

Применение нейросетевых методов в программно-аппаратные комплексы контроля оптических систем

© Ш. И. Зарипов^{1,2*}, А. В. Полесский¹, Н. А. Семенченко¹, О. А. Медведев^{1,3}

¹ АО «НПО «Орион», Москва, 111538 Россия

* E-mail: mail@tonyferro.com

² МИРЭА – Российский технологический университет, Москва, 119454 Россия

³ Московский государственный технический университет имени Н. Э. Баумана, Москва, 105005 Россия

Статья поступила в редакцию 21.05.2026; после доработки 1.06.2026; принята к публикации 5.06.2026

Разработана интеллектуальная система для автоматизированного контроля параметров оптических систем – таких, как фокусное расстояние, разрешающая способность и дисторсия различных диапазонов спектра. Система базируется на архитектуре сверточных нейронных сетей семейства YOLO и специализированном аппаратно-программном комплексе. Разработанная автоматизированная система контроля параметров объективов работает в спектральных диапазонах 0,4–2,0 и 8–14 мкм. Комплекс перспективен для серийного выпуска оптики благодаря сокращению времени измерений, уменьшению трудозатрат.

Ключевые слова: сверточная нейронная сеть, YOLO, система компьютерного зрения, обнаружение объектов, оптика, объективы, автоматизация измерений, фокусное расстояние, дисторсия, разрешающая способность.

DOI: 10.51368/1996-0948-2026-3-82-90

Введение

Производство оптических систем (далее – ОС) включает в себя этап контроля выходных параметров конечной продукции, к которым относятся фокусное расстояние, дисторсия и разрешающая способность, являющиеся ключевыми в характеристике ОС для работы в составе оптико-электронного прибора [1].

Целевая задача внедрения систем искусственного интеллекта в технологическую цепь производства объективов для различных систем технического зрения заключается в наращивании отечественного производства при уменьшении себестоимости продукции за счет создания автоматизированных систем, позволяющих проводить более быстрые и точные измерения оптических параметров с минимизацией человеческого фактора.

Современная отечественная метрологическая база, используемая для производства ОС, включает в себя методы контроля параметров ОС, однако не подразумевает автоматизацию, что порождает несколько проблем: длительный цикл производства, низкая производительность труда при серийном выпуске и субъективность в измерениях.

Для проведения автоматизированного измерения фокусного расстояния, дисторсии и разрешающей способности с использованием методов искусственного интеллекта необходимо было решить следующие задачи:

1. Разработка алгоритмов автопозиционирования и автофокусирования ОС;

2. Разработка нейронной сети для распознавания контрольных точек тест-объекта, которая будет использоваться для измерения фокусного расстояния и дисторсии ОС, а также при автопозиционировании;

3. Разработка нейронной сети для распознавания групп штрихов тест-объекта, необходимой для определения разрешающей способности ОС;

4. Разработка алгоритмов проведения анализа и выполнения необходимых расчетов для определения значений фокусного расстояния, разрешающей способности и дисторсии ОС.

Техническая реализация

Отправной точкой для разработки системы контроля с применением методов искусственного интеллекта стал ряд методик измерений и техническая реализация прецизионной измерительной установки, предназначенной для проведения измерений фокусного расстояния, дисторсии и разрешающей способности в двух спектральных диапазонах: 0,4–2,0 мкм и 8–14 мкм. Обобщенная схема измерений приведена на рисунке 1.




Рис. 1. Обобщенная схема измерений значений фокусного расстояния, дисторсии и разрешающей способности ОС: 1 – источник излучения; 2 – фотометрическая сфера (для спектрального диапазона 0,4–2,0 мкм); 3 – тест-объект; 4 – коллиматор; 5 – контролируемый объектив; 6 – матричное фотоприемное устройство; 7 – двухосный линейный транслятор; 8 – линейный транслятор; 9 – поворотная платформа; 10 – ПК с ПО

Спектральный диапазон работы стенда определяется в первую очередь видом используемого источника излучения и матричного фотоприемника. Источник излучения 1 представляет из себя модель абсолютно черного тела (АЧТ) для спектрального диапазона 8–14 мкм и узел освещения с лампой накаливания для спектрального диапазона 0,4–2,0 мкм. При работе в спектральном диапазоне 0,4–2,0 мкм при необходимости может использоваться фотометрическая сфера 2 для обеспечения равномерного распределения излучения в плоскости тест-объекта. В то же время вместо фотометрической сферы может использоваться конструкция узла освещения, выпол-

няющая аналогичную функцию. В качестве матричного фотоприемника 6 для регистрации изображения в фокальной плоскости контролируемого объектива в стенде поочередно используются неохлаждаемый микроболометр и SWIR-камера, включающая работу в видимом диапазоне – для контроля объективов соответствующих спектральных диапазонов. Используемые тест-объекты 3 представляют собой набор специально разработанных миш, включающих в себя группы штрихов для определения разрешающей способности и реперные точки для определения фокусного расстояния и дисторсии. Для формирования параллельного пучка лучей, имитирующего расположение объекта в бесконечности, используется коллиматор 4. Для обеспечения измерения разрешающей способности в технической реализации стенда используется проекционная вспомогательная оптическая система, она необходима для решения проблемы соизмеримости размеров шага матрицы и изображения штрихов.

В качестве объектов интереса для автоматизации с помощью нейросетевых методов выбраны методы измерений, принцип которых основан на следующем:

– метод измерений фокусного расстояния объективов основан на классическом методе увеличений: линейное увеличение оптической системы, состоящей из объектива коллиматора и контролируемого объектива, является одновременно отношением размеров предмета и его изображения и отношением фокусных расстояний контролируемого объектива и объектива коллиматора, в связи с чем фокусное расстояние объектива $f'_{к.о}$ определяется по одной из формул, в зависимости от того, известно ли фокусное расстояние коллиматора с достаточной точностью, либо же путем измерения угловых размеров тест-объектов с помощью теодолита:

$$f'_{к.о} = f'_{кол} \cdot \frac{y'}{y}, \quad f'_{к.о} = \frac{y'}{\text{tg}\varphi}, \quad (1)$$

где $f'_{кол}$ – фокусное расстояние объектива коллиматора, мм; y – линейный размер тест-объекта, мм; y' – линейный размер изображения тест-объекта, мм; φ – угловой размер тест-объекта, град.;

– метод измерений разрешающей способности объективов основан на определении предельно разрешаемой штриховой меры через контролируемый объектив, которой соответствует наименьшее разрешаемое расстояние между серединами двух соседних светлых (темных) штрихов штриховой меры; искомое значение предела разрешающей способности $R_{к.о}$, лин/мм, определяется в соответствии с угловым размером элемента предельно разрешаемой меры $\bar{\varphi}$, град., по формуле

$$R_{к.о} = \frac{1}{f'_{к.о} \cdot \text{tg}\bar{\varphi}}; \quad (2)$$

– метод измерений дисторсии объективов основан на измерении отклонения координаты изображения точки от расчетного значения при повороте объектива с помощью поворотной платформы 9, соответствующему отклонению положения изображения объекта на краю поля объектива (по полю объектива), возникающего из-за дисторсии ОС; значение дисторсии ν , %, при этом вычисляется по формуле

$$\nu = \frac{y' - l}{l} \cdot 100 \%, \quad (3)$$

где $l = f'_{к.о} \cdot \text{tg} \omega$ – расчетное значение перемещения изображения тест-объекта, мм, при повороте объектива на угол ω , град.; y' – фактическое перемещение изображения тест-объекта, мм.

Управление системой осуществляется через интерфейс разработанного ПО, реализующего протоколы взаимодействия с контроллерами шаговых двигателей, и захват видеопотока в режиме реального времени.

Автоматическое позиционирование и фокусирование

Базовыми функциями автоматизированной системы являются возможность автоматической фокусировки и совмещения центра тест-объекта с центром матрицы фотоприемного устройства. Данные процессы происходят при подготовке к измерениям оптических

параметров на стенде следующим образом: выполняется автоматическое позиционирование изображения тест-объекта в центр матричного фотоприемника с помощью двухосного линейного транслятора 7 (см. рис. 1), после чего происходит автоматическое фокусирование с помощью линейного транслятора 8.

Фокусировка системы – совмещение фокальной плоскости контролируемого объектива и плоскости предметов вспомогательной проекционной ОС – важна для корректной работы системы и для повышения точности приводимых измерений. Для автоматизации этого процесса в системе применен способ оценки резкости методом Таненграда [2], основанного на анализе градиентов яркости изображения. Идея метода следующая: чем больше резкость изображения, тем сильнее перепады яркости (границы объектов) и, соответственно, больше значения градиента. Этот метод базируется на операторе Собеля и демонстрирует высокую помехоустойчивость в ИК кадрах с повышенным шумовым фоном [3]. Соответственно, алгоритм автоматической фокусировки сводится к перебору диапазона линейного транслятора, отвечающего за фокусировку, с определенным оператором шагом. На каждой остановке происходит считывание кадра и расчет значения резкости методом Таненграда. Наибольшее значение запоминается системой и в конце, пройдя весь диапазон, линейный транслятор выставляется в положение с наибольшим значением градиента.

Позиционирование системы происходит в два этапа: калибровка осей – расчет количества шагов двигателей, необходимых для прохождения 1 мм линейными трансляторами; сдвиг по каждой из осей до центральной точки изображения. Калибровка осей происходит с помощью таблицы юстировки – набора корректировок для точной настройки положения. Система с помощью нейронной сети распознает центр тест-объекта, запоминает начальное положение, затем оси сдвигаются на 1 мм и выполняется повторное распознавание для определения конечного положения, далее вычисляется разница между двумя положениями – расстояние в пикселях, которое проходит система при физическом сдвиге оси на 1 мм. Причем сдвиг выполняется в несколько итераций и не только на 1 мм для более точной калибровки. Определив, какое требуется пройти

расстояние на физическом уровне, чтобы свети центр тест-объекта в центр матрицы изображения, система сдвигает оси.

Разработка нейросетевых моделей

Современный прогресс в области нейронных сетей демонстрирует возможность их использования даже со слабыми вычислительными ресурсами [4, 5], что, несомненно, закладывает в них потенциал широкого внедрения в измерительное оборудование. Это открывает путь к созданию интеллектуальных установок, способных выполнять быстрый и точный анализ данных непосредственно в процессе их получения, обеспечивая оперативное принятие решений без значительных задержек. Благодаря этому повышается эффективность работы систем в условиях ограниченного времени и ресурсов, а также снижается зависимость от внешней вычислительной инфраструктуры. Такие установки могут адаптироваться к изменяющимся условиям среды и обеспечивать высокий уровень автоматизации всего производства в целом. В результате расширяется спектр их применения – от единичных измерений до условий серийного производства.

Существующие классические не-нейросетевые методы также построены на анализе изображения (в том числе путем вычисления свертков), но не приспособлены к многоэтапным измерениям и требуют разработки сложных алгоритмов, что особенно трудно реализуемо в универсальных установках, приспособленных для проведения измерений различных оптических систем, отличающихся,

например, по спектральным диапазонам или фокусным расстояниям.

С учетом требований к системе был проведен анализ семейств нейросетевых архитектур [6–12]. Для решения задачи распознавания контрольных точек и групп штрихов рассматривались современные одностадийные архитектуры, так как они обеспечивают наилучшее соотношение скорости и точности при выполнении вычислений на центральном процессоре без использования дискретного графического ускорителя. Среди них выделяются три основных направления: классические детекторы, современные универсальные модели и сверхлегкие мобильные архитектуры. Также выделяются трансформерные модели, являющиеся наиболее актуальным направлением в компьютерном зрении. Несмотря на их высокую точность, они не рассматривались для данной системы из-за чрезмерной требовательности к ресурсам процессора. В условиях ограниченной производительности такие архитектуры работают значительно медленнее сверточных аналогов. Тем не менее, для полноты анализа трансформерные модели включены в сравнительную характеристику архитектур, приведенную в таблице 1.

На основании проведенного анализа установлено, что современные одностадийные архитектуры семейства YOLO обеспечивают наилучшее соотношение точности локализации мелких объектов, вычислительной сложности и простоты интеграции. В отличие от трансформерных моделей они демонстрируют стабильную работу в режиме реального времени на целевом оборудовании, что обусловило их выбор для реализации системы.

Таблица 1

Сравнительная таблица одностадийных нейросетевых архитектур

Архитектура	Представители	Точность для мелких объектов	Сложность интеграции в систему	Используется в режиме реального времени
Сверхлегкие	PicoDet, NanoDet	Средняя	Средняя	Да
Классические одностадийные	SSD, RetinaNet	Средняя	Низкая	Ограниченно
Современные универсальные	YOLO	Высокая	Низкая	Да
Трансформерные	RT-DETR	Высокая	Средняя	Ограниченно

Для обучения нейросетевых моделей отснято более 8 000 изображений видимого с коротковолновым (0,4–2,0 мкм) и длинноволнового (8–14 мкм) ИК диапазонов спектра для объективов с фокусными расстояниями 10 мм и 35 мм.

Обработка нейросетевой модели при проведении измерений разрабатываемых объективов с известными значениями фокусов проводилась с использованием специально разработанных мир, ширина штрихов которых соответствует увеличению, создаваемому системой «контролируемый объектив – объектив коллиматора» для того, чтобы изображение тест-объектов было хорошо различимо и читаемо, что требуется не только для получения достоверных результатов измерения, но и для стабильной работы нейросетевой модели. При этом данные миры могут использоваться для контроля объективов с другими фокусными расстояниями при условии сохранения качества изображения.

Для обучения нейронной сети проводилась следующая разметка тест-объектов (см. рис. 2): красный цвет – метки для измерения фокусного расстояния; голубой цвет – центр штриховой миры, используется для позиционирования и для измерения дисторсии; зеленый цвет – группы штрихов для определения предела разрешающей способности. При этом координаты областей интересов вычисляются посредством нахождения геометрического центра.




Рис. 2. Разметка штриховых мир (слева – для ОС с $f' = 10$ мм, справа – $f' = 35$ мм)

Каждая выделенная зеленым цветом группа штрихов имеет свое значение пространственного разрешения с шагом в 5 лин/мм и соответствующая фокусному расстоянию контролируемого объектива, которое оператор устанавливает в программе. Группы на мире справа из рис. 2 расположены в порядке воз-

растания, сверху вниз. На левой мире – группы штрихов расположены «крест-накрест»: самая маленькая по размеру группа имеет самое маленькое пространственное разрешение, далее идет группа, расположенная диаметрально противоположно к первой, следующая группа располагается левее от второй, и, наконец, последняя группа – самая большая и, соответственно, имеющая самое большое пространственное разрешение. Анализ и вычисление результатов происходят с учетом данных особенностей расположения групп на координатных осях матрицы изображения.

Для повышения робастности обучаемых нейросетевых моделей [13] применены методы аугментации [14]: геометрические трансформации (вращение, масштабирование), изменение яркости и контрастности для имитации температурного дрейфа.

Хотя обученные на этих данных нейросетевые модели успешно демонстрируют свойство запоминания образов штриховых мир, потенциал улучшения набора данных и создания алгоритмов предобработки изображений для улучшения точности и увеличения скорости отработки моделей не исчерпан. Глубокая модификация алгоритмов предобработки изображений требует отдельного исследования и не рассматривалась на данном этапе.

Оценка работы моделей

При обучении нейросетевых моделей были использованы различные модификации YOLO, начиная с 8-го поколения до 26-го, в различных конфигурациях: от наиболее компактных и быстрых (Nano) до массивных (Large). Обучение проводилось при варьировании гиперпараметров и условий среды. Наилучших результатов удалось достичь при выборе моделей средней размерности: YOLOv8m – для задачи обнаружения контрольных точек; YOLO26m – для распознавания штриховых групп мир.

Для оценки качества работы моделей использовался набор метрик, позволяющий оценить как правильность распознавания объектов, так и точность их «обводки» рамкой. Чтобы интерпретировать эти показатели, необходимо понимать четыре возможных сценария работы нейросети:

1. True Positive (TP) – истинно положительный результат: нейросеть правильно распознала объект там, где он есть;

2. False Positive (FP) – ложно положительный результат: «ложная тревога», нейросеть приняла за объект пустой участок или помеху;

3. False Negative (FN) – ложно отрицательный результат: пропуск цели, когда нейросеть не заметила существующий объект;

4. True Negative (TN) – истинно отрицательный результат: нейросеть верно определила, что на пустом участке ничего нет (в задачах обнаружения объектов этот параметр обычно не учитывается, так как количество «пустых» зон в кадре бесконечно велико).

На основе этих сценариев рассчитываются ключевые метрики, представленные в таблице 2:

– Точность (Precision) — это доля реальных объектов среди всех, которые нейросеть пометила как найденные. Высокая точность означает, что система практически не допускает «ложных тревог». Она рассчитывается по формуле:

$$P = \frac{TP}{TP + FP}; \tag{4}$$

– Полнота (Recall) — это доля найденных объектов от их общего реального количества. Высокая полнота говорит о том, что система находит почти все объекты и минимизирует пропуски. Рассчитывается по следующей формуле:

$$R = \frac{TP}{TP + FN}; \tag{5}$$

Для оценки качества локализации используется коэффициент IoU (Intersection over Union) – отношение площади пересечения

предсказанной и эталонной рамок к площади их объединения (0 = нет перекрытия, 1 = идеальное совпадение).

Центральным показателем эффективности является mAP (mean Average Precision) – средняя точность, которая объединяет в себе показатели точности и полноты. В зависимости от строгости требований к локализации (наложению рамок) выделяют две модификации:

– mAP@0,5: рассчитывается при условии, что объект считается найденным (TP), если площадь перекрытия предсказанной и эталонной рамок составляет не менее 50 %. Этот показатель характеризует общую способность модели распознавать объекты;

– mAP@0,5:0,95: представляет собой усредненное значение при различных порогах IoU (от 50 % до 95 % с шагом 5 %). Данный показатель является более жестким и критичным к качеству подгонки границ рамки, позволяя оценить устойчивость модели к геометрическим погрешностям и точности определения координат объекта.

Таким образом, модель YOLOv8m продемонстрировала высокое качество обнаружения контрольных точек (mAP@0,5 = 0,975), обеспечив высокие значения точности и полноты. Это означает, что в 97,5 % случаев система корректно находит, классифицирует и определяет местоположение контрольной точки на изображении, допуская лишь минимальный процент ошибок в виде пропусков или ложных срабатываний. При этом показатель mAP@0,5:0,95 оказался ниже, что свидетельствует о меньшей точности локализации объектов при строгих IoU-порогах. Следует отметить, что эффективность системы может быть повышена за счет разработки и интеграции алгоритмов дополнительного анализа и поиска центров контрольных точек, но исследование данной возможности остается за рамками данной статьи.

Таблица 2

Результаты обучения нейросетевых моделей

Задача	Модель	Precision (точность)	Recall (полнота)	mAP@0,5	mAP@0,5:0,95
Распознавание контрольных точек тест-объекта	YOLOv8m	0,956	0,955	0,975	0,598
Распознавание штрихов мир тест-объекта	YOLO26m	0,813	0,932	0,874	0,737

Модель YOLO26m при распознавании штрихов показала более низкую точность классификации ($mAP@0,5 = 0,874$), однако обеспечила лучшую устойчивость локализации объектов, что подтверждается более высоким значением $mAP@0,5:0,95$. Иными словами, модель верно обнаруживает и классифицирует группы штрихов в 87,4 % случаев.

Таким образом, использование комбинации данных моделей позволяет эффективно решать комплексную задачу контроля параметров оптических систем. Несмотря на различия в характере ошибок достигнутые показатели точности для каждой из подзадач формируют достаточную базу для корректной работы системы в целом, обеспечивая необходимый баланс между обнаружением ключевых точек и стабильностью распознавания штриховых групп.

Заключение

Разработанная автоматизированная система контроля параметров объективов, основанная на двух нейросетевых моделях (YOLOv8m – для измерения фокусного расстояния и дисторсии; YOLO26m – для измерения разрешения) позволяет проводить контроль параметров оптических систем различных диапазонов спектра (0,4–2,0 и 8–14 мкм).

Преимуществом данной системы является быстрота, точность, независимость от человеческого фактора, благодаря чему применение системы особенно актуально в условиях серийного выпуска оптических систем. Система продемонстрировала снижение трудозатрат при выполнении измерений: при проверке всех параметров объективов (фокусного расстояния, дисторсии и разрешающей способности) с помощью данной интеллектуальной системы требуется менее 15 минут, когда при измерении вручную у человека-оператора может потребоваться более 60 минут.

Первая нейросетевая модель на основе YOLOv8m находит контрольные точки практически идеально: в 97,5 % случаев они распознаются абсолютно верно. Это высокий показатель, который говорит о том, что ошибки при поиске точек почти исключены.

При распознавании штрихов тест-объекта вторая модель на основе YOLOv26m показы-

вает точность чуть ниже – 87,4 %. Это означает, что в 87,4 % случаев система правильно понимает, что перед ней именно группа штрихов и верно выделяет ее. При этом итоговая погрешность измерений не превышает значений, установленных методикой измерения.

Система была отлажена и протестирована на компьютере без дискретного графического ускорителя. При выполнении нейросетевых вычислений использовался центральный процессор. Несмотря на это система обеспечивает проведение быстрых измерений с требуемой точностью, что свидетельствует о правильности выбранных моделей и подходов.

СПИСОК ЛИТЕРАТУРЫ

1. Креопалова Г. В., Лазарева Н. Л., Пуряев Д. Т. Оптические измерения: учебник для вузов по специальности «Оптические приборы и установки» / Под ред. Пуряева Д. Т. – М.: Машиностроение, 1987.
2. Sun Y., Duthaler S., Nelson B. J. / *Microscopy Research and Technique*. 2004. V. 65. № 3. P. 139–149.
3. Гашиников М. В. Методы компьютерной обработки изображений / Под ред. Сойфера В. А. Изд. 2, испр. – М.: ФИЗМАТЛИТ, 2003. ISBN 5-9221-0270-2
4. Liu H.-I. et al. / *ACM Computing Surveys*. 2024. V. 57. № 6. P. 1–42. <https://doi.org/10.1145/3657282>.
5. Bouguettaya A., Kechida A., Taberkit A. M. / *International Journal of Informatics and Applied Mathematics*. 2019. V. 2. № 2. P. 28–44.
6. Redmon J., Divvala S., Girshick R., Farhadi A. / *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. 2016. P. 779–788. <https://doi.org/10.1109/CVPR.2016.91>.
7. Yaseen M. What is YOLOv8: An In-Depth Exploration of the Internal Features of the Next-Generation Object Detector / arXiv preprint. 2024. arXiv:2408.15857.
8. Liu W., Angelov D., Erhan D., Szegedy C., Reed S., Fu C.-Y., Berg A. C. / *Computer Vision – ECCV 2016. Lecture Notes in Computer Science*. V. 9905. – Cham: Springer, 2016. P. 21–37. https://doi.org/10.1007/978-3-319-46448-0_2.
9. Mittal P. / *Artificial Intelligence Review*. 2024. V. 57. Art. 242. <https://doi.org/10.1007/s10462-024-10877-1>.
10. Lin T.-Y., Goyal P., Girshick R., He K., Dollár P. / *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*. 2017. P. 2980–2988. <https://doi.org/10.1109/ICCV.2017.324>.
11. Андриянов Н. А., Дементьев В. Е., Таулинский А. Г. / *Радиотехника и электроника*. 2022. Т. 67. № 10. С. 1015–1034.
12. Zhao Y., Lv W., Xu S., Wei J., Wang G., Dang Q., Liu Y., Chen J. / *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. 2024. P. 16965–16974. arXiv:2304.08069.
13. ГОСТ Р 70462.1-2022. Информационные технологии. Интеллект искусственный. Оценка робаст-

ности нейронных сетей. Часть 1. Обзор. – М.: Стандарт-информ, 2022.

14. Емельянов С. О., Иванова А. А., Швец Е. А., Николаев Д. П. / Сенсорные системы. 2018. Т. 32. № 3. С. 236–245. <https://doi.org/10.1134/S0235009218030058>.

15. Padilla R., Netto S. L., da Silva E. A. B. / International Conference on Systems, Signals and Image Processing (IWSSIP). IEEE. 2020. P. 237–242.

<https://doi.org/10.1109/IWSSIP48289.2020.9145130>.

PACS: 07.05.Mh; 42.30.Va; 42.62.Eh

Neural network-based methods for optical system measurement

Sh. I. Zaripov^{1,2*}, A. V. Polesskiy¹, N. A. Semenchenko¹, and O. A. Medvedev^{1,3}

¹ RD&P Center ORION, JSC, Moscow, 111538 Russia

* E-mail: mail@tonyfierro.com

² MIREA – Russian Technological University, Moscow, 119454 Russia

³ Bauman Moscow State Technical University, Moscow, 105005 Russia

Received 21.05.2026; revised 1.06.2026; accepted 5.06.2026

The paper presents theoretical research and the development results of an intelligent system for the automated inspection of optical system parameters, including focal length, resolving power, and distortion, across various spectral ranges. The system is based on the YOLO convolutional neural network architecture and a specialized hardware-software complex. By employing a neural network-based approach, the software complex performs measurements of optical parameters without continuous operator intervention. This makes the system highly promising for the mass production of optical devices, as it reduces time of measurement, decreases labor costs, and eliminates the impact of the human factor.

Keywords: convolutional neural network, YOLO, computer vision system, object detection, optics, lenses, automated measurements, focal length, distortion, resolving power.

REFERENCES

1. Kreopalova G. V., Lazareva N. L., and Puryaev D. T. Optical Measurements: A Textbook for Universities / Ed. Puryaev D. T. Moscow: Mashinostroenie, 1987.
2. Sun Y., Duthaler S., and Nelson B. J., Microscopy Research and Technique **65** (3), 139–149 (2004).
3. Gashnikov M. V. Methods of Computer Image Processing / Ed. Soifer V. A., 2nd ed. Moscow: FIZMATLIT, 2003.
4. Liu H.-I., et al., ACM Computing Surveys **57** (6), 1–42 (2024). <https://doi.org/10.1145/3657282>.
5. Bouguettaya A., Kechida A., and Taberkit A. M., International Journal of Informatics and Applied Mathematics **2** (2), 28–44 (2019).
6. Redmon J., Divvala S., Girshick R., and Farhadi A. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 779–788 (2016). <https://doi.org/10.1109/CVPR.2016.91>.
7. Yaseen M. What is YOLOv8: An In-Depth Exploration of the Internal Features of the Next-Generation Object Detector, 2024. arXiv preprint. arXiv:2408.15857.
8. Liu W., et al. Computer Vision – ECCV 2016. Lecture Notes in Computer Science **9905**. Cham: Springer, 21–37 (2016). https://doi.org/10.1007/978-3-319-46448-0_2.
9. Mittal P., Artificial Intelligence Review **57**, Art. 242 (2024). <https://doi.org/10.1007/s10462-024-10877-1>.
10. Lin T.-Y., et al. Proceedings of the IEEE International Conference on Computer Vision (ICCV), 2980–2988 (2017). <https://doi.org/10.1109/ICCV.2017.324>.
11. Andriyanov N. A., Dementiev V. E., and Tashlinskiy A. G., Journal of Communications Technology and Electronics **67** (10), 1015–1034 (2022).
12. Zhao Y., et al., Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 16965–16974 (2024). arXiv:2304.08069.

13. GOST R 70462.1-2022. Information technology. Artificial intelligence. Assessment of neural network robustness. Part 1. Overview. Moscow: Standartinform, 2022.
14. Emelyanov S. O., Ivanova A. A., Shvets E. A., and Nikolaev D. P., *Sensory Systems* **32** (3), 236–245 (2018). <https://doi.org/10.1134/S0235009218030058>.
15. Padilla R., Netto S. L., and da Silva E. A. B., *International Conference on Systems, Signals and Image Processing (IWSSIP)*, 237–242 (2020). <https://doi.org/10.1109/IWSSIP48289.2020.9145130>.

Об авторах

Зарипов Шамиль Ильнурович, инженер-программист, АО «НПО «Орион» (111538, Россия, Москва, ул. Косинская, 9); МИРЭА – Российский технологический университет (119454, Россия, Москва, просп. Вернадского, 78). E-mail: mail@tonyferro.com

Полесский Алексей Викторович, д.т.н., директор по НИОКР, АО «НПО «Орион» (111538, Россия, Москва, ул. Косинская, 9). E-mail: poleskiyav@orion-ir.ru SPIN-код РИНЦ 3992-4520, Author ID 571156

Семенченко Наталья Александровна, начальник отдела, АО «НПО «Орион» (111538, Россия, Москва, ул. Косинская, 9). E-mail: nafara@mail.ru SPIN-код РИНЦ 8094-5126, Author ID 775858

Медведев Олег Александрович, АО «НПО «Орион» (111538, Россия, Москва, ул. Косинская, 9); Московский государственный технический университет имени Н. Э. Баумана (105005, Россия, Москва, 2-я Бауманская, д. 5, стр. 1). E-mail: om15032006@yandex.ru