



Г.А. Альгашев, О.П. Солдатова

## ВОССТАНОВЛЕНИЕ ИЗОБРАЖЕНИЙ С ПОМОЩЬЮ ПОРОЖДАЮЩИХ СОСТЯЗАТЕЛЬНЫХ СВЁРТОЧНЫХ СЕТЕЙ

(Самарский университет)

Одной из задач, которую решают с использованием нейронных сетей является задача восстановления изображений. Под восстановлением будем понимать повышение разрешения изображения, поступающего на вход нейронной сети.

Для решения этой задачи было решено использовать порождающие состязательные сети (GANs) [1]. Это гибридная концепция, которая объединяет дискриминативную и порождающую модель в единую систему. Сеть состоит из двух искусственных нейронных сетей, которые соперничают друг с другом:

- 1) Генератор (порождающая нейронная сеть) – модель, которая порождает новые данные, похожие на настоящие примеры;
- 2) Дискриминатор (дискриминативная нейронная сеть) – модель, которая отличает порожденные генератором данные от настоящих примеров из обучающей выборки. Иначе говоря, дискриминатор решает задачу бинарной классификации.

Схематически модель нейронной сети показана на рисунке 1.

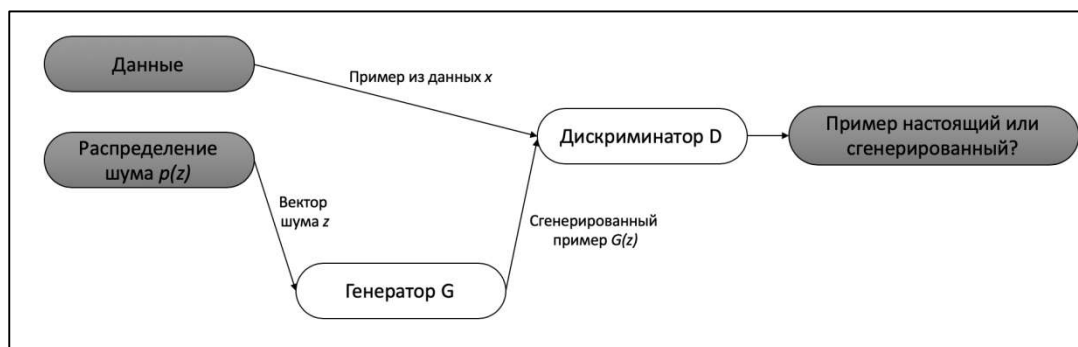


Рисунок 1 – Схема работы порождающей состязательной сети

Глубокие свёрточные порождающие состязательные сети (DCGAN) являются частным случаем обычных порождающих состязательных сетей [2]. Особенность сети заключается в том, что в качестве порождающей и дискриминативной модели выбираются свёрточные нейронные сети.

Выбранная архитектура дискриминативной модели представлена на рисунке 2. В ней используются два идущих подряд свёрточных слоя. Разница заключается в том, что первый слой сопровождается функцией активации LReLU, а во второй слой дополнительно добавлена батч-нормализация. Её отсутствие в первом слое объясняется тем, что это позволит сети запомнить, каковым было входное распределение данных. После свёрточных слоёв идёт два полносвязных слоя, которые заканчиваются сигмоидальной функцией активации.



Чтобы получить батч-нормализацию мини-выборки, необходимо вычесть среднее и поделить на дисперсию мини-выборки каждый элемент, получив распределение с центром 0 и дисперсией 1. Мини-выборка – это часть обучающей выборки фиксированного размера, которая подаётся на вход нейронной сети для обучения.

Функция ReLU – полулинейная функция активации, которая имеет следующую формулу  $f(x) = \max(0, x)$  и реализует простой пороговый переход в нуле. Функция LRelu является модификацией функции ReLU, в ней отрицательные входы не превращаются в ноль, а принимают некоторые значения меньше нуля, которые по модулю растут намного медленнее, чем для положительных входов.

Архитектура порождающей модели показана на рисунке 3. На вход модели поступает шум, который представляет из себя вектор произвольной размерности. Этот шум нет смысла расчленять на признаки с помощью свёрточных слоёв, а требуется наоборот, преобразовать в результирующее изображение. Для выполнения этой задачи будут использоваться развёрточные слои, которые по факту являются обратными к свёрточным. Принцип их действия заключается в том, что они дополняют вход нулями до матрицы необходимого размера.

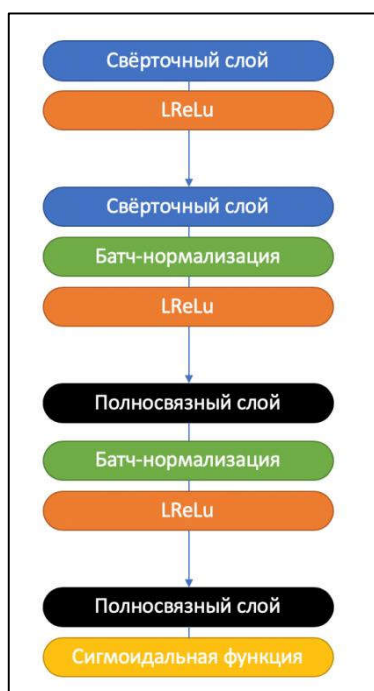


Рисунок 2 – Архитектура дискриминативной модели



Рисунок 3 – Архитектура порождающей модели

В качестве данных для обучения было решено взять набор рукописных цифр MNIST [3]. Набор состоит из 60000 монохромных изображений для обучения и 10 000 изображений для тестирования размером 28 на 28 пикселей.

В результате обучения модели нейронных сетей на наборе данных MNIST, порождающая сеть научилась генерировать изображения, показанные на рисунке 4. Анализируя результаты можно констатировать, что подавляющее



большинство изображений легко идентифицируемы, следовательно, можно сделать вывод, что модель обучена настолько, что генерируемые цифры схожи с настоящими.



Рисунок 4 – Результаты порождающей состязательной сети

Для увеличения разрешения изображения на вход порождающей модели подаётся не случайный шум, как в классическом подходе генерации новых данных, а изображение низкого разрешения, которое необходимо будет увеличить [4]. Выходом модели будет являться изображение увеличенного разрешения. Дискриминативная модель продолжает работать без изменения.

Порождающая модель для обработки изображений должна претерпеть изменения. В неё перед развёрточными слоями добавляется пара свёрточных слоёв (рисунок 5), отвечающие за то, чтобы первоначальное исходное изображение декомпозировать на признаки, а затем уже благодаря последующим преобразованиям превратить полученные свойства в изображение большего разрешения. При этом структура дискриминативной модели остаётся неизменной.

После работы модели были получены результаты (рисунок 6), из которых видно, что увеличение разрешения изображений действительно произошло. При этом объекты остались идентифицируемы, т.е. объект, который находился на фотографии низкого качества, остался тем же объектом после обработки нейронной сетью. Также из результатов можно увидеть, что полученные изображения очень похожи по качеству на оригинальные изображения, из чего можно сделать вывод, что задача восстановления изображения была выполнена.

Использование данного подхода показало хороший визуальный результат, что делает его приемлемым для решения поставленной задачи.



Рисунок 5 – Архитектура порождающей модели для восстановления изображений




Рисунок 6 – Визуальное сравнение оригинального изображения (справа), изображения низкого разрешения (слева) и обработанного изображения (центр)

### Литература

1. Generative Adversarial Nets [Электронный ресурс] // Neural Information Processing Systems (NIPS). – <https://papers.nips.cc/paper/5423-generative-adversarial-nets.pdf> (дата обращения: 03.04.2019).
2. Unsupervised Representation Learning with Deep Convolutional Generative Adversarial Networks [Электронный ресурс] // arXiv.org. – <https://arxiv.org/abs/1511.06434> (дата обращения: 07.04.2019).
3. The MNIST Database [Электронный ресурс] // Yann LeCun Blog. – <http://yann.lecun.com/exdb/mnist/> (дата обращения: 22.04.2019).
4. Semantically Decomposing the Latent Spaces of Generative Adversarial Networks [Электронный ресурс] // arXiv.org. – <https://arxiv.org/pdf/1705.07904.pdf> (дата обращения: 10.05.2019).

Р.Р. Бадрутдинов

## ДИФФЕРЕНЦИРУЕМЫЙ ПОИСК АРХИТЕКТУР СВЁРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ

(Самарский университет)

Поиск архитектур нейронных сетей (Neural Architecture Search, NAS) — процесс автоматического проектирования искусственных нейронных сетей. Подходы, разработанные в рамках этой парадигмы, показали результаты, не уступающие ручному подбору параметров моделей машинного обучения, а в