

Разработка алгоритма распознавания изображений для автоматизированной системы контроля дефектов стеклоткани на основе методов машинного обучения

А.А. Казначеева¹, О.М. Власенко¹, С.В. Захаркина¹, Е.Б. Гончарова²

¹Российский государственный университет имени А.Н. Косыгина
(Технологии. Дизайн. Искусство), г. Москва

²Национальный исследовательский университет «Московский энергетический институт»

Аннотация: В статье предложен алгоритм определения дефектов стеклоткани с помощью методов машинного обучения. Рассмотрены различные типы архитектур нейронных сетей, такие как модели с частотой срабатывания нейронов, сеть Хопфилда, ограниченная машина Больцмана, сверточные нейронные сети. Для разработки алгоритма выбрана сверточная нейронная сеть. В результате тестирования программы нейросеть отработала корректно с высоким показателем процента обучения.

Ключевые слова: стеклоткань, дефекты, машинное обучение, сверточные нейронные сети, тестирование, точность.

На сегодняшний день контроль качества текстильных материалов, в который входит обнаружение дефектов, является одним из ключевых этапов производства. Процесс определения брака проходит в несколько этапов, одним из которых является сканирование полотна. Целью сканирования является обнаружение и распознавание дефектов, их идентификация и классификация. На основании этого этапа может быть принято решение о необходимости дополнительной обработки материала. Однако в текстильной промышленности, включая предприятия по выпуску стеклоткани, разбраковка по-прежнему остается в значительной степени ручной [1]. Решением данной проблемы является разработка автоматизированной системы контроля дефектов полотен на основе алгоритма распознавания изображений с применением методов машинного обучения. Это позволит анализировать объекты на изображении, идентифицировать их, проводить классификацию и группировку.

Стекловолокно получают путем протягивания стекла через фильеры с большим количеством отверстий, охлаждения, замасливания и намотки

полученных нитей на бобины. Диаметр волокна зависит от скорости вытяжки, размера и формы отверстий фильера, температуры плавления. Различают толстое (диаметр нити свыше 25 мкм), утолщенное (диаметр нити до 12-15 мкм), тонкое (4-12 мкм) и сверхтонкое (1-3 мкм) стекловолокно [2].

Из непрерывных элементарных нитей формируются сложные нити (линейная плотность до 100 Текс), пучки (ровинги, линейная плотность свыше 100 Текс), или жгуты.

Из стекловолокон изготавливают стеклоткань, сетки, нетканые конструкционные полотна. Стекловолокно и производные из него материалы имеют ряд уникальных свойств: термостойкость, огнеупорность, низкую гигроскопичность, высокую устойчивость к деформации сжатия-растяжения, устойчивость к химическим и биологическим воздействиям [3]. Благодаря этим свойствам, стекломатериалы применяются в строительстве как утеплители и армирующие компоненты, в электротехнике, в производстве инструментов, в судо- и автомобилестроении и др. Стеклоткани могут использоваться и как декоративные элементы, для этого они проходят дополнительную обработку, пропитываются различными веществами, например латексом, полиуретановой смолой, крахмалом и др.

В процессе производства стеклоткани, как и при выработке любых других текстильных материалов, возможно образование дефектов, связанных с некорректной настройкой или калибровкой ткацких машин, неправильным натяжением нити, изменениями структуры материала или сбоями в работе оборудования. Наиболее часто встречаются следующие: 1) масляное пятно (распространено при неаккуратном обращении с материалом при транспортировке и хранении продукта); 2) недосека забойна (характеризуется неполным погружением связующего материала в структуру ткани во время ее производства, что в свою очередь влечет появление неровностей в структуре, уменьшение плотности материала, понижение его прочности и

стойкости); 3) слет утка (происходит при нарушении процесса укладки и распределения нитей утка, определяется как отклонение от нормального узора или мотива ткани); 4) близна (характеризуется неровностью или впадиной, напоминающей след от шва или складки).

Задача построения системы компьютерного зрения для обнаружения дефектов на стеклоткани является актуальной в виду сложности технологического процесса производства, высокой стоимости материала и потенциальных последствий человеческих ошибок, поэтому для создания такой системы предлагается использовать методы «глубокого» обучения нейросети. Применение этих технологий позволит повысить точность и надежность процесса выявления дефектов полотна, а также понизить вероятность пропуска бракованных участков, что в конечном итоге повысит общую производительность производственного участка.

В основе нейронной сети, как в компьютерной программе, лежат определенные алгоритмы анализа и обработки данных [4]. Типичной архитектурой является модель прямой связи, включающей в себя размещение нейронов слоями, которые последовательно обрабатывают информацию. Персептрон с одним входным слоем и выходом представляет собой простой пример такой сети.

Сетевые модели с частотой срабатывания нейронов относятся к простому классу нейронных схем [5]. В простейшем случае общий входной сигнал Q_m в выходной блок определяется выражением:

$$Q_m = \sum_{i=1}^K w_i \int_{-\infty}^t d\varphi N_m(t - \varphi) \cdot x_i(\varphi), \quad (1)$$

где K – количество нейронов, проецируемых на данный выходной нейрон; x – входная активность нейронов; N_m – синаптическое ядро, которое описывает, как входная импульсная частота линейно преобразуется во входной ток для выходного нейрона; w_i – вес (сила) каждого синапса i ($i = 1, \dots, K$). Используя

экспоненциальное ядро, динамику этой схемы можно представить следующим образом:

$$\varphi_m \frac{dQ_m}{dt} = -Q_m + \sum_{i=1}^K w_i \cdot x_i, \quad (2)$$

Импульсная частота выходного блока обычно представляет собой нелинейную функцию общего входного тока: $y = F(Q_m)$. F может быть линейной выпрямительной или сигмоидной функцией [6].

Одним из ключевых вычислительных компонентов обработки зрительного сигнала является то, что одна и та же операция повторяется во всем визуальном поле. Этот тип операции реализуется посредством свертки [6]. Для двух функций $f(t)$ и $g(t)$ операция свертки определяется как интеграл от произведения двух сигналов:

$$f(t) \cdot g(t) = \int_{-\infty}^{\infty} f(\varphi) \cdot g(t - \varphi) d\varphi, \quad (3)$$

Следующим шагом производится объединение сигналов от нескольких простых нейронов для создания сложного нейрона с аналогичной настройкой, но реагирующего независимо от положения приоритетного признака в визуальном поле. Эта операция увеличивает размер визуального поля, то есть состоит в том, чтобы взять максимум всех входных значений.

Более сложная динамика обработки сигналов может быть получена путем использования рекуррентных сетей. К такой архитектуре относится сеть Хопфилда [7]. Она характеризуется одним слоем с бинарными нейронами и симметричными весами, где все нейроны связаны между собой. Обновление состояния нейрона, в соответствии с пороговой и взвешенной суммой входных данных от всех других нейронов можно представить следующей формулой:

$$h_i(t + 1) = \text{sign}\left(\sum_{j \neq i}^K w_{ij} h_j(t) - \gamma\right), \quad (4)$$

где $h_i(t)$ – состояние блока i в момент времени t , которое может принимать значение 0 или 1 для двоичной сети; γ – порог. Таким образом состояние сети может быть представлено вектором:

$$h(t) = [h_1(t), \dots, h_K(t)], \quad (5)$$

где K – общее количество нейронов.

В данных рекуррентных сетях можно определить функцию энергии (6), значения которой снижаются на каждом шаге процесса обучения модели. Это позволяет поддерживать стабильность сети. Другими словами, сеть имеет состояния устойчивости, к которым она будет сходиться при запуске в произвольных состояниях.

$$E(t) = -\frac{1}{2} \sum_{ij} w_{ij} h_i(t) h_j(t) + \sum_i h_i(t) \gamma_i, \quad (6)$$

Одним из перспективных направлений развития архитектур нейросети является модель машины Больцмана, которая представляет собой вероятностный вариант сети Хопфилда [8]. В отличие от детерминированной ступенчатой функции нейроны в данных сетях генерируют с определенной вероятностью выходное значение 1 или 0, где вероятность активации i -го нейрона определяется по формуле:

$$P_i = \frac{1}{1 + \exp(-E_i/f)}, \quad (7)$$

где f – уровень теплового шума; E_i – сумма весов связей нейрона с нейронами активными в текущий момент.

Нейроны принимают начальное состояние, далее начинается процесс поиска состояния сети с минимальной энергией. Каждый нейрон сети с вероятностью P_i принимает значение 1, а с вероятностью $(1 - P_i)$ принимает значение 0. В исходный момент времени устанавливаются большие значения температуры, и далее они медленно уменьшаются с течением времени до тех пор, пока не будет достигнуто равновесие.

Обучение машины Больцмана требует больших затрат времени и

вычислительных ресурсов. Для уменьшения этих недостатков предложена ограниченная машина Больцмана, в которой устанавливаются связи только между нейронами в разных слоях. Бинарные элементы определяются как элементарные гипотезы, а веса – как парные взаимоограничения между ними. Если гипотезы поддерживают друг друга, то вес связи положительный, если гипотезы несовместимы, то вес связи отрицательный. Такой подход решил задачу повышения производительности алгоритмов глубокого обучения на основе многослойных рекуррентных сетей.

Еще одним распространенным подходом к повышению эффективности обучения является модель сверточной нейронной сети (convolutional neural networks – CNN). Архитектура включает следующие слои [9]: 1) сверточные, в которых нейроны объединяются в карты признаков по одинаковым весам; 2) субдискретизирующие, применяющиеся для снижения размерности изображения; 3) полносвязные, в которых каждый нейрон предыдущего слоя соединен со всеми нейронами последующего.

Стандартный слой характеризуется ядром свертки K размера $O_c \times I_c \times K \times K$, где O_c – количество выходных каналов, I_c – количество входных каналов, K – пространственная размерность ядра. Имея входную карту признаков F_i размера $I_c \times H \times W$, вычисляем выходную карту признаков F_o размера $O_c \times H \times W$ по следующей формуле:

$$F_o[n, h, w] = \sum_{m, i, j} K[n, m, i, j] \times F_i \left[m, h + 1 - \left\lfloor \frac{K}{2} \right\rfloor, w + j - \left\lfloor \frac{K}{2} \right\rfloor \right], \quad (8)$$

Для представления стандартного слоя свертки с размером ядра K будем использовать выражение $F_o = Conv_{K \times K}(F_i, K)$. Согласно формуле (8) вычислительная мощность свертки равна:

$$MAC_s(Conv_{K \times K}) = H \times W \times O_c \times I_c \times K \times K \quad (9)$$

На сегодняшний день сверточные нейронные сети используются в решении разнообразных задач, но основным применением является

обработка изображений [10], поэтому для создания алгоритма распознавания изображений дефектов на стеклоткани была выбрана модель остаточной нейронной сети (residual neural network – ResNet). Она может иметь 18, 50, 101 или 150 слоев. Блоки слоев сгруппированы для изучения функции, которая сопоставляет входные данные с выходными в виде остаточного отображения [10, 11].

```
[ ] label_to_class = {0: '0. Норма',  
                    1: 'Дефект 1. Недосека забоина',  
                    2: 'Дефект 2. Масляное пятно',  
                    3: 'Дефект 3. Слет утка',  
                    4: 'Дефект 4. Близна'}  
  
class_to_label = {v: k for k, v in label_to_class.items()}
```

Рис. 1. – Определение словаря классов дефектов

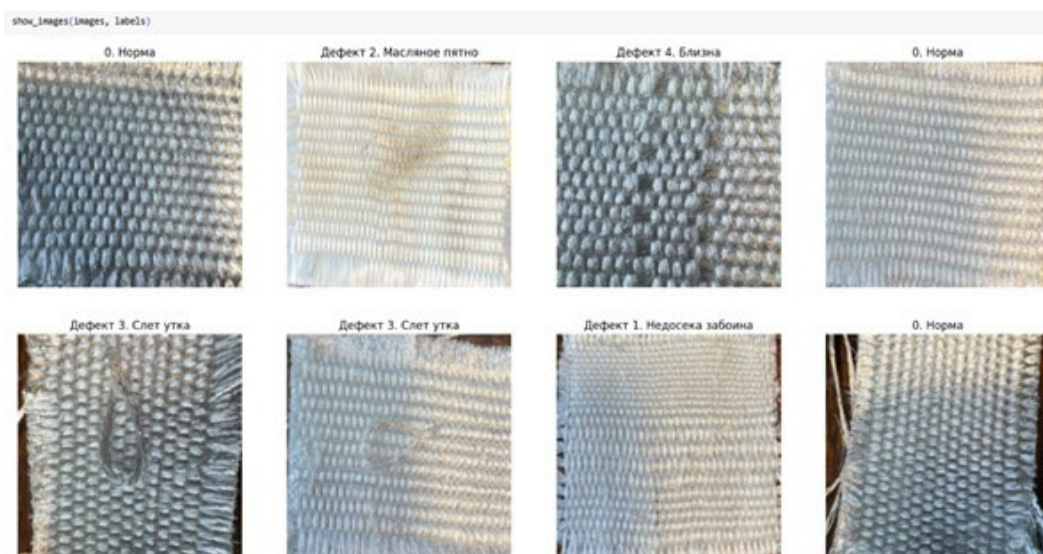


Рис. 2. – Визуализация изображений классов дефектов стеклоткани

Разработка программы проводилась с использованием платформы Google Colab на языке программирования Python. После добавления в проект набора данных и библиотек Keras, TensorFlow и PyTorch, создали словарь `label_to_class`, в котором числовым меткам с названиями классов дефектов стеклоткани ставятся в соответствие образцы «Норма». На рис. 1 приведен полученный словарь классов дефектов. На рис. 2 представлены результаты визуализации классов дефектов, полученные с помощью функции

show_images.

В процессе обучения нейронной сети для извлечения признаков из входного набора данных использовали функцию `get_embedding`. Эта функция позволяет прогнать все изображения через предварительно обученную модель и получить в итоге вектор признаков, описывающих изображения. Еще одной функцией является `dataloader` для обучающегося и тестового набора данных. Количество эпох 20. На рис. 3 приведены результаты обучения нейронной сети. Время обучения эпох составило 30 минут. Максимальный результат обучения уже на 10 эпохе достиг 93.9%. Полученные результаты являются приемлемыми для модели глубокого обучения.

```
Epoch 5: 100%|██████████| 1/1 [00:30<00:00, 30.33s/it, train_loss=0.85]
Validation Loss: -0.2366759032011032, Validation Accuracy: 0.9090909090909091
Epoch: 5
Epoch 6: 100%|██████████| 1/1 [00:29<00:00, 29.59s/it, train_loss=0.737]
Validation Loss: -0.1456703245639801, Validation Accuracy: 0.9090909090909091
Epoch: 6
Epoch 7: 100%|██████████| 1/1 [00:30<00:00, 30.27s/it, train_loss=0.71]
Validation Loss: -0.12918783724308014, Validation Accuracy: 0.9090909090909091
Epoch: 7
Epoch 8: 100%|██████████| 1/1 [00:31<00:00, 31.32s/it, train_loss=0.549]
Validation Loss: -0.1275155395269394, Validation Accuracy: 0.9090909090909091
Epoch: 8
Epoch 9: 100%|██████████| 1/1 [00:29<00:00, 29.94s/it, train_loss=0.526]
Validation Loss: -0.16328468918800354, Validation Accuracy: 0.9090909090909091
Epoch: 9
Epoch 10: 100%|██████████| 1/1 [00:35<00:00, 35.02s/it, train_loss=0.638]
Validation Loss: -0.1911369264125824, Validation Accuracy: 0.9393939393939394
```

Рис. 3. – Результаты обучения нейронной сети

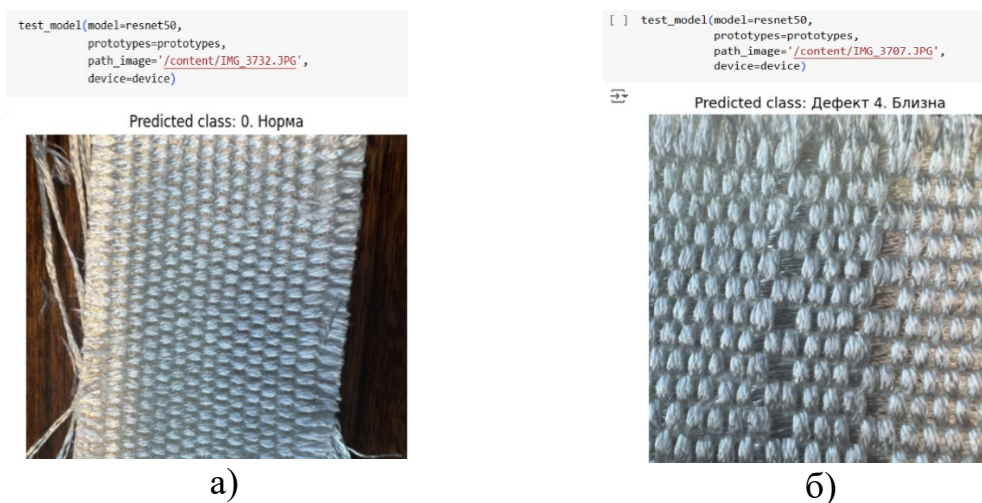


Рис. 4. Результат работы нейросети. Распознавание классов дефектов на примерах: а) «Норма», б) «Близна»

Результат корректной работы нейросети отображен на рис. 4. Проверка распознавания классов дефектов произведена в Google Colab после загрузки изображений, которые не вошли в обучающий и тестовый наборы данных.

Таким образом установлено, что стеклоткань представляет собой материал со сложной структурой, а процесс ее изготовления считается трудоемким. Для создания алгоритма распознавания изображений при контроле дефектов применялась сверточная нейронная сеть. Модель, основанная на архитектуре ResNet в процессе обучения и тестирования, показала отличные результаты. Процент обучения составил 93.9%.

Литература

1. Kaznacheeva A.A., Vlasenko O.M., Zakharkina S.V., Ryzhkova E.A., Stupak M.M. Application of neural network technologies in the tasks of quality control of textile products. // II International scientific forum on sustainable development and innovation (WFSDI 2023). 2024. pp.304-311.
2. Бондарева Т.П., Кузнецова А.В. Исследование технологии выработки стеклоткани с целью снижения ее уровня дефектности. // Материалы и технологии. 2018, №1. URL: cyberleninka.ru/article/n/issledovanie-tehnologii-vyrabotki-steklotkani-s-tselyu-snizheniya-ee-urovnya-defektnosti.
3. Ложкин Н.Д., Рыжкова Е.А. Методы контроля плотности при производстве стекловолокна. // Молодежная наука и образование: новые вызовы и векторы развития. Материалы международной студенческой научно-практической конференции. Краснодар, 2024. С. 42-52.
4. Рыжкова Е.А., Казначеева А.А., Казанцева А.М. Нейросетевые решения на основе архитектуры U-Net для автоматического определения контуров натуральных кож. // Инженерный вестник Дона. 2024. №12. URL: ivdon.ru/ru/magazine/archive/n12y2024/9679/.

5. Wang J., Wang H., Chen Y., Liu C. A constructive algorithm for unsupervised learning with incremental neural network. *Journal of Applied Research and Technology*, 13 (2015). pp. 188-196.

6. Хун Чжоу. Машинное обучение сквозь призму Excel. М: ДМК-Пресс, 2025. 270 с.

7. Sarimveis H., Alexandridis A., Bafas G. Neural network model identification based on the subtractive clustering method. 15th Triennial World Congress, Barcelona, Spain, 2002. pp. 349-354.

8. Гладков Л.А., Гладкова Н.В., Бабынин А.Н., Ксалов А.М. Метод распознавания изображений на основе моделей машины Больцмана. // Известия Кабардино-Балкарского научного центра РАН. 2015. №6. С. 54-60.

9. Ступак М.М., Казначеева А.А. Анализ существующих архитектур нейронных сетей. // Инновационное развитие техники и технологий в промышленности. Сборник материалов Всероссийской научной конференции молодых исследователей с международным участием. 2023. С. 253-256.

10. Танг Д. Умные мобильные проекты с TensorFlow. ДМК-Пресс, 2019. 384 с.

References

1. Kaznacheeva A.A., Vlasenko O.M., Zakharkina S.V., Ryzhkova E.A., Stupak M.M. II International scientific forum on sustainable development and innovation (WFSDI 2023). 2024. pp.304-311.

2. Bondareva T.P., Kuznecova A.V. *Materialy i tekhnologii*. 2018, №1. URL: cyberleninka.ru/article/n/issledovanie-tehnologii-vyrobotki-steklotkani-s-tselyu-snizheniya-ee-urovnya-defektnosti.

3. Lozhkin N.D., Ryzhkova E.A. *Molodezhnaya nauka i obrazovanie: novye vyzovy i vektory razvitiya*. Materialy mezhdunarodnoj studencheskoj nauchno-prakticheskoy konferencii. Krasnodar, 2024. pp. 42-52.



4. Ryzhkova E.A., Kaznacheeva A.A., Kazantseva A.M. Inzhenernyj vestnik Dona. 2024. №12. URL: ivdon.ru/ru/magazine/archive/n12y2024/9679/.
5. Wang J., Wang H., Chen Y., Liu C. Journal of Applied Research and Technology, 13 (2015). pp. 188-196.
6. Hun CHzhou. Mashinnoe obuchenie skvoz' prizmu Excel [Learn Data Mining Through Excel]. DMK-Press: M, 2025. 270 pp.
7. Sarimveis H., Alexandridis A., Bafas G. Neural network model identification based on the subtractive clustering method. 15th Triennial World Congress, Barcelona, Spain, 2002. pp. 349-354.
8. Gladkov L.A., Gladkova N.V., Babynin A.N., Ksalov A.M. Izvestiya Kabardino-Balkarskogo nauchnogo centra RAN. 2015. №6. pp. 54-60.
9. Stupak M.M., Kaznacheeva A.A. Sbornik materialov Vserossijskoj nauchnoj konferencii molodyh issledovatelej s mezhdunarodnym uchastiem, 2023. pp. 253-256.
10. Tang D. Umnye mobil'nye proekty s TensorFlow [Smart Mobile Projects with TensorFlow]. DMK-Press, 2019. 384 pp.

Дата поступления: 19.02.2025

Дата публикации: 25.04 2025