

# Генеративно-сопоставительные нейронные сети и их друзья

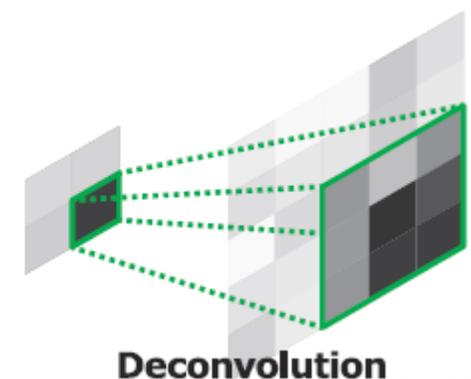
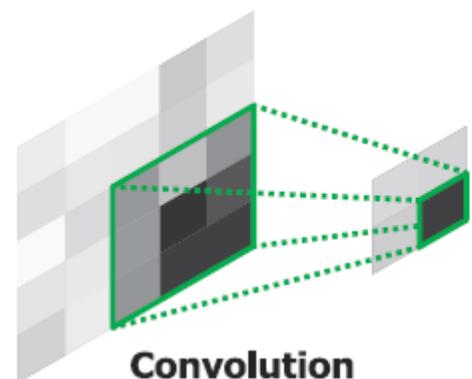
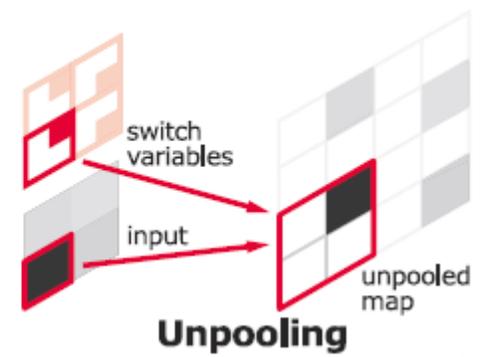
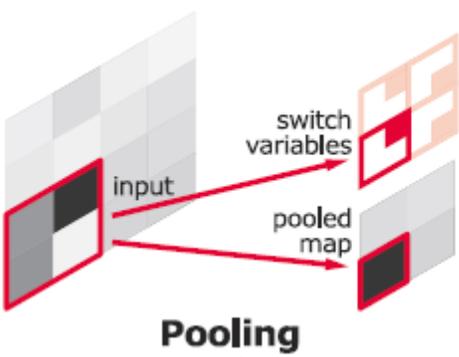
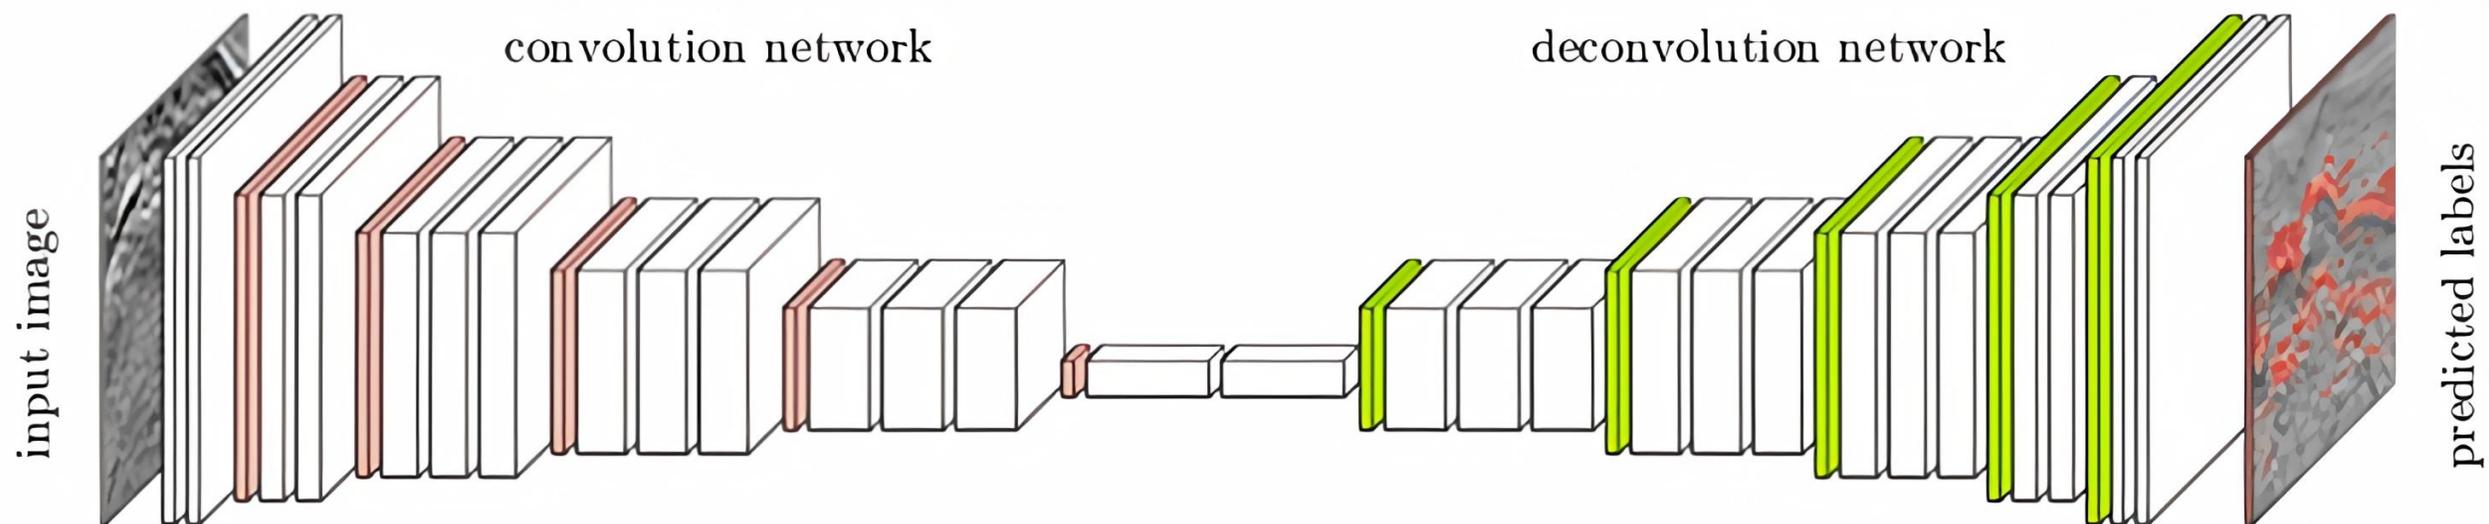
Перминов Андрей

13 октября 2021

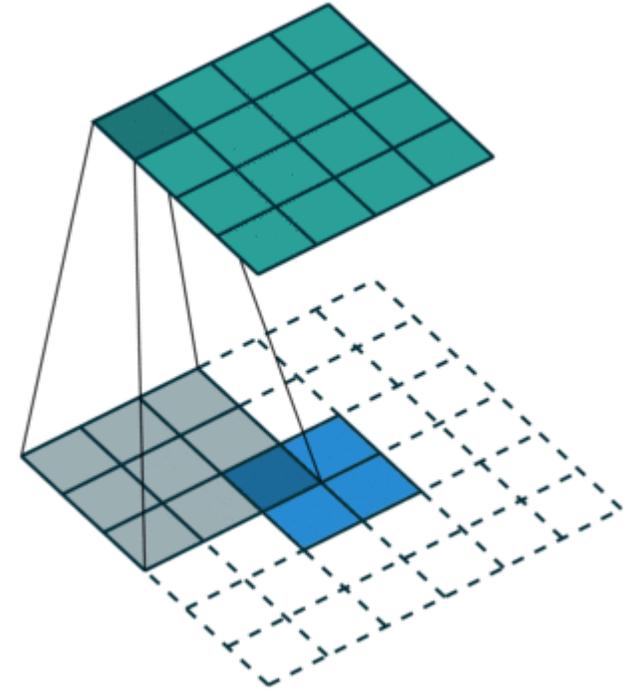
ИСП РАН



*They don't appear to want to compete. They just want to dance.*



- позволяет увеличивать размер входного тензора;
- работает аналогично шагу обратного распространения ошибки в свёрточном слое;
- в отличие от обычных интерполяционных слоёв обучается и показывает более высокие результаты;
- при вычислении фильтры поворачиваются на  $180^\circ$



Если к изображению размера  $W_{in} \times H_{in}$  применить обратную свертку размера  $F_w \times F_h$  с дополнением нулями  $P$  и шагом  $S$ , то размер выходного изображения будет равен  $W_{out} \times H_{out}$ , где:

$$W_{out} = (W_{in} - 1) \cdot S + F_w - 2P$$
$$H_{out} = (H_{in} - 1) \cdot S + F_h - 2P$$

Примеры:

$$F = 3 \times 3, P = 1, S = 1:$$

$$W_{out} = (W_{in} - 1) \cdot 1 + 3 - 2 = W_{in}$$

$$H_{out} = (H_{in} - 1) \cdot 1 + 3 - 2 = H_{in}$$

$$F = 5 \times 3, P = 2, S = 2:$$

$$W_{out} = (W_{in} - 1) \cdot 2 + 5 - 2 \cdot 2 = 2 \cdot W_{in} - 1$$

$$H_{out} = (H_{in} - 1) \cdot 2 + 3 - 2 \cdot 2 = 2 \cdot H_{in} - 3$$

2	-4	-3
1	3	-2

Изображение (2x3)

×

3	2	-1
-1	1	4
1	3	2

Фильтр

=


Результат свёртки: 5x7

2	0	-4	0	-3
0	0	0	0	0
1	0	3	0	-2

Изображение (3x5)

×

2	3	1
4	1	-1
-1	2	3

Фильтр  
(повёрнутый)

=


Результат свёртки: 5x7

0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0
0	0	2	0	-4	0	-3	0	0
0	0	0	0	0	0	0	0	0
0	0	1	0	3	0	-2	0	0
0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0

Изображение + full padding (7x9)

×

2	3	1
4	1	-1
-1	2	3

Фильтр  
(повёрнутый)

=


Результат свёртки: 5x7

0 <sub>2</sub>	0 <sub>3</sub>	0 <sub>1</sub>	0	0	0	0	0	0
0 <sub>4</sub>	0 <sub>1</sub>	0 <sub>-1</sub>	0	0	0	0	0	0
0 <sub>-1</sub>	0 <sub>2</sub>	2 <sub>3</sub>	0	-4	0	-3	0	0
0	0	0	0	0	0	0	0	0
0	0	1	0	3	0	-2	0	0
0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0

Изображение + full padding (7x9)

×

2	3	1
4	1	-1
-1	2	3

Фильтр  
(повёрнутый)

=

6						

Результат свёртки: 5x7

0	0 <sub>2</sub>	0 <sub>3</sub>	0 <sub>1</sub>	0	0	0	0	0
0	0 <sub>4</sub>	0 <sub>1</sub>	0 <sub>-1</sub>	0	0	0	0	0
0	0 <sub>-1</sub>	2 <sub>2</sub>	0 <sub>3</sub>	-4	0	-3	0	0
0	0	0	0	0	0	0	0	0
0	0	1	0	3	0	-2	0	0
0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0

Изображение + full padding (7x9)

×

2	3	1
4	1	-1
-1	2	3

Фильтр  
(повёрнутый)

=

6	4					

Результат свёртки: 5x7

0	0	0 <sub>2</sub>	0 <sub>3</sub>	0 <sub>1</sub>	0	0	0	0
0	0	0 <sub>4</sub>	0 <sub>1</sub>	0 <sub>-1</sub>	0	0	0	0
0	0	2 <sub>-1</sub>	0 <sub>2</sub>	-4 <sub>3</sub>	0	-3	0	0
0	0	0	0	0	0	0	0	0
0	0	1	0	3	0	-2	0	0
0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0

Изображение + full padding (7x9)

×

2	3	1
4	1	-1
-1	2	3

Фильтр  
(повёрнутый)

=

6	4	-14				

Результат свёртки: 5x7

0	0	0	0 <sub>2</sub>	0 <sub>3</sub>	0 <sub>1</sub>	0	0	0
0	0	0	0 <sub>4</sub>	0 <sub>1</sub>	0 <sub>-1</sub>	0	0	0
0	0	2	0 <sub>-1</sub>	-4 <sub>2</sub>	0 <sub>3</sub>	-3	0	0
0	0	0	0	0	0	0	0	0
0	0	1	0	3	0	-2	0	0
0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0

Изображение + full padding (7x9)

×

2	3	1
4	1	-1
-1	2	3

Фильтр  
(повёрнутый)

=

6	4	-14	-8			

Результат свёртки: 5x7

0	0	0	0	0 <sub>2</sub>	0 <sub>3</sub>	0 <sub>1</sub>	0	0
0	0	0	0	0 <sub>4</sub>	0 <sub>1</sub>	0 <sub>-1</sub>	0	0
0	0	2	0	-4 <sub>-1</sub>	0 <sub>2</sub>	-3 <sub>3</sub>	0	0
0	0	0	0	0	0	0	0	0
0	0	1	0	3	0	-2	0	0
0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0

Изображение + full padding (7x9)

×

2	3	1
4	1	-1
-1	2	3

Фильтр  
(повёрнутый)

=

6	4	-14	-8	-5		

Результат свёртки: 5x7

0	0	0	0	0	0 <sub>2</sub>	0 <sub>3</sub>	0 <sub>1</sub>	0
0	0	0	0	0	0 <sub>4</sub>	0 <sub>1</sub>	0 <sub>-1</sub>	0
0	0	2	0	-4	0 <sub>-1</sub>	-3 <sub>2</sub>	0 <sub>3</sub>	0
0	0	0	0	0	0	0	0	0
0	0	1	0	3	0	-2	0	0
0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0

Изображение + full padding (7x9)

×

2	3	1
4	1	-1
-1	2	3

Фильтр  
(повёрнутый)

=

6	4	-14	-8	-5	-6	

Результат свёртки: 5x7

0	0	0	0	0	0	0 <sub>2</sub>	0 <sub>3</sub>	0 <sub>1</sub>
0	0	0	0	0	0	0 <sub>4</sub>	0 <sub>1</sub>	0 <sub>-1</sub>
0	0	2	0	-4	0	-3 <sub>-1</sub>	0 <sub>2</sub>	0 <sub>3</sub>
0	0	0	0	0	0	0	0	0
0	0	1	0	3	0	-2	0	0
0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0

Изображение + full padding (7x9)

×

2	3	1
4	1	-1
-1	2	3

Фильтр  
(повёрнутый)

=

6	4	-14	-8	-5	-6	3

Результат свёртки: 5x7

0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0
0	0	2	0	-4	0	-3	0	0
0	0	0	0	0	0	0	0	0
0	0	1	0	3	0	-2 <sub>2</sub>	0 <sub>3</sub>	0 <sub>1</sub>
0	0	0	0	0	0	0 <sub>4</sub>	0 <sub>1</sub>	0 <sub>-1</sub>
0	0	0	0	0	0	0 <sub>-1</sub>	0 <sub>2</sub>	0 <sub>3</sub>

Изображение + full padding (7x9)

×

2	3	1
4	1	-1
-1	2	3

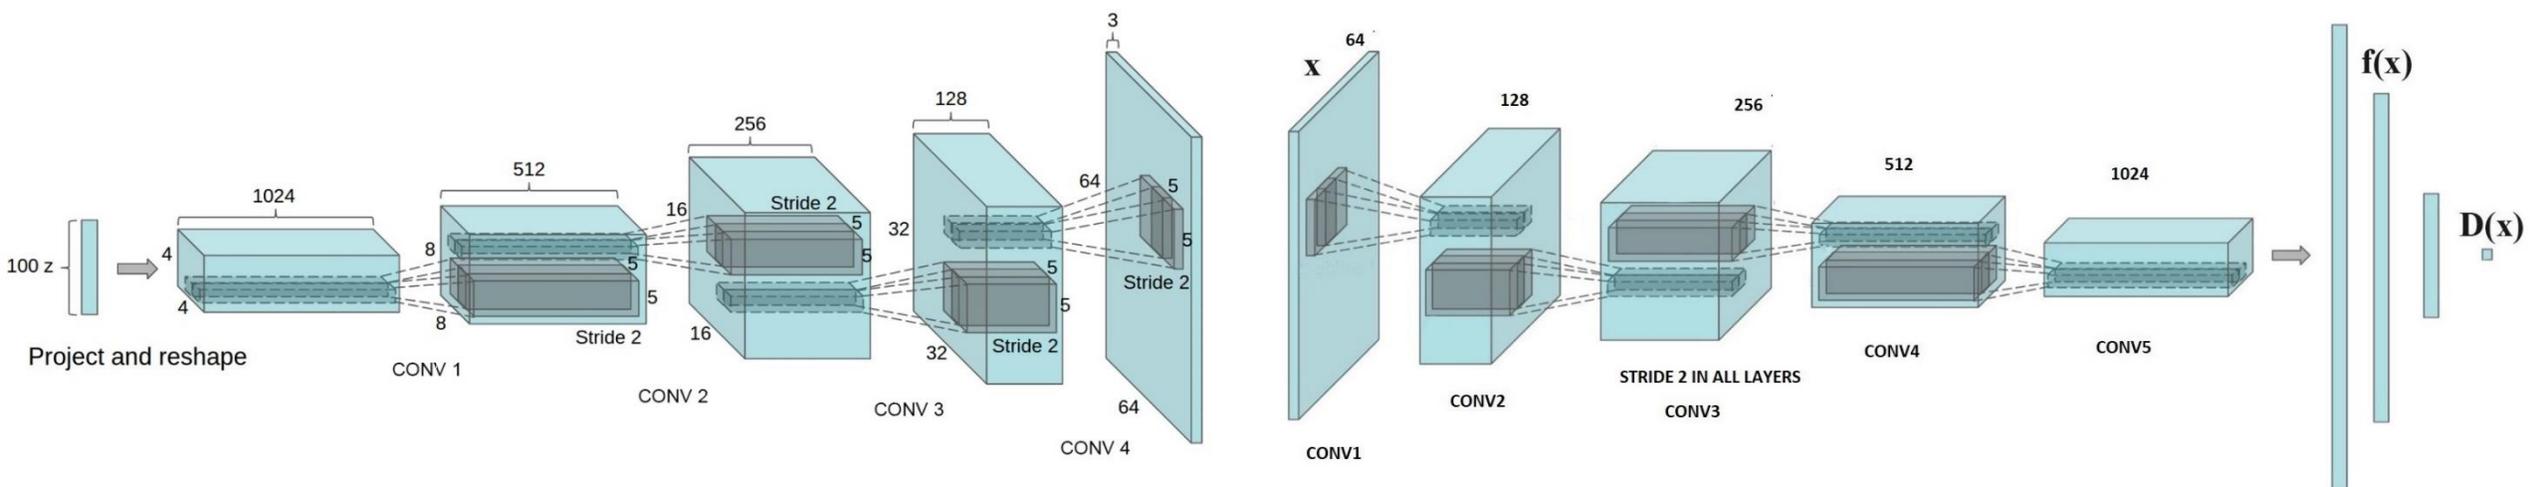
Фильтр  
(повёрнутый)

=

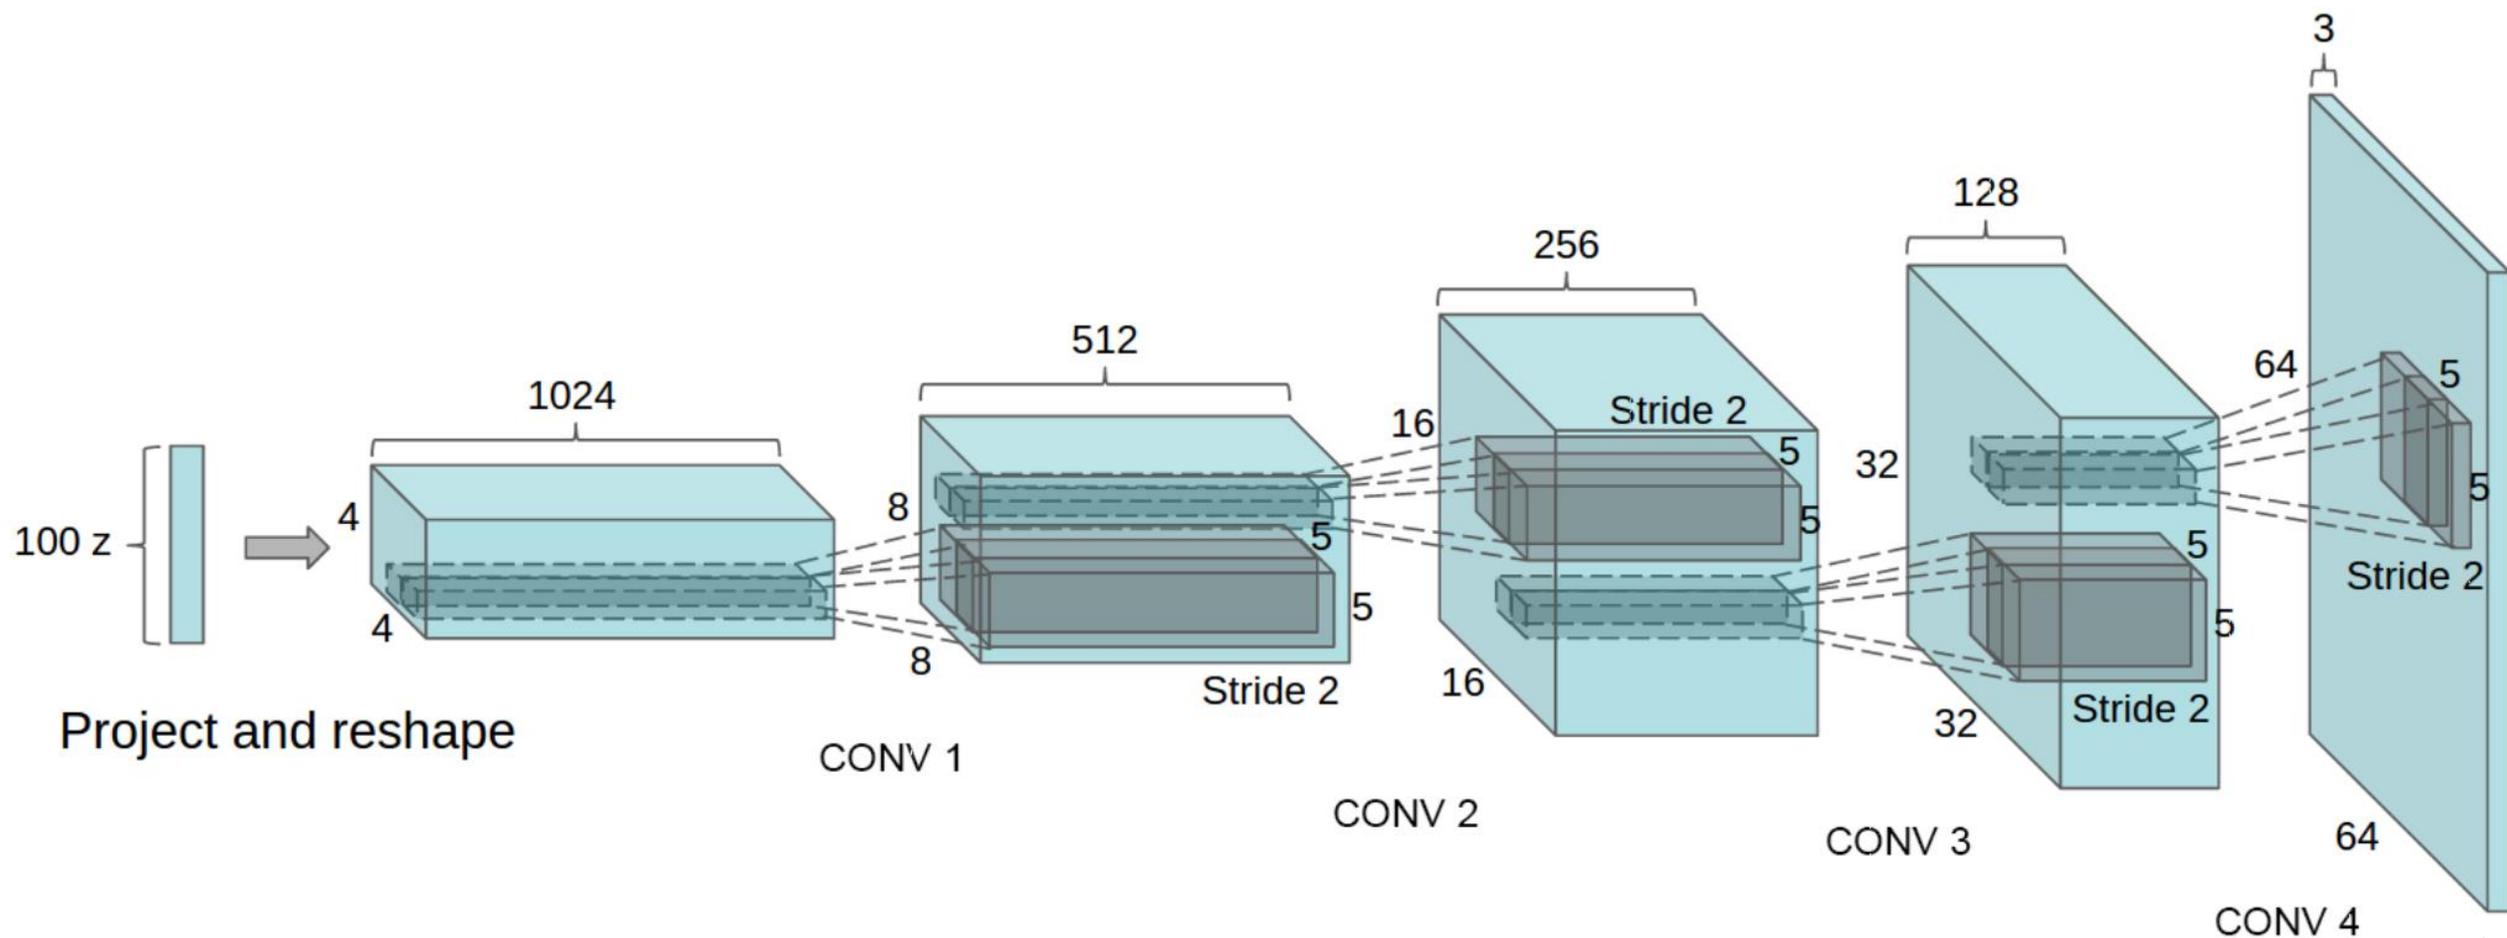
6	4	-14	-8	-5	-6	3
-2	2	12	-4	-13	-3	-12
5	8	8	-6	-20	-13	-4
-1	1	1	3	14	-2	-8
1	3	5	9	4	-6	-4

Результат свёртки: 5x7

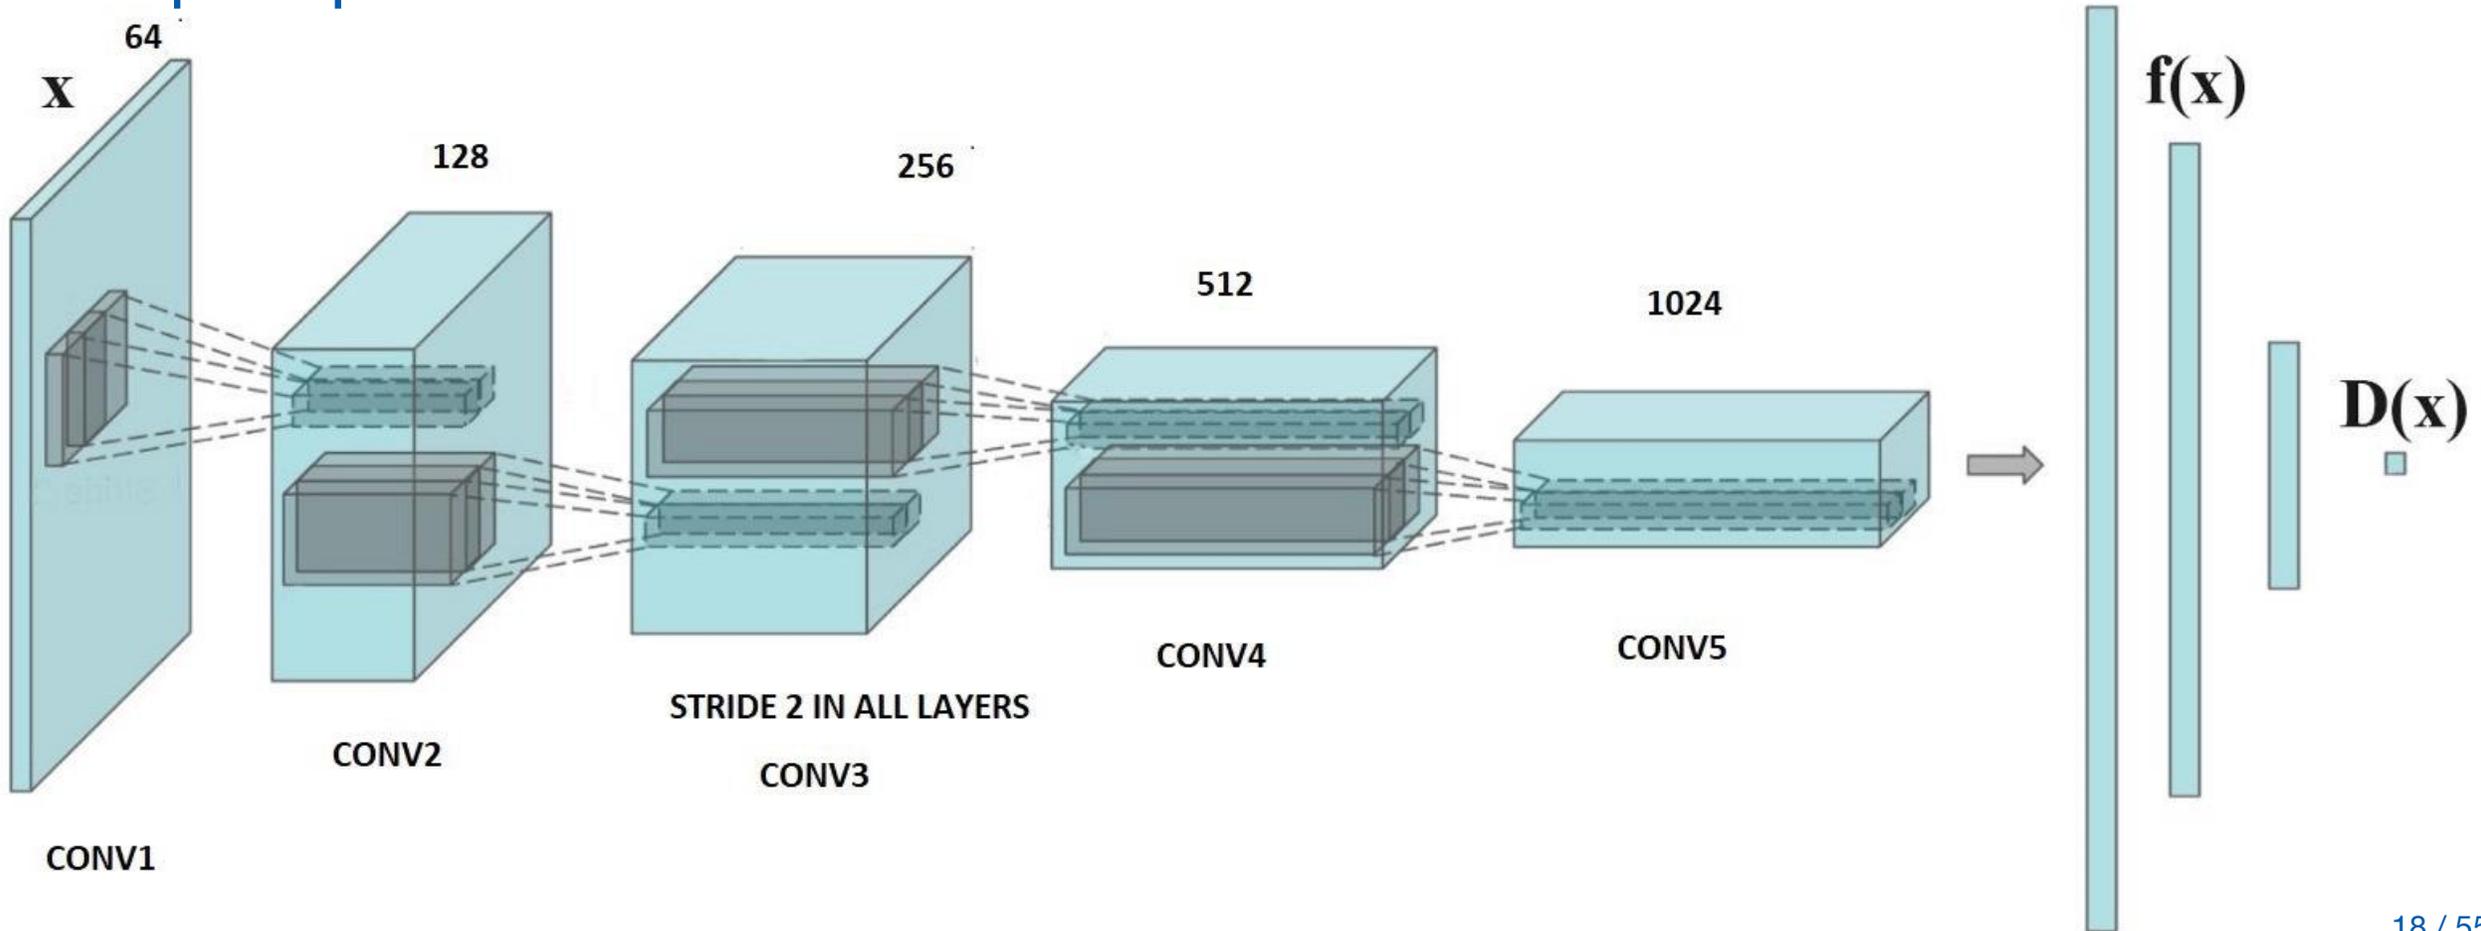
Генеративно-состязательная нейросеть (generative adversarial network, GAN) — архитектура, состоящая из двух независимых нейронных сетей, настроенных на работу друг против друга: генератора и дискриминатора.

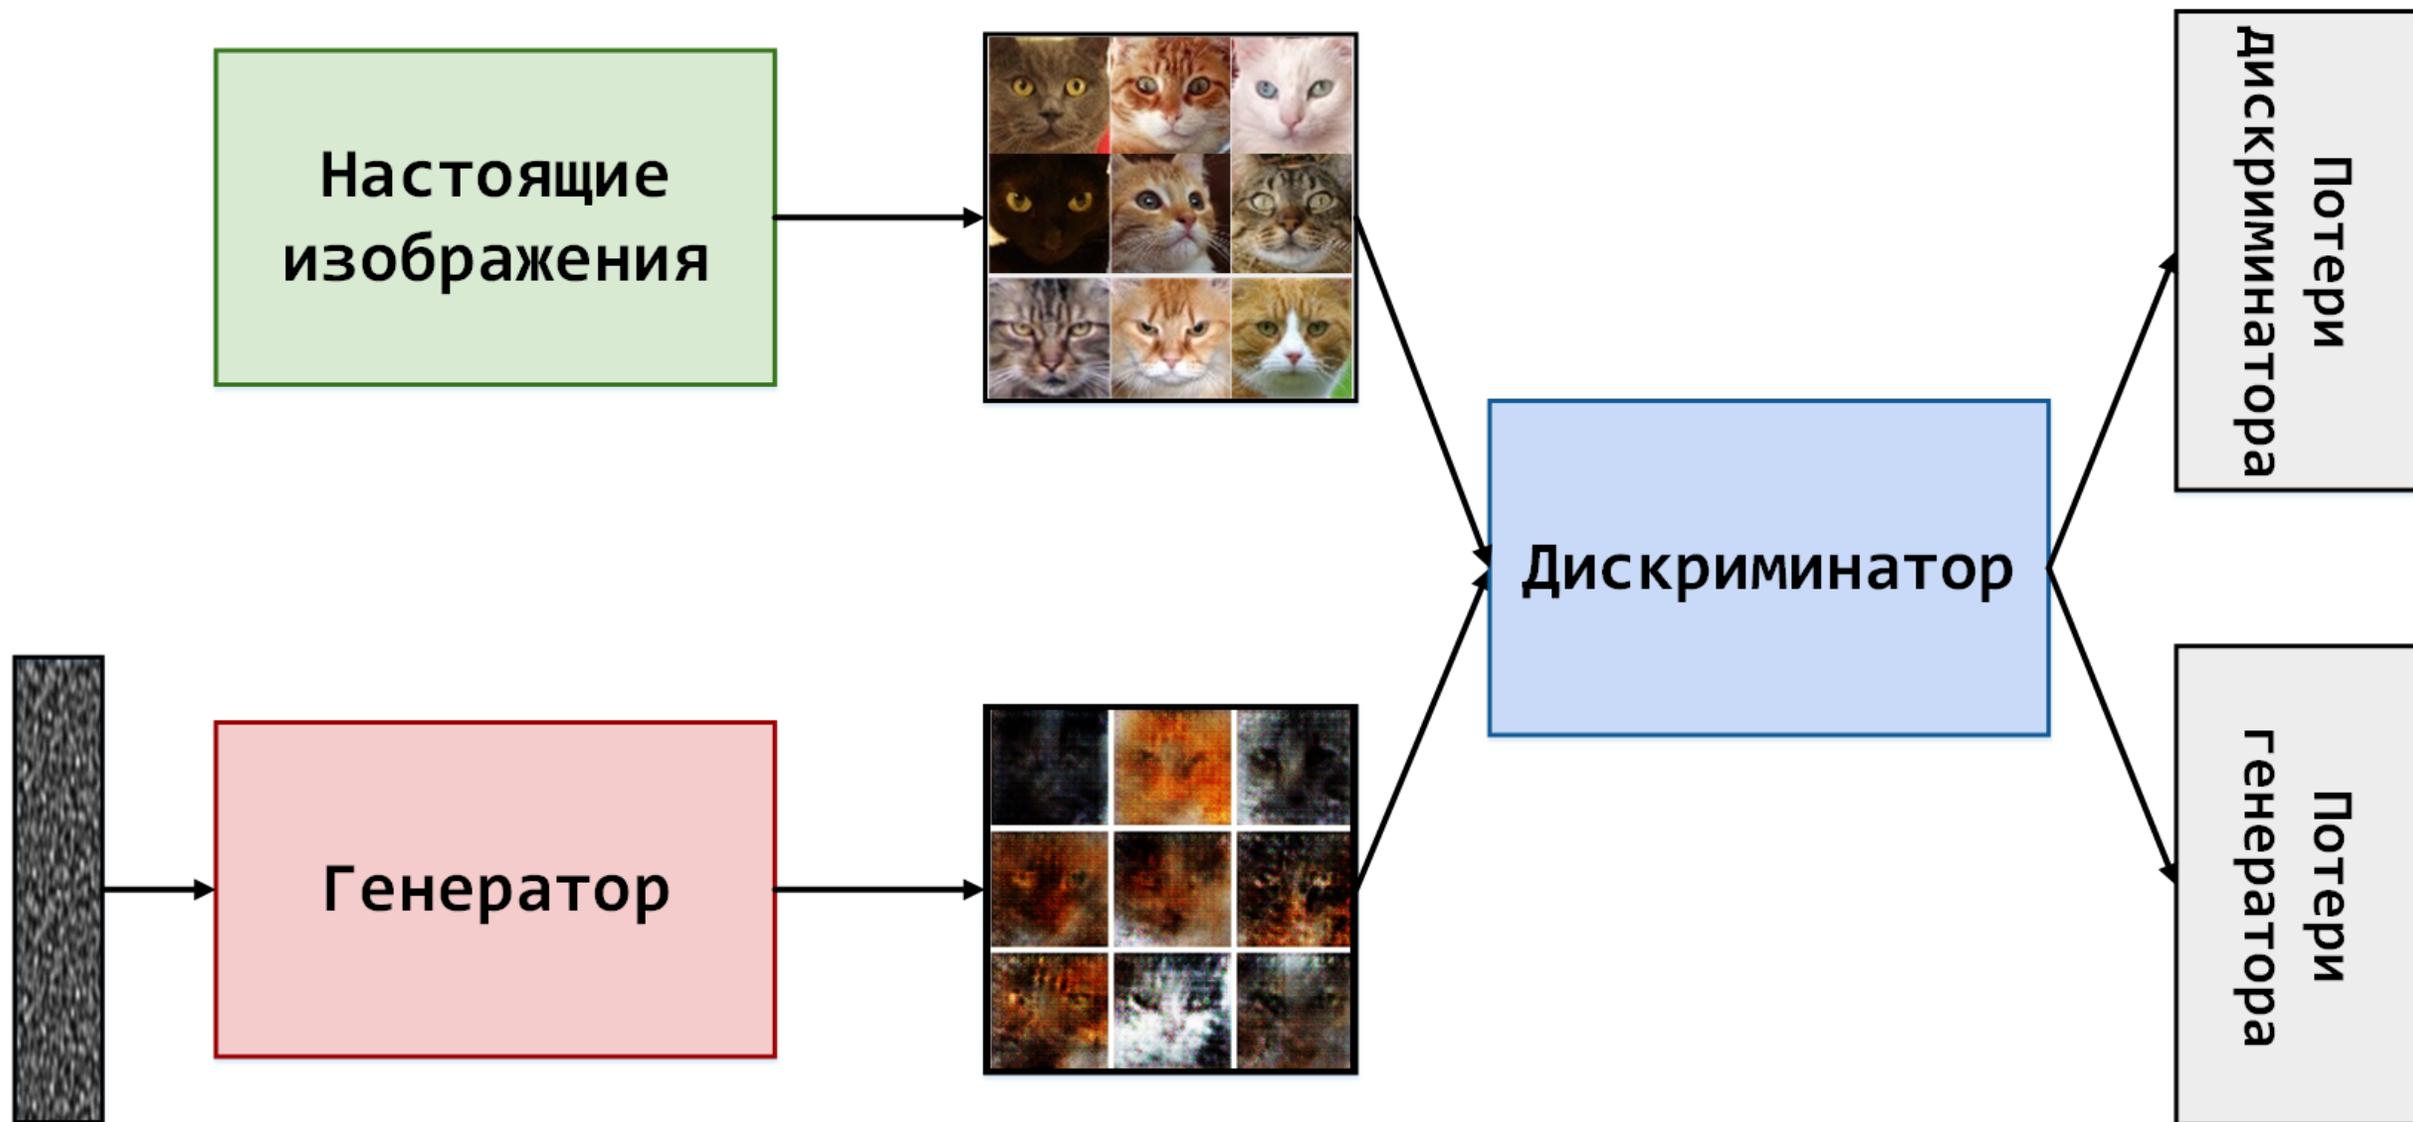


Генератор – сеть, создающая изображения, используя произвольный вектор небольшой размерности (обычно около 64-256).



Дискриминатор – бинарный классификатор, который учится отличать настоящие изображения от изображений, созданных генератором.





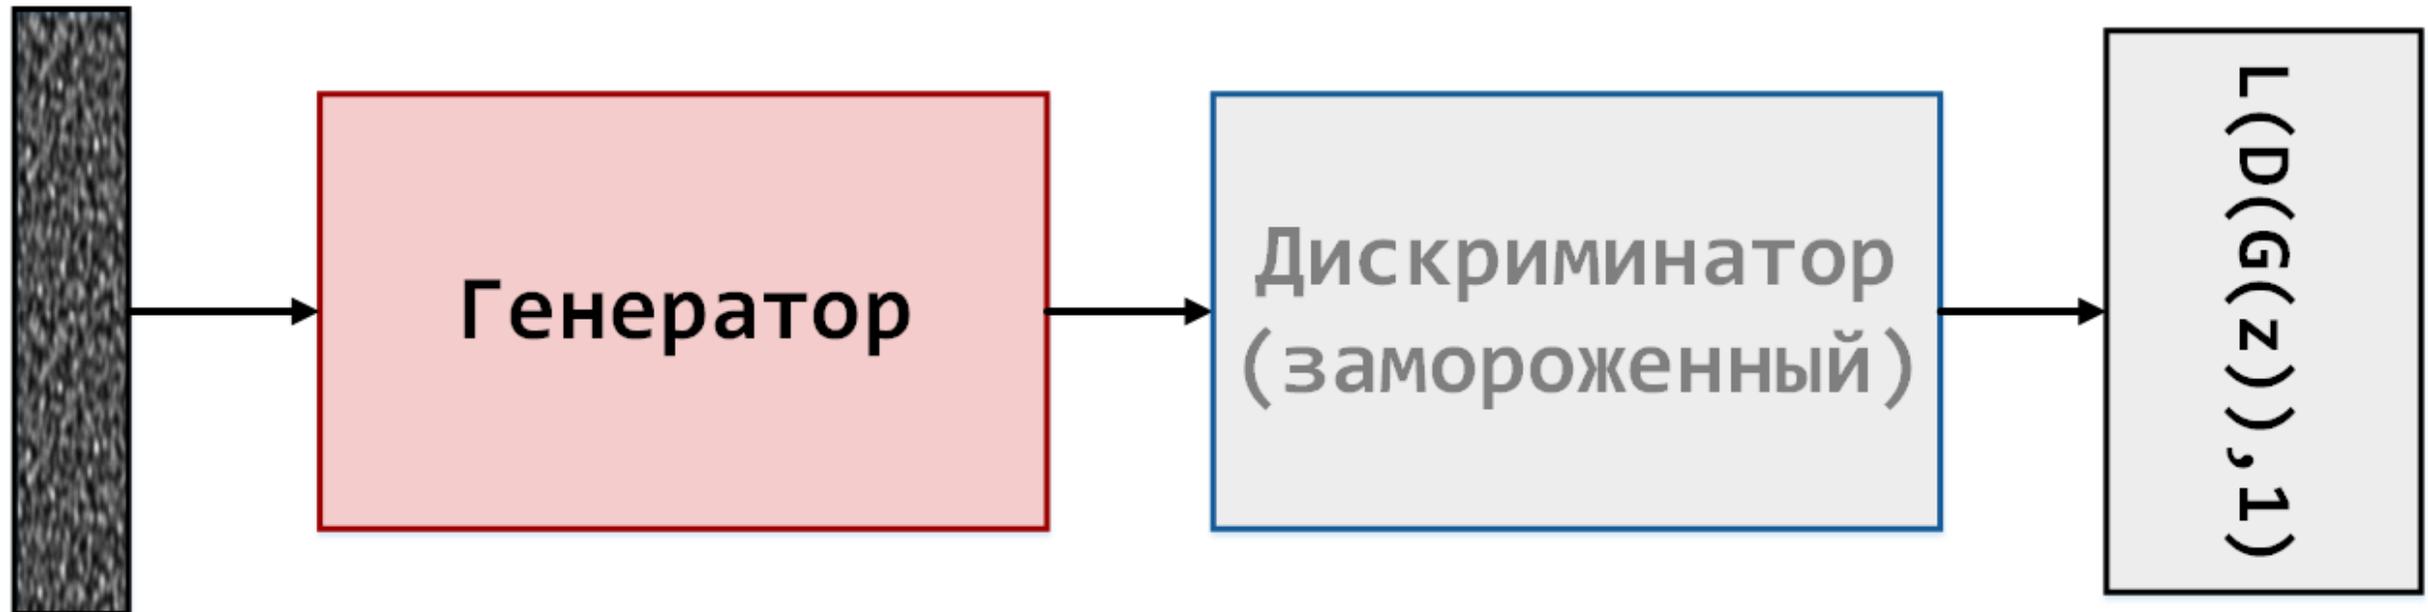
Обучаем дискриминатор предсказывать метку «1» на батче из реальных изображений.



Обучаем дискриминатор предсказывать метку «0» на батче из изображений, созданных генератором.



Замораживаем весовые коэффициенты дискриминатора и обучаем полную сеть предсказывать метку «1» для произвольного входного вектора.



Вопрос: зачем замораживать веса дискриминатора?

Функция потерь может быть получена из формулы бинарной перекрёстной энтропии:

$$L(\hat{y}, y) = y \cdot \ln \hat{y} + (1 - y) \cdot \ln(1 - \hat{y})$$

При обучении дискриминатора на настоящих данных  $y = 1, \hat{y} = D(x)$ , следовательно:

$$L(\hat{y}, y) = L(D(x), 1) = \ln D(x)$$

При обучении дискриминатора на изображениях, созданных генератором  $y = 0, \hat{y} = D(G(z))$ :

$$L(\hat{y}, y) = L(D(G(z)), 0) = \ln(1 - D(G(z)))$$

Цель дискриминатора – правильно классифицировать настоящий и поддельный набор данных, для этого значения функции должны быть максимизированы, а окончательная функция потерь будет выглядеть так:

$$L^{(D)} = \max \left[ \ln D(x) + \ln \left( 1 - D(G(z)) \right) \right]$$

Генератор постоянно борется с дискриминатором и пытается минимизировать уравнение:

$$L^{(G)} = \min \left[ \ln D(x) + \ln \left( 1 - D(G(z)) \right) \right]$$

Оба уравнения можно объединить в одно:

$$L = \min_G \max_D \left[ \ln D(x) + \ln \left( 1 - D(G(z)) \right) \right]$$

В реальности используют две разных функции:

$$L_{discriminator} = \ln D(x) + \ln \left( 1 - D(G(z)) \right)$$

$$L_{generator} = \ln \left( D(G(z)) \right)$$

**for** количество\_итераций **do**

сгенерировать набор из  $m$  случайных векторов  $\{z_1, z_2, \dots, z_m\}$

выбрать  $m$  настоящих изображений  $\{x_1, x_2, \dots, x_m\}$

обновить веса дискриминатора в сторону возрастания градиента:

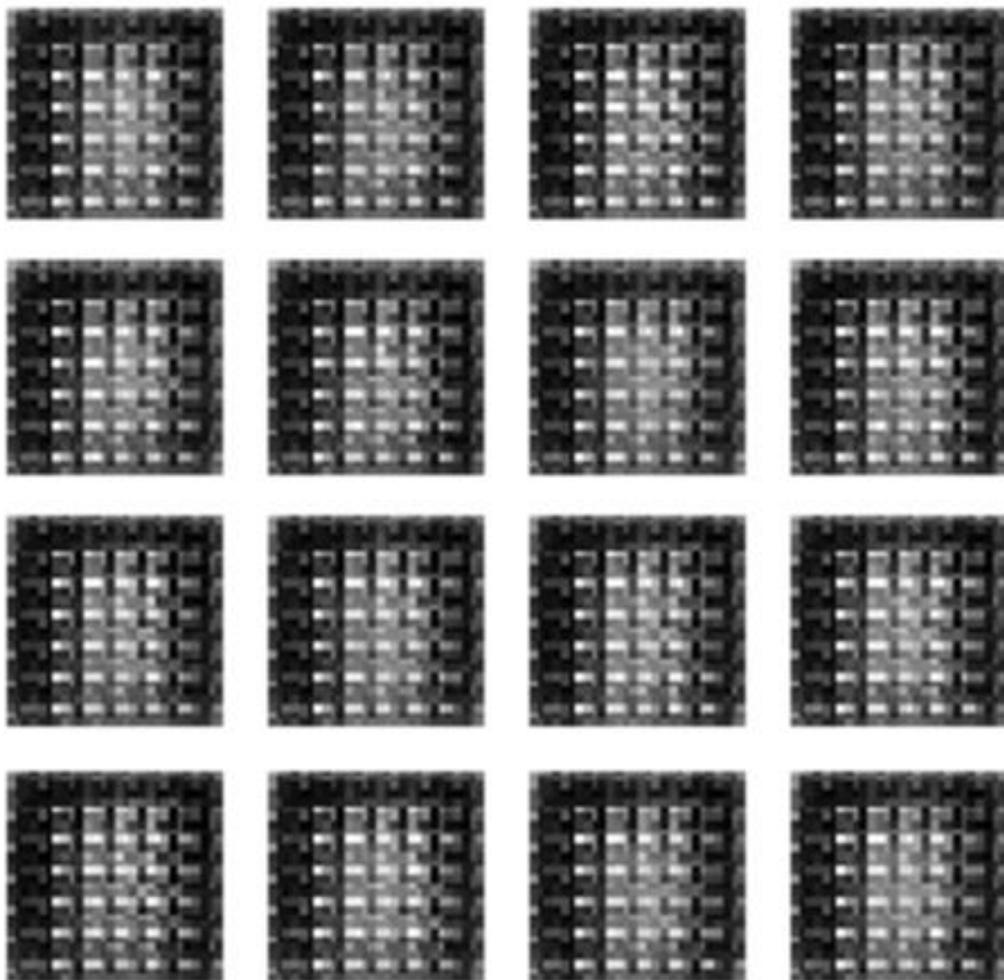
$$\nabla_{\theta_d} \frac{1}{m} \sum_{i=1}^m \left[ \ln D(x^{(i)}) + \ln \left( 1 - D(G(z^{(i)})) \right) \right]$$

сгенерировать набор из  $m$  случайных векторов  $\{z_1, z_2, \dots, z_m\}$

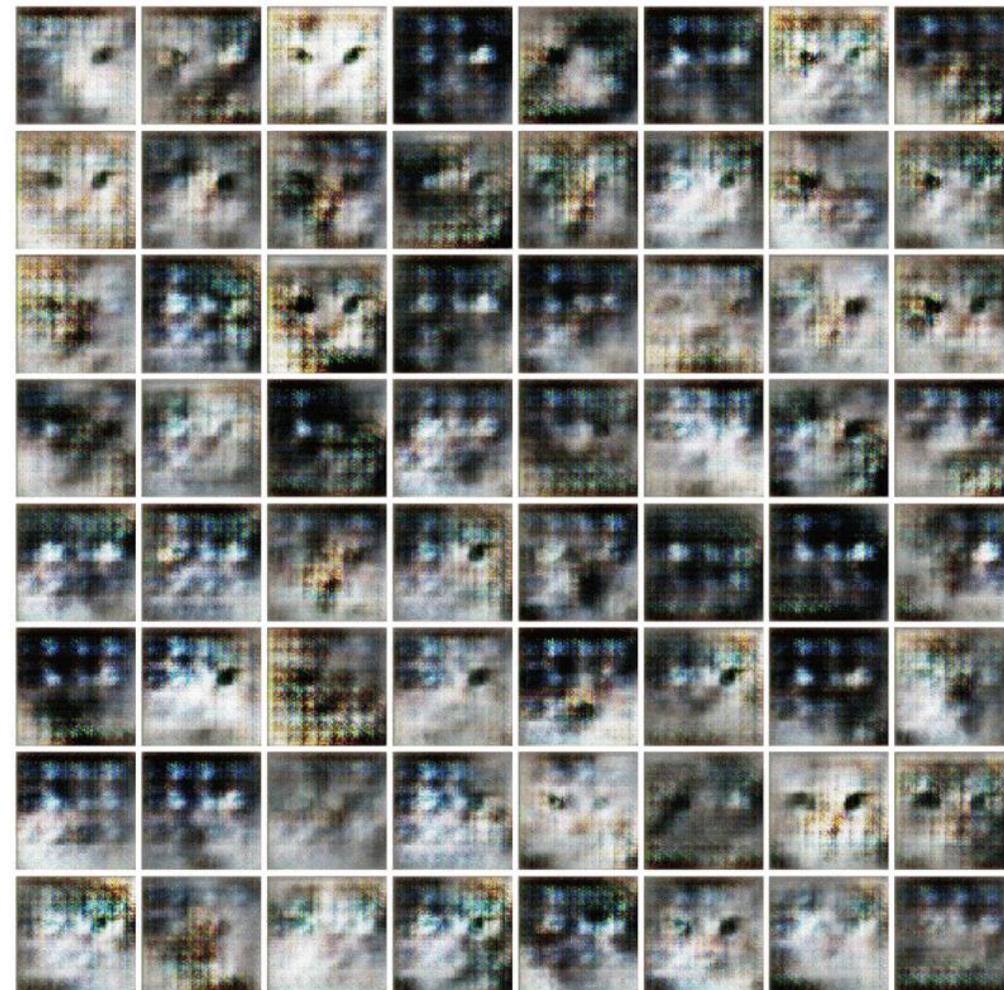
обновить веса дискриминатора в сторону уменьшения градиента:

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

**end for**



Обучение на наборе данных MNIST (.gif)



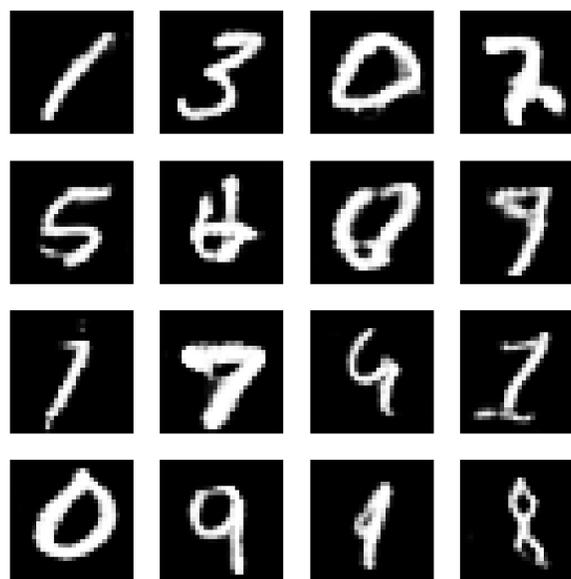
Обучение на наборе данных Cat faces (.gif)

Для качественной оценки изображений, созданных генератором, можно использовать следующие характеристики:

- сходство с изображениями обучающей выборки;
- отсутствие дубликатов из обучающей выборки;
- разнообразие изображений;
- отсутствие артефактов;



Низкое качество



Высокое качество



Обучающие данные

Frechet Inception Distance score (FID) – метрика, позволяющая оценить, насколько похожи два набора изображений между собой.

$$FID = \|\mu_r - \mu_g\|^2 + Tr\left(\Sigma_r + \Sigma_g - 2(\Sigma_r \Sigma_g)^{\frac{1}{2}}\right)$$

В качестве значений  $r$  и  $g$  используется результат работы сети InceptionV3 без последнего (классифицирующего) слоя:

$$r = \text{InceptionV}_3(x_{real})$$

$$g = \text{InceptionV}_3(x_{gen})$$

Вопрос: при каких значения FID модель лучше?

Frechet Inception Distance score (FID) – метрика, позволяющая оценить, насколько похожи два набора изображений между собой.

$$FID = \|\mu_r - \mu_g\|^2 + Tr\left(\Sigma_r + \Sigma_g - 2(\Sigma_r \Sigma_g)^{\frac{1}{2}}\right)$$

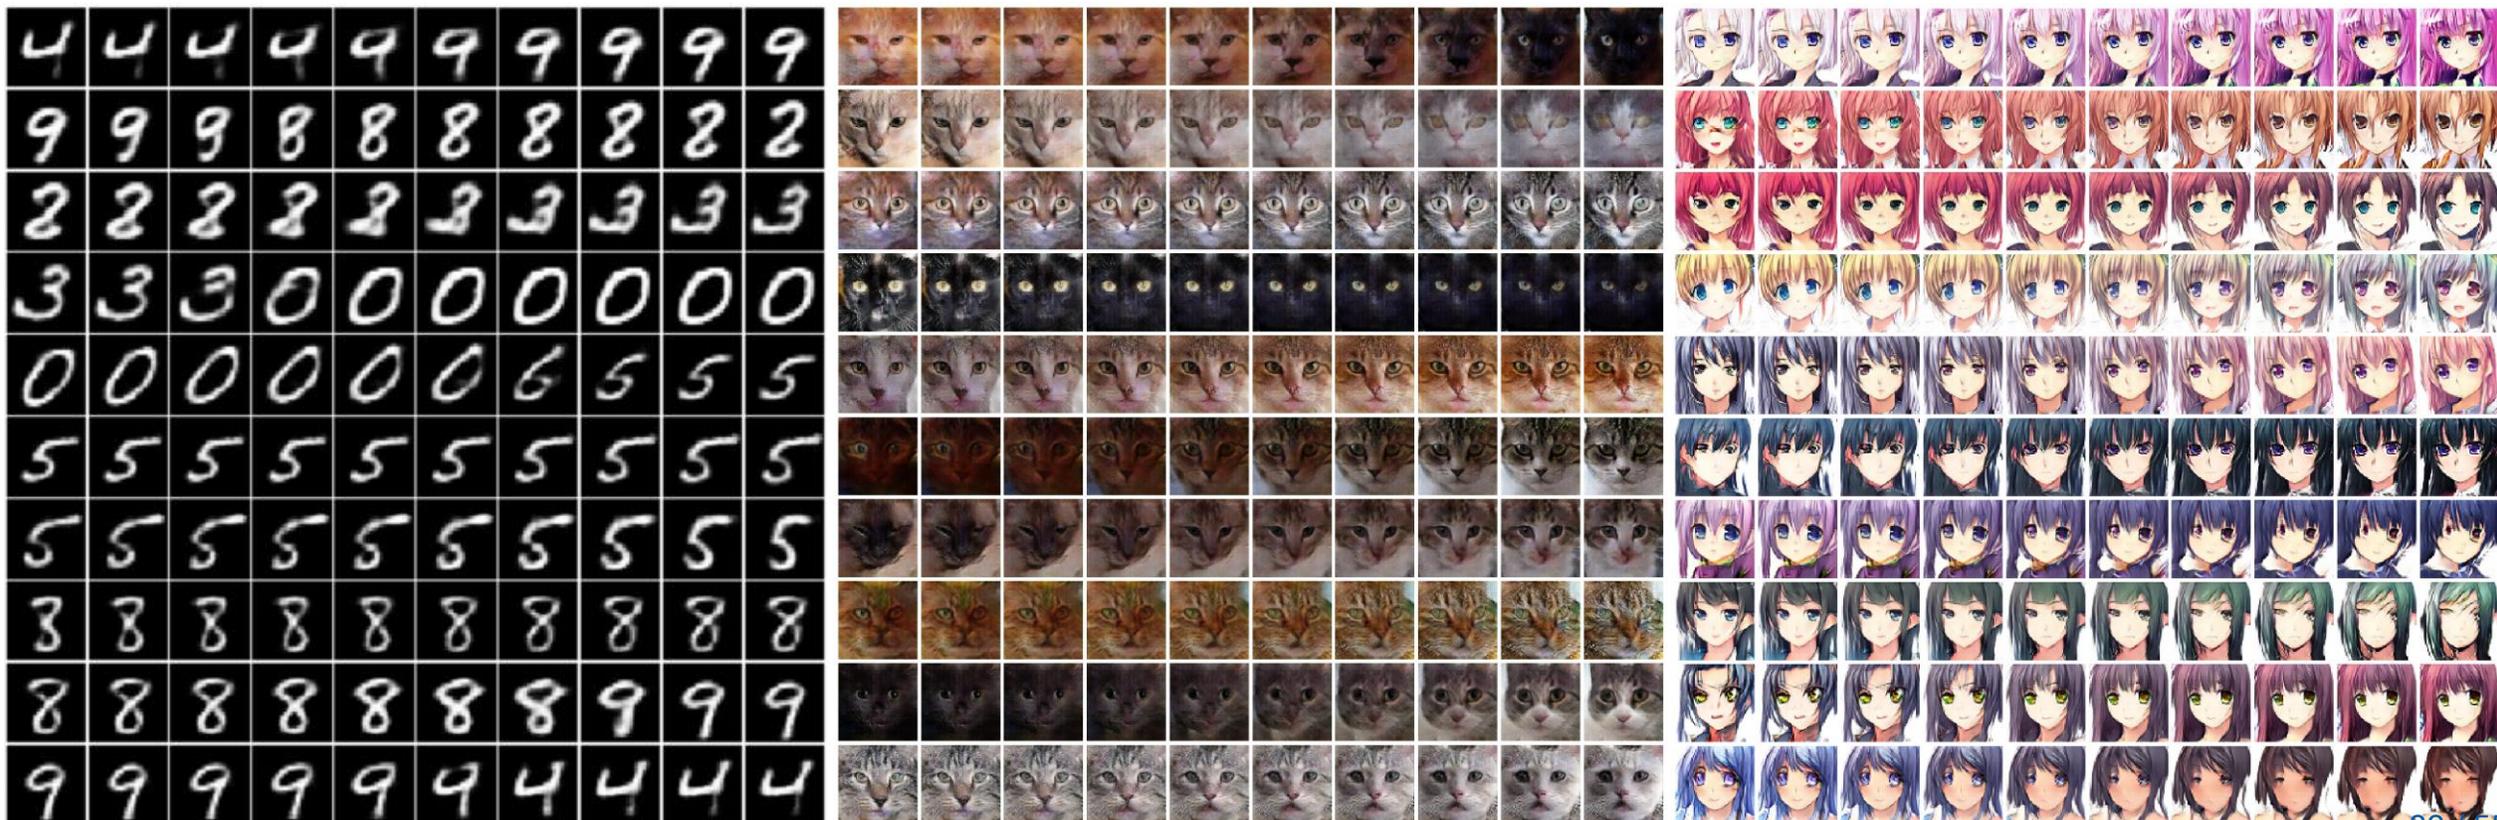
В качестве значений  $r$  и  $g$  используется результат работы сети InceptionV3 без последнего (классифицирующего) слоя:

$$r = InceptionV_3(x_{real})$$

$$g = InceptionV_3(x_{gen})$$

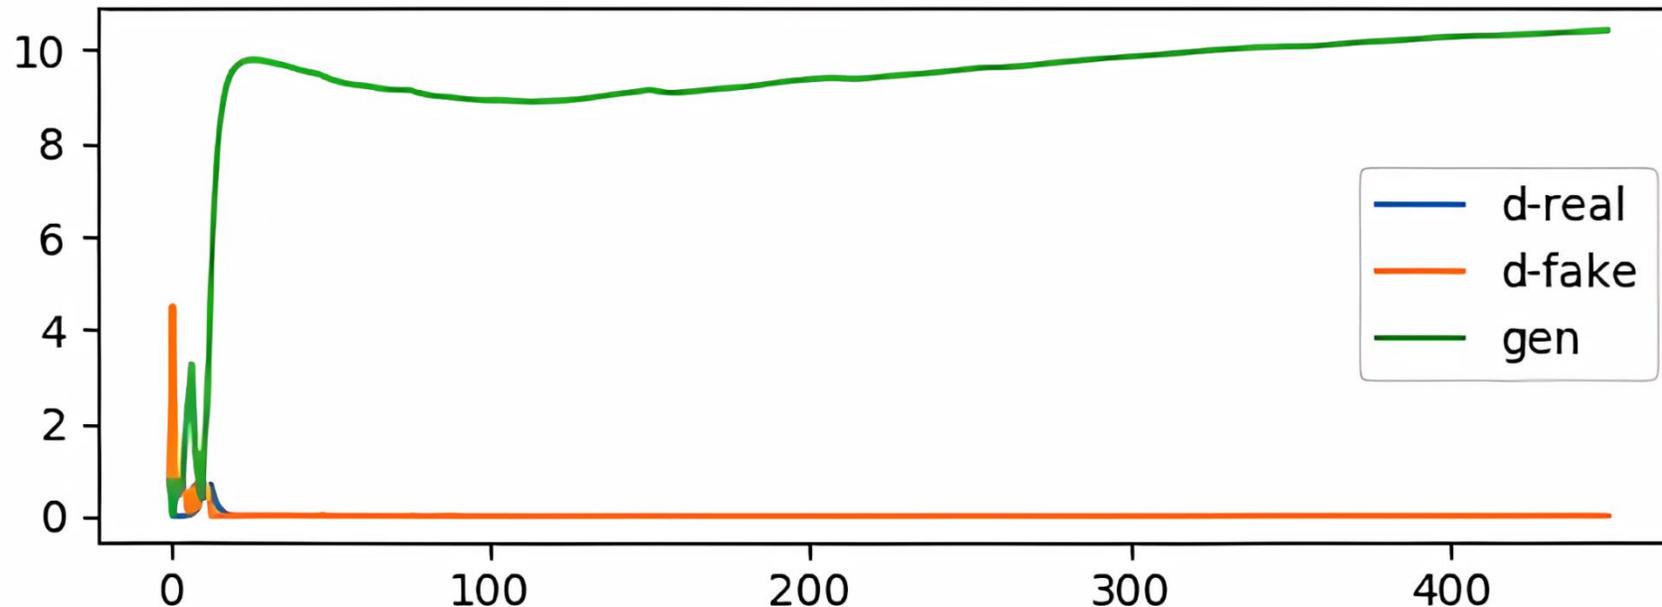
FID – расстояние, поэтому модель тем лучше, чем ниже значение метрики.

Выбирая два вектора ( $z_1$  и  $z_2$ ) в скрытом пространстве и выполняя линейную интерполяцию между ними, можно получить интерполяцию в пространстве изображений:  $z = t \cdot z_1 + (1 - t) \cdot z_2$ , где  $t \in [0, 1]$

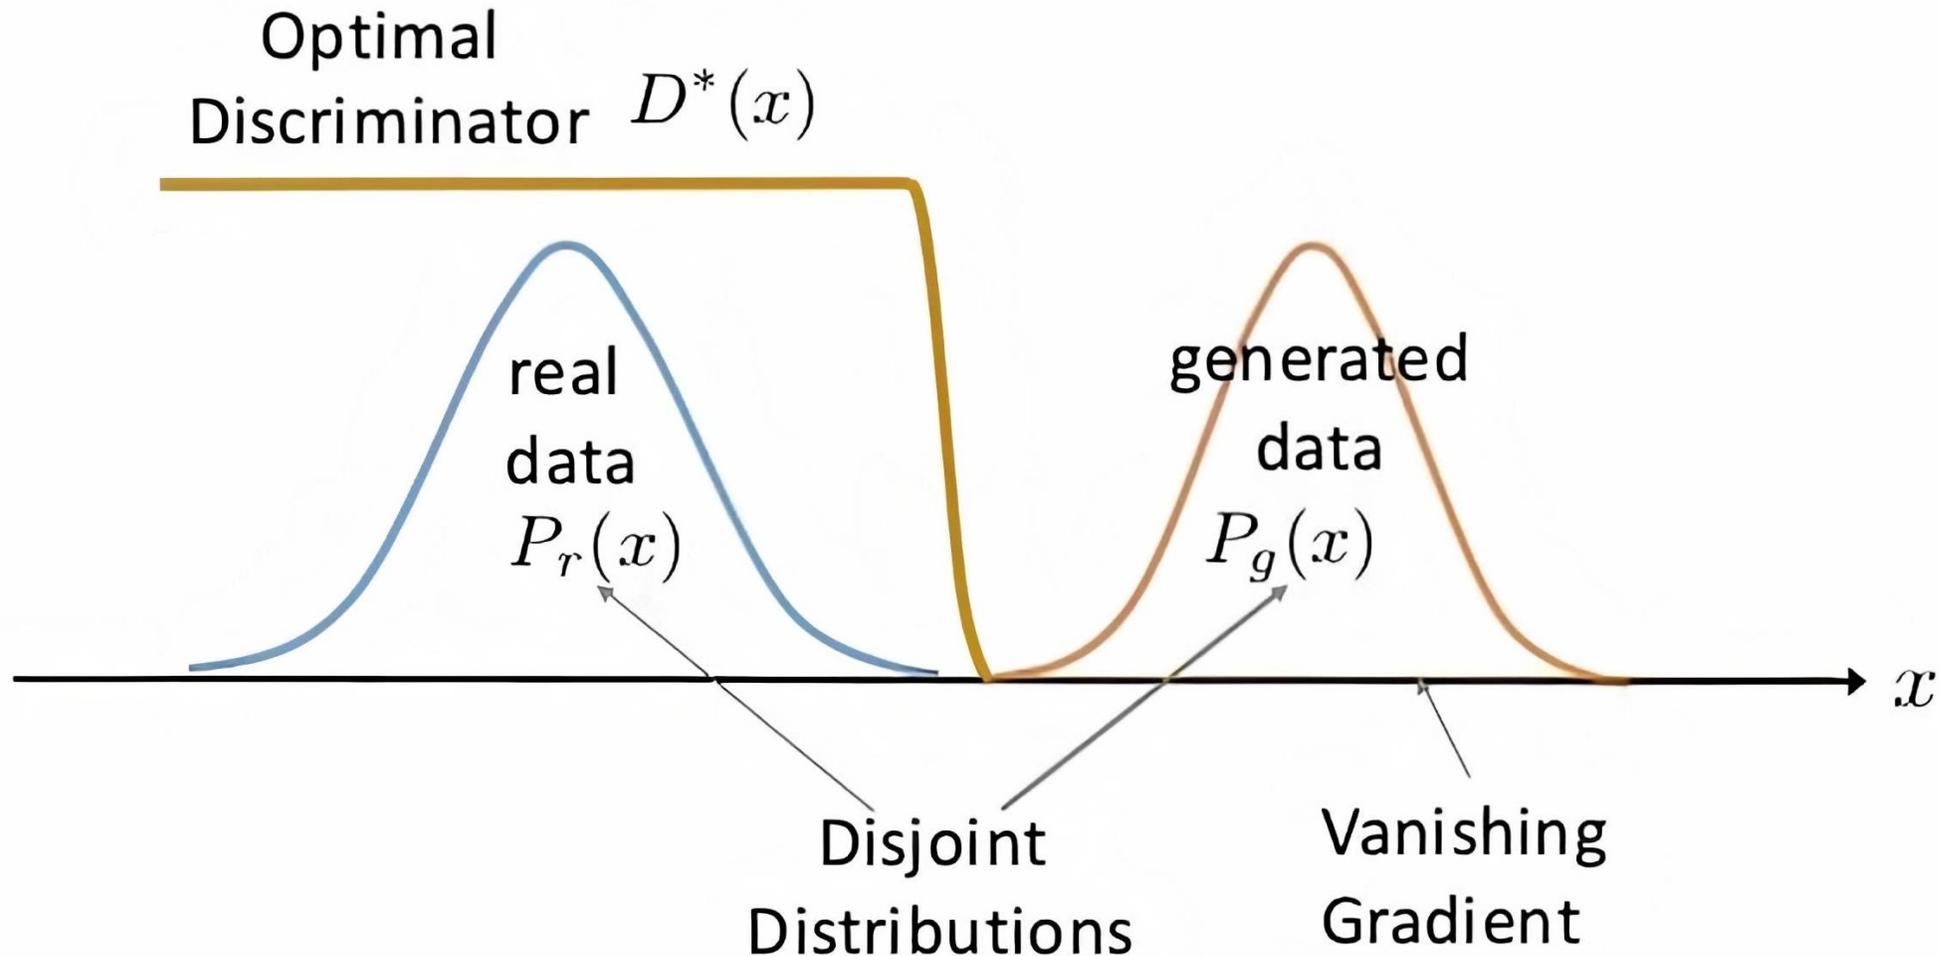


Если дискриминатор слишком хорош, то обучение генератора может не сработать из-за затухающих градиентов.

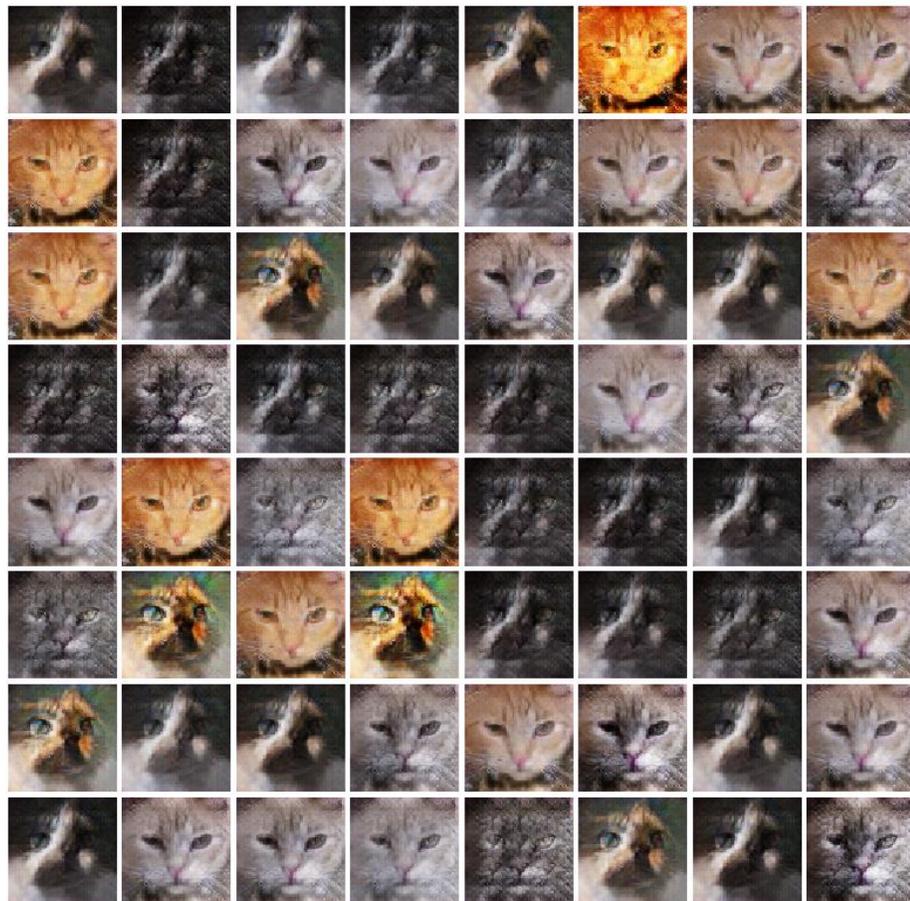
Оптимальный дискриминатор не предоставляет достаточно информации для работы генератора.



GAN'ы сложно обучать. Многие генеративно-сопоставительные модели вовсе не способны сойтись в приемлемую точку.



Режим работы GAN, при котором генератор выдаёт лишь сильно ограниченное количество изображений.



- нормализация входных данных (изображения в диапазоне  $[-1, 1]$ )
- $\tanh$  в качестве функции активации генератора;
- нормальное распределение вместо равномерного для шума;
- отдельные батчи для настоящих и сгенерированных изображений;
- использование слоёв батч-нормализации;
- использование LeakyReLU вместо ReLU;
- добавление шума в метки ( $[0, 0.3]$  и  $[0.7, 1.2]$  вместо 0 и 1)
- использование Adam со значением момента 0.5
- использование свёрточных слоёв с шагом  $> 1$  вместо макспулинга;

Автокодировщики

Вариационные автокодировщики

Wasserstein GAN (WGAN)

Progressive growing GAN (PROGAN)

Conditional GAN (CGAN)

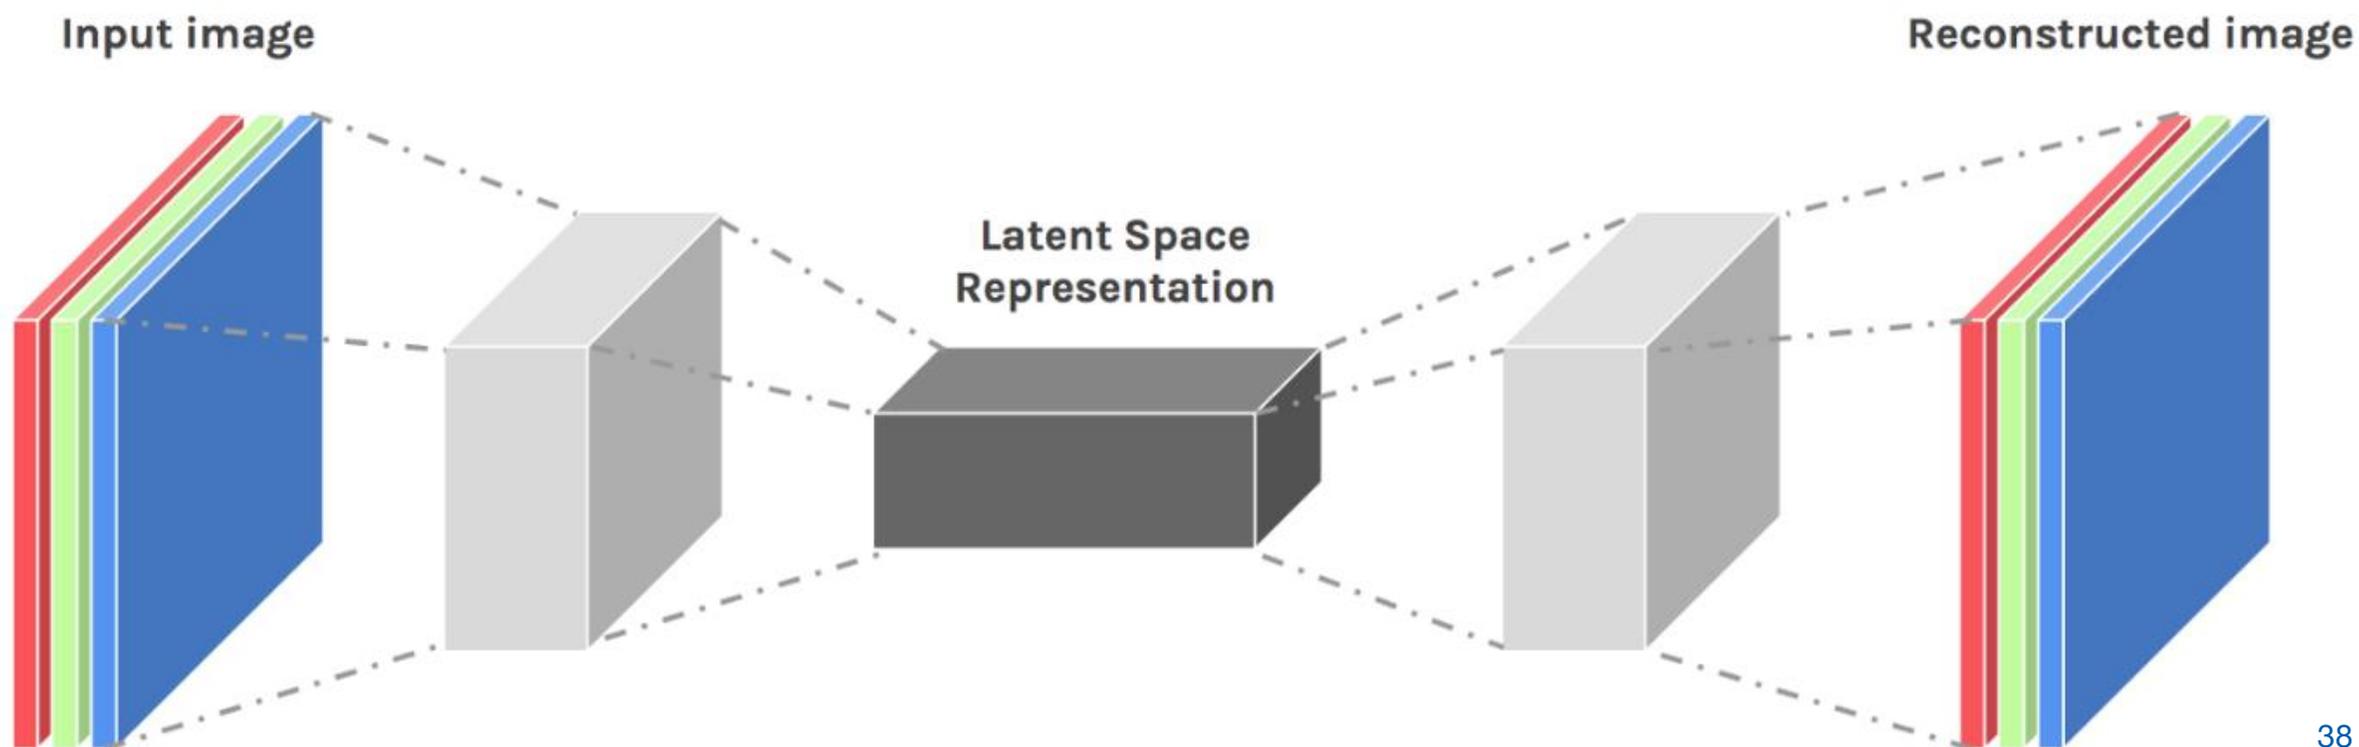
Pix2pix

Cycle GAN

Stack GAN

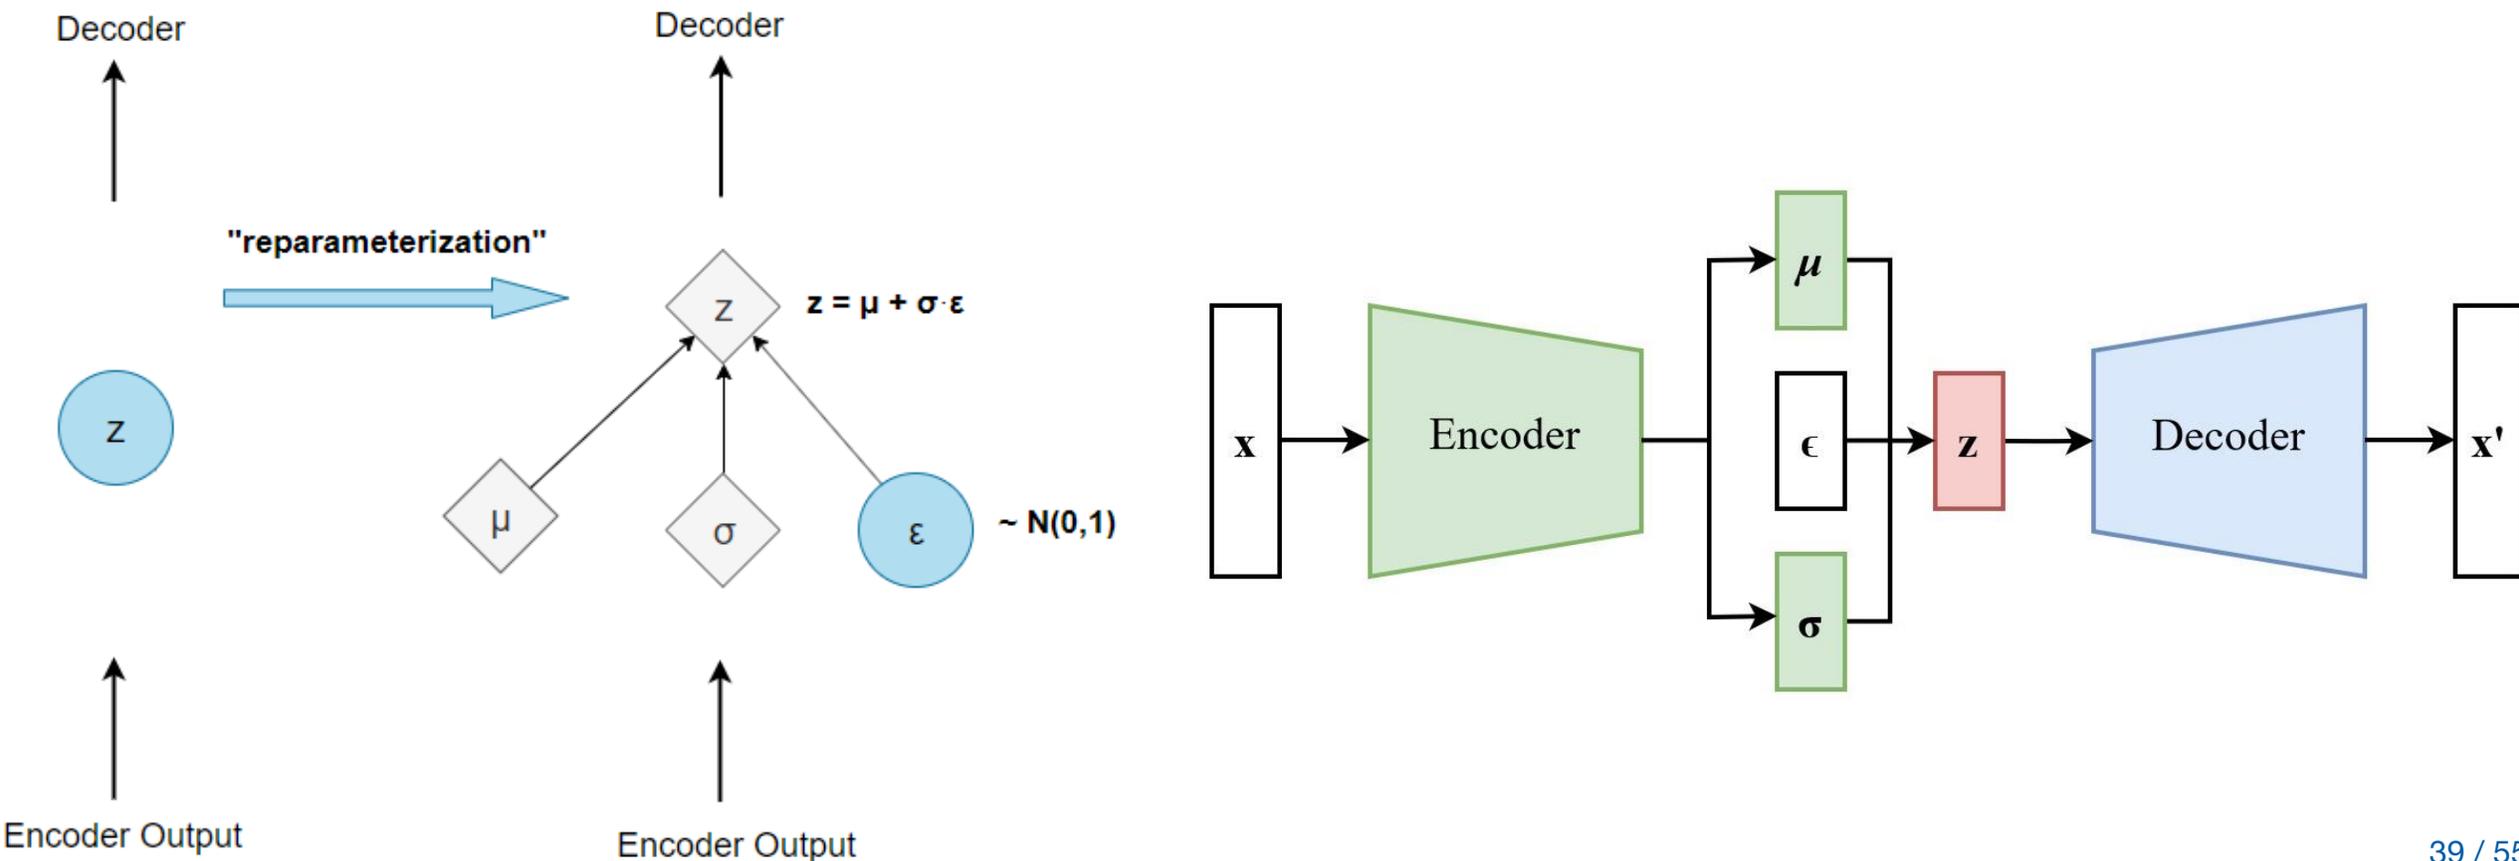
Super resolution GAN (SRGAN)

Автокодировщик (АЕ) – архитектура нейронной сети, состоящая из кодировщика и декодировщика. Принцип работы заключается в сжатии входного изображения в вектор малой размерности и восстановление исходного изображения из полученного вектора.

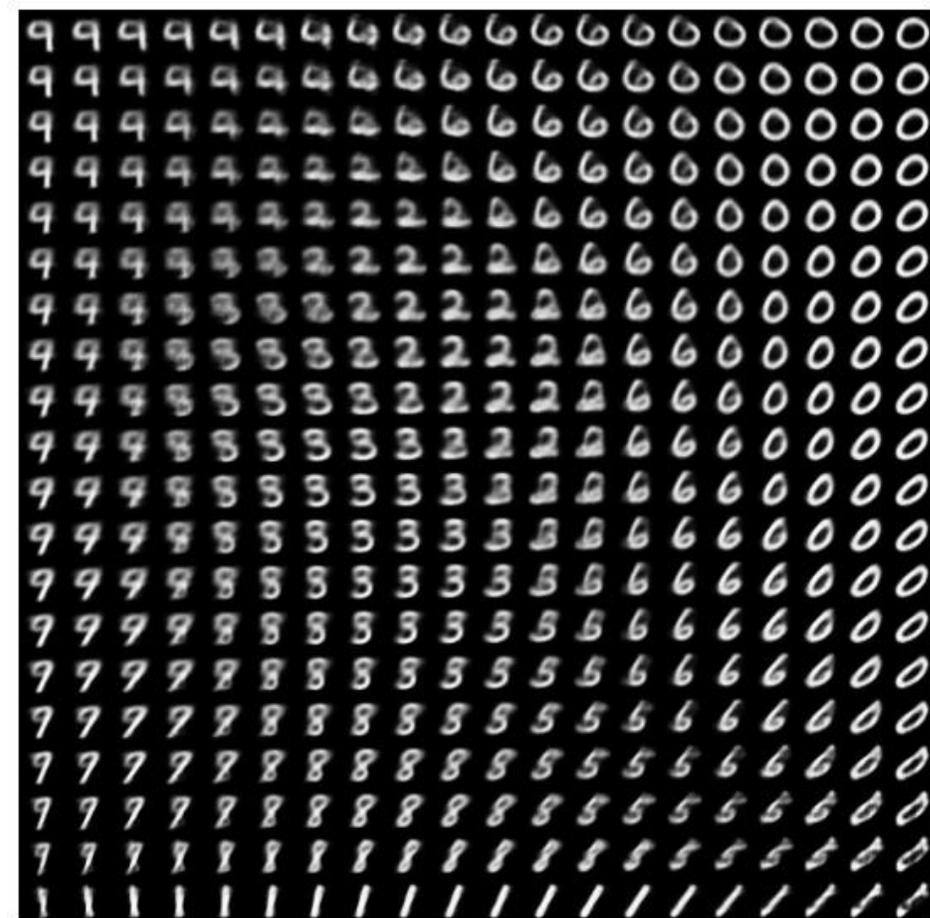


Улучшенная версия обычного автокодировщика.

Между выходом кодировщика и входом декодировщика добавляется слой репараметризации, который изменяет нормальное распределение, превращая его в распределение скрытого пространства.



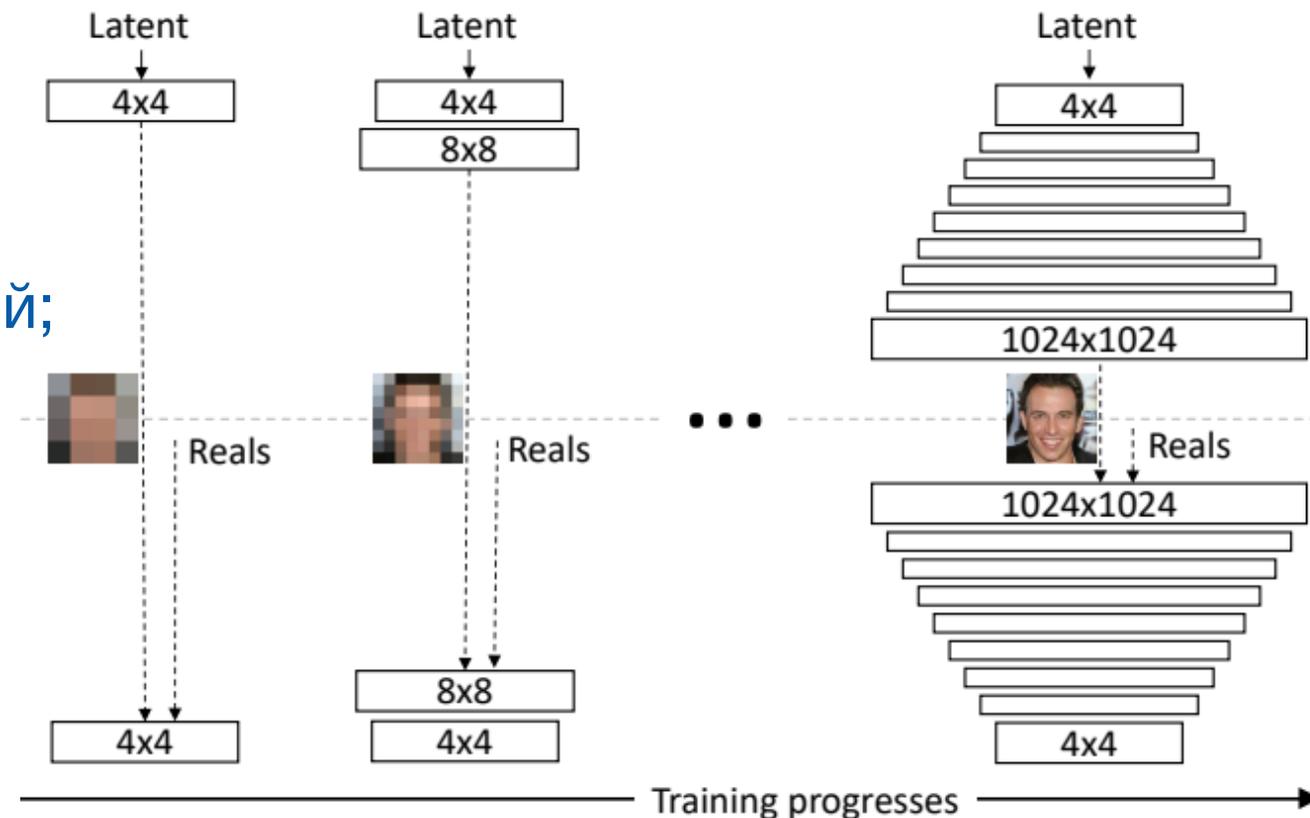
Изображения, получаемые на выходе вариационных автокодировщиков, зачастую сильно размыты и слабо отличаются от тренировочных примеров.

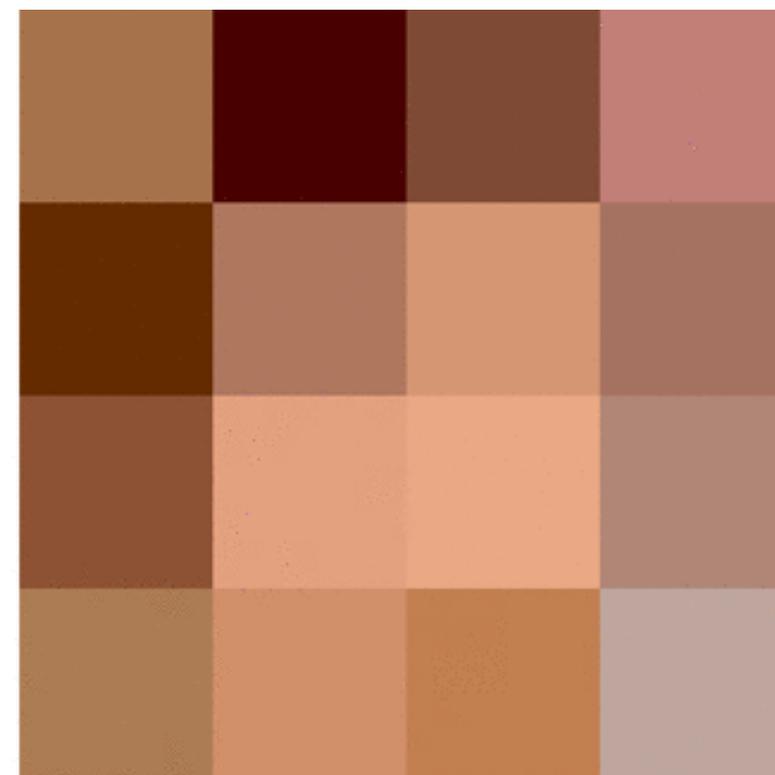
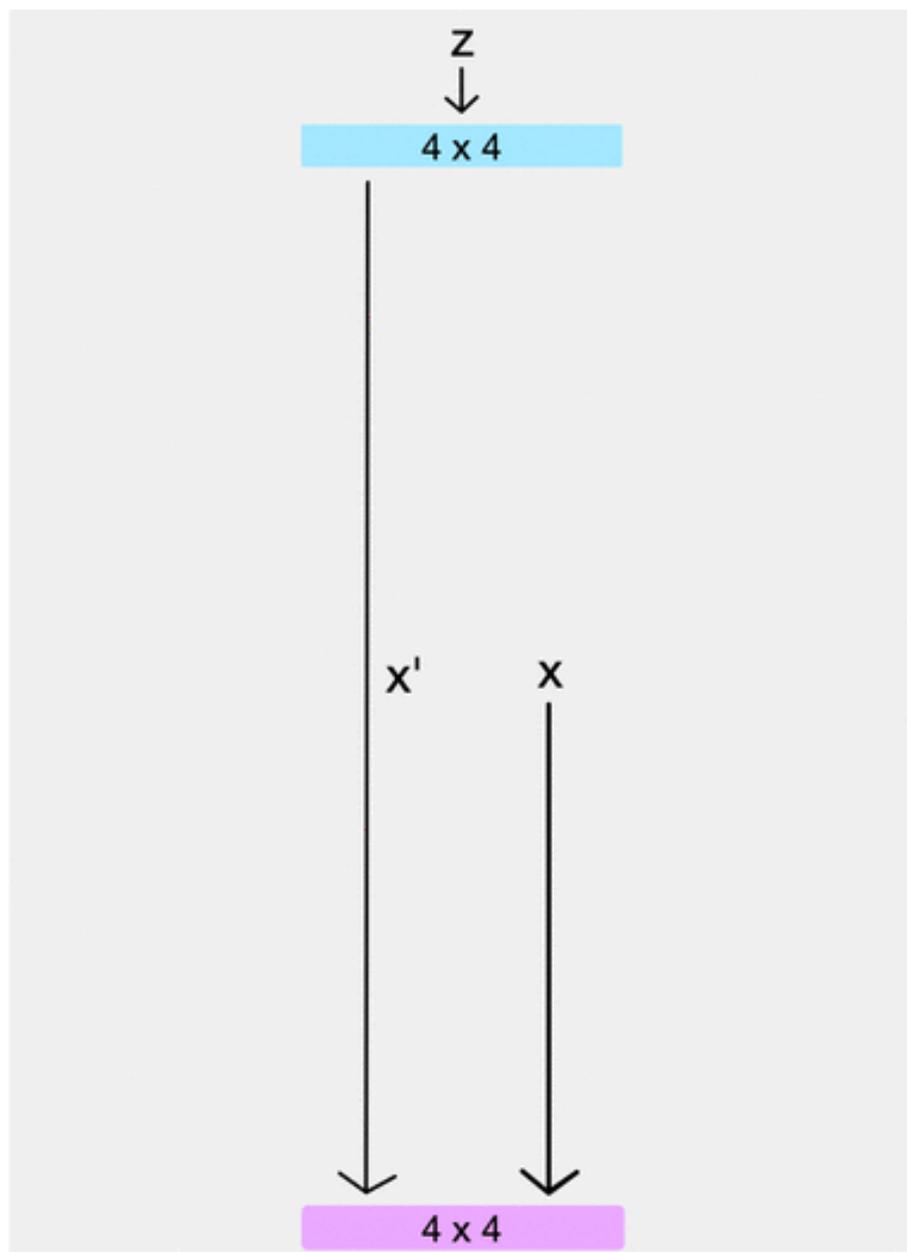


Прогрессивная генеративно состязательная сеть: во время обучения обе нейросети (генератор и дискриминатор) развиваются посредством добавления новых слоёв.

Основные плюсы:

- более реалистичные изображения;
- изображения в высоком качестве;
- большая вариативность изображений;
- легче и быстрее обучается;





Training time: 0 days  
4x4 resolution



Generator

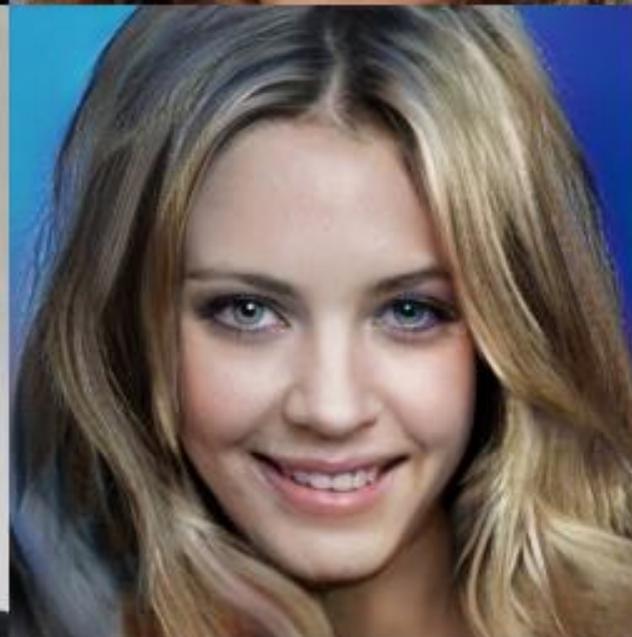
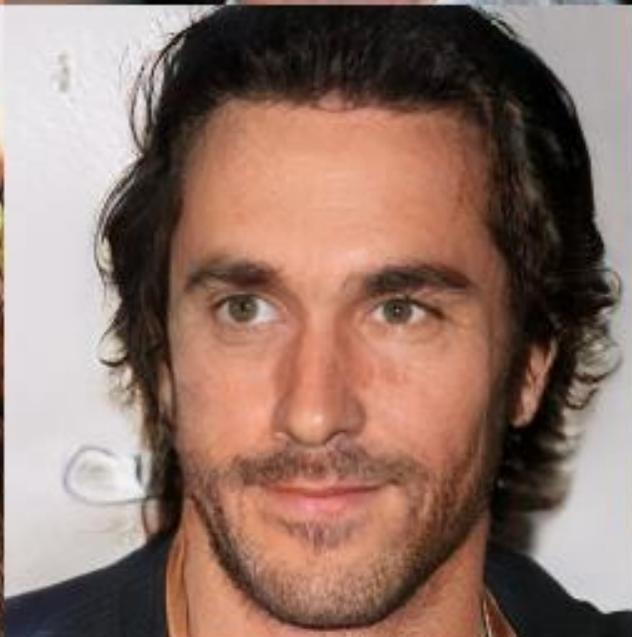
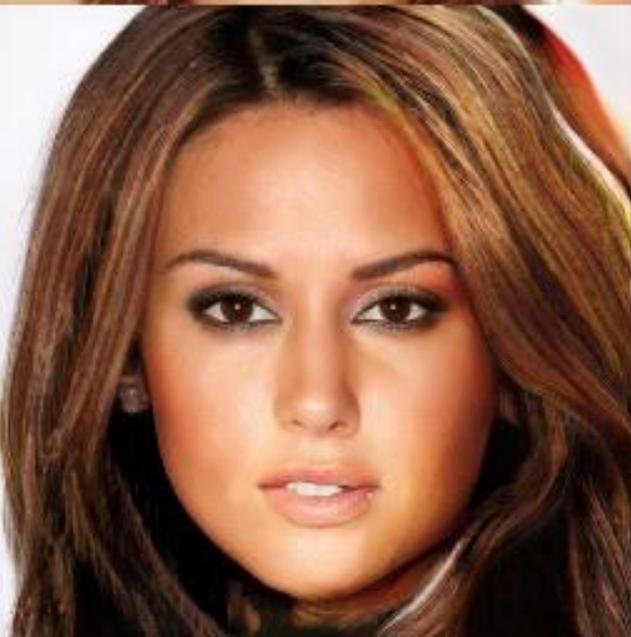


Discriminator

$z$  = random code

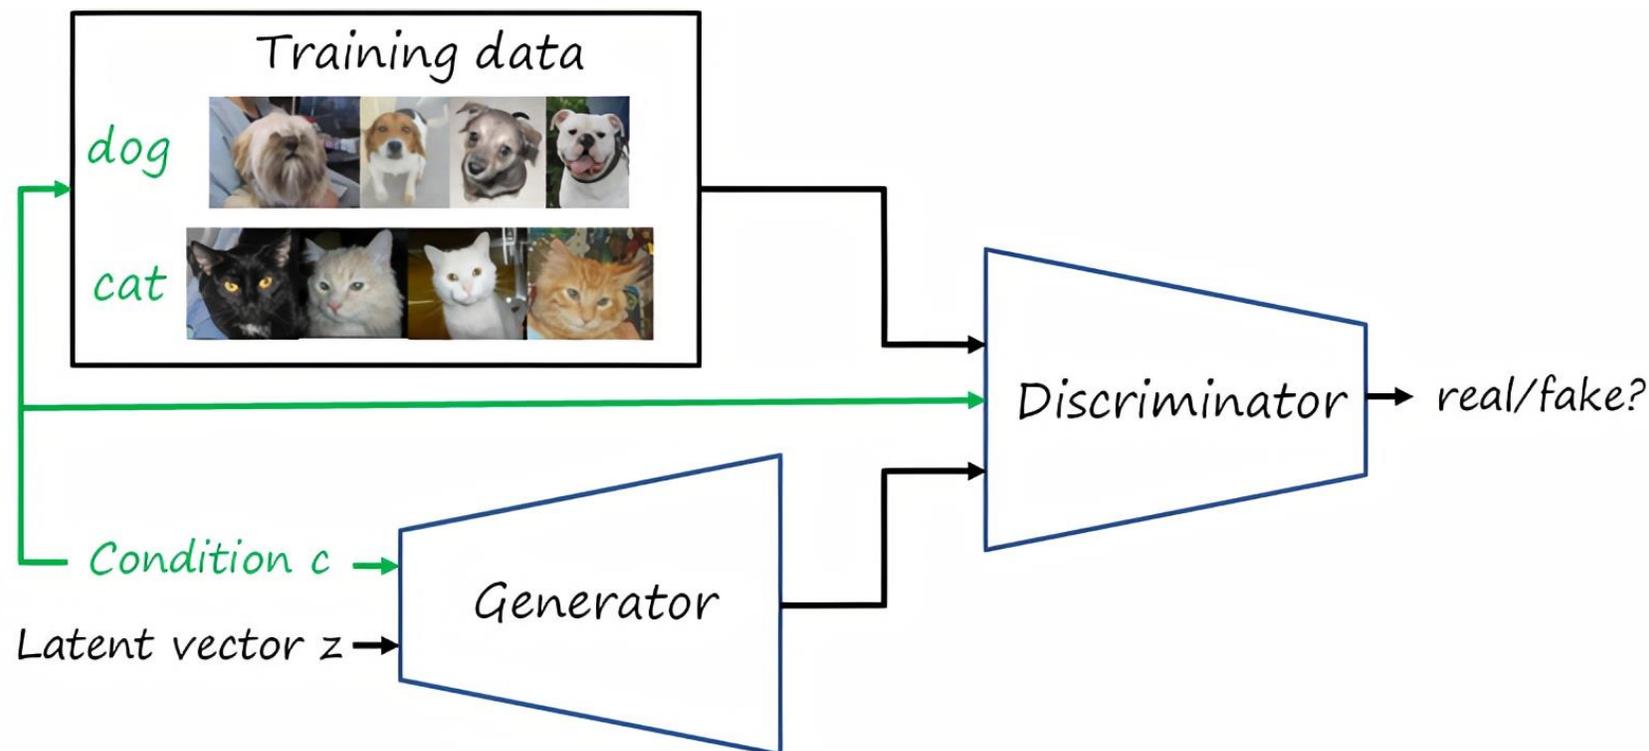
$x$  = real image

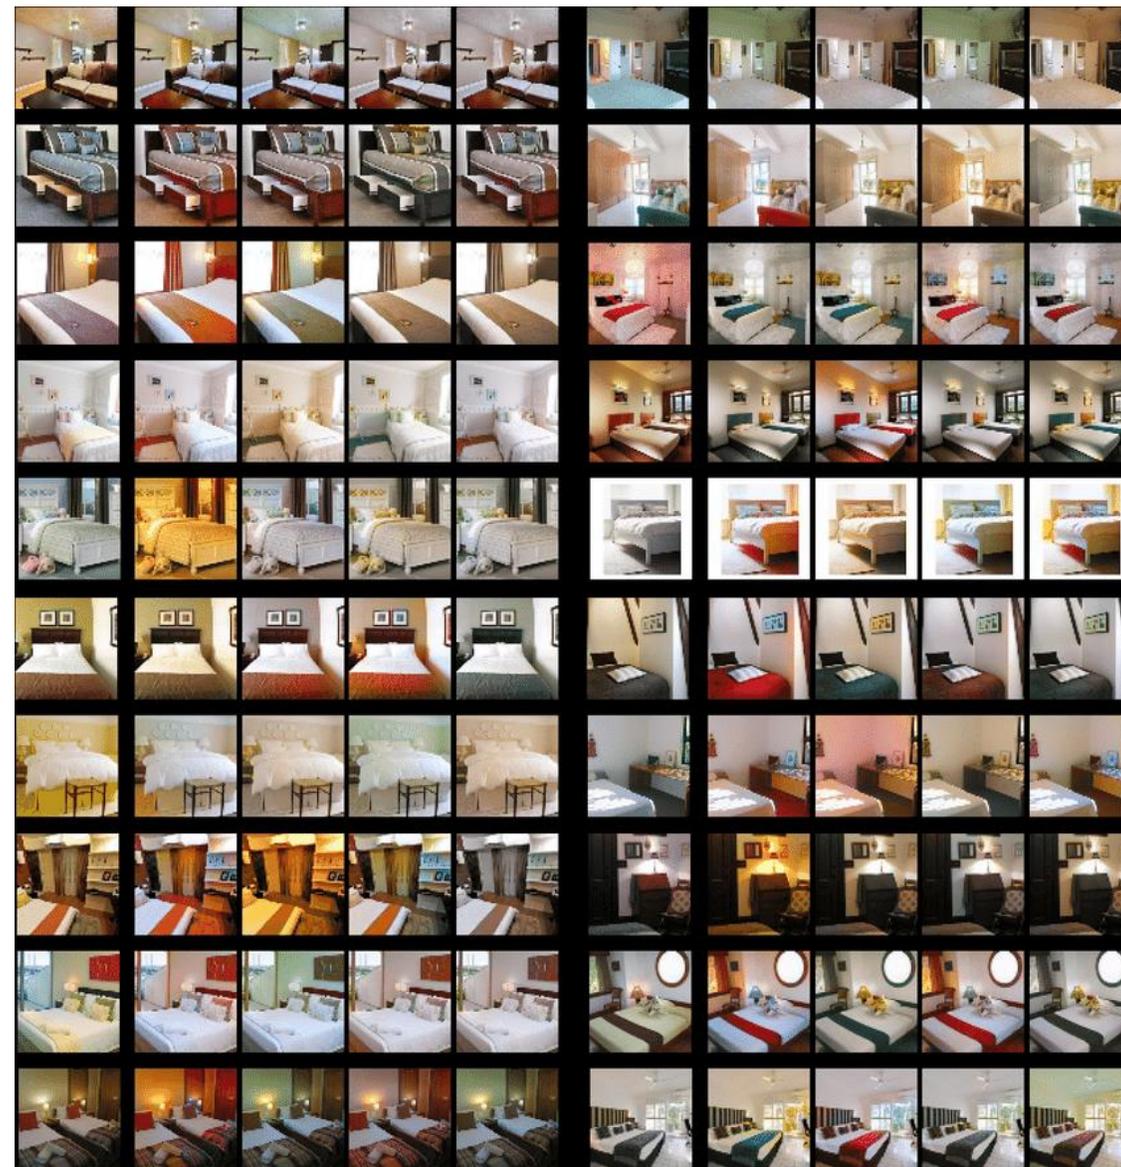
$x'$  = generated image



Условная генеративно-сопоставительная сеть – это обычная GAN, в которой помимо самих изображений используется информация об их классах.

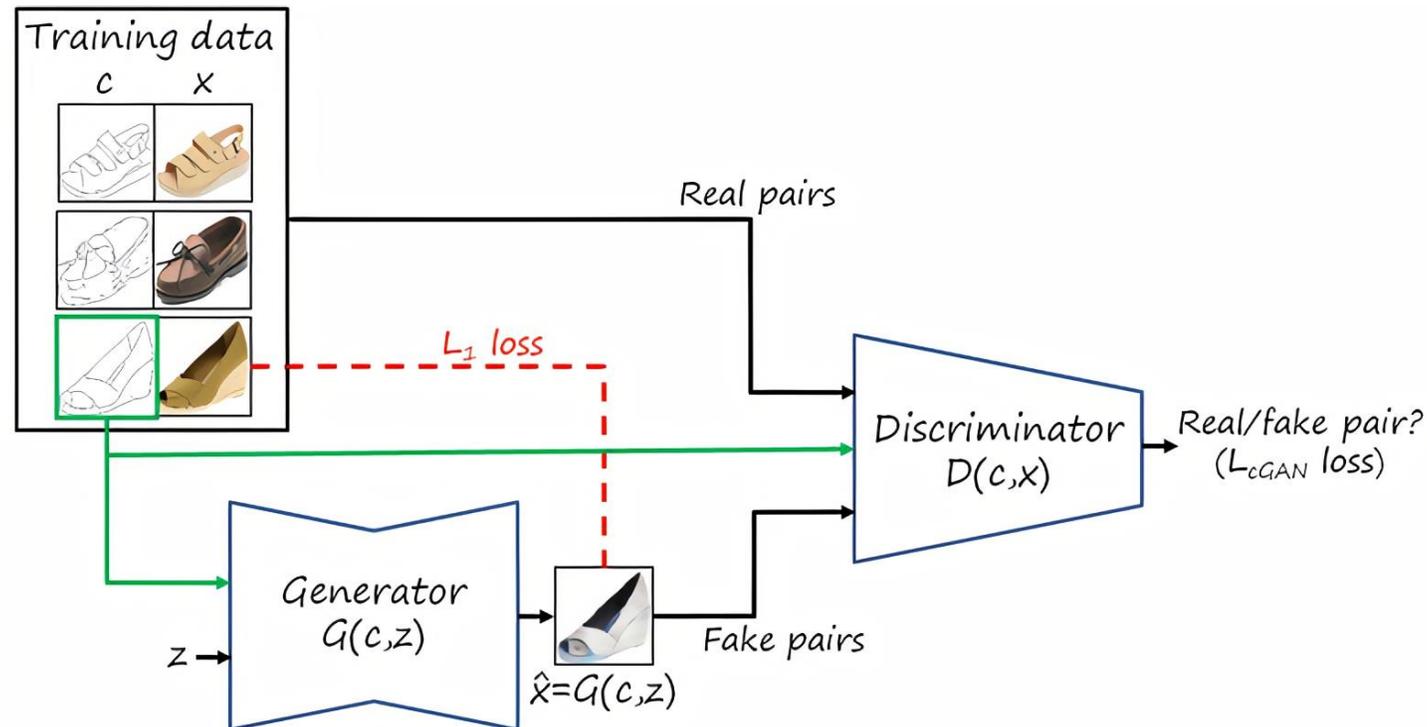
Подавая на вход генератора метку нужного класса, можно контролировать получаемые изображения.

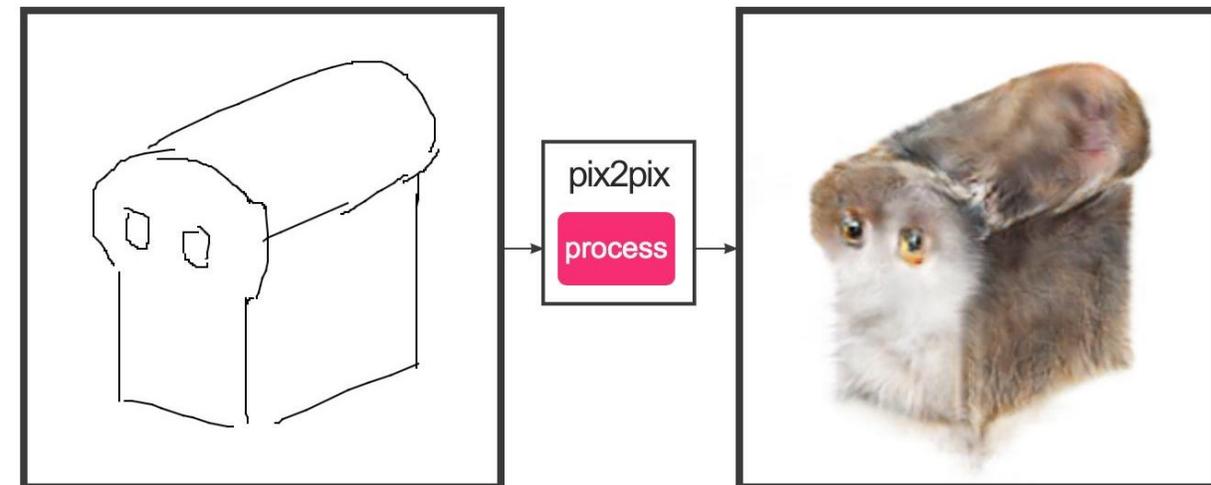
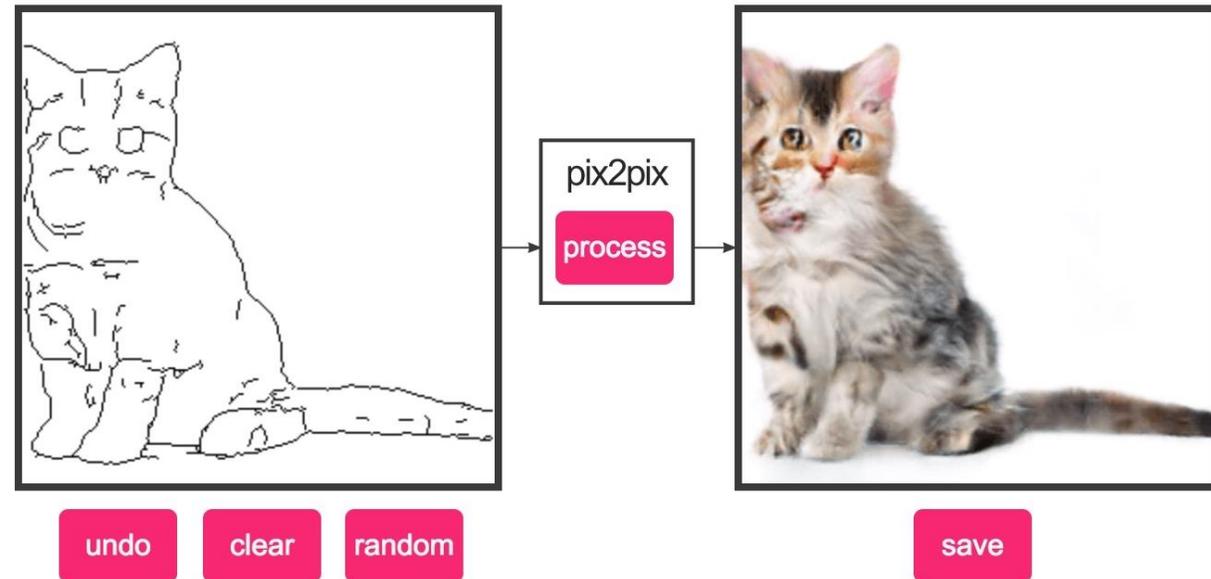
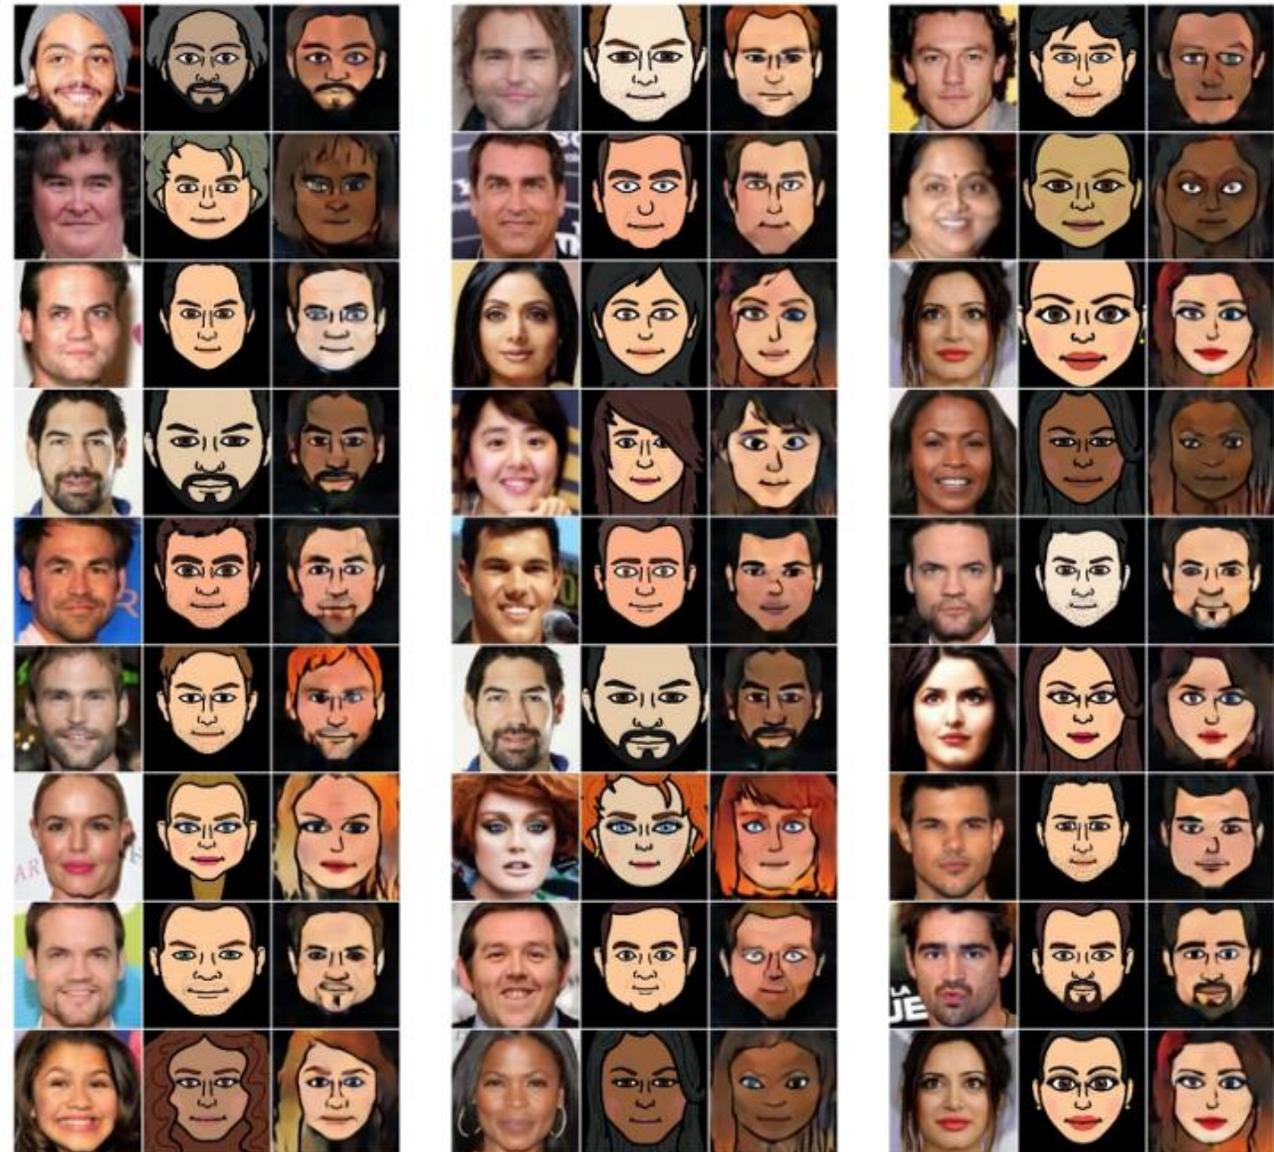




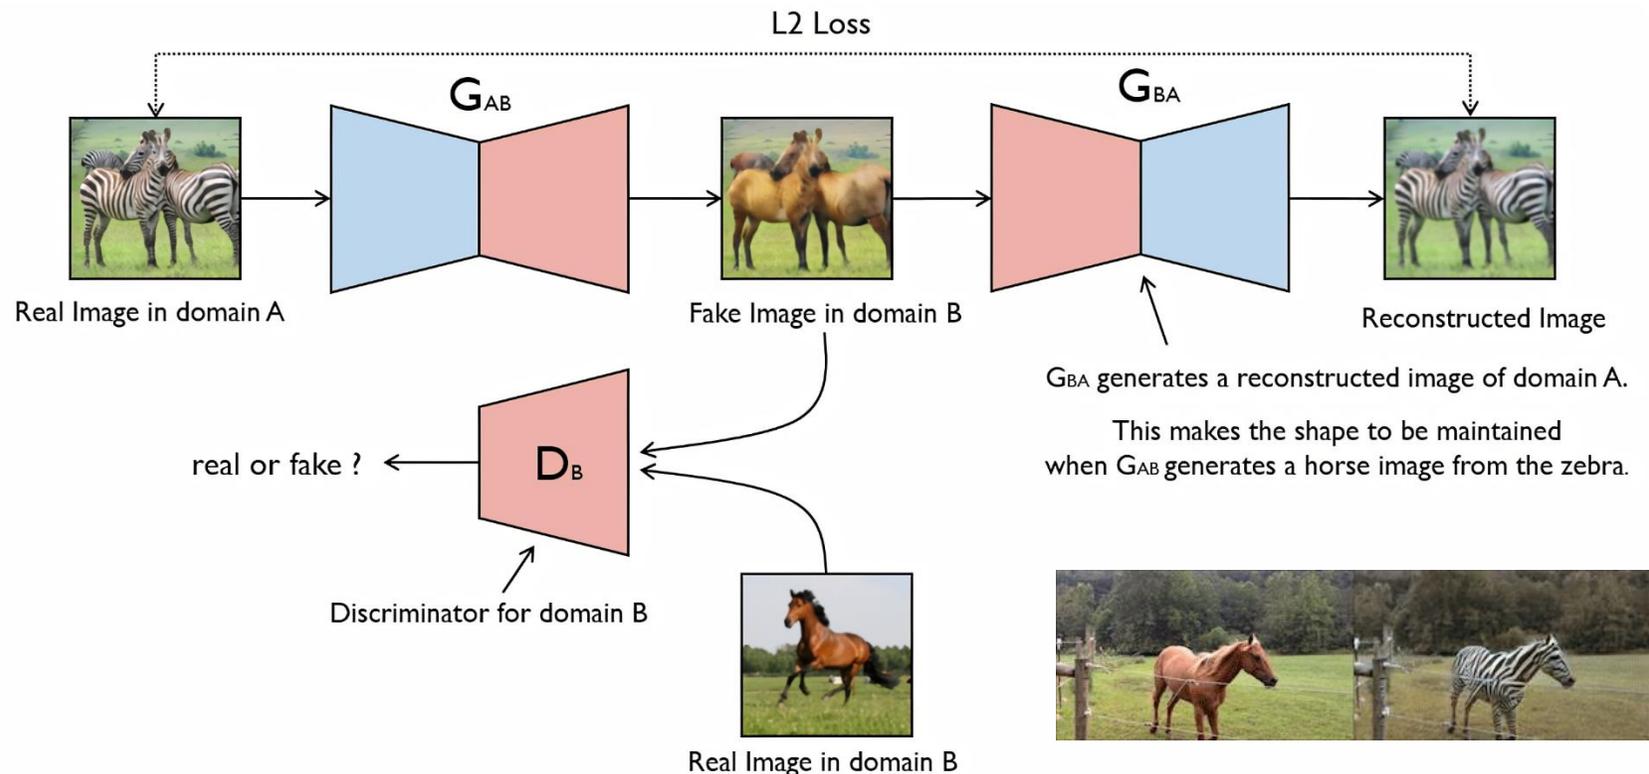
Генератору на вход дается изображение. На ее основе генератор должен сгенерировать картинку на выход.

Дискриминатор получает то же изображение и результат работы генератора и определяет, является ли сгенерированная картинка настоящей.





Содержит два генератора-автоэнкодера.  
Первый создаёт изображение в другом домене.  
Второй из полученного генерирует исходное изображение.  
Дискриминатор проверяет, похоже ли изображение, созданное первым генератором на настоящее, или нет.



Monet ↔ Photos



Monet → photo

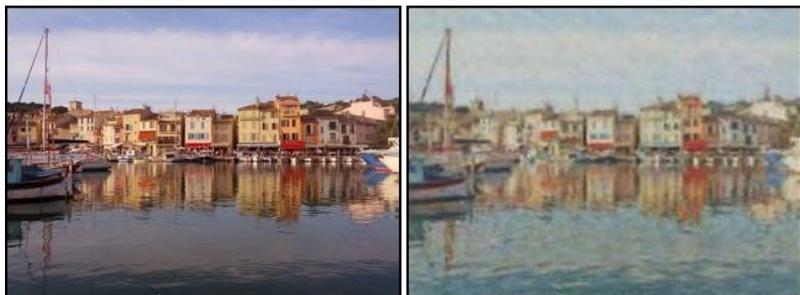


photo → Monet

Zebras ↔ Horses



zebra → horse



horse → zebra

Summer ↔ Winter



summer → winter



winter → summer



Photograph



Monet



Van Gogh

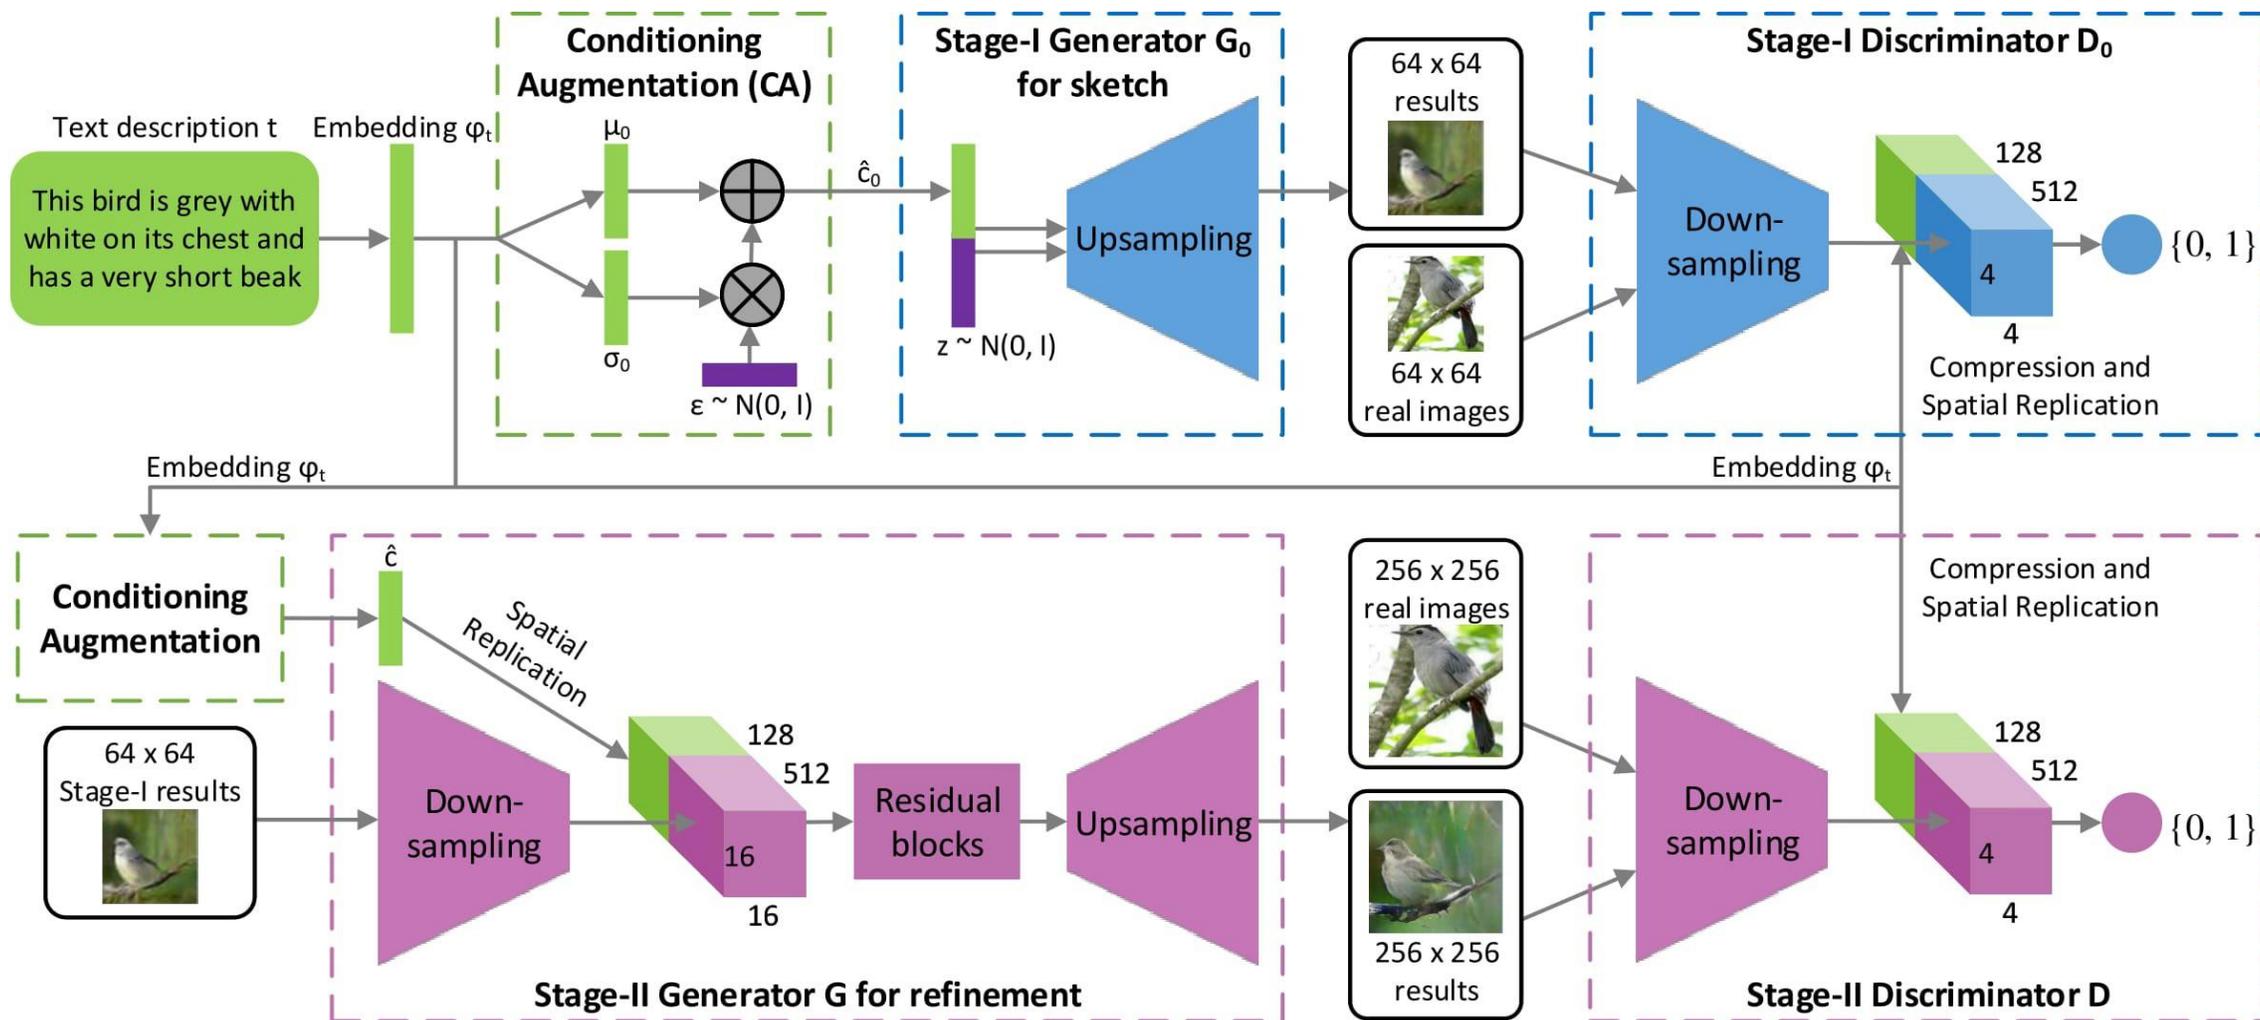


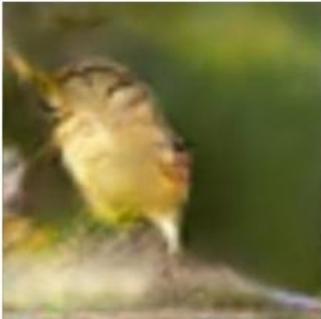
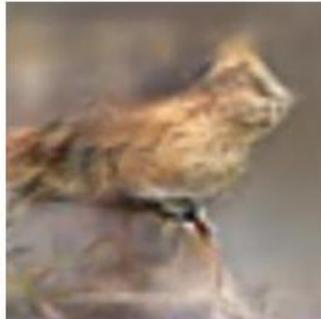
Cezanne



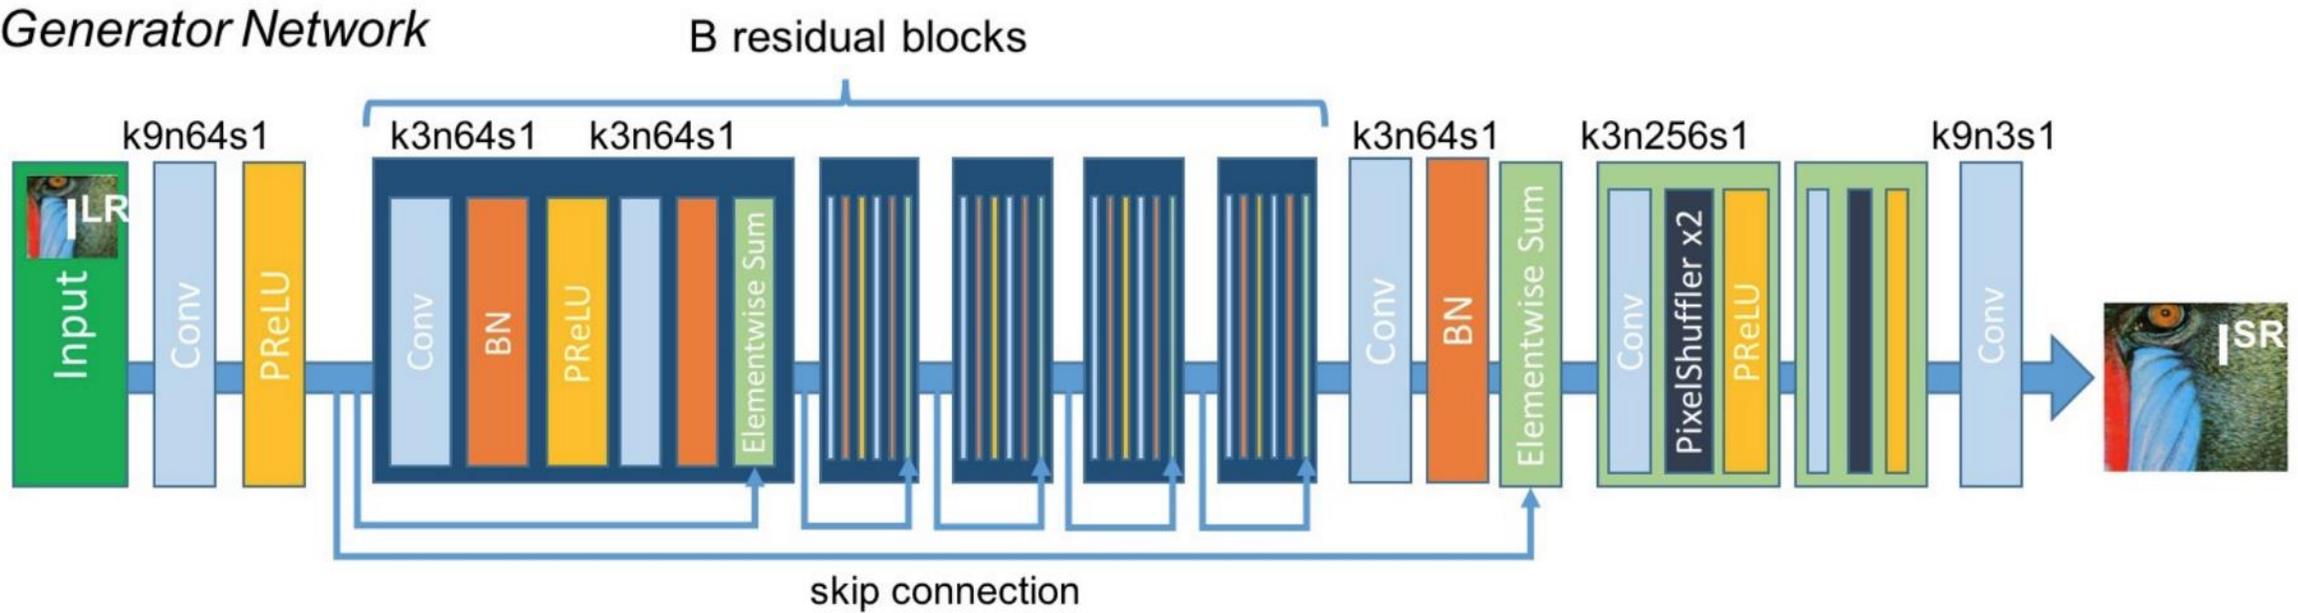
Ukiyo-e

Позволяет создавать фотореалистичные изображения по текстовому описанию.

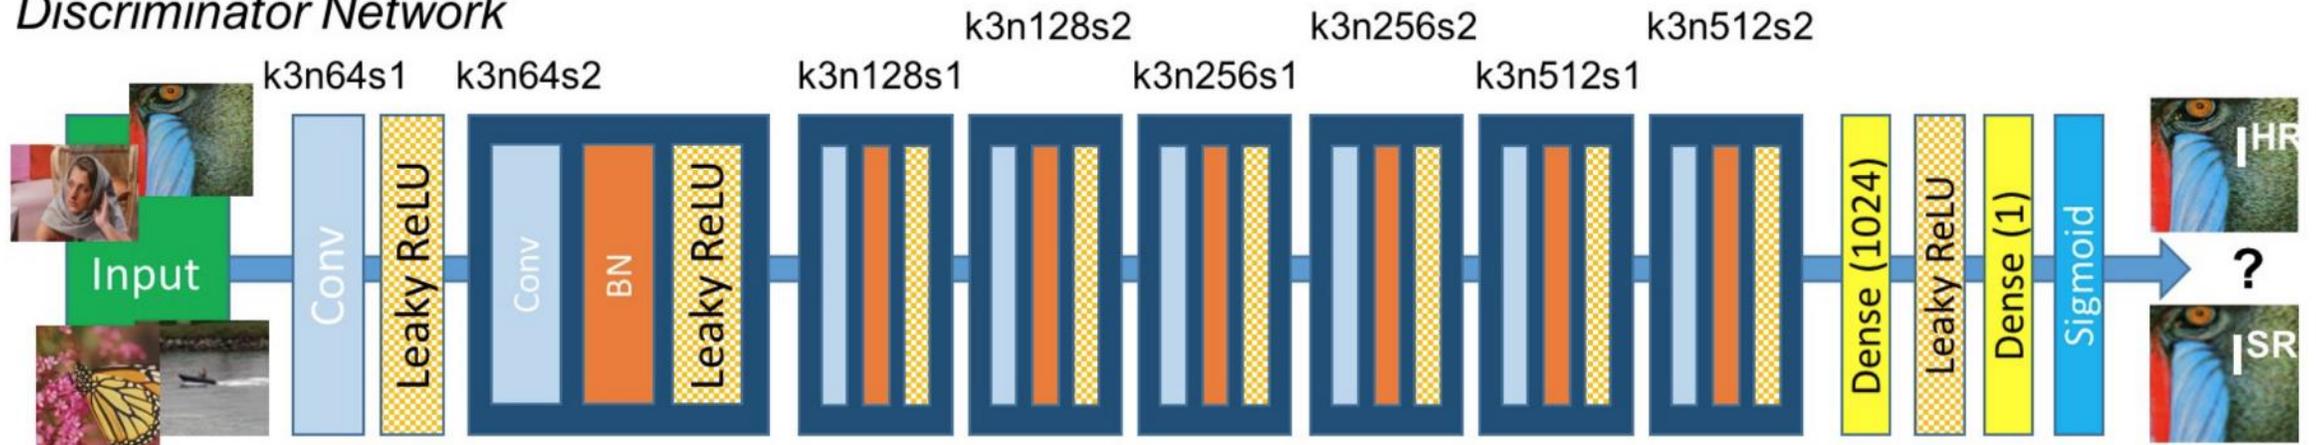


Text description	This bird is blue with white and has a very short beak	This bird has wings that are brown and has a yellow belly	A white bird with a black crown and yellow beak	This bird is white, black, and brown in color, with a brown beak	The bird has small beak, with reddish brown crown and gray belly	This is a small, black bird with a white breast and white on the wingbars.	This bird is white black and yellow in color, with a short black beak
Stage-I images							
Stage-II images							

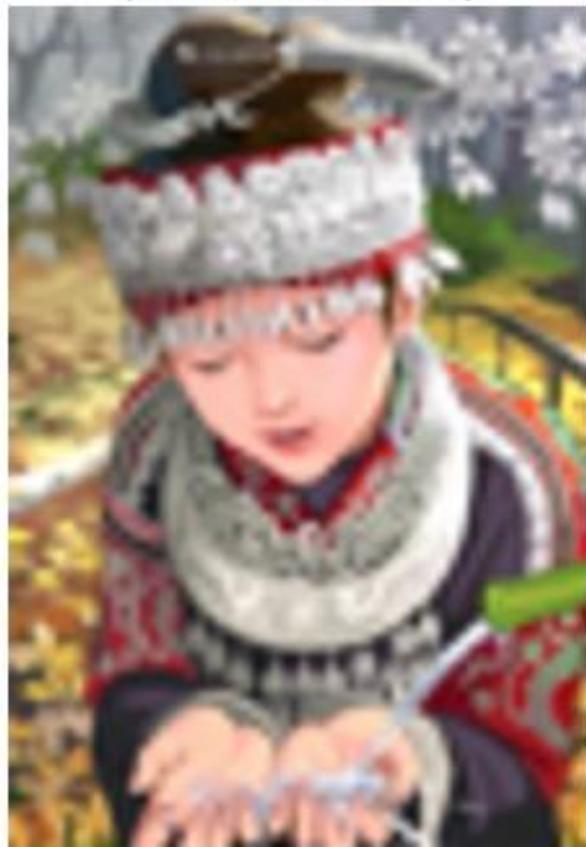
## Generator Network



## Discriminator Network



bicubic  
(21.59dB/0.6423)



SRResNet  
(23.53dB/0.7832)



SRGAN  
(21.15dB/0.6868)



original



- [GAN — What is Generative Adversarial Networks GAN](#)
- [Generative Adversarial Network \(GAN\) using Keras](#)
- [Deep Convolutional Generative Adversarial Network](#)
- [How to Train a GAN? Tips and tricks to make GANs work](#)
- [Генеративно-сопоставительная нейросеть. Руководство для новичков](#)
- [GAN loss functions](#) и [GAN problems](#)
- [Pix2pix: Как работает генератор кошечек](#)
- [Introduction to CGAN](#)
- [Implementing StackGAN using Keras](#)
- [GAN — Wasserstein GAN & WGAN-GP](#)
- [GAN — Super Resolution GAN \(SRGAN\)](#)

# Вопросы?