

УДК 620.179.14

А.Н. Петренко, А.Е. Кучеренко

## МЕТОД АВТОМАТИЧЕСКОЙ ЛОКАЛИЗАЦИИ И КЛАССИФИКАЦИИ ДЕФЕКТОВ

### Введение

Одна из главных задач дефектоскопии – задача локализации и классификации дефектов. Проблема состоит в определении дефекта в контролируемом изделии, выявлении его положения и соотнесении этого дефекта к определенному классу, что в свою очередь позволяет принять решение о годности контролируемого изделия [1].

Цифровая обработка изображений позволяет автоматизировать интерпретацию и анализ данных, что делает систему контроля более надежной, производительной и повышает экономическую отдачу. Основной недостаток существующих алгоритмов обработки цифровых изображений – жесткая привязка к начальным условиям и, соответственно узкая специализация. Результаты работы существующих алгоритмов существенно ухудшаются при наличии шумов в исходных данных. Таким образом, задача автоматического анализа цифровых изображений является нетривиальной.

Альтернативный подход в цифровой обработке изображений - использование нейронных сетей. Использование нейросетевых методов позволяет упростить процесс кластеризации изображения, а значит - и процесс выделения ключевых признаков изображения. При работе с искаженными изображениями нейронные сети позволяют выполнить фильтрацию данных, не прибегая к специальным приемам.

### Проблема локализации и классификации дефектов

Основной этап в процедуре автоматического анализа изображений - извлечение признаков и их классификация, для чего осуществляется кластерный анализ изображения. Каждая независимая измеряемая величина называется признаком. Основная парадигма состоит в том, чтобы выбрать  $n$  измеряемых величин объекта, подлежащего классификации, и затем отобразить результат в точку в  $n$ -мерном пространстве признаков. Вектор признаков (образ)

образуется как совокупность этих величин:  $x=[x_1 \ x_2 \ \dots \ x_n]$ . С помощью алгоритма кластеризации пространство признаков разбивается на части на основании некоторого математического критерия. Неизвестный объект принадлежит классу, соответствующему той части, в которую попал вектор признаков. После кластеризации в каждой области изображения проводятся простые измерения, как то площадь, периметр и т.д. Затем объект, породивший каждую область, идентифицируется с помощью классификации, основанной на этих измерениях.

Основной недостаток существующих алгоритмов кластеризации изображений является высокий уровень ошибок при анализе изображений, на котором присутствует большое количество пересекающихся объектов (что встречается довольно часто на рентгенограммах в виде небольших низкоконтрастных дефектов и больших дефектов, которые пересекаются с другими структурами). Данный факт позволяет предположить эффективность использования нейронных сетей при кластеризации и классификации элементов цифровых изображений [2].

Таким образом, можно выделить следующие задачи, возникающие при анализе цифрового изображения: 1) подготовка изображения к обработке – масштабирование, фильтрация; 2) определение признаков, по которым будет осуществляться кластеризация; 3) разбиение множества образов на классы; 4) идентификация объектов на изображении.

### **Метод автоматической обработки цифровых изображений**

На первом этапе обработки изображения производятся стандартные преобразования без потерь типа поворота изображения, обрезания несущественных элементов. Далее производится приведение разрешения изображения к одному из стандартных.

Фильтрация и очистка изображения осуществляется обычно с помощью гомоморфных фильтров, применяемых для разделения сигналов. Далее изображение переводится из полутонового в бинарное и инвертируется. В предлагаемой методике фильтрация изображения осуществляется с помощью нейронной сети Элмана с одним скрытым слоем, что позволяет выполнить три задачи: 1) очистить изображение от шума; 2) преобразовать изображение в бинарное; 3) выделить на

изображении необычные участки, т.е. выполнить сегментацию изображения.

Определение классификационных признаков обработанного таким образом изображения является важным этапом в анализе изображения, так как с одной стороны недостаточное их количество заведомо приведет к ошибкам в классификации, а избыточное – к существенному понижению производительности. В [3] рекомендован следующий минимальный набор признаков для бинарных изображений: 1)  $x_1$  – количество объектов; 2)  $x_2$  – площадь всех объектов; 3)  $x_3$  – периметр всех объектов; 4)  $x_4$  – число Эйлера. Для классификации объектов на изображении предлагается использовать многослойную нейронную сеть прямого распространения (сеть свертки), которая способна осуществлять свертку, или сжатие пространства признаков [4].

Среди множества различных видов дефектов можно выделить такие общие классы: 1) раковина – объемное образование в материале; 2) трещина – узкое углубление на поверхности; 3) окалина – объемное образование на поверхности материала, возникшее в результате нагрева. На рис. 1 приведены рентгенограммы соответствующих дефектов.

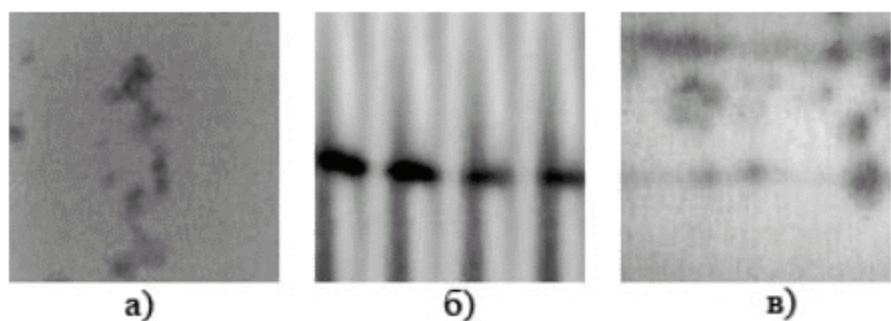


Рисунок 1 – Рентгенограммы: а) раковины в алюминиевой заготовке; б) трещина в стальной трубе с резьбой; в) окалина на поверхности стальной заготовки

На рис. 2 представлены изображения, которые были отфильтрованы и сегментированы с помощью нейронной сети. Фильтрация и сегментация изображения осуществлялась следующим образом. Скользящее окно размером  $3 \times 3$  передвигалось по изображению так, чтобы каждая его точка в свою очередь оказалась в центре этого окна.

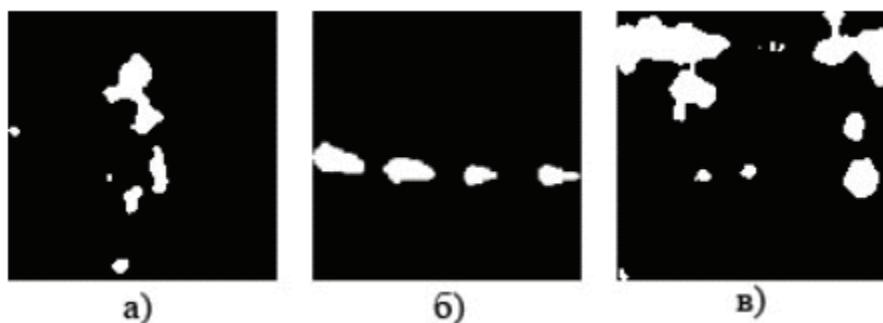


Рисунок 2 – Рентгенограммы после обработки: а) раковины в алюминиевой заготовке; б) трещина в стальной трубе с резьбой; в) окалина на поверхности стальной заготовки

Соответственно матрица размером 3x3 подавалась на вход нейронной сети, которая осуществляла сегментацию. Некоторые правила сегментации представлены на рис. 3.

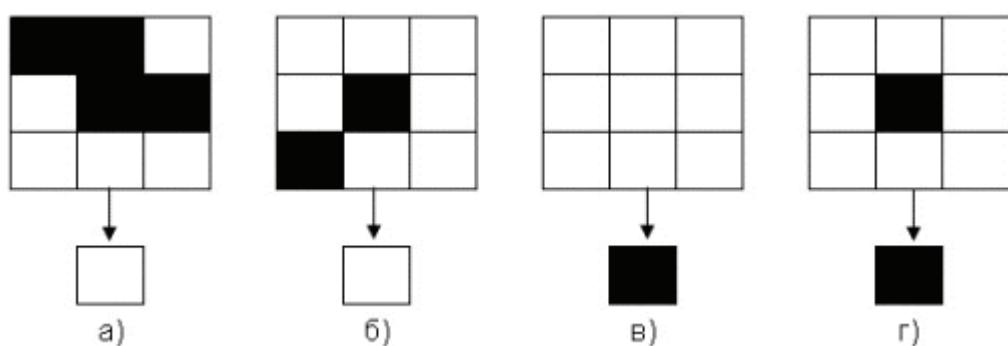


Рисунок 3 – Правила сегментации изображения: а) и б) инверсия центральной черной точки при наличии связи хотя бы с одной черной точкой; в) инверсия центральной белой точки при отсутствии связей с черными точками; г) центральная черная точка без изменения при отсутствии связей с черными точками

Сеть, предназначенная для предварительной обработки изображения, представляет собой нейронную сеть Элмана с 9 входами, 19 нейронами в скрытом слое и 1 нейроном в выходном слое. Скорость обучения сети составляла 0.05. Алгоритм обучения принадлежит к классу scaled conjugate gradient backpropagation. Первый этап обучения осуществлялся на выборке из 50 матриц размером 9x9, второй этап состоял в использовании тех же 50 матриц с добавлением аддитивного белого шума со средним 0 и среднеквадратичным отклонением 5. Первый этап обучения сеть успешно закончила за 613 эпох, второй – за 480. После обучения все исходные изображения были сегментированы сетью (примеры сегментированных изображений представлены на рис. 2). На этом этапе на бинарном изображении можно достаточно точно локализовать дефект, который представлен на изображении белым цветом.

Далее для каждого бинарного изображения определялся образ  $x=[x_1 \ x_2 \ x_3 \ x_4]$ . Для изображений на рис. 2 образы соответствуют: а)  $x=[6 \ 593.8 \ 209.8 \ 6]$ ; б)  $x=[4 \ 552 \ 176,4 \ 4]$ ; в)  $x=[10 \ 1786,5 \ 62,3 \ 10]$ . Каждый образ уникален и характеризует соответствующее изображение. Образ подавался на вход нейронной сети свертки, которая определяла его принадлежность к одному из трех классов.

Сеть свертки представляет собой многослойный персепtron с 4 входами; в первом, втором, третьем и четвертом скрытом слое количество нейронов составляет 144, 36, 48, 12, в выходном слое – 3. Передаточные функции во всех слоях – логарифмический сигмоид. Количество нейронов выбиралось исходя из следующих соображений. Каждый из 4 входных признаков соответствует одной из 4 карт размером 6х6 элементов, которые осуществляют подвыборку особенностей каждого признака; это соответствует  $4*(6*6)=144$  нейронам. Далее изменяя количество элементов карт и количество самих карт получены такие параметры: 1) второй скрытый слой соответствует 4 картам размером 3х3 элемента (всего 36 нейронов); 2) третий скрытый слой соответствует 12 картам размером 2х2 элемента (48 нейронов); 3) четвертый скрытый слой соответствует 12 картам размером 1х1 элемент (12 нейронов); 4) в выходном слое содержится 3 нейрона, что соответствует 3 классам. Данная сеть показала наилучшие результаты по скорости обучения и точности классификации по сравнению с сетями других типов с аналогичным общим количеством нейронов в скрытых слоях, но иной архитектурой.

Скорость обучения сети составляла 0.05. Алгоритм обучения также принадлежит к классу scaled conjugate gradient backpropagation. Первый этап обучения осуществлялся на выборке из 30 образов, полученных из сегментированных изображений, второй этап состоял в использовании тех же 30 образов с добавлением аддитивного белого шума со средним 0 и среднеквадратичным отклонением 5. Первый этап обучения сеть успешно закончила за 543 эпохи, второй - за 412. После обучения на вход сети для классификации дефектов подавались образы рентгенограмм, как использованных в процессе обучения, так и неизвестных нейронной сети.

На рис. 4 приведена общая схема процесса автоматической обработки цифрового изображения.

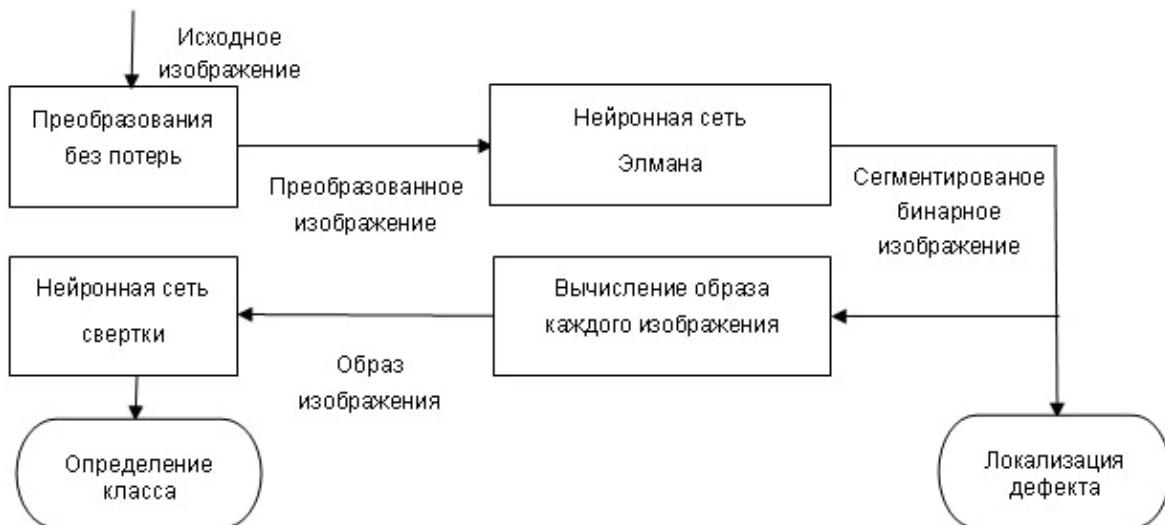


Рисунок 4 - Схема автоматического анализа изображения

### Заключение

Применение нейронных сетей для автоматической обработки изображений – эффективный метод, который позволяет с высокой точностью определять положение аномальных областей на изображении и осуществлять их классификацию. Так, было проанализировано 40 рентгенограмм дефектных объектов. Из них 30 использовались для обучения нейронных сетей, в том числе и с различным уровнем шума. После окончания обучения точность классификации дефектов на рентгенограммах из обучающей выборки достигла 96,6%. Точность классификации дефектов на серии изображений, которые не участвовали в обучении (исходные и искаженные изображения), составила 89%, что является хорошим результатом по сравнению со стандартными алгоритмами, применяемыми для анализа изображений.

### ЛИТЕРАТУРА

1. Малайчук В.П., Мозговой А.В. Математическая дефектоскопия: Монография. – Днепропетровск: Системные технологии, 2005.
2. LeCun Y., Bengio Y. “Convolutional networks for images, speech and time series”, in M.A. Arbib, ed., The Handbook of Brain Theory and Neural Networks, Cambridge, MA: MIT Press, 1995.
3. Gose E., Johnsonbaugh R., Jost S. Pattern Recognition and Image Analysis. Prentice Hall of India, 1997.
4. Хайнин С. Нейронные сети: полный курс, 2-е изд., испр.: Пер. с англ. - М.: ООО «И.Д. Вильямс», 2006.

Получено 31.07.2007 г.