РАКЕТНО-КОСМИЧЕСКОЕ ПРИБОРОСТРОЕНИЕ И ИНФОРМАЦИОННЫЕ СИСТЕМЫ 2022, том 9, выпуск 4, с. 76–91

____ ТВЕРДОТЕЛЬНАЯ ЭЛЕКТРОНИКА, РАДИОЭЛЕКТРОННЫЕ КОМПОНЕНТЫ, МИКРО- И НАНОЭЛЕКТРОНИКА, ПРИБОРЫ НА КВАНТОВЫХ ЭФФЕКТАХ

УДК 681.142 DOI 10.30894/issn2409-0239.2022.9.4.76.91

Методика применения сверточных нейронных сетей в задаче дефектоскопии интегральных микросхем

А. Ю. Вирясова, acnupaнm, contact@spacecorp.ru

АО «Российские космические системы», Москва, Российская Федерация

Д. И. Климов, к. т. н., contact@spacecorp.ru

АО «Российские космические системы», Москва, Российская Федерация

А.А.Антонова, acnupaнm, contact@spacecorp.ru

АО «Российские космические системы», Москва, Российская Федерация

О.Е.Хромов, к. т. н., contact@spacecorp.ru

АО «Российские космические системы», Москва, Российская Федерация

В. В. Орешко, к. т. н., contact@spacecorp.ru

АО «Российские космические системы», Москва, Российская Федерация

Аннотация. Одним из направлений повышения надежности аппаратуры космических аппаратов является дефектоскопия используемых интегральных микросхем. В статье показано, что для применяемых в настоящее время методик дефектоскопии присущи некоторые проблемные вопросы, снижающие ее эффективность, например влияние человеческого фактора. Для разрешения этих вопросов предложено внедрить в задаче дефектоскопии интегральных микросхем методику, использующую сверточные нейронные сети. Внедрение указанной методики позволит снизить вероятность попадания дефектных микросхем в аппаратуру и своевременно скорректировать схемные, конструктивные и технологические решения для предотвращения случаев возникновения дефектов в будущем.

Ключевые слова: нейронные сети, сверточные нейронные сети, оператор, интегральные микросхемы, дефекты, микроскоп, достоверность классификации

Methodology for the Application of Convolutional Neural Networks in the Problem of Defectoscopy of Integrated Circuits

A. Y. Virjasova, postgraduate student, contact@spacecorp.ru Joint Stock Company "Russian Space Systems", Moscow, Russian Federation

D. I. Klimov, Cand. Sci. (Engineering), contact@spacecorp.ru Joint Stock Company "Russian Space Systems", Moscow, Russian Federation

A. A. Antonova, postgraduate student, contact@spacecorp.ru Joint Stock Company "Russian Space Systems", Moscow, Russian Federation

O.E.Khromov, Cand. Sci. (Engineering), contact@spacecorp.ru

Joint Stock Company "Russian Space Systems", Moscow, Russian Federation

V. V. Oreshko, Cand. Sci. (Engineering), contact@spacecorp.ru Joint Stock Company "Russian Space Systems", Moscow, Russian Federation

Abstract. One of the ways to improve the reliability of spacecraft equipment is the flaw detection of the integrated circuits used. The article shows that for the currently used methods of flaw detection there are some problematic issues that reduce its effectiveness, for example, the influence of the human factor. To resolve these issues, it is proposed to introduce a technique using convolutional neural networks in the problem of integrated circuit flaw detection. The implementation of this technique will reduce the likelihood of defective chips getting into the equipment and timely adjust circuit, design, and technological solutions to prevent the occurrence of defects in the future.

Keywords: neural networks, convolutional neural networks, operator, integrated circuits, defects, microscope, classification reliability

Введение

Цель: Выявление проблемных вопросов существующей системы анализа дефектов интегральных микросхем и разработка методики дефектоскопии интегральных микросхем, в которой отсутствует субъективный фактор в виде оператора.

Постановка задачи: проведение исследований о возможности эффективного применения машинного зрения с целью уменьшения коэффициента входного контроля $K_{\rm BX}$, влияющего на интенсивность отказа интегральных микросхем.

«Параметр надежности определяется периодом времени, в течение которого изделие не изменяет своих свойств. В медицине и космической отрасли этот период достигает 30 лет, в других отраслях в пределах 15–20 лет» [1]. Обратив внимание на участившиеся аварийные ситуации с космическими объектами в России, можно сделать вывод, что российская промышленность не может обеспечить данные показатели надежности. «Исследования отказов определили, что самым ненадежным элементом являются электронные компоненты (ЭК)» [1].

Недостаточно просто выявить наличие дефекта, необходимо также его верно классифицировать и сформировать рекомендации по устранению и дальнейшему его недопущению.

Выделим основные задачи классификации:

 оценить показатели качества поставляемых партий интегральных микросхем и приборов;

 снизить степень риска комплектования радиоэлектронной аппаратуры (РЭА) интегральных микросхем и приборами, несоответствующими требованиям к их конструктивно технологическому исполнению;

 накопить статистические данные об уровнях качества изготовления микросхем и приборов различных типов, а также данные о заводах-изготовителях;

 использовать результаты отбраковки при прогнозировании наиболее вероятного срока активного функционирования (САФ) микросхем и приборов в составе РЭА.

Примеры дефектов интегральных микросхем, используемых для классификации под оптическим микроскопом при увеличении 80× и их названия представлены в табл. 1.

Анализ системы дефектов интегральных микросхем. На рис. 1 представлена существующая система дефектоскопии интегральных микросхем и ее свойства.

Достоверность оператора. «На данный момент классификацию обычно производит оператор, что требует дополнительных затрат, а если учесть ошибки, связанные с человеческим фактором, то необходимость автоматизации данной задачи очевидна» [3].

Согласно статье [4] на достоверность оператора влияет человеческая усталость и степень загруженности задачи ручными операциями, которая «напрямую влияет на процент сведений, содержащих ошибки» [5].

Формула для расчета достоверности оператора $P_{\text{оп}}$:

$$P_{\rm off} = P_{\rm q} \cdot (1 - Q_{\rm 3}(K)), \tag{1}$$

где $P_{\rm q}$ — достоверность ввода оператора в зависимости от времени работы;

 $Q_{\rm 3}$ — процент ошибок ввода данных в зависимости от K;

К — коэффициент загруженности задачи.

Сводная таблица показателей достоверности оператора для задачи дефектоскопии интегральных микросхем приведена в табл. 2.

«Значения эксплуатационной интенсивности отказов ЭРИ рассчитывается по формулам» [6]:

$$\lambda_{\mathfrak{s}} = \lambda_{\mathfrak{f}} \times \prod_{i=1}^{n} K_{i}, \qquad (2)$$

$$\lambda_{\mathfrak{s}} = \lambda_{\mathbf{6.c.r}} \times \prod_{i=1}^{n} K_{i}, \tag{3}$$

где λ_{6} ($\lambda_{6.c.r}$) — базовая интенсивность отказов типа (группы) ЭРИ, рассчитанная по результатам испытаний ЭРИ на безотказность, долговечность, ресурс;

 K_i — коэффициенты, учитывающие изменения эксплуатационной интенсивности отказов в зависимости от различных факторов;

n — число учитываемых факторов.

Таким образом, при расчете надежности прибора, а именно интенсивности отказов $\lambda_{\rm PAA}$, предлагается ввести дополнительный коэффициент входного контроля $K_{\rm BX}$

$$K_{\rm BX} = 1/P_{\rm off} = 1/0.85 = 1.17.$$
 (4)

Наименование дефекта	Вид де	ефекта	Описание дефекта
 Дефекты в нижнем анти- отражающем покрытии 			Наличие дефектов данного типа проявляется в виде радужных пятен круглой формы в нижележащем слое
2. Дефекты типа «искажение рисунка топологии»			Дефект состоит из того же материала, что и сам рисунок топологии
3. Дефекты типа «капля»			Характерным признаком дефектов данного класса является его правильная круглая форма и наличие радужного изменения цвета внутри
4. Дефект типа «материал»			Непрозрачная частица, напоминающая искажение рисунка, но она имеет четкий контур, так как лежит в разных плоскостях с рисунком топологии
5. Дефект типа «частица»			Материал, из которого состоит дефект, отличается от материала рисунка топологического слоя

Таблица 1. Некоторые виды дефектов микросхем [2]



Рис. 1. Состав существующей системы

В табл. З приведены интенсивности отказов приборов с учетом $K_{\rm bx}.$

Как видно из табл. 3, требования по надежности с каждым годом ужесточаются, пересматриваются приоритеты в направлении полной импортонезависимости космического приборостроения, для которой требуется улучшение показателей надежности.

Решение проблемы путем перехода в систему машинного зрения. Применение автоматизированных методов поможет снизить риски классификации дефектов, вызванных человеческим фактором. В данной работе при классификации и поиске особенностей изображений предлагается использование метода машинного обучения.

Дерево показателей системы анализа дефектов интегральных микросхем представлено на рис. 2, а состав предлагаемой системы анализа дефектов интегральных микросхем — на рис. 3.

«Так как основным критерием работы системы дефектоскопии является достоверность, а улучшить ее можно только путем увеличения этой

Характеристика	Оператор принял микросхему	Дефект найден верно	Дефект классифицирован верно	Результат
Оценка количества выполняемых в задаче ручных операций	1	1	1	_
Трудоемкость ввода данных	0	1	1	_
Сложность работы с пользовательским интерфейсом	0	0	1	—
Темп выполнения «ручной» работы	1	0	0	_
Коэффициент загруженности задачи, К	2	2	3	—
Процент ошибок ввода данных, $Q_{\scriptscriptstyle 3}$	0,01	0,1	0,015	_
Достоверность ввода оператора в зависимости от времени работы, $P_{\rm q}$	0,991	0,991	0,991	_
Достоверность оператора, P _{оп}	0,981	0,892	0,976	0,854

Таблица 2. Показатели достоверности оператора для задачи дефектоскопии интегральных микросхем

Таблица 3. Влияние коэффициента $K_{\rm\scriptscriptstyle BX}$ на интенсивность отказов

Год	Требуемая $\lambda_{ m P\Im A}$	Фактическая $\lambda_{ extsf{P} ightarrow A}$	$\lambda_{\mathrm{P} \Im \mathrm{A}}$ с учетом K_{BX} на интегральные микросхемы	$\lambda_{\mathrm{P} earrow A}$ с учетом K_{BX} на все ЭКБ прибора	Запас по надежности
1998	2,00E-06	1,27E-06	1,33E-06	1,49E-06	7,30E-07
2014	6,67E-06	1,45E-06	1,59E-06	1,70E-06	2,74E-07
2016	1,48E-07	2,40E-09	2,76E-09	3,28E-09	1,45E-07
2020	1,10E-07	9,34E-08	1,10E-07	1,23E-07	1,66E-08
2020	6,50E-08	5,11E-08	6,19E-08	6,90E-08	1,39E-08



Рис. 2. Дерево показателей системы анализа дефектов интегральных микросхем



Рис. 3. Состав предлагаемой системы анализа дефектов интегральных микросхем

характеристики у оператора, то предлагается в данной системе оператора заменить на систему машинного зрения» [7].

Методы исследования. При решении поставленных задач были использованы: теория оптимизации и методы обучения нейронных сетей, математический аппарат теории вероятностей, математической статистики, теория обработки изображений, теория искусственного интеллекта и нейронных сетей и методы структурного программирования.

Методика расчета показателей эффективности.

Получим массив пикселей, который представляет собой одно целое изображение и присвоим ему метку. На рис. 4 обобщенно показан алгоритм обработки изображения, который представляет собой набор из трех связанных параметров: вход, обучение и оценка. Разберем их по порядку.

 Вход: включает в себя входные данные, которые состоят из обучающей выборки (набора N изображений, каждое из которых помечено одним из K-различных классов).

- **Обучение:** предполагает использование обучающего набора для определения того, как выглядит каждый из классов. Такой шаг называется *мо- делью обучения*.

- **Оценка:** в итоге оценивается качество классификатора с добавленным в него набором новых



Рис. 4. Алгоритм обработки изображения

изображений, который он никогда не видел прежде. Так эти образы будут сравниваться с уже заложенными в классификаторе.

Для корректного анализа результатов необходимо рассчитать метрики качества.

Ниже представлены основные метрики:

1. «Ассигасу — доля правильных ответов алгоритма, это тот самый показатель, который в дальнейшем будет сравниваться с достоверностью оператора $P_{\text{оп}}$ » [8]:

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

2. «Precision — доля объектов, названных классификатором положительными и при этом действительно являющихся положительными» [8]:

precision
$$= \frac{TP}{TP + FP}.$$

3. «Recall — доля объектов положительного класса, которую нашел алгоритм из всех объектов положительного класса» [8]:

$$\operatorname{recall} = \frac{TP}{TP + FN}.$$

Для вычисления этих метрик необходимо знать 4 вида прогноза TruePositive (TP — верно положительные ответы), TrueNegative (TN верно отрицательные ответы), FalsePositive (FP ошибочно положительные ответы), FalseNegative (FN — ошибочно отрицательные ответы).

Определение пути решения задачи

1. Существующие методы классификации изображений

На данный момент имеются следующие основные методы классификации изображений, а именно: метод k-ближайших соседей, нейронные сети прямого распространения и сверточные нейронные. Ниже будут рассмотрены преимущества и недостатки каждого из них.

Основные недостатки полносвязных нейронных сетей:

низкая скорость обучения и большое количество обучаемых параметров,

 отсутствие возможности реализации алгоритмов обучения сети на графических процессорах (GPU) и распараллеливания вычислений,

- «восприимчивость к сдвигу позиции объекта во входных данных» [9].

Основные недостатки метода *k*-ближайших соседей:

 – «необходимость сохранения огромной базы эталонов и сравнения входного изображения с каждым из базы данных» [9],

 высокая восприимчивость этого метода к положению объектов на поле классификатора, поворотам и масштабированию.

В результате классификаций изображений были получены следующие показатели метрик (табл. 4).

Таблица 4. Показатели метрик методом классификации *k*-ближайших соседей

Метод	recall	precision	acc
<i>k</i> -ближайших соседей	0,133	0,149	0,799
Нейронные сети прямого распространения	0,442	0,805686	0,6035
Сверточные нейронные сети	0,98	0,99	0,98

Все эти недостатки решаются при помощи сверточных нейронных сетей.

«Для правильной работы нейронной сети необходимо подобрать нужную библиотеку» [2]. Далее будет показано сравнение библиотек глубокого обучения. Рассматриваются только четыре основных библиотеки: Caffe и Torch — самые используемые, а также Keras + Theano и Keras + TensorFlow — самые зрелые и функционально развитые; их основные параметры представлены в табл. 5.

В результате анализа показано, что для библиотек Keras, Torch, Caffe и TensorFlow время обучения 4 слоев составило 30 секунд, а библиотеки Deeplearning4J — 210 секунд. Время прогнозирования для библиотек Keras, Torch, Caffe и TensorFlow составило от 0,2 до 0,3 секунд, библиотеки Deeplearning4J — 1,1 секунду. Наилучшую точность показала библиотека Keras (98%), далее идет Deeplearning4J (97%), Caffe (95%) и гораздо менее точными оказались TensorFlow (87%) и Torch (84%).

Был выполнен анализ исходных фреймворков в строках исходного кода, необходимых для реализации соответствующего алгоритма, а также их языков программирования интерфейса; результаты показаны на рис. 5.



Рис. 5. Кодовая сложность, измеряемая как количество строк кода, необходимых для реализации алгоритма

Подводя итог, можно сказать, что наиболее зрелой является библиотека Theano (Keras). Библиотека Torch является очень сложной в написании и не показывает ни высокой точности, ни скорости. При этом библиотеки Caffe и TensorFlow не уступают Theano по многим критериям, поэтому нельзя исключать возможность их последующего использования.

Подготовка набора данных

Для обучения сети был подготовлен набор данных, который состоит из 2641 изображения дефектов. Распределение изображений в базе данных представлено в табл. 6.

Имя	Платформа	Язык	Интерфейс	OpenMP	OpenCL	CUDA	Рекур- рентные сети	Свер- точные сети	Парал- лельные вычис- ления
Torch	Linux, Mac OS X, Windows, Android, iOS	C, Lua	Lua, LuaJIT, C, библиотека утилит для C++/OpenCL	Да	Внешняя реализация	Да	Да	Да	Да
Theano	Кроссплат- форменность	Python	Python	Да	В разработке	Да	Да	Да	Да
TensorFlow	Linux, Mac OS X, Windows	C++, Python	Python, C/C++, Java, Go	Нет	В разработке	Да	Дa	Да	Да
Keras	Linux, Mac OS X, Windows	Python	Python	Через Theano	В стадии разработки через Theano, планируется через TensorFlow	Дa	Да	Да	Да
Caffe	Linux, Mac OS X, Windows	C++	Python, MATLAB	Да	В разработке	Да	Да	Да	Да

Іаолица 5. Основные параметры оиолиотек глуоокого ооучени	Таблица	5.	Основные	параметры	библиотек	глубокого	обучения
---	---------	----	----------	-----------	-----------	-----------	----------

Таблица 6. Распределений изображений в базе данных

■barc ■scratch	■liquid ■spray	■normal ■distortion	Наименование дефекта	Количество изображений
■material ■particle ■sludge		∎sludge	Barc — дефект антиотражающего покрытия	439
	11%	17%	Liquid — круглая форма и радужное изменение цвета внутри	155
			Normal — изображение без дефекта	182
17 %		6 %	Scratch — много мелких дефектов на одной линии	151
		7 %	Spray — много разноцветных точечных дефектов	195
5%		6%	Distortion — искажение топологического рисунка	635
		7 %	Material — дефект в фокусе объектива как отдельная частица	141
	24 %		Particle — непрозрачная частица вне фокуса объектива	455
			Sludge — полупрозрачный дефект вне фокуса объектива	288

Из них 1154 изображения использовались для обучения и 177 для верификации. Оставшиеся изображения вошли в тестовую выборку.

Обучающая выборка — это выборка, которая непосредственно участвует в обучении сети.

«Верификационная выборка — не видна пользователю до самого конца обучения. Так как в про-

цессе обучения можно следить за тестовой выборкой, то она также косвенно является объектом обучения. В данном случае верификация — финальный и самый непредвзятый судья качества получившейся сети» [10].

Так как количество изображений в каждом классе сильно различается (см. табл. 6), для

barc liquid normal scratch spray distortion material particle sludge	Наименование дефекта	Количество изображений в обучающей выборке	Количество изображений в верифика- ционной выборке
11 % 14 %	Barc — дефект антиотражающего покрытия	157	24
14% 9%	Liquid — круглая форма и радужное изменение цвета внутри	101	15
0.9/	Normal — изображение без дефетка	106	16
8%	Scratch — много мелких дефектов на одной линии	100	15
9%	Spray — много разноцветных точечных дефектов	109	17
17% 9%	Distortion — искажение топологического рисунка	196	30
	Material — дефект в фокусе объектива как отдельная частица	98	15
	Particle — непрозрачная частица вне фокуса объектива	160	25
	Sludge — полупрозрачный дефект вне фокуса объектива	127	19

Таблица 7. Распределений в обучающей и верификационной выборках

формирования «равномерных» выборок была разработана формула для подсчета образующего коэффициента, представленная ниже:

$$k_i = \frac{N_i - N_{\min}}{N_{\min} \cdot \left(\frac{N_{\max}}{N_{\min}} - 1\right)} + 1, \tag{5}$$

где k_i — образующий коэффициент для i-го класса,

N_i — количество изображений в *i*-м классе,

 $N_{\rm min}$ — количество изображений в минимальном классе,

 $N_{\rm max}$ — количество изображений в максимальном классе.

Также каждый класс будет опрашиваться последовательно по одному изображению. Совокупность вышеуказанных методов позволит повысить «равномерность» выборок и обеспечит «перемешивание» классов, что необходимо для эффективного обучения сети.

Распределение изображений в обучающей и верификационной выборках после применения образующего коэффициента представлено в табл. 7. Распределение изображений в тестовой выборке после применения образующего коэффициента представлено в табл. 8.

«Равномерность тестовой выборки не влияет на обучение сети, так как тестовая выборка не участвует в обучении, но ее ошибка видна в процессе. Судя по значению обучающей ошибки, а точнее, видя ее динамику, можно судить о том, не переучена ли сеть.

Классический пример переучившейся сети это когда ошибки теста сначала снижаются, а потом ошибка теста бесконечно возрастает. Это значит, что сеть сумела "запомнить" всю обучающую выборку и теперь подстраивается не под обобщающие характеристики всей выборки, а определяет только обучающие данные. Как правило, это случается, когда исходная выборка слишком мала или слишком однородна и/или количество внутренних слоев и нейронов при этом слишком велико» [10].

Пример переобучения сети приведен на рис. 6. Как видно из рис. 6, после сотой эпохи функ-

ция потерь начала расти.

МЕТОДИКА ПРИМЕНЕНИЯ СВЕРТОЧНЫХ НЕЙРОННЫХ СЕТЕЙ



Таблица 8. Распределений изображений в базе данных



Рис. 6. Пример переобучения сети

Сравнительный анализ архитектур сверточных нейронных сетей на оптимизаторе Adagrad

Сеть AlexNet увеличивает свою точность практически линейно, что видно на рис. 7. Уже на 80-й эпохе точность превышает 90%, при этом время обучения равно 123 часам.

Но по графикам (рис. 8) видно, что CaffeNet, в отличие от AlexNet имеет меньшее количество случайных ошибок и работает гораздо точнее. Так, начиная с 40-й эпохи точность сети сводится к 100% за исключением случайных ошибок. Время обучения составляет 52 часа.

При эксперименте с сетью GoogleNet на графиках (рис. 9) видно, что уже с 60-й эпохи первый, второй и третий критерии обучения свелись к 1,

а это означает, что распознаваемость класса практически 100%. При этом время обучения сети заняло 97 часов.

Архитектуры VGG16 и VGG19 показали худшие результаты (рис. 10). Для обучения данной сети потребовалось большое количество оперативной памяти и большое количество времени. С целью экономии ресурсов данная архитектура обучалась лишь на 25 эпохах и время обучения 20 эпох составило 288 часов.

Анализ алгоритмов обучения различных архитектур сверточной нейронной сети

Самым простым является алгоритм стохастический градиентный спуск. Результаты обучения представлены на рис. 11.

На данных графиках видно, что, начиная с 40-й эпохи, точность сети сводится к 100 % за исключением случайных ошибок. Время обучения составило 55 часов.

Также приведен анализ алгоритма адаптивного градиента. Результаты обучения представлены на рис. 12.

На данных графиках видно, что, начиная с 40-й эпохи, точность сети сводится к 100% за исключением случайных ошибок. Время обучения составило 52 часа.



Рис. 7. Качество обучения сети AlexNet



Рис. 8. Качество обучения сети CaffeNet



Рис. 9. Качество обучения сети GoogleNet



Рис. 10. Качество обучения сети VGGNet



Рис. 11. Качество обучения сети CaffeNet по алгоритму SGD



Рис. 12. Качество обучения сети CaffeNet по алгоритму RMSProp



Рис. 13. Качество обучения сети CaffeNet по алгоритму Adagrad



Рис. 14. Качество обучения сети CaffeNet по алгоритму Adadelta

Приведен анализ алгоритма среднеквадратического распределения. Результаты обучения показаны на рис. 13.

На данных графиках видно, что, начиная с 70-й эпохи, точность сети сводится к 100% за исключением случайных ошибок. Время обучения составило 19 часов.

Приведен анализ *алгоритма по методу адаптивного обучения*. Результаты обучения показаны на рис. 14.

На данных графиках видно, что сеть практически не обучилась, ее точность не достигла даже 60%. Время обучения составило 21 час.

Приведен анализ алгоритма, построенного на оценке адаптивного момента. Результаты обучения показаны на рис. 15. На данных графиках видно, что сеть хорошо обучилась, ее точность достигла 98,9% уже на 50-й эпохе. Время обучения составило 27 часов.

Приведен анализ алгоритма, построенного на инерционном моменте распределения. Результаты обучения показаны на рис. 16.

На данных графиках видно, что сеть практически обучилась, ее точность достигла 97,25% уже на 70-й эпохе. Время обучения составило 20 часов.

Обсуждение результатов

Был проведен сравнительный анализ существующих методов классификации изображений (*K*-ближайших соседей, при помощи сверточной нейронной сети и нейронной сети прямого распро-



Рис. 15. Качество обучения сети CaffeNet по алгоритму Adam



Рис. 16. Качество обучения сети CaffeNet по алгоритму Adamax

странения), моделей различных нейронных сетей (AlexNet, CaffeNet, VGGNet, GoogLeNet) и инструментов для их использования (Caffe, Keras + + Theano, Torch, Keras + TensorFlow), а также алгоритмов обучения нейронных сетей (SGD, RMSProp, Adadelta, Adagrad, Adam, Adamax).

В результате проведенного сравнительного анализа было установлено, что высокая восприимчивость метода *К*-ближайших соседей к поворотам, положению объектов на поле классификатора и масштабированию, а также необходимость сохранения внушительной базы эталонов и сравнения входного изображения с каждым из базы данных является недостатком этого метода. Такие факторы, как восприимчивость сети к сдвигу позиции объекта во входных данных, отсутствие возможности реализации распараллеливания вычислений, а еще реализации алгоритмов обучения сети на графических процессорах (GPU), низкая скорость обучения и большое количество обучаемых параметров относятся к существенным недостаткам нейронных сетей прямого распространения.

Учитывая изложенное отметим, что именно при подходе метода сверточных нейронных сетей обеспечивается частичная устойчивость к различным искажениям (таким как повороты, изменение ракурса или масштаба др.).

«Получены 5 моделей сверточных нейронных сетей, обученных на 1400 изображениях дефектов и проведена классификация по 9 различным классам. В результате экспериментально доказано, что при классификации изображений дефектов топологии СБИС наилучшие результаты по скорости и качеству обучения показывает архитектура CaffeNet.

Есть вероятность, что модели VGG16 и VGG19 дали бы лучшие показатели качества» [2] обучения, но в связи с большим потреблением ресурсов данные архитектуры уступают CaffeNet.

Из библиотек для работы с нейронными сетями была выбрана Keras, а в качестве бекендной библиотеки необходимо использовать библиотеку Theano, так как данный инструмент показал наилучшие временные и точностные показатели.

Из алгоритмов обучения наилучшие показатели по скорости и качеству обучения сети показал алгоритм Adagrad, поэтому именно его рекомендуется использовать в задаче классификации топологии интегральных микросхем. По результатам, указанным выше, сеть была протестирована и результаты работы сети приведены на рис. 17.

Если сравнить рис. 13 и рис. 17, очевидно, что работа сети в первом случае, когда обучающая и тестовая выборки совпадают, гораздо лучше, однако для практического использования сети этот вариант не подходит. Результат обучения сети на сотой эпохе приведен в табл. 9.

В табл. 9 видно, что ошибка однозначной классификации дефекта (top-1) по предоставленному изображению равна 13 %, что уже лучше 15%, так как уменьшает коэффициент входного контроля *K*_{вх} с 1,17 на 1,15. В дальнейшем эту точность можно будет увеличить, добавляя анализ изображения нейронной сетью другой архитектуры. То есть если во время прохождения верификационной выборки схожесть изображения для конкретного класса меньше определенного порога, то оно пропускается и анализируется другой архитектурой.

Заключение

Очевидно, что искусственный интеллект все больше привлекает внимание ученых и обычных обывателей, ведь ошибки, связанные с человеческим фактором, очень трудно контролировать и прогнозировать. А с учетом повышения требований по надежности элементной базы данные ошибки необходимо свести к минимуму.

Следует отметить, что дефекты, используемые при анализе, относятся только к идентифицируемым средствами визуального контроля при ограничениях в увеличении. Но данную предметную область можно расширить при наличии элементной базы для обучения нейронной сети. Также сейчас активно применяются генеративные нейронные сети, позволяющие сократить обучающую выборку, сохраняя точность прогнозирования.



Рис. 17. Результат работы сети на реальном наборе данных

T (0	D	-				
Таблица	9	Результаты	обучения	сети	на	сотои	эпохе
	۰.	1 cojubiaibi	00, 1011111			001011	0110110

val_mae	loss	recall	mae	precision	acc	val_acc	val_recall	val_precision	val_loss
0,11	2,59	0,82	0,05	0,93	0,87	0,53	0,5	0,5	4,26

Список литературы

- Ветлугин К. Человеческий фактор. Computerworld № 11. 2006. https://www.osp.ru/cw/2006/48/ 3812027 (Дата обращения 24.05.2022).
- Аристов Р.С., Власов А.И., Вирясова А.Ю. и др. Исследование различных моделей сверточных нейронных сетей для классификации изображений дефектов топологического рисунка СБИС // Наноиндустрия, 2018, № 9. С. 392–398.
- 3. Кириенко В.Е. Человеческий фактор корпоративных информационных систем (на примере Томского горисполкома) //Вестник Томского государственного университета, 2002, № 275. С. 133–138.
- Акимова Г.П., Соловьев А.В. Методология оценки надежности иерархических информационных систем // Труды ИСА РАН, 2006, т. 23. С. 18–47.
- 5. *Цибулевский И.Е.* Ошибочные реакции человекаоператора. М.: Советское радио, 1979. 208 с.

- 6. Справочник «Надежность ЭРИ». Методические указания. 2006. 7 с.
- 7. Балухто А.Н., Булаев В.И., Власов А.И. и др. Нейрокомпьютеры в системах обработки изображений. М.: Радиотехника, 2003. С. 56–98.
- Вирясова А.Ю., Гладких А.А. Анализ предметной области и разработка базы данных для реализации дефектоскопии интегральных структур / Сборник трудов Международной молодежной научно-технической конференции «Наукоемкие технологии и интеллектуальные системы, 2018. С. 411–422.
- 9. Вирясова А.Ю., Власов А.И., Гладких А.А. Нейросетевые методы дефектоскопии интегральных структур // Нейрокомпьютеры: разработка, применение, 2019, № 2. С. 54–67.
- Нейронная сеть дома. Нейронные сети: какие бывают и как их используют бренды. https://halzen.ru/ ram/neironnaya-set-doma-neironnye-seti-kakiebyvayut-i-kak-ih-ispolzuyut.html (Дата обращения 31.10.2022).