

Труды МАИ. 2025. № 142  
Trudy MAI. 2025. No. 142. (In Russ.)

Научная статья

УДК 658.5

URL: <https://trudymai.ru/published.php?ID=185116>

EDN: <https://www.elibrary.ru/URZFFZG>

## **ПРИМЕНЕНИЕ МЕТОДОВ СИСТЕМНОГО АНАЛИЗА И МАШИННОГО ОБУЧЕНИЯ ДЛЯ АВТОМАТИЗАЦИИ ЧТЕНИЯ ЧЕРТЕЖЕЙ**

**Даниил Андреевич Девятков<sup>1</sup>, Мария Равилевна Королева<sup>2</sup>,  
Михаил Сергеевич Лялин<sup>3</sup>, Ольга Владимировна Мищенкова<sup>4</sup>,  
Алена Алексеевна Чернова<sup>5</sup>✉**

<sup>1,4,5</sup>Ижевский государственный технический университет имени М.Т. Калашникова,  
Ижевск, Россия

<sup>2</sup>Удмуртский федеральный исследовательский центр Уральского отделения  
Российской академии наук, Ижевск, Россия

<sup>3</sup>Ижевский нефтяной научный центр, Ижевск, Россия

<sup>1</sup>[divatov\\_daniil1999@mail.ru](mailto:divatov_daniil1999@mail.ru)

<sup>2</sup>[koroleva@udman.ru](mailto:koroleva@udman.ru)

<sup>3</sup>[mcldays@gmail.com](mailto:mcldays@gmail.com)

<sup>4</sup>[mov@istu.tu](mailto:mov@istu.tu)

<sup>5</sup>[alicaaaa@gmail.com](mailto:alicaaaa@gmail.com)✉

**Аннотация.** Данная работа посвящена вопросам построения эффективного и универсального подхода к автоматизации распознавания инженерных чертежей. Выполнена систематизация и классификация элементов чертежей, что позволило

выделить общие характеристики и признаки, необходимые для их структурированного описания. Предложен алгоритм идентификации технологических элементов, реализованный с использованием нейронной сети. Модель адаптирована для поиска и анализа ключевых конструктивных компонентов на чертежах, демонстрируя эффективность в условиях различных типов данных. Полученные результаты закладывают основу для дальнейшего развития систем автоматизации анализа чертежей, обеспечивая интеграцию с современными инженерными процессами.

**Ключевые слова:** чертеж, автоматизация, алгоритм, машинное обучение, нейронные сети

**Для цитирования:** Девятков Д.А., Королева М.Р., Лялин М.С., Мищенко О.В., Чернова А.А. Применение методов системного анализа и машинного обучения для автоматизации чтения чертежей // Труды МАИ. 2025. № 142. URL: <https://trudymai.ru/published.php?ID=185116>

Original article

## APPLICATION OF METHODS OF SYSTEM ANALYSIS AND MACHINE LEARNING TO AUTOMATE THE READING OF DRAWINGS

Daniil A. Devyatov<sup>1</sup>, Maria R. Koroleva<sup>2</sup>, Mikhail S. Lyalin<sup>3</sup>,  
Olga V. Mishchenkova<sup>4</sup>, Alena A. Chernova<sup>5</sup>

<sup>1,4,5</sup>Kalashnikov Izhevsk state technical university, Izhevsk, Russia

<sup>2</sup>Udmurt federal research center of the Ural Branch of the Russian Academy of Sciences, Izhevsk, Russia

<sup>3</sup>Izhevsk Oil Research Center, Izhevsk, Russia

<sup>1</sup>[divatov\\_daniil1999@mail.ru](mailto:divatov_daniil1999@mail.ru)

<sup>2</sup>[koroleva@udman.ru](mailto:koroleva@udman.ru)

<sup>3</sup>[mcldays@gmail.com](mailto:mcldays@gmail.com)

<sup>4</sup>[mov@istu.tu](mailto:mov@istu.tu)

<sup>5</sup>[alicaaa@gmail.com](mailto:alicaaa@gmail.com)✉

**Abstract.** The work is devoted to the issues of building an effective and universal approach to automating the recognition of engineering drawings. The aim of the work is the construction and development of effective algorithms for recognising graphical information from drawings for the subsequent formation of initial information used in the automation of technological preparation of production. In the proposed approach the recognition of information from engineering drawings is implemented through the joint application of methods of system analysis of image objects in drawings, an adapted method of rules and mathematical apparatus of machine learning - a specialised neural network. The systematisation and classification of elements of drawings has been carried out, which allowed to identify common characteristics and features necessary for their structured description. An algorithm for identification of technological elements implemented using a neural network is proposed. The model is adapted for searching and analysing key structural components in drawings, demonstrating its effectiveness under different data types. The formulated approach and methods are tested on the task of finding and describing holes in

drawings. The validation revealed that the training model requires further training on a more massive sample. In the current version of the model makes some errors in pattern recognition, the accuracy of classification of the drawing element provided by the neural network, when retested on the validation sample, reaches 80%, which is acceptable for the prototype.

Thus, the proposed approach allows to automate the process of reading drawings and allows to form the initial information for automation of technological preparation of production. Thus, a new approach to the automation of engineering drawings analysis is formed and proposed in the work. The testing of the approach has shown that the developed system achieves the minimum accuracy required for the prototype when recognising and analysing drawing elements, which confirms its effectiveness and practical applicability. The obtained results lay the foundation for further development of systems for automation of drawing analysis, providing integration with modern engineering processes.

**Keywords:** drawing, automation, algorithm, machine learning, neural networks

**For citation:** Devyatov D.A., Koroleva M.R., Lyalin M.S., Mishchenkova O.V., Chernova A.A. Application of methods of system analysis and machine learning to automate the reading of drawings. *Trudy MAI*. 2025. No. 142. (In Russ.). URL: <https://trudymai.ru/eng/published.php?ID=185116>

## Введение

Требования, представленные к современным промышленным производствам [1] предполагают быстрое освоение новых видов изделий, реинжиниринг, в том числе

и обратный, а также переход к мгновенному развертыванию производства. Все вышеперечисленное невозможно без применения систем автоматизации производства, в том числе и систем автоматизации технологической подготовки производства. При этом существующие системы [2], в основном ориентированы на серийное и крупносерийное производство, что значительно ограничивает их применение в условиях полиноменклатурных и наукоемких производств, а также в других специализированных производственных задачах.

В работе [3,4] показано, что алгоритм автоматизации технологической подготовки производства может быть адаптирован под условия единичного и мелкосерийного производства [5], однако в этом случае требуется решить задачу автоматической подготовки исходных данных. Поскольку, согласно [6], именно этап подготовки исходной информации, включающий анализ конструкторской документации, является начальным или «входным» этапом в процесс автоматизации технологической подготовки производства.

Необходимо отметить, что процесс подготовки информации предполагает использование программного инструментария. В современных САПР (CAD, CAE) задачи распознавания и анализа изображений, а также оценки конструкторской документации, решаются методом прямой передачи системных данных о структуре и особенностях элементов изображений из систем автоматизации проектирования CAD в блок формирования технологического проектирования. В виду закрытости кодов CAD систем и, как следствие, невозможности использования истории построения

детали, актуальным остается разработка алгоритмов и методов автоматизации анализа и распознавания элементов непосредственно с чертежа.

В работе [7] рассмотрены вопросы автоматизированного распознавания графической информации с чертежей. Показано, что для эффективной работы методов обработки изображений требуется предварительный анализ как самого изображения, так и отдельных его элементов. Целью данной работы является построение и разработка эффективных алгоритмов распознавания графической информации с чертежей для последующего формирования исходной информации, используемой при автоматизации технологической подготовки производства.

Достижение поставленной цели требует формирования нового подхода к распознаванию и анализу графической информации с инженерных чертежей, основанного как на применении методов системного анализа для обобщения уникальных и типовых элементов на чертежах, так и на использовании аппарата нейронных сетей [8] для поиска, выявления и анализа данных элементов структуры.

## **1. Систематизация и классификация элементов**

Понимание различных элементов на чертеже имеет ключевое значение для их анализа [9] и классификации. В контексте чертежей, элементы [10] — это составные части, которые вместе формируют графическое представление изделия. Элементы могут включать: геометрические фигуры (линии, круги, прямоугольники), определяющие форму и размеры объекта; размерные линии и знаки, указывающие на

размеры объекта и требования к ним; марку материала; технические условия, содержащие требования к обработке, сборке и контролю качества.

Существует четыре основных подхода к классификации элементов на чертеже: методы, основанные на правилах [11], методы машинного обучения [12], гибридные методы [13] и семантическая сегментация [14]. Методы, основанные на правилах - это традиционный подход, в котором классификация осуществляется на основе заранее определённых правил. Такие правила могут включать геометрические параметры, типы линий и другие характеристики, которые легко формализовать. Методы машинного обучения могут применяться, как обучаемые, самообучаемые, так и в виде нейронных сетей. Гибридные методы предполагают комбинацию различных подходов, например, правил с элементами машинного обучения, для улучшения точности и надёжности классификации. Метод семантической сегментации основан на использовании глубокого обучения для разделения изображения [15] на сегменты, каждый из которых классифицируется отдельно, что позволяет точно определять границы объектов на чертеже.

В данной работе предложено использовать разработанную систему классификационных признаков и характеристик элементов чертежей, являющуюся адаптацией метода правил, совместно с методами машинного обучения. Этапы реализации данного подхода подробно рассматриваются ниже.

Под классификационными признаками на чертежах подразумеваются различные характеристики и элементы, позволяющие описывать и классифицировать

геометрию детали. Структурированная классификация обобщенных признаков элементов чертежа представлена на рис. 1.

Для повышения точности поиска, выделения и последующего описания элементов на чертежах введены обобщенные и уникальные признаки элементов. Под обобщёнными признаками понимаются признаки, применимые или справедливые для широкого ряда деталей, например, геометрические формы (круги, прямоугольники, цилиндры и т. п.), типы линий (сплошные, пунктирные, волнистые и т. д.), размерные данные (длины, ширины, высоты, диаметры и т.д.) и технические указания (например, допуски, посадки, шероховатость поверхности) и т.д.

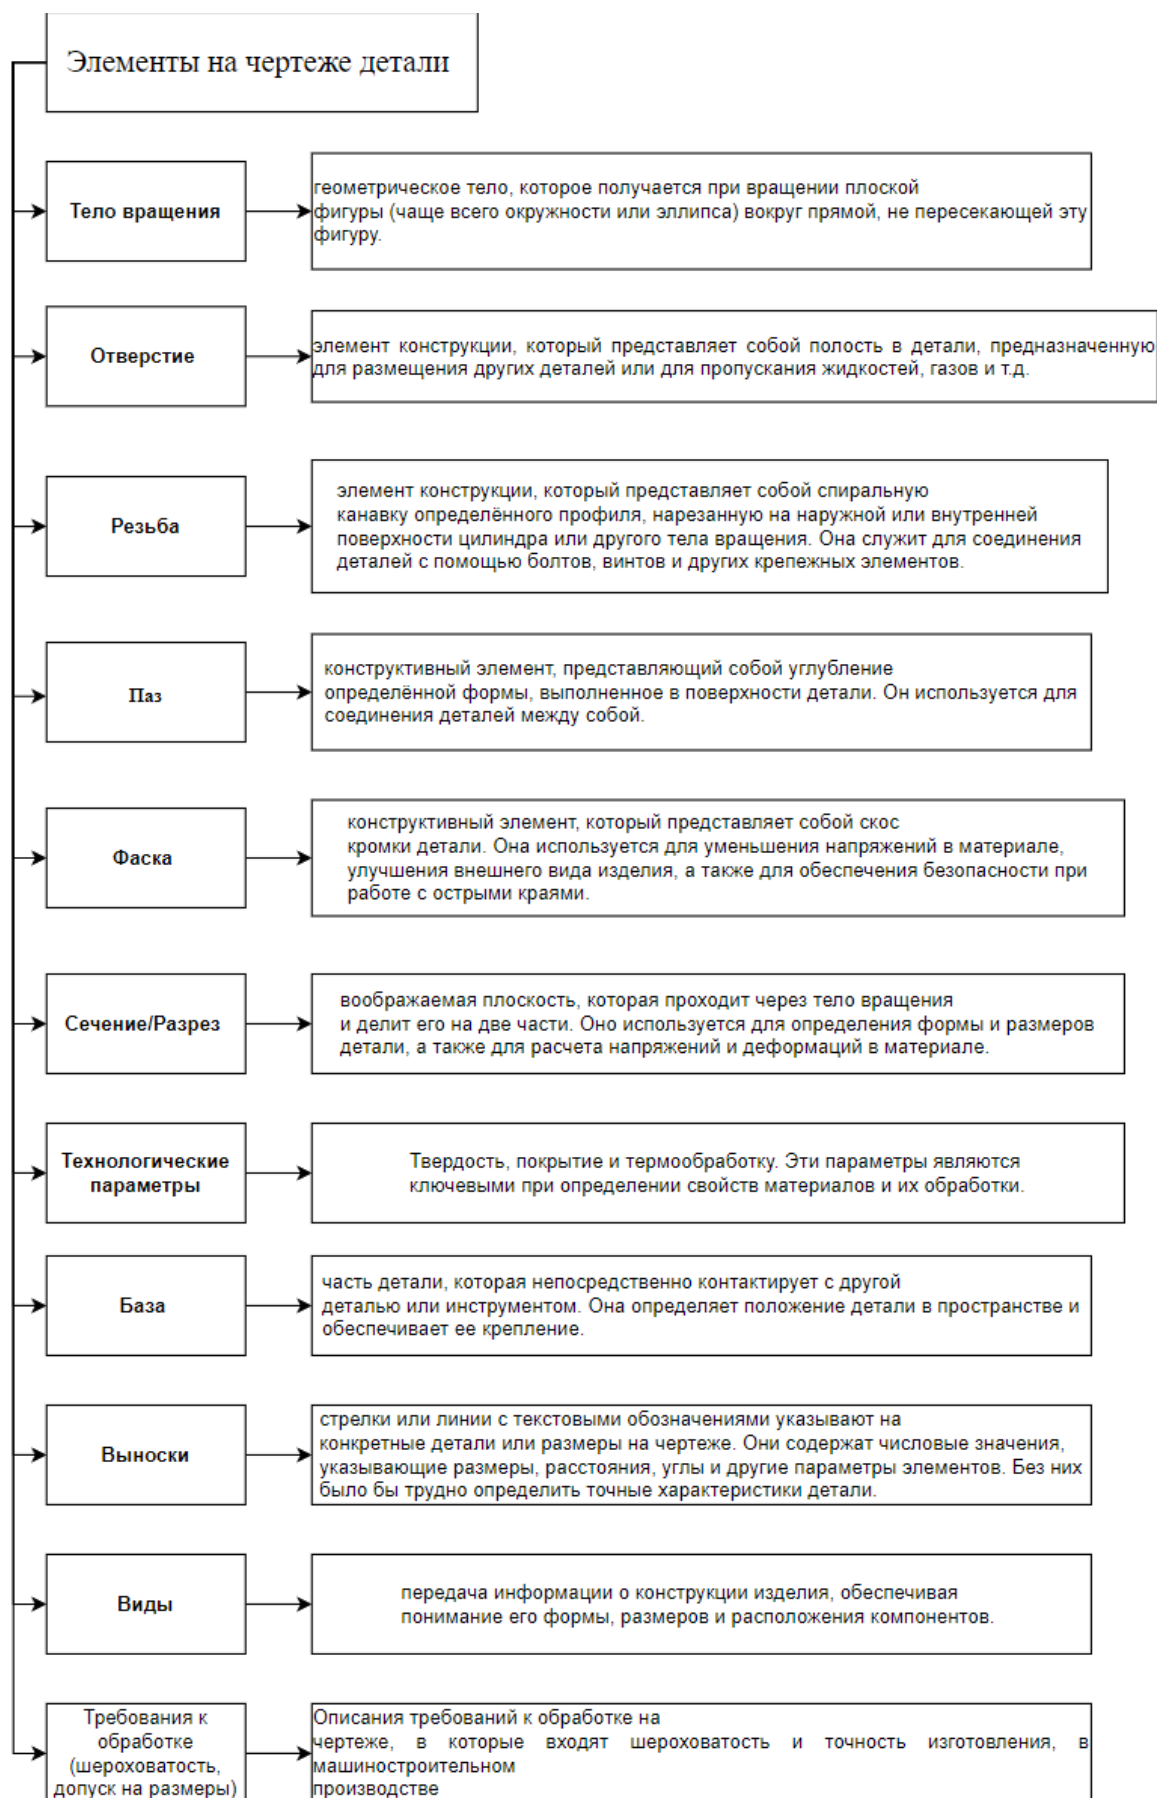


Рисунок 1 — Общие признаки элементов на чертеже

Под уникальными понимаются признаки, специфичные для конкретной детали, такие как уникальные сочетания форм и линий (определяющие и характеризующие сложные геометрические конфигурации), специальные функциональные элементы (канавки, выступы, отверстия) и уникальные требования к изготовлению (особые методы обработки или материалы). Таким образом, общий вид признаков элементов чертежей может быть обобщен в виде, представленном в Табл.1.

Таблица 1. Признаки элементов

| Наименование            | Описание                                                                                                                 |
|-------------------------|--------------------------------------------------------------------------------------------------------------------------|
| Геометрические признаки | форма, размеры (длины, ширины и высоты элементов), углы, радиусы                                                         |
| Структурные признаки    | наличие и тип соединений, отверстий, выступов, пазов и прочих особенностей конструкции                                   |
| Материальные признаки   | применяемые материалы для каждого элемента                                                                               |
| Функциональные признаки | назначение элемента, его роль в конструкции и взаимосвязи с другими элементами                                           |
| Относительные признаки  | расположение элемента относительно других элементов или координатной системы                                             |
| Текстовые признаки      | наличие текстовых меток, надписей или символов, связанных с отдельными элементами                                        |
| Графические символы     | специальные символы, обозначающие наличие элемента, требования к точности обработки (отклонения, шероховатость, допуска) |

Поскольку, для тестирования предложенного подхода далее будет рассматриваться задача поиска на чертеже отверстий, то, в качестве примера,

проиллюстрирован (рис.2) процесс формирования системы классификационных признаков отверстий (Табл.2)




Рисунок 2 – Признаки отверстий

Таблица 2. Признаки для идентификации отверстий

| Признак                  | Описание                                                                                                                                      |
|--------------------------|-----------------------------------------------------------------------------------------------------------------------------------------------|
| Диаметр отверстия        | Основной размер, может быть указан непосредственно или через условные обозначения.                                                            |
| Глубина отверстия        | Определяет является ли отверстие сквозным или глухим.                                                                                         |
| Форма отверстия          | Может быть круглой, овальной, квадратной, прямоугольной и т.д., в зависимости от функциональных требований.                                   |
| Тип обработки            | Указывает на метод создания отверстия, например, сверление, растачивание, фрезерование или эрозия.                                            |
| Технологические припуски | Допуски на размеры, которые необходимы для последующей обработки или сборки.                                                                  |
| Текстовая информация     | Содержит требования к шероховатости поверхности, допускам, а также указания на необходимость специальных обработок, таких как нарезка резьбы. |

На основе вышеописанной системы классификационных признаков разработан алгоритм, позволяющий идентифицировать технологические элементы и выполнять их автоматизированный анализ на чертежах (рис.3).




Рисунок 3 - Алгоритм поиска технологического элемента на чертеже

Представленный алгоритм может быть реализован с применением методов машинного обучения. Разработка такого инструмента классификации [16] включает 4 основных этапа. Процесс инициализируется этапом сбора данных, направленного на создание базы данных с аннотированными примерами каждого элемента. Далее производится обучение программного инструментария. Данный этап требует применения алгоритмов машинного обучения для последующих распознавания и классификации элементов. Обучение завершается этапами тестирования и валидации, в рамках которых производится проверка точности работы алгоритма на новых, неизвестных ей чертежах. Разработка инструментария завершается этапом оптимизации, направленном на улучшение алгоритма путем корректировки и добавления данных.

## **2. Разработка нейронной сети для поиска технологического элемента на чертеже**

Этап разработки нейронной сети [17] для поиска и анализа элементов на изображениях и чертежах предполагает предварительный анализ применимости существующих методов и подходов к обучению и анализу моделей в рамках концепции компьютерного зрения. В этой парадигме, основная задача нейронной сети сводится к классификации (на основе ранее разработанной системы признаков) и распознаванию элементов на изображениях.

Нейронная сеть рассматриваемого функционального назначения, может быть спроектирована на основе следующих основных алгоритмов:

1) Одностадийные сети (YOLO, SSD, Retina Net) – данный подход позволяет осуществлять обнаружение объектов в один этап, что существенно ускоряет процесс распознавания графических объектов.

2) Двухстадийные сети (R-CNN, Mask R-CNN) предполагают последовательную нелинейную процедуру выделения определенных регионов на изображении, с последующим уточнением образов внутри региона.

3) Детекторы объектов на основе моделей архитектуры трансформер – инновационные подходы в обработке изображений, которые в настоящее время не имеют четкой реализации. Подобные подходы используют архитектуру трансформеров, что позволяет вместо привычных рамок изображений распознавать объекты через «скользящее окно»

Для формирования системы автоматизированного чтения чертежей выбрана нейронная сеть одностадийного типа и модель YOLOv8 [18]. Данная модель дробит исходное изображение на систему подобластей с их последующим поэтапным анализом. Если центр объекта находится в конкретной ячейке на подобласти, то данная ячейка будет отвечать за предсказание ограничивающей рамки, классификацию объекта и вероятность присутствия необходимого объекта на изображении, что является необходимым инструментом для применения системы признаков элементов.

Тестирование построенных алгоритмов распознавания и системы классификации элементов на основе признаков производилось на задаче распознавания элементов

типа «отверстия» на чертежах различных деталей, в соответствии с ранее сформированными признаками (Табл.2).

Для оценки качества работы модели YOLOv8 была использована метрика средней точности модели, сопоставимая с Faster R-CNN [19]. Данная метрика является стандартной для задач распознавания объектов.

В качестве основной метрики для измерений была выбрана метрика «mean Average Precision» (mAP) с двумя значениями порога Intersection over Union (ioU):  $ioU = 0.5$  и усредненное значение порога  $ioU = (0.5 \div 0.95)$ . Порог ioU позволяет оценить наличие и отсутствие пересечения рамки, представленной моделью, с разметкой изображения: так, при  $ioU = 1$  наблюдается полное совпадение рамки с разметкой, а при  $ioU = 0$  – пересечение отсутствует. Анализ изменения метрик mAP при  $ioU = 0.5$  и  $ioU = (0.5 \div 0.95)$  для моделей YOLOv8 и Faster R-CNN приведено на рисунке 4.




Рисунок 4 - Сравнение метрик для моделей

Из рис.4, видно, что соотношение скорости и точности достижимое при использовании модели YOLOv8 выше, чем при использовании Faster R-CNN, так как модель YOLO использует одноэтапный подход для распознавания, в свою очередь модель FR-CNN использует двухэтапный подход. Таким образом показана достаточная точность и вычислительная эффективность применения модели YOLOv8 для задач распознавания изображений.

### **3. Алгоритм процесса автоматизации чтения и анализа чертежей**

Процесс автоматизации поиска технологического элемента на чертеже начинается с этапа предобработки данных, целью которого является приведение исходных инженерных чертежей к однородному формату и улучшение качества изображений для корректного анализа. На этом этапе выполняется конвертация чертежей в растровые изображения, повышение их контрастности и удаление шумов для улучшения четкости, а также преобразование изображений в оттенки серого, что позволяет уменьшить объем данных и упростить последующую обработку. Этап предобработки изображений завершается их адаптацией к единому, совместимому с моделью YOLOv8, формату.

Следующим этапом процесса автоматизации поиска и анализа элементов на чертежах является этап детекции объектов. Рассмотрим его построение на примере задачи поиска отверстий.

Модель принимает на вход обработанное изображение и разбивает чертеж на сетку. Для каждой ячейки на сетке определяется вероятность наличия отверстия его

класс и параметр ограничивающей рамки. Выходной результат модели включает координаты рамки, метки класса (в рассматриваемом примере - отверстия) и значение вероятности присутствия элемента на чертеже.

После завершения этапа детекции элементов выполняется обработка результатов для устранения дублирования предсказанных объектов и преобразования данных в удобный для чтения формат. На этом этапе применяется алгоритм Non-Maximum Suppression [20], который устраняет перекрытия ограничивающих рамок, а результаты сохраняются в формате JSON, что упрощает их интеграцию с различными системами проектирования. Для повышения точности модели на новых данных проводится обучение и дообучение модели. Этот процесс включает сбор дополнительной разметки изображений на основе обратной связи, после чего модель переобучается на обновленных данных, что улучшает ее точность и адаптивность.

#### **4. Валидация сформированного подхода**

Для обучения предложенной модели необходимо сформировать тренировочную и валидационную (тестовую) выборки. В качестве такой выборки применялись наборы инженерных чертежей, на которых была произведена предварительная разметка - выполнено предварительное ограничение части изображения, на которой изображено только отверстие (рис 5.).

В результате подготовки выборки было получено более 70-ти файлов аннотаций формата COCO. Необходимо отметить, что требуется как преобразовать файлы выборки в формат модели YOLO, так и разделить комплект файлов на

тренировочную и тестовую части. Выборки имеют класс свойство «отверстие», с использованием которого производится обучение модели.




Рисунок 5 - Разметка Bounding Box

Инициация процесса обучения производилась с использованием фреймворков pyTorch<sup>1</sup> и ultralytics<sup>2</sup>. В качестве гиперпараметров были использованы: - количество эпох (200); - размер изображения (640); - batchsize (8). Процесс обучения модели производился на GPU ядрах.

В результате обучения нейросети получен набор метрик (рис.6-7) позволяющих оценить качество обучения.

---

<sup>1</sup> <https://pytorch.org/> (accessed 10.10.2024)

<sup>2</sup> <https://www.ultralytics.com/ru> (accessed 10.10.2024)




Рисунок 6 - График-анализ распределения объектов

На рис.6 представлен анализ распределения объектов после обучения: левый верхний рисунок - график распределения аннотаций в тренировочной выборке; правый верхний рисунок - визуализация размера распределения ограничивающих рамок (Bounding Boxes) для объектов на изображениях. Нижний ряд изображений на рис.6 включает две точечных диаграммы, анализ которых позволяет определить, как распределены центры объектов в выборке.




Рисунок 7- График распределения зависимостей

На рис.7 представлена корреляция взаимосвязи (зависимости) координат и размеров объекта на изображении. Данная диаграмма позволяет оценить частоту появления определенных значений для координат и размеров объектов на распознаваемом изображении.

Чертежи имеют высокую структурированность, потому что в них присутствуют повторяемые объекты, и они имеют регулярные геометрические фигуры. Такие вводные уменьшают сложность задачи распознавания при использовании описанного выше подхода к обучению. Этап тренировки нейронной сети завершается анализом корректности распознавания объектов сетью (рис.8).




Рис.8 Результат распознавания объектов

В результате распознавания получены области, отнесенные нейронной сетью к отверстиям. Выявлено, что тренировочная модель требует дообучения на более массивной выборке. В текущем варианте модель совершает некоторые ошибки при распознавании образов, обеспеченная нейронной сетью точность классификации элемента чертежа, при повторном тестировании на валидационный выборке, достигает 80%, что является приемлемым для прототипа.

Таким образом, предложенный подход позволяет автоматизировать процесс чтения чертежей и позволяет формировать исходную информацию для автоматизации технологической подготовки производства.

### **Выводы**

В данной работе предложен подход к автоматизации анализа инженерных чертежей, включающий систематизацию и классификацию элементов, разработку нейронной сети для идентификации технологических компонентов, а также математическое обоснование применяемых методов. Проведённое тестирование подхода показало, что разработанная система достигает точности 80% при распознавании и анализе элементов чертежей, что подтверждает её эффективность и практическую применимость.

Полученный результат показывает высокий потенциал применения предложенного подхода для решения задач машинной подготовки блока исходных данных с целью последующего автоматизированного проектирования и технологической подготовки производства. В то же время существует перспектива дальнейшего совершенствования системы, включая доработку модели для повышения её точности, а также расширение функционала для работы с более сложными типами чертежей и данных.

### **Список источников**

1. Девятов Д.А., Чернова А.А. Оценка возможности автоматизации формирования технологических процессов в мелкосерийном производстве // Вестник ИжГТУ имени М.Т. Калашникова. 2023. Т. 26. № 3. С. 67-74. DOI: [10.22213/2413-1172-2023-3-67-74](https://doi.org/10.22213/2413-1172-2023-3-67-74)

2. Балашов А.И., Кошевой В.В., Савченко Е.А. Управление жизненным циклом продукции. - М.: Машиностроение, 2003.
3. Поляков Е.Ю., Кондусов Д.В., Кондусова В.Б. Унифицированная модель процесса автоматизации согласования документации технологической подготовки производства // Автоматизация в промышленности. 2023. № 6. С. 56–58. DOI: [10.25728/avtprom.2023.06.13](https://doi.org/10.25728/avtprom.2023.06.13)
4. Попов В.Н., Батырева А.Б., Ковтун Л.И., Бояров И.П. Автоматизация накопления опыта оптимизации технологических процессов и минимизации рисков распределенного виртуального производства в ходе эксплуатации сервиса технологической подготовки производства // Экономика. Право. Инновации. 2019. № 1. С. 42–48.
5. Хрусталева И.Н., Любомудров С.А., Романов П.И. Автоматизация технологической подготовки единичного и мелкосерийного производства // Научно-технические ведомости СПбПУ. Естественные и инженерные науки. 2018. Т. 24, № 1. С. 113–121. DOI: [10.18721/JEST.240111](https://doi.org/10.18721/JEST.240111)
6. Кордюков А.В., Савченков М.И., Чернова А.А. Адаптация алгоритма работы системы автоматизированного проектирования технологического процесса для выполнения технологической подготовки в условиях мелкосерийного и единичного производства // Вестник ИжГТУ имени М.Т. Калашникова. 2023. Т. 26. № 3. С. 26-32.
7. Александров И.А. Принципы автоматизация технологической подготовки производства путем нейросетевого моделирования // Инженерный вестник Дона. 2019. № 5 (56). 12 с.

8. Чигринец Е.Г., Верченко А.В. CAD/CAM/CAE системы, OMW-технологии и нейросетевые алгоритмы анализа данных на предприятиях авиастроительной отрасли // Труды МАИ. 2019. № 104. URL: <https://trudymai.ru/published.php?ID=102420>
9. Yasutomo Sugisawa, Keigo Takasugi, Naoki Asakawa. Machining sequence learning via inverse reinforcement learning // Precision Engineering journal. 2022. V. 73, P. 477-487.  
DOI: [10.1016/J.PRECISIONENG.2021.09.017](https://doi.org/10.1016/J.PRECISIONENG.2021.09.017)
10. Касимов Д.Р., Чернова А.А., Королева М.Р. Автоматическая идентификация и описание поверхностей на 2D чертежах // Автоматизация в промышленности. 2024. № 1. С. 55-58. DOI: [10.25728/avtprom.2024.01.14](https://doi.org/10.25728/avtprom.2024.01.14)
11. Babic B., Nesic N., Miljkovic Z. A review of automated feature recognition with rule-based pattern recognition // Computers Industry. 2008. No. 59 (4). P. 321–337. DOI: [10.1016/j.compind.2007.09.001](https://doi.org/10.1016/j.compind.2007.09.001)
12. Mazin Al-wswasi, Atanas Ivanov, Harris Makatsoris. A survey on smart automated computer-aided process planning (ACAPP) techniques // The International Journal of Advanced Manufacturing Technology. 2018. V. 97 (1), P. 809-832. DOI: [10.1007/s00170-018-1966-1](https://doi.org/10.1007/s00170-018-1966-1)
13. Sakurai H., Dave P. Volume decomposition and feature recognition. Part II: Curved objects // Computer-Aided Desing. 1996. V. 28, P. 519–537.
14. Ning F., Shi Y., Cai M., Xu W., Zhang X. Manufacturing cost estimation based on the machining process and deep-learning method // Journal of Manufacturing Systems. 2020. V. 56, P. 11–22. URL: <https://doi.org/10.1016/j.jmsy.2020.04.011>

15. Хомяков О.О., Панищев В.С., Титов В.С., Ватутин Э.И. Математическая модель и параллельный алгоритм обработки изображений, содержащих символьную информацию // Труды МАИ. 2024. № 137. URL: <https://trudymai.ru/published.php?ID=181884>
16. Малыгин И.В., Бельков С.А., Тарасов А.Д., Усвятцов М.Р. Применение методов машинного обучения для классификации радиосигналов // Труды МАИ. 2017. № 96. URL: <https://trudymai.ru/published.php?ID=85797>
17. Гусев П.Ю., Таволжанский А.В., Поцобнева И.В. Моделирование выбора характеристик временных рядов для методов машинного обучения на основе корреляционной матрицы // Труды МАИ. 2024. № 138. URL: <https://trudymai.ru/published.php?ID=182676>
18. Terven J., Cordova-Esparza D.-M., Romero-González J.-A. A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS // Machine Learning and Knowledge Extraction. 2023. No. 5 (4). P. 1680-1716. DOI: [10.3390/make5040083](https://doi.org/10.3390/make5040083)
19. Ren Sh., He K., Girshick R., Sun J. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2015. No. 39 (6). P. 1137-1149. DOI: [10.1109/TPAMI.2016.2577031](https://doi.org/10.1109/TPAMI.2016.2577031)
20. Hosang J.H., Benenson R., Schiele B. Learning Non-maximum Suppression // IEEE Conference on Computer Vision and Pattern Recognition (CVPR). 2017. P. 6469-6477. URL: <https://doi.org/10.48550/arXiv.1705.02950>

## References

1. Devyatov D.A., Chernova A.A. Assessment of the possibility of automating the formation of technological processes in small-scale production. *Vestnik IzhGTU imeni M.T. Kalashnikova*. 2023. V. 26, No 3. P. 67-74. (In Russ.). DOI: [10.22213/2413-1172-2023-3-67-74](https://doi.org/10.22213/2413-1172-2023-3-67-74)
2. Balashov A.I., Koshevoi V.V., Savchenko E.A. *Upravlenie zhiznennym tsiklom produktsii* (Product Lifecycle Management). Moscow: Mashinostroenie Publ., 2003.
3. Polyakov E.Yu., Kondusov D.V., Kondusova V.B. Unified model of the process of automating the coordination of documentation for technological preparation of production. *Avtomatizatsiya v promyshlennosti*. 2023. No. 6. P. 56–58. (In Russ.). DOI: [10.25728/avtprom.2023.06.13](https://doi.org/10.25728/avtprom.2023.06.13)
4. Popov V.N., Batyreva A.B., Kovtun L.I., Boyarov I.P. Automation of accumulating experience in optimizing technological processes and minimizing risks of distributed virtual production during the operation of a technological preparation service. *Ekonomika. Pravo. Innovatsii*. 2019. No. 1. P. 42–48. (In Russ.)
5. Khrustaleva I.N., Lyubomudrov S.A., Romanov P.I. Automation of technological preparation for single and small-scale production. *Nauchno-tekhnicheskie vedomosti SPBPU. Estestvennye i inzhenernye nauki*. 2018. V. 24, No. 1. P. 113–121. (In Russ.). DOI: [10.18721/JEST.240111](https://doi.org/10.18721/JEST.240111)
6. Kordyukov A.V., Savchenkov M.I., Chernova A.A. Adaptation of the algorithm for the operation of a computer-aided process planning system for technological preparation in

- small-scale and single production. *Vestnik IzhGTU imeni M.T. Kalashnikova*. 2023. V. 26, No. 3. P. 26-32. (In Russ.)
7. Aleksandrov I.A. Principles of automating technological preparation of production through neural network modeling. *Inzhenernyi vestnik Dona*. 2019. No. 5 (56). 12 p. (In Russ.)
8. Chigrinets E.G., Verchenko A.V. CAD/CAM/CAE systems, OMV technologies and neural network based data analysis algorithms at the aviation industry enterprises. *Trudy MAI*. 2019. No. 104. (In Russ.). URL: <https://trudymai.ru/eng/published.php?ID=102420>
9. Yasutomo Sugisawa, Keigo Takasugi, Naoki Asakawa. Machining sequence learning via inverse reinforcement learning. *Precision Engineering journal*. 2022. V. 73, P. 477-487. DOI: [10.1016/J.PRECISIONENG.2021.09.017](https://doi.org/10.1016/J.PRECISIONENG.2021.09.017)
10. Kasimov D.R., Chernova A.A., Koroleva M.R. Automatic identification and description of surfaces in 2D drawings. *Avtomatizatsiya v promyshlennosti*. 2024. No.1. P. 55-58. (In Russ.). DOI: [10.25728/avtprom.2024.01.14](https://doi.org/10.25728/avtprom.2024.01.14)
11. Babic B., Nesic N., Miljkovic Z. A review of automated feature recognition with rule-based pattern recognition. *Computers Industry*. 2008. No. 59 (4). P. 321–337. DOI: [10.1016/j.compind.2007.09.001](https://doi.org/10.1016/j.compind.2007.09.001)
12. Mazin Al-wswasi, Atanas Ivanov, Harris Makatsoris. A survey on smart automated computer-aided process planning (ACAPP) techniques. *The International Journal of Advanced Manufacturing Technology*. 2018. V. 97 (1), P. 809-832. DOI: [10.1007/s00170-018-1966-1](https://doi.org/10.1007/s00170-018-1966-1)

13. Sakurai H., Dave P. Volume decomposition and feature recognition. Part II: Curved objects. *Computer-Aided Desing*. 1996. V. 28, P. 519–537.
14. Ning F., Shi Y., Cai M., Xu W., Zhang X. Manufacturing cost estimation based on the machining process and deep-learning method. *Journal of Manufacturing Systems*. 2020. V. 56, P. 11–22. URL: <https://doi.org/10.1016/j.jmsy.2020.04.011>
15. Khomyakov O.O., Panishchev V.S., Titov V.S., Vatutin E.I. Mathematical model and a parallel algorithm for processing images containing symbolic information about products. *Trudy MAI*. 2024. No. 137. (In Russ.). URL: <https://trudymai.ru/eng/published.php?ID=181884>
16. Malygin I.V., Bel'kov S.A., Tarasov A.D., Usvyatsov M.R. Machine learning methods in classification of radio signals. *Trudy MAI*. 2017. No. 96. (In Russ.). URL: <https://trudymai.ru/eng/published.php?ID=85797>
17. Gusev P.Yu., Tavolzhanskii A.V., Potsebneva I.V. Modeling the selection of time series haracteristics for machine learning methods based on the correlation matrix. *Trudy MAI*. 2024. No. 138. (In Russ.). URL: <https://trudymai.ru/eng/published.php?ID=182676>
18. Terven J., Cordova-Esparza D.-M., Romero-González J.-A. A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS. *Machine Learning and Knowledge Extraction*. 2023. No. 5 (4). P. 1680-1716. DOI: [10.3390/make5040083](https://doi.org/10.3390/make5040083)
19. Ren Sh., He K., Girshick R., Sun J. Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2015. No. 39 (6). P. 1137-1149. DOI: [10.1109/TPAMI.2016.2577031](https://doi.org/10.1109/TPAMI.2016.2577031)

20. Hosang J.H., Benenson R., Schiele B. Learning Non-maximum Suppression. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2017. P. 6469-6477.  
URL: <https://doi.org/10.48550/arXiv.1705.02950>

Статья поступила в редакцию 19.02.2025

Одобрена после рецензирования 28.02.2025

Принята к публикации 25.06.2025

The article was submitted on 19.02.2025; approved after reviewing on 28.02.2025; accepted for publication on 25.06.2025