



Методы автоматической обработки изображений и видео однородных плотно сгруппированных объектов

Румянцева Мария Юрьевна

**2.3.8. Информатика и информационные процессы
(технические науки)**

Научный руководитель: докт. техн. наук, профессор А.А. Шалыто

Актуальность

- Требуется непрерывный контроль качества однородных плотно сгруппированных объектов (руды, флотация, окатыши).
- Характеристики:
 - Размер и форма частиц.
 - Пористость и плотность структуры.
 - Перекрытие и слипание объектов.
 - Динамика изменений во времени.
 - Выход за допуски (негабарит, дефекты).
- В настоящее время точный анализ возможен при использовании детализированной ручной разметки (существующие методы).
- Разметка требует времени, ресурсов и экспертов.
- Особенно сложно проводить разметку для множества мелких и перекрывающихся объектов.

Возникает **противоречие: для создания системы точного анализа требуется детализированная разметка, но ручная разметка будет трудоемкой и неточной.**



Процесс флотации, где технологам важно понимание размеров, формы, цвета, скорости пузырьков



Гранулометрия руды:
для управления
дробилкой важно знать
размеры и
“глинистость”
отдельных камней

Степень разработанности темы исследования

Задача	Ранее	Недостатки
Гранулометрия руды	Методы классификации, детекции, метод сегментации - водораздел (Сун ¹ , Чжан ² , Ян ³).	Требует ручной разметки, неустойчивы к форме объектов и качеству данных.
Флотация	Классические методы сегментации: пороговые преобразование, водораздел (Альдрих и Лю ⁴ , Мехршад и Массинаеи ⁵). Методы сегментации на основе размеченного набора данных: использование моделей Unet, Mask-RCNN, GAN, SAM (Роннебергер и др. ⁶ , Хэ и др. ⁷ , Чен и др. ⁸ , Мулман и др. ⁹ , Гхарехчобог ¹⁰).	Зависимость от типа объектов, качества данных, медленно
Окатыши	Классический метод сегментации: водораздел. Метод сегментации на основе размеченного набора данных: использование модели Unet (Ансари ¹¹).	Плохо адаптируется, нестабильно
Поризация гипсокартона	–	Отсутствие исследований

Вывод: во всех задачах сохраняются общие ограничения: высокая зависимость от разметки, слабая адаптивность к сложной геометрии и доменной вариативности. Это приводит к необходимости создания **унифицированных и масштабируемых подходов, устойчивых к изменениям качества данных**. Они не должны требовать полной ручной разметки.

¹ Sun G., Huang D., Cheng L., Jia J., Xiong C., Zhang Y. Efficient and Lightweight Framework for Real-Time Ore Image Segmentation Based on Deep Learning // Minerals. 2022. Vol. 12, No. 5. Art. 526.

² Zhang Y., Cheng L., Peng Y., Xu C., Fu Y., Wu B., Sun G. Faster OrefSDet: A Lightweight and Effective Few-Shot Object Detector for Ore Images // Pattern Recognition. 2023. Vol. 141. Art. 109664.

³ Yang D., Wang X., Zhang H., Yin Z., Su D., Xu J. A Mask R-CNN based particle identification for quantitative shape evaluation of granular materials // Powder Technology. 2021. Vol. 392, pp. 296–305.

⁴ Aldrich C., Liu X. Monitoring of Flotation Systems by Use of Multivariate Froth Image Analysis // Minerals. 2021. Vol. 11, No. 7. Art. 683.

⁵ Mehrshad N., Massinaei M. New image-processing algorithm for measurement of bubble size distribution from flotation froth images // Mining, Metallurgy & Exploration. 2011. Vol. 28, pp. 146–150.

⁶ Ronneberger O., Fischer P., Brox T. U-Net: Convolutional Networks for Biomedical Image Segmentation // MICCAI 2015. LNCS 9351, pp. 234–241.

⁷ He K., Gkioxari G., Dollár P., Girshick R. Mask R-CNN // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2020. Vol. 42, No. 2, pp. 386–397.

⁸ Chen Y., Xu D., Wan K. A froth velocity measurement method based on improved U-Net++ semantic segmentation in flotation process // International Journal of Minerals, Metallurgy and Materials. 2024. Vol. 31, pp. 1816–1827.

⁹ Moolman D. W., Aldrich C., Van Deventer J. S. J. The monitoring of froth surfaces on industrial flotation plants using connectionist image processing techniques // Minerals Engineering. 1995. Vol. 8, No. 1–2, pp. 23–30.

¹⁰ Gharehchobogh B. K., Kuzeikanan Z. D., Sobhi J., Khiavi A. M. Flotation froth image segmentation using Mask R-CNN // Minerals Engineering. 2023. Vol. 192, pp. 107959.

¹¹ Ansari M. A., Crampton A., Garrard R., et al. A Convolutional Neural Network (CNN) classification to identify the presence of pores in powder bed fusion images // International Journal of Advanced Manufacturing Technology. 2022. Vol. 120, pp. 5133–5150.

Термины

В диссертационной работе используются следующие термины:

Термин	Определение
Сегментация	Разделение изображения на области, соответствующие объектам или фонам.
Аннотация	Процесс разметки данных метками или атрибутами, описывающими их содержание, для использования в анализе и обучении моделей машинного обучения.
Классические методы сегментации	Эвристические методы без обучения (пороговый, градиентный, водораздел и т. д.).
Фундаментальные модели сегментации	Предобученные универсальные модели (например, Segment Anything Model), применимые без дообучения.
Модель сегментации	Обучаемая нейросеть для выделения объектов на изображениях. Видео рассматривается как последовательный набор изображений.
“Слабая” разметка (аннотация)	Неточная разметка для обучения моделей.
Аугментация	Процесс искусственного увеличения и разнообразия обучающего набора данных за счёт преобразований исходных данных без изменения их семантического содержания.
Коллапс мод	Явление, при котором генеративная модель воспроизводит ограниченное число однотипных выходов, теряя разнообразие и не охватывая все моды распределения данных.
Доменная адаптация	Приближение распределения синтетических данных к реальному для повышения реалистичности.
Контроль стиля	Управление визуальными характеристиками генерируемого изображения (текстурой, цветовой гаммой, освещением, общим внешним видом) при сохранении его содержательной структуры.

Объект исследования: изображения и видео однородных плотно сгруппированных объектов: камней руды на конвейере, пузырьков флотации, пористых материалов и т. д.



Предмет исследования: методы автоматической обработки изображений и видео однородных плотно сгруппированных объектов.

Методы исследования: методы машинного обучения и компьютерного зрения.

Цель исследования: снижение трудоемкости и обеспечение качества обработки изображений и видео однородных плотно сгруппированных объектов за счет использования методов “слабой” аннотации (“слабой” разметки) и генерации синтетических данных для обучения моделей машинного обучения без использования предварительно созданной маски изображения.

Задачи диссертационной работы

1. Выполнить **обзор существующих методов** обработки изображений с однородными плотно сгруппированными объектами.
2. Разработать **метод «слабой» разметки**, предназначенный для сегментации изображений и видео однородных плотно сгруппированных объектов.
3. Разработать **метод генерации синтетических данных** для обучения нейронных сетей, предназначенных для сегментации изображений и видео однородных плотно сгруппированных объектов без ручной разметки.
4. Разработать **библиотеку программ**, в которой реализованы предложенные методы анализа изображений и видео и обеспечивается вычисление обобщённых характеристик групп объектов.
5. Провести **экспериментальные исследования** разработанных методов, включающие:
 - а. гранулометрический анализ руды;
 - б. оценку эффективности процесса флотации;
 - с. анализ структуры пористых материалов.
6. **Внедрить** результаты исследований в промышленность.

Положения, выносимые на защиту



1. **Метод автоматизированной “слабой” аннотации (“слабой” разметки) изображений и видео с однородными плотно сгруппированными объектами**, использующий сегментацию, отличающийся тем, что с целью устраниния ручной разметки изображений и видео, используется комбинация одного из классических методов и одной из фундаментальных моделей сегментации.
2. **Метод генерации синтетических данных однородных плотно сгруппированных объектов**, использующий сегментацию, отличающийся тем, что **с целью устраниния ручной разметки** изображений и видео, при обучении моделей машинного обучения не используются предварительно созданные маски изображений.
3. **Библиотека программ, обеспечивающих оценку групповых характеристик однородных плотно сгруппированных объектов на изображениях и видео**, отличающаяся тем, что с целью автоматизации оценки этих характеристик, в ней реализованы предложенные методы.

Первые два положения обладают научной новизной, третье положение имеет важное практическое значение.

Соответствие паспорту специальности

Пункт 4: Разработка методов и технологий цифровой обработки аудиовизуальной информации...



Разработаны методы анализа изображений и видео с плотными структурами, что непосредственно соответствует задачам цифровой обработки визуальной информации.

Пункт 7: Разработка методов обработки, группировки и аннотирования информации...

Разработаны методы “слабой” аннотации (“слабой” разметки) и генерации синтетических данных для изображений и видео без использования ручной разметки, что относится к задачам аннотирования и подготовки информации для последующего анализа.

Пункт 16: Разработка алгоритмов, программных и программно-аппаратных средств интеллектуальной обработки информации и управления данными...

В диссертации разработана библиотека программ, обеспечивающих оценку групповых характеристик однородных плотно сгруппированных объектов на изображениях и видео. В ней реализованы предложенные методы, направленные на интеллектуальную обработку изображений и видео.

Промышленные задачи



Гранулометрия (анализ размера и поиск негабарита) руды для корректировки режима мельницы



Анализ размера, формы, цветности, скорости пузырьков флотации для корректировки рецептов



Анализ размера и влажности окатышей руды для корректировки рецептов

Анализ групповых процессуально значимых характеристик объектов, скученно расположенных на изображении и видео для решения технологических задач

Состояние предметной области

- Несмотря на прикладную значимость, исследования проводятся разрозненно для разных объектов (анализ руды, анализ флотации)¹.
- Близкие исследования: анализ медицинских данных (клетки) – работа с изображениями².
- Более простая задача: анализ частиц материалов, которые не являются плотно сгруппированными³.
- Общие подходы и теоретическая формализация класса однородных плотно сгруппированных объектов не найдены.
- Размеченных наборов данных плотно сгруппированных объектов в открытом доступе нет.

¹ Jooshaki M., Nad A., Michaux S. A Systematic Review on the Application of Machine Learning in Exploiting Mineralogical Data in Mining and Mineral Industry // *Minerals*. 2021. Vol. 11, No. 8. Article 816.

² Tian Z., Wei Y., Yu Y., Zhou F., Huang Z.-L. Blood Cell Analysis: From Traditional Methods to Super-Resolution Microscopy // *Photonics*. 2022. Vol. 9, No. 4. Article 261.

³ Sultana R., Khatun A., Hossen M. F. A Comprehensive Review of Particle Size Analysis Techniques // *International Journal of Pharmaceutical Research and Development*. 2024. Vol. 6. P. 1-5.

Разобщённые подходы, используемые в настоящее время

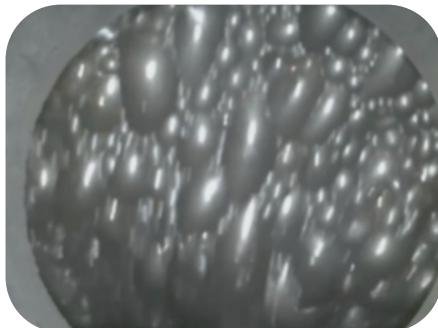


Методы гранулометрии:

- ситовой анализ;
- рентгенорадиометрический анализ;
- сканирование с использование 3D камер;
- лазерное 3D-сканирование;
- **использование компьютерного зрения;**

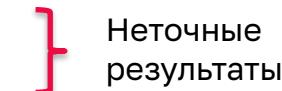


Дорогостоящее
оборудование



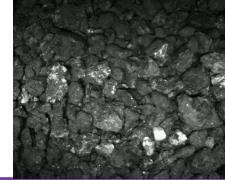
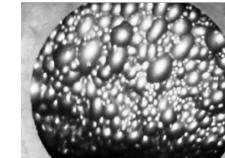
Методы анализа флотации:

- визуальный анализ характеристик;
- классификация пены по классам;
- **использование компьютерного зрения;**



Неточные
результаты

Групповые характеристики для анализа

Задача	Пример данных	Число объектов	Размер	Цвет	Форма	Движение
Анализ качества порозации		<u>Требуется для анализа</u>	<u>Требуется для анализа</u>	Не требуется для анализа	<u>Требуется для анализа</u>	Не требуется для анализа
Гранулометрия руды		<u>Требуется для анализа</u>	<u>Требуется для анализа</u>	<u>Требуется для анализа</u>	Не требуется для анализа	<u>Требуется для анализа</u>
Анализ флотации		<u>Требуется для анализа</u>				

достаточно
детекции для
определения

достаточно
сегментации для
определения

достаточно
сегментации для
определения

достаточно
сегментации для
определения

достаточно
детекции для
определения

Таким образом, все представленные задачи целесообразнее выполнять с помощью сегментации.

Методы и модели, используемые в настоящее время

Задачи	Примеры методов	Особенности
Классические методы	Гранулометрия, анализ флотации	Пороговая сегментация ¹ , маркерный водораздел ^{2,3} Низкая устойчивость к шумам, вариативности размеров
Нейросетевые методы	Гранулометрия, анализ флотации	Классификация, регрессия, сегментация (модели Unet ⁴ , Mask-RCNN, DeepLab) Необходимость размеченных данных
Фундаментальные модели сегментации	Анализ удобрений, флотации	Сегментация (Segment Anything Model) Работа не в реальном времени, работают на основе предразметки на задаче детекции объекта и данными хорошего качества

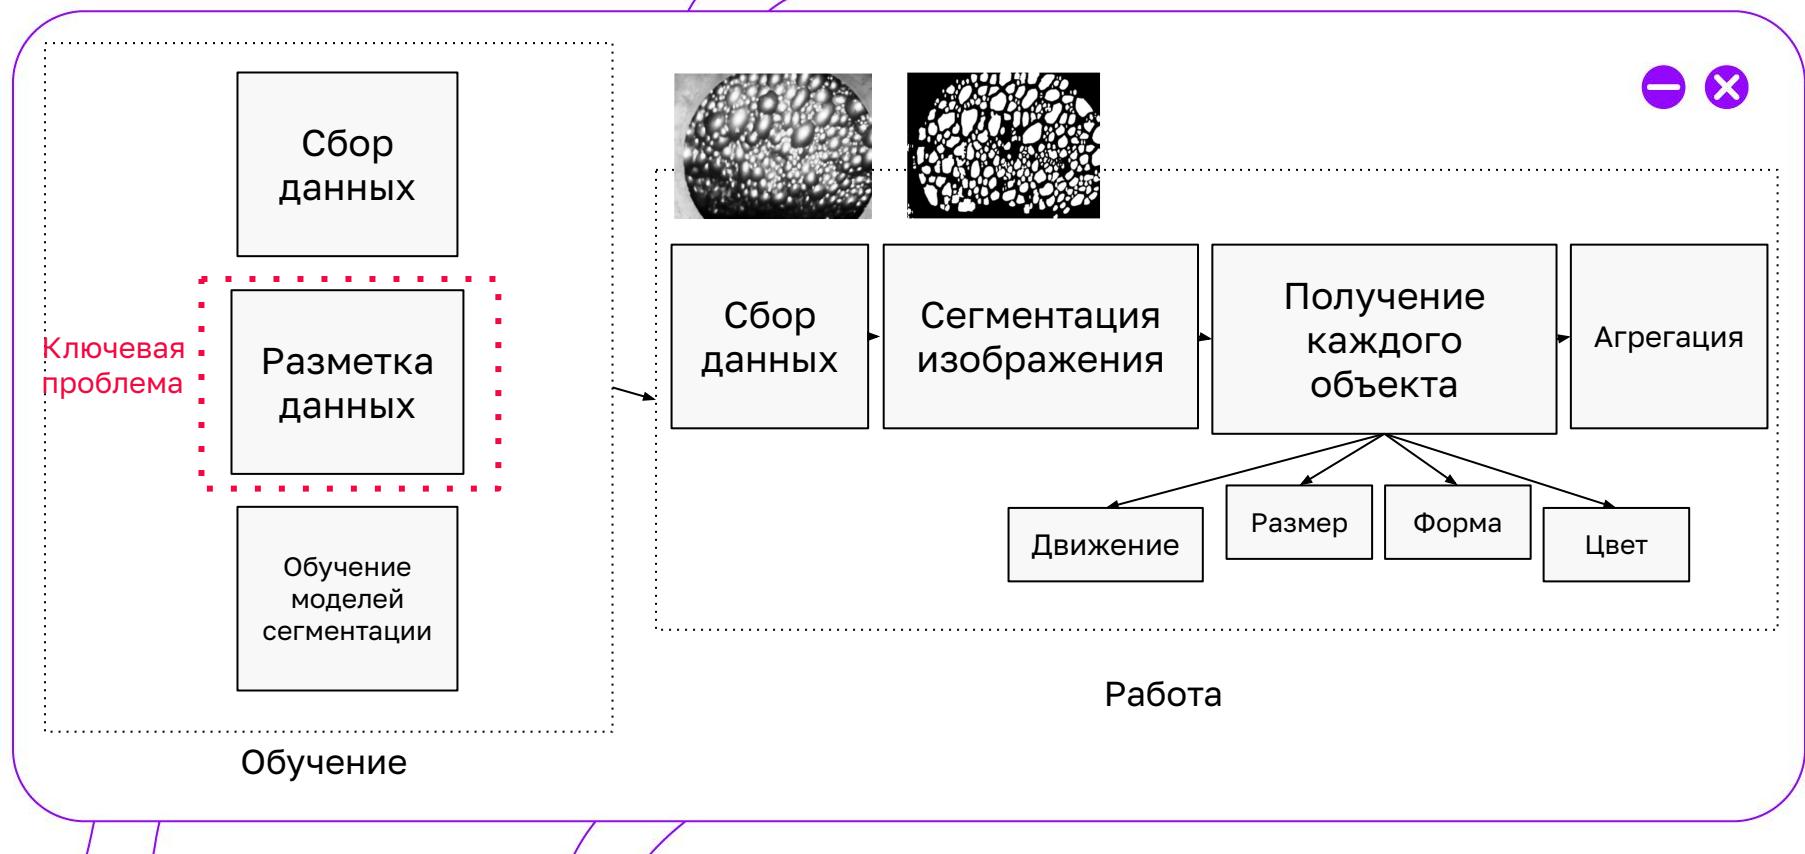
¹ Sun G., Huang D., Cheng L., Jia J., Xiong C., Zhang Y. Efficient and Lightweight Framework for Real-Time Ore Image Segmentation Based on Deep Learning // Minerals. 2022. Vol. 12, No. 5. Article 526.

² Amankwah A., Aldrich C. Automatic Ore Image Segmentation Using Mean Shift and Watershed Transform // Proceedings of the 21st International Conference Radioelektronika. Brno, Czech Republic, 2011. P. 1–4.

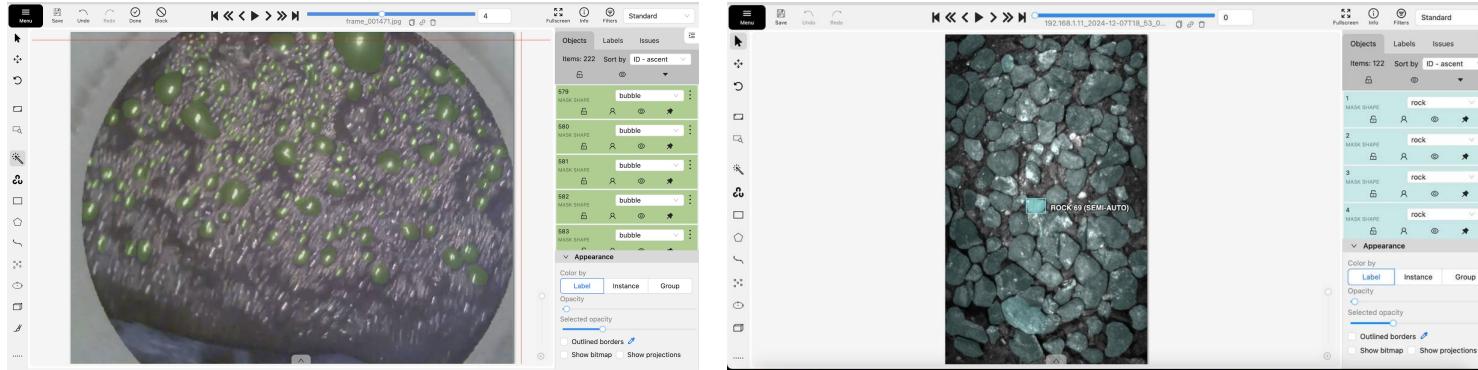
³ Zhang W., Jiang D. The Marker-Based Watershed Segmentation Algorithm of Ore Image // Proceedings of the 3rd IEEE International Conference on Communication Software and Networks. Xi'an, China, 2011. P. 472–474.

⁴ Wang W., Li Q., Xiao C., Zhang D., Miao L., Wang L. An Improved Boundary-Aware U-Net for Ore Image Semantic Segmentation // Sensors. 2021. Vol. 21, No. 8. Article 2615.

Общий технологический процесс



Узкое место работы



- Изображения с плотно сгруппированными объектами содержат более 100 объектов, каждый из которых требует индивидуальной ручной аннотации.
- Применение автоматических методов разметки на основе фундаментальных моделей невозможно из-за отсутствия предварительно обученных моделей, способных обрабатывать эти данные.
- Экспертная разметка подвержена неточностям из-за визуальной сложности и плотной скученности объектов.
- Среднее время ручной аннотации (разметки) одного изображения превышает три часа, что делает процесс крайне ресурсоёмким и ограничивает масштабируемость.

Обзор известных моделей сегментации

Модель	Тип	Особенности	Достоинства	Недостатки
U-Net (2015)	Семантическая	Кодировщик-декодировщик со прямыми связями	Простая и быстрая, идеальна для медицины	Плохо захватывает глобальный контекст
Mask R-CNN (2017)	Экземплярная	Сегментация + детекция объектов	Точная маска на объект, проверенная модель	Медленная работа
DeepLab v3+ (2018)	Семантическая	Дилатации + ASPP + декодер	Четкие границы, подходит для сложных сцен	Высокое потребление памяти
SOLOv2 (2020)	Экземплярная	Без якорных рамок, сегментация через сетку	Быстро, простой постпроцессинг	Меньше точности на сложных объектах
Mask2Former (2021)	Универсальная	Трансформеры для всех типов сегментации.	Современный стандарт, унификация задач	Требует много ресурсов и аннотаций
SAM (2023)	Универсальная	Сегментация “без обучения” любого объекта по клику/рамке.	Не требует обучения, очень быстро	Не адаптирован под узкие классы

Обзор известных моделей генерации данных

Модель	Применение	Достоинства	Недостатки
GAN (2014)	Генерация редких классов, смена стилей (CycleGAN).	Чёткие изображения, быстрая генерация	Сложное обучение, возможен коллапс мод
VAE (2014)	Вариации внутри классов, генерация редких форм	Простота, нет коллапса мод	Размытые образы, слабая детализация
DDPM (2020)	Генерация новых образцов, вариации с img2img	Высокое качество, нет коллапса мод	Медленно, ресурсоёмко
Stable Diffusion (2022)	Аугментация по тексту, стилю, освещению	Быстрее модели DDPM, гибкое управление	Требует GPU, качество зависит от модели
ControlNet (2023)	Генерация по позам, сегментации, структурам	Точный контроль, комбинируемые условия	Нужны карты условий, сложнее в настройке

Выводы по главе 1

1. Промышленные задачи (гранулометрия руды, анализ пены флотации, анализ качества окатышей, проверка качества пористых продуктов) сводятся к анализу **однородных плотно сгруппированных объектов**.
2. Основная проблема – **ручная разметка**: трудоёмкая, нестабильная, сложно масштабируется.
3. Классические методы плохо масштабируются на разные объекты.
4. Нейросетевые методы требуют качественной аннотации, но **неустойчивы к изменению качества данных и вариативности**.
5. Современные генеративные модели позволяют создавать и аугментировать изображения, близкие к реальным.
6. Современные универсальные модели сегментации (Segment Anything Model и т. д.) **требуют использования дополнительных входных данных** для однородных плотно сгруппированных объектов.
7. Необходима разработка автоматизированных методов разметки изображений однородных плотно сгруппированных объектов.



«Слабая» разметка

Понятие:

“Слабая” разметка (weak labeling) – это подход к аннотированию данных, при котором метки предоставляются в упрощённой, неполной или неточной форме по сравнению с полной разметкой (full supervision).



Контекст использования:

- дефицит точно размеченных данных;
- высокая стоимость аннотации;
- работа с трудноразделимыми объектами.

Задача:

Разработать **метод «слабой» разметки**, предназначенный для автоматической сегментации изображений и видео однородных плотно сгруппированных объектов.

Улучшение относительно существующих методов:

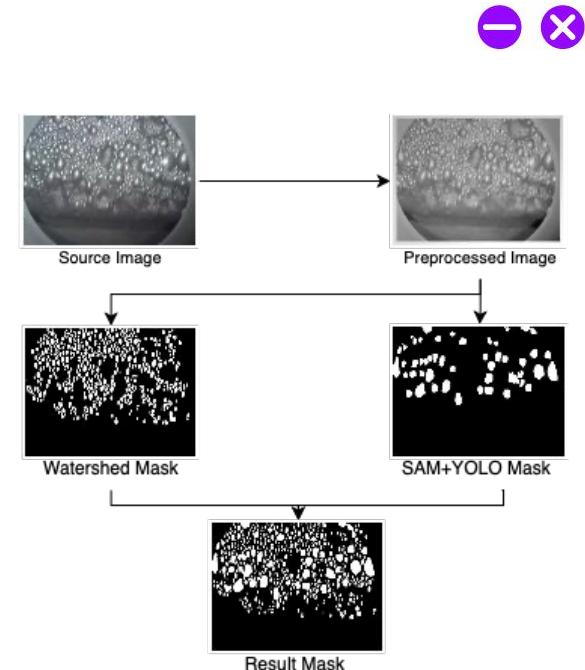
Снижает затраты на аннотацию, повышает масштабируемость и позволяет использовать неструктурированные или частично размеченные данные.

Описание метода

В главе предлагается метод автоматизированной разметки на основе **классического метода** маркерного водораздела и **фундаментальной модели** Segment Anything Model, состоящий из следующих шагов:

1. Предобработка изображения (корректировка яркости, контрастности и т. д.).
2. Применение метода маркерного водораздела для разметки мелких объектов.
3. Разметка крупных объектов с помощью фундаментальной модели Segment Anything Model.
4. Объединение разметок по п. 2 и 3.
5. Постобработка (сужение границ для устранения слипания объектов).

Метод внедрен (см. главу 5).



Метрики оценки качества обучения

В предложенном методе используются следующие соотношения для оценки качества его работы:

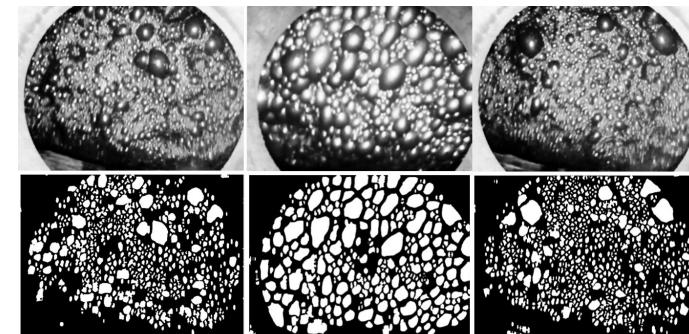
Метрика	Формула	Описание	 
Accuracy	$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$	Доля всех правильно классифицированных пикселей	
Precision	$\text{Precision} = \frac{TP}{TP + FP}$	Точность положительных предсказаний пикселей	
Recall	$\text{Recall} = \frac{TP}{TP + FN}$	Полнота: доля обнаруженных реальных положительных пикселей	
F1-score	$F1 = \frac{2 \cdot \text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} = \frac{2TP}{2TP + FP + FN}$	Гармоническое среднее Precision и Recall	
IoU	$\text{IoU} = \frac{ \text{Prediction} \cap \text{GT} }{ \text{Prediction} \cup \text{GT} } = \frac{TP}{TP + FP + FN}$	Доля пересекающихся пикселей относительных всех пикселей	
Dice	$\text{Dice} = \frac{2 \text{Prediction} \cap \text{GT} }{ \text{Prediction} + \text{GT} } = \frac{2TP}{2TP + FP + FN}$	Гармоническое среднее Precision и Recall для пересекающихся пикселей	
Object Recall	$\text{Object Recall} = \frac{\text{Число правильно найденных объектов}}{\text{Число объектов в GT}}$	Доля правильно найденных объектов – объект считается найденным, если IoU с GT > порога (обычно 0.5).	

Метод использования “слабой” разметки для анализа однородных данных

- Метод протестирован на **флотационной пено**.
- Маски, полученные автоматически, использовались как разметка для обучения известных моделей сегментации.
- Протестированы несколько архитектур моделей с точки зрения точности и скорости для выявления лучшей.



Модель	IoU	Dice	Precision	Recall	Accuracy	Object recall
Swin-UNETR	0.791	0.864	0.874	0.853	0.922	0.691
HRNet	0.758	0.832	0.816	0.870	0.907	0.535
DeepLabv3	0.701	0.798	0.784	0.801	0.891	0.585
SegFormer	0.688	0.785	0.769	0.793	0.887	0.521



Обеспечивается результат в 79% точности относительно экспертной разметки, который показывает, что “слабая” разметка может достигать результатов, сравнимых с экспертной разметкой (при учёте, что модель, обученная на “слабой” разметке, может выделять объекты, невыделенные экспертом).

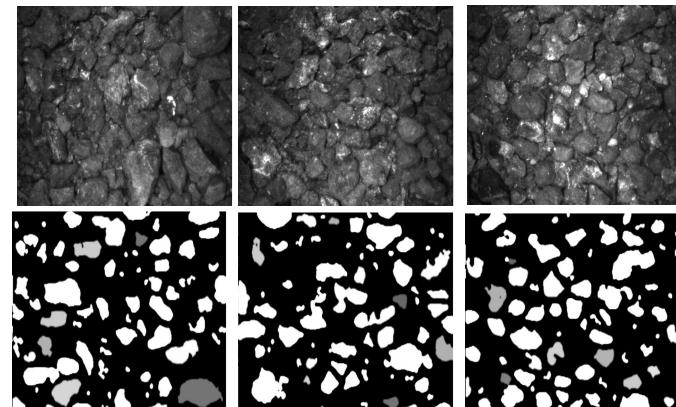
Метод использования слабой разметки для анализа однородных данных

- Метод протестирован на **камнях руды**.
- Маски, полученные автоматически, использовались как разметка для обучения лучшей модели сегментации (на основе исследования флотации).
- Метод менее подходит для объектов, где сложнее выявить опорные маркеры (например, блики у пузырьков).



Модель	IoU	Dice	Precision	Recall	Accuracy	Object Recall
Swin-UNETR	0.540	0.701	0.904	0.572	0.762	0.591

Модель Swin-UNETR на объектах руды показывает меньшую точностью (54%) относительно экспертной разметки, что подтверждается визуальным сравнением. Это показывает ограничения метода в случае отсутствия возможности выделить опорные маркеры.



Подходы к оценке слабой разметки

Для оценки качества сегментации традиционно используются метрики, сравнивающие предсказанную маску с эталонной разметкой:

- **IoU** (Intersection over Union);
- **Dice коэффициент**;
- **Precision, Recall, F1-score** – на основе пиксельной классификации.

Метрики **IoU** (Intersection over Union) и **Dice** предполагают, что существует однозначная и точная ground truth разметка. Однако в случае **однородных плотно сгруппированных объектов** это не так:

1. **Разметка неоднозначна**: объекты часто сливаются, и границы размечаются субъективно.
2. **Малейшее смещение границ сильно снижает метрику** – особенно при перекрытии и агломерации.
3. **Нет "правильного" способа деления на объекты** – можно нарезать по-разному, и все варианты будут допустимы.

Несмотря на допустимые значения метрик IoU и Dice для сегментации руды и пузырьков флотации, визуальная оценка показывает более низкое качество сегментации руды.



Выводы по главе 2

1. Разработан **метод автоматизации разметки**, который протестирован на двух доменах (флотационная пена и камни руды).
2. Метод **устраняет потребность в ручной разметке** и позволяет создавать аннотированные наборы данных для сложных изображений с однородными плотно сгруппированными объектами.
3. Метод хорошо работает с **данными, имеющими явный маркер** (например, блик пузырьков).
4. Лучшая модель, обученная на размеченном наборе данных, показывает пересечение с размеченным набором данных в 79% на пузырьков флотации (хороший результат), и 54% на камнях руды (средний результат, потребовавших разработки второго метода).
5. Проведено сравнение известных моделей сегментации для работы с задачей анализа плотно сгруппированных объектов.
6. Полученные результаты обосновывают положение 1, выносимое на защиту.



Предпосылки создания метода

“Слабая” аннотация позволяет быстро получить разметку реальных изображений без полной ручной разметки. Это критично на ранних этапах, когда нет датасета. Однако качество такой разметки обладает недостатками:



- ошибки на перекрытиях;
- искажения формы;
- чувствительность к шуму.

Ограниченнное качество «слабой» разметки стало узким местом:

- ошибки передаются в модель;
- нестабильность на сложных сценах;
- невозможность точного контроля распределения объектов.

Задача: создание метода генерации данных по разметке:

- позволяет задать точные характеристики (форма, плотность, расположение);
- формирует эталонные пары «разметка–изображение»;
- используется для дообучения модели и улучшения моделей, обученных на «слабой» разметке.

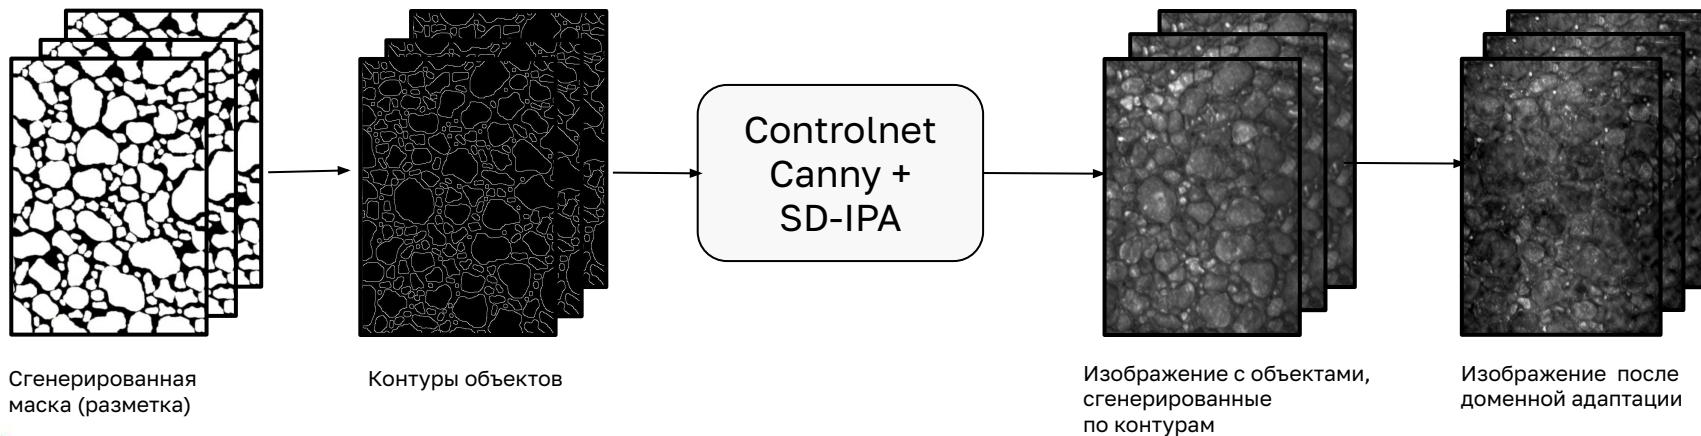
Улучшение относительно существующих методов:

учтены особенности однородных плотно сгруппированных объектов

Метод последовательной генерации однородных данных

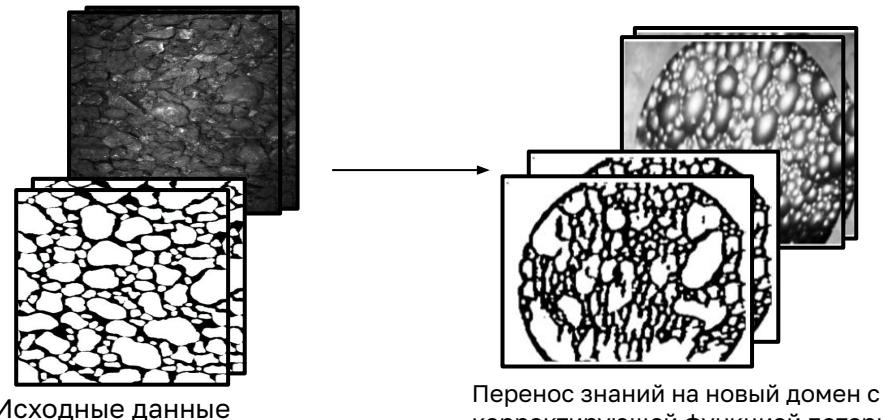
Предложенный метод состоит из трёх этапов:

1. Генерируется разметка для бинарной сегментации на основе переноса между доменами (основная новизна метода).
2. Полученная разметка преобразуется в контуры объектов.
3. По контурам с помощью генеративной модели IP-Adapter создаётся целевое изображение.
4. Применяется доменная адаптация для контроля стиля.



Этап 1: Генерация разметок

1. Обучение на парах «разметка – изображение».
2. Перенос знаний на новый тип данных с функциями потерь, корректирующими форму и соответствие размерам.



Генерация разметок с помощью переноса знаний

Функция потерь Тверского:

$$\mathcal{L}_{Tversky} = 1 - TI$$

$$TI = \frac{\sum_{x \in \Omega} y_x p_x}{\sum_{\forall x \in \Omega} y_x p_x + \alpha \sum_{x \in \Omega} (1 - y_x) p_x + \beta \sum_{x \in \Omega} y_x (1 - p_x)}$$



Краевая функция потерь:

$$\mathcal{L}_{boundary} = \frac{1}{|\Omega|} \sum_{x \in \Omega} d_y(x) \cdot |p_x - y_x|$$

Счётная функция потерь:

$$\hat{c}_k = \sum_{x \in \Omega} (p * G_k)(x), \quad c_k = \sum_{x \in \Omega} (y * G_k)(x)$$

$$L_{count} = \sum_k w_k \cdot \frac{|\hat{c}_k - c_k|}{c_k + \epsilon}$$

Комбинация с коэффициентом:

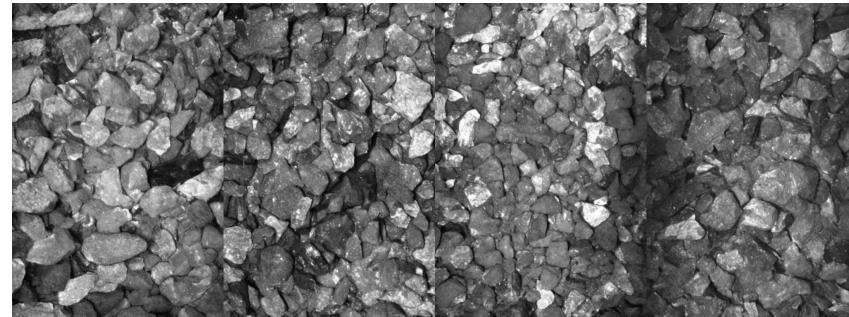
$$L = w_{tvrs} \cdot \mathcal{L}_{Tversky} + w_{bd} \cdot \mathcal{L}_{boundary} + w_{count} \cdot L_{count}$$

Этап 2: Создание изображение по разметкам

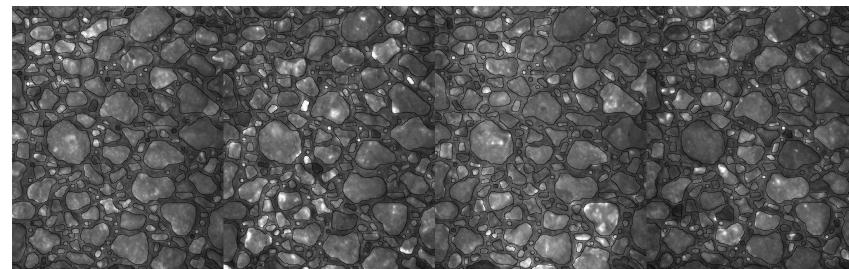
Предложен метод генерации изображений по заданной геометрии объектов (разметкам), что позволяет контролировать плотность, форму и расположение элементов.

- генерация изображений по бинарным разметкам, преобразованным в контуры;
- контроль плотности и формы объектов;
- применимо к различным типам однородных структур (руда, окатыши, пузыри).

Генерация объектов по разметкам позволяет достичь полного совпадения размеров и формы с разметками.



Пример сгенерированных изображений



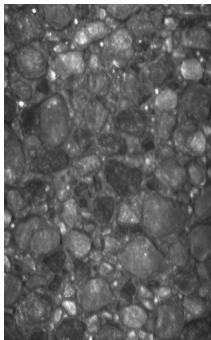
Пример наложения контуров разметок на сгенерированные изображения

Этап 3: Доменная адаптация

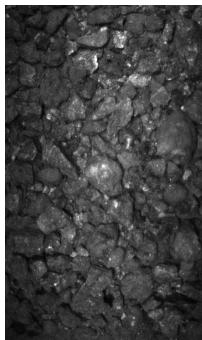
Используется метод доменной адаптации Fourier Domain Adaptation (FDA): замена низкочастотной компоненты синтетических изображений на реальные.

Результаты:

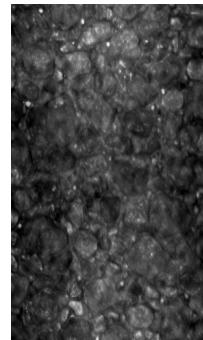
1. Увеличение IoU на 1–2%.
2. Улучшение качества границ и устойчивости к условиям съёмки.



Сгенерированное изображение



Целевое изображение



Адаптированное изображение



Формализация метода:

$$\hat{I}_s = \mathcal{F}^{-1} \left(\text{Swap}(A(I_s), A(I_t), r) \cdot e^{j \cdot P(I_s)} \right)$$

I_s – синтетическое изображение (source),
 I_t – реальное изображение (target),

$\mathcal{F}(\cdot)$ – прямое 2D-преобразование Фурье,
 $\mathcal{F}^{-1}(\cdot)$ – обратное преобразование Фурье,

$A(\cdot)$ – амплитудный спектр,
 $P(\cdot)$ – фазовый спектр,

$\text{Swap}(A_s, A_t, r)$ – операция замены

низкочастотной области радиусом r из A_s на
соответствующую область из A_t .

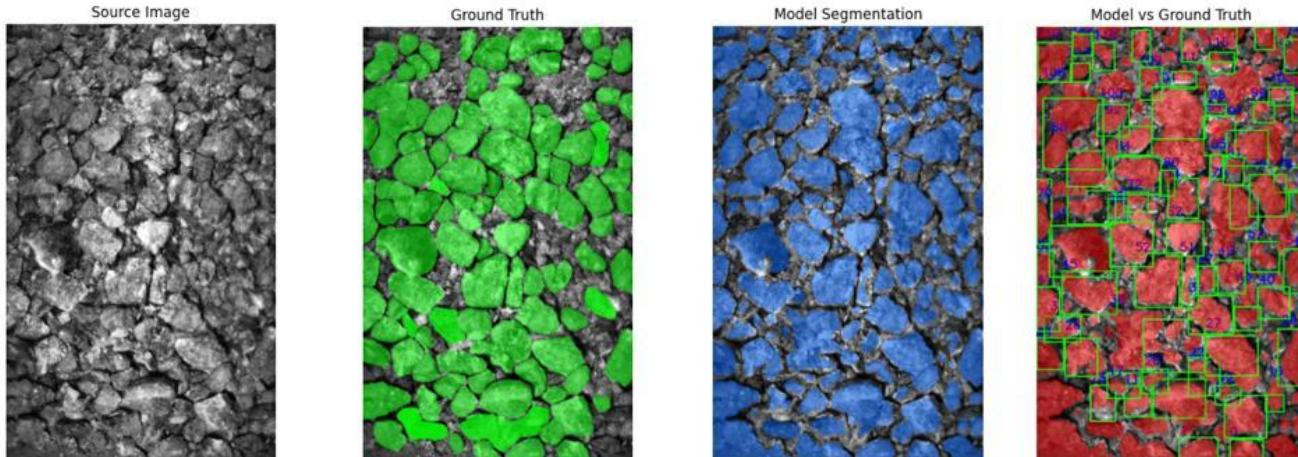
Результаты сегментации

На основе модели Swin-UNETR (модель с большим числом параметров), обученной на доменно-адаптированном синтетическом наборе данных, была выполнена разметка набора данных на изображениях (фотографиях, полученных с камеры, установленной над конвейером).

На этом наборе данных обучена модель HRNet для работы в режиме реального времени.

Метрики

Dice	0.75
IoU	0.85
F1	0.74
Precision	0.64
Recall	0.91
Obj Recall	0.91



В результате получена модель сегментации изображений руды, которая автоматически выделяет все камни, отмеченные экспертной разметкой, а также более мелкие камни, не указанные экспертом. Модель позволяет рассчитывать групповые характеристики и была обучена полностью без использования ручной разметки.

Выводы по главе 3

1. Разработан **метод генерации разметок** однородных плотно сгруппированных объектов.
2. Разработан **метод генерации синтетических данных** на основе разметок.
3. Обоснована эффективность применения метода.
4. Он позволяет масштабировать обучение моделей сегментации при дефиците размеченных данных – создавать синтетические данные.
5. Полученные результаты обосновывают положение 2, выносимое на защиту.



Библиотека для анализа однородных данных

Задача:

Адаптировать процесс автоматической разметки и последующий анализ групповых характеристик для разных доменов однородных плотно сгруппированных объектов.



Улучшение относительно существующих библиотек:

Уникальная открытая библиотека для автоматической разметки изображений с однородными плотно сгруппированными объектами.

Уникальность библиотеки:

1. Первая открытая специализированная библиотека, ориентированная на анализ однородных плотно сгруппированных объектов на изображениях с автоматической разметкой.
2. Объединяет в себе классические и современные нейросетевые подходы.
3. Поддерживает интерпретируемость результатов и работу в условиях ограниченной разметки.
4. Используется в реальных проектах – от флотации до гранулометрии и пористых материалов.

Библиотека содержит следующие компоненты:

1. Модуль для слабой аннотации изображений на основе первого метода.
2. Модуль для генерации синтетических данных на основе второго метода.
3. Модуль для обучения моделей сегментации изображений, использующий разметки, созданные с помощью первого или второго метода.
4. Модуль для самообучения, улучшающий качество сегментации.
5. Модуль оценки групповых характеристик.
6. Модуль предобработки изображений.
7. Модуль оценки качества.

Структура

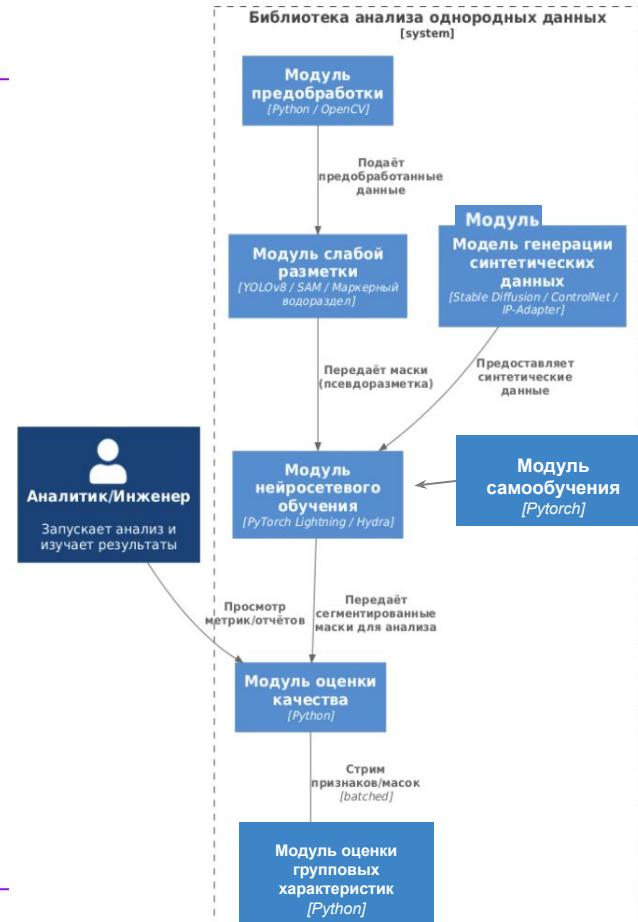
Модульная архитектура, позволяющая интегрировать новые компоненты.

Основные модули (описаны ниже):

1. Модуль слабой разметки (уникальный модуль).
2. Модуль генерации синтетических данных.
3. Модуль нейросетевого обучения.
4. Модуль самообучения.
5. Модуль оценки групповых характеристик.

Вспомогательные модули:

6. Модуль предобработки изображений.
7. Модуль оценки качества.



1. Модуль слабой аннотации изображений на основе первого метода

СТСІ (Clumped Texture Composite Images) –
программный инструмент для слабой аннотации
однородных изображений.



Функциональность:

- автоматическая разметка (YOLOv8 + SAM + водораздел);
- постобработка (морфология, Retinex, выравнивание гистограммы);
- полуавтоматическая генерация масок и датасетов;
- адаптивность к новым доменам.

2. Модуль генерации синтетических данных на основе второго метода



Функциональность:

- генерация примеров синтетических масок по фотографии с заданными условиями;
- генерация соответствующих целевому домену изображений по маскам;
- генерация видео.

3. Модуль обучения моделей сегментации изображений, использующий разметки, созданные с помощью первого или второго метода



Функциональность:

- обучение различных моделей сегментации;
- управления обучением моделей;
- отслеживания процесса обучения моделей.

4. Модуль самообучения, улучшающего качество сегментации (1/2)

Методы самообучения (self-supervised learning) – методы машинного обучения, при которых модель обучается без ручной разметки, извлекая обучающие сигналы из структуры самих данных (например, через предсказание скрытых частей, согласованность представлений или контраст между примерами). Часто используются как методы предварительного обучения для вычисления признаков.



Основные подходы:

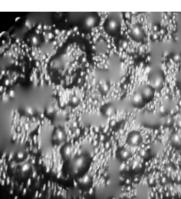
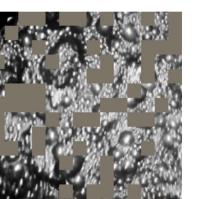
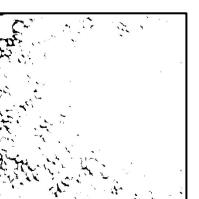
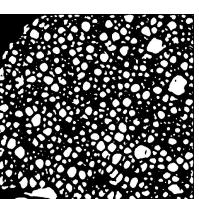
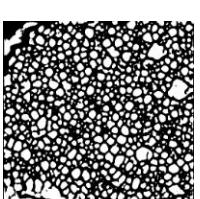
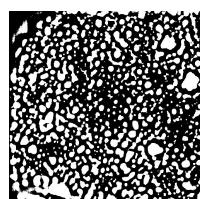
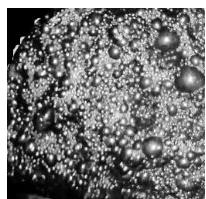
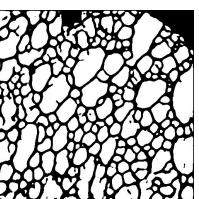
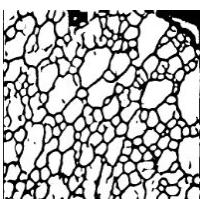
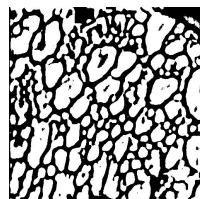
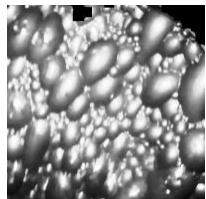
1. **Контрастивное обучение:** сравнение похожих и непохожих примеров (например, SimCLR, MoCo).
2. **Предсказание масок / патчей / соседних фрагментов:** маскирование части входных данных и восстановление скрытого (например, методы MAE, BEiT, BERT).
3. **Pretext-задачи:** вспомогательные задачи для обучения признаков (определение порядка, вращения, цветовой заливки).

4. Модуль самообучения, улучшающего качество сегментации (2/2)

- Реализованы методы **MoCo**, **Barlow Twins**, **Jigsaw**, **SparK** для предварительного обучения моделей без разметки.
- Методы на основе маскирования (SparK) и вспомогательных задач (Jigsaw) **плохо работают** на пне: усреднённый шум вместо структуры.
- Получено улучшение метрик на 3 % для контрастивных методов, рекомендуется их использование в процессе обучения.



Оригинал Unet BT-Unet MoCo-Unet Jigsaw-Unet Маскированное Восстановленное



Глава 4. Библиотека программ, обеспечивающих решение задач оценки групповых характеристик однородных плотно сгруппированных объектов на изображениях и видео (8/9)

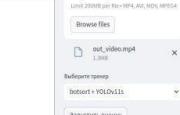
5. Модуль оценки групповых характеристик

Функциональность:

Получение:

- распределения размеров;
- распределения формы;
- распределения цветности;
- времени жизни;
- скорости передвижения объектов.

Основано на методах автоматической разметки, сегментации и внедренных моделей отслеживания.



Автоматизация анализа флотации

Основные метрики Покадровый просмотр Детальные графики

Обработка завершена!

Среднее смещение:

15.22 px

Равн. обнаружение:

89.08%

Итоговая оценка:

0.9280

Средний оптический поток:

15.18 px

Температура сопственности:

0.40

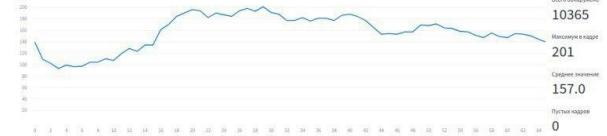
Средняя длина трека:

16.61 кадров

Кол. активных треков:

201

Динамика обнаружения пузырей



Статистика

Всего обнаружено:

10365

Максимум кадра:

201

Среднее значение:

157.0

Пустых кадров:

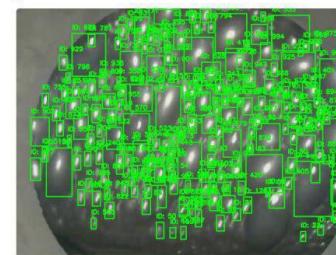
0

Автоматизация анализа флотации

Основные метрики Покадровый просмотр Детальные графики

Покадровый просмотр результатов

Выберите кадр:



Выводы по главе 4

1. **Разработана и апробирована библиотека СТС1**, объединяющая методы обработки для задач оценки групповых характеристик однородных плотно сгруппированных объектов, обеспечивающая слабую аннотацию, генерацию масок и подготовку данных для обучения без ручной разметки, что значительно снижает трудозатраты и ускоряет внедрение.
2. Модульная библиотека позволяет **быстро разрабатывать разметки** однородных плотно сгруппированных объектов и обучать модели для последующей разработки систем анализ характеристик.
3. Разработанные методы подтверждают положение 3, выносимое на защиту.



Результаты внедрены:



- при анализе качества пористого материала для компании ООО «Кнауф Гипс Кубань» (акт внедрения получен в июне 2025 года);
- при анализе гранулометрического состава для горно-обогатительного комбината (Апатиты) (акт внедрения получен в августе 2025 года);
- в работу учебно-научной лаборатории «Компьютерные технологии» в 2023–2025 года.

5.1. Использование метода слабой аннотации к задаче анализа поризации гипсокартона: компания ООО «Кнауф Гипс Кубань» (1/4)

ИТМО

Автоматическая сегментация и морфометрический анализ пор на микроскопических изображениях гипсокартона без ручной разметки.



Задача: анализ качества поризации (низкое/среднее/высокое).

Решение с использованием библиотеки: использование метода слабой аннотации (первый метод).

Конкретное использование: обучение модели сегментации AttUnet для сегментации образца гипсокартона на основе слабой разметки. Вычисление характеристик и получения статуса качества поризации.

Результаты:

1. Совпадение с экспертной разметкой: **99 %**.
2. Снижение времени обработки одного изображения с **10 мин до 1 сек.**
3. Повышение воспроизводимости анализа.
4. Подтверждена переносимость методов, разработанных для изображений пены и руды, на микроскопический домен.
5. Разработан сервис для автоматического анализа.

5.1. Использование метода слабой аннотации к задаче анализа поризации гипсокартона: компания ООО «Кнауф Гипс Кубань» (2/4)

Архитектура решения

Процесс подготовки образца



Разлив массы

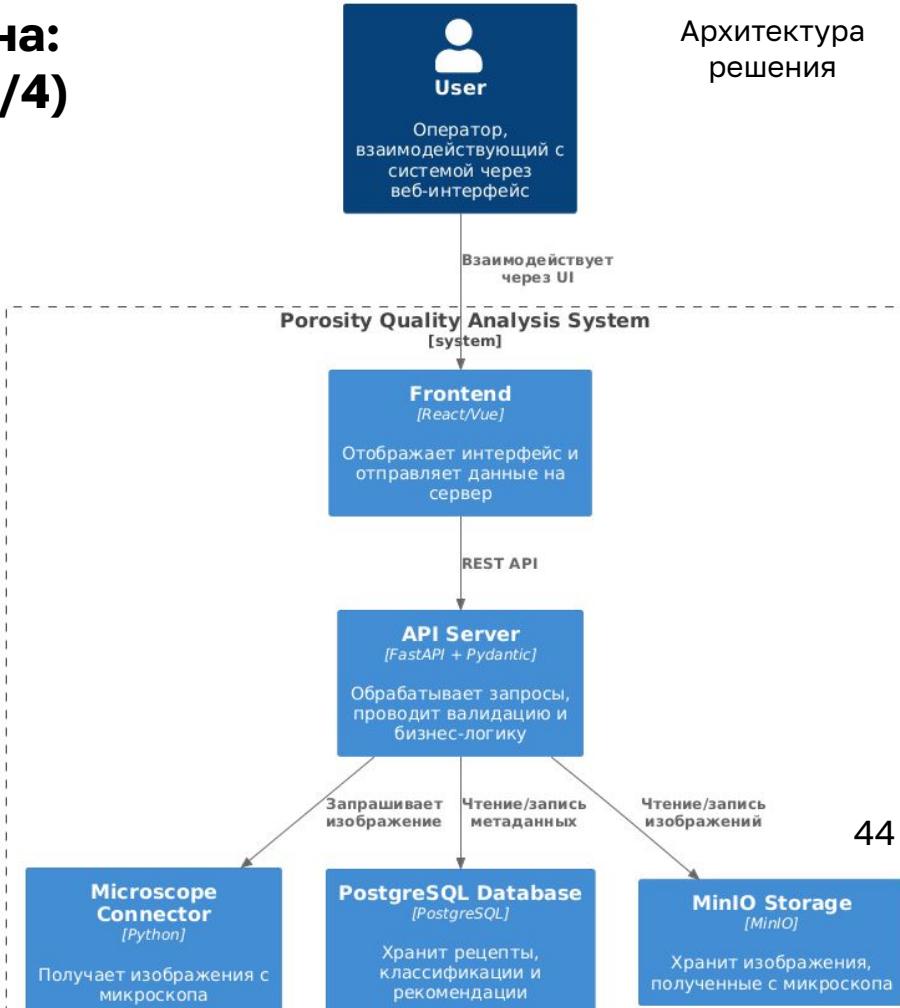


Затвердевание



Разлом для получения образца

Предыдущее решение: сравнение с фотографией образцов разного статуса поризации и принятие решения оператором на основе визуальной информации



5.1. Использование метода слабой аннотации к задаче анализа поризации гипсокартона: компания “Кнауф Гипс Кубань” (3/4)

ИТМО

STATANLY
technologies

Функционал для пользователя:

- фотография напрямую с микроскопа;
- анализ статуса поризации;
- рекомендации для устранения изменений в случае некачественной пробы;
- журнал проб и рецептов.

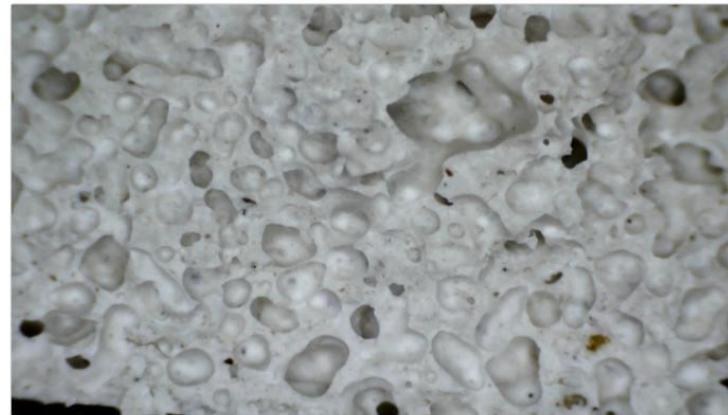
КНАУФ ГИПС КУБАНЬ

ДОБАВИТЬ РЕЦЕПТ +

Определение поризации формовочной массы

Дата взятия пробы	Время	Статус поризации	Рецепт	Способы устранения изменений
16.12.24	07:25	высокая поризация	РЕЦЕПТ	<p>1. Снизить дозировку пены без изменения соотношения.</p> <p>2. Изменение соотношения пен в сторону</p> <p>ДАЛЕЕ</p>

Контроль формовочной массы



СФОТОГРАФИРОВАТЬ

КОНТРОЛЬ ПРОБЫ

УДАЛИТЬ

5.1. Использование метода слабой аннотации к задаче анализа поризации гипсокартона: компания “Кнауф Гипс Кубань” (4/4)

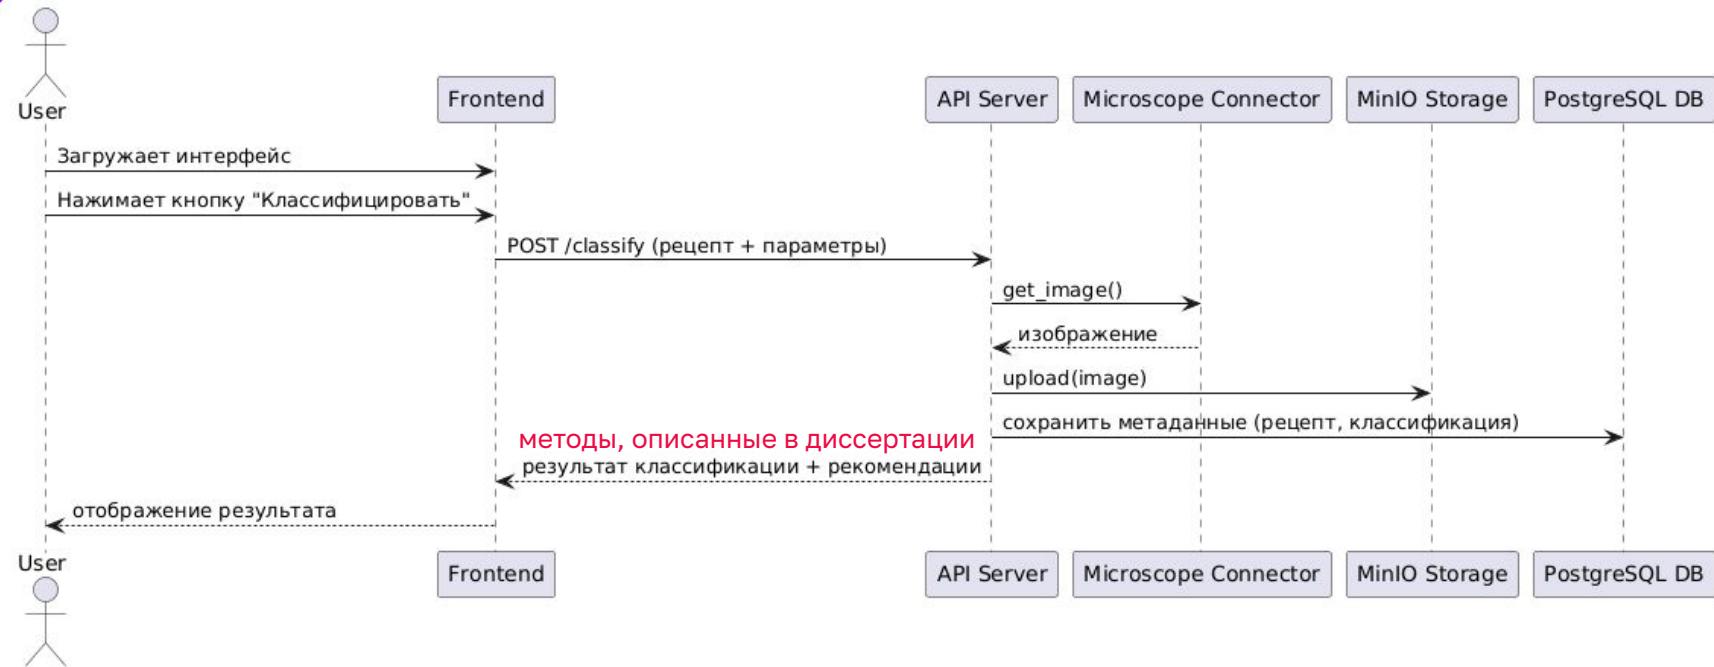


Диаграмма последовательностей процесса анализа статуса поризации

5.2. Использование метода генерации синтетических данных для решения задачи анализа гранулометрии руды (1/3)

Модуль для автоматического управления дробилкой на предприятии, расположенном в районе г. Апатиты.

Исходные данные: разработка с нуля.

Задача:

Определить гранулометрический состав руды на конвейере с использованием компьютерного зрения

Решение с использованием библиотек СТСІ-gen и СТСІ.

- генеративные данные (второй метод);
- оценка характеристик.

Конкретное использование:

- обучение модели YOLOv11 на генеративных данных, выполнение “слабой” разметки реальных фотографий на основе генеративной разметки;
- сегментация для оценки групповых характеристик (размер, число).

Результаты:

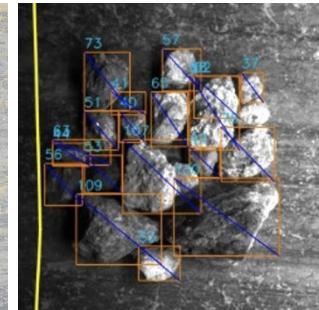
- совпадение с экспертной разметкой – 91 %;
- разработан модуль управления дробилкой на основе Modbus-TCP-сервера.



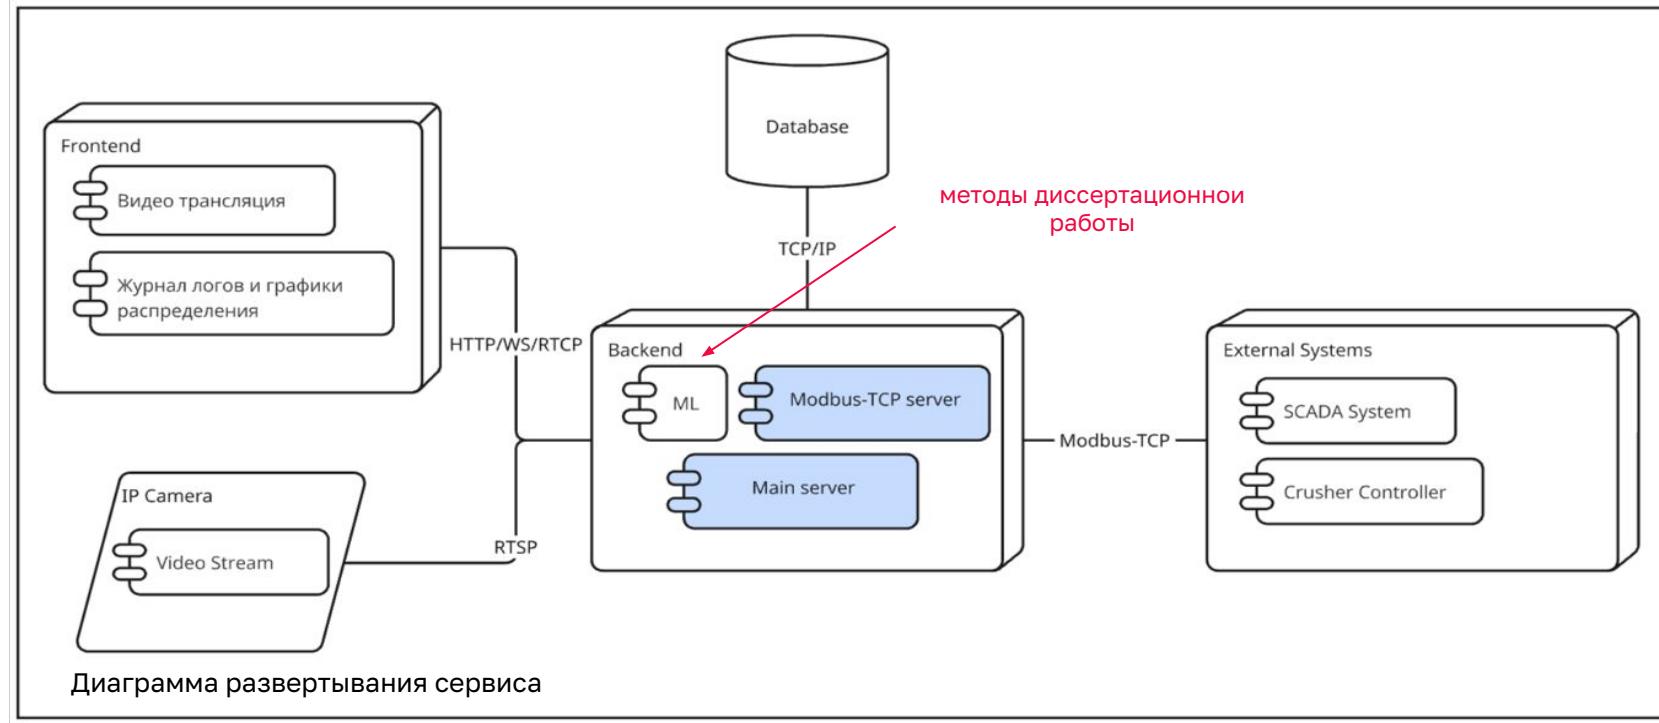
установка камеры над конвейером



проведение контрольных замеров



5.2. Использование метода генерации синтетических данных для решения задачи анализа гранулометрии руды (2/3)



5.2. Использование метода генерации синтетических данных для решения задачи анализа гранулометрии руды (3/3)

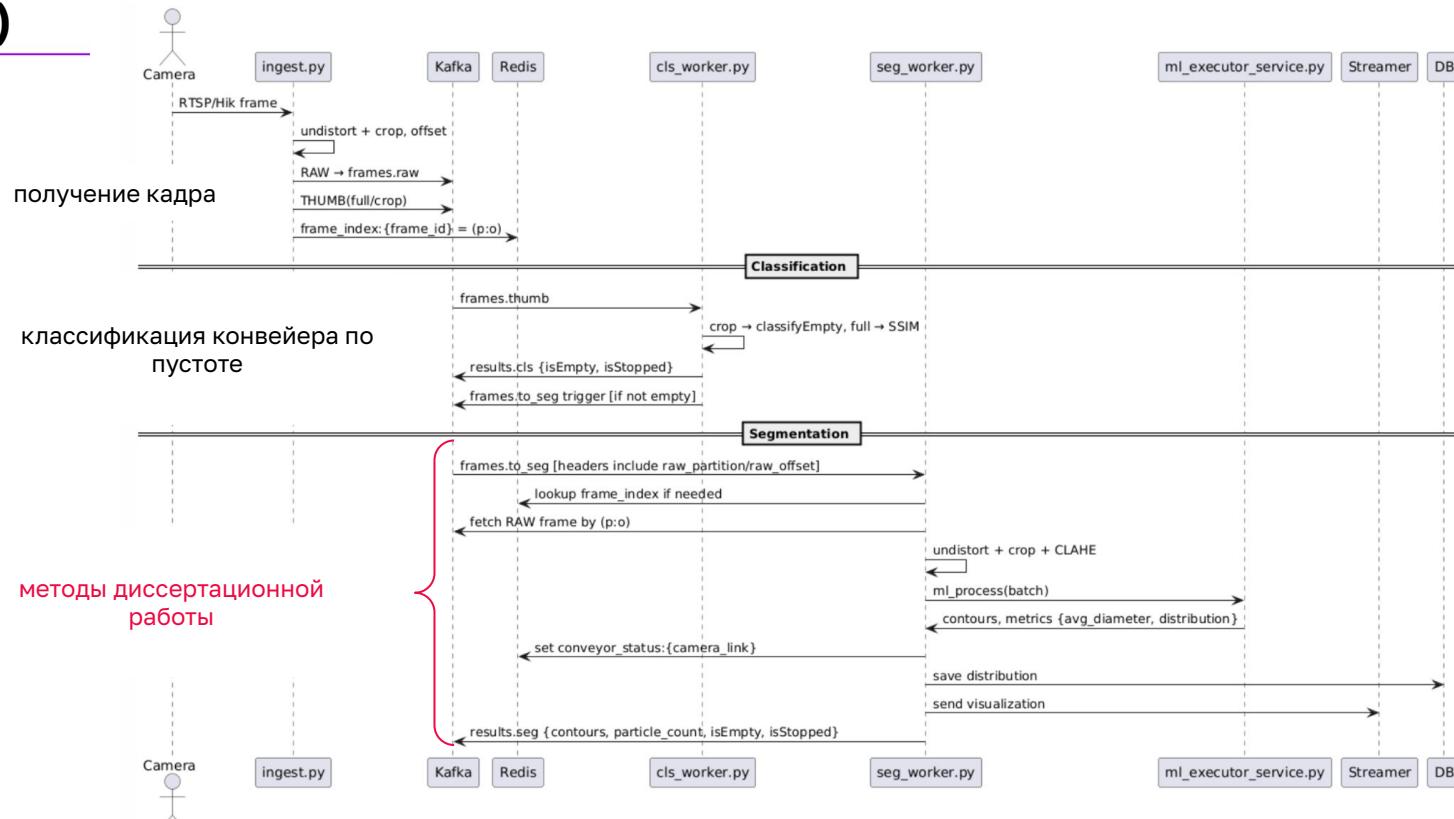


Диаграмма последовательностей работы сервиса анализа гранулометрического состава

Выводы по главе 5

1. Создана и внедрена система анализа статуса поризации с эффективностью 99% процентов с использованием компьютерного зрения, основанная на использовании методов слабой аннотации библиотеки СТСІ.
2. Создана и внедрена система анализа гранулометрического анализа руды для управления дробилкой, основанная на использовании методов создания синтетических данных библиотеки СТСІ, позволяющая управлять дробилкой с необходимой частотой.
3. Результаты подтверждают практическую значимость диссертационного исследования.



1. Разработан **метод автоматизированной слабой разметки изображений однородных плотно сгруппированных объектов**.
2. Разработан **метод генерации синтетических данных для изображений и видео однородных плотно сгруппированных объектов**, исключающих необходимость ручной разметки и обеспечивающих высокое качество обучающих наборов.
3. Разработана **библиотеки программ**, реализующих предложенные методы и обеспечивающих решение задач оценки групповых характеристик изображений и видео.
4. Проведено **экспериментального исследования предложенных подходов** на задачах, связанных с гранулометрическим анализом руды, оценкой эффективности процесса флотации и определением структуры пористых материалов.
5. Результаты внедрены в предприятиях по изготовлению гипсокартона (ООО «Кнауф Гипс Кубань») и на горно-обогатительном комбинате (г. Апатиты).

Публикации

Scopus/WoS:

1. **Rumiantceva M.**, Filchenkov A. Deep Learning and Pseudo-Labeling for Ore Granulometry // Procedia Computer Science. 2022. Vol. 212. P. 387–396 (~90 %). — X
2. **Rumiantceva M.**, Kriukov A., Prokopov E., Efimova V. Self-supervised Learning to Improve Froth Images Segmentation // Proceedings of the Ninth International Congress on Information and Communication Technology. 2024. Vol. 1055. P. 483–494 (~70 %).
3. Prokopov E., Usacheva D., **Rumiantceva M.**, Efimova V. Weak Segmentation and Unsupervised Evaluation: Application to Froth Flotation Images // Proceedings of the 20th Int. Joint Conf. on Computer Vision, Imaging and Computer Graphics Theory and Applications (VISAPP). 2025. Vol. 3. P. 500–507 (~50 %).

Свидетельство о регистрации программ:

4. Ефимова В.А., **Румянцева М.Ю.**, Прокопов Е.М., Усачева Д.М., Леманов А.А., Крюков А.Д. Программа для ЭВМ «Библиотека для анализа однородных объектов». Свидетельство о государственной регистрации № 2024 669273 от 15.08.2024 (30 %).
5. Программа для ЭВМ «Программный комплекс детекции, сегментации и нахождения ключевых точек объектов на изображении» № 2024692026 от 25.12.2024, Муравьёв С.Б., Забашта А.С., Ефимова В.А., **Румянцева М.Ю.**, Жарский И.А. (20 %).

В скобках указан личный вклад автора.

Апробация

Международные конференции:

1. Rumiantceva M. Weak Segmentation and Unsupervised Evaluation: Application to Froth Flotation Images / The 20th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications (VISIGRAPP 2025), Порту, Португалия.
2. Rumiantceva M. Self-supervised Learning to Improve Froth Images Segmentation / The 9th International Congress on Information and Communication Technology (ICICT 2024), онлайн.
3. Rumiantceva M. Deep Learning and Pseudo-Labeling for Ore Granulometry The 11th International Young Scientists Conference in Computational Science (YSC 2022), Санкт-Петербург.

Всероссийские конференции:

1. Румянцева М. Ю., Универсальные алгоритмы сегментации однородных объектов / XII Конгресс молодых ученых. 2023, Санкт-Петербург. ИТМО.
2. Румянцева М.Ю., Современные алгоритмы сегментации изображения в контексте определения контуров объектов, XI Конгресс молодых ученых. 2022, Санкт-Петербург. ИТМО.
3. Румянцева М. Ю., Распознавание контуров флотационной пены в потоке / X Конгресс молодых ученых. 2021, Санкт-Петербург. ИТМО.
4. Румянцева М. Ю., Выделение контуров на изображении / Пятидесятая научная и учебно-методическая конференция Университета ИТМО, 2021, Санкт-Петербург. ИТМО.
5. Румянцева М. Ю., Выделение контуров камней на конвейере с помощью методов компьютерного зрения / Ежегодная межвузовская научно- техническая конференция студентов, аспирантов и молодых специалистов имени Е. В. Арменского, 2021, Москва. НИУ ВШЭ.

Спасибо
за внимание!

ITMO *more than a*
UNIVERSITY