

УДК 004.896
DOI 10.17513/snt.40217

О ДЕТЕКЦИИ БРАКА НА ПРОИЗВОДСТВЕННОМ ПРЕДПРИЯТИИ С ИСПОЛЬЗОВАНИЕМ НЕЙРОСЕТЕЙ (НА ПРИМЕРЕ ООО «АЛАТОЙС»)

Талалаев М.В.

ООО «Алатойс», Йошкар-Ола;
ФГБОУ ВО «Марийский государственный университет», Йошкар-Ола,
e-mail: oblomoff1@yandex.ru

Цель исследования – разработка и апробация нейросетевой модели для детекции брака на производственном предприятии, осуществляющем выпуск продукции для детей дошкольного возраста, на базе предобученной модели YOLOv8. Данное решение было предложено для реализации в связи с регулярным получением отзывов с торговых площадок, связанных с теми или иными недокомплектами, что, в свою очередь, образуется ввиду использования ручного труда на предприятии. Попытки решить данный производственный вопрос без применения искусственного интеллекта успехом не увенчались ввиду значительного объема выпускаемых изделий и отсутствием технологий, способных на 100% исключить данный фактор (брак при ручной сборке). Для проверки гипотезы был создан минимально жизнеспособный продукт, в основе которого был использован собственный размеченный датасет для обучения нейросети, состоящий из изображений выпускаемых изделий с детектируемыми объектами, в течение недели была обучена сама нейросеть на размеченных данных, а также была проведена адаптация результата для конечных пользователей с помощью написания простейшего фронтенда и реализации подключения видекамеры в режиме реального времени. Модель в своей работе в режиме реального времени показала отличные результаты. Предложенное решение подтвердило первичную гипотезу, а также возможность успешного использования нейросетей на предприятиях Российской Федерации, выпускающих детскую продукцию.

Ключевые слова: нейросеть, компьютерное зрение, искусственный интеллект, датасет, детекция брака, ОТК, промышленное предприятие, деревянные игрушки, промышленность, контроль качества, дети, обрабатывающие производства, малый бизнес

ABOUT THE DEFECT DETECTION AT A MANUFACTURING ENTERPRISE USING NEURAL NETWORKS (ON EXAMPLE OF ALATOYS LLC)

Talalaev M.V.

Alatoys LTD, Yoshkar-Ola;
Mari State University, Yoshkar-Ola, e-mail: oblomoff1@yandex.ru

The purpose of the study is to develop and test a neural network model for detecting defects at a manufacturing enterprise that produces products for preschool children based on the pre-trained YOLOv8 model. This solution was proposed for implementation in connection with the regular receipt of feedback from trading platforms related to certain deficiencies, which, in turn, is formed due to the use of manual labor in the enterprise. Attempts to solve this production issue without the use of artificial intelligence have not been successful due to the significant volume of products produced and the lack of technologies capable of 100% eliminating this factor (defects in manual assembly). To test the hypothesis, a minimally viable product was created, based on which its own marked-up dataset was used to train a neural network, consisting of images of manufactured products with detectable objects, within a week the neural network itself was trained on marked-up data, and the result was adapted for end users by writing the simplest frontend and implementing the connection of a video camera in real-time mode. The model has shown excellent results in its real-time operation. The proposed solution confirmed the primary hypothesis, as well as the possibility of successful use of neural networks at enterprises of the Russian Federation producing children's products.

Keywords: neural network, computer vision, artificial intelligence, dataset, marriage detection, industrial enterprise, wooden toys, children, quality control, yolov8, industry, manufacturing, small & medium enterprises

Введение

Отрасль создания игрушек является уникальной, в том числе потому, что в ней практически не существует стандартизированных решений в области автоматизации ручного труда. Каждый производитель зачастую занимается собственным конструированием и производством оборудования под конкретную производственную задачу.

Компания «Алатойс» является одним из лидеров страны в области производства детских развивающих игрушек из дерева [1]. В деятельности компании присутствует ручной труд, который при высоких показателях выпуска идентичной продукции в единицу времени непременно приводит к браку в виде недокомплектов изделий, что подтверждается отзывами на маркетплейсах.

С учетом событий начала 2022 г., а также самых низких показателей рождаемости с 1999 г. [2] данные тенденции в целом продолжают негативным образом сказываться на рынке труда и на емкости отрасли. В этой связи вопросы автоматизации труда, повышения его интенсификации и эффективности являются сверхактуальными абсолютно для всех участников рынка исследуемой отрасли промышленности. Особенно с учетом того фактора, что научные труды по использованию компьютерного зрения в области производства деревянных развивающих игрушек отсутствуют.

Автором работы в целях решения поставленной задачи были изучены основные нейронные сети, применяемые в компьютерном зрении (в основном сверточные). Они представлены как одноуровневыми, так и двухуровневыми моделями. Широко распространены в компьютерном зрении приобрели следующие нейросети: R-CNN (Region-based Convolutional Neural Networks), EfficientNets, VGG (Visual Geometry Group), ResNets, YOLO (You Only Look Once) [3, с. 478–491]. Выбор последней в качестве одного из инструментов для решения поставленной задачи обусловлен в первую очередь скоростью и точностью ее работы при потреблении незначительных вычислительных ресурсов.

Цель исследования – разработка и апробация нейросетевой модели для детекции брака на производственном предприятии, осуществляющем выпуск продукции для детей дошкольного возраста, на базе предобученной модели YOLOv8.

Материалы и методы исследования

Написание кода осуществлялось на языке Python в интерпретаторе VSCode. Гиперпараметры обучения модели:

- epochs = 500,
- imgsz = 640,
- batch = 32,
- patience = 200.

В рамках исследования был использован собственный датасет, представленный 240 снимками и разделенный в следующих пропорциях:

- 192 единицы – обучающая выборка,
- 48 единиц – валидационная.

Разметка снимков проводилась вручную с помощью сервиса CVAT.ai [4]. Для разметки были выделены три уникальных идентификатора в каждом из артикулов, взятых для разметки: «карточки», «фишки», «подставки». Указанные артикулы выбраны ввиду их наибольшей распространенности по недокомплекткам в отзывах от покупателей. Разметка проводилась методом «Polygon Shape».

Для преобразования полученных файлов использовался репозиторий с GitHub, расположенный по ссылке: https://github.com/Koldim2001/COCO_to_YOLOv8 [5]. По итогам отработки кода была получена следующая структура рабочей папки:

- файл data.yaml;
- папка train;
- папка validation.

Папки train и validation, в свою очередь, состояли из папок images и labels, а также файла labels.cache. Папка images представлена файлами с расширением *.jpg, папка labels – с расширением *.txt.

Для обучения были выбраны два размера модели YOLOv8 от Ultralytics [6]: yolov8s-seg и yolov8m-seg. Параметры моделей представлены на рис. 1.

Обучение производилось на локальной машине с операционной системой MacOS на чипе m1 и встроенной видеокарты. Как показала практика, выбор аппаратного средства не являлся оптимальным ввиду низкой адаптации ноутбуков на базе указанного чипа под решение аналогичных задач. Обучение меньшей по размеру модели (yolov8s-seg) заняло более 3 суток, большей по размеру (yolov8m-seg) – более 7 суток.

Модель	Размер (пикселей)	mAPbox 50-95	mAPmask 50-95	Скорость CPU ONNX (мс)	Скорость A100 TensorRT (мс)	params (M)	FLOPs (B)
YOLOv8n-seg	640	36.7	30.5	96.1	1.21	3.4	12.6
YOLOv8s-seg	640	44.6	36.8	155.7	1.47	11.8	42.6
YOLOv8m-seg	640	49.9	40.8	317.0	2.18	27.3	110.2
YOLOv8l-seg	640	52.3	42.6	572.4	2.79	46.0	220.5
YOLOv8x-seg	640	53.4	43.4	712.1	4.02	71.8	344.1

Рис. 1. Параметры предобученной модели YOLOv8

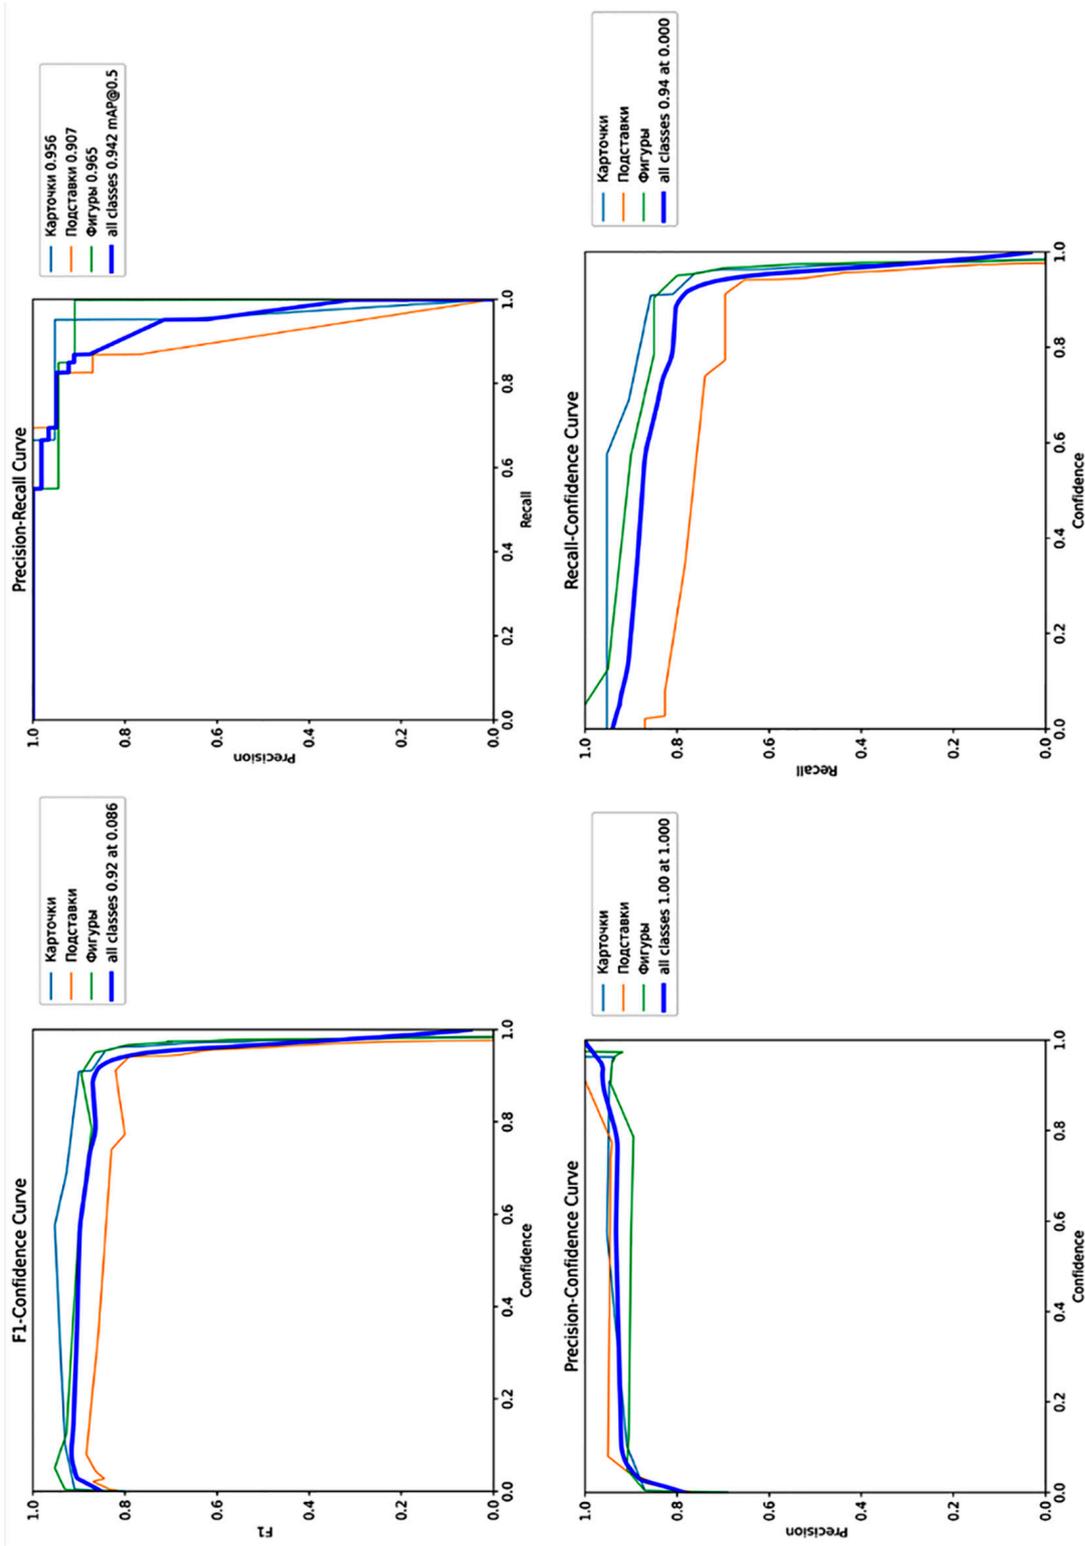


Рис. 2. Графики метрик качества при детекции box'ов

Результаты исследования и их обсуждение

В результате обучения модели были получены следующие данные, представленные на рис. 2. Первый блок полученных параметров представлен графиками «box»'ов, то есть границ детектируемых объектов и корректности определения их классов (меток).

График в левом верхнем углу отражает f1-меру, то есть гармоническое среднее точности (precision) и полноты (recall). Максимум для всех классов (0,92) метрика принимает при значении параметра confidence (уверенность) в 0,086. В то же время скорость «снижения» графика при росте показателя уверенности предсказания является незначительной. Однозначно можно сделать вывод, что при уверенности более 0,9 модель выдает метрику f1 более 0,8, что говорит о высоком качестве ее работы.

Остальные три графика характеризуют уверенность (confidence) работы модели на метриках точности (precision) и полноты

(recall). Можно сделать вывод, что модель уверенно ведет себя при определении точности (значение метрика = 1,0 при confidence = 1,0), то есть 100% точность работы модели. При этом график Precision – Recall curve (правый верхний график) демонстрирует значение точности более 0,9 при полноте более 0,8 с условием threshold = 0,5 по метрике mAP. Метрику полноты (recall) для всех классов снижает возможность определения метки «подставка», что говорит о необходимости расширения датасета в целях обучения модели для детекции именно их.

Отметим, что графики метрик качества для определения масок предметов показывают идентичные результаты, поэтому в настоящей статье данный блок графиков будет упущен.

Следующий блок изображений представлен матрицами ошибок (нормализованной и обычной), корреляционной матрицей меток и описанием представленных меток. Группировка изображена на рис. 3.

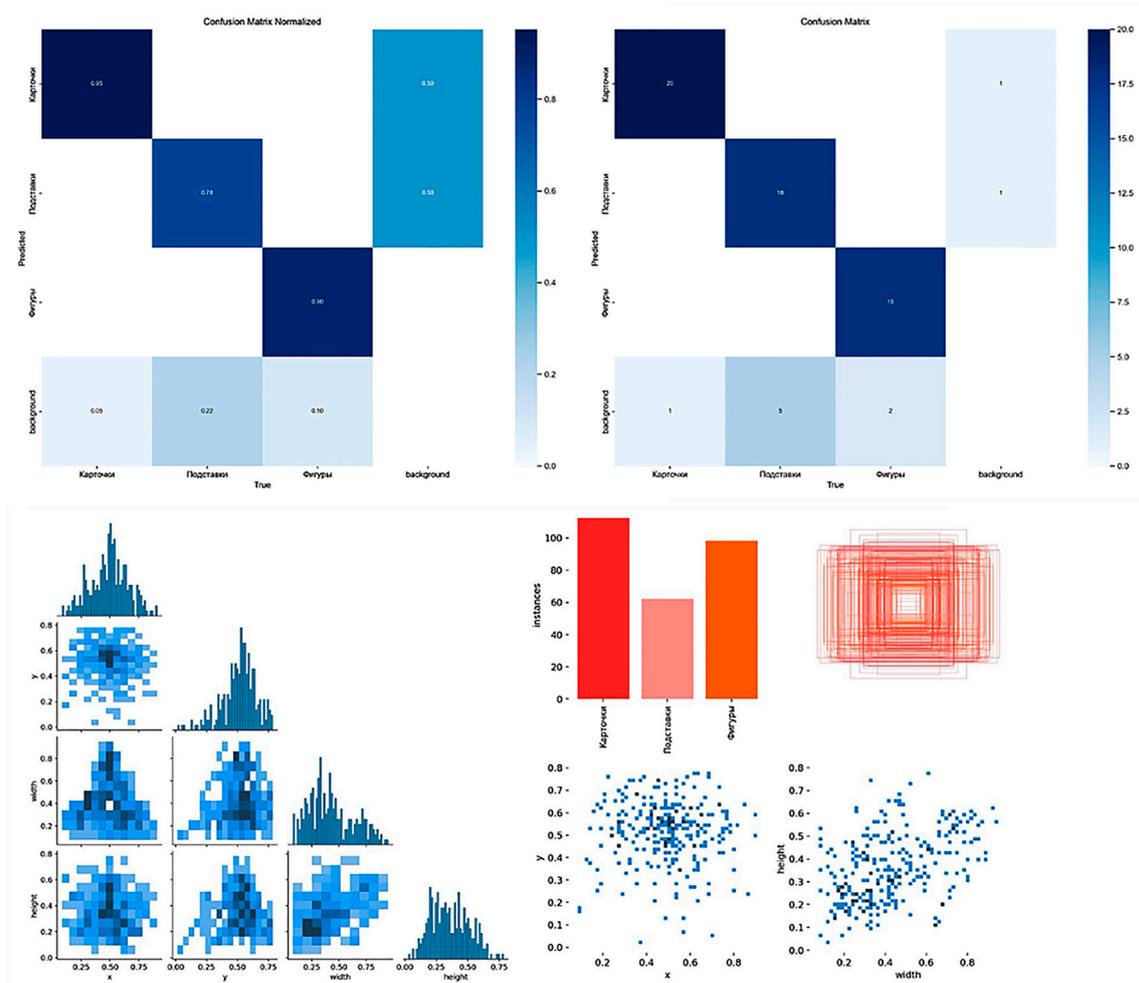


Рис. 3. Графики матриц, полученных в ходе обучения ошибок и меток

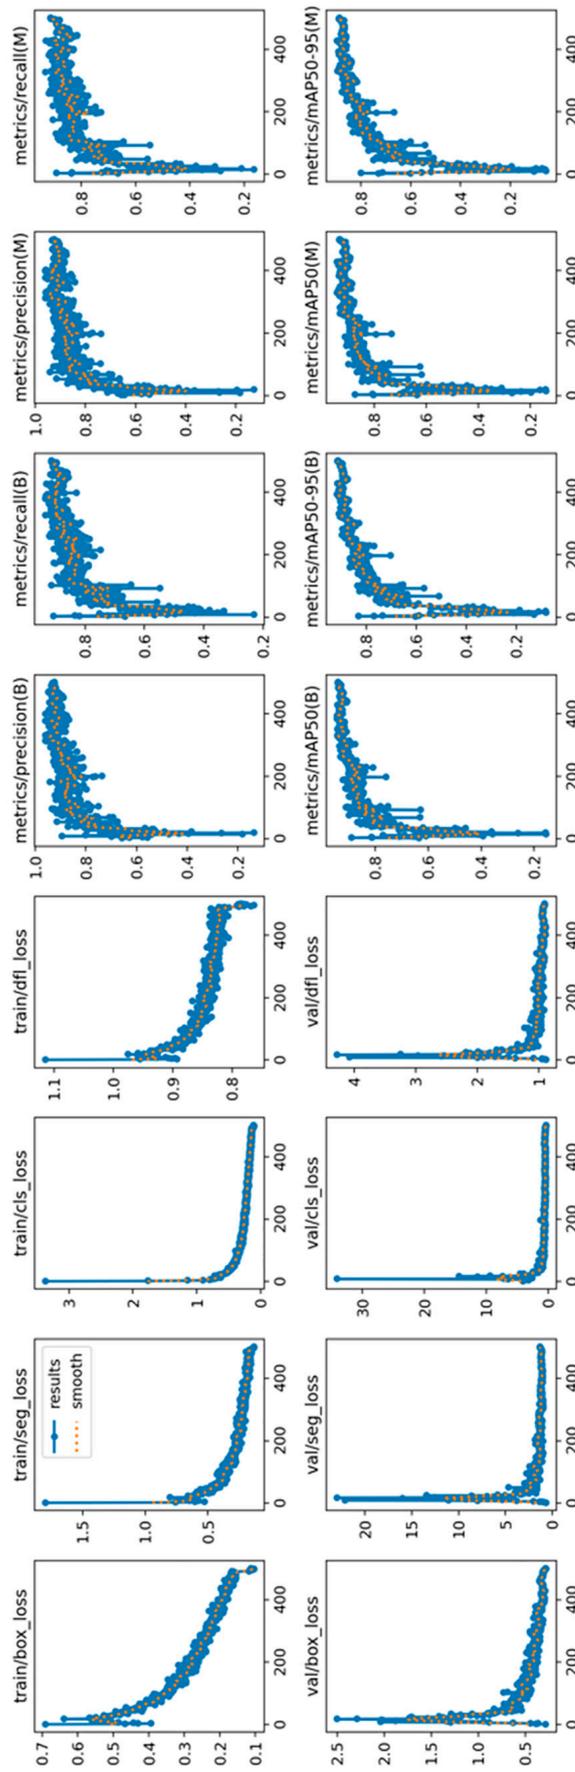


Рис. 4. Графики ошибок, а также средних значений средней точности при различных пороговых значениях IoU, варьирующихся от 0,5 до 0,95

Представленные графики подтверждают гипотезу худшей обработки модели (по сравнению с остальными метками) для определения метки «подставка». Можно увидеть, что при обучении модель «путает» подставку с фоном изображения, либо, наоборот, определяет подставку там, где на фоне ее нет. В свою очередь, по верхнему правому графику можно сделать предположение, что модель обрабатывает подобным образом ввиду наименьшего количества меток «подставка» в изображениях, вошедших в обучающую выборку, и для последующего получения лучших результатов следует дополнить ее именно изображениями с метками «подставка». Но даже с учетом вышенаписанного показатели детекции находятся на высоком уровне (метрика обнаружения объекта с меткой «подставка» равна 0,78).

Одним из основополагающих файлов с точки зрения отслеживания процес-

са обучения модели является файл с изображениями графиков снижения ошибки при обучении, а также графиков средних значений средней точности при различных пороговых значениях IoU, варьирующихся от 0,5 до 0,95. Все метрики, заложенные разработчиками в модель (определение точности построения прямоугольника координат объекта (box), сегментация объекта (seg), определение вероятности отнесения объекта к той или иной метке (cls), определение объекта при его деформации (dff), а также метрики средней точности при перекрытии объекта от 50 до 95 % (mAP)), показывают уверенное снижение (в зону нуля) показателей ошибки, а также увеличение значений точности (в зону единицы) с ростом количества эпох обучения. Результаты представлены на рис. 4.

На рис. 5 представлены примеры детекции объектов в рамках обучения описанной выше модели.

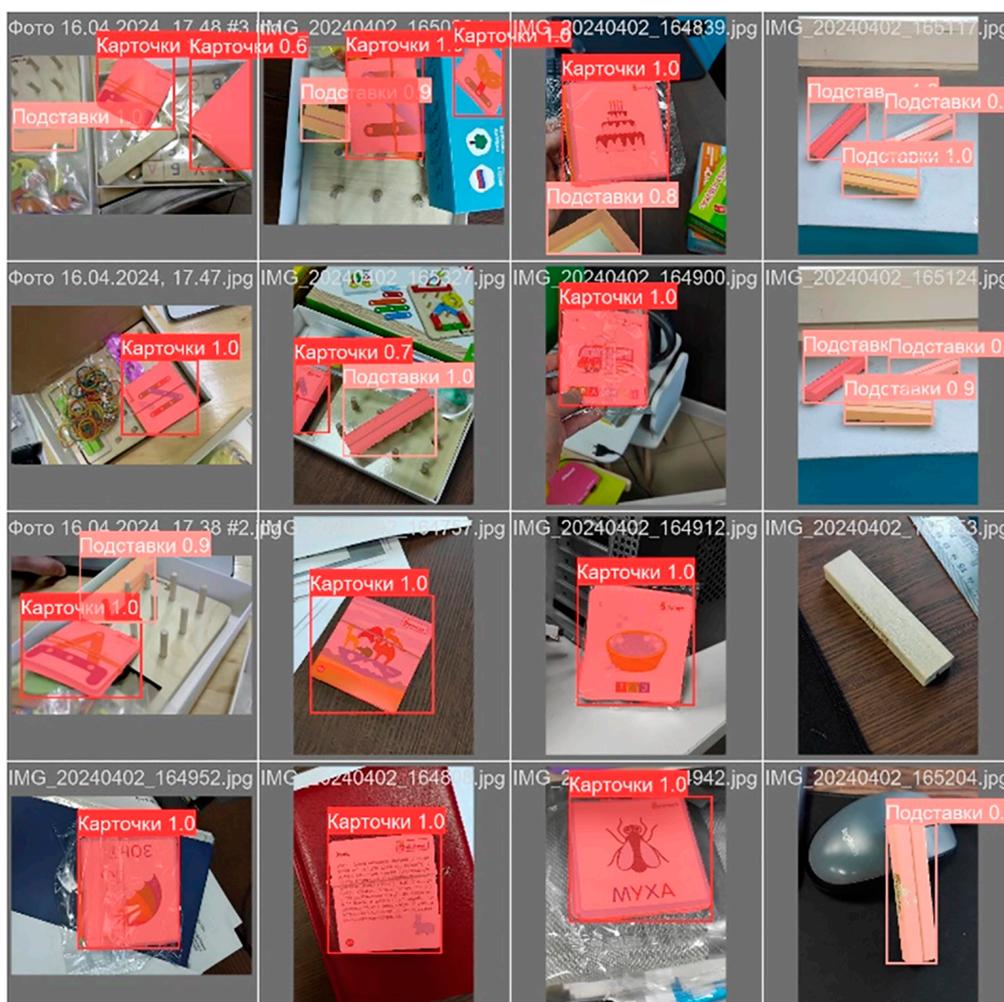


Рис. 5. Пример изображений, получаемых в ходе обучения модели на базе YOLOv8

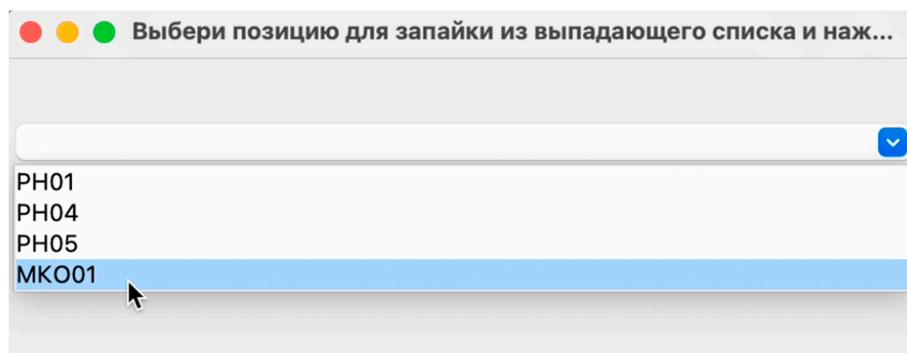


Рис. 6. Пользовательский интерфейс, в который обернута разработанная модель

После обучения модели на языке Python был написан модуль подключения видеокмеры, в том числе беспроводной, для осуществления детекции и блока упрощенного фронтенда для взаимодействия с пользователем с помощью библиотек cv2 [7] и tkinter [8]. На рис. 6 представлен скриншот фронтенда, в рамках которого пользователь выбирает артикул выпускаемого изделия. В рамках работы конвейера при обнаружении детектируемого объекта код считывает количество обнаруженных меток, на которые обучена модель, и сравнивает их количество с количеством единиц выпущенного продукта (они должны совпадать). Оператор станка запайки сравнивает их и при выявлении расхождений проводит повторную проверку партии.

Заключение

По результатам проведенных экспериментов можно сделать однозначный вывод о том, что разработанный прототип показывает достаточно высокую эффективность при использовании на производстве. Подтверждается гипотеза о возможности использования компьютерного зрения на промышленных предприятиях, осуществляющих разработку продукции для детей. И если в целом компьютерное зрение находит свое применение в крупных отраслях промышленности, то разработанное решение вполне может изменить ситуацию с ручным трудом и отслеживанием брака и в малых формах хозяйствования без потребления значительных ресурсов, что особенно актуально в условиях более жестких мер правительства по борьбе с инфляцией, когда и без того недостаточный доступ к оборотным ресурсам предпринимателей грозит значительным сокращением их общего количества.

Кроме того, обучение предлагаемой модели доказало высокую зависимость от набора данных, из которых происходит формирование исходного датасета. При дальнейшей адаптации продукта к выпуску в промышленное применение требуется дообучить модель для детекции метки «подставка», а также продумать, какие аппаратные средства целесообразно использовать для работы модели непосредственно в рамках конвейерных линий. Таким образом, формируются дальнейшие этапы для научного изыскания.

Список литературы

1. Всероссийский бизнес-рейтинг. [Электронный ресурс]. URL: <https://lider-otrasli.ru/reiting-predpriyatij.html> (дата обращения: 14.10.2024).
2. Как в 1999-м. В России зафиксировали рекордно низкий уровень рождаемости. [Электронный ресурс]. URL: <https://360.ru/news/obschestvo/kak-v-1999-m-v-rossii-zafiksirovali-rekordno-nizkij-uroven-rozhdaemosti/> (дата обращения: 14.10.2024).
3. Сычугов А.Н., Михайчиков В.Н., Чернышов М.В. Применение нейронных сетей для распознавания объектов на железнодорожном транспорте // Известия Петербургского университета путей сообщения. СПб.: ПГУПС, 2023. Т. 20. Вып. 2. С. 478–491.
4. Open Data Annotation Platform. [Электронный ресурс]. URL: <https://www.cvat.ai> (дата обращения: 14.10.2024).
5. COCO to YOLO converter for instance segmentation (YOLOv8-seg) and oriented bounding box detection (YOLOv8-obb). [Электронный ресурс]. URL: https://github.com/Koldim2001/COCO_to_YOLOv8 (дата обращения: 14.10.2024).
6. Ultralytics YOLOv8. [Электронный ресурс]. URL: <https://docs.ultralytics.com/models/yolov8/> (дата обращения: 14.10.2024).
7. OpenCV. [Электронный ресурс]. URL: https://docs.opencv.org/4.x/d6/d00/tutorial_py_root.html (дата обращения: 14.10.2024).
8. tkinter – Python interface to Tcl/Tk. [Электронный ресурс]. URL: <https://docs.python.org/3/library/tkinter.html#module-tkinter> (дата обращения: 14.10.2024).