

ОПРЕДЕЛЕНИЕ ДЕФЕКТОВ НА ИЗДЕЛИЯХ МИКРОЭЛЕКТРОНИКИ В РЕЖИМЕ РЕАЛЬНОГО ВРЕМЕНИ  
ПРИ ПОМОЩИ СВЕРТЧОЧНОЙ НЕЙРОННОЙ СЕТИ

REAL-TIME DEFECT DETECTION ON MICROELECTRONIC COMPONENTS USING A CONVOLUTIONAL NEURAL NETWORK

**Рубцов Ю.В.** генеральный директор, главный конструктор, +7 (926) 009-37-00, rubtsov@deyton.ru,  
**Малышев В.Э.** инженер лаборатории унификации и замещения, malyshev@deyton.ru,  
**Назаренко А.А.** инженер лаборатории унификации и замещения; nazarenko@deyton.ru,  
АО «ЦКБ «Дейтон»

**Rubtsov Yu.V.**, general director, head of chair, chief designer, +7 (926) 009 37 00, rubtsov@deyton.ru,  
**Malyshev V.E.**, engineer of the unification and substitution laboratory, malyshev@deyton.ru,  
**Nazarenko A.A.**, engineer of the unification and Substitution Laboratory, nazarenko@deyton.ru,  
JSC central design office "Deyton"

**Аннотация.** Данная статья посвящена применению сверточной нейронной сети для обеспечения автоматизированного контроля качества изделий микроэлектроники в режиме реального времени. Была обучена сверточная нейронная сеть для поиска дефектов на корпусах для интегральных микросхем. Результаты экспериментов демонстрируют высокую точность и скорость обнаружения дефектов при использовании сверточной нейронной сети, что подтверждает ее потенциал в применении для решения задач контроля качества.

**Annotation.** This article is dedicated to the application of a convolutional neural network for ensuring automated real-time quality control of microelectronic components. A convolutional neural network was trained to detect defects on the casings of integrated circuits. The experimental results demonstrate high accuracy and speed of defect detection when using the convolutional neural network, confirming its potential for quality control applications.

**Ключевые слова:** сверточная нейронная сеть, поиск дефектов, компьютерное зрение, контроль качества.

**Keywords:** convolutional neural network, defect detection, computer vision, quality control.

**Научная специальность:** 2.3.5. Математическое и программное обеспечение вычислительных систем, комплексов и компьютерных сетей.

## Введение

В современной микроэлектронике контроль качества изделий играет решающую роль в обеспечении надежной работы электронных устройств. С уменьшением размеров компонентов, традиционные методы контроля, такие как визуальный осмотр, не всегда обеспечивают высокую эффективность при обнаружении мельчайших дефектов в реальном времени.

В последние годы нейросетевые методы стали популярным средством для решения задач компьютерного зрения, включая обнаружение объектов на изображениях [1]. Сверточные нейронные сети позволяют крайне точно и быстро определять нужные объекты на изображениях, даже в условиях ограниченной освещенности или изменяющейся сцены.

Целью данной статьи является исследование возможности применения сверточной нейронной сети для обнаружения дефектов на изделиях микроэлектроники в режиме реального времени.

## Основная часть

Распознавание объектов на изображении успешно осуществляется при помощи сверточной нейронной сети, представляющей собой математическую модель, состоящую из взаимосвязанных искусственных нейронов.



Ю.В. Рубцов



В.Э. Малышев



А.А. Назаренко

Входные данные представлены в виде вектора признаков, который последовательно проходит через слои нейросети, а на выходе получаются вероятности принадлежности объекта к заданным классам [2]. Обычно нейронная сеть работает с числовыми данными, а не символьными.

На рис. 1 изображена схема искусственного нейрона, принимающего на вход параметры  $X_1, X_2, X_3, X_4, \dots, X_n$ , которые могут быть как исходными данными, так и выходными параметрами других нейронов. У каждого параметра есть свой вес  $W$ , на который умножается его значение. Затем взвешенные параметры суммируются, а полученное значение отправляется в функцию активации, которая после вычисления результата принимает решение о том, передавать ли сигнал следующему нейрону.




Рис. 1. Схема искусственного нейрона

Сверточная нейронная сеть состоит из нескольких различных слоев. На рис. 2 представлена подробная структура сверточной нейронной сети [3].




Рис. 2. Структура сверточной нейронной сети

### Входной слой

Входные данные [32x32x3] будут содержать необработанные значения пикселей изображения. В данном случае, изображение шириной 32, высотой 32 и тремя цветовыми каналами (RGB) показано на входных данных (INPUT) на рис. 2.

### Сверточный слой

Сверточный уровень является основой сверточной нейронной сети. Параметры уровня свертки состоят из набора обучаемых фильтров. Каждый фильтр пространственно невелик по ширине и высоте, но простирается на всю глубину входного объема. Например, типичный фильтр на первом слое сверточных сетей может иметь размер 5x5x3, ширину и высоту в 5 пикселей, а также 3 пикселя в глубину (цветовые каналы). Во время прямого прохода мы перемещаем (свертываем) каждый фильтр по ширине и высоте входного объема и вычисляем точечные произведения между элементами фильтра и входными данными в любом положении. Перемещая фильтр по ширине и высоте входного объема, мы создаем двумерную карту активации, которая отображает отклики этого фильтра в каждом пространственном положении. Интуитивно сеть распознает фильтры, которые активируются, когда они видят какие-либо визуальные особенности, такие как край определенной ориентации или пятно определенного цвета. После получения полного набора фильтров в каждом слое свертки, каждый из них создаст отдельную двумерную карту активации. Если мы сложим эти карты активации по измерению глубины, то получим выходной объем [4]. Пример двумерных сверток показан на рис. 3. На данном примере мы ограничиваем вывод только позициями, в которых фильтр или ядро полностью находятся внутри изображения. Прямоугольники со стрелками показывают, как создается верхний левый элемент выходных данных путем применения фильтра к соответствующей верхней левой области входных данных.




Рис. 3. Работа с двумерными вертками

### ReLU

ReLU расшифровывается как выпрямленная линейная единица и является нелинейной операцией (англ. rectified linear unit). ReLU - это поэлементная операция, применяющаяся для каждого пикселя, которая заменяет все отрицательные значения пикселей на карте объектов на ноль. Цель ReLU - ввести нелинейность в нашу нейронную сеть, поскольку нам нужно, чтобы большая часть реальных данных, которые требуется изучить нашей нейронной сети, была нелинейной (свертка - это линейная операция поэлементного умножения и сложения матриц, поэтому мы учитываем нелинейность, вводя нелинейную функцию, подобную ReLU).

### Пулинговый слой

Пулинговый слой отвечает за уменьшение пространственного размера карт активации, сохраняя наиболее важную информацию. Как правило, они используются после нескольких повторений других уровней сверточности и нелинейности, чтобы постепенно снижать вычислительные требования к сети, а также сводить к минимуму вероятность переобучения [5].

### Полносвязный слой

Полносвязный слой — это слой, в котором каждый нейрон соединен со всеми нейронами на предыдущем уровне [6]. Математически, данный слой может быть описан следующей формулой:

$$y = \text{activation}(W \times x + b),$$

где  $y$  — выходные данные слоя;

$x$  — входные данные (вектор), полученные из предыдущего слоя;

$W$  — матрица весов, которая соединяет входные и выходные данные;

$b$  — вектор сдвига, который добавляется к выходным данным;

activation — функция активации, которая применяется к выходным данным.

Функция активации может быть различной в зависимости от задачи и выбора алгоритма. Наиболее подходя-

щей функцией активации для осуществления контроля качества является ReLU.

#### Выходной слой

После того, как все предыдущие слои были связаны с помощью полносвязного слоя, наступает время для классификации выходных данных. Для того, чтобы понять, каким именно образом это работает, приведем небольшой пример: предположим, что мы провели обучение сверточной нейронной сети на наборе изображений, который имеет 2 класса: X и O. После обучения, мы предоставляем входные данные для классификации. Наш результат будет отображаться в виде 0 или 1. Как мы можем видеть в таблице 1, X представлен как 1, а O представлен как 0. Существует 94 %-ная вероятность того, что изображение принадлежит к классу X и 52 %-ная вероятность принадлежности к классу O. Таблица также показывает, что из 54 % от вероятности ошибки, 6 % приходится на X и 48 % на O. В зависимости от этих вероятностей, сверточная нейронная обнаруживает и классифицирует изображения.

Таблица 1

Вычисление ошибки

|       | Вероятность правильной классификации | Вероятность ошибки |
|-------|--------------------------------------|--------------------|
| X (1) | 0,94                                 | 0,06               |
| O (0) | 0,52                                 | 0,48               |

#### Методология контроля качества

В процессе посещения завода по производству корпусов для интегральных микросхем и тщательного изучения линии контроля качества, стало понятно, что данный процесс может быть выполнен с помощью сверточной нейронной сети, что позволит значительно сократить время и существенно повысить точность отбраковки. Для реализации данного проекта был сформирован датасет, состоящий из более, чем 2000 изображений корпусов, которые были разделены на два класса: корпус со стеклом и корпус с раковинной. На рис. 4 продемонстрирован пример корпуса с дефектом «раковина».




Рис. 4. Пример корпуса с раковинной

#### Обучение

После того, как изображения были получены, датасет был разделен в соотношении 3:1 на две части: снимки для обучения и снимки для валидации. Далее была осу-

ществлена разметка браков на изображениях и проведено обучение сверточной нейронной сети. Результат обучения представлен на рис. 5.




Рис. 5. Результат обучения

#### Результаты

Завершающим этапом стала проверка работы сверточной нейронной сети на реальных корпусах, в таблице 2 приведены результаты данной проверки.

Таблица 2

Среднее значение точности проведенных тестов

|           | Обучение, % | Валидация, % | Тестирование на реальных корпусах, % |
|-----------|-------------|--------------|--------------------------------------|
| Тест 1    | 91,89       | 86,94        | 81,46                                |
| Тест 2    | 91,92       | 87,95        | 81,95                                |
| Тест 3    | 91,87       | 87,82        | 83,34                                |
| Тест 4    | 91,90       | 87,91        | 81,67                                |
| Тест 5    | 91,94       | 88,16        | 82,19                                |
| Ср. знач. | 91,90       | 87,76        | 82,12                                |

#### Заключение

В данной статье был описан метод классификации изделий микроэлектроники с целью контроля качества с использованием сверточной нейронной сети. Эффективность данного способа поиска дефектов была подтверждена тестированиями по их обнаружению на корпусах для интегральных микросхем.

#### Литература:

1. Lecun Y., 2011. Traffic Sign Recognition with Multi-Scale Convolutional Networks.

2. Socher R., Huval B., Bhat B., Manning C. D., Ng A.Y., 2012. Convolutional-Recursive Deep Learning for 3D Object Classification.
3. LeCun Y., Bottou L., Bengio Y., Haffner P. Gradient Based Learning Applied to Document Recognition // PROC OF THE IEEE. 1998.
4. Goodfellow I., Bengio Y., Courville A. Deep Learning. The MIT Press, 2016.
5. Zhao L., Zhang Z. A improved pooling method for convolutional neural networks // Scientific Reports. 2024.
6. Basha S.S., Dubey S.R., Pulabaigari V., Mukherjee S. Impact of Fully Connected Layers on Performance of Convolutional Neural Networks for Image Classification // Neurocomputing. 2019.