



УДК 004.896:629.735.33:631.3  
МРНТИ 27.35.15:28.23.19:29.19.15  
[https://doi.org/10.53364/24138614\\_2026\\_40\\_1\\_2](https://doi.org/10.53364/24138614_2026_40_1_2)

Л.А. Городецкая<sup>1</sup>, Р. И. Мухамедиев<sup>1</sup>, Н.Р. Юничева<sup>2,3\*</sup>, А. Сымагулов<sup>1</sup>

<sup>1</sup>КазНИТУ им. К.И. Сатпаева, Алматы, Казахстан

<sup>2</sup>Институт информационных и вычислительных технологий КН МНВО РК, Алматы, Казахстан

<sup>3</sup>Алматинский Университет энергетики и связи им. Г. Даукеева, Алматы, Казахстан

\*E-mail: [naduni@mail.ru](mailto:naduni@mail.ru)

## МЕТОДЫ КОМПЬЮТЕРНОГО ЗРЕНИЯ ДЛЯ АНАЛИЗА ПРОЗРАЧНОСТИ АТМОСФЕРЫ ПО СНИМКАМ С БЕСПИЛОТНЫХ ЛЕТАТЕЛЬНЫХ АППАРАТОВ

**Аннотация.** В работе рассматривается задача автоматизированной оценки прозрачности атмосферы в городских условиях на основе изображений, полученных с беспилотного летательного аппарата, с применением методов компьютерного зрения и глубокого обучения. Исследуется подход, ориентированный на анализ визуальных признаков задымлённости вблизи линии горизонта, где концентрация аэрозольных загрязнений, как правило, наиболее выражена. Для экспериментального исследования сформирован специализированный набор данных, включающий аэрофотоснимки городской атмосферы Алматы, полученные в январе-феврале 2024 года, с последующим пространственным разбиением изображений на девять секторов и ручной визуальной оценкой уровня прозрачности по дискретной шкале. Такой способ разметки позволил зафиксировать пространственную неоднородность загрязнения в пределах одного кадра и учесть различия между небесным фоном, линией горизонта и городской застройкой. На основе предобученной архитектуры MobileNetV2 реализованы два варианта модели — классификационная и регрессионная, что позволило сопоставить дискретный и непрерывный подходы к интерпретации визуальной информации. Сравнительный анализ показал, что классификатор обеспечивает более высокую точность строгого совпадения классов (83,9%), тогда как регрессионная модель, при округлении предсказаний до целых значений, демонстрирует более высокую точность в пределах допуска  $\pm 1$  класс (97,2%) и меньший уровень систематических ошибок. Полученные результаты подтверждают перспективность использования БПЛА в сочетании с методами компьютерного зрения для локального мониторинга прозрачности атмосферы и подчёркивают потенциал данного подхода как дополнения к традиционным наземным системам экологического контроля в городских условиях, что особенно актуально при ограниченной плотности стационарных станций.

**Ключевые слова:** мониторинг качества воздуха, данные с БПЛА, компьютерное зрение, прозрачность атмосферы, смог, глубокое обучение.

**Введение.** Загрязнение атмосферного воздуха остаётся одной из наиболее значимых экологических проблем современности. Согласно отчётам Всемирной организации

здравоохранения, более 90% населения планеты проживает в регионах, где концентрации загрязняющих веществ превышают установленные нормы [1]. Особенно остро эта проблема проявляется в крупных городах, где повышенные уровни мелкодисперсных частиц (PM2.5, PM10), оксидов азота и других загрязнителей оказывают существенное влияние на здоровье населения [2,3]. В Казахстане также наблюдаются регулярные эпизоды высокого уровня загрязнения воздуха в крупнейших городах — Алматы и Астане, где годовые концентрации PM2.5 превышают предельные значения ВОЗ более чем в 4–7 раз, а число дней с превышением суточных лимитов достигает 151–217 в год [4].

В последние годы активно развивается направление использования беспилотных летательных аппаратов (БПЛА) в задачах экологического мониторинга [5]. Малые БПЛА рассматриваются как перспективная платформа для локальных исследований качества воздуха, поскольку они позволяют проводить замеры вблизи источников загрязнения и в труднодоступных местах, где традиционные методы оказываются неэффективными. При этом они обладают рядом преимуществ, включая низкую стоимость, возможность автономных полётов и высокую пространственную детализацию, что делает их удобным инструментом для изучения локальных явлений, таких как смог [6].

В ряде исследований также предлагались гибридные подходы, в которых изображения, полученные с БПЛА, используются совместно с данными наземных сенсорных сетей для повышения точности и энергоэффективности прогнозов качества воздуха [7].

Наряду с этим в научной литературе всё больше внимания уделяется применению методов компьютерного зрения и смежных технологий для анализа визуальных признаков загрязнения атмосферы. Так, в ряде исследований предлагалось использовать камеры видеонаблюдения для оценки концентраций PM10 и построения временных профилей загрязнённости воздуха [8], а также датчики, установленные на транспортных средствах, для распознавания загрязнения воздуха и тумана [9].

Более современные работы показали, что визуальная оценка задымлённости по фотографиям и изображениям с камер может надёжно коррелировать с концентрациями загрязнителей и индексами качества воздуха. В частности, специализированные алгоритмы, такие как fastDBCP, обеспечивают высокую скорость и точность классификации загрязнённости в городских условиях [10].

Дальнейшее развитие в этой области связано с созданием более универсальных моделей глубокого обучения, которые позволяют одновременно оценивать концентрации PM2.5, PM10 и AQI [11], а также с использованием гибридных архитектур, сочетающих CNN и LSTM и учитывающих пространственно-временные характеристики изображений, что повышает точность прогнозов как днём, так и ночью [12].

В данной работе рассматривается метод оценки прозрачности атмосферы по изображениям, полученным с борта БПЛА, с использованием подходов классификации и регрессии. Предложенный подход предполагает разметку изображений по секторам, обучение моделей на основе архитектуры MobileNetV2 и сравнительный анализ их работы.

#### **Материалы и методы исследования.**

##### *Сбор данных и формирование набора данных.*

Для обучения и валидации моделей компьютерного зрения был сформирован специализированный набор данных (dataset), содержащий изображения городской атмосферы Алматы, полученные с борта беспилотного летательного аппарата [13]. Сформированный набор данных представляет собой структурированную коллекцию аэрофотоснимков с пространственно распределённой экспертной разметкой, ориентированной на анализ визуальных признаков задымлённости и прозрачности атмосферы в городских условиях.

### *Параметры съёмки.*

Съёмка проводилась в январе–феврале 2024 года с использованием малогабаритного БПЛА DJI Mavic Mini 2. Камера фиксировала изображения в формате JPEG при разрешении 4000×2250 пикселей ( $\approx 9$  МП). Полёты выполнялись на высоте от 100 до 500 метров над уровнем земли, при этом дрон выполнял полный оборот на 360°, что обеспечивало круговой охват территории. Камера ориентировалась в сторону горизонта (Camera Pitch  $\approx 0^\circ$ ), что позволяло фиксировать как небесный фон, так и зону скопления смога вблизи поверхности. Географически съёмки охватывали центральную часть города Алматы (примерные координаты 43°15' N, 76°54' E).

В результате было собрано 970 фотографий, данные о которых объединены в 13 таблиц метаданных. Для каждой фотографии автоматически сохранялись дата, время, название файла, высота полёта и направление съёмки (азимут).

### *Разметка изображений.*

С целью получения пространственно распределённой информации о задымлённости каждое изображение было разделено на девять равных секторов (рисунок 1). Для каждого сектора волонтерами вручную выставлялась оценка уровня смога по шкале от 1 до 10 (десять классов прозрачности атмосферы), где 1 соответствовал чистому воздуху, а 10 — максимальной задымлённости. Такая схема позволила более детально зафиксировать пространственные вариации загрязнения: верхние секторы (1–3) чаще содержали чистое небо, нижние (7–9) — городскую застройку, а средние (4–6) — область горизонта, где обычно концентрировался смог.

Разметка представлена в виде единого файла в формате CSV, содержащего идентификаторы изображений, метаданные, номера секторов и соответствующие им значения уровня задымлённости.




Рисунок 1 – Нумерация секторов на изображении, полученном с помощью БПЛА

### **Результаты и их обсуждение.**

Обучение модели и анализ результатов. Архитектура и гиперпараметры.

Для решения задачи автоматического выявления признаков смога по изображениям, полученным с БПЛА, были реализованы два подхода: классификация и регрессия. В обоих случаях использовалась архитектура MobileNetV2, предобученная на датасете ImageNet и дообученная на собранных данных. Важно отметить, что изначально задача формулировалась как классификация по 10 уровням задымлённости (от 1 до 10).

Использование регрессора позволило предсказывать непрерывные значения и тем самым учитывать промежуточные состояния между дискретными уровнями шкалы.

Подбор гиперпараметров показал, что оптимальными значениями являются:

- количество эпох обучения (EPOCHS) — 60,
- скорость обучения (LEARNING\_RATE) —  $5 \cdot 10^{-5}$ ,
- порог начала тонкой настройки предобученных слоёв (FINE\_TUNE\_AT) — 120.

Такая конфигурация обеспечила баланс между скоростью сходимости и устойчивостью обучения.

*Аугментация данных.*

С целью повышения обобщающей способности моделей применялась аугментация обучающих изображений. Использовались следующие преобразования: случайные повороты до  $15^\circ$ , горизонтальные и вертикальные сдвиги до 10% размера изображения, сдвиги по срезу (shear) до 10%, масштабирование (zoom) в пределах  $\pm 10\%$ , а также случайное горизонтальное отражение. Все изображения были нормированы в диапазон [1].

Аугментация позволила имитировать вариации условий съёмки (изменение угла наклона дрона, смещение горизонта, колебания освещённости) и снизить риск переобучения при работе с ограниченным по объёму набором данных.

*Динамика обучения.*

Графики обучения для обеих моделей показывают стабильную сходимость. Уже на первых эпохах наблюдается резкое снижение ошибки, после чего кривые стабилизируются без признаков переобучения.

Для классификатора валидационные кривые функции потерь и средней абсолютной ошибки (MAE) расположены близко к обучающим, что свидетельствует о корректности выбранных гиперпараметров (рисунок 2).

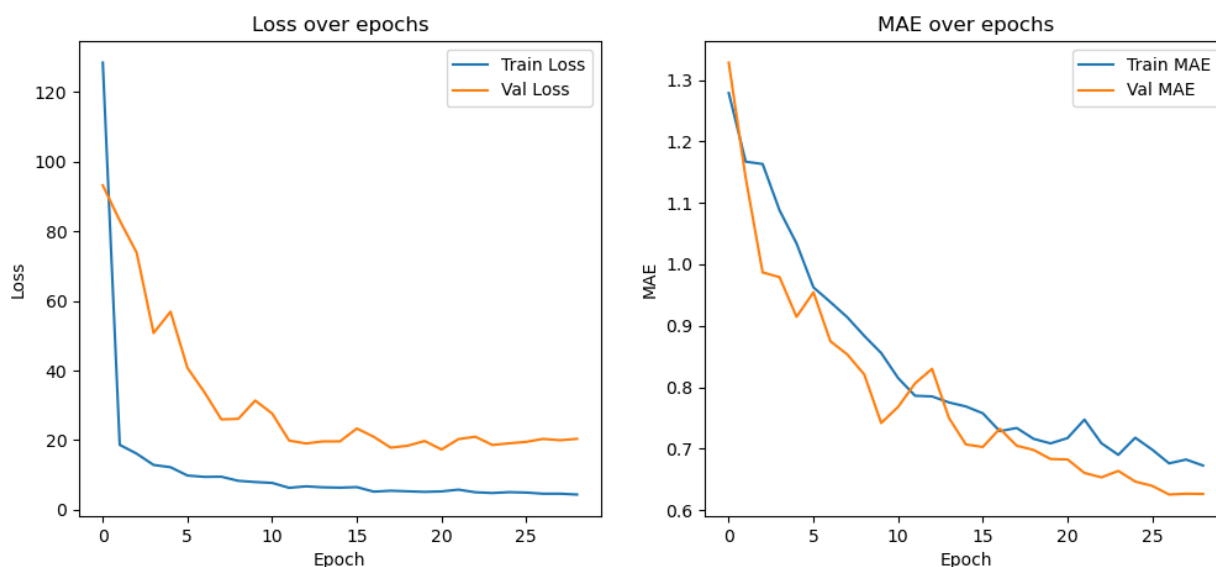


Рисунок 2 – Динамика функции потерь (Loss) и MAE при обучении классификатора

Для регрессора процесс обучения также характеризуется плавным снижением ошибки, при этом значения на валидации несколько выше, что ожидаемо, так как задача регрессии сложнее дискретной классификации и требует предсказания непрерывных значений (рисунок 3).

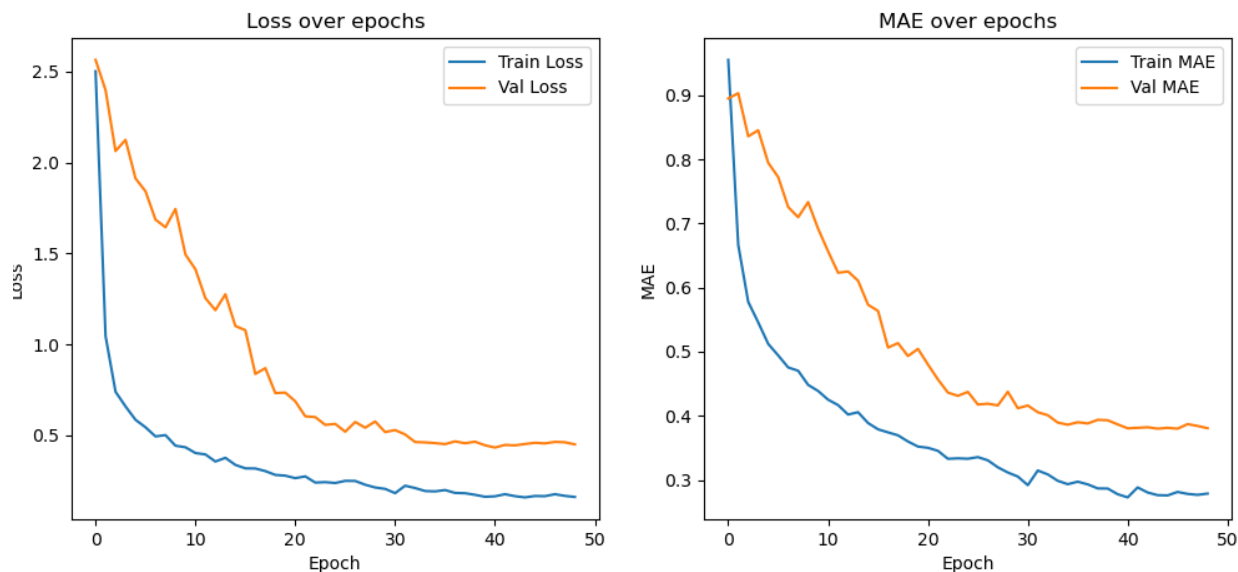


Рисунок 3 – Динамика функции потерь (Loss) и MAE при обучении регрессора

#### Сравнительный анализ классификатора и регрессора.

Для оценки качества работы моделей были использованы метрики точность строгого совпадения (exact accuracy), точность с отклонением не более чем на  $\pm 1$  уровень (accuracy within  $\pm 1$ ) и средняя абсолютная ошибка (MAE). В случае регрессора метрики точности рассчитывались после округления предсказанных значений до ближайшего целого числа. Таким образом, exact accuracy показывает долю точных совпадений с экспертной разметкой, а accuracy within  $\pm 1$  — долю предсказаний, которые не отличаются от экспертной оценки более чем на один класс.

Результаты классификатора:

- exact accuracy — 83.9%,
- accuracy within  $\pm 1$  — 94.8%.

Результаты регрессора:

- MAE (без округления) — 0.38,
- exact accuracy — 78.8%,
- accuracy within  $\pm 1$  — 97.2%.

Распределение ошибок по секторам оказалось схожим для обеих моделей: минимальные отклонения характерны для нижних секторов (7–9), умеренные ошибки наблюдаются в верхних секторах (1–3), наибольшие отклонения приходятся на средние сектора (4–6), соответствующие линии горизонта.

Однако у классификатора bias выражен сильнее: для сектора 5 ошибка составила – 0.78, тогда как у регрессора — лишь –0.39. При этом регрессор имеет тенденцию к небольшому завышению предсказаний в верхних секторах (+0.19...+0.28) (рисунок 4), в то время как классификатор в целом склонен к занижению (рисунок 5).




Рисунок 4 – средняя ошибка (предсказание – реальность) по секторам для регрессора




Рисунок 5 – средняя ошибка (предсказание – реальность) по секторам для классификатора

Визуальное сравнение предсказаний с ручной разметкой подтверждает выявленные закономерности (рисунок 6).

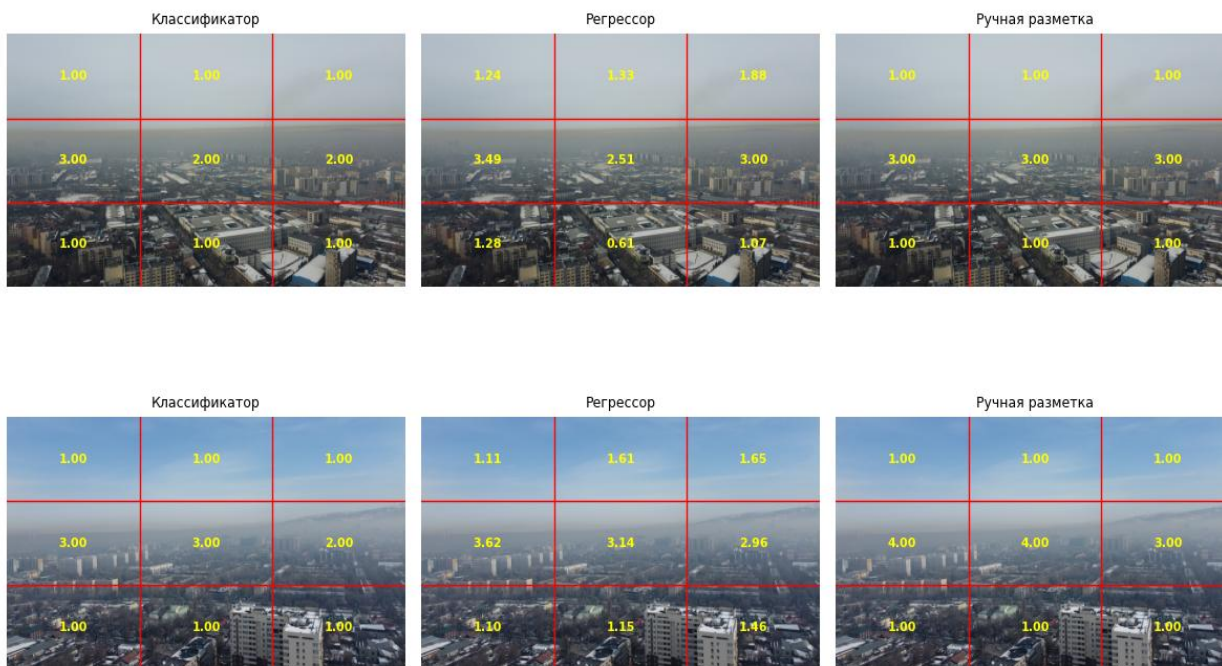


Рисунок 6 – пример сравнения работы моделей с ручной разметкой

Обе модели продемонстрировали сопоставимые результаты и выявили одинаковые проблемные зоны — сектора 4–6, соответствующие линии горизонта, где наиболее часто наблюдается смог. Классификатор обладает преимуществом по метрике строгой точности (83.9% против 78.8%), тогда как регрессор (с округлением до целого) показывает лучшие результаты с учётом расхождения не более чем на один класс (97.2% против 94.8%).

Таким образом, оба подхода могут использоваться для решения задачи анализа прозрачности атмосферы по изображениям с БПЛА. Выбор конкретного метода зависит от целей исследования: классификатор лучше подходит для строгого распределения по категориям, тогда как регрессор обеспечивает более устойчивые оценки с учётом возможной субъективности ручной разметки.

#### **Заключение.**

В данной работе предложен метод оценки прозрачности атмосферы по изображениям, полученным с беспилотного летательного аппарата, с использованием моделей компьютерного зрения. Сформированный набор данных из 970 изображений, размеченных по девяти секторам, позволил обучить и сравнить два подхода — классификацию и регрессию. Анализ показал, что обе модели обладают удовлетворительными обобщающими свойствами и демонстрируют сопоставимые результаты при решении задачи. Классификатор обеспечивает более высокую точность строгого совпадения классов, тогда как регрессор демонстрирует преимущество при учёте допуска  $\pm 1$  класс и меньший уровень систематических ошибок.

Вместе с тем исследование имеет ряд ограничений. Во-первых, прозрачность атмосферы оценивалась экспертами в секторах с различной толщиной воздушного пространства: верхние и горизонтальные сектора отражают фактически неограниченное расстояние, тогда как нижние (7–9) зависят от высоты полёта БПЛА. Во-вторых, объём размеченного набора данных невелик и не сбалансирован: случаи сильного загрязнения встречаются значительно реже по сравнению с чистым небом (1 класс) и слабыми загрязнениями (2-3 класс). В-третьих, оценки прозрачности атмосферы не были связаны с данными наземных станций мониторинга качества воздуха.

Будущие исследования будут направлены на расширение набора данных как по числу изображений, так и по пространственному делению на сектора, а также на интеграцию информации от наземных станций для повышения объективности разметки. Дополнительным направлением может стать использование мультиспектральных изображений и спектральных индексов, позволяющих более надёжно выявлять загрязнение воздуха.

Таким образом, полученные результаты подтверждают возможность применения БПЛА и методов компьютерного зрения в задачах локального мониторинга качества воздуха и указывают на потенциал дальнейшего развития данного направления для оперативного экологического контроля в городских условиях.

***Благодарности.** Работа выполнена при финансовой поддержке Комитета науки Министерства науки и высшего образования Республики Казахстан (грант BR28713375 «Многоцелевая роботизированная беспилотная летательная платформа дистанционного мониторинга (AeroScope)»).*

### Список литературы

1. Всемирная организация здравоохранения. (2021). Загрязнение воздуха. Всемирная организация здравоохранения. <https://www.who.int/health-topics/air-pollution>
2. Коэн, А. Дж., Брауэр, М., Бёрнетт, Р., и др. (2017). Оценки и 25-летние тенденции глобального бремени болезней, связанных с загрязнением воздуха: анализ данных Исследования глобального бремени болезней 2015 года. *The Lancet*, 389(10082), 1907–1918. [https://doi.org/10.1016/S0140-6736\(17\)30505-6](https://doi.org/10.1016/S0140-6736(17)30505-6)
3. Лелиевельд, Й., Клингмюллер, К., Позцер, А., и др. (2019). Пересмотр оценки бремени сердечно-сосудистых заболеваний от загрязнения воздуха в Европе с использованием новых функций коэффициентов риска. *European Heart Journal*, 40(20), 1590–1596. <https://doi.org/10.1093/eurheartj/ehz135>
4. Мухтаров, Р., Ибрагимова, О. П., Омарова, А., Турсынбаева, М., Турсын, К., & Муратулы, А. (2023). Эпизодическая оценка неблагоприятных эффектов траекторий воздушных масс на уровень PM<sub>2.5</sub> в Астане и Алматы, Казахстан. *Urban Climate*, 49, 101541. <https://doi.org/10.1016/j.uclim.2023.101541>
5. Альбрехт, В., Мухамедиев, Р. И., Попова, Ю., Мухамеджиева, Е., & Ботайбеков, А. (2025). Тематическое моделирование Top2Vec для анализа динамики публикационной активности, связанной с экологическим мониторингом с использованием беспилотных летательных аппаратов. *Publications*, 13(2), 15. <https://doi.org/10.3390/publications13020015>
6. Вилла, Т. Ф., Гонсалес, Ф., Мильевич, Б., и др. (2016). Обзор малых беспилотных летательных аппаратов для измерения качества воздуха: современные применения и перспективы. *Sensors*, 16(7), 1072. <https://doi.org/10.3390/s16071072>
7. Ян, Ю., Ху, Ч., Бянь, К., & Сун, Л. (2019). ImgSensingNet: система мониторинга качества воздуха с использованием UAV визуализации и наземных датчиков. *arXiv preprint arXiv:1905.11299*. <https://arxiv.org/abs/1905.11299>
8. Вонг, К. Дж., Матжафри, М. З., Абдулла, К., Лим, Х. С., & Лоу, К. Л. (2007). Мониторинг качества воздуха во времени с использованием камер наблюдения. В *Proceedings of the 2007 Geoscience and Remote Sensing Symposium* (стр. 2864–2868). Барселона, Испания. <https://doi.org/10.1109/IGARSS.2007.4423350>
9. Саллис, П., Даннхайм, К., Икинг, К., & Мэдер, М. (2014). Обнаружение загрязнения воздуха и тумана с помощью автомобильных датчиков. В *Proceedings of the 8th Asia Modelling Symposium* (стр. 181–186). Тайбэй, Тайвань. <https://doi.org/10.1109/AMS.2014.36>
10. Чу, Ю., Чен, Ф., Фу, Х., & Ю, Х. (2023). Обнаружение загрязнения воздуха в городских районах с использованием мониторинговых изображений. *Atmosphere*, 14(5), 772. <https://doi.org/10.3390/atmos14050772>

11. Коу, П.-Й., Хся, И.-В., Чанг, Л.-Ц., & Чанг, Ф.-Дж. (2022). Оценка качества воздуха в реальном времени на основе изображений с использованием нейронных сетей глубокого обучения. *Journal of Environmental Management*, 307, 114560. <https://doi.org/10.1016/j.jenvman.2022.114560>
12. Ван, Х., Ван, М., Лю, С., Мао, Ю., Чен, Ю., & Дай, С. (2023). Мониторинг качества воздуха на открытом воздухе на основе изображений с камер наблюдения. *Environmental Science and Ecotechnology*, 18, 100319. <https://doi.org/10.1016/j.ese.2023.100319>
13. Набор данных аэрофотоснимков городской атмосферы Алматы, полученных с использованием БПЛА (2024). Электронный ресурс. URL: <https://drive.google.com/drive/folders/1nEOJKky6Ghu3DDtQ3cVZHpt3lDhLYjak> (дата обращения: 04.02.2026).

### References

1. World Health Organization. (2021). *Air pollution*. World Health Organization. <https://www.who.int/health-topics/air-pollution>
2. Cohen, A. J., Brauer, M., Burnett, R., et al. (2017). Estimates and 25-year trends of the global burden of disease attributable to ambient air pollution: An analysis of data from the Global Burden of Diseases Study 2015. *The Lancet*, 389(10082), 1907–1918. [https://doi.org/10.1016/S0140-6736\(17\)30505-6](https://doi.org/10.1016/S0140-6736(17)30505-6)
3. Lelieveld, J., Klingmüller, K., Pozzer, A., et al. (2019). Cardiovascular disease burden from ambient air pollution in Europe reassessed using novel hazard ratio functions. *European Heart Journal*, 40(20), 1590–1596. <https://doi.org/10.1093/eurheartj/ehz135>
4. Mukhtarov, R., Ibragimova, O. P., Omarova, A., Tursumbayeva, M., Tursun, K., & Muratuly, A. (2023). An episode-based assessment for the adverse effects of air mass trajectories on PM<sub>2.5</sub> levels in Astana and Almaty, Kazakhstan. *Urban Climate*, 49, 101541. <https://doi.org/10.1016/j.uclim.2023.101541>
5. Albrekht, V., Mukhamediev, R. I., Popova, Y., Muhamedijeva, E., & Botaibekov, A. (2025). Top2Vec topic modeling to analyze the dynamics of publication activity related to environmental monitoring using unmanned aerial vehicles. *Publications*, 13(2), 15. <https://doi.org/10.3390/publications13020015>
6. Villa, T. F., Gonzalez, F., Miljevic, B., et al. (2016). An overview of small unmanned aerial vehicles for air quality measurements: Present applications and future prospectives. *Sensors*, 16(7), 1072. <https://doi.org/10.3390/s16071072>
7. Yang, Y., Hu, Z., Bian, K., & Song, L. (2019). ImgSensingNet: UAV vision guided aerial-ground air quality sensing system. *arXiv preprint arXiv:1905.11299*. <https://arxiv.org/abs/1905.11299>
8. Wong, C. J., Matjafri, M. Z., Abdullah, K., Lim, H. S., & Low, K. L. (2007). Temporal air quality monitoring using surveillance camera. In *Proceedings of the 2007 Geoscience and Remote Sensing Symposium* (pp. 2864–2868). Barcelona, Spain. <https://doi.org/10.1109/IGARSS.2007.4423350>
9. Sallis, P., Dannheim, C., Icking, C., & Maeder, M. (2014). Air pollution and fog detection through vehicular sensors. In *Proceedings of the 8th Asia Modelling Symposium* (pp. 181–186). Taipei, Taiwan. <https://doi.org/10.1109/AMS.2014.36>
10. Chu, Y., Chen, F., Fu, H., & Yu, H. (2023). Detection of air pollution in urban areas using monitoring images. *Atmosphere*, 14(5), 772. <https://doi.org/10.3390/atmos14050772>
11. Kow, P.-Y., Hsia, I.-W., Chang, L.-C., & Chang, F.-J. (2022). Real-time image-based air quality estimation by deep learning neural networks. *Journal of Environmental Management*, 307, 114560. <https://doi.org/10.1016/j.jenvman.2022.114560>
12. Wang, X., Wang, M., Liu, X., Mao, Y., Chen, Y., & Dai, S. (2023). Surveillance-image-based outdoor air quality monitoring. *Environmental Science and Ecotechnology*, 18, 100319. <https://doi.org/10.1016/j.ese.2023.100319>

13. A set of aerial photographs of the urban atmosphere of Almaty, obtained using UAVs (2024). Electronic resource. URL: <https://drive.google.com/drive/folders/1nEOJKky6Ghu3DDtQ3cVZHpt3lDhLYjak> (accessed on 04.02.2026).

### БЕЙНЕНІ БАСҚАРУСЫЗ ҰШУ АППАРАТТАРЫ ТҮСІРГЕН СУРЕТТЕР БОЙЫНША АТМОСФЕРАЛЫҚ МӨЛДІРЛІКТІ ТАЛДАУҒА АРНАЛҒАН КОМПЬЮТЕРЛІК КӨРУ ӘДІСТЕРІ

**Аңдатпа.** Бұл мақала ұшқышсыз ұшу аппаратынан алынған суреттер негізінде компьютерлік көру және терең оқыту әдістерін қолдана отырып, қалалық жағдайда атмосфераның мөлдірлігін автоматты бағалау мәселесін қарастырады. Бұл тәсіл көкжиек маңындағы түтіннің визуалдық белгілерін талдауға бағытталған, себебі дәл осы жерде аэрозольдік ластанудың концентрациясы әдетте ең жоғары болады. Эксперименттік зерттеу үшін 2024 жылдың қаңтар–ақпан айларында алынған Алматы қаласының атмосферасының әуе фотосуреттерінен тұратын арнайы деректер жиынтығы құрылды, кейіннен суреттер тоғыз секторға кеңістіктік бөлініп, мөлдірлік деңгейі дискретті шкала бойынша қолмен визуалды бағаланды. Бұл белгілеу әдісі бір кадр шегінде ластанудың кеңістіктік гетерогенділігін тіркеуге және аспан фоны, көкжиек сызығы мен қалалық даму арасындағы айырмашылықтарды ескеруге мүмкіндік берді. Алдан дайындалған MobileNetV2 архитектурасына негізделген екі модель нұсқасы — классификация және регрессия — іске асырылды, бұл визуалдық ақпаратты түсіндіруде дискретті және үздіксіз тәсілдерді салыстыруға мүмкіндік берді. Салыстырмалы талдау көрсеткендей, классификатор қатаң сынып сәйкестендіруде жоғары дәлдікті (83,9%) қамтамасыз етеді, ал регрессиялық модель болжамдарды бүтін мәндерге дөңгелете отырып  $\pm 1$  сынып шегінде жоғары дәлдікті (97,2%) және жүйелік қателердің төмен деңгейін көрсетеді. Нәтижелер атмосфералық мөлдірлікті жергілікті мониторингтеу үшін ұшқышсыз ұшу аппараттарын компьютерлік көру әдістерімен біріктіріп қолданудың әлеуетін растап, қалалық ортадағы дәстүрлі жерге негізделген экологиялық мониторинг жүйелеріне қосымша ретіндегі бұл тәсілдің мүмкіндіктерін айқындайды, бұл бекітілген станциялардың аздығы жағдайында аса өзекті.

**Түйін сөздер:** ауа сапасын бақылау, ҰҒА деректері, компьютерлік көру, атмосфералық мөлдірлік, смог, терең оқыту.

### COMPUTER VIEWING METHODS FOR ANALYSING ATMOSPHERIC TRANSPARENCY FROM IMAGES TAKEN BY UNMANNED AERIAL VEHICLES

**Abstract.** This paper considers the problem of automated assessment of atmospheric transparency in urban conditions based on images obtained from an unmanned aerial vehicle, using computer vision and deep learning methods. The study explores an approach focused on analyzing visual signs of smoke near the horizon, where the concentration of aerosol pollution is usually most pronounced. For the experimental study, a specialized dataset was formed, including aerial photographs of the urban atmosphere of Almaty taken in January-February 2024, followed by spatial division of the images into nine sectors and manual visual assessment of the transparency level on a discrete scale. This method of marking allowed us to record the spatial heterogeneity of pollution within a single frame and take into account the differences between the sky background, the horizon line, and urban development. Based on the pre-trained MobileNetV2 architecture, two model variants were implemented — classification and regression — which made it possible to compare discrete and continuous approaches to the interpretation of visual information. A comparative analysis showed that the classifier provides higher accuracy of strict class matching (83.9%), while the regression model, when rounding predictions to whole values, demonstrates higher accuracy within a tolerance of  $\pm 1$  class (97.2%) and a lower level of

*systematic errors. The results confirm the promise of using UAVs in combination with computer vision methods for local monitoring of atmospheric transparency and highlight the potential of this approach as a supplement to traditional ground-based environmental monitoring systems in urban environments, which is particularly relevant given the limited density of stationary stations.*

**Keywords:** *air quality monitoring, UAV data, computer vision, atmospheric transparency, smog, deep learning.*

#### Сведения об авторах

Городецкая Людмила	магистрант, «Казахский национальный исследовательский технический университет имени К.И. Сатпаева» (НАО "КазННТУ им. К.И.Сатпаева"). E-mail: ludmila260601@gmail.com
Мухамедиев Равиль Ильгизович	Доктор инженерных наук, профессор, Институт автоматизации и информационных технологий, кафедра программной инженерии, «Казахский национальный исследовательский технический университет имени К.И. Сатпаева» (НАО "КазННТУ им. К.И.Сатпаева"), E-mail: ravil.muhamedyev@gmail.com
Юничева Надия Рафкатовна	к.т.н., доцент, Ведущий научный сотрудник Института информационных и вычислительных технологий КН МНВО РК, E-mail: naduni@mail.ru
Сымагулов Адилхан	Ведущий инженер, «Казахский национальный исследовательский технический университет имени К.И. Сатпаева» (НАО "КазННТУ им. К.И.Сатпаева"), E-mail: asmogulove00@gmail.com

#### Авторлар туралы мәлімет

Городецкая Людмила	"Қ.И. Сәтбаев атындағы Қазақ ұлттық техникалық зерттеу университеті" E-mail: ludmila260601@gmail.com
Мұхамедиев Равиль Ильгизович	Инженерия ғылымдарының докторы, профессор, "Қ.И. Сәтбаев атындағы Қазақ ұлттық техникалық зерттеу университеті", E-mail: ravil.muhamedyev@gmail.com
Юничева Надия Рафкатовна	т. ғ. к., доцент, ҚР БҒМ ҒК АЕТИ жетекші ғылыми қызметкері, E-mail: naduni@mail.ru
Сымағұлов Әділхан	"Қ.И. Сәтбаев атындағы Қазақ ұлттық техникалық зерттеу университеті" E-mail: asmogulove00@gmail.com

#### Information about the authors

Gorodetskaya Liudmila	master's student, Satbayev University (KazNRTU), Almaty, Kazakhstan E-mail: ludmila260601@gmail.com
Symagulov Adilkhan	Satbayev University (KazNRTU), Almaty, Kazakhstan E-mail: asmogulove00@gmail.com
Mukhamediev Ravil I.	Doctor of Engineering, Professor, Institute of Automation and Information Technologies, Satbayev University (KazNRTU), Almaty, Kazakhstan E-mail: ravil.muhamedyev@gmail.com
Yunicheva Nadiya	Candidate of Technical Science, leading researcher of the Institute of High Technologies of the National Academy of Sciences of the Republic of Kazakhstan, E-mail: <a href="mailto:naduni@mail.ru">naduni@mail.ru</a> ,
Symagulov Adilkhan	Satbayev University (KazNRTU), Almaty, Kazakhstan E-mail: asmogulove00@gmail.com