

DOI: 10.24412/2077-8481-2026-3-42-54

УДК 621.865.8:004.932

Б. ОЗДЕМИР

В. М. ШЕМЕНКОВ, канд. техн. наук, доц.

Белорусско-Российский университет (Могилев, Беларусь)

РАЗРАБОТКА АЛГОРИТМА ОБУЧЕНИЯ МОДУЛЯ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА С РЕАЛИЗАЦИЕЙ В РОБОТИЗИРОВАННОЙ СИСТЕМЕ КОНТРОЛЯ КАЧЕСТВА

Аннотация

Рассматривается разработка алгоритма обучения модуля искусственного интеллекта на основе методов глубокого обучения и технологий компьютерного зрения для автоматизированного контроля качества деталей машиностроения. Предложенное решение реализовано в робототехнической системе, включающей промышленный робот, специально разработанный фотобокс и программный модуль анализа изображений. В рамках данной работы робот помещает деталь в фотобокс, где за счёт стабильных условий освещения снижается влияние внешних факторов на качество съёмки. Экспериментальная проверка показала, что точность итогового решения системы достигла 98 %.

Ключевые слова:

машинное обучение, глубокое обучение, YOLO11s, компьютерное зрение, фотобокс, автоматизированный контроль качества, робототехническая система, детали машиностроения, обнаружение дефектов, промышленный робот.

Для цитирования:

Оздемир, Б. Разработка алгоритма обучения модуля искусственного интеллекта с реализацией в роботизированной системе контроля качества / Б. Оздемир, В. М. Шеменков // Вестник Белорусско-Российского университета. – 2026. – № 3 (92). – С. 42–54.

Введение

В современном машиностроении все большее значение приобретает не только высокая производительность, но и стабильный контроль качества выпускаемых деталей. При росте темпов производства традиционный визуальный контроль постепенно становится менее эффективным и менее надежным, особенно если он полностью зависит от оператора. На результат проверки могут влиять усталость человека, условия освещения, опыт контролёра и субъективная оценка дефектов. Поэтому для предприятий всё более актуальной становится задача снижения влияния человеческого фактора и перехода к более устойчивым средствам контроля.

Современное машиностроение всё активнее использует робототехнические решения, что связано с необходимостью повышения производительности, качест-

ва и экономической эффективности производственных процессов [1]. В этих условиях особое значение приобретает не только внедрение промышленных роботов, но и разработка прикладных систем, способных выполнять конкретные производственные операции, включая автоматизированный контроль качества деталей.

Для решения данной задачи перспективным является применение автоматизированных систем, в которых промышленный робот работает совместно с системой компьютерного зрения и модулем искусственного интеллекта. В этом случае робот может выполнять перемещение детали, а программный модуль – получать изображение, анализировать его и принимать решение о наличии дефекта. Для машиностроения такой подход особенно важен, поскольку качество отдельных деталей напрямую

связано с надёжностью готовой продукции.

В последние годы для анализа изображений все чаще применяются методы глубокого обучения. Практический интерес представляют модели семейства YOLO, т. к. они позволяют обнаруживать объекты и дефекты на изображениях в автоматическом режиме. Однако для получения стабильного результата одной только обученной модели недостаточно. Важно также обеспечить повторяемые условия съемки, правильно подготовить обучающие данные, организовать обмен данными между программным модулем и роботом, а также проверить работу всей системы в едином цикле.

Вместе с тем совместное применение промышленного робота, фотобокса, модуля визуального контроля и алгоритмов глубокого обучения в задаче автоматизированного контроля качества деталей требует дополнительного исследования. В реальных условиях результат зависит не только от точности нейронной сети, но и от согласованной работы всех элементов системы. Поэтому необходимо рассматривать не отдельную модель, а все разработанное решение в целом.

В работе рассматривается разработка алгоритма обучения модуля

искусственного интеллекта на основе глубокого обучения и компьютерного зрения для автоматизированного контроля качества деталей машиностроения. Разработанный модуль реализован в составе робототехнической системы, после чего проведена экспериментальная проверка его работы на контролируемых деталях.

Описание эксперимента

В эксперименте использовались серийно изготавливаемые детали машиностроения, пример которых показан на рис. 1. На них проверялась работоспособность разработанной системы автоматизированного контроля качества. Контролю подлежали передняя и задняя поверхности детали. Анализировались два типа дефектов: поверхностные дефекты и дефекты кромок. На рис. 1, *а* показана зона контроля поверхностных дефектов, а на рис. 1, *б* – зона контроля дефектов кромок. Для каждой детали предварительно определялись наличие дефектов и итоговое состояние по принципу ОК/НОК, где ОК соответствует годной детали, а НОК – негодной. Это позволило сравнить результаты автоматизированного контроля с исходной оценкой.




Рис. 1. Контролируемая деталь: *а* – зона контроля поверхностных дефектов; *б* – зона контроля дефектов кромок

Экспериментальная установка включала промышленный робот TM12 с захватным устройством OnRobot RG2, программное обеспечение TMFlow 1.86 для управления роботом, специально разработанный фотобокс, камеру IDS uEye UI-1640SE-C-HQ с USB-интерфейсом, компьютер с программным модулем анализа изображений и модель YOLO11s. Камера использовалась для получения изображений контролируемой детали, а наличие USB-интерфейса обеспечило её подключение к компьютеру и передачу изображений в программный модуль системы [2]. Управление движениями робота и последовательностью операций выполнялось в среде TMFlow 1.86. Робот обеспечивал подачу детали в зону съёмки, её переворот и последующую сортировку по результатам контроля. Камера IDS uEye применялась для получения изображений контролируемой детали, а программный модуль на базе Python выполнял обработку изображений, запуск модели YOLO11s, обмен данными с роботом и формирование итогового решения ОК/НОК.

Для съёмки деталей был разработан специальный фотобокс, обеспечивающий изоляцию от внешнего освеще-

ния, а также стабильные и повторяемые условия съёмки. Конструкция фотобокса включала несущий каркас, вертикальную кольцевую LED-подсветку, боковую LED-подсветку, камеру, контролируемую деталь и рабочую поверхность. Вертикальная кольцевая подсветка применялась для равномерного освещения поверхности детали и повышения контрастности изображения, а боковая подсветка, установленная под углом 10° по принципу низкоуглового тёмнопольного освещения, позволяла лучше выявлять локальные неровности поверхности, поверхностные дефекты и дефекты кромок [3]. Такое сочетание освещения позволило получить более стабильные изображения для последующего анализа моделью YOLO11s. Общий вид и схема конструкции фотобокса показаны на рис. 2.

В процессе эксперимента робот помещал деталь в фотобокс, после чего выполнялась съёмка первой поверхности. Затем деталь переворачивалась, и аналогичным образом получалось изображение второй поверхности. Полученные изображения передавались в модуль глубокого обучения для анализа дефектов. Общий вид экспериментальной установки представлен на рис. 3.

а)



б)




Рис. 2. Фотобокс: а – общий вид фотобокса; б – схема конструкции фотобокса: 1 – несущий каркас; 2 – вертикальная кольцевая LED-подсветка; 3 – боковая LED-подсветка; 4 – камера; 5 – контролируемая деталь; 6 – рабочая поверхность



Рис. 3. Экспериментальная робототехническая установка для автоматизированного контроля качества деталей: *а* – фотобокс; *б* – промышленный робот TM12; *в* – ноутбук с программным модулем анализа изображений; *г* – контролируемые детали; *д* – контейнеры для сортировки деталей по результату OK/NOK

Для анализа изображений была выбрана модель семейства YOLO, поскольку в данной работе алгоритм должен был работать не отдельно, а в составе робототехнической системы контроля качества. В такой системе важны не только точность обнаружения дефектов, но и скорость обработки, простота интеграции с роботом и программным модулем, а также возможность работы в режиме, близком к реальному времени. В отличие от двухэтапных методов обнаружения объектов, основанных на предварительном формировании областей-кандидатов, YOLO относится к одностадийным детекторам. В данной архитектуре одна нейронная сеть за один проход по изображению предсказывает ограничивающие рамки и вероятности классов, что делает её удобной для задач, где важны скорость обработки и простота интеграции с другими модулями системы [3, 4].

Выбор YOLO как быстрого одностадийного метода обнаружения также подтверждается результатами J. Redmon и др. [4]. На рис. 4 приведены кривые

precision-recall для набора данных Picasso, где YOLO сопоставляется с другими методами обнаружения объектов. С учетом указанных особенностей в данной работе для практической реализации была использована модель YOLO11s.

На поверхностях детали рассматривались два типа дефектов: поверхностные дефекты и дефекты кромок. На этапе подготовки данных значимыми считались дефекты шириной 2 пикселя и более, что при использованном разрешении изображения соответствовало примерно 0,27 мм. С учетом данного порога все выявленные дефекты были размечены в программе LabelImg в формате, предназначенном для обучения модели YOLO11s. Объект исследования и используемый шаблон определения порога значимого дефекта представлены на рис. 5.

На основе подготовленного набора данных было выполнено обучение модели YOLO11s. Для оценки влияния объёма обучающих данных на качество обучения были проведены три цикла

обучения с последующей экспериментальной проверкой системы. В каждом следующем цикле количество деталей, изображений и размеченных дефектов увеличивалось. Данные разделялись на обучающую, валидационную и тестовую выборки, что позволило отдельно выполнять обучение модели, контролировать процесс её настройки и проверять итоговое качество работы [5]. В данной работе использовалось соотношение

70 : 15 : 15. Обучение выполнялось при размере входного изображения 1024 пикселя и количестве эпох 150. После каждого цикла модель проверялась по основным валидационным метрикам, а затем использовалась при экспериментальной проверке всей системы автоматизированного контроля качества. Общая последовательность подготовки данных, обучения и оценки модели показана на рис. 6.




Рис. 4. Кривые precision-recall для набора данных Picasso [4]




Рис. 5. Объект исследования и используемый шаблон определения порога значимого дефекта




Рис. 6. Основные этапы подготовки данных, обучения и оценки модели YOLO11s

Характеристика наборов данных, использованных в трёх циклах обучения модели YOLO11s, приведена в табл. 1. После каждого цикла модель обучалась

заново, а затем выполнялась экспериментальная проверка работы всей системы автоматизированного контроля качества.

Табл. 1. Характеристика наборов данных, использованных при обучении модели YOLO11s

Параметр	Цикл обучения 1	Цикл обучения 2	Цикл обучения 3
Количество использованных деталей	80	140	200
Общее количество изображений	160	280	400
Количество обучающих изображений	112	196	280
Количество валидационных изображений	24	42	60
Количество тестовых изображений	24	42	60
Соотношение обучающей / валидационной / тестовой выборки, %	70 / 15 / 15	70 / 15 / 15	70 / 15 / 15
Количество изображений с дефектами	128	219	301
Количество изображений без дефектов	32	61	99
Общее количество размеченных дефектов	465	868	1184
Используемая модель	YOLO11s	YOLO11s	YOLO11s
Размер изображения	1024	1024	1024
Количество эпох обучения	150	150	150
Метрики оценки модели	Precision, Recall, mAP50, mAP50–95		

После каждого цикла обучения выполнялась повторная оценка валидационных показателей модели YOLO11s: Precision, Recall, mAP50, mAP50–95 и F1-score. Precision, Recall, mAP50, mAP50–95 и F1-score. Затем проводилась экспериментальная проверка всей системы, в ходе которой определя-

лись доля дефектов, выявленных системой, и точность итогового решения ОК/НОК.

После обучения модель YOLO11s применялась для обнаружения поверхностных дефектов и дефектов кромок на изображениях контролируемых деталей. Пример работы обученной модели приведён на рис. 7.




Рис. 7. Пример обнаружения поверхностных дефектов и дефектов кромок моделью YOLO11s

Основная часть

Качество обучения модели YOLO11s оценивалось по валидационным метрикам Precision, Recall, mAP50, mAP50–95 и F1-score. Precision характеризует долю корректно найденных дефектов среди всех объектов, обнаруженных моделью, Recall характеризует способность модели находить реальные

дефекты, а F1-score отражает баланс между этими двумя показателями. Метрики mAP50 и mAP50–95 использовались для оценки качества обнаружения при различных порогах IoU (Intersection over Union – степень пересечения предсказанной и истинной ограничивающих рамок). Основные результаты валидации после трёх циклов обучения приведены в табл. 2.

Табл. 2. Основные показатели валидации модели YOLO11s после трёх циклов обучения

Цикл обучения	Количество деталей	Количество изображений	Количество дефектов	Precision	Recall	mAP50	mAP50–95	F1-score
1	80	160	465	0,57	0,56	0,49	0,12	0,57
2	140	280	868	0,69	0,71	0,7	0,54	0,70
3	200	400	1184	0,79	0,86	0,84	0,64	0,82

Из данных табл. 2 видно, что увеличение объёма обучающей выборки положительно повлияло на качество работы модели. После первого цикла обучения значения метрик были сравнительно низкими, что связано с ограниченным количеством изображений и размеченных дефектов. После второго цикла наблюдалось заметное улучшение всех основных показателей. Наилучшие результаты были получены после третьего цикла обучения, когда использовался

полный набор данных из 200 деталей и 400 изображений. В этом случае Precision составил 0,79, Recall – 0,86, mAP50 – 0,84, mAP50–95 – 0,64, а F1-score достиг 0,82.

Для более наглядного анализа результатов третьего цикла обучения на рис. 8 приведены графики функций потерь, основных метрик и кривых оценки качества модели YOLO11s.




Рис. 8. Графики функций потерь, метрик и кривых оценки качества модели YOLO11s после третьего цикла обучения: а – графики функций потерь; б – графики метрик; в – кривые оценки качества модели YOLO11s

На рис. 8 показаны результаты третьего цикла обучения модели YOLO11s в виде графиков функций потерь, основных метрик и кривых оценки качества. По графикам потерь

локализации (box_loss), классификации (cls_loss) и уточнения границ (dfl_loss) видно, что в процессе обучения ошибки модели постепенно снижались. Графики точности (Precision), полноты (Recall),

mAP50 и mAP50–95 отражают общий рост качества обнаружения дефектов по мере обучения. Кривые оценки качества дополнительно показывают, что после третьего цикла обучения модель работала более устойчиво при различных значениях порога уверенности.

Особенно важным для задачи контроля качества является рост показателя полноты (Recall). Его увеличение с 0,56 до 0,86 показывает, что модель стала пропускать меньше реальных дефектов. Это имеет практическое значение, т. к. при контроле качества опаснее не ложное срабатывание, а пропуск

дефектной детали.

Помимо валидационных метрик модели, была проведена экспериментальная проверка всей системы. В этом случае оценивалась уже не отдельная способность модели находить дефекты на изображениях, а итоговый результат работы системы при разделении деталей на годные и негодные. Для каждой детали сравнивались исходный статус ОК/НОК и результат, полученный системой после анализа двух поверхностей. Обобщённые результаты экспериментальной проверки приведены в табл. 3.

Табл. 3. Обобщённые результаты экспериментальной проверки системы после трёх циклов обучения модели YOLO11s

Цикл обучения	Количество проверенных деталей	Исходное количество дефектов	Количество дефектов, выявленных системой	Количество ОК по решению системы	Количество NOK по решению системы	Доля выявленных дефектов, %	Точность итогового решения, %
До начала	200	1184	—	33	167	—	—
После 1-го цикла	200	1184	818	63	137	69,09	85,00
После 2-го цикла	200	1184	988	43	157	83,45	95,00
После 3-го цикла	200	1184	1059	37	163	89,44	98,00

По данным табл. 3 видно, что после каждого следующего цикла обучения система выявляла большее количество дефектов. После первого цикла было обнаружено 818 дефектов из 1184, после второго – 988, а после третьего – 1059. Доля выявленных дефектов увеличилась с 69,09 % до 89,44 %. Одновременно выросла и точность итогового решения ОК/НОК: с 85,00 % после первого цикла до 98,00 % после третьего цикла обучения.

На рис. 9 приведено сравнение F1-score модели YOLO11s после третьего цикла обучения и итоговой точности системы при разделении деталей на годные и негодные.

Уровни 74 % [6] и 95 % [7] в данной работе использованы как условные ориентиры базового и высокого качества

соответственно. Как видно из рис. 9, F1-score модели составил 82 %, а итоговая точность решения ОК/НОК достигла 98 %.

Следует отметить, что валидационные показатели модели и итоговая точность системы имеют разный смысл. Валидационные метрики характеризуют качество работы YOLO11s на уровне отдельных дефектов: насколько точно модель выявляет дефектные области, определяет их класс и не пропускает реальные дефекты на изображениях. А итоговая точность системы, в свою очередь, относится уже к конечному решению по детали: считается она годной или негодной. Поэтому эти показатели не должны полностью совпадать по значению.



Рис. 9. Сравнение F1-score модели YOLO11s и итоговой точности системы OK/NOK

Различие между валидационными показателями модели и итоговой точностью системы связано с принятой логикой OK/NOK. В данной системе деталь относится к категории негодных, если хотя бы на одной из двух контролируемых поверхностей обнаружен значимый дефект. Поэтому для правильного итогового решения системе не обязательно выявить все дефекты, имеющиеся на детали. Достаточно обнаружить один значимый дефект, чтобы решение NOK было принято правильно. Этим объясняется ситуация, при которой F1-score модели после третьего цикла обучения составил 82 %, а точность итогового решения системы достигла 98 %.

Согласно рекомендациям Ultralytics, для более устойчивого обучения моделей YOLO желательно использовать не менее 1500 изображений и 10000 размеченных объектов на каждый класс [8]. В данной работе, как показано в табл. 1, максимальный объем данных составил 400 изображений и 1184 размеченных дефекта. Поэтому валидационные метрики следует рассматривать с учетом ограниченного размера обучающей выборки. Для сравнения, в работе А. В. Инютина и М. М. Лукашевича для детекции дефектов печатных плат использовался набор DeepPCB,

содержащий 1500 пар изображений. При таком объеме данных модель YOLOv8 показала значение mAP50, равное 0,98 [9]. Этот пример дополнительно показывает связь между объемом обучающих данных и качеством детального обнаружения и классификации дефектов.

В обзорной работе D. Y. Patrashko и V. Gurau [7], где рассматривалось более 50 исследований по машинному зрению для роботизированного контроля, отмечается, что во многих работах точность обнаружения и классификации дефектов превышает 95 %. В связи с этим уровень 95 % в данной работе рассматривается как условный ориентир высокого качества работы системы. Таким образом, точность 98 % характеризует эффективность разработанной системы именно на уровне автоматизированного разделения деталей на годные и негодные. Дальнейшее повышение качества детального анализа отдельных дефектов требует расширения обучающего набора данных.


Для наглядного представления изменения результатов после трех циклов обучения была построена зависимость основных показателей системы от объема обучающих данных. Как видно из рис. 10, увеличение количества изображений и размеченных дефектов

привело к последовательному росту как доли выявленных дефектов, так и точности итогового решения.

Дополнительно была выполнена оценка эффективности применения промышленного робота при выполнении операции контроля. Для этого сравнивались два варианта подачи детали в фотобокс. В первом случае деталь перемещалась промышленным роботом, во

втором – оператор вручную устанавливал деталь в фотобокс по той же последовательности действий. При этом получение изображений и их анализ выполнялись одинаковым способом. Поэтому сравнение было направлено не на оценку качества визуального анализа, а на определение влияния роботизации на время выполнения операции и повторяемость операции контроля. Результаты сравнения времени контроля приведены в табл. 4.

а)



б)




Рис. 10. Итоговые результаты работы системы после трёх циклов обучения модели YOLO11s: а – точность итогового решения ОК/НОК; б – доля выявленных дефектов

Табл. 4. Сравнение времени контроля при ручной установке детали и роботизированной подаче

Показатель	Ручная установка детали	Роботизированная подача
Количество деталей	200	200
Общее время контроля	162 мин	56,7 мин
Время на одну деталь	48,6 с	17 с
Экономия времени	—	≈105 мин
Ускорение процесса	—	≈2,9 раза

Из табл. 4 видно, что применение промышленного робота позволило существенно сократить время выполнения контроля. При ручной установке деталей в фотобокс общее время проверки 200 деталей составило 162 мин, тогда как при роботизированной подаче – около 56,7 мин. Таким образом, процесс контроля стал примерно в 2,9 раза быстрее.

Основная разница связана с тем, что при ручной установке значительное

время затрачивается на позиционирование детали, её переворот и повторное размещение в фотобоксе. При использовании робота эти операции выполняются более стабильно и с меньшими временными потерями. Поэтому роботизированная подача деталей повышает не только производительность контроля, но и повторяемость выполнения операции.

В целом результаты проведённого

исследования показывают, что увеличение объема обучающих данных положительно влияет как на валидационные показатели модели YOLO11s, так и на итоговую точность работы всей системы. После третьего цикла обучения система достигла точности 98,00 % при разделении деталей на годные и негодные. Кроме того, применение промышленного робота позволило сократить время контроля и сделать процесс более стабильным. Полученные результаты подтверждают работоспособность разработанного решения и возможность его применения для автоматизированного контроля качества деталей машиностроения.

Заключение

На основании проведенного исследования разработан алгоритм обучения модуля искусственного интеллекта на основе методов глубокого обучения и компьютерного зрения, реализованный в составе робототехнической системы автоматизированного контроля качества деталей машиностроения. Проведена экспериментальная проверка работоспособности разработанного решения. В состав системы вошли промышленный робот TM12, захватное устройство OnRobot RG2, фотобокс с контролируемыми условиями освещения, камера IDS uEye UI-1640SE-C-HQ, модель YOLO11s и программный модуль принятия решения на базе Python. Показано, что использование фотобокса позволяет снизить влияние внешнего освещения и обеспечить повторяемые условия получения изображений контролируемой детали.

Для анализа изображений была обучена модель YOLO11s, предназначенная для обнаружения поверхностных дефектов и дефектов кромок. Обучение проводилось в три цикла с постепенным увеличением объема данных: от 80 деталей и 160 изображений до 200 деталей и 400 изображений. Установлено, что

увеличение количества изображений и размеченных дефектов положительно влияет на качество работы модели. После третьего цикла обучения были получены лучшие значения валидационных показателей: точности (Precision) составил 0,79, полноты (Recall) – 0,86, mAP50 – 0,84, mAP50–95 – 0,64, а F1-score – 0,82.

Экспериментальная проверка всей системы показала, что после третьего цикла обучения доля выявленных дефектов достигла 89,44 %, а точность итогового решения ОК/НОК составила 98,00 %. Такое различие между валидационными метриками модели и итоговой точностью системы объясняется логикой принятия решения: для отнесения детали к категории негодных достаточно обнаружить хотя бы один значимый дефект на одной из контролируемых поверхностей. Поэтому показатель 98,00 % характеризует эффективность разработанного решения именно на уровне автоматизированного разделения деталей на годные и негодные.

Дополнительно установлено, что применение промышленного робота позволяет сократить время выполнения контроля по сравнению с ручной установкой деталей в фотобокс. Проверка 200 деталей при роботизированной подаче заняла около 56,7 мин вместо 162 мин при ручной установке, что соответствует ускорению процесса примерно в 2,9 раза. Это подтверждает, что роботизация операции повышает не только производительность контроля, но и повторяемость выполнения цикла.

Полученные результаты подтверждают работоспособность разработанной системы и возможность ее применения для автоматизированного контроля качества деталей машиностроения. Дальнейшее развитие работы может быть связано с расширением обучающего набора данных, добавлением новых типов деталей и дефектов, а также адаптацией системы к условиям непрерывного производственного контроля.

СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ

1. **Ozdemir, B.** Return on Investment in Industrial Robotics Transformation «One Case and 10 Countries» / B. Ozdemir, V. M. Shemenkov // 4th International Congress on Materials Engineering and Advanced Manufacturing Technologies (IMEAMTC 2025), Istanbul, 26 Jan. 2025. – Istanbul, 2025. – P. 48–55.
2. IDS Imaging Development Systems GmbH. UI-1640SE-C uEye Camera. Technical Data Sheet. – URL: <https://www.adept.net.au/cameras/ids/pdf/1640C.pdf> (date of access: 03.05.2026).
3. STEMMER Imaging. Machine Vision Lighting for Industrial Inspection. – URL: <https://www.stemmer-imagingusa.com/blog/machine-vision-lighting-for-industrial-inspection> (date of access: 03.05.2026).
4. You Only Look Once: Unified, Real-Time Object Detection / J. Redmon, S. Divvala, R. Girshick, A. Farhadi // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). – 2016. – P. 779–788.
5. Google for Developers. Machine Learning Crash Course: Training and Test Sets – Splitting Data. – URL: <https://developers.google.com/machine-learning/crash-course/training-and-test-sets/splitting-data> (date of access: 05.05.2026).
6. Ultralytics. Mean Average Precision (mAP) in Object Detection. – URL: <https://developers.google.com/machine-learning/crash-course/training-and-test-sets/splitting-data> (date of access: 10.05.2026).
7. **Patrashko, D. Y.** Machine Learning-Powered Vision for Robotic Inspection in Manufacturing: A Review / D. Y. Patrashko, V. Gurau // Sensors. – 2026. – Vol. 26, № 3. – P. 788.
8. Ultralytics. Tips for Best YOLOv5 Training Results // Ultralytics YOLO Docs. – URL: https://docs.ultralytics.com/yolov5/tutorials/tips_for_best_training_results (date of access: 10.05.2026).
9. **Инютин, А. В.** Детекция дефектов печатных плат на основе архитектуры YOLOv8 / А. В. Инютин, М. М. Лукашевич // Системный анализ и прикладная информатика. – 2024. – № 2. – С. 16–24.

Статья сдана в редакцию 1 июня 2026 года

Контакты:

namebulent@gmail.com (Оздемир Бюлент);
vshemenkov@yandex.by (Шеменков Владимир Михайлович).

B. OZDEMIR, V. M. SHEMENKOV

DEVELOPMENT OF AN AI MODULE TRAINING ALGORITHM IMPLEMENTED IN A ROBOTIC QUALITY CONTROL SYSTEM

Abstract

The article considers the development of a training algorithm for an artificial intelligence module based on deep learning methods and computer vision technologies for automated quality control of mechanical engineering parts. The proposed solution is implemented in a robotic system that includes an industrial robot, a specially developed photobox, and a software module for image analysis. Within the scope of this work, the robot places the part into the photobox, where stable lighting conditions reduce the influence of external factors on image quality. Experimental verification showed that the accuracy of the final system decision reached 98 %.

Keywords:

machine learning, deep learning, YOLO11s, computer vision, photobox, automated quality control, robotic system, mechanical engineering parts, o defect detection, industrial robot.

For citation:

Ozdemir, B. Development of an AI module training algorithm implemented in a robotic quality control system / B. Ozdemir, V. M. Shemenkov // Belarusian-Russian University Bulletin. – 2026. – № 3 (92). – P. 42–54.