



Комплексное изучение типов сейсмоакустических фаций с использованием методов глубокого обучения в трансформном разломе Романш

Попов М.С., Борисов М.А., Борисов Д.Г.
МФТИ, Институт океанологии им. П.П. Ширшова РАН

ОПРЕДЕЛЕНИЯ

Контуриты – это осадки, отложенные и переотложенные в результате длительного, преобладающего над остальными процессами осадконакопления воздействия придонных течений.



Дрифты – это осадочные тела, сформированные главным образом под действием придонных течений.

ЗАЧЕМ ДЕТЕКТИРОВАТЬ АВТОМАТИЧЕСКИ


Осадки – это природные архивы палеоциркуляции прошлого и маркеры газовых и нефтяных ловушек

~20 000 морских миль профилей — ручной анализ невозможен

Нужна система автоматического картирования




Батиметрия района исследований (GEBCO 2024) с расположением линий сеймопрофилирования (63-ий рейс НИС «АКАДЕМИК ИОФФЕ») и общими направлениями течений ААДВ. [Попов и др. (а), 2026]



- - станции отбора проб донных осадков
- ▲ - скважины глубоководного бурения

Положение станций отбора проб донных осадков в районе исследования [Иванова и др., 2024]



Процесс разметки обработанных сейсмоакустических данных

		Схематичное изображение	Примеры акустических образов на профилях НСП		Кол-во образов
(Суб)параллельные акустические образы	A				19
	B1				6
	B2				19
	B3				225
	B4				89
	B5				38

		Схематичное изображение	Примеры акустических образов на профилях НСП		Кол-во образов
Гиперболические акустические образы	C1				141
	C2				116
	C3				73
	C4				74
	C5				76

Основные типы акустических образов отложений, выявленных в верхнем слое осадочного чехла трансформной долины Романш


[Попов и др. (б), 2026]

Датасет: 884 bbox, сильный дисбаланс классов

СОСТАВ


- 402 изображения (train + val)
- 884 bounding box, 11 классов
- Разметка: Label Studio (bounding box)
- Разбивка по рейсам (не случайно по кадрам)
- train: АИ-63 + АИ-65 · val: АИ-66

КОЛИЧЕСТВО BBOX ПО КЛАССАМ



B1, A, B2 — критически мало (< 20 объектов)

Pipeline: тайлинг → детекция → классификация



ДЕТЕКТОРЫ

- YOLOv8 n/s/m/l/x — anchor-free, один проход
- RT-DETR-L/X — трансформер, без NMS
- 640 vs 1280 px · mosaic vs rect

ОСОБЕННОСТИ GRAYSCALE-ЗАДАЧИ

- HSV-аугментации отключены (бессмысленны для одноканального изображения)
- copy_paste=0.3 для редких классов
- NMS IoU=0.4 на стыках тайлов (overlap 20%)

Стратегия: 11 классов vs 1 класс + классификатор


End-to-end 11-class YOLO



- Одна сеть одновременно локализует и классифицирует
- При малом датасете путает схожие классы
- B3 ↔ C1 ↔ C5 — потери recall

mAP@0.5 = 0.246 (val, YOLOv8l)


1-class детектор + ResNet-18 классификатор



- Детектор находит ВСЕ объекты (↑ recall)
- Классификатор работает на кропах — проще задача
- Масштабируется: новые классы без переобучения детектора
- Узкое место при малых данных — классификатор

Detector recall: mAP@0.5 = 0.589

Сравнение архитектур: mAP@0.5 (val)



mAP@0.5 — итоговая метрика детектора

Precision & Recall

1

Precision = $TP / (TP+FP)$ — доля верных детекций среди всех выданных

Recall = $TP / (TP+FN)$ — доля найденных объектов от всех GT

PR-кривая

2

Все детекции сортируются по убыванию confidence.

На каждом пороге вычисляются P и R — строится кривая $P(R)$.

AP — площадь под PR-кривой

3

AP (одного класса) = площадь под PR-кривой.

11-point interpolation: среднее Precision при $R = 0, 0.1, \dots, 1.0$.

mAP@0.5

4

mean AP = среднее AP по всем N классам (у нас $N = 11$).

@0.5 означает: детекция считается верной при $IoU \geq 0.5$.

Интерпретация

mAP = 0.0

детектор не находит ничего

mAP = 0.25

хор. результат: 11 классов, мало данных


mAP = 0.50

сильный результат для сложной задачи


mAP = 1.0

идеальный детектор

Наши результаты (model.val(), amp=False):



AP@0.5 по классам: 11-class YOLO vs 1-class + ResNet-18



Пайплайн ограничен classifier (val_аcc=44.6% на GT-кропах, 618 train-семплов)

RT-DETR: финальные результаты

- RT-DETR (Detection TRansformer) — encoder-decoder без NMS
- Лучше обрабатывает перекрытия боксов (релевантно для overlap 20%)
- Нет anchor-зависимости, глобальный контекст через attention



Лучший YOLO baseline для сравнения: YOLOv8l mosaic = 0.372

RT-DETR-L превышает лучший 11-class YOLO на +24% · copy_paste даёт дополнительный прирост

Все прогоны завершены (4× NVIDIA L40S, 200–300 эп., раннее останов по patience=60)

Выводы и планы

ТЕКУЩИЕ РЕЗУЛЬТАТЫ

- YOLOv8l 1-class: mAP@0.5 = 0.589 — лучший результат
- RT-DETR-L + copy_paste: mAP@0.5 = 0.465 (+24% vs YOLOv8l 1-class)
- RT-DETR-L 1-class: mAP@0.5 = 0.550 — конкурентен с YOLO 1-class
- B3 и B4 стабильно детектируются ($AP_{50} \geq 0.29$) — proof of concept
- Пайплайн детект+классифик архитектурно верен; узкое место — объём разметки

СЛЕДУЮЩИЕ ШАГИ

RT-DETR ✓

L+copy_paste = 0.465, X = 0.408

MoCo v3

pretraining на 50k+ тайлов без разметки

Экспедиция 2027

цель ≥ 1000 bbox → full pipeline

Картирование

автоматический анализ архива АИ-63/65/66 и др.