Введение в компьютерное зрение. Продолжение

Лектор — Троешестова Лидия

Задача генерации изображений

Хотим научиться генерировать изображения. Какие задачи бывают:

- Перенос стиля
- Генерация произвольных изображений
- Генерация изображений по тексту
- Super Resolution
- Inpainting / Outpainting
- Image-to-image Translation
- …

Задача генерации изображений

Перенос стиля

Генерация произвольных изображений

Перенос стиля | Задача

Gatys et al. (2016)

Дано: изображение контента $\vec{p}$ и изображение стиля $\vec{a}$.

Задача: получить изображение $\vec{x}$, объединяющее данный контент и стиль.

Перенос стиля | Применение свойств CNN

- **Content features**
  Выходы глубоких слоев сверточной нейросети хранят высокоуровневую информацию про изображенные объекты.

- **Style features** – матрицы Грама по выходам слоев CNN, где
  - начальные слои представляют мелкие текстуры
  - более глубокие – особенности стиля художника

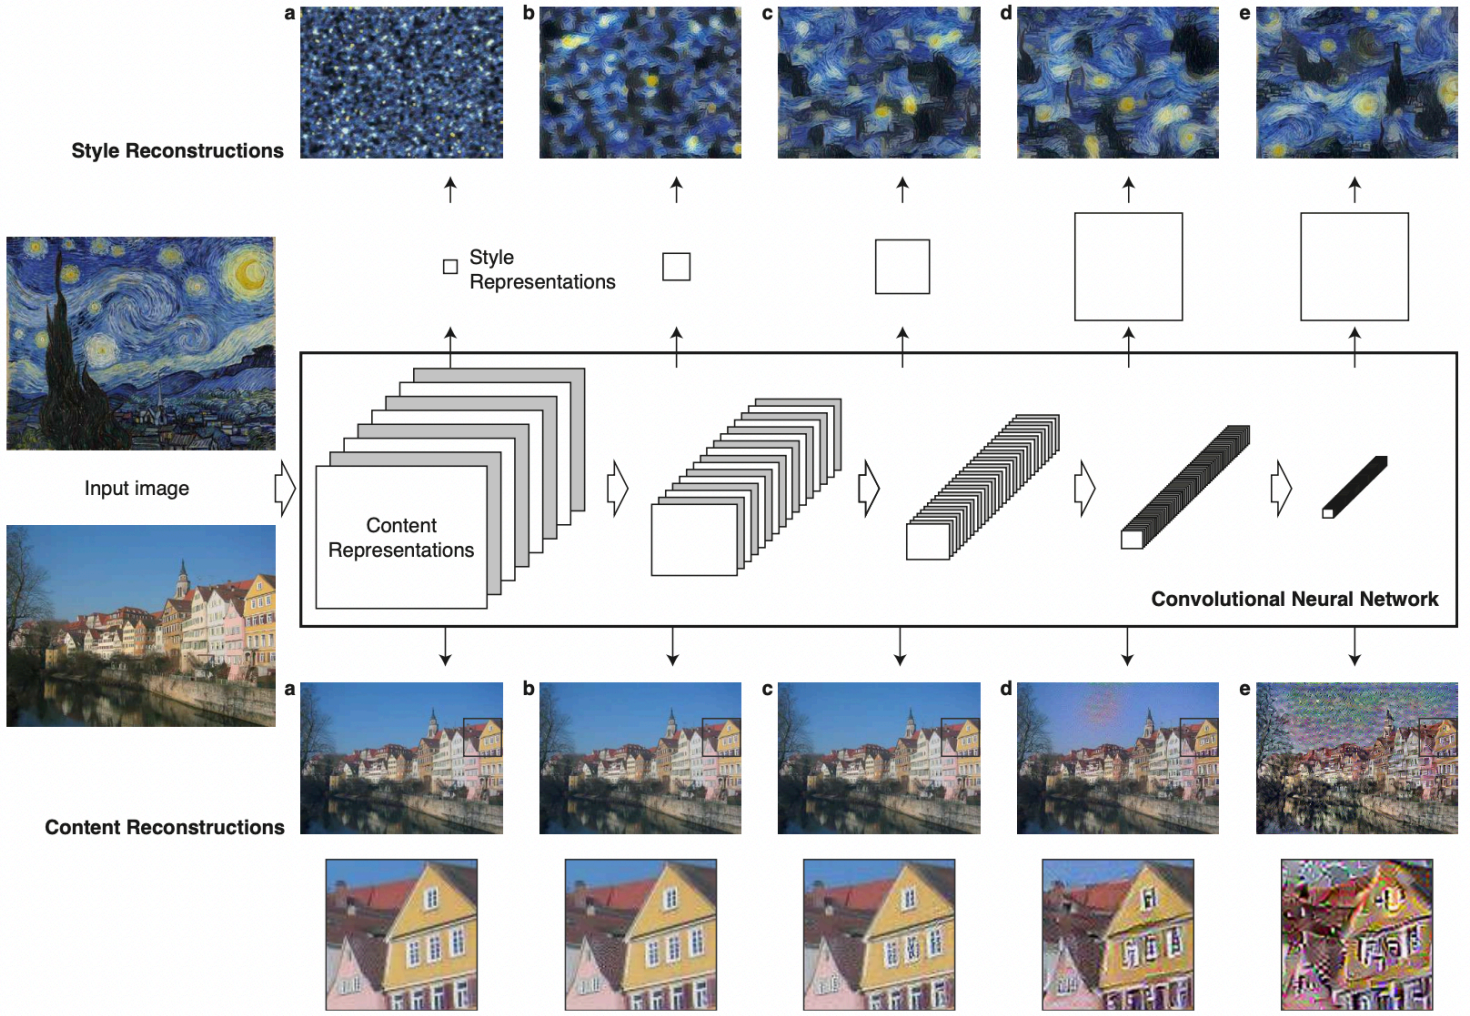

Перенос стиля | Алгоритм

Идея. Хотим оптимизировать картинку $\vec{x}$ так, чтобы:

- Content Features $\vec{x}$ были близки к Content Features картинки контента $\vec{p}$;
- Style Features $\vec{x}$ были близки к Style Features картинки стиля $\vec{a}$.

Алгоритм:

- инициализируем $\vec{x}$ нормальным шумом;
- задаем лосс близости контента $\mathscr{L}_{content}$ и лосс близости стиля $\mathscr{L}_{style}$;
- оптимизируем $\vec{x}$ градиентным спуском.

Перенос стиля | Алгоритм

Применяем предобученную сверточную сеть к картинке $\vec{x}$.

G^L – матрица Грама для выходов F^L сверточного слоя L:

$$G^L_{ij} = \sum_k F^L_{ik} F^L_{jk}.$$

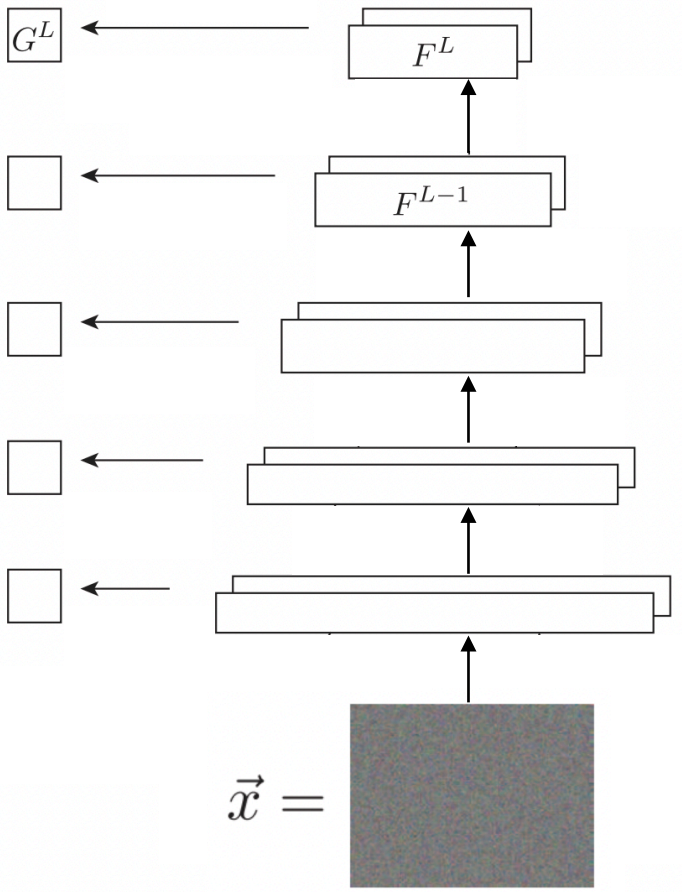

Перенос стиля | Алгоритм

Применяем сверточную сеть к картинке стиля $\vec{a}$.

A^L – матрица Грама для выходов сверточного слоя L.

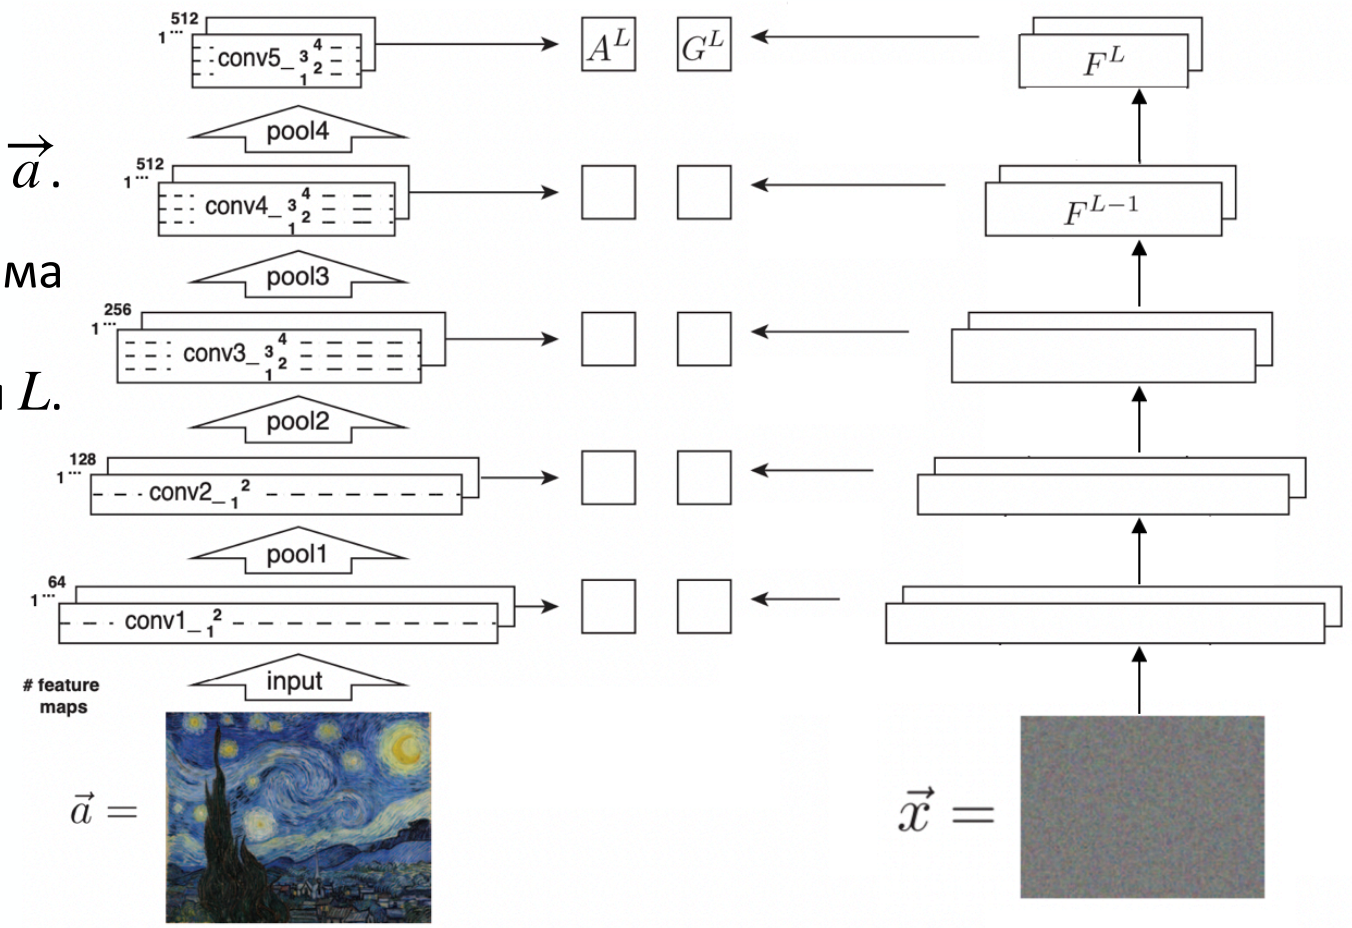

Перенос стиля | Алгоритм

Применяем сверточную сеть к картинке стиля $\vec{p}$.

P^L – выход сверточного слоя L.

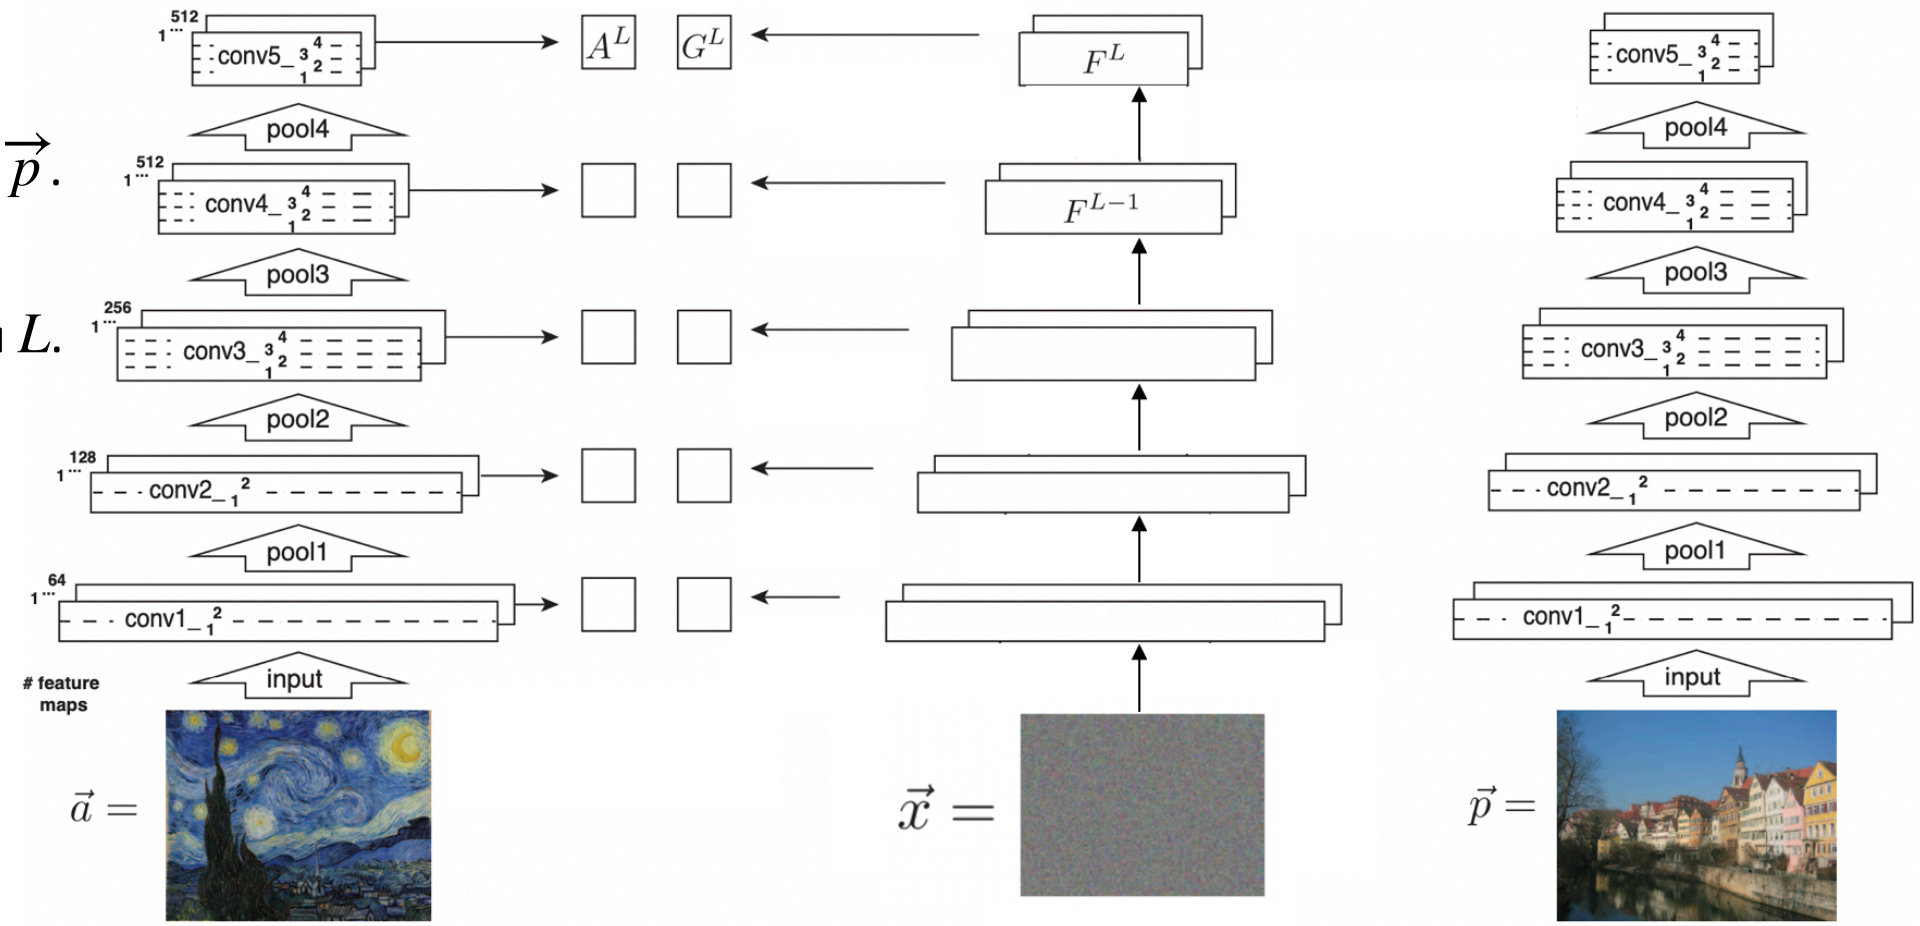

Перенос стиля | Алгоритм

$\mathscr{L}_{style}$ – сумма
по слоям MSE
для матриц Грама

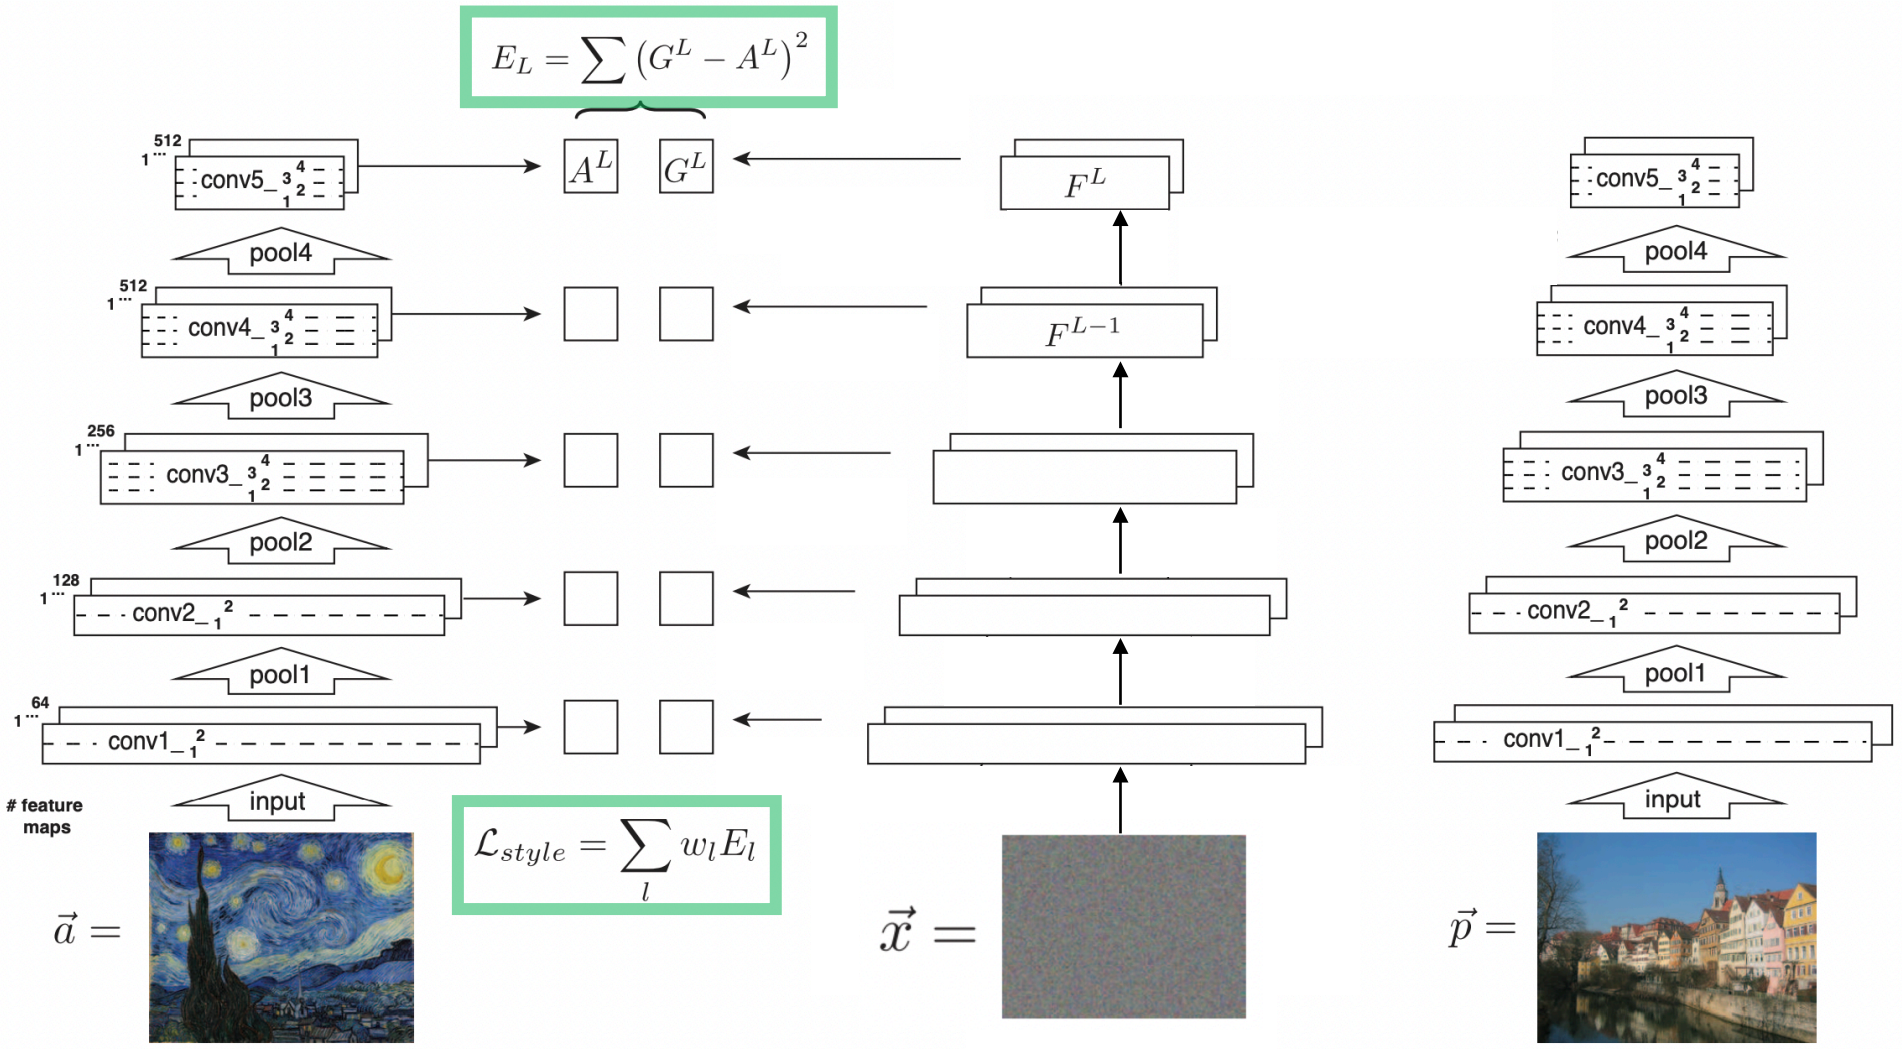

Перенос стиля | Алгоритм

$\mathscr{L}_{content}$ – сумма по слоям MSE для выходов сверточных слоев

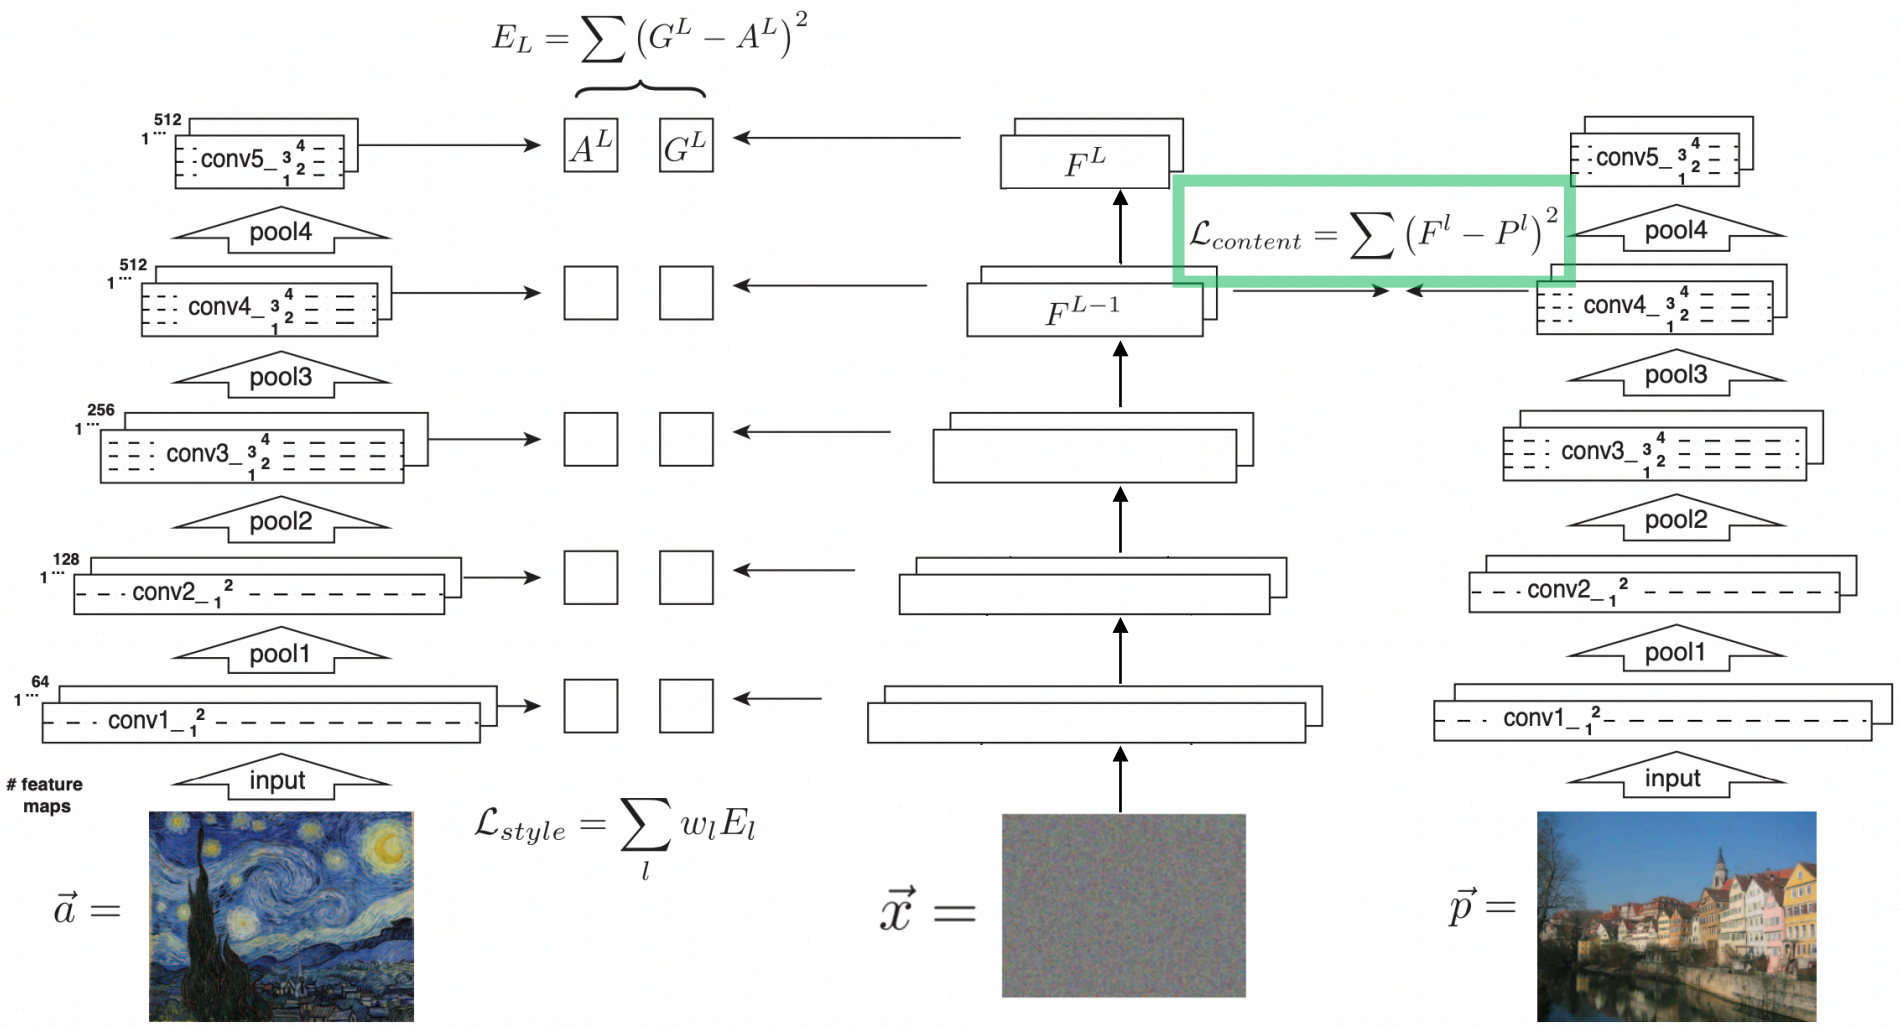

Перенос стиля | Алгоритм

$\mathcal{L}_{total}$ – взвешенная сумма $\mathcal{L}_{content}$ и $\mathcal{L}_{style}$

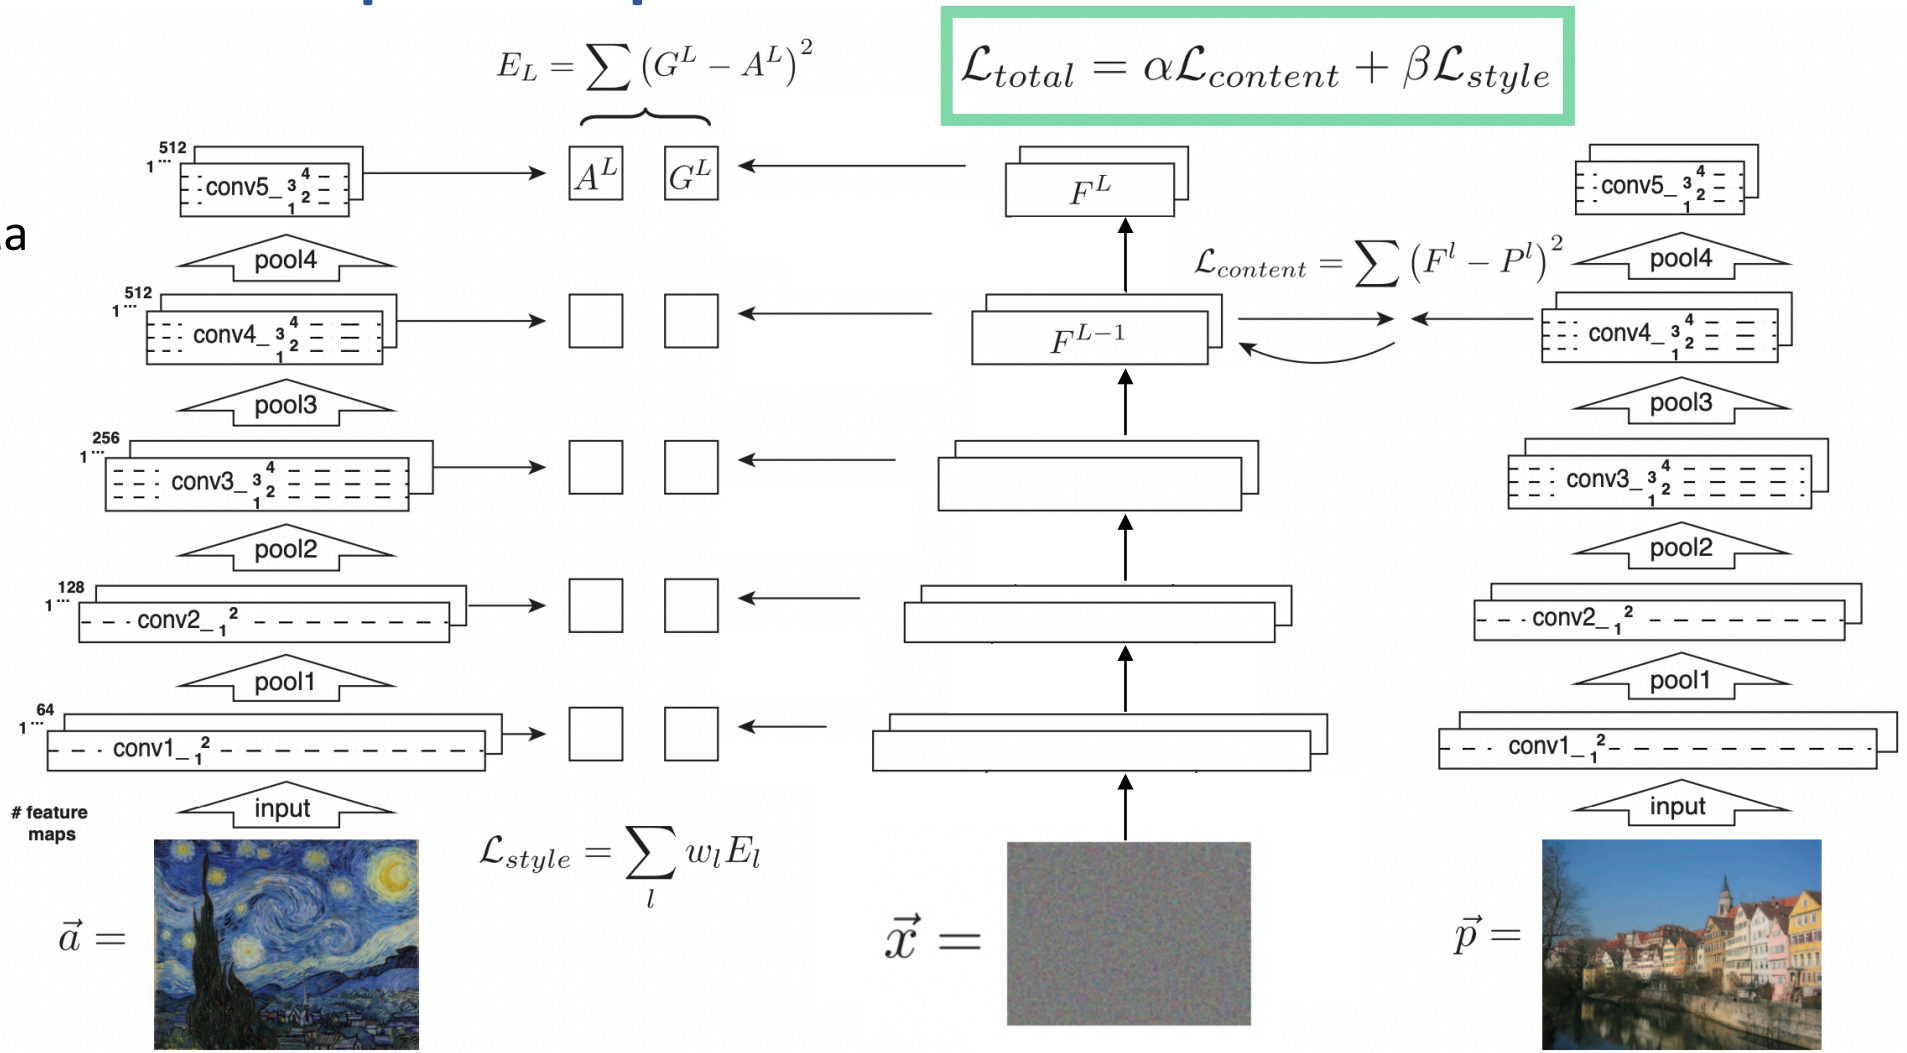

Перенос стиля | Алгоритм

Делаем обновление $\vec{x}$ градиентным спуском.

В итоге получаем искомую картинку.

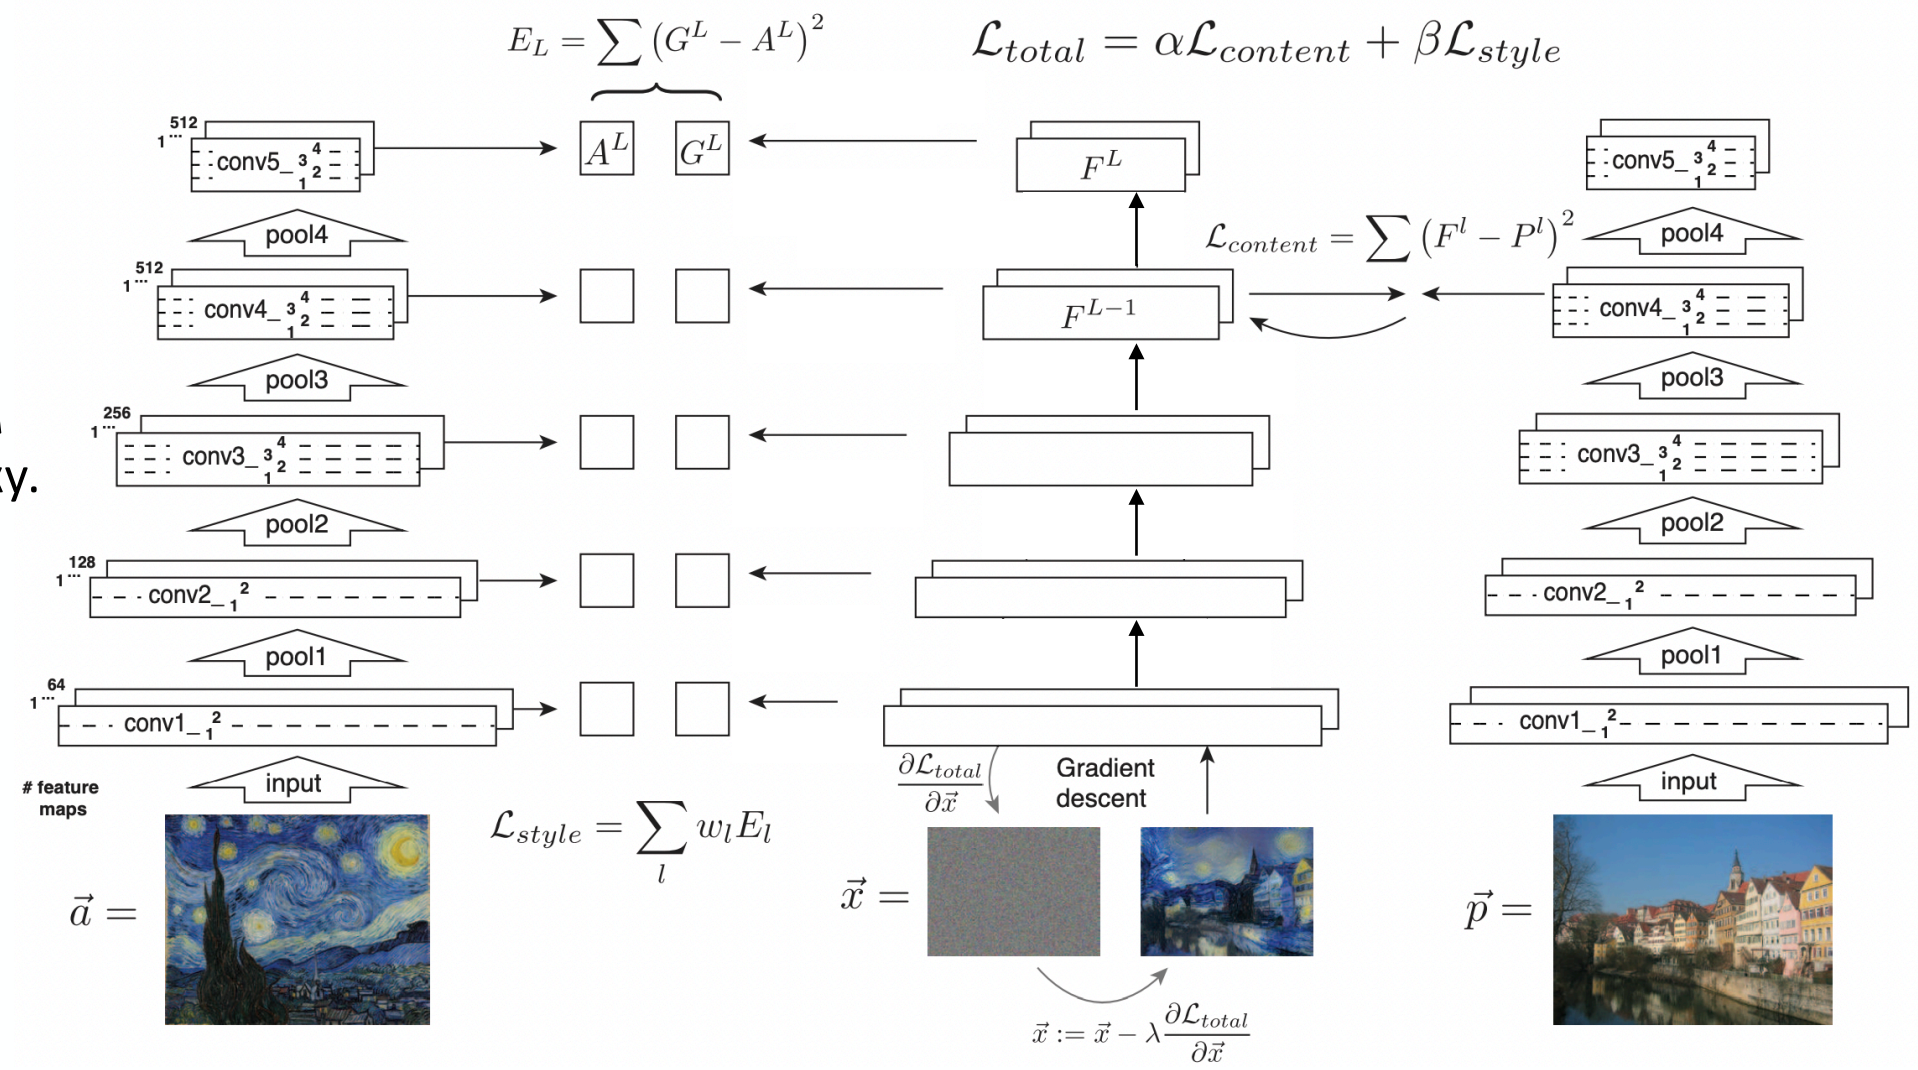

Влияние коэффициентов лосса

$$\mathcal{L}_{total} = \alpha \mathcal{L}_{content} + \beta \mathcal{L}_{style}$$

Результаты при разных значениях отношения $\frac{\alpha}{\beta}$ коэффициентов компонент лосса:

10^{-4}

10^{-3}

10^{-2}

10^{-1}

Задача генерации изображений

Перенос стиля

Генерация произвольных изображений

Генеративные модели|Задача

Пусть P – некоторое распределение данных, например, распределение картинок с котиками. Хотим сгенерировать новые объекты, которые:

- выглядят так, будто получены из P;
- отличаются от уже существующих.

Генеративные модели | Генератор

P – некоторое распределение картинок $X \in \mathcal{X}$.

Как получить модель, генерирующую картинки из P, которых мы еще не видели?
Будем давать ему на вход шум - случайный вектор Z. Это будет нашим генератором.

Но как построить такую сеть?

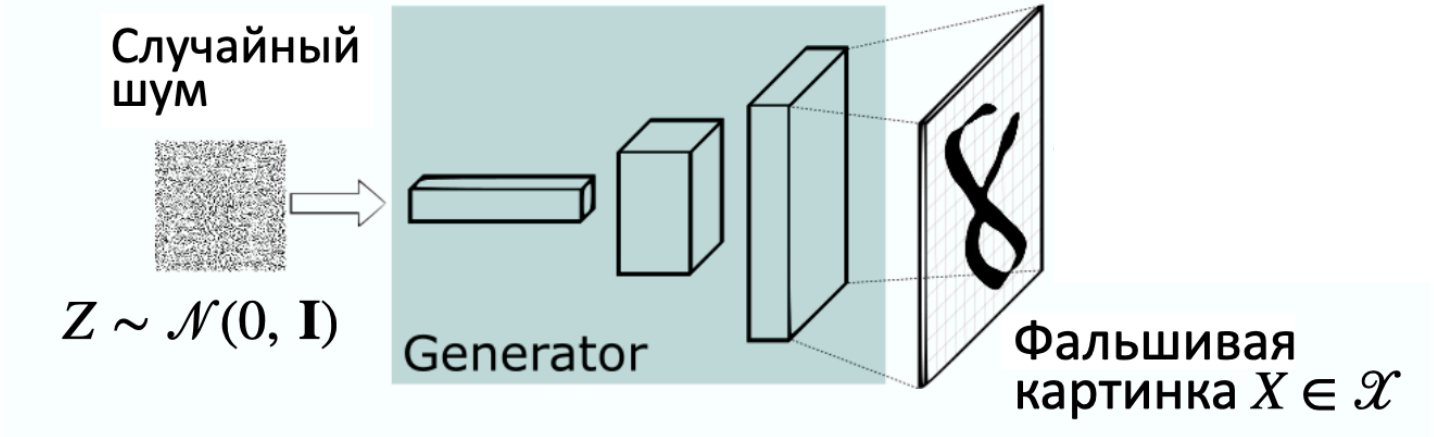

Про природу пространства представлений Z узнаем на 4 курсе DS-потока.

Генеративные модели | Генератор

Обычно для генерации используется модель, повышающая размерность входа.
Нужна операция, которая из тензора размера $h \times w \times d$ получает тензор размера $H \times W \times K$, где $h < H$, $w < W$, то есть операция повышения размерности.
Такая операция называется **Upsampling**.

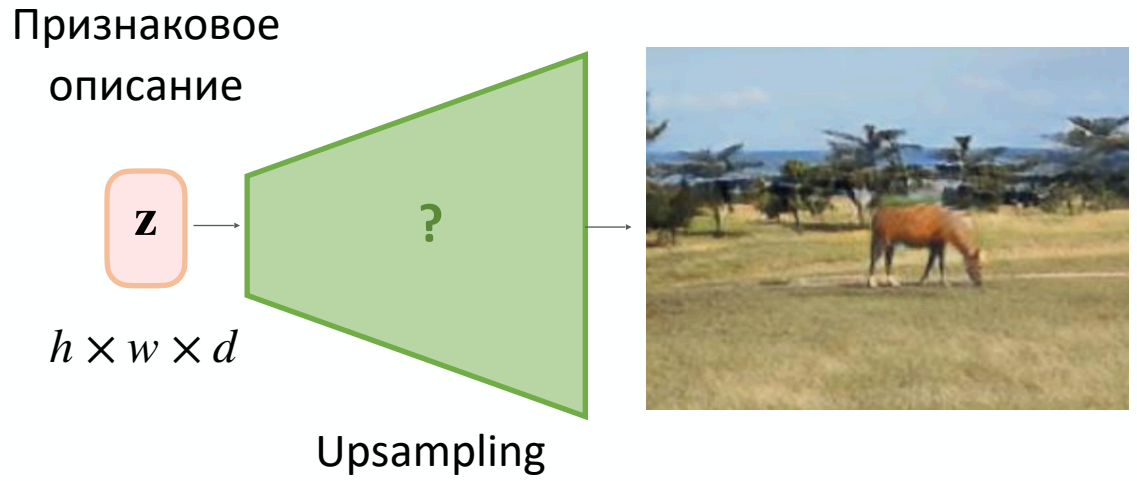

Про природу пространства представлений Z узнаем на 4 курсе DS-потока.

Upsampling: интерполяция

Нужна операция, которая из тензора размера $h \times w \times d$ получает тензор размер $H \times W \times K$, где $h < H$, $w < W$, то есть операция повышения размерности.

Такая операция называется **Upsampling**. Рассмотрим очевидный способ:

По ближайшему соседу
(Nearest Neighbors)

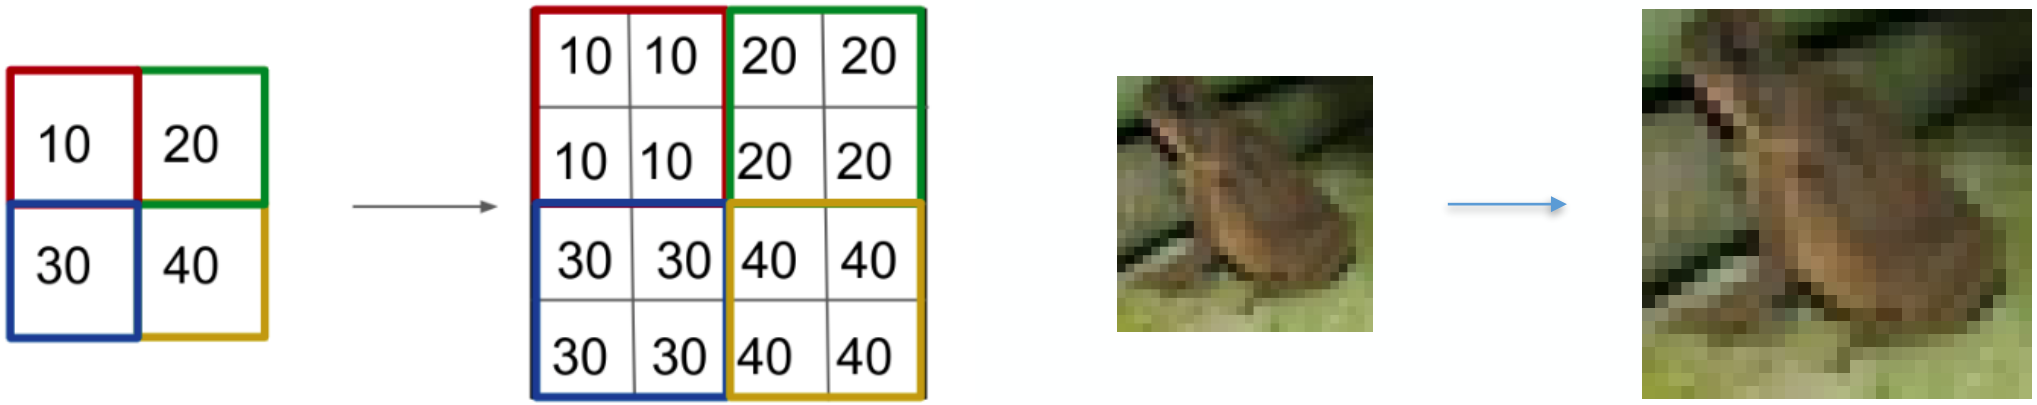

Upsampling: интерполяция

Билинейная (Bilinear)

Перенесем значения исходной матрицы таким образом, чтобы по краям новой матрицы матрицы оказались краевые значения исходной матрицы.

10	20
30	40

→

10	13	17	20
17	20	23	27
23	27	30	33
30	33	37	40

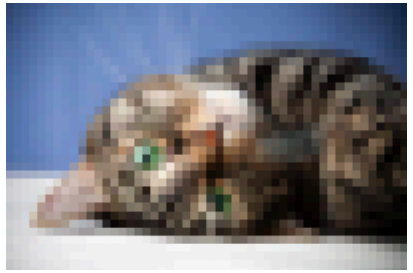

→

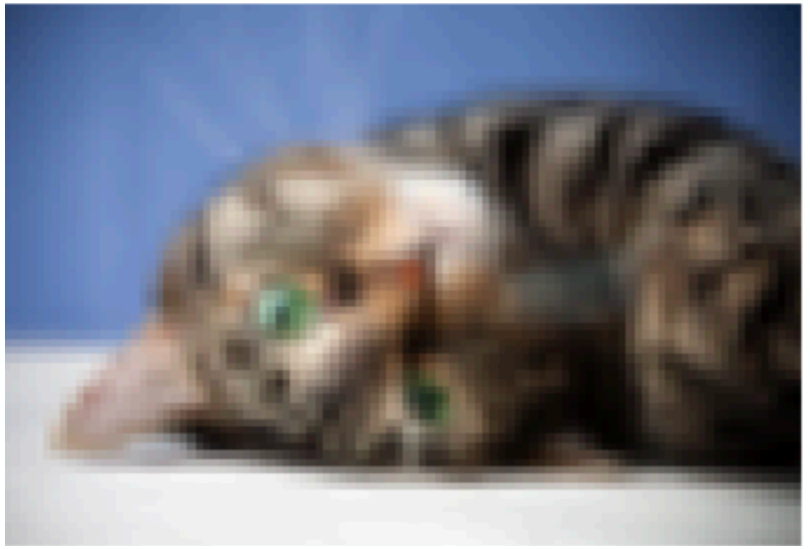

Upsampling: transposed convolution

aka deconvolution, up-conv

Как в обычной свертке имеем вход и ядро. Раньше мы накладывали и поэлементно умножали ядро на картинку, сумму записывали в 1 пиксель. А теперь умножаем ядро целиком на 1 пиксель входа и во вход прибавляем матрицу.

stride=2:

a	b
c	d

x_{11}	x_{12}	x_{13}
x_{21}	x_{22}	x_{23}
x_{31}	x_{32}	x_{33}

ax_{11}	ax_{12}	$ax_{13} + bx_{11}$	bx_{12}	bx_{13}
ax_{21}	ax_{22}	$ax_{23} + bx_{21}$	bx_{22}	bx_{23}
ax_{31}	ax_{32}	$ax_{33} + bx_{31}$	bx_{32}	bx_{33}

stride=1:

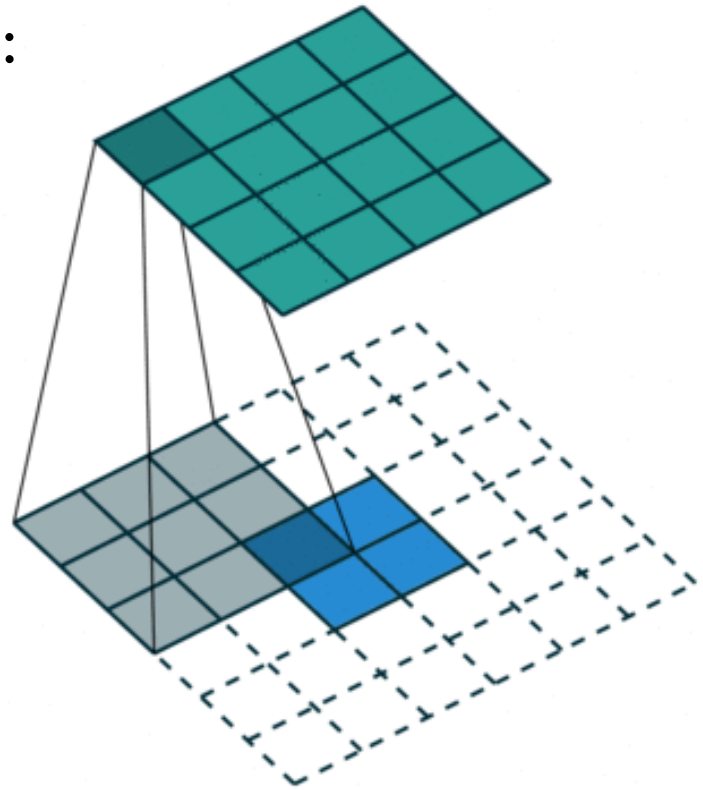

Больше про upsampling узнаем на 3 курсе DS-потока.

Генератор картинок

P – некоторое распределение картинок $X \in \mathcal{X}$.

Как получить модель, генерирующую картинки из P, которых мы еще не видели?
Будем давать ему на вход шум - случайный вектор Z. Это будет нашим генератором.

Но как такую нейросеть обучать?

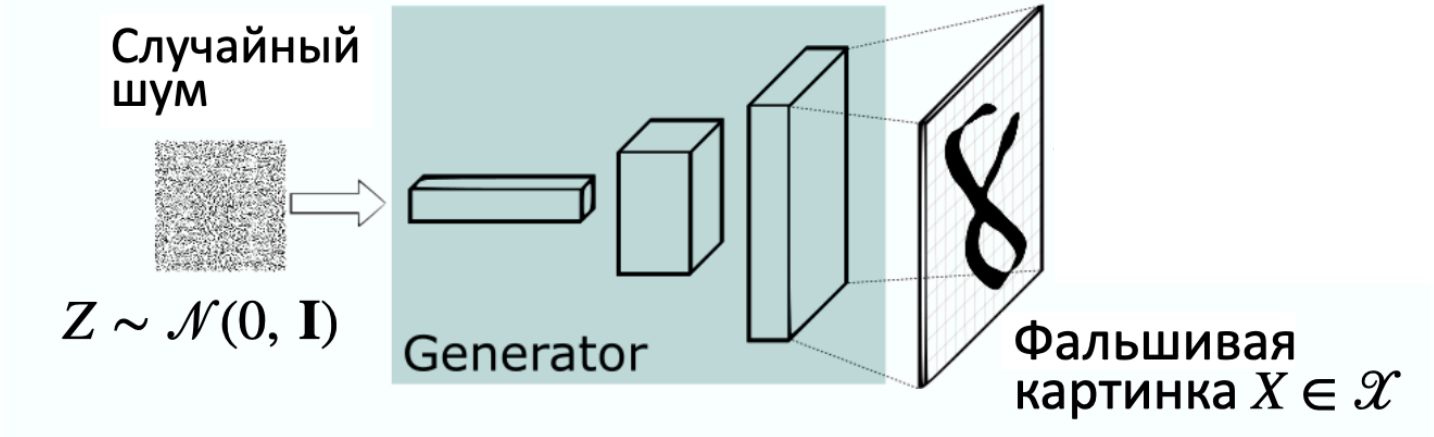

Дискриминатор

Для определения того, настоящая картинка или сгенерированная, заведем модель Discriminator. Это будет обычный классификатор, принимающий на вход $X \in \mathcal{X}$ и выдающий 0 фальшивкам, и 1 примерам из датасета.

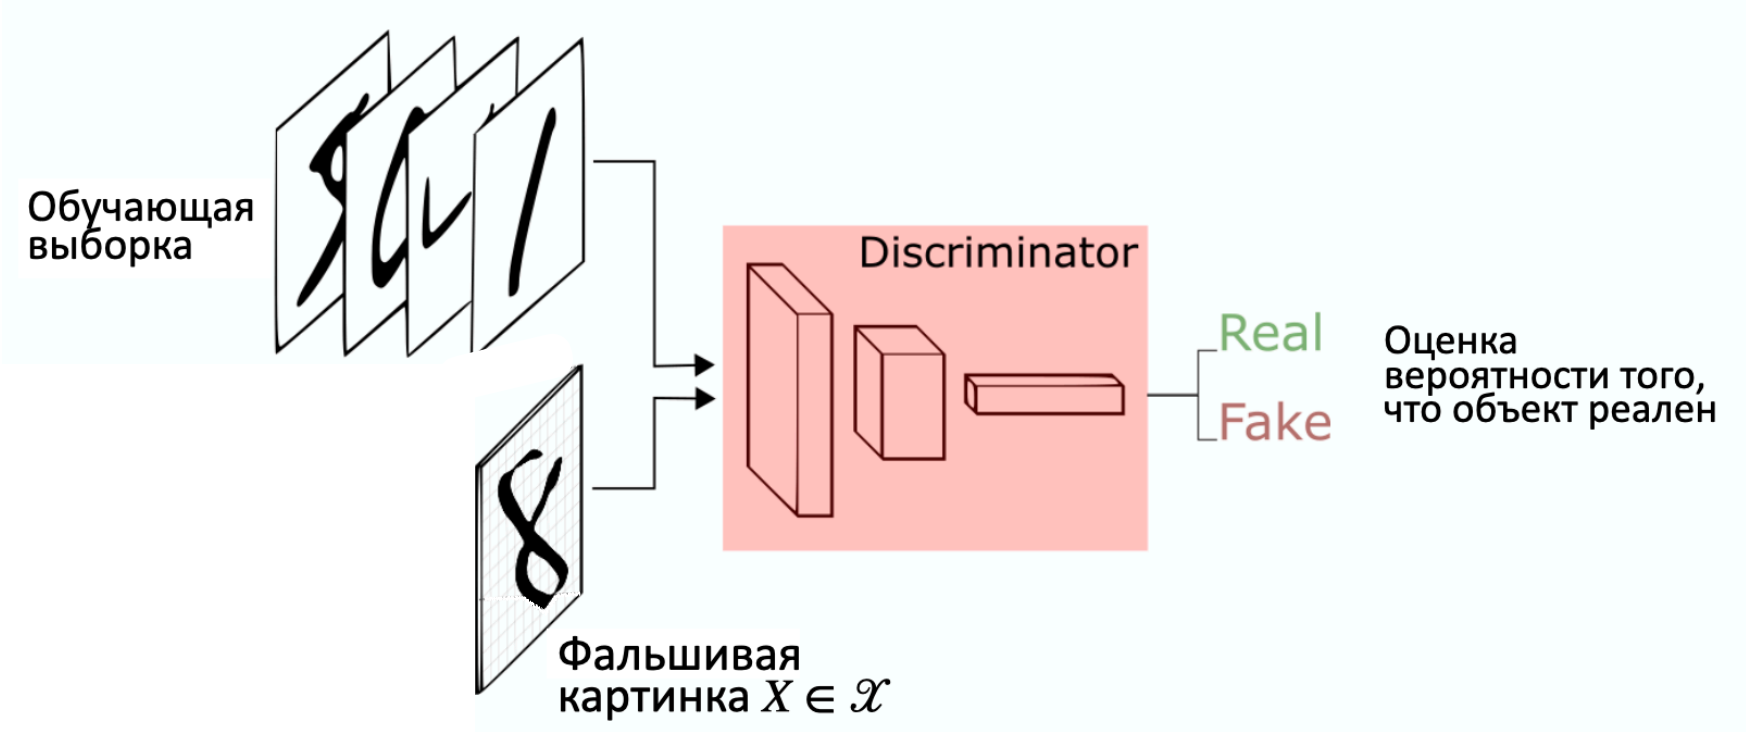

GAN: Generative Adversarial Network

Модель GAN призвана генерировать реалистичные объекты из распределения картинок и состоит из генератора и дискриминатора. Они обучаются попеременно.

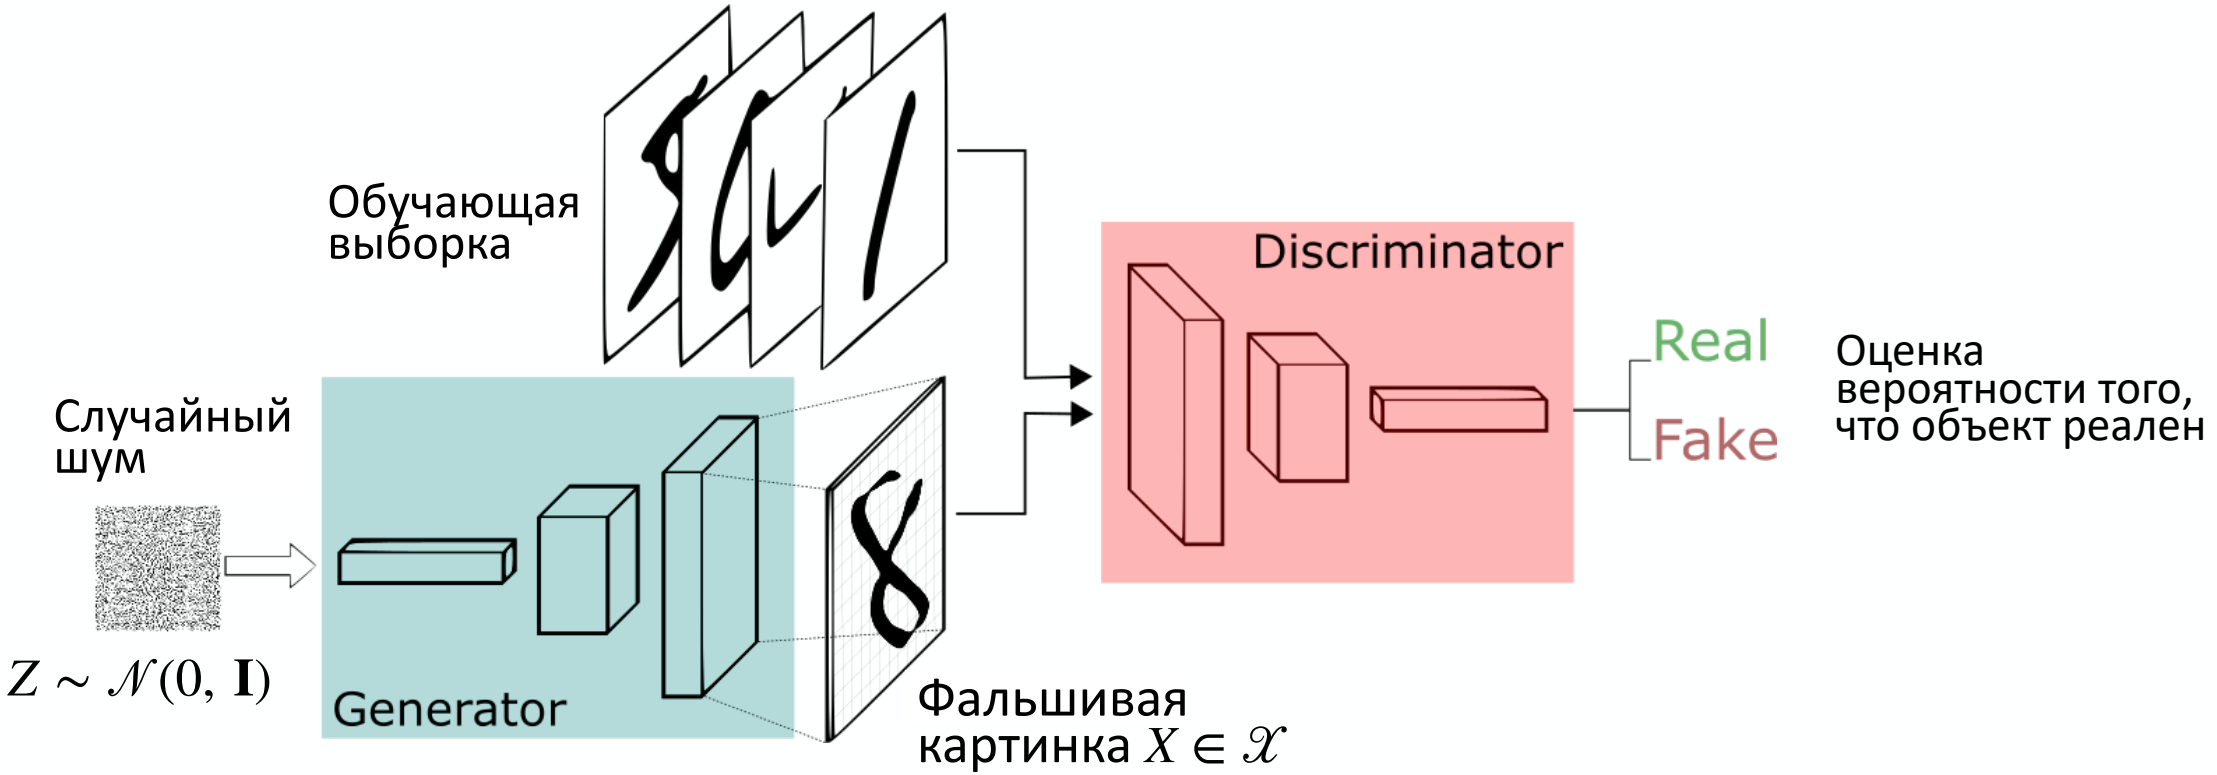

GAN: Generative Adversarial Network

Обучение называется состязательным, так как генератор и дискриминатор решают противоположные задачи:

- Дискриминатор хочет выдавать 1 для истинных картинок и 0 для сгенерированных:

$$\mathrm{E}\log D(X) + \mathrm{E}\log[1 - D(G(Z))] \longrightarrow \max_D$$

- Генератор хочет уметь обманывать дискриминатор – генерировать настолько хорошие картинки, что дискриминатор подумает, что они реальны:

$$\mathrm{E}\log D(G(Z)) \longrightarrow \max_G$$

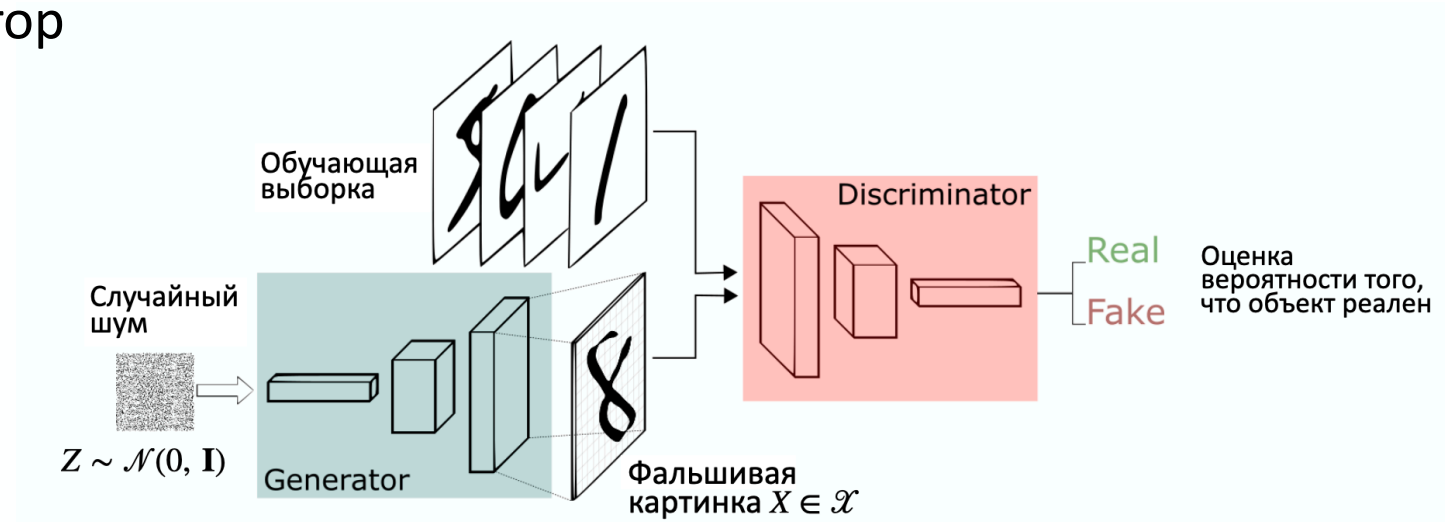

Современная генерация картинок

Развитие генеративных моделей

VAE
2013

GAN
2014

DCGAN
2015

StyleGAN
2018

DaLLE-2
2022

VAE разберем подробнее на байесовских методах, StyleGAN – на курсе по генеративным моделям на 4 курсе DS-потока.

Диффузионная модель

Диффузионная модель состоит из 2 процессов.

- **Прямой процесс** — постепенно добавляем шум ко входу.
- **Обратный процесс** — модель постепенно восстанавливает данные из шума.

Прямой диффузионный процесс

При $T \to \infty$, $X_T \to N(0, I)$.

На последнем шаге итераций получаем гауссовский шум.

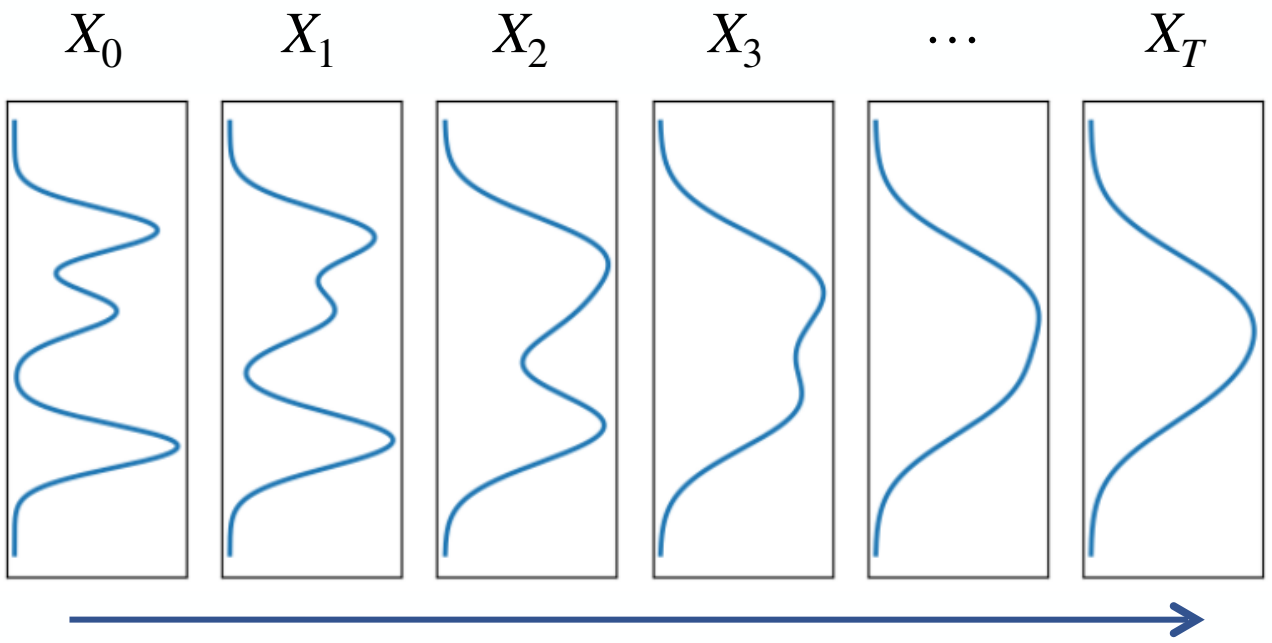

Обратный диффузионный процесс

Хотим восстановить исходное изображение.

Знаем $X_T \sim N(0, I)$. Будем итеративно семплировать $X_{t-1} \mid X_t$.

Но как?

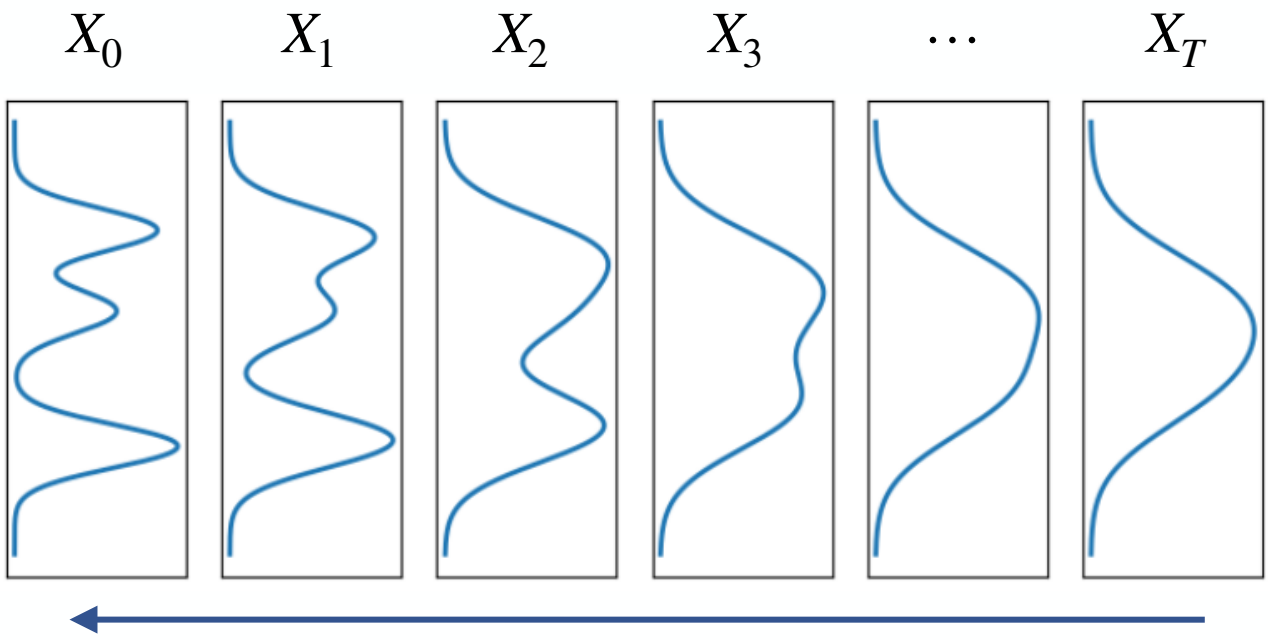

Обратный диффузионный процесс

Будем **аппроксимировать $X_{t-1} \mid X_t$ нормальным распределением**, среднее которого получается из нейросети, параметризуемой θ.

$$X_{t-1} \mid X_t \sim N\Big(\mu_\theta(X_t, t),\ \sigma_t^2 I\Big).$$

В результате X_0 – сгенерированная из шума картинка.

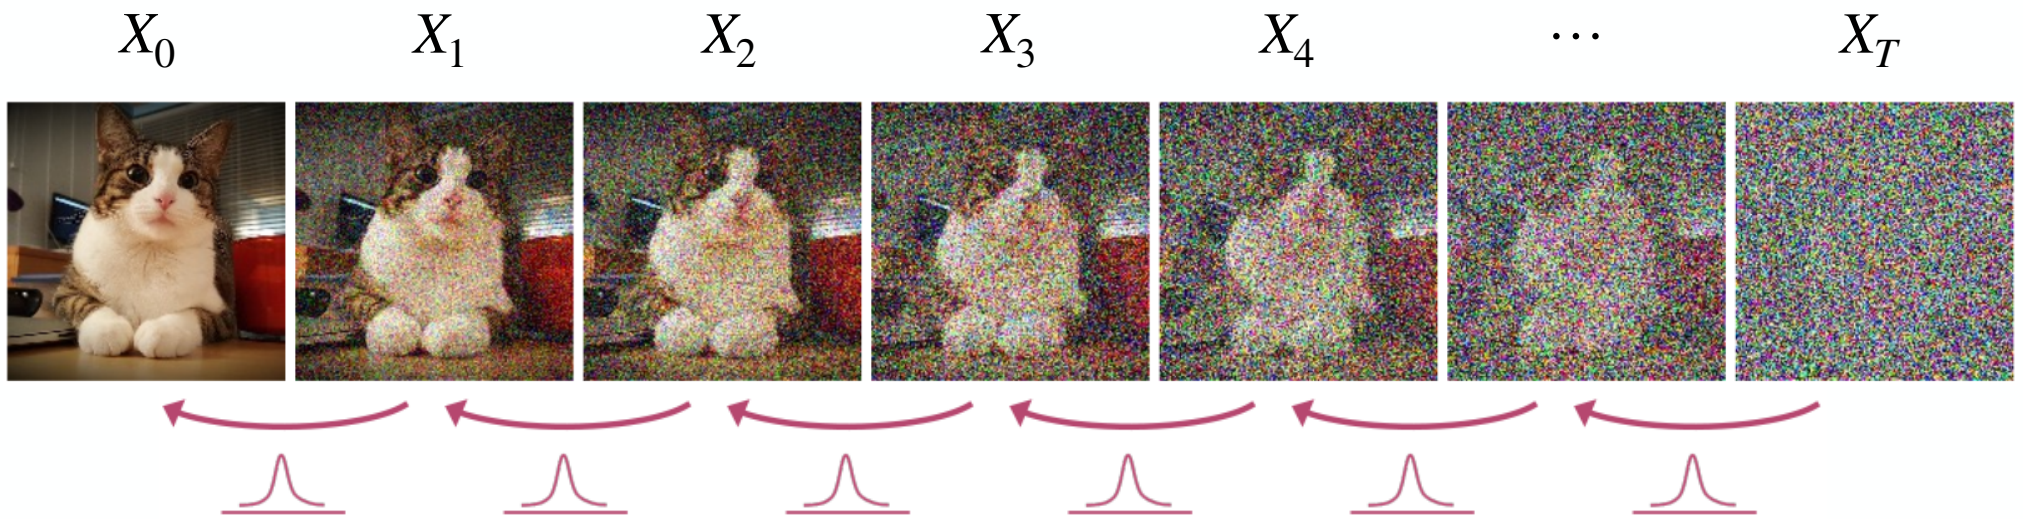

Обратный диффузионный процесс

Обучение диффузионной модели

На практике учим нейронную сеть предсказывать не μ_θ,
а **реконструкцию шума** ε_θ, т.е. шум, который был добавлен к X_0
на итерации t прямого диффузионного процесса.

А $\mu_\theta(X_t, t)$ выражается через $\varepsilon_\theta(X_t, t)$.

Почему?

В таком случае сеть учится решать задачу
в пространстве с простым распределением
выходов сети, что приводит к быстрой сходимости.

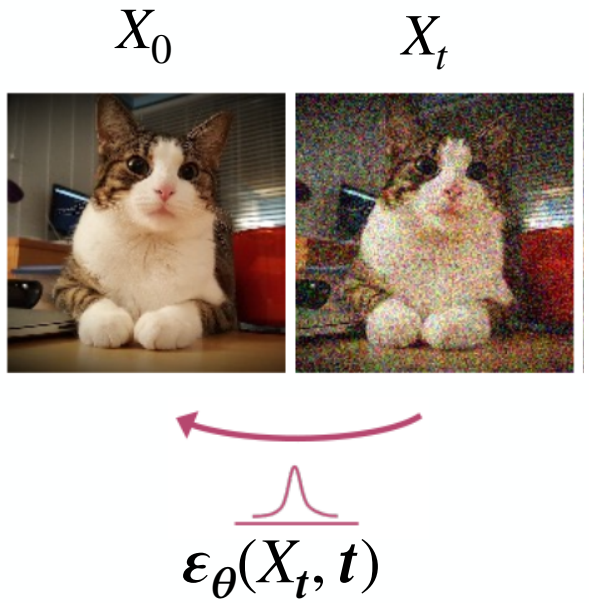

Подробнее – на 4 курсе DS-потока.

Диффузионная модель. Реализация

- Обычно для предсказания $\varepsilon_\theta(X_t, t)$ используется U-Net-подобная архитектура
- Для времени t подсчитываются некоторые признаки и представления через MLP-сеть
- Преобразованный вектор времени подается на слои U-Net как дополнительная информация

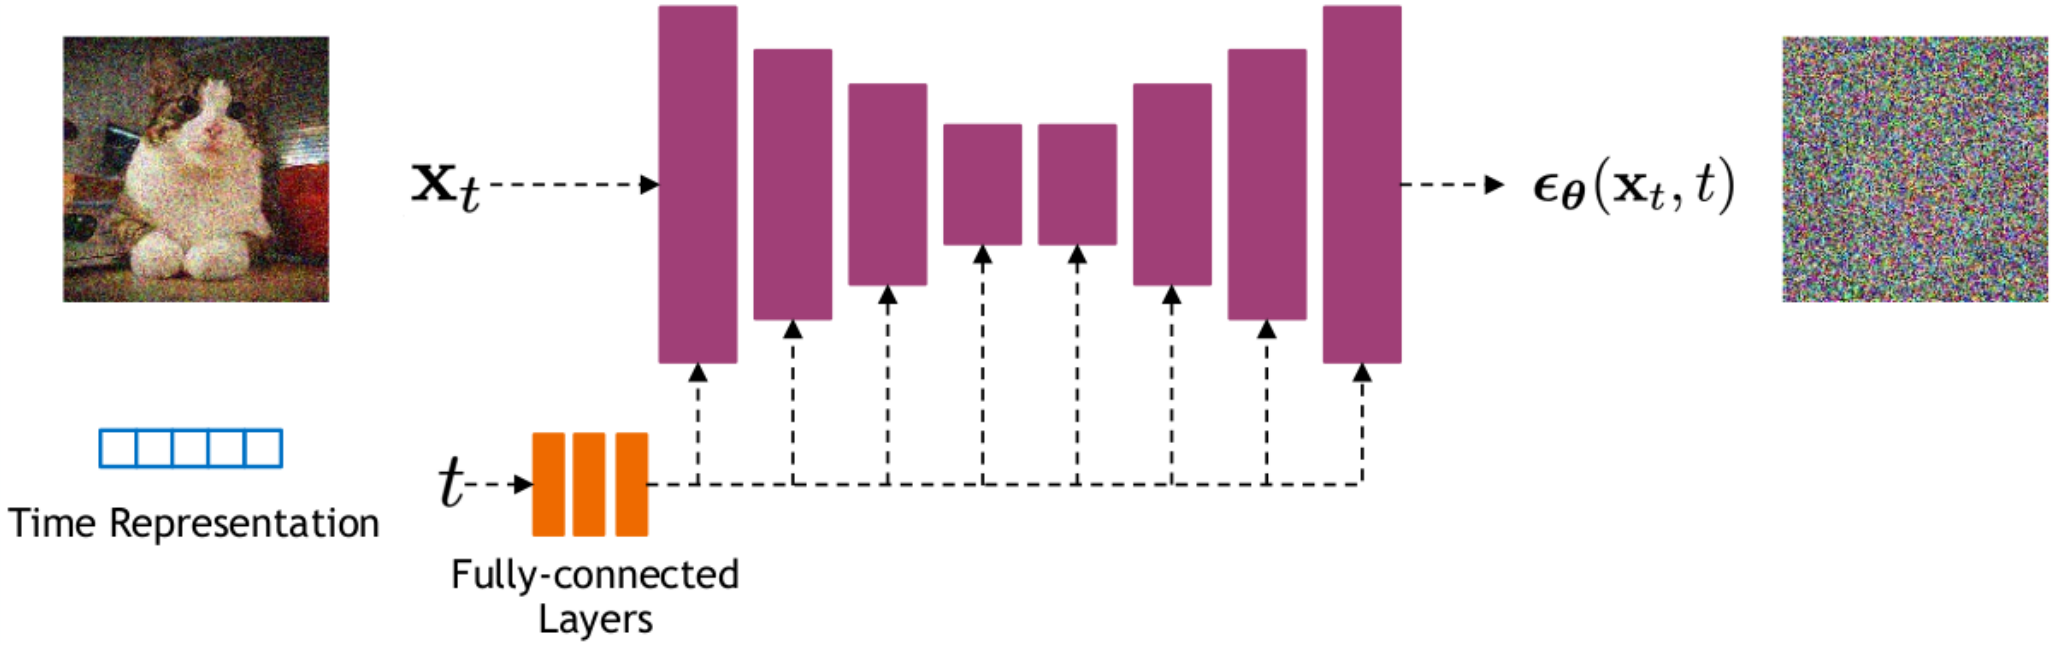

Обзор других задач в CV

Детекция

Задача.

Построить модель, определяющую координаты всех объектов на изображении.

Идея.

Предсказывать координаты ограничивающих прямоугольников, решая задачу регрессии и классификации одновременно.

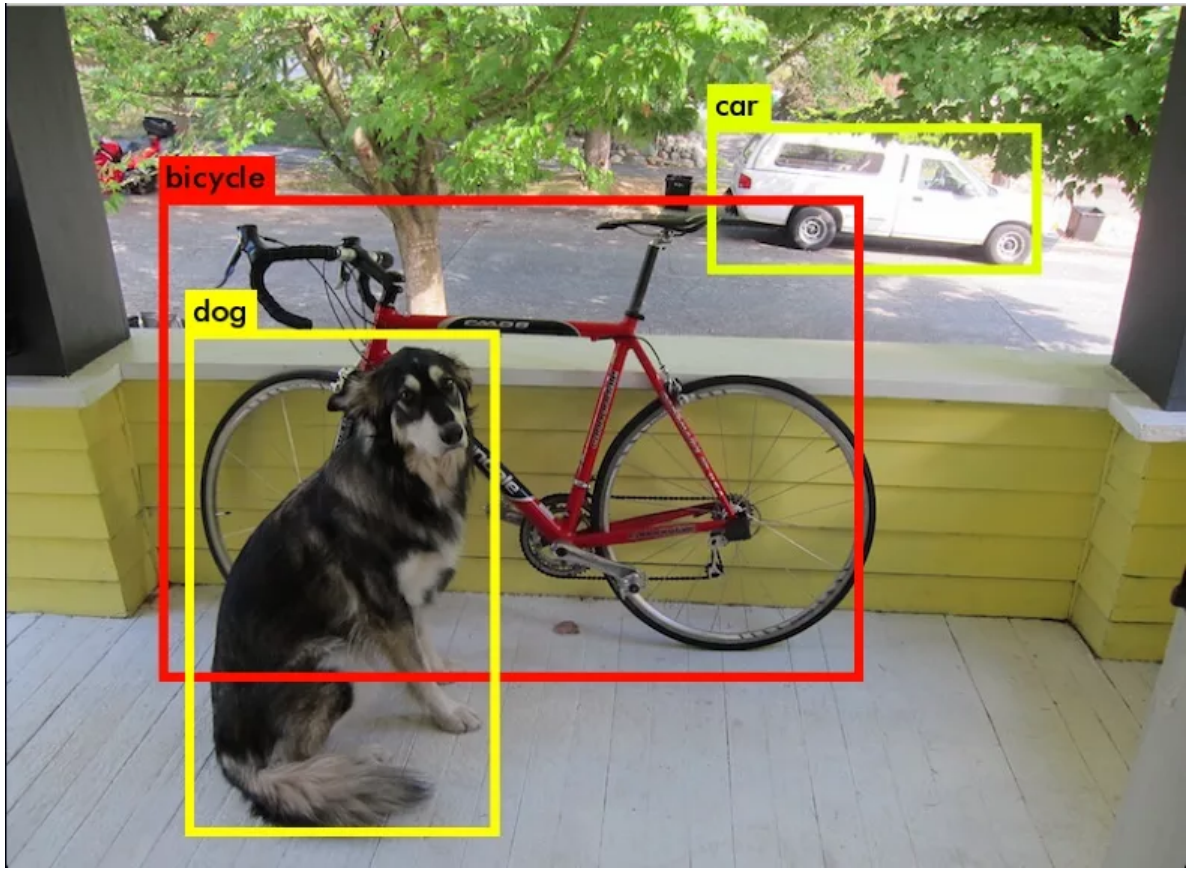

Больше про детекцию узнаем на 3 курсе DS-потока.

Сегментация

- **Semantic**: классифицировать каждый пиксель изображения.
- **Instance**: вывести bounding box и маску пикселей для каждого объекта, классифицировать объект.
- **Panoptic**: классифицировать каждый пиксель изображения, при этом разделяя объекты одного класса.

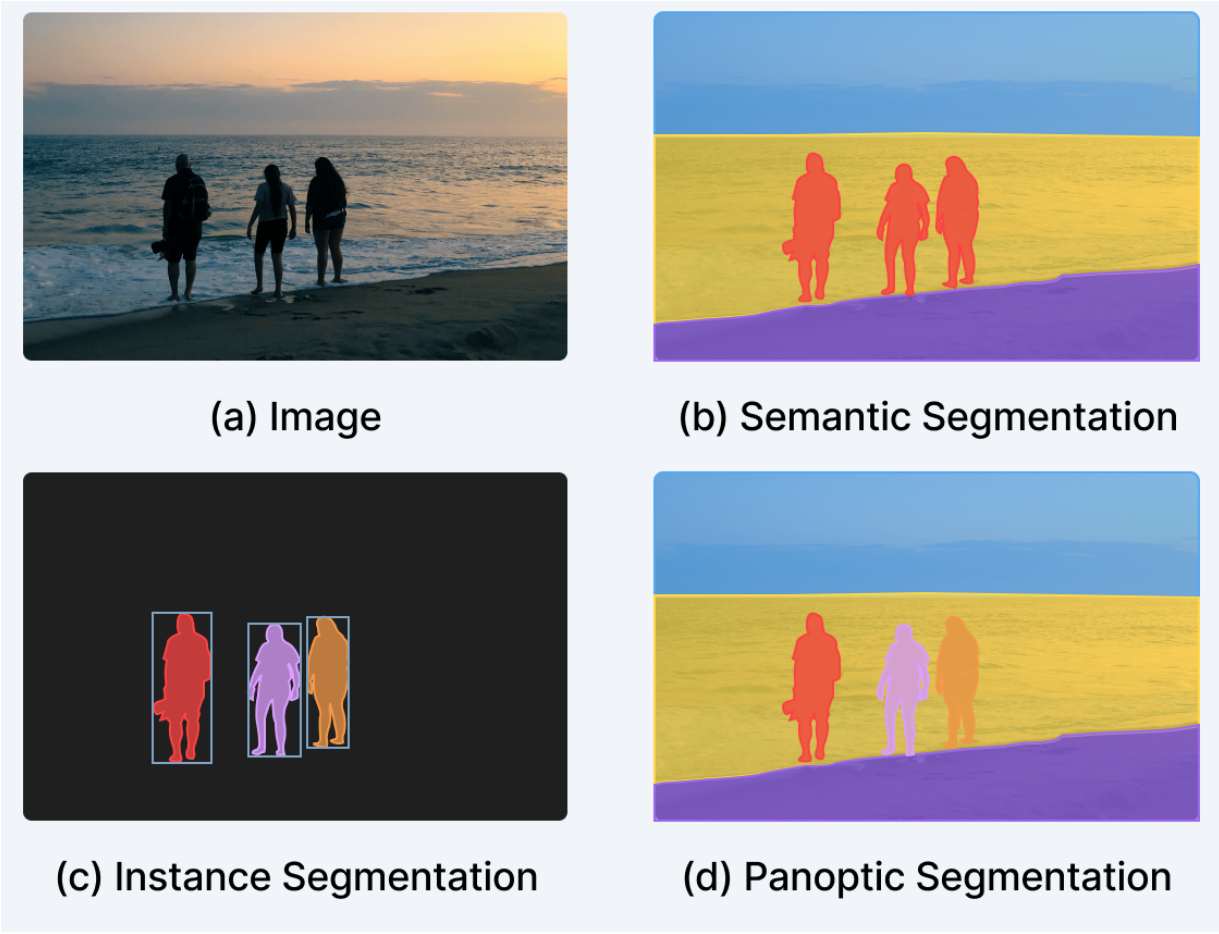

Больше про сегментацию узнаем на 3 курсе DS-потока.

Keypoint Estimation

Задача. Построить модель, определяющую координаты заданных ключевых точек лица или тела.

Идея. Сначала решить задачу детекции объектов, а затем для каждого из них предсказывать координаты точек.

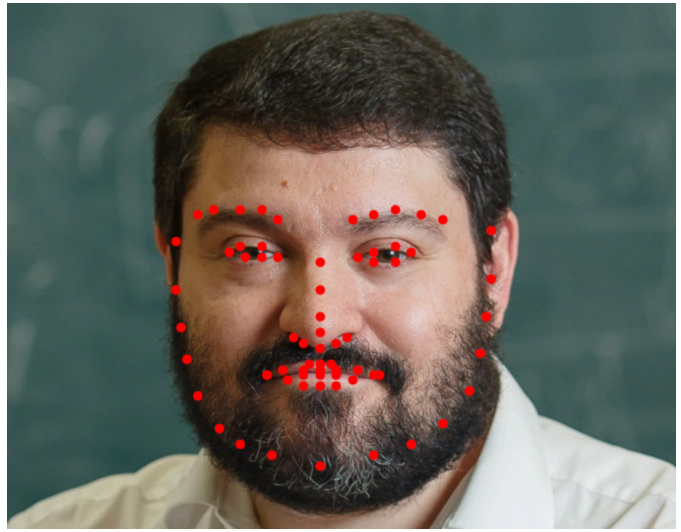

Больше про Keypoint Estimation узнаем на 3 курсе DS-потока.

3D реконструкция

Задача. Построить 3D-модель объекта или сцены, имея несколько 2D-изображений.

Идея. Сначала решить задачу детекции объектов, а затем для каждого из них предсказывать координаты точек.

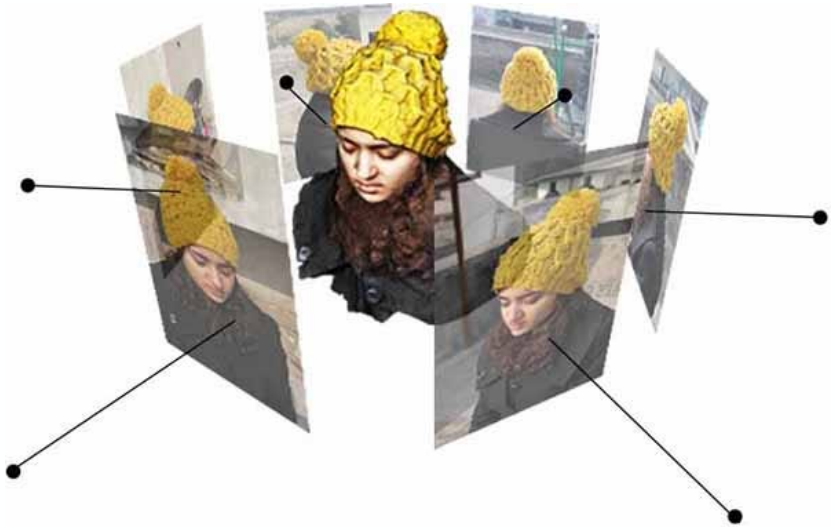

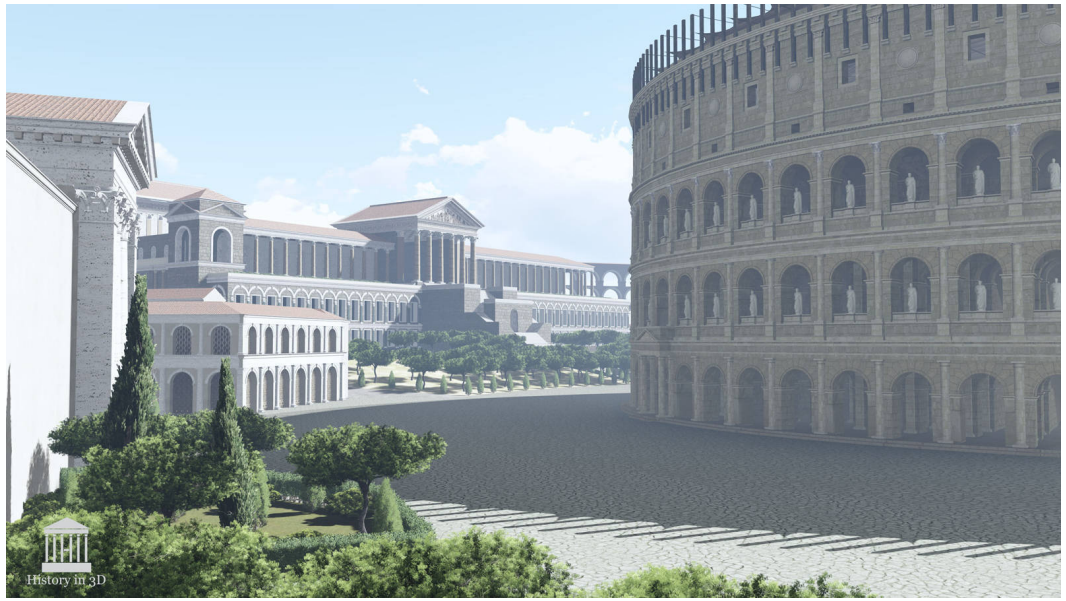

ВСЁ!