


## РАЗРАБОТКА СИСТЕМЫ АВТОМАТИЧЕСКОЙ ДЕТЕКЦИИ И КЛАССИФИКАЦИИ ИНКЛЮЗИВНОГО ЯНТАРЯ НА ВИДЕОПОТОКЕ



Д. Р. Юрков, студент 2-го курса магистратуры  
E-mail: [denis.yurkov@klgtu.ru](mailto:denis.yurkov@klgtu.ru)  
ФГБОУ ВО «Калининградский государственный  
технический университет»

А. В. Снытников, д.т.н.  
E-mail: [aleksej.snytnikov@klgtu.ru](mailto:aleksej.snytnikov@klgtu.ru)  
ФГБОУ ВО «Калининградский государственный  
технический университет»

В статье представлена разработка системы автоматической детекции и классификации включений в янтаре на основе анализа видеопотока. Предложена двухэтапная методика: первый этап включает сегментацию янтара с использованием модели YOLO11n-seg, второй – обнаружение и классификация включений внутри выделенной области с применением модели YOLO11n-det. Для обучения моделей были собраны и аннотированы собственные датасеты, а также реализовано расширение выборки с помощью аугментаций. Параметры для обучения моделей определялись методом полнофакторного эксперимента. Экспериментальные результаты демонстрируют высокую точность работы системы, что делает ее перспективной для использования в промышленных условиях и научной деятельности.

**Ключевые слова:** обработка изображений, компьютерное зрение, сегментация, янтарь, детекция, машинное обучение, YOLO, полнофакторный эксперимент.

### ВВЕДЕНИЕ

Янтарь – это окаменевшая смола древних деревьев, которая часто содержит включения – остатки растений, насекомых и других организмов, захваченных смолой миллионы лет назад [1]. Эти включения представляют огромную ценность для палеонтологов, биологов и коллекционеров. Однако анализ включений в янтаре традиционно является трудоемким процессом, требующим участия экспертов и длительного визуального осмотра. Существующие автоматизированные системы решают задачи идентификации формы [2] и цвета [3] янтара на потоке, однако методы классификации инклюзивного янтара до настоящего времени остаются неразработанными.

С развитием технологий компьютерного зрения появляется возможность автоматизации этого процесса. Автоматическая система детекции и классификации включений в янтаре позволяет значительно повысить эффективность анализа, особенно при обработке больших объемов образцов [4].

Целью данной работы является разработка программно-аппаратной системы автоматической детекции и классификации включений в янтаре на видеопотоке, основанной на современных нейросетевых подходах.

### ОБЪЕКТ ИССЛЕДОВАНИЯ

Объектом исследования являются изображения и видеопотоки, содержащие образцы янтара с включениями различной природы. Эти данные служат основой для разработки и обучения нейросетевых моделей, обеспечивающих автоматическую сегментацию янтара и последующую детекцию, а также классификацию включений внутри него.

## ЦЕЛЬ И ЗАДАЧИ ИССЛЕДОВАНИЯ

Целью данного исследования является разработка системы автоматической детекции и классификации включений в янтаре на основе анализа видеопотока. Предполагается создать программное решение, способное в реальном времени выделять области с янтарём и распознавать находящиеся в них включения, что позволит автоматизировать процесс анализа образцов и повысить его точность и скорость.

Для достижения поставленной цели были сформулированы следующие задачи:

Собрать и подготовить специализированные датасеты для задач сегментации янтара и детекции включений.

Обучить и оптимизировать нейросетевые модели YOLO11seg и YOLO11det для выполнения сегментации и детекции с использованием аугментированных данных.

Провести оценку качества работы моделей и эффективности всей системы в целом.

## МЕТОДЫ ИССЛЕДОВАНИЯ

Предложенная система автоматической детекции и классификации включений в янтаре включает несколько взаимосвязанных компонентов, обеспечивающих комплексную обработку видеопотока. В качестве источника данных выступает видеокамера, с которой поступает входной поток изображений. Далее применяется модуль сегментации янтара на основе модели YOLO11seg, предназначенный для выделения областей изображения, содержащих образцы янтара и деления их на отдельные объекты. Затем с использованием полученных масок выполняется обрезка кадра до отдельных фрагментов, соответствующих индивидуальным образцам. На завершающем этапе каждый выделенный фрагмент анализируется с помощью модели YOLO11det, которая осуществляет детекцию и классификацию включений, определяя их наличие в янтаре.



Рисунок 1 – Схема алгоритма обработки

Для обучения нейросетевых моделей были собраны и подготовлены два специализированных датасета. Первый – датасет сегментации – включает 256 изображений янтара, с размещением как отдельных образцов, так и групповых композиций. Второй – датасет детекции включений – состоит из 1043 изображений, на которых каждый обнаруженный инклюз был помечен bounding box'ом (детектирован).

Аннотирование данных выполнялось вручную с использованием инструмента CVAT, что позволило обеспечить высокую точность разметки. На этапе предварительной обработки датасетов были удалены дубликаты изображений путем сравнения хэшей, а также проведена проверка на соответствие формату разметки и качество изображений. Эта процедура способствовала повышению репрезентативности выборки и улучшению обобщающей способности обучаемых моделей [5].

Анализ пространственного распределения сегментированных объектов на изображениях, а также их размерных характеристик в датасете свидетельствует о том, что янтарные включения равномерно распределены по всей площади изображений.

Статистический анализ размерного ряда объектов демонстрирует преобладание образцов со средними размерами, однако в выборке также присутствуют экземпляры как значительно крупнее, так и мельче среднего. Такое распределение размеров объектов способствует повышению обобщающей способности модели, обеспечивая корректное детектирование янтара различных фракций [6].




Рисунок 2 – График расположения объектов сегментации на пространстве изображений и размерный ряд объектов сегментации в датасете

Проведенный анализ пространственного распределения объектов детекции на изображениях демонстрирует, что янтарные включения присутствуют на всей площади изображения, однако наблюдается их статистически значимая концентрация в центральной области.

Сравнительный анализ размерного распределения объектов в датасетах детекции и сегментации выявил более выраженную вариабельность размерных характеристик в датасете детекции. В частности, диапазон размеров объектов в датасете детекции превышает соответствующий показатель в датасете сегментации, что свидетельствует о его большей репрезентативности относительно размерной вариативности янтарных включений.




Рисунок 3 – График расположения объектов детекции на пространстве изображений и размерный ряд объектов детекции в датасете

Для повышения устойчивости и обобщающей способности нейросетевых моделей на этапе обучения была реализована динамическая аугментация изображений. Поскольку собранные датасеты имеют ограниченный объем, особенно в случае датасета сегментации, использование аугментаций позволило увеличить разнообразие входных данных и уменьшить риск переобучения [7].

В ходе экспериментов применялись такие преобразования, как горизонтальное и вертикальное отражение, изменение яркости и контраста, а также копирование объектов на свободные зоны изображения (copy\_paste). Все аугментации применялись в реальном времени при подаче данных модели во время обучения, что исключало необходимость предварительного расширения датасета и позволяло обучаться на более вариативных представлениях одного и того же образца.

В процессе обучения моделей были активированы параметры `deterministic=True` и задано фиксированное значение `seed`. Эти параметры используются для обеспечения воспроизводимости результатов экспериментов.

Параметр `deterministic` отключает недетерминированные алгоритмы вычислений на GPU, такие как оптимизированные реализации сверток в библиотеке `cuDNN`. По умолчанию такие алгоритмы могут давать немного разные результаты при разных запусках даже с одинаковыми начальными условиями. Включение этого режима гарантирует, что последовательность вычислений будет воспроизводимой.

Значение `seed` задавалось для инициализации генератора случайных чисел, используемого при инициализации весов сети, разбиении выборки, применении аугментаций и других случайных операциях во время обучения. Это позволило добиться полной повторяемости экспериментов: при повторном запуске обучения с тем же `seed` модель проходила идентичную последовательность итераций, что помогло корректно оценить влияние измененных параметров.

Обучение модели сегментации YOLO11n-seg проводилось на видеокарте NVIDIA RTX 3090 с использованием фреймворка Ultralytics YOLO. В ходе экспериментов были протестированы различные конфигурации гиперпараметров, основные из которых подбирались с применением метода полнофакторного эксперимента (PFE) для обеспечения максимальной точности и устойчивости модели [8].

Базовые параметры обучения включали:

Количество эпох: 100.

Размер батча: 32.

Количество воркеров: 10.

Варьируемые параметры, определяемые с помощью PFE:

Размер входного изображения:  $640 \times 640$  и  $1024 \times 1024$  пикселей.

Оптимизаторы: AdamW, Adam.

Начальная скорость обучения (`lr0`): 0.001, 0.004, 0.007, 0.01.

Weight decay: 0.0001, 0.0003, 0.0005.

Финальная скорость обучения (`lrf`): 0.01, 0.03, 0.05.

Оценку результата проводил по метрикам `mAP/50` и `mAP/50-95` лучших эпох каждого обучения.

Лучше всего себя показала модель с параметрами:

Размер входного изображения:  $1024 \times 1024$  пикселей.

Оптимизаторы: Adam.

Начальная скорость обучения (`lr0`): 0.001.

Weight decay: 0.0003.

Финальная скорость обучения (`lrf`): 0.05.

Пример сегментации:




Рисунок 4 – Изображение до и после сегментации

Характеристики лучшей эпохи следующие:

mAP/50: 0.96535;

mAP/50-95: 0.86187.

Для последующего анализа включений в янтаре важно выделить каждый отдельный образец из исходного кадра и сохранить его в виде отдельного изображения. Для этого был разработан и реализован алгоритм обрезки, основанный на результатах сегментации, выполненной моделью YOLO11seg. После того как модель определяет местоположение и форму каждого янтарного образца на изображении, алгоритм использует информацию о маске и bounding box для извлечения интересующей области.

Алгоритм начинает работу с получения координат ограничивающего прямоугольника (bounding box), который охватывает область с найденным янтарём. Эти координаты корректируются таким образом, чтобы они не выходили за границы исходного изображения. Далее, с учетом информации о двоичной маске, которая была получена на этапе сегментации, создается изображение, где фон заменяется на белый, а сам янтарь остаётся без изменений. Это позволяет более точно отделить объект от окружающей среды и упрощает дальнейшую обработку.

После подготовки изображения по маске и ограничивающему прямоугольнику, фрагмент обрезается и сохраняется в отдельном файле. Каждому выделенному образцу присваивается уникальное имя, основанное на названии исходного файла и порядковом номере найденного объекта. Такой подход обеспечивает структурированное хранение данных и упрощает их использование на следующих этапах анализа, таких как детекция и классификация включений.



Рисунок 5 – Изображения после обработки алгоритмом

После завершения этапа сегментации и обрезки отдельных образцов янтара была организована работа модуля детекции включений, реализованного на основе модели YOLO11det. Этот этап являлся ключевым для достижения цели исследования – автоматического обнаружения включений внутри каждого выделенного фрагмента.

Обучение проводилось аналогично этапу сегментации – на видеокарте NVIDIA RTX 3090 с применением фреймворка Ultralytics YOLO, при этом также активировались параметры deterministic=True и фиксированное значение seed.

В ходе обучения были протестированы различные конфигурации гиперпараметров, подобранных с помощью метода полнофакторного эксперимента (PFE). Варьируемые параметры включали:

Тип оптимизатора: AdamW, Adam.

Начальную скорость обучения (lr0): 0.001, 0.005, 0.01.

Вес регуляризации (weight\_decay): 0.0001, 0.0005, 0.007.

Финальную скорость обучения (lrf): 0.01, 0.05, 0.1.

Оценка эффективности каждой конфигурации проводилась по метрикам mAP/0.5 и mAP/0.5-0.95, характеризующим точность и устойчивость модели к различным значениям порога IoU. Лучшие результаты показала модель, обученная со следующими параметрами:

Размер входного изображения: 640 × 640 пикселей.

Оптимизатор: Adam.

Начальная скорость обучения (lr0): 0.01.

Weight decay: 0.0007.

Финальная скорость обучения (lrf): 0.05.

Характеристики лучшей эпохи составили:

mAP/0.5: 0.991;

mAP/0.5–0.95: 0.77.

Эти значения свидетельствуют о высокой точности обнаружения включений и стабильной работе модели на различных типах изображений. После завершения обучения модель была интегрирована в общую архитектуру системы, где она последовательно обрабатывает каждый выделенный фрагмент янтаря и обнаруживает включения.

Примеры работы модели детекции представлены на рисунке 6, где показаны исходные фрагменты янтаря с нанесенными bounding box'ами. Такая визуализация позволяет экспертам не только проверить корректность работы системы, но и использовать ее в дальнейшем для автоматической каталогизации найденных включений.



Рисунок 6 – Примеры обнаружения включений в янтаре

## ЗАКЛЮЧЕНИЕ

В ходе выполнения работы была разработана система автоматической детекции и классификации включений в янтаре на видеопотоке. Система основана на комбинации моделей YOLO11seg и YOLO11det, что позволило последовательно выполнять сегментацию объектов и анализ их содержимого. Были собраны оригинальные датасеты и проведено их расширение с использованием аугментаций. Параметры обучения были оптимизированы с помощью метода полнофакторного эксперимента (PFE), что позволило выявить наиболее эффективные конфигурации гиперпараметров для каждой из моделей. Модель сегментации YOLO11seg достигла высоких показателей качества: mAP/0.5 = 0.965 и mAP/0.5–0.95 = 0.862, что говорит о ее способности точно выделять образцы янтаря на сложном фоне. Модель детекции YOLO11det показала mAP/0.5 = 0.897 и mAP/0.5–0.95 = 0.763, обеспечивая стабильное обнаружение и классификацию включений внутри сегментированных фрагментов.

## СПИСОК ЛИТЕРАТУРЫ

1. Чанг, С.-С. Янтарные датировки: обзор и перспектива / С.-С. Чанг, И. Ли, Д. Чжэн // Minerals. – 2023. – Т. 13, № 7. – С. 948. – DOI: 10.3390/min13070948.
2. Ostreika, A. Классификация объектов по форме применительно к классификации драгоценных камней янтаря / A. Ostreika, M. Pivoras, A. Misevičius, T. Skersys, L. Paulauskas // Applied Sciences. – 2021. – Т. 11, № 3. – С. 1024. – DOI: 10.3390/app11031024.
3. Katkus, D. Классификация цветов драгоценных камней янтаря по CNN / D. Katkus, P. Mačiulavičius, A. Lipnickas // 2023 12th International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS). – Dortmund, Germany, 2023. – С. 531–536. – DOI: 10.1109/IDAACS58523.2023.10348663.
4. Long, T. Обзор технологий искусственного интеллекта в идентификации минералов: классификация и визуализация / T. Long, Z. Zhou, G. Hancke, Y. Bai, Q. Gao // Journal of Sensor and Actuator Networks. – 2022. – Т. 11, № 3. – С. 50. – DOI: 10.3390/jsan11030050.
5. Агабагерлу, А. Влияние дублирования данных на классификаторы изображений на основе глубоких нейронных сетей: робастность и стандартные модели / А. Агабагерлу,

А. Абади, С. Саркар, В. Дасу, Б. Пренил // arXiv preprint arXiv:2504.00638v1 [cs.LG]. – 2025. – URL: <https://arxiv.org/abs/2504.00638> (дата обращения: 04.05.2025).

6. Сингх, Б. Анализ масштабной инвариантности в детектировании объектов – SNIP / Б. Сингх, Л. С. Дэвис // Материалы конференции IEEE/CVF по компьютерному зрению и распознаванию образов (CVPR). – 2018. – arXiv:1711.08189 [cs.CV]. – DOI: 10.48550/arXiv.1711.08189.

7. Ложкин, И. А. Аугментация наборов изображений для обучения нейронных сетей при решении задач семантической сегментации / И. А. Ложкин, М. Е. Дунаев, К. С. Зайцев, А. А. Гармаш // International Journal of Open Information Technologies. – 2023. – № 1. – URL: <https://cyberleninka.ru/article/n/augmentatsiya-naborov-izobrazheniy-dlya-obucheniya-neyronnyh-setey-pri-reshenii-zadach-semanticheskoy-segmentatsii> (дата обращения: 03.05.2025).

8. Куковинец, А. В. Полный факторный эксперимент для исследования фрагментарного метода обнаружения границ объектов на цифровом изображении // Colloquium-journal, 2020. – № 2(54). – URL: <https://cyberleninka.ru/article/n/polnyy-faktorny-eksperiment-dlya-issledovaniya-fragmentarnogo-metoda-obnaruzheniya-granits-obektov-na-tsifrovom-izobrazhenii> (дата обращения: 10.05.2025).

## DEVELOPMENT OF A SYSTEM FOR AUTOMATIC DETECTION AND CLASSIFICATION OF INCLUSIVE AMBER ON A VIDEO STREAM

D. R. Yrkov, 2nd year master's degree student

E-mail: [denis.yurkov@digital-klgtu.ru](mailto:denis.yurkov@digital-klgtu.ru)

Kaliningrad State Technical University

A.V. Snytnikov, Doctor of Technical Sciences, Associate professor

E-mail: [aleksej.snytnikov@klgtu.ru](mailto:aleksej.snytnikov@klgtu.ru)

Kaliningrad State Technical University

The article presents the development of a system for automatic detection and classification of inclusions in amber based on video stream analysis. A two-stage technique is proposed: the first stage includes amber segmentation using the YOLO11n-seg model, the second stage includes detection and classification of inclusions within the selected area using the YOLO11n-det model. To train the models, our own datasets were collected and annotated, and the sample was expanded using augmentations. The parameters for training the models were determined using a full-factorial experiment. The experimental results demonstrate the high accuracy of the system, which makes it promising for use in industrial conditions and scientific activities.

**Key words:** *image processing, computer vision, segmentation, amber, detection, machine learning, YOLO, full-factorial experiment.*