



Введение в анализ данных



Генерация изображений



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
- ...



Генерация 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 $\mathcal{L}_{content}$ и лосс близости стиля $\mathcal{L}_{style}$;
- оптимизируем $\vec{x}$ градиентным спуском.




Перенос стиля. Алгоритм

Применяем предобученную
сверточную сеть (VGG19) к картинке $\vec{x}$.

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

$$G_{ij}^L = \sum_k F_{ik}^L F_{jk}^L.$$






Перенос стиля. Алгоритм

Применяем
сверточную сеть $\rightarrow$
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


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





Перенос стиля. Алгоритм


$\mathcal{L}_{content}$ – 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.






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 α/β коэффициентов компонент лосса:

10^{-4}



10^{-3}



10^{-2}



10^{-1}





Генерация 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 $\mathcal{Z}$ 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	→		10	13	17	20
				17	20	23	27
30	40			23	27	30	33
				30	33	37	40





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 **сопоставительным**, так как генератор и дискриминатор решают противоположные задачи:

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

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

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

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





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 $T \rightarrow \infty$, $X_T \xrightarrow{d} N(0, I)$.

На последнем шаге итераций получаем гауссовский шум.



Прямой диффузионный процесс




Обратный диффузионный процесс

Хотим восстановить исходное изображение.

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

Но как?



Обратный диффузионный процесс




Обратный диффузионный процесс

Будем аппроксимировать условное распр. $X_{t-1}|X_t$ нормальным распределением, среднее которого получается из нейросети, параметризуемой θ .

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

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.

При этом $\mu_\theta(X_t, t)$ 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.





Диффузионная модель. Реализация

- Обычно для предсказания $\epsilon_{\theta}(X_t, t)$ 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





ВСЁ!