

ИСПОЛЬЗОВАНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ РЕШЕНИЯ ЗАДАЧИ ПОИСКА ДЕФЕКТОВ НА РАСТРОВЫХ ИЗОБРАЖЕНИЯХ

М. А. Дрюченко, А. А. Сирота, В. В. Гаршина, Е. Ю. Митрофанова

Воронежский государственный университет

Поступила в редакцию 20.08.2018 г.

Аннотация. Рассматривается задача поиска дефектов на тематических изображениях различных классов с использованием двух вариантов обучаемых классификаторов – нейронных сетей прямого распространения и сверточных сетей. Отличительной особенностью анализируемых изображений является наличие полезных объектов различной степени сложности и плотности заполнения, расположенных на текстурном фоне. Алгоритмы диагностики дефектов предназначены для выявления артефактов типа аппликативных помех, искажения границ и засветки объектов или их частей. Приводятся результаты тестирования для различных типов изображений.

Ключевые слова: машинное обучение, нейронные сети, растровые дефекты.

Annotation. The problem of defects detection on images of different classes is considered. Two variants of trained classifiers – direct propagation neural networks and convolutional networks are considered for solving this problem. A distinctive feature of the analyzed images is the presence of objects located on a textural background. Algorithms for defects detection are designed to identify artifacts such as applicative errors, distortions of object boundaries or their parts. Test results for various types of images are given.

Keywords: machine learning, neural networks, raster defects.

ВВЕДЕНИЕ

Широкое распространение и практическое использование систем машинного зрения в различных отраслях науки и техники обуславливает необходимость развития и совершенствования методов обработки, распознавания, анализа и получения информации из различного класса цифровых изображений. При решении промышленных задач, связанных с обработкой и анализом больших массивов изображений, важную роль играет максимальная автоматизация технологического процесса (или отдельных его этапов) с целью минимизации ручного труда, что в свою очередь предъявляет более жесткие требования к используемым алгоритмам и к достоверности результатов их работы. К числу значимых проблем при обработке и анализе растровых изображений необходимо отнести возможность

появления на них различного рода артефактов и дефектов, затрудняющих распознавание или искажающих геометрию представленных на изображении объектов. В зависимости от типа и характера обрабатываемых изображений дефекты растрового представления могут быть обусловлены различными причинами: низким качеством съемки, цифровыми шумами, локальным изменением уровней яркости, наличием на кадрах посторонних объектов (мусор аппликативного характера), наличием объективных искажений непосредственно на отснятом материале (царапины, смаз границ объектов и т. п.). Возможность получения ошибок в алгоритмах обработки изображений, потенциально содержащих дефекты, обуславливает актуальность исследований, направленных на разработку новых методов и алгоритмов, позволяющих с высокой достоверностью диагностировать на снимках проблемные участки с целью дальнейшего реагирования на подобные ситуации в контексте решаемой задачи.

© Дрюченко М. А., Сирота А. А., Гаршина В. В., Митрофанова Е. Ю., 2018

Известные подходы к решению задачи диагностирования дефектов растровых представлений можно разбить на две группы в зависимости от характера анализируемых изображений.

В первую группу можно отнести алгоритмы, работающие с текстуро-подобными изображениями, не содержащими явно выраженных объектов [1, 2]. Как правило, подобные алгоритмы основаны на использовании методов пороговой обработки [3] с последующим анализом связанных областей пикселей бинарного представления на принадлежность к «дефектам», либо на использовании различных методов текстурного анализа совместно с методами машинного обучения [4–6] для сегментации и классификации областей изображения на «хорошие» и «проблемные». На практике алгоритмы данной группы, как правило, применяются в промышленных системах оптического неразрушающего контроля качества материалов и продукции.

Во вторую группу можно отнести алгоритмы, работающие с изображениями, содержащими явно выраженные объекты, которые могут искажаться дефектами, как на уровне физического представления, так и на уровне растрового представления, например, в процессе получения самого изображения. Наличие объектов, как правило, затрудняет задачу поиска дефектов и предполагает выполнение дополнительных операций по сегментации дефекта от фона и полезных объектов с использованием пороговых, морфологических методов или методов наращивания областей [7].

В последнее время набирают популярность методы обработки изображений, использующие технологии глубокого обучения, не требующие предварительной сегментации, а реализующие анализ сцены с поиском

и классификацией объектов интереса (дефектов) напрямую [8]. Также для «сложных» изображений, содержащих множество гетерогенных объектов, можно отметить подход, предполагающий использование нескольких вариантов изображений одной и той же сцены, с последующим сопоставлением данных изображений и поиском отличий [9]. Дефекты фиксируются на участках кадров, содержащих отличия. Данный подход применяется, например, для поиска дефектов полупроводниковых пластин [10].

МЕТОДЫ И МАТЕРИАЛЫ

В качестве исходных данных в работе рассматривались сложные, не текстурные изображения двух типов – изображения элементов зерновых смесей с различными примесями, получаемых в системах фотосепарации реального времени [11] и изображения фрагментов интегральных микросхем [12]. Характерными объективными дефектами, присутствовавшими на изображениях, были:

- неравномерное распределение яркости (выраженная засветка объектов и их частей);
- деформация границ полезных объектов, сопровождаемая искажением их геометрии;
- аппликативные помехи в виде посторонних ярких и темных объектов неправильной формы, частично или полностью перекрывающих полезные объекты.

Примеры типовых дефектов, представленные в работах [11–13], приведены на рис. 1.

Для диагностики указанных дефектов в данной работе были реализованы два варианта обучаемых алгоритмов, использующих классические нейронные сети (НС) прямого распространения и глубокие нейронные сверточные сети. Далее рассмотрим их более подробно.

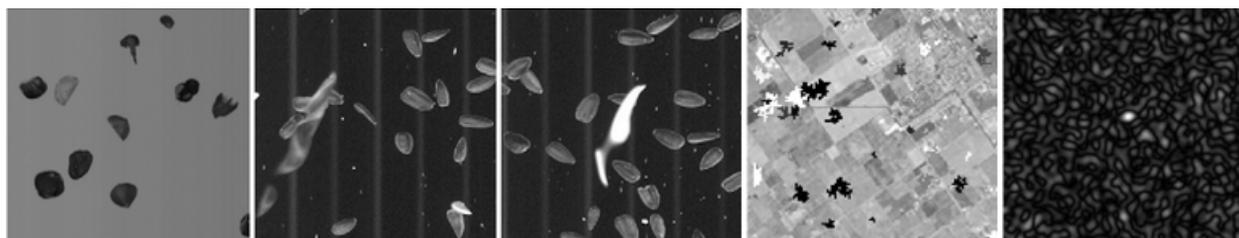


Рис. 1. Примеры типовых дефектов на растровых изображениях

ВЫЯВЛЕНИЕ ДЕФЕКТОВ РАСТРОВОГО ПРЕДСТАВЛЕНИЯ С ИСПОЛЬЗОВАНИЕМ НЕЙРОННЫХ СЕТЕЙ ПРЯМОГО РАСПРОСТРАНЕНИЯ

Ключевым фактором, определяющим работоспособность данного подхода, является качественное распознавание (бинаризация) препарируемых кадров, т. е. максимально полное и точное распознавание хороших/дефектных объектов и фона при наличии признаков, выявляемых в ходе предварительной обработки. Для предварительной обработки изображений использовался алгоритм адаптивной бинарной сегментации [14], дополненный процедурами постобработки получаемого двоичного представления, включающими восстановление внутреннего заполнения объектов при наличии на них ложных дырок, а также удаление ложных фоновых объектов. Предполагается, что для снимков хорошего качества, не содержащих явных артефактов, можно ожидать высокого качества бинаризации, и, наоборот, – на снимках низкого качества результат бинаризации может содержать различного рода ошибки, которые будут выявлены в процессе классификации.

После бинаризации для каждого объекта кадра вычислялся набор признаков – отличительных характеристик, влияющих на принятие решения о принадлежности объекта одному из классов. В решаемой задаче все объекты делились на два класса – «хорошие» и «плохие». Объекты первого класса характеризовались хорошей фотометрией (статистическими характеристиками цветности/яркости) и корректной, минимально искаженной морфологией, характеризующей форму объектов с точки зрения ее правильности, ориентации, изрезанности границ. В случае наличия выраженных отклонений по фотометрии и геометрии объекты относились ко второму классу. Набор признаков описателей для классификации объектов включал:

Контрастность объекта

$$\varphi_1 = (m_{obj} - m_{bg}) / m_{obj},$$

где

$$m_{obj} = N_{obj}^{-1} \sum_{i,j=1, B_k(i,j) \neq 0}^{w_k, h_k} I_k(i, j),$$

$$m_{bg} = N_{bg}^{-1} \sum_{i,j=1, B_k(i,j)=0}^{w_k, h_k} I_k(i, j) - \text{средние значения яркости пикселей объекта и фона фрагмента; } N_{obj} = S(B_k) - \text{количество пикселей объекта, } N_{bg} = w_k h_k - S(B_k) - \text{количество пикселей фона; } I_k - \text{фрагмент исходного растра в градациях серого, соответствующий области размером } w_k \times h_k \text{ пикселей, вписывающей } k\text{-й распознанный бинарный объект; } B_k - \text{аналогичный фрагмент на бинарном представлении } I_B. \text{ Данный признак является достаточно информативным, особенно для малоразмерных объектов, и характеризует степень отличия средних значений яркости пикселей объекта от яркости фона в его окрестности. Позволяет определять потенциально ложно распознанные объекты в фоне, характеризующиеся малой разницей } m_{obj} \text{ и } m_{bg}.$$

Контрастность областей вдоль границ объекта

$$\varphi_2 = (m_{brdIn} - m_{brdOut}) / m_{brdIn},$$

$$\text{где } m_{brd} = (w_k h_k)^{-1} \sum_{i,j=1, G_{brd}(i,j) \neq 0}^{w_k, h_k} I_k(i, j),$$

$$brd = \{brdIn, brdOut\},$$

$G_{brdIn} = M_{grad}(M_{erode}(B_k, r), r)$ – бинарная маска внутренних границ объекта, $G_{brdOut} = M_{grad}(M_{dil}(B_k, r), r)$ – бинарная маска внешних границ объекта, M_{erode} , M_{dil} , M_{grad} – операции математической морфологии (эрозия, дилатация, градиент) [14]. Данный признак характеризует степень отличия средних значений яркости пикселей на внутренних и внешних границах контура объекта. Пригоден для выявления слабоконтрастных объектов, а также объектов, находящихся на локально размытых участках кадра с потерей фокусировки.

Оценки неравномерности яркости объекта на основе морфологического градиента. Предназначены для отслеживания локальных дефектов на границах объектов, посторонних вкраплений внутри объектов, а также для фиксации падения резкости самих объектов:

$$\varphi_3 = \begin{cases} m_{G_I} / m_{G_B}, & m_{G_I} < m_{G_B} \\ m_{G_B} / m_{G_I}, & m_{G_I} \geq m_{G_B} \end{cases},$$

где $m_{G_I} = (w_k h_k)^{-1} \sum_{i,j=1, B_k(i,j) \neq 0}^{w_k h_k} G_I(i, j),$

$$m_{G_B} = (w_k h_k)^{-1} \sum_{i,j=1, B_k(i,j) \neq 0}^{w_k h_k} G_B(i, j),$$

$$G_I = T_{otsu}(M_{grad}(I_k, 3)),$$

$G_B = T_{otsu}(M_{grad}(B_k, 3))$ – бинаризованные с глобальным порогом Оцу результаты вычисления морфологического градиента (радиус ядра 3) от фрагментов исходного в градациях серого и бинарного представлений объекта I_k, B_k .

$$\varphi_4 = 1 - \left| \varphi_3 - \sum_{i,j=1, G_C(i,j) \neq 0}^{w_k h_k} G_C(i, j) \right|,$$

где $G_C = G_I \wedge G_B$ – результат конъюнкции бинарных масок градиентов. Для «плохих» объектов бинарное представление градиента дает лишнее шумовое заполнение внутренних областей объекта, следствием чего является снижение значений φ_3, φ_4 . В случае анализа слабоконтрастных объектов с дефектами или недостаточной резкостью границ, при вычислении градиента, как правило, наблюдается частичная потеря контуров границ с превращением их в «пунктир», что также отражается на снижении значений φ_3, φ_4 .

Дисперсионную характеристику гладкости контура (СКО кривизны) [11] определяющую степень «изрезанности» контура объекта и вычисляемую по формуле

$$\varphi_5 = \sqrt{l^{-1} \sum_{i=1}^l (r_i - m_r)^2},$$

где $r = (r_1, r_2, \dots, r_l)$ – вектор расстояний от центра масс объекта до точек, составляющих его границу, $r_i = \sqrt{(x_c - x_i)^2 + (y_c - y_i)^2}, i = \overline{1, l}, (x_i, y_i)$ – координаты точек границы контура, l – их число, $m_r = l^{-1} \sum_{i=1}^l r_i$ – среднее вектора расстояний.

Относительную площадь «бахромы»

$$\varphi_6 = S_{tophat} / S_G,$$

где $S_{tophat} = S(M_{tophat}(B_k, r))$ – площадь

«бахромы», полученной как результат применения операции морфологической изоляции ярких регионов M_{tophat} к бинарному объекту $B_k, S_G = S(M_{grad}(M_{erode}(B_k, r), r))$ – площадь области вдоль границ объекта (рис. 2). Данный признак применяется для оценки степени изрезанности (дребезга) контуров границ объектов, чаще всего обусловленной объективными характеристиками изображения вроде наличия мелких ярких фоновых вкраплений.



Рис. 2 – Области объектов, используемые при вычислении относительной выпуклой площади

Бинарный признак наличия острых углов между соседними сегментами аппроксимированного контура, характеризующий допустимость или недопустимость взаимного расположения смежных сегментов аппроксимированного контура объекта. Если в аппроксимированном контуре объекта существует хотя бы одна пара соседних сегментов, длина каждого из которых превышает l_{max} (по умолчанию $l_{max} \leq 12$) угол между которыми, будет меньше заданного α (обычно $\alpha \leq 80$), то $\varphi_7 = 0$, иначе $\varphi_7 = 1$. Данный признак подходит для обнаружения вдавленных или выпуклых участков неправильной формы на границах реальных объектов.

Отметим, что информативность и полезность описанных выше признаков может отличаться в зависимости от характера и типа содержимого анализируемых изображений. Данный факт был подтвержден в результате предварительных экспериментов.

В качестве классификатора при решении задачи поиска дефектов, использовалась НС типа многослойный перцептрон (MLP), реализующая двухальтернативное решающее правило. Архитектура сети приведена на рис. 3.

Количество входных контактов сети n определялось размерностью вектора призна-

ков ($n = 7$). Количество нейронов скрытого слоя m_1 задавалось в диапазоне $n \leq m_1 \leq 2n + 1$. Выходной слой сети включал один нейрон, на выходе которого формировалось решение в виде $rec = \text{sign}(y - 0.5)$, где значения $+1$ и -1 переменной rec соответствовали первому (объект «хороший») и второму (объект «дефектный») классам. По умолчанию НС использовала нелинейные передаточные функции типа SIGMOID_SYMMETRIC, с выходными значениями в диапазоне от -1 до 1 .

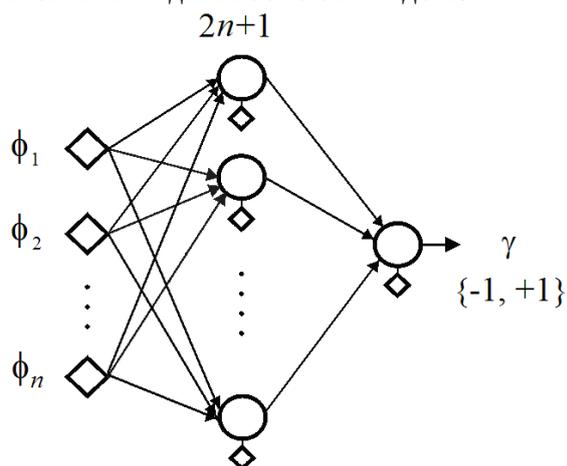


Рис. 3. Архитектура многослойного перцептрона, используемого для классификации дефектов

Обучающие и тестовые данные сети представляли собой множество значений векторов признаков $\Phi = ((\varphi_1, \dots, \varphi_n)_1^T, \dots, (\varphi_1, \dots, \varphi_n)_N^T)$, вычисленных для выделенных бинарных объектов. Разметка «дефектных» объектов кадра осуществляется по результатам прогонки через обученную НС тестовых данных, сформированных по всем распознанным объектам кадра. Объект классифицируется как «дефектный» если значение на выходе сети $\gamma < 0$.

ВЫЯВЛЕНИЕ ДЕФЕКТОВ РАСТРОВОГО ПРЕДСТАВЛЕНИЯ С ИСПОЛЬЗОВАНИЕМ МЕТОДОВ ГЛУБОКОГО ОБУЧЕНИЯ

Данный подход не требует предварительного анализа и подготовки признаков, т. е. фактически реализует возможность ухода от эвристических правил, работающих с априорно известными допустимыми и недопустимыми диапазонами значений характеристик

изображений и содержащихся на них объектов. При этом обеспечивается реализация воспроизводимого процесса, позволяющего получать устойчивые, пригодные для принятия решения о наличии дефектов выходные данные, на основе общих представлений о качестве растровых фрагментов и подготовки обучающих данных в виде фрагментов изображений. Сразу отметим, что данные представления целиком базируются на субъективном (человеческом) восприятии «качественных» и «дефектных» фрагментов изображений.

Подход на основе глубокого обучения не предполагает дополнительной «оцифровки» исходных данных, т. е. не требует формирования специальных векторов признаков изображений, а обрабатывает их напрямую. Для обучения «глубоких» сетей необходимы корректно сформированные обучающие выборки достаточно больших размеров, включающие от нескольких тысяч до десятков тысяч примеров. Разметка исходных данных при формировании обучающих выборок, заключающаяся в просмотре множества кадров и выделении на них типичных примеров «хороших» и «дефектных» областей, проводится вручную. Отметим, что ее качество, определяемое полнотой и непротиворечивостью примеров фрагментов двух классов, во многом обуславливает итоговую работоспособность классификаторов.

В рамках реализованного подхода для классификации фрагментов и выявления дефектов растрового представления использовались сверточные НС (CNN). Сверточные НС – это глубокие искусственные НС, которые используются для классификации изображений, кластеризации их по подобию, а также для распознавания объектов (людей, дорожных знаков, опухолей и т.п.) на сложных сценах [15]. Входными данными таких сетей являются растровые фрагменты заданного размера (в работе рассматривались фрагменты 50×50 пикселей), содержащие и не содержащие дефекты или их части. На выходе НС ожидается значение $v_{0,1} = \{-1, +1\}$ или вектор значений $\gamma = (v_0, v_1)^T$, характери-

зующий тип фрагмента – «хороший» или «дефектный». Сверточные НС принимают и обрабатывают изображения как тензоры (матрицы чисел с несколькими измерениями – высотой, шириной и глубиной). Архитектура таких сетей (количество слоев, их типы, связи между слоями) может варьироваться в зависимости от характера исходных данных и типа решаемой задачи.

Для задачи выявления дефектов на растровых изображениях рассматривались простые варианты сетей, включавшие по несколько сверточных слоев (*conv layer*) с передаточными функциями *ReLU*, чередуемых слоями субдискретизации (*pooling layer*), с добавлением одного полносвязного слоя (*fully connected*), предшествующего выходу сети, включающему один (передаточная функция *Sigmoid*) или два (передаточная функция *Softmax*) нейрона. Для минимизации возможности переобучения сети использовался стандартный механизм прореживания нейронов (*Dropout*). Исключенные нейроны не вносят свой вклад в процесс обучения ни на одном из этапов алгоритма обратного распространения ошибки, поэтому исключение хотя бы одного из нейронов равносильно обучению новой НС. Число исключаемых нейронов определяется

параметрически задаваемой вероятностью исключения (обычно 0,5). В качестве базового оптимизатора в алгоритме обучения сети использовался *RMSProp* (*root mean square propagation*). Типовые архитектуры сверточных сетей, применявшихся для решения задачи поиска дефектов, приведены на рис. 4.

Рассматривались два варианта представления исходных данных, подаваемых на вход сверточных НС:

- растровые фрагменты в градациях серого размером $r \times r$ пикселей (по умолчанию $r = 50$);
- трехканальные *RGB* представления фрагментов размером $r \times r \times 3$ (где канал *R* содержит исходное серое представление фрагмента, *G* – результат логического умножения серого представления на соответствующее ему бинарное, полученное по тому же алгоритму бинаризации, который применялся в алгоритме с многослойными персептронами, *B* – результат логического умножения серого на соответствующее ему инвертированное бинарное).

Первый вариант является предпочтительным с точки зрения обеспечения универсальности алгоритма выявления дефектов, т.к. на исходные данные не будут влиять результаты

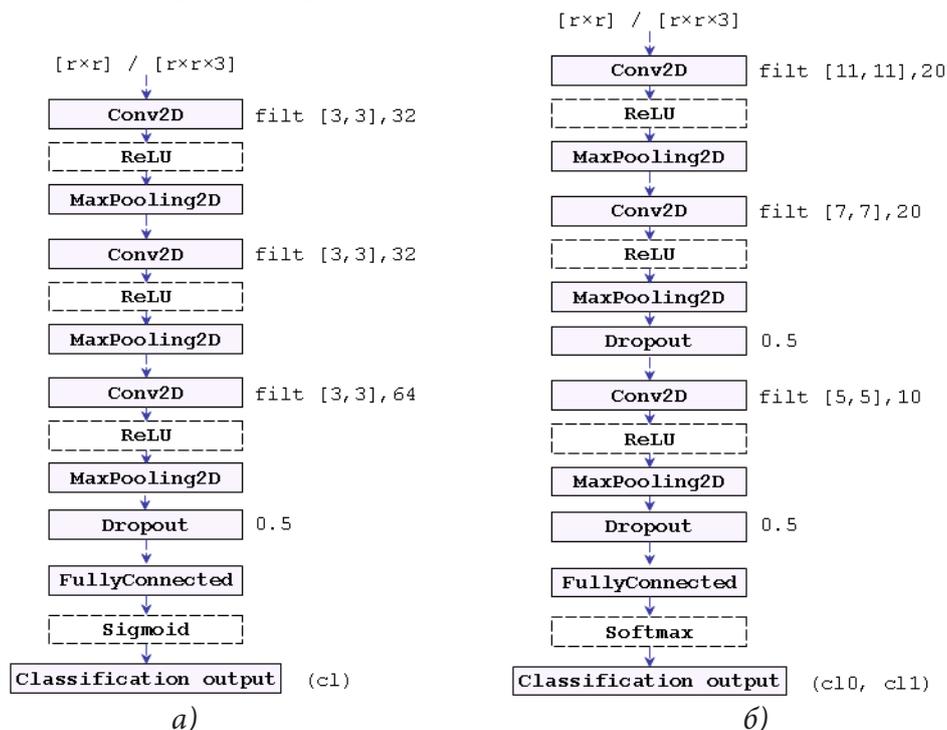


Рис. 4. Архитектуры сверточных сетей, используемых для классификации дефектов

распознавания. Второй вариант с потенциально большей достоверностью позволит выявлять дефекты при точном распознавании объектов. В этом случае реальные дефекты на растровом представлении будут подкрепляться искаженными контурными представлениями.

На выходе сверточной НС формируется вещественное значение (пара значений), характеризующих принадлежность входного фрагмента одному из классов. В простейшем случае границы прогоняемых через сеть фрагментов совпадают с границам ячеек сетки, накладываемой на анализируемый кадр, и т. о. обеспечивается полное покрытие кадра. Если ширина и высота выбираемых на изображении фрагментов не совпадают с размерами входов обученной НС, то данные фрагменты могут автоматически масштабироваться к необходимому размеру. После прогонки всех фрагментов кадра через НС формируется множество векторов $C = \{c_1, c_2, \dots, c_k\}$, $c_i = (x, y, v_{0,1})^T$, x, y – координаты левого верхнего угла фрагмента, $v_{0,1} = \{-1, +1\}$, $k = (W/r)(H/r)$ – число блоков на кадре размером $W \times H$ пикселей. По данным C осуществляется разметка «дефектных» блоков кадра.

РЕЗУЛЬТАТЫ ЭКСПЕРИМЕНТА И ИХ ОБСУЖДЕНИЕ

Обучение нейросетевых классификаторов первого (MLP) и второго (CNN) типов проводилось с использованием выборки из 120 изображений (разрешением 2048×4096 и 2000×2000 пикселей), содержащих и не содержащих растровые дефекты. Для каждого типа изображений («Зерновые смеси» и «Изображения полупроводниковых пластин») формировалась своя выборка из 120 кадров, по которой обучались классификаторы. Изображения были представлены в градациях серого. Обучающая выборка для MLP формировалась по результатам распознавания представленных на кадрах объектов в режиме интерактивной разметки их классов. Обучающая выборка для CNN формировалась по результатам интерактивной разметки клас-

сов непересекающихся растровых фрагментов размером 50×50 пикселей. Дополнительная обучающая выборка для CNN, содержащая фрагменты в трехканальном RGB представлении, формировалась на основе размеченных фрагментов в градациях серого с использованием (по вышеописанным правилам) ранее полученных для MLP бинарных представлений кадров. Для изображений типа «Зерновые смеси» объем обучающей выборки для MLP составлял 18800 примеров, из которых 9500 составляли «хорошие» примеры и 9300 «плохие», объем обучающей выборки для CNN – 11300, из которых 6200 составляли «хорошие» примеры и 5100 «плохие». Для изображений типа «Полупроводниковые пластины» объем обучающей выборки для MLP составил 17600 примеров, из которых 9600 составляли «хорошие» примеры и 8000 «плохие», объем обучающей выборки для CNN – 14130, из которых 8830 составляли «хорошие» примеры и 5300 «плохие».

Тестирование алгоритмов поиска дефектов проводилось на двух выборках из 70 изображений каждого типа, не использовавшихся при обучении. Для MLP сети на каждом кадре тестовой выборки проводилось распознавание объектов, вычисление по каждому объекту вектора признаков и прогонка его через классификатор. Для CNN сети, работающей с фрагментами в градациях серого, тестирование реализовывалось прогонкой непересекающихся растровых фрагментов размером 50×50 пикселей, соответствующих ячейкам регулярной сетки целиком покрывающей кадр выборки. Для CNN сети, работающей с трехканальным RGB представлением фрагментов, тестирование реализовывалось аналогично, но с использованием фрагментов с добавленными в дополнительные каналы результатами распознавания.

Результаты анализа в виде усредненных по выборкам кадров значений вероятности ошибок первого $P_{err}^{(1)}$ (обнаружение ложных дефектов) и второго рода $P_{err}^{(2)}$ (необнаружение реальных дефектов) приведены в табл. 1. С целью упрощения процедур анализа и минимизации числа операций ручного просмотра результатов работы алгоритмов выявляе-

ния дефектов, была реализована предварительная ручная разметка «дефектных» областей на кадрах из тестовых выборок. Каждый кадр просматривался в ручном режиме и на нем мышью выделялись прямоугольные области минимального размера, вписывающие различные выраженные объективные дефекты. Далее координаты выделенных областей вместе с именем соответствующего растра записывались в файл. В процессе тестирования $P_{err}^{(1)}$ фиксировались по факту отсутствия пересечений областей, вписывающих программно найденный дефект с областями, размеченными вручную, а $P_{err}^{(2)}$ фиксировались в том случае если для размеченной вручную области, содержащей дефект, не было получено ни одного пересечения с классифицированными алгоритмами «дефектными» областями.

При работе с изображениями типа «Зерновые смеси» наилучшие результаты по точности обнаружения дефектов были получены для CNN сети, обученной для работы с растровыми фрагментами в градациях серого – $P_{err}^{(1)}$ составила порядка 2.7 %, а $P_{err}^{(2)}$ – 2 %. Для CNN сети, обученной на работу с трехканальными фрагментами, значения усредненных вероятностей ошибок оказались несколько хуже (3.2 % и 4 %), что объясняется недостаточным качеством сегментации объектов на некоторых изображениях тестовой выборки. Алгоритм на основе MLP сетей позволят диагностировать дефекты с вероятностями ошибок первого и второго рода порядка 4 и 5 %. Следует отметить, что для алгоритма данного типа качество сегментации имеет принципиальное значение, также как и изначальный выбор системы информативных непротиворечивых признаков.

Для изображений типа «Полупроводниковые пластины» наименьшие значения $P_{err}^{(1)}$ (1.6 %) были получены для CNN сети, обученной на фрагментах в градациях серого. Для этой же сети $P_{err}^{(2)}$ составила порядка 2.5 %. Наименьшее значение $P_{err}^{(2)}$ (1.7 %) было получено для MLP сети, обученной по признаковым описателям распознанных объектов. Стоит отметить, что использование качественных результатов распознавания при формировании трехканальных представлений растровых фрагментов позволяет несколько улучшить значение $P_{err}^{(2)}$ для сверточных сетей с 2.4 % для CNN (gray) до 2.2 % для CNN (RGB).

К достоинствам алгоритма диагностики дефектов на основе использования MLP можно отнести:

- хорошие обобщающие свойства сетей данного класса;
- возможность использования нелинейных передаточных функций для обработки линейно-неразделимых множеств значений признаков;
- возможность дообучения классификаторов при поступлении новых данных или обучения новых классификаторов для обработки специфических данных.

Недостатками алгоритма на основе MLP являются:

- зависимость результатов от качества сегментации;
- необходимость предварительного анализа и подготовки признаков;
- частичное покрытие кадра – поиск дефектов лишь в областях, содержащих распознанные объекты.

К достоинствам алгоритма диагностики дефектов на основе использования CNN можно отнести:

Таблица 1

Результаты тестирования алгоритмов классификации дефектов

Тип классификатора	Тестовая выборка			
	«Зерновые смеси»		«Полупроводниковые пластины»	
	$P_{err}^{(1)}$	$P_{err}^{(2)}$	$P_{err}^{(1)}$	$P_{err}^{(2)}$
MPL	0.041	0.048	0.025	0.017
CNN (gray)	0.027	0.019	0.016	0.024
CNN (RGB)	0.032	0.039	0.020	0.022

- полное покрытие кадра;
- отсутствие необходимости формирования и вычисления векторов признаков описателей классифицируемых фрагментов;
- возможность дообучения классификаторов для работы с новыми данными;
- возможность последовательного использования нескольких НС-классификаторов, каждый из которых обучен для обнаружения специфических типов дефектов.

К недостаткам алгоритма на основе CNN можно отнести:

- анализ и принятие решения по фрагментам без учета контекста их окружения;
- необходимость качественной ручной разметки материала и обработки «пограничных» ситуаций;
- чувствительность к изменению статистических характеристик содержимого препарируемых кадров, обуславливающая необходимость дообучения сетей при работе с новыми, ранее не предъявлявшимися материалами.

ЗАКЛЮЧЕНИЕ

Рассмотренные сравнительные варианты решения задачи поиска дефектов на растровых изображениях демонстрируют универсальность применения нейросетевого подхода, показавшего высокую достоверность при поиске дефектов на изображениях принципиально различных типов. Установлено некоторое преимущество глубоких сверточных нейронных сетей по сравнению с многослойным персептроном с точки зрения достоверности распознавания фрагментов, содержащих дефектные объекты (примеси, аппликативные локальные искажения). Главной трудностью при их применении является необходимость качественной ручной разметки материала для подготовки обучающих данных и влияние субъективного фактора при определении «плохих» и «хороших» фрагментов. Поэтому при наличии необходимой квалификации разработчика с точки зрения выполнения эффективной предварительной обработки и подготовки набора информативных признаков применение классической парадигмы в

виде многослойного персептрона для решения указанной задачи остается актуальным.

СПИСОК ЛИТЕРАТУРЫ

1. Xie, X. A review of recent advances in surface defect detection using texture analysis techniques / X. Xie // *Electronic Letters on Computer Vision and Image Analysis*, 2008. – Vol. 7 (3). – P. 1–22.
2. Optical and Infrared Vision Non-Destructive Techniques: Integration as a means for the Defects Detection on Impacted Composite Materials / A. Bendada [et al.] // *Proceedings of the 4th International Conference on Crack Paths (CP 2012)*, Gaeta, Italy. – 2012. – P. 841–848.
3. Sezgin, M. Selection of thresholding methods for nondestructive testing applications / M. Sezgin, B. Sankur // *In: Proceedings. 2001 International Conference on Image Processing*. IEEE. – P. 764–767.
4. Weimer, D. Learning Defect Classifiers for Textured Surfaces Using Neural Networks and Statistical Feature Representations / D. Weimer, H. Thamer, B. Scholz-Reiter // *Procedia CIRP*, 2013. – Vol. 7. – P. 347–352.
5. A Learning-Based Approach for Automatic Defect Detection in Textile Images / D. Yapi [et al.] // *IFAC-PapersOnLine*, 2015. – Vol. 48(3). – P. 2423–2428.
6. A fast and robust convolutional neural network-based defect detection model in product quality control / T. Wang [et al.] // *Int. J. Adv. Manuf. Technol.* – 2018. – Vol. 94, – P. 3465–3471.
7. Kalinin, P. V. A graph based approach to hierarchical image over-segmentation / P. V. Kalinin, A. A. Sirota // *Computer Vision and Image Understanding*. – 2015. – Vol. 130, – P. 80–86.
8. Young-Jin, C. Deep Learning-Based Crack Damage Detection Using Convolutional Neural Networks / C. Young-Jin, C. Wooram, B. Oral // *Computer-Aided Civil and Infrastructure Engineering*, 2017. – Vol. 32(5). – P. 361–378.
9. Real-time Defect Detection Method for Printed Images Based on Grayscale and Gradient Differences / W. Yangping [et al.] // *Journal of Engineering Science and Technology Review*, 2018. – Vol. 11 (1). – P. 180–188.

10. Nakagaki, R. Automatic recognition of defect areas on a semiconductor wafer using multiple scanning electron microscope images / R. Nakagaki, T. Honda, K. Nakamae // Measurement Science and Technology. – 2009. – Vol. 20 (7). – P. 075503–12.

11. Аппаратно-программный комплекс для анализа неоднородного потока объектов в системах фотосепарации реального времени / Э. К. Алгазинов [и др.] // Измерительная техника: оптико-физические измерения. – 2014. – №5. – С. 23–29.

12. Semiconductor wafer defect detection using digital holography / M. A. Schulze [et al.] //

Proc. SPIE 5041, Process and Materials Characterization and Diagnostics in IC Manufacturing, 2003. – doi: 10.1117/12.485237.

13. Калинин, П. В. Статистические, нейросетевые и комбинированные алгоритмы фильтрации аппликативных помех на изображениях / П. В. Калинин, А. А. Сирота // Автометрия. – 2012. – № 6. – С. 18–28.

14. Гонсалес, Р. Цифровая обработка изображений / Р. Гонсалес, М. Вудс. – М.: Техносфера, 2005. – 1072 с.

15. Гудфеллоу, Я. Глубокое обучение / Я. Гудфеллоу, И. Бенджио, А. Курвилль – 2-е изд., испр. – М.: ДМК Пресс, 2018. – 652 с.

Дрюченко Михаил Анатольевич – доцент кафедры технологий обработки и защиты информации Воронежского государственного университета.

E-mail: m_dryuchenko@mail.ru

Сирота Александр Анатольевич – профессор, зав. кафедрой технологий обработки и защиты информации Воронежского государственного университета.

E-mail: sir@cs.vsu.ru

Гаршина Вероника Викторовна – доцент кафедры технологий обработки и защиты информации Воронежского государственного университета.

E-mail: garshina@cs.vsu.ru

Митрофанова Елена Юрьевна – доцент кафедры технологий обработки и защиты информации Воронежского государственного университета.

E-mail: mitrofanova.e_yu@mail.ru

Dryuchenko Mikhail Anatolievich – docent at the Chair of Information Processing and Security Technologies at Voronezh State University.

E-mail: m_dryuchenko@mail.ru

Sirota Alexander Anatolievich – prof., Head of the Chair of Information Processing and Security Technologies at Voronezh State University,

E-mail: sir@cs.vsu.ru

Garshina Veronika Viktorovna – docent at the Chair of Information Processing and Security Technologies at Voronezh State University.

E-mail: garshina@cs.vsu.ru

Mitrofanova Elena Yurievna – docent at the Chair of Information Processing and Security Technologies at Voronezh State University.

E-mail: mitrofanova.e_yu@mail.ru