

УДК 61

U-NET ДЛЯ РЕШЕНИЯ ЗАДАЧИ СЕГМЕНТАЦИИ МЕДИЦИНСКИХ ИЗОБРАЖЕНИЙ



О.В. Козлова
Магистрант кафедры
ЭВМ БГУИР



Е.Ю. Куница
Магистрант кафедры
ЭВМ БГУИР



М.М. Лукашевич
Декан ФКСиС БГУИР,
кандидат технических
наук, доцент

Белорусский государственный университет информатики и радиоэлектроники,
Республика Беларусь
E-mail: ooksanakozlova@gmail.com

О.В. Козлова

Окончила БГУИР в 2017 году по специальности Вычислительные машины, системы и сети. С 2017 года учится в магистратуре БГУИР на специальности Технологии виртуализации и облачных вычислений.

Е.Ю. Куница

Окончил БГУИР в 2017 году по специальности Вычислительные машины, системы и сети. С 2017 года учится в магистратуре БГУИР на специальности Технологии виртуализации и облачных вычислений.

М.М. Лукашевич

Кандидат технических наук, доцент, декан факультета компьютерных систем и сетей. Занимается научными исследованиями в области обработки изображений и распознавания образов, нейронных сетей.

Аннотация. Авторами рассмотрен один из самых сложных этапов анализа изображений, а именно сегментация. Наряду с классическими методами и алгоритмами сегментации для сегментации изображений нашли свое применение глубокие нейронные сети, которые позволяют выполнять семантический анализ изображений. Сверточная сеть U-Net позволяет учитывать особенности обработки медицинских изображений и дает приемлемое качество сегментации.

Ключевые слова. Сегментация изображений, сверточные нейронные сети, качество сегментации.

Введение. Изображения являются необходимыми в медицинской диагностике и лечении, так как позволяют врачам поставить верный диагноз. Наиболее важной частью медицинской обработки изображений является сегментация изображений. С помощью сегментации выделяются границы тканей и органов.

Сегментация изображений - это процесс разделения изображения на составляющие части или объекты в изображении, то есть наборы пикселей. Чтобы найти и идентифицировать границы объектов в изображении, пиксели оцениваются по некоторым критериям однородности, таким как цвет, интенсивность или текстура [1].

Недавние преимущества в области обработки медицинских изображений связаны главным образом с применением методов глубокого обучения, которые позволяют эффективно изучать особенности объектов непосредственно из данных визуализации.

К методам глубокого обучения, которые применяются для сегментации медицинских изображений относятся сверточные нейронные сети (CNN) и полностью сверточные нейронные сети (FCN) [3].

Особенности семантической сегментации медицинских изображений. Автоматизированная сегментация медицинских изображений является сложной задачей из-за большого разнообразия форм и размеров анатомии между пациентами. Кроме того, низкая контрастность с окружающими тканями может затруднить автоматическую сегментацию.

Сегментация аномалий на медицинских изображениях требует более высокого уровня точности, чем на естественных изображениях. Точная маска сегментации может не иметь решающего значения на естественных изображениях, но даже незначительные ошибки сегментации на медицинских изображениях могут привести к снижению качества работы пользователя в клинических условиях. Поэтому желательно использовать архитектуры сегментации изображений, которые могут эффективно восстанавливать мелкие детали целевых объектов в медицинских изображениях.

Для работы с классическими нейронными сетями требуется большое количество данных, однако тысячи тренировочных образов обычно недоступны для медицинских задач [3].

Сеть U-Net. Сверточная сеть U-Net была разработана с учетом особенностей обработки медицинских изображений. Она позволяет достичь высокой точности и использует небольшой набор данных.

Сеть обучается сквозным способом на небольшом количестве изображений и превосходит предыдущий наилучший метод (сверточную сеть со скользящим окном) на соревновании ISBI по сегментации нейронных структур в электронно-микроскопических стеках. Используя ту же сеть, которая была обучена на изображениях световой микроскопии пропускания, U-Net заняла первое место в конкурсе ISBI 2015 года по трекингу клеток в этих категориях с большим отрывом [4].

Unet соответствует архитектуре кодер-декодер. Кодировщик постепенно уменьшает пространственное измерение с помощью объединения слоев, а декодер постепенно восстанавливает детали объекта и пространственное измерение. Также существуют быстрые соединения от кодера к декодеру, чтобы помочь декодеру лучше восстановить детали объекта. [5]

Сеть не имеет полностью соединенных слоев и использует только действительную часть каждой свертки, то есть карта сегментации содержит только пиксели, для которых полный контекст доступен во входном изображении. Для качественной сегментации Unet увеличивает количество данных путем деформации имеющихся изображений.

На рисунке 1 приведена архитектура сети для изображения с разрешением 32×32 пикселя. Каждый синий квадрат соответствует многоканальной карте признаков. Количество каналов приведено в верхней части прямоугольника. Размер x - y приведен в нижнем левом краю прямоугольника. Белые прямоугольники представляют собой копии карты свойств.

Сеть U-Net состоит из сокращающейся части (левая сторона) и расширяющейся части (правая сторона).

Сужающаяся часть соответствует типичной архитектуре сверточной сети. Она состоит из многократного применения двух сверток размером 3×3 (свертка без отступов), за которыми следует функция активации ReLU. Затем идет слой субдискретизации с фильтром 2×2 и шагом 2 для уплотнения карты признаков. На каждом шаге понижающей дискретизации мы удваиваем количество каналов признаков.




Рисунок 1. Архитектура сети U-Net

Каждый шаг в расширяющейся части состоит из повышающей дискретизации карты объектов, за которой следует:

- свертка размером 2x2 («свертка вверх»), которая вдвое уменьшает количество каналов признаков;
- объединение с соответствующим образом обрезанной картой признаков из сокращающейся части;
- две свертки размера 3x3;
- за каждой сверткой следует функция активации ReLU.

Обрезка необходима из-за потери граничных пикселей в каждой свертке. На последнем слое свертка размера 1x1 используется для отображения каждого 64-компонентного вектора признаков на требуемое количество классов.

Всего в сети 23 сверточных слоя. Чтобы обеспечить бесшовное разбиение карты выходной сегментации, важно выбрать размер входного фрагмента так, чтобы все операции слоя субдискретизации с фильтром 2x2 применялись к слою, у которого длина и ширина кратны двум [6].

Dataset. Для решения задачи семантической сегментации необходим набор данных, который содержит маски объектов. Поэтому для обучения нейронной сети U-Net использовался датасет с медицинскими изображениями, который предоставлялся в рамках конкурса “Data Science Bowl 2018”.

Суть конкурса заключалась в идентификации клеточных ядер. Идентификация ядер позволяет исследователям идентифицировать каждую отдельную клетку в образце, и, измеряя, как клетки реагируют на различные обработки, исследователь может понять основные биологические процессы на работе. Этот набор данных содержит изображения сегментированных ядер. Данные разделены на две части:

- 620 изображения для обучения;
- 50 изображений для проверки.

Изображения были получены в различных условиях и различаются по типу клеток, масштабу и цвету. Набор данных предназначен для проверки способности алгоритма обобщать эти вариации. На Рисунке 2 представлены примеры изображений из обучающего набора.




Рисунок 2. Изображения обучающего набора

Каждому изображению из обучающего набора соответствует несколько изображений с масками ядер клеток. Каждая маска содержит одно ядро. Маски не могут перекрываться (ни один пиксель не принадлежит двум маскам). На Рисунке 3 приведен пример масок. В тестовом наборе находятся только изображения клеток [7].



Рисунок 3. Маски объектов

Эксперименты. Для анализа работы нейронной сети U-Net было проведено три эксперимента. В них изменялись loss-функция и оптимизационный алгоритм, который обновляет веса нейронной сети. В каждом эксперименте нейронная сеть обучалась 200 эпох.

Эксперимент №1. В первом эксперименте используется оптимизатор стохастического градиентного спуска (Stochastic gradient descent), а в качестве loss-функции выступает функция перекрёстной энтропии.

Формула перекрёстной энтропии определяет близость двух распределений (1):

$$H(p, q) = -\sum p(x) \cdot \log q(x) \quad (1)$$

где p - распределение данных, предсказанных сетью, а q - распределение исходных данных.

Стохастический градиентный спуск относится к оптимизационным алгоритмам. При стохастическом градиентном спуске значение градиента аппроксимируется градиентом функции стоимости, вычисленным только на одном элементе обучения. Затем параметры изменяются пропорционально приближенному градиенту. Таким образом параметры модели изменяются после каждого объекта обучения. Для больших массивов данных стохастический градиентный спуск может дать значительное преимущество в скорости по сравнению со стандартным градиентным спуском.

Эксперимент №2. Вторая модификация сети использует Adam в качестве оптимизатора и функцию перекрёстной энтропии в качестве loss-функции.

Алгоритм Адама - оптимизационный алгоритм адаптивной оценки момента, который является расширением стохастического градиентного спуска. Он сочетает в себе и идею накопления движения и идею более слабого обновления весов для типичных признаков.

Преимущества использования Адама для задач оптимизации:

- вычислительно эффективен;
- маленькие требования к памяти;
- инвариант к изменению масштаба градиента по диагонали;
- хорошо подходит для задач, которые являются большими с точки зрения данных и/или параметров;
- подходит для задач с очень шумными или редкими градиентами;
- гиперпараметры имеют интуитивно понятную интерпретацию и обычно требуют небольшой настройки.

Эксперимент №3. В третьей модификации сети в качестве оптимизатора используется алгоритм Adam, а в качестве loss-функции средняя квадратическая ошибка (Mean Square Error). Средняя квадратическая ошибка определяется формулой(2):

$$E = \frac{1}{P} \sum_{i=1}^P (d_i - y_i)^2 \quad (2)$$

где P - количество обработанных нейронной сетью примеров, y_i - реальный выход нейронной сети, d_i - желаемый (идеальный) выход нейронной сети.

Оценка экспериментов. Для оценки решений использовалась метрика Jaccard Index. Анализ метрики проводился каждые 20 эпох. Схематично данную метрику можно пояснить с помощью кругов Эйлера (см. рисунок 4). Jaccard Index изменяется на промежутке от 0 до 1. При этом в задаче метрики считалась одновременно для всех картинок. Плохое предсказание на одной картинке значительно влияло на финальную метрику. Поэтому требовалось избегать ложноположительных срабатываний.

Результаты. На рисунке 5 приведены значения Jaccard Index для трех экспериментов.




Рисунок 4. Пересечение реального ядра клетки A с предсказанным ядром B

Результаты




Рисунок 5. Результаты экспериментов

Выводы. Проведены эксперименты по использованию нейронной сети U-NET для решения задачи сегментации медицинских изображений. Результаты экспериментов показали целесообразность использования данного подхода для семантического анализа изображений. Отдельные результаты показывают, что U-NET сеть быстрее обучается и даёт хорошие результаты с использованием Adam оптимизатора, изменение же loss-функции практически не влияет на результаты.

Литература

- [1]. Alireza Norouzi, Mohd Shafry Mohd Rahim, Ayman Altameem, Tanzila Saba, Abdolvahab Ehsani Rad, Amjad Rehman & Mueen Uddin (2014) Medical Image Segmentation Methods, Algorithms, and Applications, IETE Technical Review, 31:3, 199-213
- [2]. Cornell University [Electronic resource]. – Mode of access: <https://arxiv.org/pdf/1803.08691.pdf>. – Date of access: 21.01.2019.
- [3]. Cornell University [Electronic resource]. – Mode of access: <https://arxiv.org/pdf/1807.10165.pdf>. – Date of access: 21.01.2019.
- [4]. Vision [Electronic resource]. – Mode of access: <https://lmb.informatik.uni-freiburg.de/people/ronneber/isbi2015/>. – Date of access: 21.01.2019
- [5]. Qure.ai Blog [Electronic resource]. – Mode of access: <http://blog.quire.ai/notes/semantic-segmentation-deep-learning-review>. – Date of access: 21.01.2019.
- [6]. Cornell University [Electronic resource]. – Mode of access: <https://arxiv.org/pdf/1505.04597.pdf>. – Date of access: 21.01.2019.
- [7]. Kaggle [Electronic resource]. – Mode of access: <https://www.kaggle.com/c/data-science-bowl-2018>. – Date of access: 21.01.2019.

U-NET FOR SOLVING THE PROBLEM OF MEDICAL IMAGES SEGMENTATION

O.V. KOZLOVA

Master student of BSUIR

E.Y. KUNITSA

Master student of BSUIR

M.M. LUKASHEVICH, PhD

Dean of the Faculty of Computer Systems and Networks of BSUIR

*Belarusian State University of Informatics and Radioelectronics, Republic of Belarus
E-mail: ooksanakozlova@gmail.com*

Abstract. The authors considered one of the most difficult stages of image analysis, namely segmentation. Along with classical methods and segmentation algorithms for image segmentation, deep neural networks have been applied, which allow performing semantic image analysis. U-NET convolutional network allows to take into account the features of medical image processing and provides an acceptable segmentation quality.

Keywords: image segmentation, convolutional neural networks, segmentation quality.