

# Анализ изображений микросхем на основе свёрточной нейронной сети

И.Н. Колобов<sup>1</sup>, А.В.Коробейников<sup>1</sup>, А.Г. Ложкин<sup>1</sup>

<sup>1</sup> Ижевский Государственный Технический Университет имени М.Т. Калашникова, Студенческая 7, Ижевск, Россия, 426069

**Аннотация.** В работе рассматривается анализ изображений микросхем с помощью искусственной нейронной сети. Для работы использовалась свёрточная сеть кодировщик-декодер (Encoder-Decoder Convolutional Neural Network, ED-CNN) на основе архитектуры U-Net для определения границ элементов транзисторов – задача сегментации изображений микросхем. В результате работы получена точность в среднем 90% по определению принадлежности пикселей (binary accuracy) и 16% потерь по бинарной перекрестной энтропии (binary cross entropy) на тестовой выборке. Предложенная система эффективно решает задачу сегментации изображений микросхем на основе стандартных блоков современных сверточных нейронных сетей.

## 1. Введение

Проблема сегментации изображений является одной из наиболее сложных в процессе обработки и анализа изображений. Сегментация обычно предшествует другим стадиям анализа и ошибки определения границ объектов на этом шаге влияют на все другие. В данной работе рассматривается работа с рентгеновскими изображениями транзисторов.

В мире используется все больше микросхем и компонентов для них проанализировать все уже не представляется возможным. Поэтому использование технических средств для анализа становится необходимостью.

Сейчас интерес к глубинному обучению очень высок в связи с доступностью вычислительных мощностей. Под глубоким обучением поднимется ветвь машинного обучения где используются алгоритмы, которые моделируют сложные абстракции с помощью множества обрабатывающих слоев. В таких моделях обычно используются конволюционные нейронные сети. Одними из наиболее успешных сетей являются сети кодировщик-декодер, состоящие из сети кодировщика, соответствующей сети декодера и слоя для классификации.

Целью работы является изучение методов глубокого обучения и сетей для изучения сегментации изображений транзисторов и других компонентов.

## 2. Проведение эксперимента

Исследование было проведено на выборке из 20 размеченных изображений и группе для валидации, размером 256 на 256 пикселей. Все изображения были черно-белыми. Перед передачей на вход сети изображения случайным образом преобразовывались: сдвигались, поворачивались и масштабировались. Точно такое же преобразование проходило и размеченное изображений, чтобы сеть обучалась. Целью данных манипуляций было научить

сеть работать вне зависимости от положения изображений и подготовить к невиданным ранее изображениям.

Базовые элементы архитектуры U-net представлены сверточным(кодировщиком) и обратным сверточным(декодером) слоем. Кодировочная часть состоит из 4 одинаковых модулей в начале идут два конволюционных слоя с нормализацией[1] и слой субдискретизации. Декодер тоже состоит из 4 частей: в начале идет апсемплинг, затем два конволюционных слоя с нормализацией. В качестве функции активации использовался Relu[2]. На вход декодирующему слою дополнительно подавался выход соответствующего кодировщика для уменьшения ошибок при оптимизации и увеличения возможного числа слоев. На последнем слое использовалась сигмоидальная функция активации:

$$y = \frac{1}{1 + e^{-x}} \quad (1)$$

Структура сети представлена на рисунке 1.

Для эксперимента были использованные следующие параметры:

- 1) Размер входного и выходного изображения 256x256 пикселей.
- 2) Размер батча в 10 изображений.
- 3) Число эпох 50, в каждой эпохе 100 поколений.

В качестве оптимизационного алгоритма использовался стохастический градиентный спуск.

Для проведения экспериментов на основе предложенной структуры нейронной сети для подсчета ошибки и функции потерь была использована библиотека Keras.

В качестве критерия оптимизации использовалась бинарная перекрестная энтропия. Под ошибкой здесь понималась разница между желаемой и действительной вероятностью принадлежности к классу. Если представить черно-белое изображение в виде одномерного массива:

$$y = (y_1, y_2 \dots y_n) \quad (2)$$

где значения  $y_i$  лежат в отрезке  $[0;1]$ . Тогда формула потерь будет:

$$L = - \sum_i y_i \log y_i - \sum_i (1 - y_i) \log(1 - y_i) \quad (3)$$

где  $y$  ожидаемое изображение.




Рисунок 1. Структура нейронной сети.


### 3. Результаты работы

Результаты работы нейронной сети в виде метрик качества представлены в таблице 1.

Полученные в ходе работы изображения представлены на рисунке 2. Полученные результаты показывают работоспособность сети и применимость сетей для данного класса задач. На размеченных сетью изображениях присутствуют неточности и маленькие артефакты. На рисунке 2 слева находятся исходные изображения, справа размеченные людьми изображения, а по центру полученные после обработки сетью. Изображения А и В были в обучающей выборке, хоть и имеют ошибки, не такие значительные как С и D из тестовой. Большая ошибка на С и D объясняется отсутствием похожих примеров в обучающей выборке.

**Таблица 1.** Результаты работы нейронной сети на выборках.

	Binary cross entropy	Binary accuracy
Обучающая	0,35	0,83
Тестовая	0,15	0,90



**Рисунок 2.** Примеры работы нейронной сети.

#### 4. Заключение

Результаты, полученные в этой работе, позволяют говорить о применимости ED-CNN для сегментации изображений транзисторов. Однако получаемые разбиения получаются не идеальными, что может влиять на некоторые задачи.

Система эффективно решает задачу будучи основанной на стандартных блоках современных сверточных сетей, что упрощает ее создание развитие и поддержку.

#### 5. Литература

- [1] Ioffe, S. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift / S. Ioffe, C. Szegedy // ArXiv:1502.03167v3.
- [2] Fred, A. Deep Learning using Rectified Linear Units (ReLU) / A. Fred, M. Agarap // ArXiv:1803.08375v2.

- [3] Skollet, F. Keras, Keras [Электронный ресурс] – Режим доступа: <https://github.com/fchollet/keras> (10.11.2018).
- [4] Николенко, С. Глубокое обучение / С. Николенко, А. Кадури, Е. Архангельская – СПб.: Питер, 2018. – 480 с.
- [5] Хайкин, С. Нейронные сети: полный курс – М.: Издательский дом “Вильямс”, 2006. – 1104 с.
- [6] LeCun, Y. Bengio: Convolutional Networks for Images, Speech, and Time-Series / Y. LeCun // The Handbook of Brain Theory and Neural Networks – MIT Press, 1995.

## The microcircuit images analysis based on convolutional neural network

I. Kolobov<sup>1</sup>, A. Korobeynikov<sup>1</sup>, A. Lozhkin<sup>1</sup>

<sup>1</sup> Kalashnikov Izhevsk State Technical University, Studencheskaya 7, Izhevsk, Russia, 426069

**Abstract.** The paper deals with the analysis of microcircuit images using an artificial neural network. It was used a convolutional network encoder-decoder (Encoder-Decoder Convolutional Neural Network, ED-CNN) based on the U-net architecture to determine the boundaries of transistor elements: the task of segmentation of microcircuit images. As a result, was obtained an average binary accuracy of 90% for determining the ownership of pixels and 16% loss for binary cross entropy on the test sample. The proposed system effectively solves the problem of segmentation of microcircuit images based on standard blocks of modern convolutional neural networks.