

Научная статья

ДЕТЕКТИРОВАНИЕ ТВЁРДЫХ БЫТОВЫХ ОТХОДОВ С ПОМОЩЬЮ БПЛА В ПРЕДЕЛАХ ГОРОДСКОЙ АГЛОМЕРАЦИИ АЛМАТЫ

Людмила А. Городецкая¹ , Равиль И. Мухамедиев^{1,2}  д.инж.н., Надия Р. Юничева^{2*}  к.т.н.,
Елизавета С. Витулёва¹  PhD

¹ Satbayev University, Алматы, Казахстан; ludmila260601@gmail.com (ЛАГ), ravil.muhamedyev@gmail.com (РИМ), lizavita@list.ru (ECB)

² Институт информационных и вычислительных технологий КН МНВО РК, Алматы, Казахстан; naduni@mail.ru (НПИО)

Автор корреспонденции: Надия Р. Юничева, naduni@mail.ru

КЛЮЧЕВЫЕ СЛОВА

мониторинг
твёрдые отходы
данные с БПЛА
нейронные сети
YOLOv8

АБСТРАКТ

Ускоренный рост городских агломераций Казахстана вызывает острые экологические проблемы, связанные с загрязнением воздушной, водной и наземной среды городов и пригородов. Растет число стихийных свалок мусора и бытовых отходов. Увеличение образования твердых бытовых отходов (ТБО) представляет собой серьезную экологическую проблему, особенно в урбанизированных и промышленных регионах. Традиционные методы мониторинга отходов являются трудоемкими и ограничены по масштабам. В этом исследовании предлагается система для автоматического детектирования ТБО, основанная на использовании снимков, полученных с борта БПЛА и модели глубокого обучения YOLOv8. В результате тестирования системы была достигнута высокая точность обнаружения ТБО: Precision 84,8 %, Recall 81,5 % и mAP@0.5 (85,1 %), при IoU 0,5. Визуальный анализ подтвердил способность модели эффективно обнаруживать отходы в различных условиях с минимальными ошибками. Результаты исследования могут быть интегрированы в системы экологического мониторинга для оперативного выявления несанкционированных свалок и оптимизации мероприятий по их ликвидации.

По статье:

Получено: 11.02.2025
Пересмотрено: 29.04.2025
Принято: 15.05.2025
Опубликовано: 30.06.2025

Для цитирования:

Городецкая Л., Мухамедиев Р.,
Юничева Н., Витулёва Е.
Детектирование твёрдых
бытовых отходов с помощью
БПЛА в пределах городской
агломерации Алматы // *Гидрометеорология и экология*,
№2 (117), 2025, 49-60.

1. ВВЕДЕНИЕ

Одной из ключевых экологических проблем современности является увеличение объемов ТБО [1...3], особенно в условиях роста урбанизации и промышленного производства. ТБО включают в себя материалы, такие как пластик, металлы, бумага и органические отходы, которые требуют надлежащей утилизации или переработки. Неэффективное управление отходами может привести к незаконному сбросу, загрязнению почвы и воды, а также к потере биоразнообразия и ухудшению общественного здоровья, что подчеркивает необходимость в современных системах мониторинга [4...5].

Мегаполисы генерируют значительные объемы ТБО (до 373 кг/чел. в год), причем их состав включает высокую долю трудноразлагаемых материалов (пластик, стекло). Рост отходов на 14...25 % за 5 лет в Санкт-Петербурге, Стокгольме и Хельсинки подтверждает, что урбанизация усугубляет проблему, требуя комплексных решений по переработке и сокращению потребления [6].

В Алматинской агломерации эта проблема приобретает особую остроту: на полигоне захоронения ТБО в селе Айтей Карасайского района, функционирующем с 1990 года, уже накоплено свыше 12 миллионов тонн отходов. При этом ежегодно мусоросортировочный комплекс Green Recycle принимает около 550 тысяч тонн ТБО, из

которых лишь часть (пластик, макулатура, стекло, металлы) направляется на переработку, а неутильные фракции продолжают пополнять объемы захороненных отходов [7].

Традиционные методы обнаружения незаконных мест захоронения отходов часто включают ручные исследования, которые являются трудоемкими и ограниченными в охвате. Решение экологических задач, связанных с отходами, становится всё более сложной задачей. В этом контексте использование беспилотных летательных аппаратов (БПЛА) и технологий искусственного интеллекта (ИИ) предоставляет уникальные возможности для автоматизации процессов мониторинга и анализа отходов.

Применение алгоритмов глубокого обучения позволяет повысить точность и скорость обнаружения отходов на обширных территориях, включая труднодоступные и опасные для человека зоны [8...9].

Одной из наиболее успешных моделей глубокого обучения для задач детекции является семейство алгоритмов YOLO (You Only Look Once) [10...12]. Благодаря своей скорости, точности и возможности детекции объектов различных масштабов в реальном масштабе времени, YOLO находит широкое применение в экологических исследованиях и задачах мониторинга. Например, в работе Nan и др. [13] демонстрирует использование YOLO для детекции плавающих пластиковых отходов, где достигнута высокая точность в классификации трёх типов мусора: пластиковых пакетов (95 %), пенопласта (90 %) и пластиковых бутылок (87 %). Практическая реализация подобной системы экологического мониторинга предложена в работе Liao Y.-H и др [14]. Её авторы разработали систему мониторинга морского мусора в режиме реального времени с использованием БПЛА и технологий интернета вещей (IoT). Их подход позволяет анализировать данные и передавать информацию о мусоре на удалённые станции в виде тепловых карт. Предложенная система доказала свою эффективность в обнаружении мусора в прибрежных зонах, демонстрируя высокий потенциал для применения в различных экологических программах.

Другая практическая реализация предложена в работе Казаков С. И др. [15], в которой разработали систему учета мусора на основе БПЛА и модели YOLOv5. Их работа продемонстрировала потенциал использования веб-приложений для визуализации обнаруженных отходов на картах, что облегчает управление твердыми коммунальными отходами. Тем не менее, применение этих методов для обнаружения ТБО остается ограниченным.

Настоящее исследование посвящено разработке системы автоматического обнаружения ТБО с использованием изображений, полученных с помощью БПЛА, и модели YOLOv8 [16]. Методика исследования включает сбор данных, их предварительную обработку с аннотированием и аугментацией, а также обучение модели с использованием предварительно обученных весов и оптимизацию гиперпараметров.

2. МАТЕРИАЛЫ И МЕТОДЫ

2.1 Основная идея подхода

Разработанный метод распознавания ТБО включает четыре этапа:

Этап 1: Сбор данных в формате видеозаписей, полученных с борта БПЛА, выполненных на территориях, содержащих свалки ТБО, в пределах Алматинской городской агломерации.

Этап 2: Преобразование видеозаписей в изображения в формате .jpg, их разметка и аугментация.

Этап 3: Обучение нейронной сети для задачи обнаружения объектов на основе полученных изображений.

Этап 4: Оптимизация гиперпараметров модели и анализ результатов.

На первом этапе осуществляется сбор данных для последующего обучения, валидации и тестирования модели. Разнообразие собранных данных играет ключевую роль в повышении способности модели к генерализации, так как оно позволяет учитывать различные сценарии и условия, при которых могут встречаться целевые объекты.

В рамках исследования предлагается использовать изображения санкционированных свалок строительного мусора на урбанизированных территориях города, так как их сбор является наиболее доступным, экономически целесообразным и удобным. Для увеличения объёма и разнообразия данных также необходимо включить изображения несанкционированных свалок, расположенных в природных зонах Алматинской области.

Данные, собранные на этом этапе, обладают высокой долговременной ценностью, поскольку могут использоваться повторно на протяжении нескольких лет. Ключевым фактором при сборе данных является время проведения съёмки: необходимо учитывать сезонные изменения, чтобы гарантировать надёжную работу модели при различных погодных условиях.

На втором этапе производится подготовка данных, полученных с дронов. Этот процесс включает ручную разметку изображений с использованием специализированных инструментов, таких как сервис Roboflow. Кроме того, применяются методы аугментации данных, что позволяет искусственно увеличить объём тренировочного набора и улучшить способность нейронной сети к обобщению.

Третий этап включает обучение модели YOLOv8 с использованием метода переноса обучения (transfer learning). Этот подход был выбран как оптимальный из-за ограниченного объёма доступных данных, полученных с БПЛА.

Использование предварительно обученных весов позволяет модели задействовать знания, полученные в процессе предварительного обучения на большом наборе данных COCO (Common Objects in Context) [17], тем самым ускоряя процесс адаптации к новой задаче и снижая вероятность переобучения.

Предобученные веса содержат обобщённые представления о структурных и текстурных признаках объектов, что значительно повышает точность работы модели на узкоспециализированной задаче распознавания ТБО.

На четвёртом этапе осуществляется подбор оптимальных гиперпараметров, таких как количество эпох и размер батча. Завершается процесс анализом производительности модели, включая визуализацию результатов детекции и оценку её эффективности с использованием стандартных метрик, таких как точность, полнота и mAP.

Такой подход обеспечивает высокую степень адаптации модели к задаче распознавания ТБО, одновременно снижая затраты на сбор данных и обучение модели.

2.2 Обработка данных, полученных с БПЛА

Для подготовки входных данных, необходимых для обучения нейронной сети, каждое видео, полученное БПЛА, было разрезано на кадры разрешением 1920×1080 пикселей. Кадры, не содержащие ТБО, были исключены из набора, чтобы сосредоточиться исключительно на целевых объектах.

В результате был сформирован набор данных, включающий 990 изображений.

Все данные были разделены на три подвыборки:

Обучающая выборка (70 %) — использовалась для оптимизации параметров модели;

Валидационная выборка (20 %) — предназначалась для контроля точности модели в процессе обучения;

Тестовая выборка (10 %) — применялась для итоговой оценки качества работы модели.

Ручная разметка данных для обучающей и валидационной выборок проводилась с использованием специализированного инструмента Roboflow [18].

На каждом изображении целевые объекты (свалки ТБО) выделялись ограничивающими рамками (bounding boxes), что позволило определить точные координаты объектов для последующего обучения модели.

Пример процесса маркировки данных представлен на рисунке 1.




Рисунок 1. Разметка данных с помощью инструмента Roboflow

Для повышения эффективности модели и её способности к обобщению был применён ряд техник аугментации данных. Аугментация позволяет искусственно увеличить объём тренировочного набора, изменяя исходные изображения различными способами. В рамках данного исследования использовались следующие параметры:

Outputs per training example: 3

Flip: Horizontal, Vertical

Crop: 0 % Minimum Zoom, 25 % Maximum Zoom

Saturation: Between -20 % and +20 %

Brightness: Between -20 % and +20 %

Применение данных методов позволило расширить исходный обучающий набор до 2019 изображений. Это значительно повысило способность модели обрабатывать ранее невидимые данные и улучшило её устойчивость к различным условиям съёмки. Таким образом, процесс аугментации данных стал ключевым этапом подготовки к обучению, обеспечив более высокую производительность нейронной сети.

2.3 Обучение модели и подбор гиперпараметров

Архитектура модели

Для решения задачи детекции ТБО была применена модель YOLOv8, представляющая одну из наиболее передовых архитектур для обнаружения объектов. YOLOv8 обладает высокой производительностью, что выражается в эффективной обработке изображений высокого разрешения при сбалансированном соотношении скорости и точности. Архитектура модели основана на свёрточных нейронных сетях (CNN) и включает механизмы для многомасштабного анализа, что позволяет учитывать, как крупные, так и мелкие объекты на изображениях.

Количество обучаемых параметров в данном фреймворке YOLO довольно большое (70...80 миллионов). Однако использование предварительно обученных весов значительно сократило время дообучения модели и способствовало повышению её

точности. Это особенно важно в условиях ограниченного объёма данных, так как предварительное обучение обеспечивает эффективный перенос знаний из крупных наборов данных на специализированную задачу.

Настройка гиперпараметров

Процесс обучения модели был оптимизирован с использованием следующих ключевых гиперпараметров:

Количество эпох: 60

Значение этого гиперпараметра было выбрано на основе экспериментального анализа. Графики потерь (loss) для обучающей и валидационной выборок показали стабилизацию к концу обучения, указывая на достижение моделью состояния, близкого к оптимальному. Метрики точности (precision) и полноты (recall) также продемонстрировали близость к насыщению. Увеличение числа эпох сверх 60, вероятно, не приведёт к существенным улучшениям, а может повысить риск переобучения.

Размер батча: 8 изображений

Данный размер батча был выбран с учётом ограничений по видеопамяти (VRAM) графического процессора. Меньший размер батча позволил стабильно обучать модель на оборудовании с ограниченными ресурсами, хотя и увеличил общее время обучения.

Функция потерь модели

Обучение YOLOv8 оптимизируется с помощью суммарной функции потерь, включающей три компонента:

box_loss — отвечает за точность предсказания координат ограничивающих рамок (bounding boxes);

cls_loss — определяет ошибки в предсказании классов объектов;

dfl_loss (Distribution Focal Loss) — улучшает прогнозирование границ объектов за счёт более точного распределения вероятностей

Результаты процесса обучения

На рисунке 2 представлены ключевые метрики обучения такие как точность (precision), полнота (recall) и средняя точность (mAP). Анализ графиков подтверждает эффективность выбранных гиперпараметров: метрики точности и полноты достигают достаточно высоких значений при увеличении числа эпох, демонстрируя сбалансированное качество детекции.

Графики mAP50 и mAP50-95 демонстрируют среднюю точность предсказаний при разных порогах IoU (Intersection over Union). Метрика mAP50 вычисляется при фиксированном IoU = 0,5, тогда как mAP50-95 усреднена по диапазону IoU от 0,5 до 0,95 с шагом 0,05, что даёт более строгую оценку качества детекции.

Метрики качества на валидационном наборе

Результаты оценки качества модели на валидационном наборе данных представлены ниже:

Precision (P): 0,848 (84,8 %) — доля обнаруженных объектов, которые действительно принадлежат к правильным классам.

Recall (R): 0,815 (81,5 %) — доля объектов из валидационного набора, которые были успешно обнаружены.

mAP@0.5: 0,851 (85,1 %) — средняя точность при пороговом значении IoU, равном 0,5.

mAP@0.5:0,95: 0,563 (56,3 %) — средняя точность по диапазону порогов IoU от 0,5 до 0,95.

Высокие значения precision и recall свидетельствуют о хорошей способности модели идентифицировать объекты и минимизировать ложные срабатывания. Метрика mAP@0.5:0,95, равная 56,3 %, отражает удовлетворительную обобщающую способность модели. Однако данное значение указывает на возможность дальнейшего улучшения качества детекции при более строгих порогах IoU.




Рисунок 2. Ключевые метрики обучения и валидации: точность (*precision*), полнота (*recall*), средняя точность (*mAP*)

Визуальная и количественная оценка результатов

Для подтверждения качества работы модели была проведена визуальная оценка её предсказаний. На рисунках 3 и 4 представлены сравнительные результаты разметки данных: исходная разметка, созданная вручную (рисунок 3, *val_batch_labels*), и результаты предсказаний модели (рисунок 4, *val_batch_pred*).



Рисунок 3. Исходная разметка, созданная вручную



Рисунок 4. Результаты предсказаний модели

Количественное сравнение предсказаний модели с вручную размеченными данными показало, что из 38 объектов, присутствующих на изображениях, модель корректно идентифицировала 34, пропустив 4 объекта и допустив 9 ложных срабатываний. Доля правильно обнаруженных объектов составила 89,5 %, что свидетельствует о высокой полноте модели.

Для оценки точности (precision) воспользуемся стандартной формулой (1):

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP}) \quad (1)$$

где: TP (true positives) — количество объектов, корректно обнаруженных моделью, FP (false positives) — число ложных срабатываний.

Подставляя полученные значения (TP=34, FP=9), вычисляем точность модели:

$$\text{Precision} = 34 / (34 + 9) = 0,79$$

Таким образом, точность модели в данном примере составляет 79 %, что демонстрирует её способность корректно идентифицировать целевые объекты при допустимом уровне ложных срабатываний.

Сравнение этих изображений демонстрирует, что модель уверенно детектирует объекты, корректно идентифицируя их границы. Совпадение большинства предсказанных рамок с размеченными вручную свидетельствует о высоком качестве работы модели не только в количественных метриках, но и с точки зрения визуального анализа. Это подтверждает, что модель способна справляться с реальными данными, содержащими разнообразные сцены и объекты различного масштаба. Такие результаты доказывают, что выбранная архитектура модели и параметры обучения обеспечивают высокую точность и надёжность детекции.

3. РЕЗУЛЬТАТЫ И ИХ ОБСУЖДЕНИЕ

Анализ ложных срабатываний модели и их причины.

Несмотря на высокие количественные показатели эффективности модели, визуальная оценка выявила ряд случаев ошибочной детекции. Анализ ложных срабатываний позволяет выявить уязвимости алгоритма и определить направления для дальнейшего улучшения системы.

На изображении 5 зафиксировано ложное срабатывание модели: область крыши здания была ошибочно классифицирована как скопление отходов с уровнем уверенности 0,75. Данная ошибка обусловлена схожестью визуальных признаков объекта фона и целевого класса, такими как беспорядочная текстура, наличие контрастных элементов и цветовые особенности покрытия крыши, напоминающие распределённые мусорные кучи.



Рисунок 5. Ложное срабатывание модели: детекция фрагмента крыши как скопления ТБО

Дополнительно выявлены случаи некорректной работы модели на изображениях, представленных на рисунках 6...7. На первом из них модель ошибочно детектировала участки снега вблизи деревьев как объекты класса «dump». Вероятно, причиной стало сходство текстуры и цвета между фрагментами природных объектов и реальными мусорными скоплениями, представленными в обучающем наборе данных.

На следующем рисунке аналогичная ошибка возникла на участке снега, частично загрязнённого почвой. Модель зафиксировала область, содержащую пятна грязи и следы от обуви, как мусор. Это указывает на недостаточную дифференциацию модели между мусором и естественными загрязнёнными участками почвы или снегового покрова.

Основной причиной этих ошибок является недостаточная репрезентативность обучающей выборки. Поскольку сбор данных проводился преимущественно в бесснежный период, модель не имела достаточного количества примеров для корректного различения снега, грязи и истинных скоплений отходов.

Эти примеры подтверждают необходимость увеличения разнообразия тренировочного датасета за счёт включения изображений с похожими на мусор элементами природной среды (грязь, снег, камни, обнажённая почва). Это позволит

улучшить способность модели различать мусорные скопления и естественные объекты, минимизируя количество ложных срабатываний.



Рисунок 6. Ошибочная классификация скопления снега как мусора



Рисунок 7. Ложноположительная детекция загрязнённого снежного покрова

4. ЗАКЛЮЧЕНИЕ

В рамках данного исследования была разработана и протестирована система распознавания ТБО на основе архитектуры YOLOv8, предназначенная для работы с изображениями, полученными с БПЛА. Разработанный метод включает последовательные этапы сбора данных, их подготовки, обучения модели и оптимизации гиперпараметров.

Анализ количественных метрик, таких как precision (84,8 %), recall (81,5 %), и mAP@0.5 (85,1 %), подтверждает достаточную для практики эффективность предложенного метода детекции ТБО. Дополнительно, визуальная оценка предсказаний модели демонстрирует её способность успешно идентифицировать целевые объекты с минимальным количеством ошибок. Это доказывает, что модель обладает высокой обобщающей способностью и устойчивостью к различным условиям съёмки.

Однако, несмотря на достигнутые результаты, остаются области для дальнейшего совершенствования. Например, метрика mAP@0.5:0,95 (56,3 %) указывает на возможность повышения точности модели при более строгих порогах IoU. В будущем

планируется увеличить объём данных за счёт добавления изображений различных типов отходов и условий съёмки, а также провести дополнительные эксперименты с альтернативными архитектурами моделей.

Разработанный подход обладает потенциалом для использования в реальных задачах экологического мониторинга, включая автоматизацию процессов идентификации и контроля свалок ТБО, что может способствовать повышению эффективности управления отходами и снижению их негативного воздействия на окружающую среду.

ВКЛАД АВТОРОВ

Концептуализация – РИМ; Управление данными – НРЮ; Формальный анализ – ЕСВ; Методология – РИМ; Программное обеспечение – ЛАГ; Отслеживание – НРЮ; Визуализация – ЛАГ; Написание исходного проекта – РИМ, ЛАГ; Написание и редактирование – НРЮ, ЕСВ.

ФИНАНСИРОВАНИЕ

Работа выполнена при финансовой поддержке Комитета науки Министерства науки и высшего образования Республики Казахстан (грант № BR21881908 «Комплекс экологического сопровождения городской агломерации (CUES)»).

СПИСОК ЛИТЕРАТУРЫ

1. Бекежанов Д. Проблемы и перспективы утилизации твердых бытовых отходов в Республике Казахстан // Вестник КазНУ. – 2017. – № 1(81). – С. 227- 233.
2. Булекова А.А., Габдуллина С. Проблема утилизации ТБО // Вестник ЗКУ. – 2021. – № 1(81). – С. 448-454
3. Калиева С.С., Төлепов Ә.Е., Хойч А., Шаяхметова Л.М. Экономическая оценка политики по сокращению ТБО в Республике Казахстан с использованием метода условной оценки (CV) // Вестник университета «Туран». – 2024. – № 3. – С. 23-34. <https://doi.org/10.46914/1562-2959-2024-1-3-23-34>.
4. Hoornweg D., Bhada-Tata P. What a waste: A global review of solid waste management. World Bank, 2012.
5. Скрипка Г.И., Сапрыгин В.В., Ивлиева О.В., Беспалова Л.А., Глинка В.В. Опыт использования беспилотных летательных аппаратов для выявления мест размещения отходов в водоохраных зонах // Известия высших учебных заведений. Северо-Кавказский регион. Естественные науки. – 2023. – № 3(219). – С. 131-139. doi: 10.18522/1026-2237-2023-3-131-139.
6. Холявко Т.И. Динамика количества твердых бытовых отходов и их морфологический состав на примере Санкт-Петербурга, Стокгольма, Токио и Хельсинки Приоритетные научные направления: от теории к практике. – 2014. – № 10. – С. 16-21.
7. Сатбаева А. Около 80 миллиардов iPhone. Сколько мусора накопилось в Алматы и Астане//Tengrinews.kz [Электронный ресурс] URL: https://tengrinews.kz/kazakhstan_news/okolo-80-milliardov-iphone-skolko-musora-nakopilos-almaty-493313/, дата обращения: 28.04.2025
8. Русаков К.Д. Использование глубокого обучения и беспилотных летательных аппаратов для обнаружения мусора на водной поверхности // Всероссийское совещание управления. – 2024. – С. 1157–1161.
9. Мониторинг мусорных полигонов с применением дронов // Aeromotus [Электронный ресурс]. – URL: <https://aeromotus.ru/monitoring-of-landfills-from-uavs/>, дата обращения: 11.01.2025
10. Redmon J., Divvala S., Girshick R., Farhadi A. You only look once: Unified, real-time object detection. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA, 27–30 June 2016, pp. 779–788.
11. Casas E., Ramos L., Romero C., Rivas-Echeverría F. A review of computer vision applications for asset inspection in the oil and gas Industry. Journal of Pipeline Science and Engineering, 2024, pp. 100246. <https://doi.org/10.1016/j.jpse.2024.100246>.
12. Gheorghe C., Duguleana M., Boboc R.G., Postelnicu C.C. Analyzing Real-Time Object Detection with YOLO Algorithm in Automotive Applications: A Review. CMES - Computer Modeling in Engineering and Sciences, 2024, Vol. 141, Issue 3, pp. 1939-1981. <https://doi.org/10.32604/cmescs.2024.054735>.
13. Han W., Luo W., Jin Y., Zho M. A Deep Learning Model for Automatic Plastic Waste Monitoring Using Unmanned Aerial Vehicle (UAV) Data. ESS Open Archive, 2021. <https://doi.org/10.1002/essoar.10507932.1>.
14. Liao Y.-H., Juang J.-G. Real-Time UAV Trash Monitoring System. Applied Science, 2022, Vol. 12, pp. 1838. <https://doi.org/10.3390/app12041838>
15. Казаков С., Азаренко Н. Интеллектуальная система обнаружения и учета мусора на территории муниципалитета // Сборник статей IV Всероссийской научно-практической конференции, приуроченной к Году науки и технологий в России «Вызовы цифровой экономики: тренды развития в условиях последствий пандемии COVID-19». – Брянск, 2021. – С. 10–12.
16. Explanation of all of YOLO series Part 11. [Электронный ресурс]. URL: https://zenn.dev/yuto_mo/articles/14a87a0db17dfa, дата обращения: 11.01.2025
17. Набор данных COCO. [Электронный ресурс]. URL: <https://docs.ultralytics.com/ru/datasets/detect/coco/>, дата обращения: 11.01.2025
18. Roboflow. [Электронный ресурс]. URL: <https://app.roboflow.com> (дата обращения: 11.02.2025).

REFERENCES

1. Bekezhanov D. (2017). Problemy i perspektivy utilizatsii tverdykh bytovykh otkhodov v Respublike Kazakhstan [Problems and prospects of solid domestic waste utilisation in the Republic of Kazakhstan]. Vestnik KazNU, Vol. 1(81), pp. 227- 233 [in Russian].
2. Bulekova A. A., Gabdullina S. (2021). Problema utilizatsii TBO [The problem of utilisation of MSW]. Vestnik ZKU, Vol. 1(81), pp. 448-454 [in Russian].

3. Kalieva S. S., Telepov O. E., Khoich A., Shayakhmetova L. M. (2024). Ekonomicheskaya otsenka politiki po sokrashcheniyu TBO v Respublike Kazakhstan s ispol'zovaniem metoda uslovnoi otsenki (CV) [Economic evaluation of the policy to reduce MSW in the Republic of Kazakhstan using the method of contingent valuation (CV)]. Vestnik universiteta «Turan», Vol. 3, pp. 23-34. <https://doi.org/10.46914/1562-2959-2024-1-3-23-34> [in Russian].
4. Hoornweg D., Bhada Tata P. (2012). What a waste: A global review of solid waste management. World Bank, 2012.
5. Skripka G. I., Saprygin V. V., Ivlieva O. V., Bespalova L. A., Glinka V. V. (2023). Opyt ispol'zovaniya bespilotnykh letatel'nykh apparatov dlya vyyavleniya mest razmeshcheniya otkhodov v vodookhrannyykh zonakh. Izvestiya vysshikh uchebnykh zavedenii. Severo-Kavkazskii region [Experience in the use of unmanned aerial vehicles to identify waste disposal sites in water protection zones]. Estestvennyye nauki, Vol. 3(219), pp. 131-139. <https://doi.org/10.18522/1026-2237-2023-3-131-139> [in Russian].
6. Kholyavko T.I. Dynamics of the amount of municipal solid waste and its morphological composition on the example of St. Petersburg, Stockholm, Tokyo and Helsinki. Priority scientific directions: from theory to practice [Dynamics of the amount of solid domestic waste and its morphological composition on the example of St. Petersburg, Stockholm, Tokyo and Helsinki Priority scientific directions: from theory to practice], Vol. 10, 2014, pp. 16-21 [in Russian].
7. Satbaeva A. About 80 billion iPhones. How much garbage has accumulated in Almaty and Astana [How much rubbish has accumulated in Almaty and Astana], Tengrinews.kz [Electronic resource] URL: https://tengrinews.kz/kazakhstan_news/okolo-80-milliardov-iphone-skolko-musora-nakopilos-almaty-493313/, date of access: 28.04.2025
8. Rusakov K. D. (2024). Ispol'zovanie glubokogo obucheniya i bespilotnykh letatel'nykh apparatov dlya obnaruzheniya musora na vodnoi poverkhnosti [Use of deep learning and unmanned aerial vehicles for the detection of debris on the water surface]. Vserossiiskoe soveshchanie upravleniya, pp. 1157–1161 [in Russian].
9. Aeromatus. (2025). Monitoring musornykh poligonov s primeneniem dronov. [Electronic resource] URL: <https://aeromatus.ru/monitoring-of-landfills-from-uavs/>, date of access: 11.01.2025 [in Russian].
10. Redmon J., Divvala S., Girshick R., Farhadi A. (2016). You only look once: Unified, real-time object detection. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA, 27–30 June 2016, pp. 779–788.
11. Casas E., Ramos L., Romero C., Rivas-Echeverria F. (2024). A review of computer vision applications for asset inspection in the oil and gas Industry. Journal of Pipeline Science and Engineering, pp.100246. <https://doi.org/10.1016/j.jpse.2024.100246>.
12. Gheorghe C., Duguleana M., Boboc R. G., Postelnicu C. C. (2024). Analyzing Real-Time Object Detection with YOLO Algorithm in Automotive Applications: A Review. CMES - Computer Modeling in Engineering and Sciences, Vol. 141(3), pp. 1939-1981. <https://doi.org/10.32604/cmcs.2024.054735>.
13. Han W., Luo W., Jin Y., Zho M. (2021). A Deep Learning Model for Automatic Plastic Waste Monitoring Using Unmanned Aerial Vehicle (UAV) Data. ESS Open Archive, <https://doi.org/10.1010.1002/essoar.10507932.1>.
14. Liao Y.-H., Juang J.-G. (2022) Real-Time UAV Trash Monitoring System. Applied. Science, Vol. 12, pp. 1838. <https://doi.org/10.3390/app12041838>
15. Kazakov S., Azarenko N. (2021). Intel'lektual'naya sistema obnaruzheniya i ucheta musora na territorii munitsipaliteta [Intelligent system of detection and accounting of rubbish on the territory of the municipality]. In Sbornik statei IV Vserossiiskoi nauchno-prakticheskoi konferentsii, priurochennoi k Godu nauki i tekhnologii v Rossii «Vyzovy tsifrovoi ekonomiki: trendy razvitiya v usloviyakh posledstviy pandemii COVID-19», Bryansk, pp. 10–12 [in Russian].
16. Explanation of all of YOLO series Part 11. [Electronic resource] URL: https://zenn.dev/yuto_mo/articles/14a87a0db17dfa, date of access: 28.04.2025
17. Ultralytics. (Nabor dannykh COCO [Electronic resource] URL: <https://docs.ultralytics.com/ru/datasets/detect/coco/>, date of access: 28.04.2025
18. Roboflow. Roboflow [Electronic resource] URL: <https://app.roboflow.com>, date of accessed: 11 February 2025.

АЛМАТЫ ҚАЛАЛЫҚ АГЛОМЕРАЦИЯСЫ ШЕГІНДЕ ҰШҚЫШСЫЗ ӘУЕ КӨЛІГІНІҢ КӨМЕГІМЕН ҚАТТЫ ТҰРМЫСТЫҚ ҚАЛДЫҚТАРДЫ АНЫҚТАУ

Людмила А. Городецкая¹, Равиль И. Мухамедиев^{1,2} инж. ғылым. докторы,
Надия Р. Юничева^{2*} т.ғ.к., Елизавета С. Витулёва¹ PhD

¹ Satbayev University; Алматы, Қазақстан; ludmila260601@gmail.com, ravil.muhamedyev@gmail.com, lizavita@list.ru

² ҚР ҒЖБМ ҒК Ақпараттық және есептеуіш технологиялар институты, Алматы, Қазақстан; naduni@mail.ru

Автор корреспонденция: Надия Р. Юничева, naduni@mail.ru

ТҮЙІН СӨЗДЕР

бақылау
қатты қалдықтар
UAV деректері
нейрондық желілер
YOLOv8

Мақала жайында:

Жіберілді: 11.02.2025
Қайта қаралды: 29.04.2025
Қабылданды: 15.05.2025

АБСТРАКТ

Қазақстанның қалалық агломерацияларының жедел өсуі қалалар мен қала маңындағы ауа, су және жер үсті ортасының ластануымен байланысты өткір экологиялық проблемаларды тудырады. Қоқыс пен тұрмыстық қалдықтардың стихиялық полигондарының саны артып келеді. Қатты тұрмыстық қалдықтардың (ҚТҚ) көбеюі, әсіресе урбанизацияланған және өнеркәсіптік аймақтарда күрделі экологиялық проблема болып табылады. Қалдықтарды бақылаудың дәстүрлі әдістері көп уақытты қажет етеді және ауқымы шектеулі. Бұл зерттеу ұшқышсыз әуе көлігінен (ҰӘК) алынған суреттерді және YOLOv8 терең оқыту моделін пайдалануға негізделген ҚТҚ-ны автоматты түрде анықтау жүйесін ұсынады. Жүйені тестілеу нәтижесінде қатты тұрмыстық қалдықтарды

Жарияланды: 30.06.2025

анықтаудың жоғары дәлдігіне қол жеткізілді: дәлдік 84,8 %, қалпына келтіру 81,5 % және mAP@0.5 (85,1 %), IOU 0,5 кезінде. Көрнекі талдау модельдің әртүрлі жағдайларда қалдықтарды минималды қателіктермен тиімді анықтау қабілетін растады. Зерттеу нәтижелері рұқсат етілмеген үйінділерді жедел анықтау және оларды жою шараларын оңтайландыру үшін экологиялық мониторинг жүйелеріне біріктірілуі мүмкін.

DETECTION OF SOLID DOMESTIC WASTE USING UAVS WITHIN THE URBAN AGGLOMERATION OF ALMATY

Liudmila Gorodetskaya¹, Ravil Mukhamediev^{1,2} Doctor of Science (Engineering), Nadiya Yunicheva^{2*} Candidate of Technical Science, Yelizaveta Vitulyova¹ PhD

¹ Satbayev University; Almaty, Kazakhstan; ludmila260601@gmail.com, ravil.muhamedyev@gmail.com, lizavita@list.ru

² Institute of Information and Computing Technologies CS MSHE RK, Almaty, Kazakhstan; naduni@mail.ru

Corresponding author: Nadiya Yunicheva, naduni@mail.ru

KEY WORDS

monitoring
solid waste
UAV data
neural networks
YOLOv8

About article:

Received: 11.02.2025
Revised: 29.04.2025
Accepted: 15.05.2025
Published: 30.06.2025

ABSTRACT

Accelerated growth of urban agglomerations in Kazakhstan causes acute environmental problems associated with pollution of air, water and land environment of cities and suburbs. The number of unauthorized garbage and household waste dumps is growing. Increased generation of municipal solid waste (MSW) is a serious environmental problem, especially in urbanized and industrial regions. Traditional waste monitoring methods are labor intensive and limited in scope. This study proposes a system for automatic MSW detection based on the use of UAV-derived imagery and YOLOv8 deep learning model. The system was tested and achieved high MSW detection accuracy of Precision 84,8 %, Recall 81,5 % and mAP@0.5 (85,1 %), with an IoU of 0,5. Visual analysis confirmed the model's ability to effectively detect waste under different conditions with minimal errors. The research findings can be integrated into environmental monitoring systems for rapid detection of unauthorized waste dumps and optimization of remediation measures.

Примечание издателя: заявления, мнения и данные во всех публикациях принадлежат только автору (авторам), а не журналу "Гидрометеорология и экология" и/или редактору (редакторам).