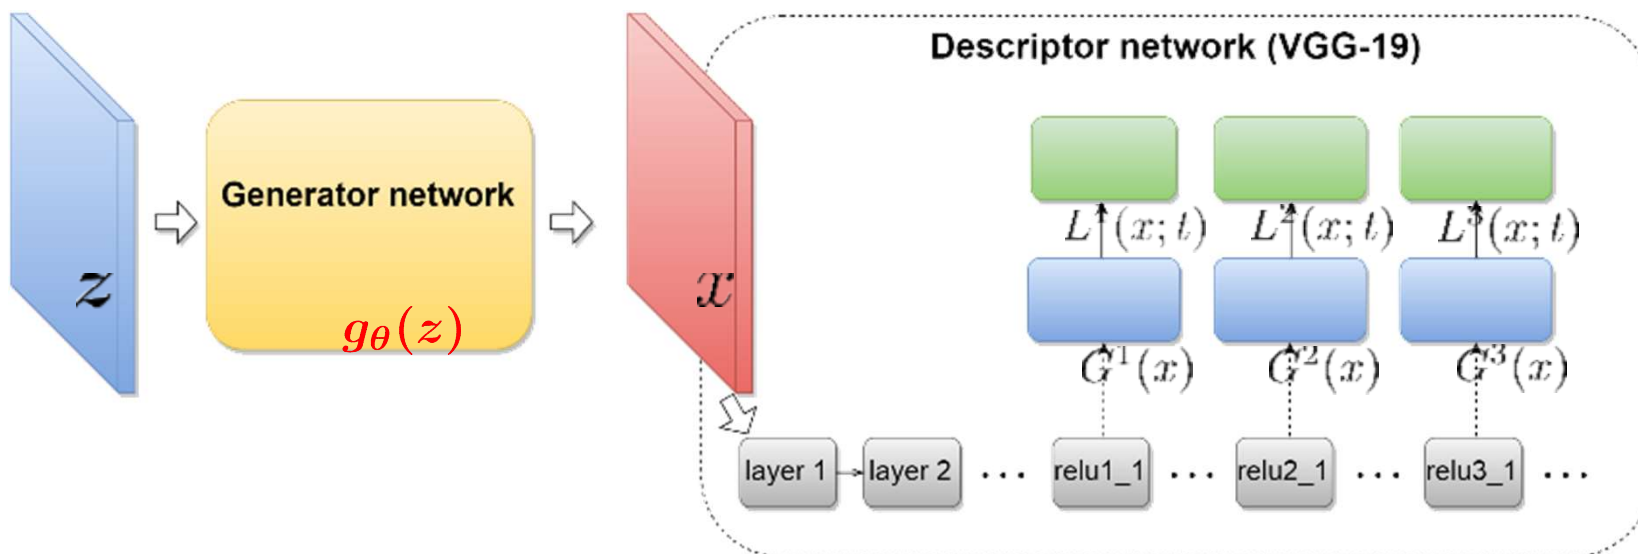


Image generation:

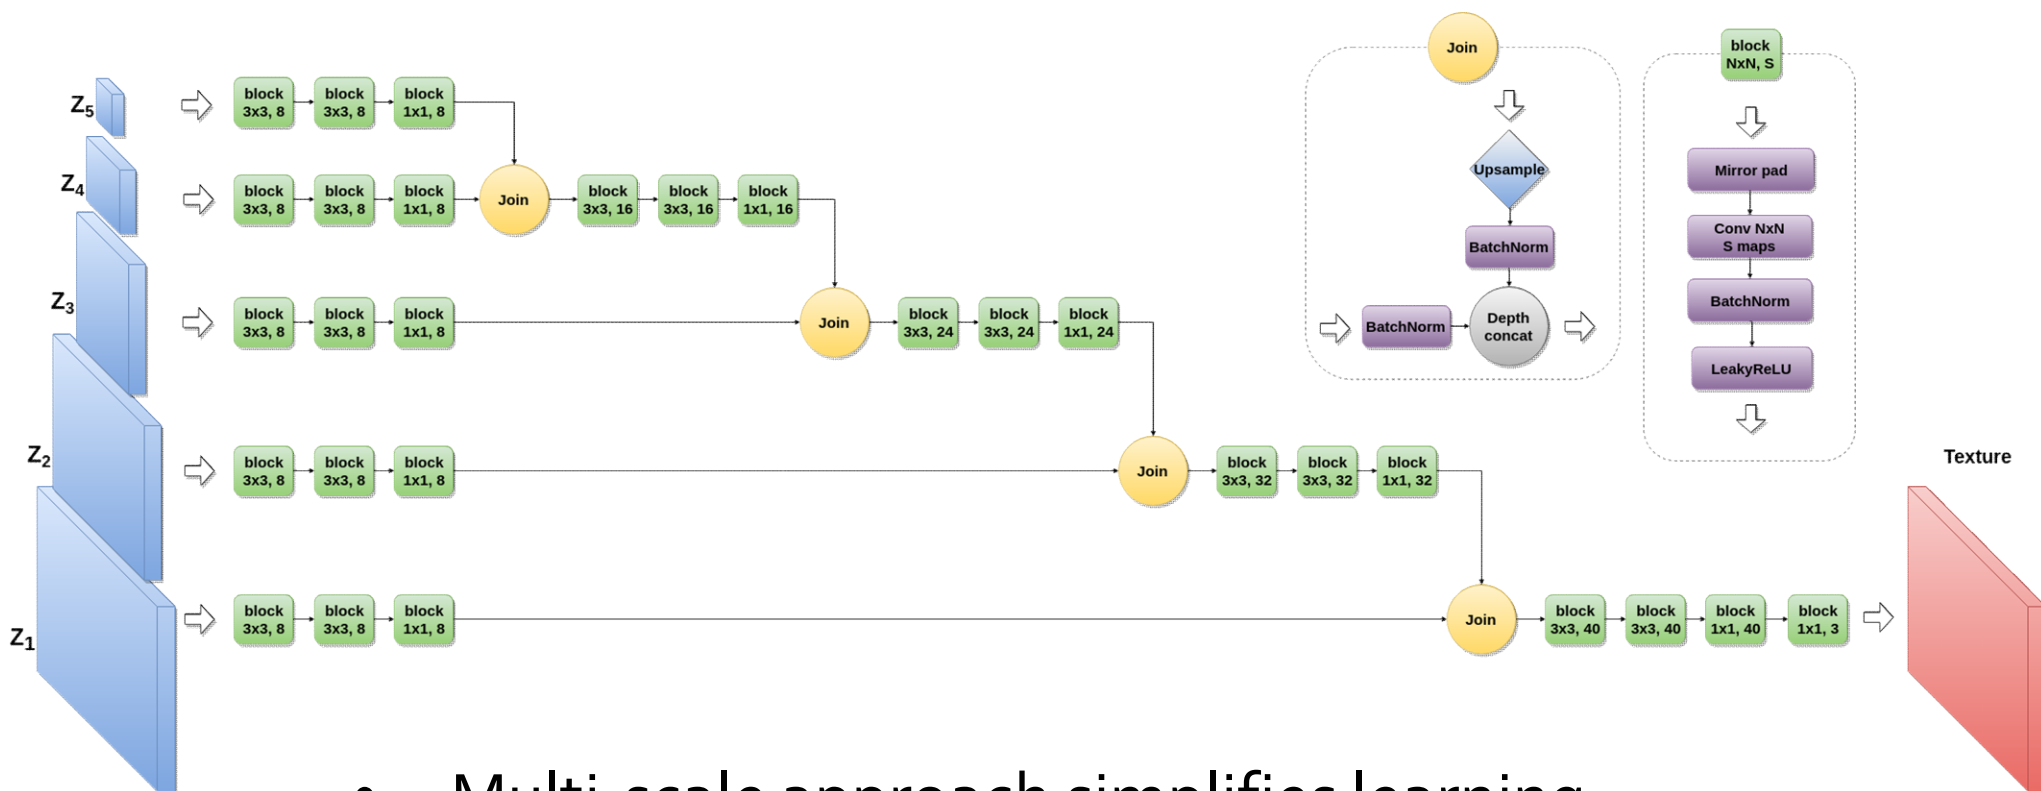
$$x = g_{\theta}(z), \quad z \sim U(0, 1)$$

Optimization task becomes:

$$\min_{\theta} \mathbb{E} \mathcal{L}_{texture}(g_{\theta}(z); t), \quad z \sim U(0, 1)$$


$$\theta^{k+1} = \theta^k - \alpha \frac{\partial \mathcal{L}(g_{\theta}(z); t)}{\partial \theta}$$

Generator networks details



- Multi-scale approach simplifies learning
- Looks scary, but still feedforward and fully convolutional

Примеры прямого синтеза




образец

результаты

“Глубокие нейросети со структурированным выводом”

Сравнение синтеза текстур



образец


оптим.

TextureNet

[Ulyanov, Lebedev, Vedaldi, Lempitsky ICML16]

“Глубокие нейросети со структурированным выводом”

Сравнение синтеза текстур




образец

оптим.

TextureNet

“Глубокие нейросети со структурированным выводом”

Сравнение синтеза текстур







образец

оптим.

TextureNet

“Глубокие нейросети со структурированным выводом”

Сравнение синтеза текстур




образец

оптим.

TextureNet

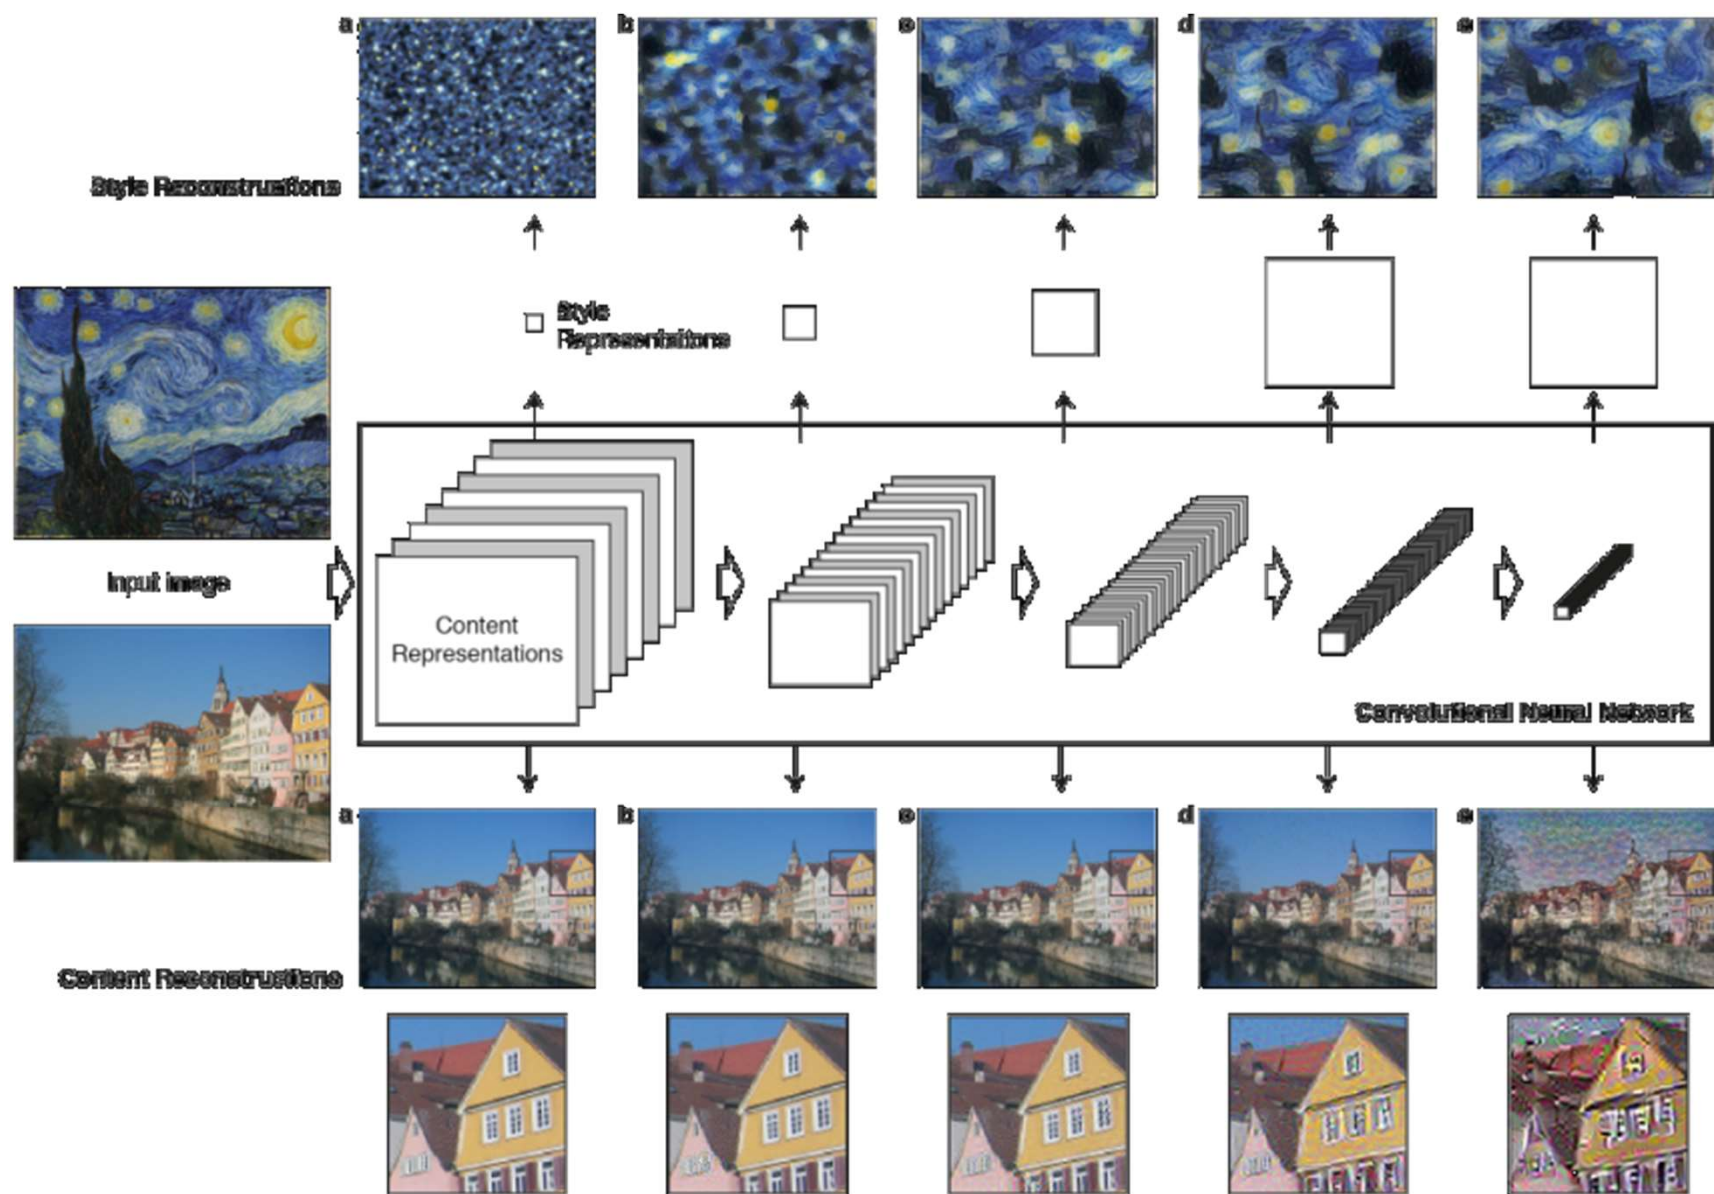
“Глубокие нейросети со структурированным выводом”

Quantitative evaluation



- Horizontal lines: average sample loss
 - **0.06 second** to generate sample
- Dotted lines: *optimization-based* loss as a function of time
 - **10 seconds** to achieve the same loss values

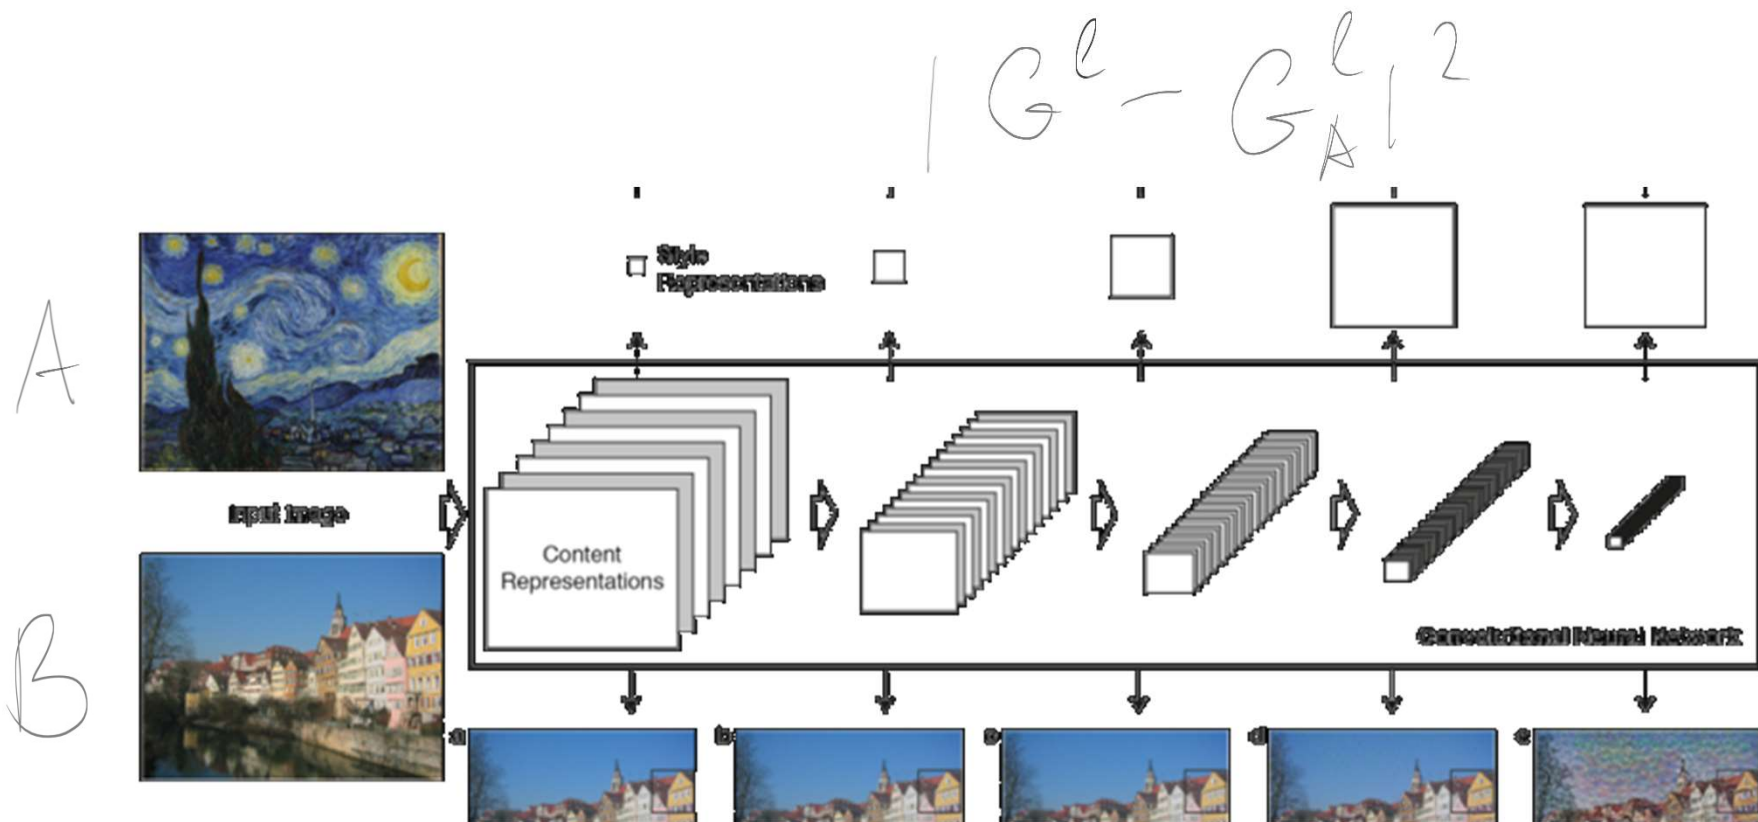
Стилизация изображений



[Gatys, Ecker, Bethge 2015]

“Глубокие нейросети со структурированным выводом”

Stylization with texture loss



$$L = \|G^l - G_A^l\|^2 + \|F^{l'} - F_B^{l'}\|^2$$

[Gatys, Ecker, Bethge 2015]

Neural algorithm for artistic style

A




B



C



D



[Gatys et al. 2015]

“Глубокие нейросети со структурированным выводом”


Feed-forward stylization



photo



style



result

“Style” network

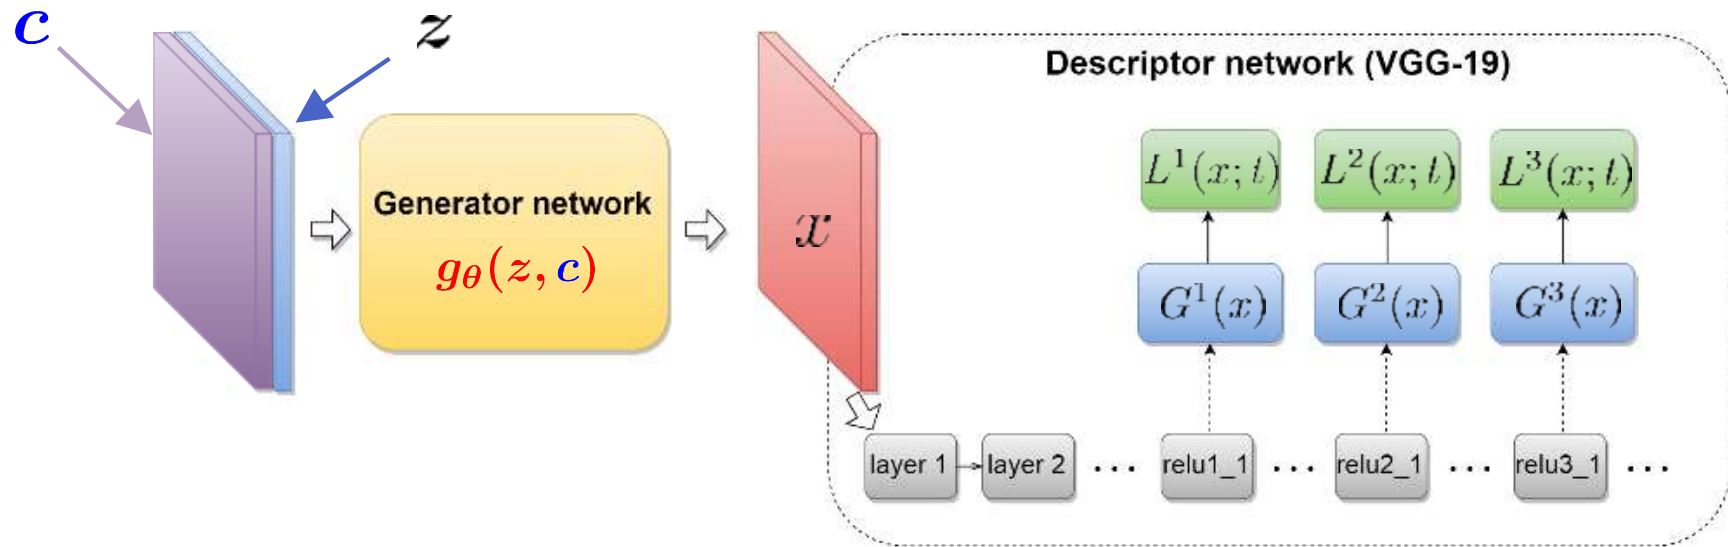


Image generation: $x = g_{\theta}(z, c), \quad z \sim U(0, 1)$

Optimization task: $\min_{\theta} \mathbb{E} \mathcal{L}(g_{\theta}(z, c); c, t), \quad z \sim U(0, 1)$

Feed-forward stylization




feedforward

optimization



Feed-forward stylization




feedforward

optimization



Feed-forward stylization



feedforward

optimization



Feed-forward stylization



feedforward



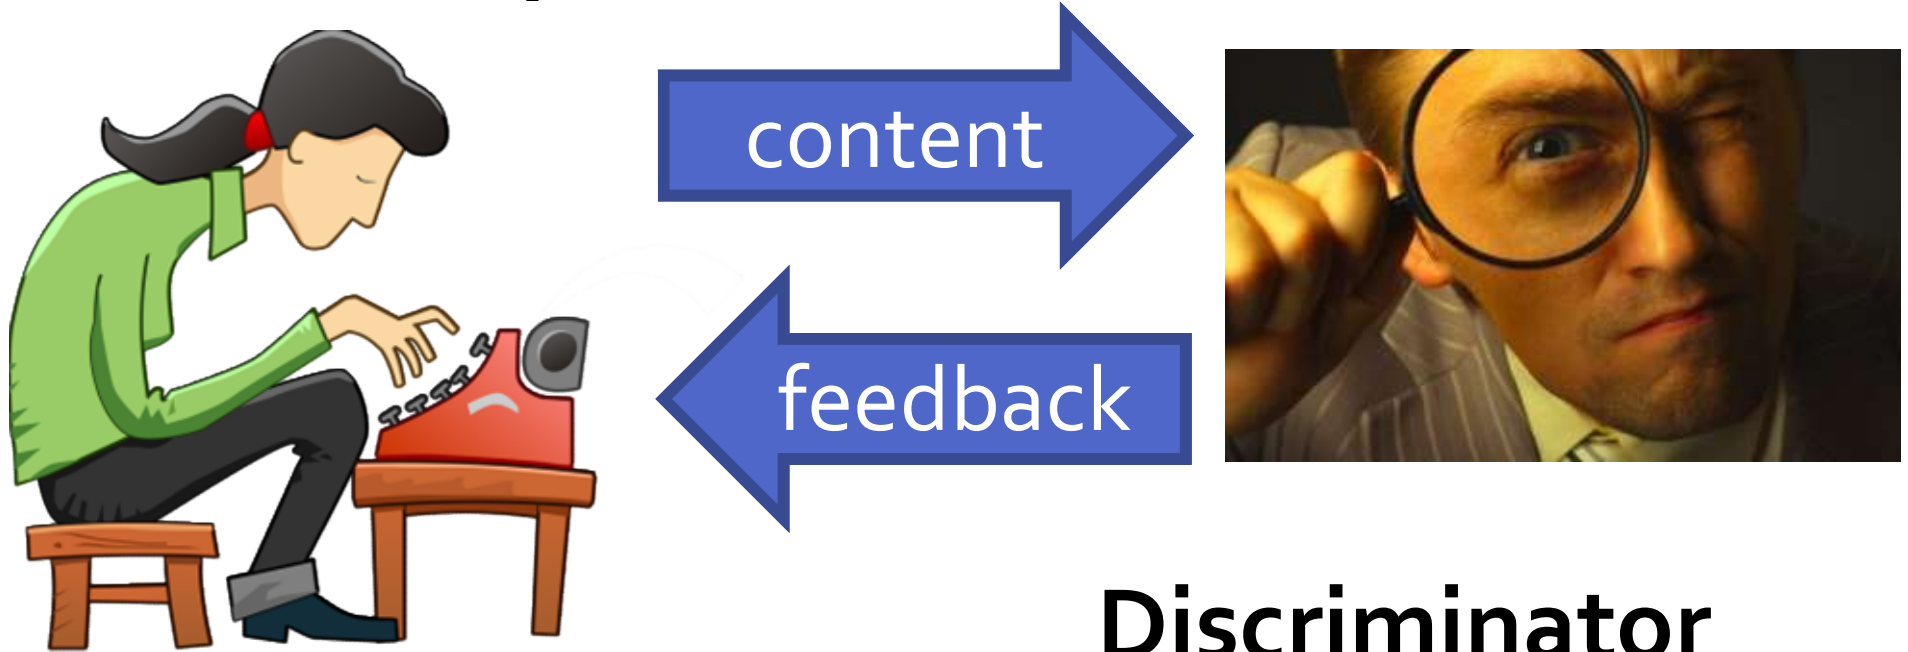
optimization

План

1. «Стандартные» свёрточные сети
2. «Практическая» оптимизация
3. Синтезирующие сети с простыми функциями потерь
4. Синтез через повторение статистик
5. **Играющие сети (adversarial networks)**

Let us look at reconstruction deficiencies

- How can we tell between **real** and **synthetic**?
- Can a **computer** tell between them?




Generator Network:
generates content
(e.g. images)

Discriminator Network:
assesses the result
(e.g. images)

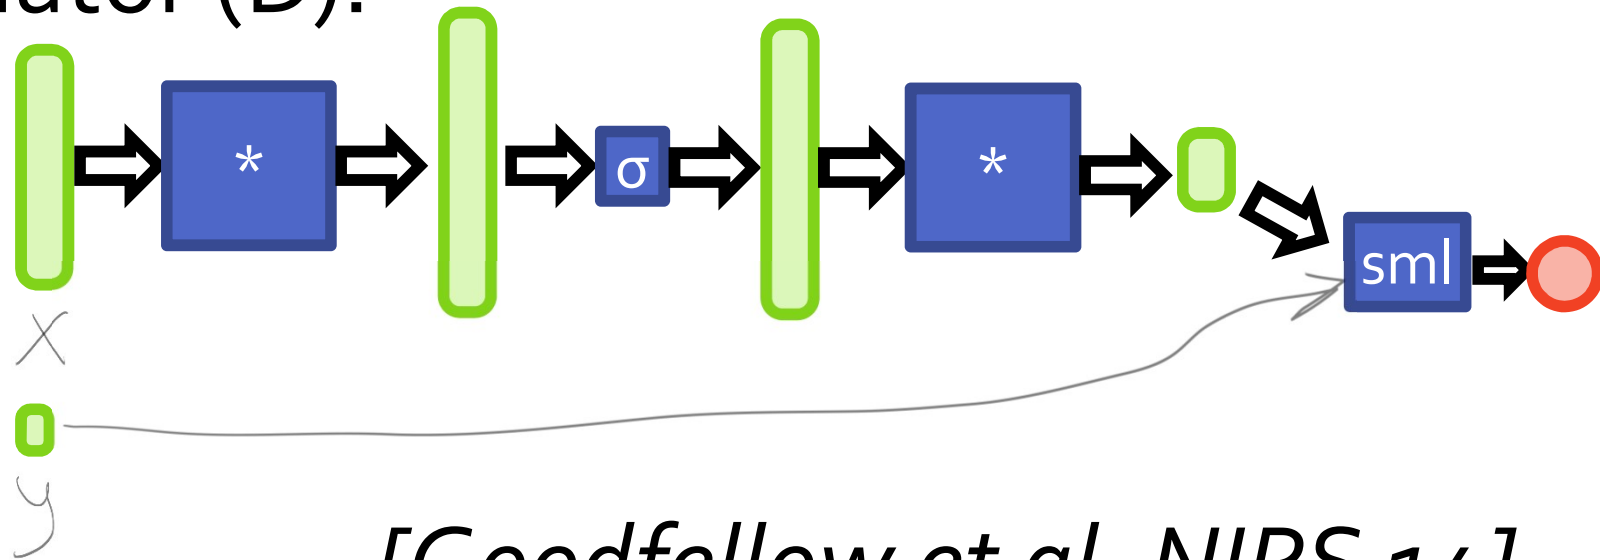
Adversarial generative networks

Generator (G):

noise



Discriminator (D):



[Goodfellow et al. NIPS 14]

Adversarial learning

for number of training iterations **do**

for k steps **do**

- Sample minibatch of m noise samples $\{z^{(1)}, \dots, z^{(m)}\}$ from noise prior $p_g(z)$.
- Sample minibatch of m examples $\{x^{(1)}, \dots, x^{(m)}\}$ from data generating distribution $p_{\text{data}}(x)$.
- Update the discriminator by ascending its stochastic gradient:

$$\nabla_{\theta_d} \frac{1}{m} \sum_{i=1}^m \left[\log D(x^{(i)}) + \log \left(1 - D(G(z^{(i)})) \right) \right].$$

end for

- Sample minibatch of m noise samples $\{z^{(1)}, \dots, z^{(m)}\}$ from noise prior $p_g(z)$.
- Update the generator by descending its stochastic gradient:

$$\nabla_{\theta_g} \frac{1}{m} \sum_{i=1}^m \log \left(1 - D(G(z^{(i)})) \right).$$


end for

[Goodfellow et al. NIPS 14]

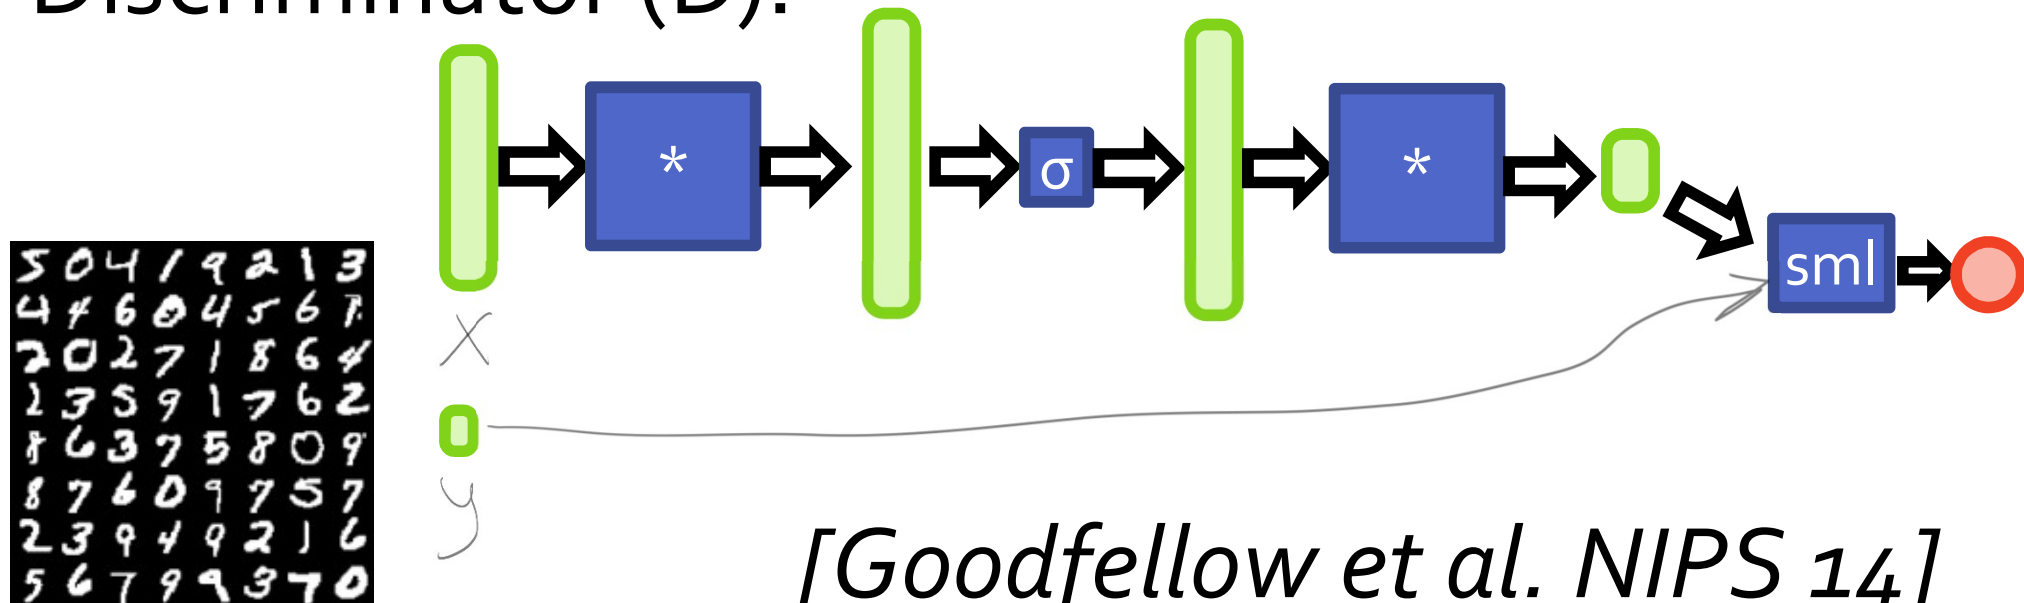
Adversarial generative networks

Generator (G):

noise




Discriminator (D):



Adversarial learning

Поиск игрового равновесия:

$$\min_G \max_D V(D, G) - E_{x \sim p_D(x)} [\log D(x)] - \\ E_{z \sim p_z(z)} [\log (1 - D(G(z)))]$$



[Goodfellow et al. NIPS 14]

Adversarial networks



[Goodfellow et al. NIPS 14]

“Глубокие нейросети со структурированным выводом”


Adversarial loss

Adding adversarial loss greatly improves the sharpness:



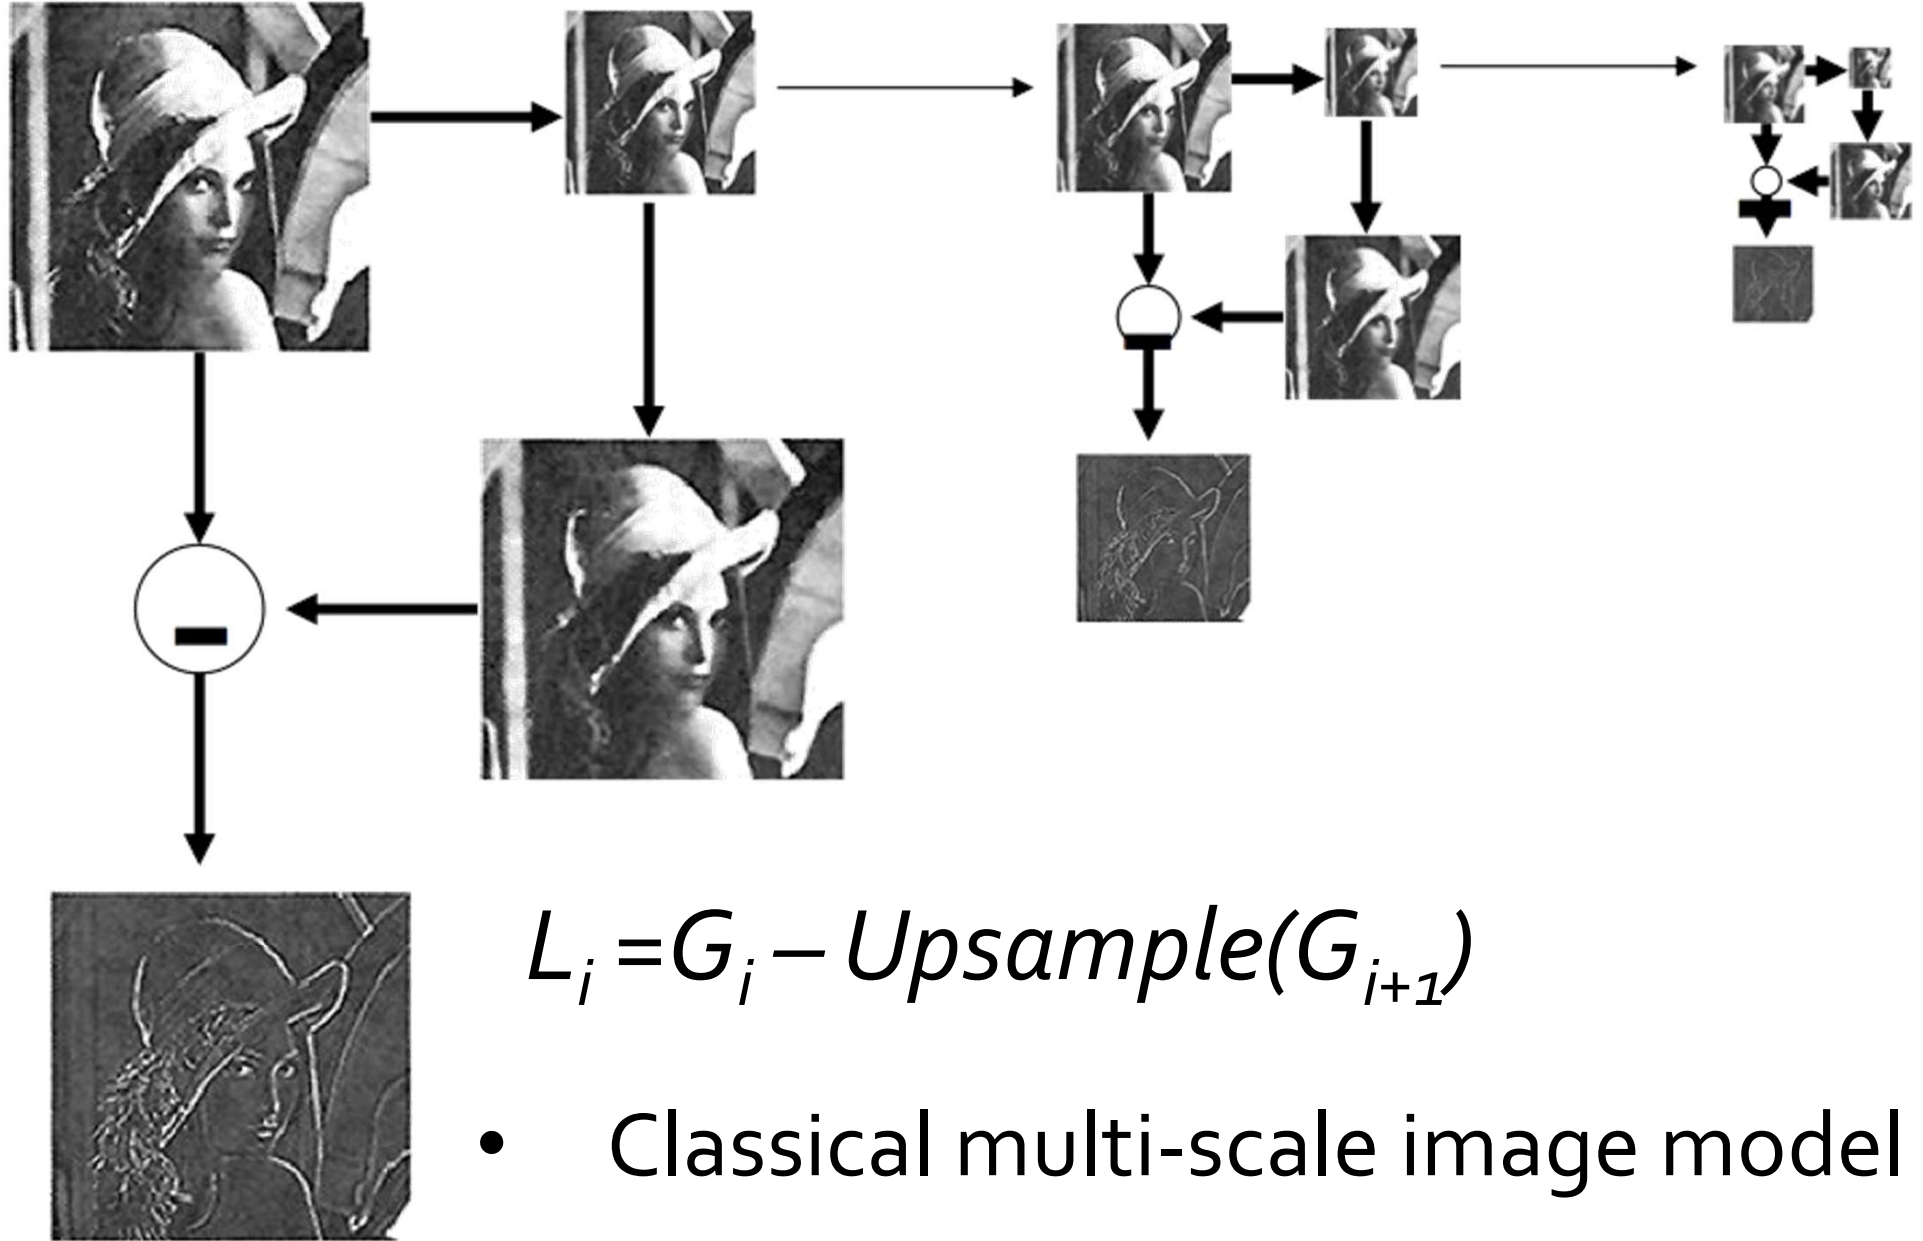
[Dosovitskiy and Brox, Arxiv15]

Gaussian pyramid




$$G_i = \text{Subsample}(\text{Blur}(G_{i-1}))$$

Laplacian pyramid



[Burt Adelson IEEE TC83]

Multiresolutional splining




$$L_i = L^1_i G^M_i + L^2_i (1 - G^M_i)$$

[Burt Adelson TOG83]

Multiresolutional splining




$$L_i = L^1_i G^M_i + L^2_i (1 - G^m_i)$$



[Burt Adelson
TOG83]


Multiresolutional splining



(d)



(h)

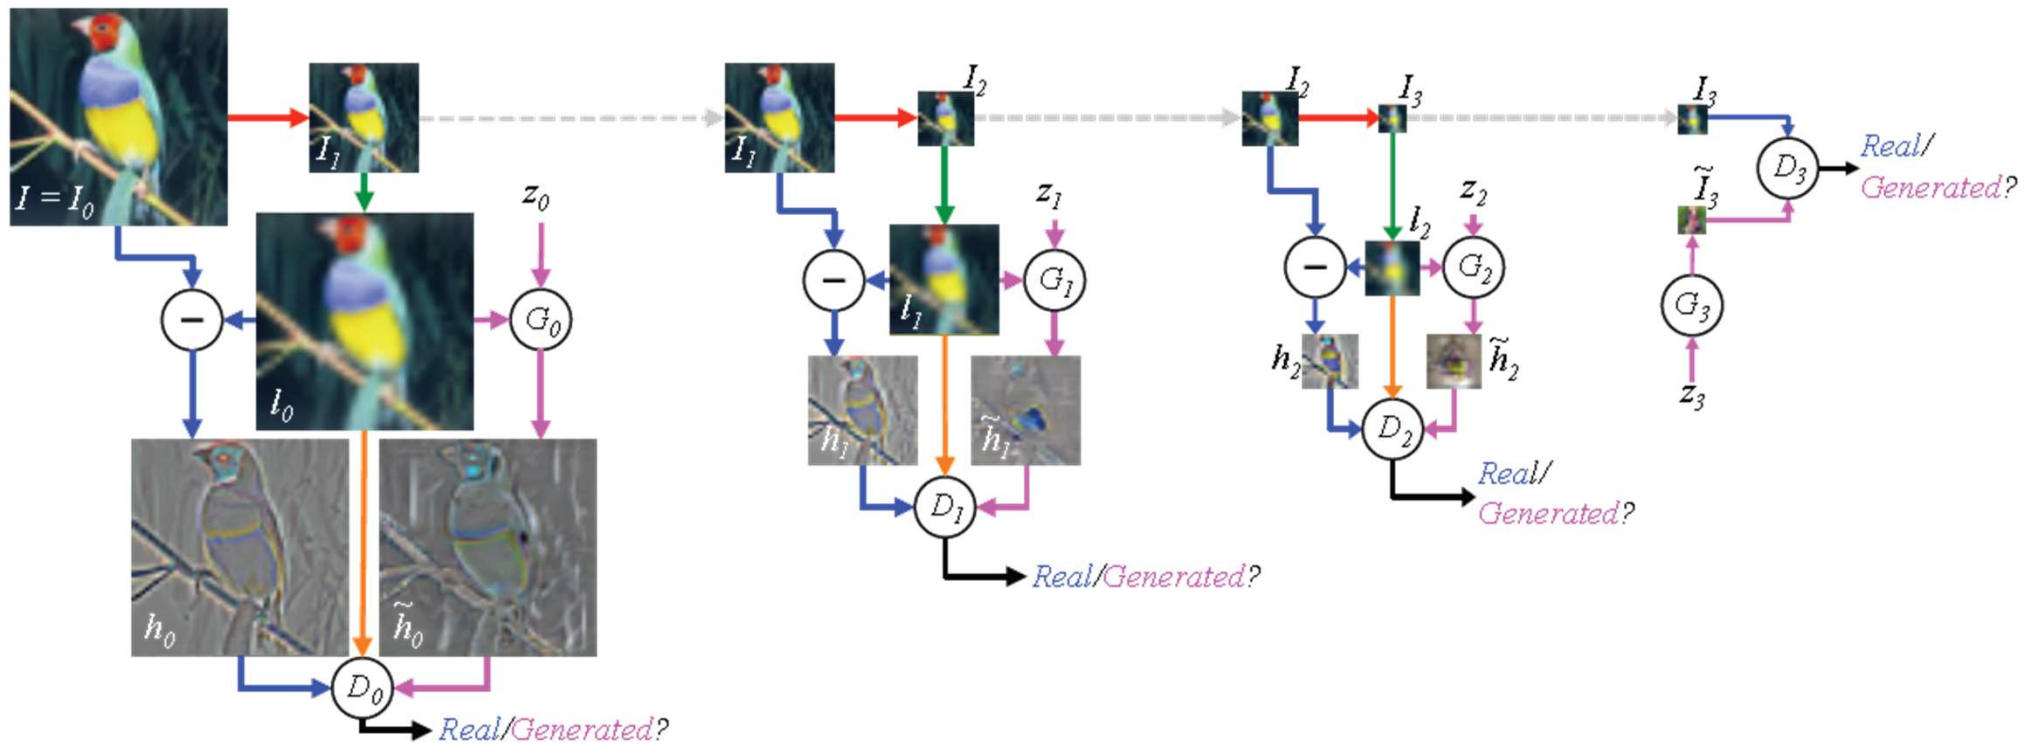


(l)

$$L_i = L^1_i G^M_i + L^2_i (1 - G^m_i)$$

[Burt Adelson TOG83]

Applying GAN in Laplacian fashion



- GAN are applied at each level to generate L_i
- Generator accepts noise and Upsample(G_{i+1})
- At testtime, L_i is generated and G_i is recovered

$$G_i = L_i + \text{Upsample}(G_{i+1})$$

[Denton et al. ICLR15]

Applying GAN in Laplacian fashion



[Denton et al. ICLR15]

“Глубокие нейросети со структурированным выводом”

Applying GAN in Laplacian fashion





[Denton et al. ICLR15]

“Глубокие нейросети со структурированным выводом”

Assessing realism


Ultimate measure: user study




Открытая проблема: каким образом
можно автоматизировать измерение
качества?

[Denton et al. ICLR15]

DCGAN [Radford et al. 2016]




После 1 эпохи:




“Глубокие нейросети со структурированным выводом”

DCGAN [Radford et al. 2016]




После 5 эпох:



“Глубокие нейросети со структурированным выводом”

DCGAN [Radford et al. 2016]




man
with glasses



man
without glasses





woman
without glasses



woman with glasses




DCGAN [Radford et al. 2016]



DCGAN reproduced by [Zhao et al. 2016]

“Глубокие нейросети со структурированным выводом”

Оптимизационные эвристики

 soumith committed on GitHub Merge pull request #4 from raminia/dropout Latest commit d09bbf3 8 hours ago

imagesfirst commit7 days ago

README.mdAdded a dropout trick based on <https://arxiv.org/pdf/1611.07004v1.pdf>a day ago

README.md

How to Train a GAN? Tips and tricks to make GANs work

While research in Generative Adversarial Networks (GANs) continues to improve the fundamental stability of these models, we use a bunch of tricks to train them and make them stable day to day.

Here are a summary of some of the tricks.

[Here's a link to the authors of this document](#)

If you find a trick that is particularly useful in practice, please open a Pull Request to add it to the document. If we find it to be reasonable and verified, we will merge it in.

1. Normalize the inputs

- normalize the images between -1 and 1
- Tanh as the last layer of the generator output

2: A modified loss function

In GAN papers, the loss function to optimize G is $\min (\log 1-D)$, but in practice folks practically use $\max \log D$

- because the first formulation has vanishing gradients early on
- Goodfellow et. al (2014)

In practice, works well:

- Flip labels when training generator: real = fake, fake = real


3: Use a spherical Z

- Dont sample from a Uniform distribution


<https://github.com/soumith/ganhacks>

“Глубокие нейросети со структурированным выводом”

State-of-the-art: EBGAN [Zhao et al. 2016]



DCGAN



EBGAN

$$f_{PT}(S) = \frac{1}{N(N-1)} \sum_i \sum_{j \neq i} \left(\frac{S_i^T S_j}{\|S_i\| \|S_j\|} \right)^2$$

“Глубокие нейросети со структурированным выводом”


State-of-the-art: EBGAN [Zhao et al. 2016]

1000-классовая генерация 256x256:



“Глубокие нейросети со структурированным выводом”

Deep supervised neural networks



- are a “big thing” in computer vision and beyond
- **are hungry for labeled data**



Where to get the data?

Lots of modalities do not have large labeled data sets:


- Biomedical
- Unusual cameras / image types
- Videos
- Data with expert-level annotation (not mTurkable)
-

Surrogate training data often available:

- Borrow from adjacent modality
- Generate synthetic imagery (computer graphics)
- Use data augmentation to amplify data (*image-based rendering, morphing, re-synthesis,....*)

Resulting training data are shifted. *Domain adaptation* needed.

Example: Internet images -> Webcam sensor





[Saenko et al. ECCV2010]



“Глубокие нейросети со структурированным выводом”

Example: (semi-)synthetic to real



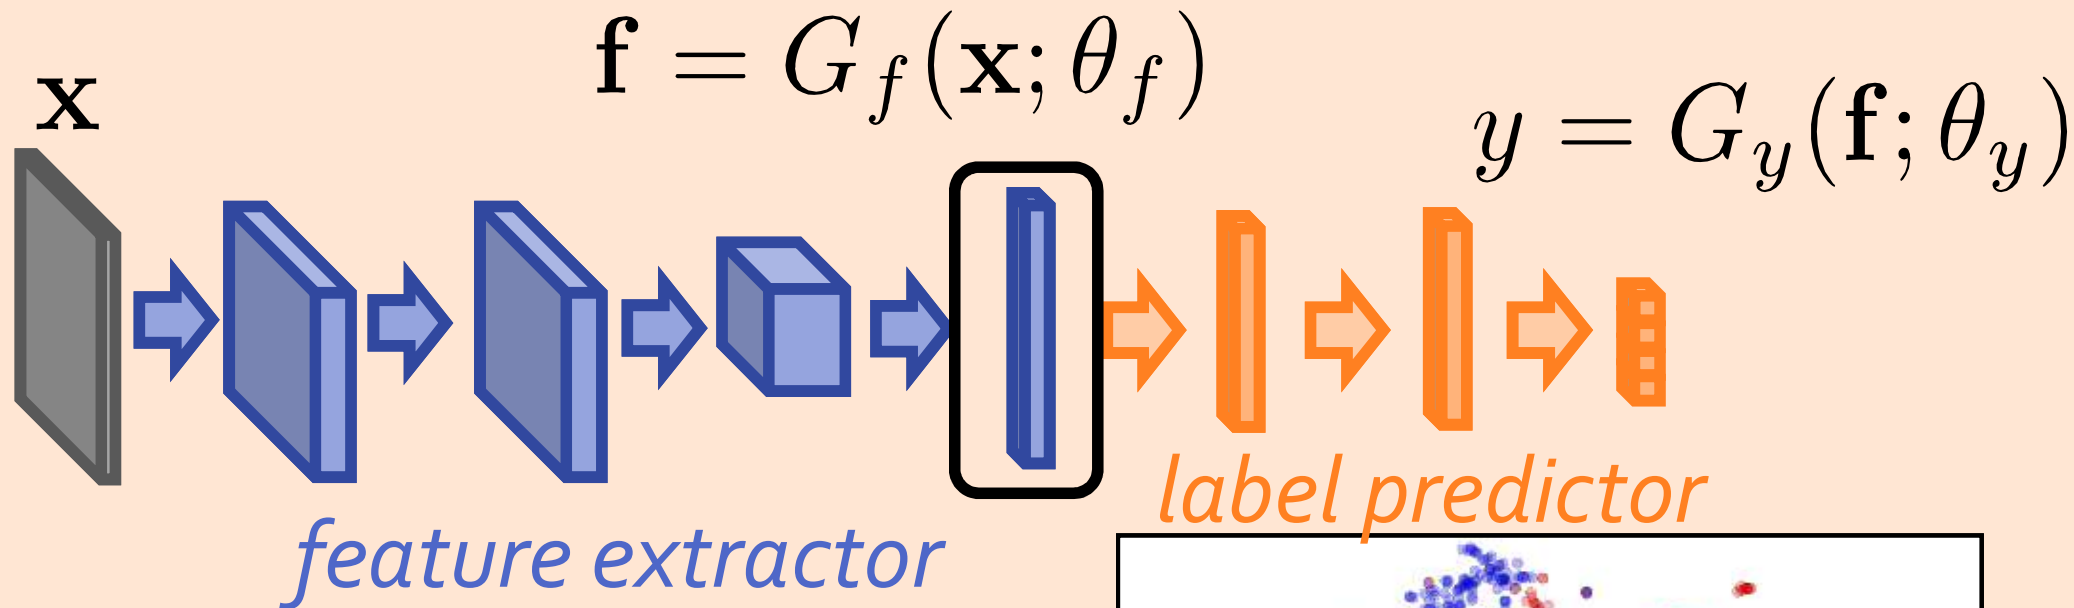
“Глубокие нейросети со структурированным выводом”

Assumptions and goals


- Lots of *labeled* data in the *source domain* (e.g. synthetic images)
- Lots of *unlabeled* data in the *target domain* (e.g. real images)
- **Goal:** train a **deep neural net** that does well on the **target domain**

Large-scale deep unsupervised domain adaptation

Domain shift in a deep architecture



When trained on source only, feature distributions do not match:





$$S(\mathbf{f}) = \{G_f(\mathbf{x}; \theta_f) \mid \mathbf{x} \sim S(\mathbf{x})\}$$


$$T(\mathbf{f}) = \{G_f(\mathbf{x}; \theta_f) \mid \mathbf{x} \sim T(\mathbf{x})\}$$

Idea 1: domain-invariant features wanted



Feature distribution without adaptation:




Our goal (after adaptation):



Idea 2: measuring domain shift




Domain loss low



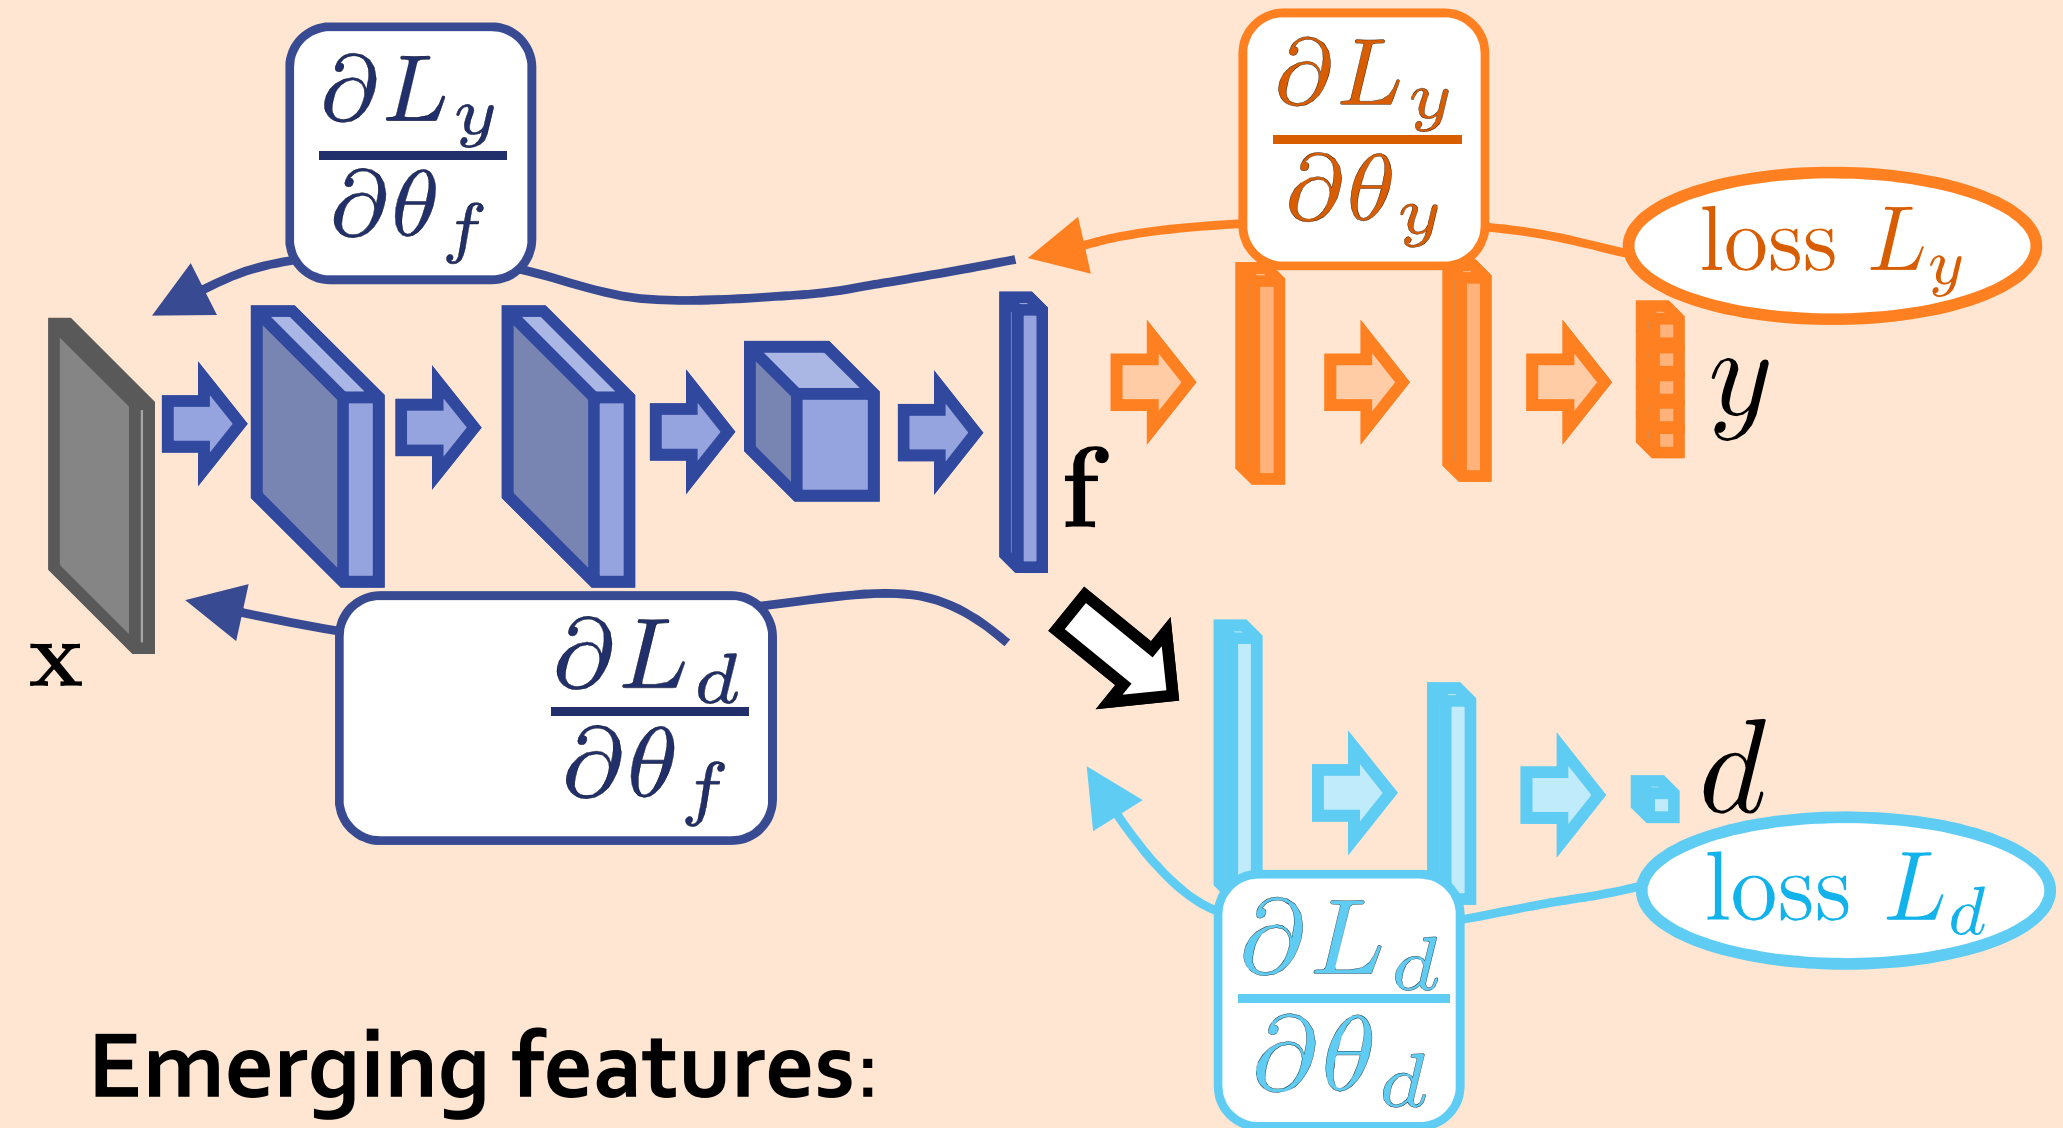
Domain loss high

Learning with adaptation



1. Build this network
2. Train **feature extractor** + **class predictor** on source data
3. Train **feature extractor** + **domain classifier** on source+target data
4. Use **feature extractor** + **class predictor** at test time

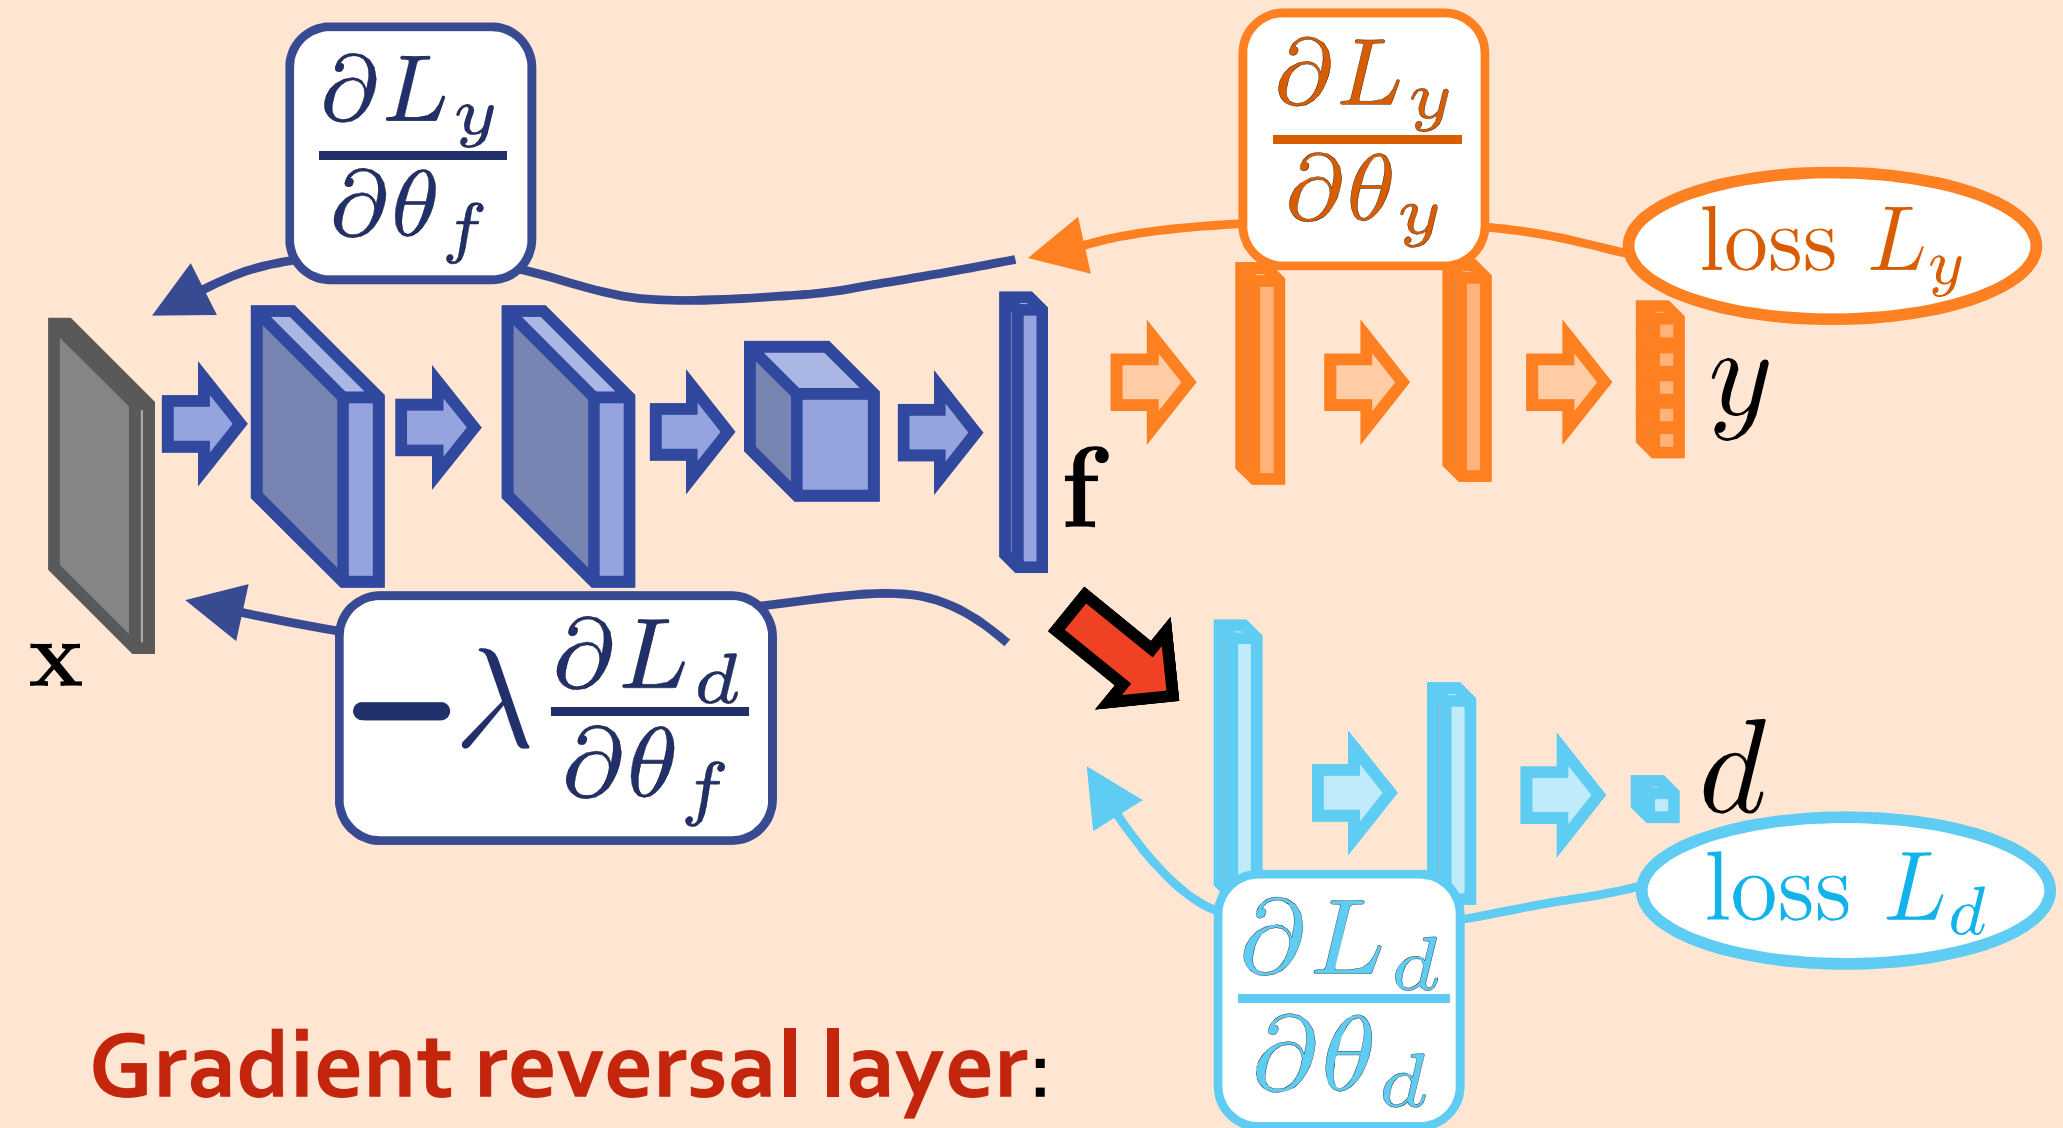
Idea 3: minimizing domain shift



Emerging features:

- Discriminative (good for predicting y)
- Domain-discriminative (good for predicting d)

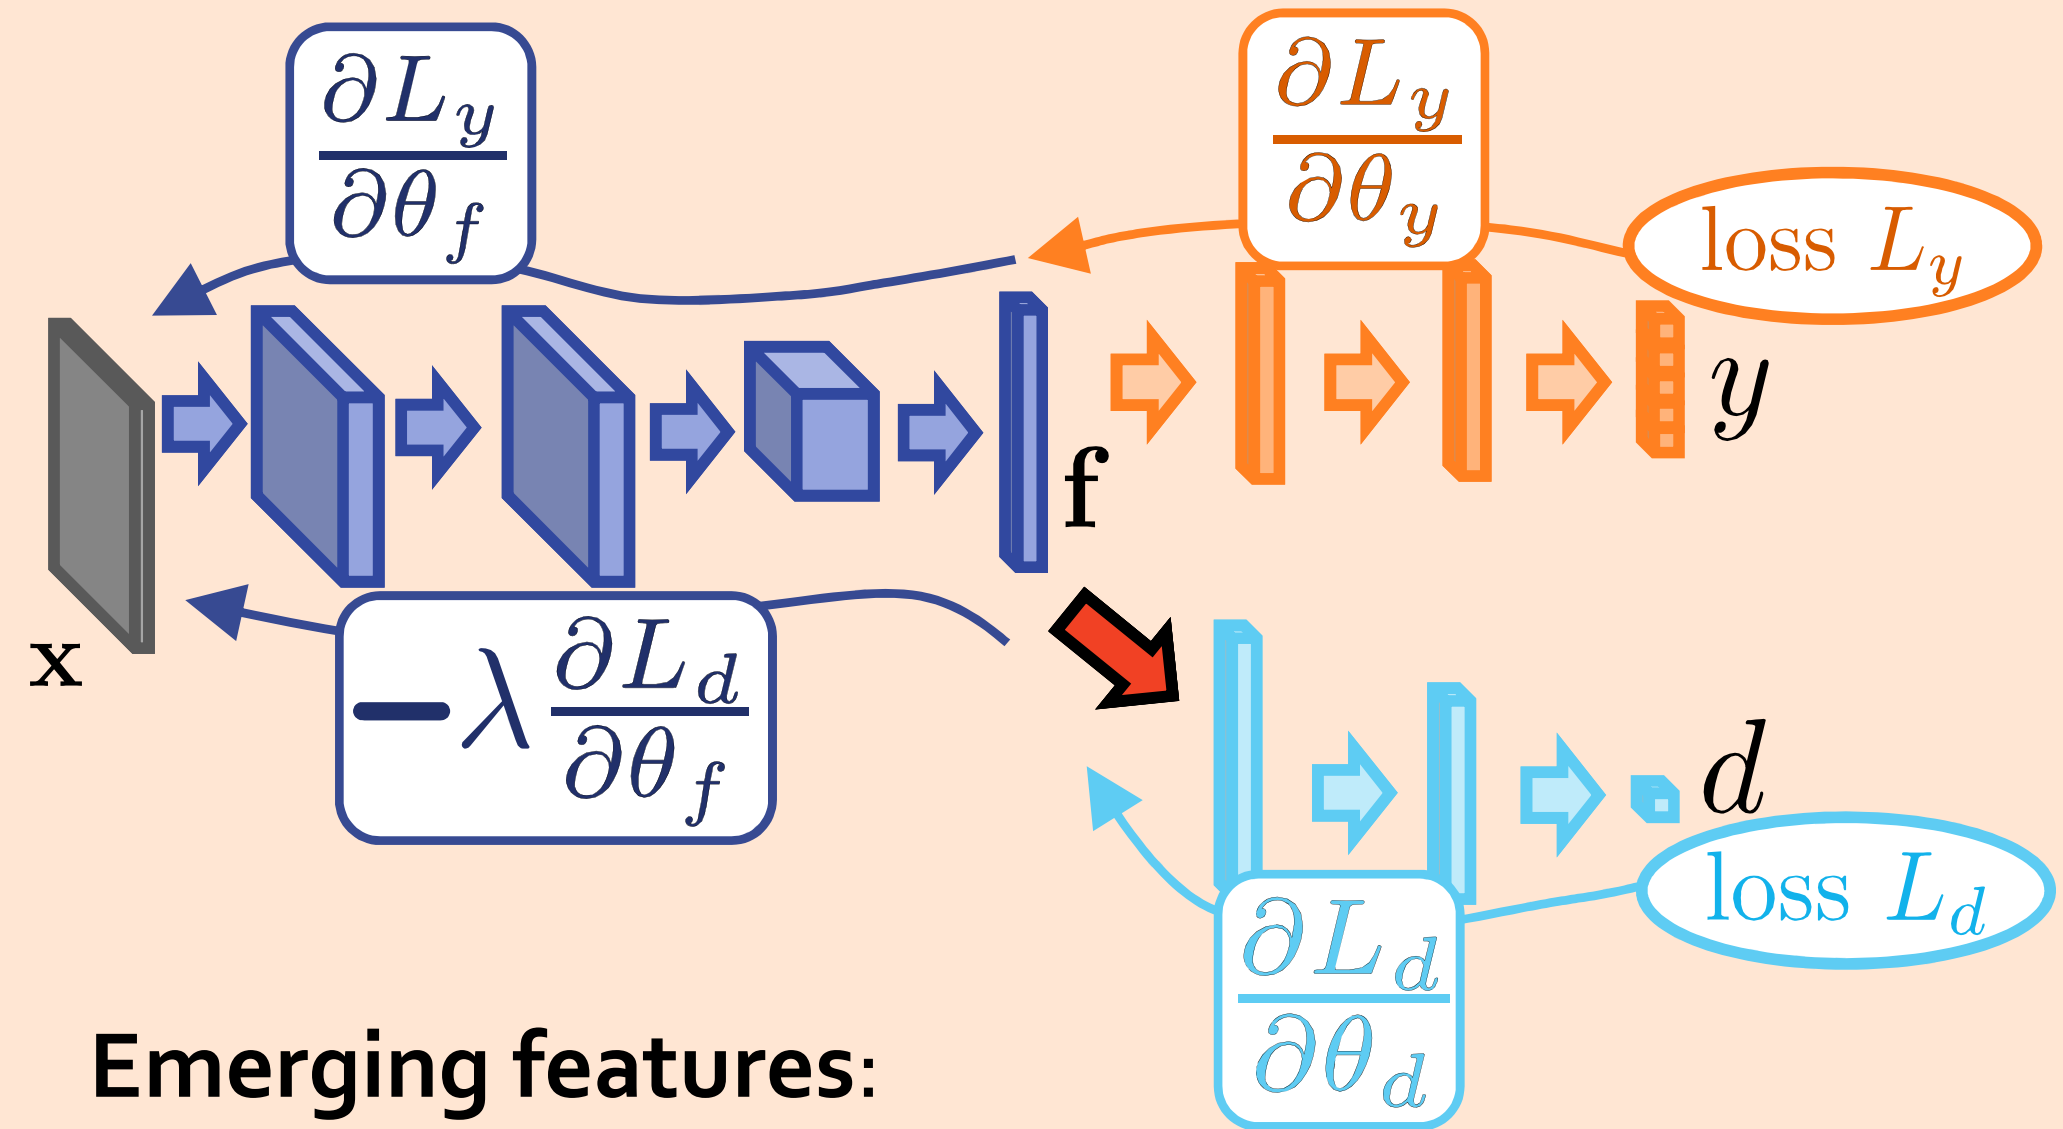
Idea 3: minimizing domain shift



Gradient reversal layer:

- Copies data without change at forwardprop
- Multiplies the gradient by $-\lambda$ at backprop

Idea 3: minimizing domain shift



Emerging features:

- Discriminative (good for predicting y)
- Domain-invariant (not good for predicting d)

Gradient reversal layer

```
class GradReversalLayer : Layer {  
  
    float lambda;  
  
    blob forward (blob  $x$ )    {  
        return  $x$   
    }  
  
    blob backward(blob  $dzdy$ ) {  
        return multiply( $dzdy$ ,  $-lambda$ )  
    }  
}
```

Saddle point interpretation

Our objective (small label prediction loss + large domain classification loss wanted)

$$E(\theta_f, \theta_y, \theta_d) = \sum_{\substack{i=1..N \\ d_i=0}} L_y^i(\theta_f, \theta_y) - \lambda \sum_{i=1..N} L_d^i(\theta_f, \theta_d)$$

The backprop converges to a saddle point:

$$(\hat{\theta}_f, \hat{\theta}_y) = \arg \min_{\theta_f, \theta_y} E(\theta_f, \theta_y, \hat{\theta}_d)$$

$$\hat{\theta}_d = \arg \max_{\theta_d} E(\hat{\theta}_f, \hat{\theta}_y, \theta_d).$$


Similar idea for generative networks:

[Goodfellow et al. Generative adversarial nets. In NIPS, 2014]

Backprop updates

Domain classification loss for the i th example


Label prediction loss for the i th example


$$\theta_f \leftarrow \theta_f - \mu \left(\frac{\partial L_y^i}{\partial \theta_f} - \lambda \frac{\partial L_d^i}{\partial \theta_f} \right)$$

$$\theta_y \leftarrow \theta_y - \mu \frac{\partial L_y^i}{\partial \theta_y}$$

$$\theta_d \leftarrow \theta_d - \mu \frac{\partial L_d^i}{\partial \theta_d}$$

Office dataset



[Saenko et al. ECCV2010]



“Глубокие нейросети со структурированным выводом”

Results on Office dataset


METHOD	SOURCE	AMAZON	DSLR	WEBCAM
	TARGET	WEBCAM	WEBCAM	DSLR
GFK(PLS, PCA) (GONG ET AL., 2012)		.464 \pm .005	.613 \pm .004	.663 \pm .004
SA (FERNANDO ET AL., 2013)		.450	.648	.699
DA-NBNN (TOMMASI & CAPUTO, 2013)		.528 \pm .037	.766 \pm .017	.762 \pm .025
DLID (S. CHOPRA & GOPALAN, 2013)		.519	.782	.899
DECAF ₆ SOURCE ONLY (DONAHUE ET AL., 2014)		.522 \pm .017	.915 \pm .015	–
DANN (GHIFARY ET AL., 2014)		.536 \pm .002	.712 \pm .000	.835 \pm .000
DDC (TZENG ET AL., 2014)		.594 \pm .008	.925 \pm .003	.917 \pm .008
PROPOSED APPROACH		.673 \pm .017	.940 \pm .008	.937 \pm .010

Most similar approach (matches means of distributions):

[Tzeng et al. Deep domain confusion: Maximizing for domain invariance. CoRR, abs/1412.3474, 2014]


- In the comparison we use more target examples than [Tseng et al.] (and same as DLID)
- Both our results and Tseng et al. fine-tune *AlexNet*

Example: from synthetic to real




“Windows digits”


“House numbers”



Example: large gap



“House numbers”




Reverse
direction
does not
work 😞

TODO: what I have not covered

1. Автоэнкодеры, вариационные автоэнкодеры
2. Последовательная генерация (Pixel CNNs/Pixel RNNs/DRAW,....)
3. Обращаемые отображения

Автоэнкодер




низкоразмерное представление

$$L(\theta_e, \theta_d) = \|d(e(x; \theta_e); \theta_d) - x\|^2$$

$$\theta_{e,d}^{t+1} = \theta_{e,d}^t - \lambda_t \frac{dL}{d\theta_{e,d}}(x_t)$$


- Автоэнкодер обеспечивает сокращение размерности $x \rightarrow e(x; \theta_e)$
- Обобщает линейные методы

Редактирование с помощью автоэнкодера



x_i^1 x_i^2

Редактирование с помощью автоэнкодера



$$V_i = e(x_i^2; \theta_e) - e(x_i^1; \theta_e)$$

$$V = \frac{1}{N} \sum_{i=1}^N V_i$$


$$x^1 \rightarrow e(x^1; \theta_e) + \bar{V}$$

$$e(x^1) + \bar{V} \rightarrow d(e(x^1) + \bar{V}) \approx x^2$$


x_i^1 x_i^2



Редактирование с помощью автоэнкодера



$$d(e(x^I; \theta_e) + \alpha v, \theta_d)$$



Thanks to L.Yekimov
(+F.Chervinsky,D.Kononenko,D.Sungatullina,Y.Ganin)

План

1. «Стандартные» свёрточные сети
2. «Практическая» оптимизация
3. Синтезирующие сети с простыми функциями потерь
4. Синтез через повторение статистик
5. **Играющие сети (adversarial networks)**