

---

УДК 004.9

А.В. ЗОЛОТУХИН, студент (КНИТУ им. А.Н. Туполева – КАИ)  
Научный руководитель: В.В. МОКШИН, к.т.н., доцент (КНИТУ – КАИ)  
г. Казань

**СРАВНИТЕЛЬНЫЙ АНАЛИЗ НЕЙРОСЕТЕВЫХ МЕТОДОВ  
РАСПОЗНАВАНИЯ ДЕФЕКТОВ НА ИЗОБРАЖЕНИЯХ**

В настоящее время здоровая рыночная конкуренция заставляет фирмы стремиться к оптимизации производственных процессов. На данный момент все производства хотят внедрить больше процессов автоматизации и качественное планирование производства, сборки и выпуска изделий.

Например, управление и обслуживание отдела по контролю качества в среднем требует от 100 до 200 человек рабочего персонала, каждый из которых за один рабочий день производит оценку качества не более 1200 наименований товаров. В то время как сеть из 15 камер, оснащённых модулями компьютерного зрения и анализа изображений, позволит оценивать качество товаров с большей скоростью, позволит увеличить скорость конвейера и уменьшить процент ошибок при оценке качества изделий на производстве.

Поэтому в современных производствах задача автоматизации процесса контроля качества выпускаемых изделий представляет собой важный прикладной раздел и позволяет решить задачи по управлению, автоматизации и оптимизации производства. Задача контроля качества в практическом плане представляет собой задачу распознавания дефектов на изделиях, выпускаемых производственным цехом. На сегодняшний день существует ряд методов обработки и сегментации изображений, позволяющих распознать объекты на фото или видео. Для изучения данных методов требуется провести исследование методов анализа изображений с помощью нейронных сетей и предиктивных алгоритмов.

Задача анализа изображений является одной из самых сложных задач компьютерного зрения за счет своей нетривиальности и невозможности решения детерминированными полиномиальными алгоритмами. Для решения подобных сложно формализуемых задач активно используются методы машинного обучения и нейронных сетей.

В решении задач анализа изображений преуспели четыре вида нейронных сетей: многослойный перцептрон (MLP), рекуррентная нейронная сеть (RNN), сверточная нейронная сеть (CNN) и нейронная сеть обратной свертки (DNN) [1].

---

Многослойный перцептрон является наиболее известным и наиболее часто используемым типом нейронной сети. В большинстве случаев сигналы внутри сети передаются в одном направлении: от входа к выходу. Эта архитектура называется прямой связью. Многослойность перцептрона выражена тем, что между входным и выходным слоем содержатся слои, которые не связаны напрямую со средой, они называются скрытыми. Первый уровень (входной уровень) – уровень сети, единственная функция которого заключается в передаче входных сигналов в верхние слои. Последний уровень сети (выходной уровень) – уровень сети, единственная функция которого заключается в преобразовании входных сигналов в единственный выходной сигнал (ответ перцептрона) [2].

Сверточная нейронная сеть (CNN) – это класс глубоких искусственных нейронных сетей с прямой связью (где соединения между узлами не образуют цикл), которая состоит из комбинации стандартных слоев многослойных перцептронов, разработанных для минимальной предварительной обработки и сверточных слоев, которые вдохновлены зрительной корой животных. Сверточные нейронные сети (CNN) схожи с традиционными нейронными сетями тем, что они состоят из нейронов, которые оптимизируются посредством обучения. Каждый нейрон будет по-прежнему получать входные данные и выполнять операцию (например, скалярное произведение, за которым следует нелинейная функция) [3].

Глубокие нейронные сети (DNN) относятся к семейству архитектур нейронных сетей, которые имеют несколько уровней вычислений. Технически это граф вычислений, где некоторые узлы являются входными узлами, некоторые выходные узлы, а остальные называются скрытыми узлами. Для простоты мы можем представить каноническую глубокую нейронную сеть, состоящую из нескольких слоев, где слои расположены вертикально друг над другом. Каждый слой состоит из одного или нескольких узлов. Узлы имитируют «нейроны», которые являются вычислительными элементами нашего мозга. Входные данные применяются к входному слою (для простоты представьте, что это самый нижний слой), а выходные данные создаются на выходном слое (представьте, что это самый верхний слой вертикального стека слоев). Поскольку сеть имеет структуру графа, строго вертикальный стек является особым случаем, но мы представляем нашу глубокую нейронную сеть (DNN) как вертикально-слоистую архитектуру с целью ответа на этот вопрос.

Рекуррентная нейронная сеть (RNN) относится к классу искусственных нейронных сетей, в которых соединения между узлами образуют ориентированный граф вдоль временной последовательности. Поэтому, рекуррентные нейронные сети используются для обработки временных последовательностей. Это позволяет им демонстрировать временное динамическое

поведение. Полученные из нейронных сетей с прямой связью, RNN могут использовать свое внутреннее состояние (память) для обработки последовательностей входных данных переменной длины. Это делает их применимыми к таким задачам, как несегментированное распознавание рукописного ввода или распознавание речи.

Для того, чтобы определить оптимальную модель нейронной сети для решения задачи анализа дефектов, было проведено сравнение методов анализа изображений. Сравнение проводилось по скорости и точности работы метода на задачах распознавания.

Для создания модели были протестированы несколько стандартных сетей: MLP-300 (MLP), LSTM (RNN), LeNet5 (CNN), ResUNet (DNN), на наборе данных chars74k20 для распознавания символов. Этот набор данных состоит из рукописных цифр и английских символов, т. е. содержит 62 класса объектов. Для экспериментов по сравнению этот набор данных был поделен на 34658 обучающих изображений (55%), 12586 проверочных изображений (20%) и 15748 тестовых изображений (25%).

Для MLP сети была использована полносвязная модель со скрытым слоем из 300 нейронов. MLP обучается по алгоритму обратного распространения ошибки. Сеть LSTM представляет собой стандартную рекуррентную нейронную сеть с модификацией долгой краткосрочной памяти. Для сети CNN использовалась стандартная модификация LeNet5 с ядром свертки 5x5 и ядром субдискретизации 2x2. Сеть ResUNet структурно представляет собой комбинацию CNN и RNN с чередованием сверточных и полносвязных слоев.

В таблице 1 показана производительность обучения и классификации MLP, LSTM, LeNet5 и ResUNet на наборе данных chars74k. По данным тестов можно видеть, что CNN, RNN и DNN превосходят MLP в примерно 1,35 раза по точности обучения и в 2 раза по точности классификации. Среди нейронных сетей можно выделить лидерство ResUNet.

Таблица 1  
Сравнение точности обучения нейросетей

Нейросеть	Точность обучения (%)	Точность классификации (%)
MLP-300 (MLP)	70.72	43.4
LSTM (RNN)	88	88.39
LeNet5 (CNN)	86.23	85.53
ResUNet (DNN)	89.90	90.56

Также была проведена оценка времени обучения и классификации на GPU на наборе данных chars74k. Таблица 2 показывает общее время

обработки для обучения и классификации всех символов набора данных с использованием размера батча в 64 символа.

Таблица 2

Сравнение времени обучения нейросетей

Нейросеть	Обучение (с.)	Классиф. (с.)	Класс. 1 симв. (мс.)
LSTM (RNN)	120	10	0.635
LeNet5 (CNN)	100	10	0.635
ResUNet (DNN)	556	19	1.2

На основании полученных результатов было принято решение для решения задачи анализа дефектов использовать глубокую нейронную сеть (DNN) модели ResUNet.

Для программной реализации выбранных алгоритмов сегментации и распознавания была спроектирована и обучена сверточная нейронная сеть, написанная на языке Python версии 3.7. Разработанная нейронная сеть решает задачу анализа изображений на наличие дефектов.

На вход нейронной сети поступают изображения поверхности металла размером 250 на 1600 пикселей, на которых может присутствовать 4 вида дефектов, в разных количествах и комбинациях. Тренировочная выборка состоит из 12600 изображений, тестовая из 5000. В тренировочной выборке только 6700 изображений имеют различные дефекты, остальные 5900 дефектов не имеют. Таким образом на входной слой нейронной сети поступает трехканальное изображение 250x1600: 4500000 параметров. На выходном слое – 5 однозначно определяемых классов.

В качестве сторонней библиотеки для реализации нейронной сети была выбрана Python-библиотека TensorFlow. TensorFlow – это открытая программная библиотека для машинного обучения.

За стандартную модель нейросети была взята модель ResUNet которая архитектурно состоит из следующих слоев:

1. Слой нормализации батча (BatchNorm)
2. Полносвязный слой с активацией ReLU
3. Сверточный слой (Conv2D)
4. Слой нормализации батча (BatchNorm)
5. Полносвязный слой с активацией ReLU
6. Сверточный слой (Conv2D)
7. Выходной полносвязный слой из 5 нейронов

Точность предсказания нейросети в конце обучения на обучающей и валидационной выборках была соответственно равна 0.7985 и 0.7505, график роста точности представлен на рис. 1.




Рис. 1. График точности предсказания нейронной сети

На рис.2 представлен результат классификации дефектов.




Рис. 2. Изображение изделия с дефектами 2 типов

Результат работы разработанного ПО демонстрирует высокую точность определения дефектов на изделиях, тем самым автоматизирует процесс контроля качества продукции на конвейерных лентах производственного цеха.

#### Список литературы:

1. Zhang Yong, Yuan Jiazheng, LiuHongzhe, Li Qing. Image segmentation algorithms based on structure tensor // The Journal of China Universities of Posts and Telecommunications – 2017. – v. 24-2, pp. 38-47.
2. Cires,an, D.C., Meier, U., Gambardella, L.M., Schmidhuber, J.: Convolutional neural network committees for handwritten character classification. In: Document Analysis and Recognition (ICDAR), 2011 International Conference on. pp. 1135–1139.

3. Marius-Constantin Popescu, Valentina E. Balas, Liliana Perescu-Popescu, Nikos Mastorakis. Multilayer Perceptron and Neural Networks // WSEAS TRANSACTIONS on CIRCUITS and SYSTEMS – Issue 7, Volume 8, July 2009 – pp. 579-588.

Информация об авторах:

Золотухин Александр Владимирович, студент КНИТУ им. А.Н. Туполева – КАИ, Корпус №1, ул. Карла Маркса, 15, Казань, Респ. Татарстан, 420111, avol116@yandex.ru

Мокшин Владимир Васильевич, доцент КНИТУ им. А.Н. Туполева – КАИ, Корпус №1, ул. Карла Маркса, 15, Казань, Респ. Татарстан, 420111, vladimir.mokshin@mail.ru