

СРАВНИТЕЛЬНЫЙ АНАЛИЗ АРХИТЕКТУР НЕЙРОННЫХ СЕТЕЙ ДЛЯ ЗАДАЧ СЕГМЕНТАЦИИ МИКРОПЛАСТИКА В ВОДНЫХ ПРОБАХ



А. А. Симонова, студентка 1-го курса магистратуры
E-mail: simonova.ann.a@yandex.ru
ФГБОУ ВО «Калининградский государственный
технический университет»

М. А. Романов, старший преподаватель
E-mail: mikhail.romanov@klgtu.ru
ФГБОУ ВО «Калининградский государственный
технический университет»

В статье представлен аналитический обзор современных архитектур нейронных сетей, потенциально предназначенных для автоматизации процесса мониторинга загрязнения водных объектов частицами микропластика. Проведен комплексный анализ семи семейств архитектур нейронных сетей, включая сверточные модели и трансформеры, на основе специфических критериев: детекции сверхмалых объектов, поддержки инстанс-сегментации для количественного учета частиц и возможности эффективного функционирования на центральных процессорах стандартных персональных компьютеров. В статье подробно рассматриваются инновационные решения 2025-2026 гг., такие как RF-DETR-Seg и YOLO26-seg. Обосновывается отказ от использования классических архитектур в пользу моделей со сквозным механизмом предсказания без использования NMS. На основе анализа опубликованных метрик (mAPmask, GFLOPs, параметры) выявлено, что наиболее сбалансированным решением для условий ограниченных вычислительных ресурсов является модель YOLO26s-seg. Результаты исследования могут быть использованы при проектировании автоматизированных систем экологического мониторинга и разработке программного обеспечения для анализа микроскопических изображений водных проб.

Ключевые слова: нейронные сети, сегментация, компьютерное зрение, RF-DETR, YOLO26, микропластик, экологический мониторинг.

ВВЕДЕНИЕ

В современную эпоху загрязнение биосферы синтетическими полимерами достигло критических масштабов. Особую угрозу представляют микропластик – частицы размером менее 5 мм, которые вследствие своей персистентности и малых габаритов интегрируются в трофические цепи как морских, так и пресноводных экосистем [1]. Глобальный характер данной проблемы подтверждается обнаружением фрагментов полимеров в удаленных точках Мирового океана, от глубоководных желобов до арктических льдов [2].

Несмотря на растущую актуальность мониторинга, существующие протоколы количественного и качественного анализа проб воды остаются крайне трудозатратными. Традиционный подход, базирующийся на ручной оптической микроскопии и визуальной идентификации, сопряжен с высоким риском субъективной ошибки (так называемым человеческим фактором) и требует значительных временных ресурсов высококвалифицированных экспертов [3]. В условиях необходимости обработки массивов данных в режиме реального времени или реализации масштабных программ мониторинга такие методы демонстрируют низкую масштабируемость.

Автоматизация процессов детекции и сегментации микрочастиц с применением алгоритмов компьютерного зрения и глубокого обучения рассматривается в современной литературе как наиболее перспективный вектор развития экологического мониторинга [4]. Интеграция нейросетевых архитектур позволяет не только повысить точность дифференциации морфологических типов пластика, но и обеспечить объективность получаемых статистических данных, что является критически важным для формирования научно обоснованных стратегий по защите водных ресурсов [5].

ОБЪЕКТ ИССЛЕДОВАНИЯ

Объектом исследования в данной работе являются архитектуры сверточных нейронных сетей и трансформеров, ориентированные на выполнение задачи сегментации экземпляров. Особое внимание уделяется моделям, способным эффективно обрабатывать изображения мелких, частично прозрачных и перекрывающихся волокон пластика.

ЦЕЛЬ И ЗАДАЧИ ИССЛЕДОВАНИЯ

Целью данного исследования является проведение сравнительного анализа современных легковесных архитектур нейронных сетей для сегментации микрочастиц пластика на фотоизображениях водных проб и обоснование выбора оптимальной модели для развертывания в системах экологического мониторинга с ограниченными вычислительными ресурсами.

Для достижения поставленной цели необходимо решить следующие задачи:

1. Определить критерии, необходимые для эффективного функционирования алгоритмов в задачах обнаружения микропластика.
2. Провести предварительный скрининг существующих нейросетевых решений и отобрать наиболее релевантные семейства моделей.
3. Выполнить сравнительный анализ отобранных архитектур по заданным критериям.
4. Сформулировать рекомендации по выбору архитектуры, обеспечивающей наиболее сбалансированное соотношение точности сегментации и скорости работы.

МЕТОДЫ ИССЛЕДОВАНИЯ

Для объективной оценки и последующего выбора оптимальной нейросетевой модели необходимы критерии, учитывающие специфические морфологические и технические условия анализа микропластика в водных пробах.

Микроволокна и тонкие фрагменты полимеров представляют собой наиболее сложные объекты для детекции вследствие их малого геометрического сечения. Стандартные сверточные сети в процессе понижения размерности склонны к потере информации о тонких линейных структурах, классифицируя их как фоновый шум [6]. В связи с этим выбранная архитектура должна обеспечивать сохранение высокой детализации на всех этапах извлечения признаков, предотвращая деградацию границ сверхмалых объектов.

В реальных пробах частицы микропластика часто располагаются в непосредственной близости друг от друга или частично перекрываются (эффект окклюзии). Следовательно, необходима поддержка инстанс-сегментации, которая позволяет идентифицировать каждую частицу как отдельный объект, что является критически важным для корректного количественного учета – фундаментального требования экологического мониторинга [7].

Изображения водных проб характеризуются наличием специфических помех: неоднородного фона, флуоресцентного шума, пузырьков воздуха, органических остатков и градиентов освещения. Архитектура нейронной сети должна обладать высокой робастностью, позволяющей эффективно дифференцировать синтетические полимеры от естественных примесей и оптических искажений среды.

Сбор и разметка качественных датасетов микропластика являются трудоемкими процессами, что объективно ограничивает объем доступных обучающих данных. Архитектура должна демонстрировать стабильные результаты обучения в условиях дефицита данных, эффективно используя методы аугментации и трансферного обучения без риска переобучения.

Для дальнейшего исследования и создания автоматизированной системы требуется разработка решения, не требующего специализированного дорогостоящего оборудования. Приоритет отдается легковесным моделям, оптимизированным для инференса на центральных процессорах стандартных персональных компьютеров.

Таким образом, сформулированы пять критериев для анализа нейросетевых архитектур: разрешающая способность для идентификации микрообъектов, поддержка инстанс-сегментации, устойчивость к визуальным шумам и артефактам среды, эффективность обучения на малых выборках, вычислительная эффективность и аппаратная доступность.

РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ

На основании критериев был проведен предварительный скрининг существующих семейств нейросетевых архитектур, релевантных задаче обнаружения микропластика на изображениях водных проб. По результатам анализа выделено семь семейств, обладающих принципиальными архитектурными особенностями, соответствующими специфике решаемой задачи.

Семейство RT-DETR представляет собой класс сквозных детекторов на базе трансформеров компьютерного зрения, принципиальной особенностью которых является отказ от механизма подавления немаксимальных значений и использование гибридного кодера для эффективного взаимодействия признаков разных масштабов. Модификации данного семейства демонстрируют способность сохранять информацию о тонких линейных структурах на этапе понижения размерности, что отвечает первому критерию отбора. Кроме того, механизмы глобального внимания, свойственные архитектурам трансформеров, потенциально обеспечивают высокую устойчивость к сложному фону и частичным перекрытиям объектов [8].

Семейство YOLO является общепризнанным решением для задач детекции в реальном времени. Современные версии, начиная с восьмой итерации, предлагают встроенную поддержку сегментации отдельных экземпляров, что обеспечивает возможность разделения соседних и частично перекрывающихся частиц. Архитектуры данного семейства хорошо зарекомендовали себя в задачах дообучения с переносом знаний при малом объеме целевых данных [5].

Семейство EfficientDet основано на концепции масштабируемого детектора с оптимизированной двунаправленной пирамидой признаков. Данная архитектура обеспечивает эффективное слияние карт признаков разных уровней без значительного увеличения вычислительных затрат, что соответствует критерию вычислительной эффективности [9]. Улучшенная передача информации о разномасштабных структурах способствует более точному выделению мелких частиц. Однако, несмотря на высокую эффективность в задачах локализации, семейство EfficientDet не в полной мере отвечает поставленным критериям, поскольку нативная архитектура этих моделей не поддерживает инстанс-сегментацию «из коробки», что делает невозможным проведение корректного разделения перекрывающихся частиц микропластика.

Семейства Mask R-CNN и U-Net объединяет архитектуры, изначально ориентированные на прецизионное пиксельное разделение. Архитектура U-Net, разработанная для биомедицинских изображений, демонстрирует высокую эффективность при обучении на малых выборках. Модификации с добавлением механизмов внимания повышают устойчивость к сложному фону и артефактам, подавляя незначимые признаки [10]. Однако применение U-Net в рамках данного исследования ограничено тем, что сеть реализует семантическую сегментацию, объединяющую соприкасающиеся объекты в единые области, что делает невозможным проведение индивидуального количественного учета частиц. В свою очередь, архитектура Mask R-CNN, несмотря на поддержку инстанс-сегментации и высокую точность масок, характеризуется избыточной вычислительной сложностью и двухэтапным механизмом обработки, что приводит к существенному увеличению задержек при инференсе на центральных процессорах.

Семейства MobileNet и EfficientNet оптимизированы для работы на мобильных и встраиваемых устройствах. Данные архитектуры служат отличной основой для трансферного обучения и могут быть эффективно дообучены для специфической задачи поиска микропластика, обеспечивая высокое качество даже при ограниченном размере целевого датасета [11]. Но данные модели являются классификаторами, а не готовыми системами детекции. Для решения задач локализации микропластика они требуют интеграции с мета-архитектурами, что при работе с микрообъектами часто приводит к деградации пространственного разрешения. Кроме того, отсутствие встроенных механизмов инстанс-сегментации и склонность к потере текстурных нюансов сверхмалых волокон при агрессивном сжатии признаков делают их менее эффективными по сравнению с современными трансформерными решениями.

Анализ архитектурных особенностей выявил существенные различия в способности моделей адаптироваться к специфике малых объектов и ограничениям аппаратного обеспечения. Обобщенные результаты приведены в таблице 1, которая визуализирует соответствие каждого семейства вектору требований данного исследования.

Таблица 1 – Сводная оценка семейств нейросетевых архитектур

Семейство архитектур	Разрешающая способность	Инстанс-сегментация	Устойчивость к шумам	Обучение на малых данных	Эффективность на CPU
RT-DETR	+	+	+	+	+
YOLO	+	+	+	+	+
EfficientDet	+	-	+	+	+
Mask R-CNN	+	+	+	+	-
U-Net	+	-	+	+	+
MobileNet	-	-	-	+	+
EfficientNet	-	-	-	+	+

Таким образом, проведенная систематизация подтверждает, что универсальной архитектуры, изначально созданной под задачи микропластического мониторинга, на данный момент не существует. Однако сравнительная оценка по пяти ключевым критериям позволила сузить область поиска, исключив модели с избыточной вычислительной сложностью (Mask R-CNN) или отсутствием механизмов разделения соприкасающихся объектов (U-Net, EfficientDet). По результатам обзора наиболее перспективными признаны семейства RT-DETR и YOLO, которые продемонстрировали потенциальное соответствие всем технологическим и морфологическим требованиям.

Для проведения дальнейшего анализа на основе верифицированных литературных данных и технических спецификаций отобраны две репрезентативные модели: RF-DETR-Seg и YOLO26-seg. Сравнение будет проводиться в разрезе трех типоразмеров каждой модели: nano (N), small (S) и medium (M), что позволяет оценить масштабируемость архитектур и определить оптимальную конфигурацию для задачи детекции микропластика.

1. RF-DETR-Seg. Семейство RF-DETR, представленное в 2025 г., является дальнейшим развитием сквозных детекторов на базе трансформеров и основывается на архитектуре LW-DETR с принципиально новым подходом к адаптации модели под конкретные условия развертывания. Ключевой инновацией данного семейства выступает применение сквозного механизма Neural Architecture Search (NMS) с разделением весов, который позволяет одной предобученной базовой модели генерировать тысячи субконфигураций с различным компромиссом между точностью и задержкой инференса без необходимости повторного обучения. В отличие от предшествующих архитектур класса, RF-DETR использует в качестве основы предобученную модель DINOv2, что обеспечивает значительное повышение точности детекции на малых датасетах за счет переноса знаний. Кроме того, авторами предложен ряд архитектурных упрощений, включая отказ от пакетной нормализации в пользу слоевой нормализации, что облегчает обучение на пользовательских GPU с малым объемом памяти [12].

Расширение RF-DETR для задачи инстанс-сегментации реализовано путем добавления легковесной сегментационной «головы», формирующей пиксельные эмбединги на основе билинейной интерполяции выхода кодера. Данный подход минимизирует вычислительные затраты по сравнению с многоуровневыми методами, поскольку не требует включения многомасштабных признаков основы в сегментационную ветвь. Ключевые метрики производительности на эталонном датасете COCO, согласно опубликованным данным разработчика, систематизированы в таблице 2.

Таблица 2 – Технические характеристики конфигураций RF-DETR-Seg

Модель	mAPmask 50-95, %	Параметры, млн	GFLOPs
RF-DETR-Seg N	40.3	33.6	50.0
RF-DETR-Seg S	43.1	33.7	70.6
RF-DETR-Seg M	45.3	35.7	102.0

Анализ данных демонстрирует высокую исходную точность сегментации даже для младшей версии RF-DETR-Seg Nano (mAPmask 40.3 %). Переход к версии Small обеспечивает прирост точности на 2.8 процентных пункта (до 43.1 %) при увеличении вычислительной сложности с 50.0 до 70.6 GFLOPs, что обусловлено повышением разрешения входного изображения с 312 до 384 пикселей. Версия Medium достигает наивысшей в семействе точности mAPmask 45.3%, однако ее вычислительная сложность вдвое превышает показатели Nano-версии (103.0 против 50.0 GFLOPs). Все три конфигурации демонстрируют близкое количество параметров (от 33.6 до 35.7 млн), что объясняется применением единого механизма NMS с разделением весов.

Существенным ограничением для задачи настоящего исследования является отсутствие в открытых источниках опубликованных данных о производительности RF-DETR-Seg на центральных процессорах, поскольку разработчиком представлены метрики задержки исключительно для графического процессора NVIDIA T4 с использованием TensorRT. Тем не менее архитектурные особенности модели, а именно сквозной подход без применения NMS и упрощенная сегментационная «голова», позволяют предполагать конкурентоспособную производительность на центральных процессорах.

2. YOLO26-seg. YOLO26, выпущенное в сентябре 2025 г., представляет собой новейшую итерацию в линейке YOLO, целенаправленно спроектированную для эффективного развертывания на периферийных и маломощных устройствах. В отличие от предыдущих версий (YOLOv8-YOLOv13), которые в значительной степени полагались на компоненты, усложняющие экспорт и инференс, YOLO26 реализует принципиально упрощенный конвейер обработки [13].

Ключевой архитектурной инновацией данной версии является отказ от модуля Distribution Focal Loss, что упростило задачу регрессии рамок и устранило проблемы совместимости при экспорте моделей в различные форматы. Вторым принципиальным нововведением стал переход к сквозному предсказанию без использования механизма подавления немаксимальных значений, что позволило снизить задержки инференса и устранить зависимость от ручной настройки пороговых значений. Кроме того, внедрение механизмов Progressive Loss Balancing и Small-Target-Aware Label Assignment обеспечило повышенную точность при детекции мелких и частично перекрытых объектов без чрезмерного усложнения архитектуры. Также заявлено до 43 % ускорения инференса на центральных процессорах по сравнению с предыдущими версиями.

В таблице 3 приведено сопоставление моделей YOLO26 различных масштабов для задачи инстанс-сегментации на эталонном датасете COCO при разрешении 640 px.

Таблица 3 – Технические характеристики конфигураций YOLO26-seg

Модель	mAPmask 50-95 (e2e), %	Скорость CPU, мс	Параметры, млн	GFLOPs
YOLO26n-seg	33.9	53.3 ± 0.5	2.7	9.1
YOLO26s-seg	40.0	118.4 ± 0.9	10.4	34.2
YOLO26m-seg	44.1	328.2 ± 2.4	23.6	121.5

По данным, представленным в таблице 3, наблюдается предсказуемое масштабирование производительности внутри семейства. Версия YOLO26n-seg характеризуется минимальной вычислительной сложностью (9.1 GFLOPs) и наименьшим временем инференса на центральном процессоре (53.3 мс), что делает ее перспективной для сценариев, требующих высокой скорости обработки на маломощных устройствах. Версия YOLO26m-seg, напротив, достигает максимальной точности сегментации (mAPmask 44.1 %), однако ее использование сопряжено со значительно более высокими затратами вычислительных ресурсов: количество FLOPs возрастает до 121.5 млрд, а время инференса на CPU увеличивается до 328.2 мс. Промежуточное положение занимает модель YOLO26s-seg, обеспечивающая сбалансированное соотношение между точностью (mAPmask 40.0 %) и временем инференса (118.4 мс при 34.2 GFLOPs).

Обобщая результаты анализа, можно заключить, что выбор между моделями RF-DETR-Seg и YOLO26-seg определяется вектором приоритетности между точностью и аппаратной доступностью. Несмотря на выдающиеся показатели RF-DETR-Seg M в области сегментации (mAPmask 45,3 %), отсутствие верифицированных данных о скорости ее работы на центральных процессорах и относительно высокая вычислительная сложность (102 GFLOPs) могут стать критическим препятствием для развертывания на стандартных ПК. В то же время модель YOLO26s-seg демонстрирует наиболее сбалансированные характеристики для задач экологического мониторинга: при показателе mAPmask 40,0 % она обеспечивает инференс на CPU в пределах 118,4 мс, что позволяет обрабатывать пробы в режиме, близком к реальному времени. Внедрение в YOLO26 алгоритма STAL нивелирует классический разрыв в качестве детекции мелких объектов между сверточными и трансформерными архитектурами, делая версию Small оптимальным базовым решением для автоматизированного учета микропластика в условиях ограниченных вычислительных ресурсов.

ЗАКЛЮЧЕНИЕ

В ходе проведенного исследования был выполнен аналитический обзор и систематизация современных нейросетевых архитектур, пригодных для решения задачи сегментации микропластика в водных пробах. На основе специфики объекта исследования были сформулированы пять ключевых критериев отбора, включая разрешающую способность, поддержку инстанс-сегментации и эффективность работы на центральных процессорах. Предварительный скрининг семи семейств моделей позволил исключить архитектуры, не соответствующие фундаментальным требованиям мониторинга: семантические сегментаторы (U-Net) – из-за невозможности количественного учета частиц; тяжеловесные модели (Mask R-CNN) – вследствие низкой скорости инференса; классические детекторы (EfficientDet) – ввиду отсутствия нативной поддержки сегментации экземпляров.

Наиболее перспективными для практического внедрения признаны семейства RF-DETR-Seg и YOLO26-seg. Проведенный сопоставительный анализ их технических спецификаций и метрик показал, что для систем мониторинга, базирующихся на стандартном лабораторном оборудовании без специализированных графических ускорителей, приоритетной является модель YOLO26s-seg. Она обеспечивает необходимую глубину анализа морфологии частиц при сохранении высокой пропускной способности системы. Дальнейшие этапы исследования предполагают экспериментальную верификацию выбранной модели на специфических датасетах микропластика.

СПИСОК ЛИТЕРАТУРЫ

1. Occurrence, Bioaccumulation, and Risk Assessment of Microplastics in the Aquatic Environment: A Review / X. Li, L. Bao, Y. Wei, W. Zhao [et al.]. – DOI 10.3390/w15091768 // Water. – 2023. – Vol. 15, № 9. – Art. №1768. – URL: <https://www.mdpi.com/2073-4441/15/9/1768> (дата обращения: 18.04.2026).
2. Microplastics in Aquatic Ecosystems: A Global Review of Distribution, Ecotoxicological Impacts, and Human Health Risks / A. R. Sunny, S. A. Sazzad, M. A. Islam, M. H. Mithun [et

al.]. – DOI 10.3390/w17121741 // Water. – 2025. – Vol. 17, № 12. – Art. № 1741. – URL: <https://www.mdpi.com/2073-4441/17/12/1741> (дата обращения: 18.04.2026).

3. Quantitative Assessment of Visual Microscopy as a Tool for Microplastic Research: Recommendations for Improving Methods and Reporting / S. Kotar, R. McNeish, C. Murphy-Hagan, V. Renick [et al.]. – DOI 10.1016/j.chemosphere.2022.136449 // Chemosphere. – 2022. – Vol. 308, Pt. 3. – Art. № 136449. – URL: <https://pmc.ncbi.nlm.nih.gov/articles/PMC11197986/> (дата обращения: 18.04.2026).

4. Microplastics in Aquatic Environments: Bridging Occurrence and Mitigation through Machine Learning Detection and Bioremediation Strategies / A. Mojiri, J.L. Zhou, B. KarimiDermani, M. Vakili [et al.]. – DOI 10.1016/j.enceco.2025.100158 // Environmental Chemistry and Ecotoxicology. – 2025. – Vol. 4. – Art. № 100158. – URL: <https://www.sciencedirect.com/science/article/pii/S0964830525001982> (дата обращения: 18.04.2026).

5. Advances in Machine Learning for the Detection and Characterization of Microplastics in the Environment / M. M. Khanam, M. K. Uddin, J. U. Kazi. – DOI 10.3389/fenvs.2025.1573579 // Frontiers in Environmental Science. – 2025. – Vol. 13. – Art. № 1573579. – URL: <https://www.frontiersin.org/journals/environmental-science/articles/10.3389/fenvs.2025.1573579/full> (дата обращения: 18.04.2026).

6. Rethinking the Inception Architecture for Computer Vision / C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens [et al.]. – DOI: 10.1109/CVPR.2016.308 // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). – 2016. – P. 2818–2826. – URL: <https://arxiv.org/pdf/1512.00567> (дата обращения: 20.04.2026).

7. Deep Learning Approach for Automatic Microplastics Counting and Classification / J. Lorenzo-Navarro, M. Castrillón-Santana, E. Sánchez-Nielsen, B. Zarco [et al.]. – DOI 10.1016/j.scitotenv.2020.142728 // Science of the Total Environment. – 2021. – Vol. 765. – Art. № 142728. – URL: <https://pubmed.ncbi.nlm.nih.gov/33127127/> (дата обращения: 20.04.2026).

8. AUHF-DETR: A Lightweight Transformer with Spatial Attention and Wavelet Convolution for Embedded UAV Small Object Detection / H. Guo, Q. Wu, Y. Wang. – DOI 10.3390/rs17111920 // Remote Sensing. – 2025. – Vol. 17, № 11. – Art. № 1920. – URL: <https://www.mdpi.com/2072-4292/17/11/1920> (дата обращения: 20.04.2026).

9. EfficientDet: Scalable and Efficient Object Detection / M. Tan, R. Pan, Q. V. Le – DOI: 10.1109/CVPR42600.2020.01079 // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. – 2020. – P. 10781–10790. – URL: <https://arxiv.org/pdf/1911.09070> (дата обращения: 20.04.2026).

10. Automatic pre-screening of outdoor airborne microplastics in micrographs using deep learning / S. M. Cabaneros, E. Chapman, M. Hansen [et al.]. – DOI 10.1016/j.envpol.2025.125993 // Environmental Pollution. – 2025. – Vol. 372. – Art. № 125993. – URL: <https://www.sciencedirect.com/science/article/pii/S0269749125003665> (дата обращения: 20.04.2026).

11. Automated micro-plastic detection and classification using deep convolution neural network pre-trained models and transfer learning / K. Devipriya, M. Tlija, C. K. Kumar [et al.]. – DOI 10.1063/5.0243976 // AIP Advances. – 2025. – Vol. 15, № 2. – Art. № 025207. – URL: <https://pubs.aip.org/aip/adv/article/15/2/025207/3333894/Automated-micro-plastic-detection-and> (дата обращения: 20.04.2026).

12. RF-DETR: Neural Architecture Search for Real-Time Detection Transformers / I. Robinson, P. Robicheaux, M. Popov, D. Ramanan, N. Peri // Proceedings of the International Conference on Learning Representations (ICLR). – 2026. – URL: <https://arxiv.org/abs/2511.09554> (дата обращения: 22.04.2026).

13. YOLO26: Key Architectural Enhancements and Performance Benchmarking for Real-Time Object Detection / R. Sapkota, R. H. Cheppally, A. Sharda, M. Karkee. – Текст: электронный // arXiv: [сайт]. – 2025. – 29 Sept. – URL: <https://arxiv.org/abs/2509.25164> (дата обращения: 22.04.2026).

COMPARATIVE ANALYSIS OF NEURAL NETWORK ARCHITECTURES FOR MICROPLASTIC SEGMENTATION IN WATER SAMPLES

A. A. Simonova, 1st year Master student
E-mail: simonova.ann.a@yandex.ru
Kaliningrad State Technical University

M. A. Romanov, Senior Lecturer
E-mail: mikhail.romanov@klgtu.ru
Kaliningrad State Technical University

The article presents an analytical review of modern neural network architectures potentially designed to automate the monitoring of aquatic environment pollution by microplastic particles. A comprehensive analysis has been conducted on seven families of neural network architectures, including convolutional models and transformers, based on specific criteria: detection of ultra-small objects, support for instance segmentation for quantitative particle accounting, and the feasibility of efficient operation on central processing units of standard personal computers. The paper examines in detail innovative solutions from 2025–2026, such as RF-DETR-Seg and YOLO26-seg. The rationale for rejecting classical architectures in favor of end-to-end models that eliminate the need for Non-Maximum Suppression is presented. Based on the analysis of published metrics (mAPmask, GFLOPs, parameters), it has been found that the YOLO26s-seg model represents the most balanced solution for environments with limited computational resources. The research findings can be utilized in designing automated environmental monitoring systems and developing software for analyzing microscopic images of water samples.

Keywords: *neural networks, instance segmentation, computer vision, microplastics, environmental monitoring, YOLO26, RT-DETR.*