V конференция «Математика в Медицине»
Москва, 1-2 Декабря 2025

Стетоскоп 3.0
Трансформеры, VLM и Latent-Diffusion

Мультимодальный конвейер машинного обучения для быстрого скрининга бронхиальной астмы по дыхательным шумам

Докладчик: Аптекарев Ф. А., соискатель степени PhD, НИУ ВШЭ, Нижний Новгород

Авторы:
- Аптекарев Федор (НИУ ВШЭ),
- Соколовский Владимир (Ben-Gurion University),
- Фурман Евгений (ПГМУ им. ак. Е.А. Вагнера),
- Калинина Наталья (Пермская Краевая Клиническая Больница),
- Фурман Григорий (Ben-Gurion University)

ПЕРМСКИЙ МЕДИЦИНСКИЙ УНИВЕРСИТЕТ АКАДЕМИКА ВАГНЕРА

Проблема и мотивация

Ключевые проблемы

- 250–350 млн пациентов с БА[1]
- Нет "золотого стандарта" диагностики; до 30% неверных диагнозов[2]
- Ограничения спирометрии/аускультации: субъективность, трудности у детей
- Дефицит доступа к специалистам и оборудованию

Мотивация: объективировать и стандартизовать первичный скрининг

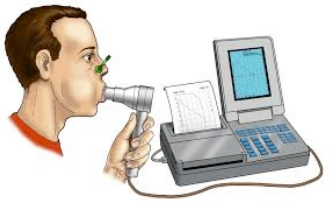

Цель и задачи

Цель

Разработать и экспериментально обосновать ML-конвейер для скрининга/поддержки диагностики бронхиальной астмы по респираторным шумам

Задачи

- Сформировать корпус дыхательных шумов
- Построить конвейер признаков (мел-спектрограммы)
- Выбрать и обучить модели
- Разработать схему синтетической аугментации
- Обеспечить интерпретируемость
- Разработать модель интеграции в систему здравоохраниения

1. - Global Initiative for Asthma, 2018 ; GBD 2019 Diseases and Injuries Collaborators, 2020
2. - “Deep learning facilitates the diagnosis of adult asthma”; Tomita et al., 2019

Эволюция методов анализа респираторных шумов (2015-2025)

До 2017

- Классические методы цифровой обработки сигналов
- Традиционный ML (SVM, GMM, HMM с ручными признаками)
- Первые эксперименты с DL

2017-2020 (до COVID19)

- Расширение экспериментов с DL
- Использование CNN, RNN
- Публикация ICBHI датасета

2020-2025

- Современный DL
- Больше open access датасетов
- Dense CNNs, Трансформеры, VLM, и т.д.

Год	Автор	Название	Что примечательного
2016	Chamberlain et al.	Application of semi-supervised deep learning to lung sound analysis	AUC 0,86/0,74 с неразмеченными данными
2017	Pramono et al.	Automatic adventitious respiratory sound analysis: A systematic review	Систематический обзор
2017	Aykanat et al.	Classification of lung sounds using convolutional neural networks	86% accuracy, сопоставимо с SVM
2017	Rocha et al.	An open access database for the evaluation of respiratory sound classification algorithms	Open access ICBHI 2017 датасет
2019	Chen et al.	Triple-Classification of Respiratory Sounds Using Optimized S-Transform and Deep Residual Networks	~98% accuracy
2019	Tomita et al.	Deep learning facilitates the diagnosis of adult asthma	~98% accuracy, AUC ~0,99
2021	Kim et al.	Respiratory sound classification for crackles, wheezes, and rhonchi in the clinical field using deep learning	~86,5% accuracy + проверили в клинических условиях
2021	Hsu et al.	Benchmarking of eight recurrent neural network variants for breath phase and adventitious sound detection on a self-developed open-access lung sound database – HF_Lung_V1	Open access HF_Lung_V1 датасет
2023	Aptekarev et al.	Application of deep learning for bronchial asthma diagnostics using respiratory sound recordings	~87% accuracy, 93% precision

Датасет

Собирался на базе ПГМУ им. ак. Е.А. Вагнера и Пермской Краевой Клинической Больнице в 2014-2020 гг.

Всего обследуемых: 1613
Пациенты с подтвержденным диагнозом: 1480
Пациенты с астмой: 1113
Единица анализа: 5-сек фрагменты
Предобработка: фильтрация/нормализация

Точка записи	Астма	Здоровый	Больной (не астма)
Трахея	563	123	101
Второе межреберье	285	9	10
Грудная клетка сзади	256	0	12
Ротовая полость	9	1	2
NA	0	0	242
Total	1113	133	367

Возрастная группа	Астма	Здоровый	Больной(не астма)
0-2	14	6	1
2-4	8	0	39
4-13	515	32	221
13-20	516	13	106
20	60	82	0
Total	1113	133	367

Диагноз	F	M	Всего
Астма (неполная ремиссия)	113	307	420
Астма (обострение)	53	131	184
Астма (ремиссия)	77	166	243
Астма (другое)	70	196	266
Здоров	52	81	133
БЛД	1	0	1
Муковисцидоз	153	90	243
ХНЗЛ	0	1	1
Пневмония	10	0	10
РОБЛ	13	84	97
Аплазия легкого	0	15	15
Total	542	1071	1613

Aptekarev T, Sokolovsky V, Furman E, Kalinina N, Furman G. Application of deep learning for bronchial asthma diagnostics using respiratory sound recordings. PeerJ Comput Sci. 2023 doi: 10.7717/peerj-cs.1173

Предварительная обработка

1. Исходный сигнал

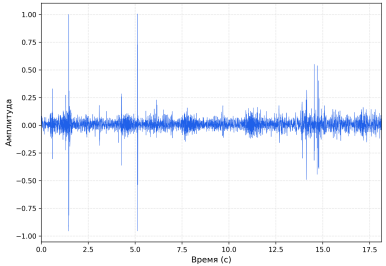

2. Фильтрация коротких записей

Устанавливаем порог по хронометражу

$$CHRONO\_THRESHOLD = 14\text{c}$$

Считаем хронометраж по частоте дискретизации

$$duration = \frac{len(waveform)}{sample\_rate}$$

Всё что меньше - бракуем

$$technical\_defect = \begin{cases} True, & \text{если } duration < 14\,c \\ False, & \text{в противном случае} \end{cases}$$

3. Фильтрация клипинг артефактов

Считаем 95й перцентиль абсолютных значений амплитуд

$$Threshold = P_{95}(|\ waveform\ |)$$

Считаем процент сэмплов попадающих в 95й перцентиль

$$\text{Clipping\%} = \frac{N_{\text{samples}} \geq \text{Threshold}}{N_{\text{total}}} \cdot 100$$

Бракуем если процент сэплов попадающих в 95й перцентиль больше чем

$$QUALITY\_THRESHOLD = 2$$

4. Обрезка сигнала

Определяем сколько будем обрезать с начала и конца

$$t_{trim} = 2c$$

Считаем сколько семплов отрезать по частоте дискретизации

$$N_{trim} = t_{trim} \cdot f_s$$

Обрезаем нужное кол-во семплов с начала и конца

$$\text{waveform}[N_{trim} : (\text{len}(\text{waveform}) - N_{trim})]$$

5. Сегментация сигнала

Определяем перекрытие и шаг смещения между клипами

$$L = T \cdot f_s \qquad S = L \cdot \left(1 - \frac{\alpha}{100}\right)$$

Рассчитываем число целых клипов которые можно получить

$$C = \left\lfloor \frac{L_{total} - L}{S} \right\rfloor + 1$$

Итерационно вырезаем нужное число целых клипов из середины

$$T_{span} = (C - 1) \cdot S + L$$

$$T_{lower} = \left\lfloor \frac{L_{total} - T_{span}}{2} \right\rfloor, \quad T_{upper} = T_{lower} + T_{span}$$

6. Нормализация клипов

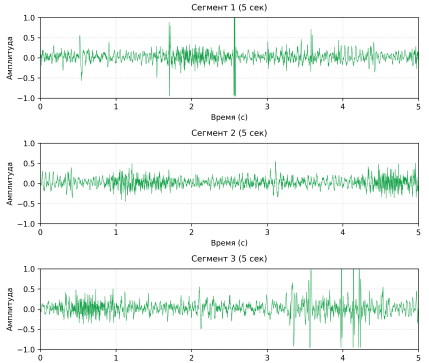

ISU

Aptekarev T, Sokolovsky V, Furman E, Kalinina N, Furman G. Application of deep learning for bronchial asthma diagnostics using respiratory sound recordings. PeerJ Comput Sci. 2023 doi: 10.7717/peerj-cs.1173

Модели и обучение

Диагностические модели

- **DenseNet201**: CNN используемая как baseline
- **AST**: Основная модель, инициализированная ViT.
- **Moondream**: Мультимодальная (спектрограмма + текст)

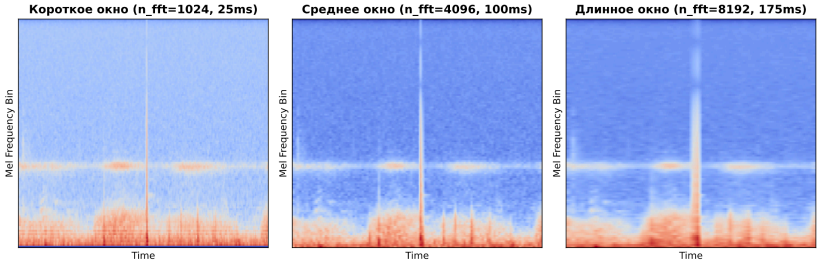

Извлечение спектральных признаков

3 STFT Окна:

- короткое (25 мс)
- среднее (100 мс)
- длинное (175 мс)

Мел-фильтры: Частотная ось преобразуется в нелинейную мел-шкалу (128 мел-коэффициентов, полоса 0-8 кГц)

Обучение и валидация

- Базовая классификация: “Астма | Не астма”
- Бутылочное горлышко при создании обучающего корпуса: записи здоровых
- Мониторинг validation loss/accuracy
- Ранняя остановка при отсутствии улучшений
- Метрики: Accuracy, Sensitivity, Youden Index

```yaml
model_name: "MIT/ast-finetuned-audioset-10-10-0.4593"

# Training parameters
num_train_epochs: 25
per_device_train_batch_size: 16
learning_rate: 0.000008
warmup_ratio: 0.25
weight_decay: 0.03
logging_steps: 1
eval_steps: 10
save_steps: 50
gradient_accumulation_steps: 4
max_grad_norm: 1.0
fp16: true

# Early stopping
early_stopping_patience: 5

# Scheduler parameters
scheduler_type: "cosine"
scheduler_warmup_steps: 150
scheduler_decay_steps: null
scheduler_decay_rate: 0.1
```

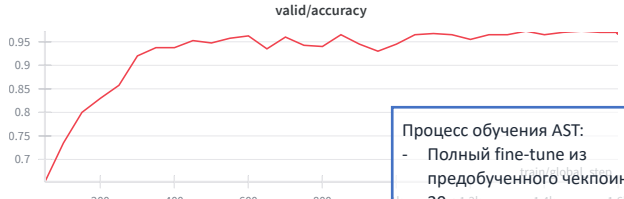

Процесс обучения AST:

- Полный fine-tune из предобученного чекпоинта
- 20 эпох
- <5 часов
- Nvidia A40 (48GB VRAM)

- “Densely Connected Convolutional Network” (Huang et al, 2017, <https://doi.org/10.48550/arXiv.1608.06993>)
- “AST: Audio Spectrogram Transformer (Gong et al, 2021 <https://doi.org/10.48550/arXiv.2104.01778>)
- <https://github.com/vikhyat/moondream>

Результаты бинарной классификации

Астма | Не астма

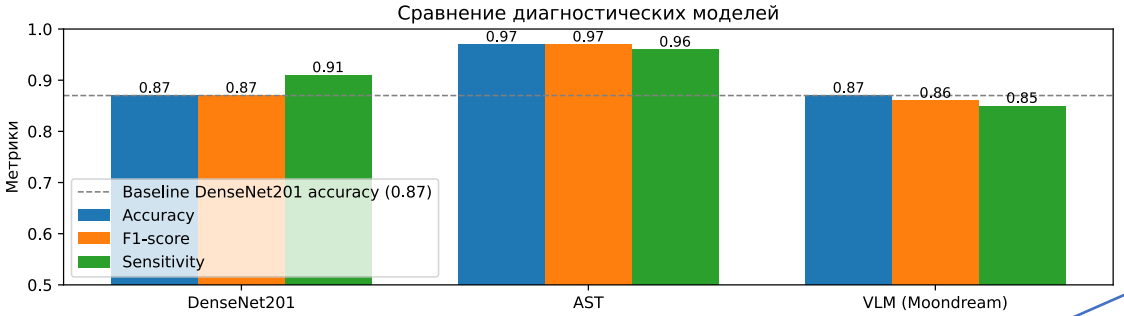

Оценка на 5-сек клипах; кросс-валидация

Процесс inference на VLM

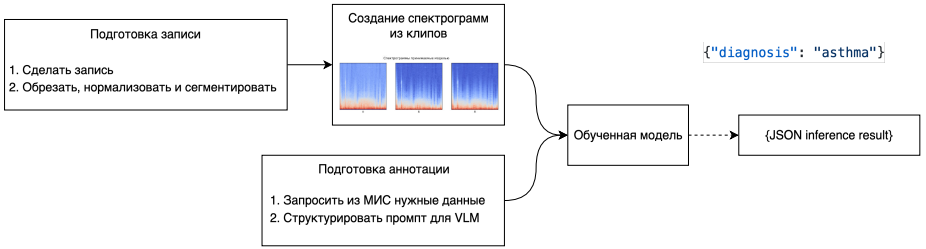


```
{
    "task": "Write a diagnosis for this patient by analyzing the respiratory sound spectrogram.",
    "patient_sex": "M",
    "patient_age": 9,
    "record_point": "posterior thoracic rib",
    "spectrogram_bins_width": "[0.025, 0.1, 0.175]"
}
```

На что смотрит модель?

Интерпретируемость: необходимое условие клинического внедрения

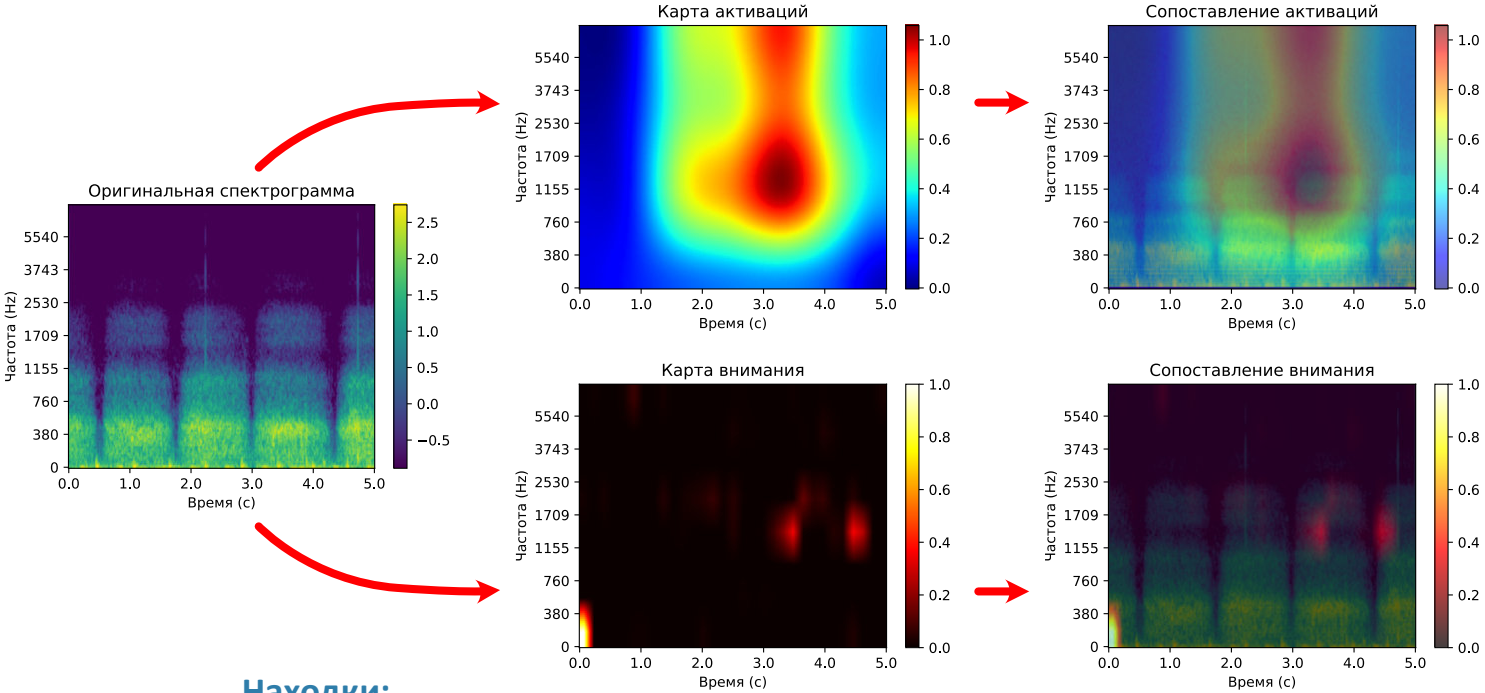

Находки:

- Совпадение фокусов на удлиненном выдохе и характерных зонах
- Подтверждение представлений о клинических проявлениях патологии

Синтетическая аугментация

```
{
    "prompt": "Breath sample from F 8yo diagnosed with bronchial asthma",
    "seconds_start": 0,
    "seconds_total": 5
},
```

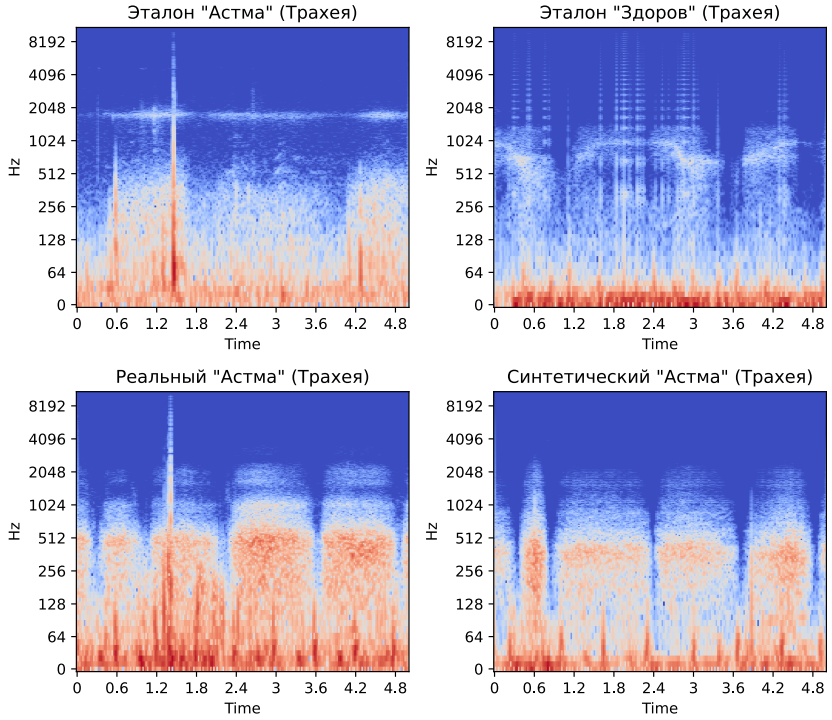

Вопрос: как валидировать синтетику?

Точность диагностического классификатора: ≈95.2%

Идея: ИИ проверяет ИИ

Цель: борьба с дисбалансом и дефицитом данных

Процесс генерации

Текстовые/акустические условия

↓

Stable Audio Open (адаптация)

↓

Синтетические дыхательные сигналы

Parameter	Pretraining	Asthma FT	Healthy FT
Steps	250	200	200
CFG scale	[3,6,9]	6.5	5.5
Temperature	1	0.9	0.95
Top-k	100	50	100

Stable Audio Open, Evans et al., 2024 <https://doi.org/10.48550/arXiv.2407.14358>

Интеграция в систему здравоохранения

Федеративная схема

Центральная модель (НИИ) → распределение в клиники → локальное дообучение → агрегация весов (FedAvg) → обновленная базовая модель

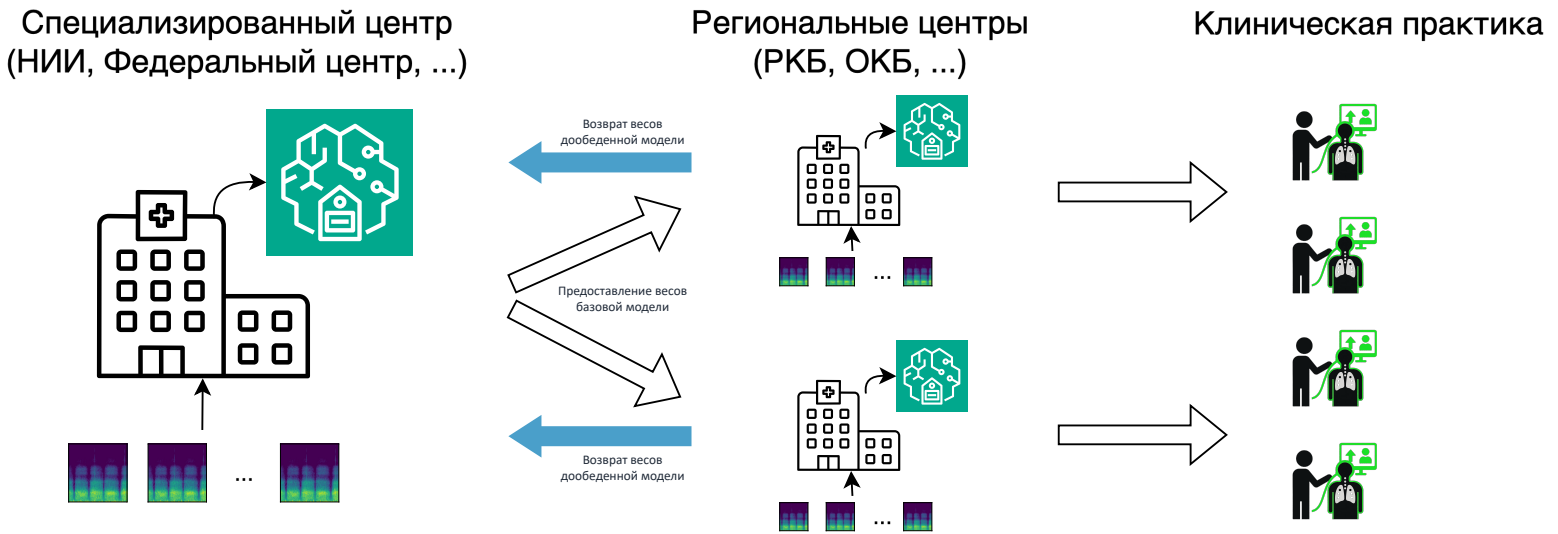

Преимущества подхода

- Конфиденциальность: данные не покидают учреждение
- Переносимость: локальная адаптация под популяцию/оборудование
- Обновляемость: периодическая синхронизация

“Communication-Efficient Learning of Deep Networks from Decentralized Data”, McMahan et al. 2016 <https://doi.org/10.48550/arXiv.1602.05629>

Ограничения, выводы и следующие шаги

Ограничения

- Нужна экспертная валидация синтетики и клиническая верификация
- Расширение за пределы бинарной задачи (ХОБЛ, муковисцидоз)
- Стандартизация отчета для врача

Выводы

- ML-конвейер демонстрирует высокую точность (AST ≈97%) и объяснимость
- Синтетика помогает с дефицитом данных (≈95.2%)
- Федеративная схема обеспечивает приватность и адаптацию

Благодарю за внимание! Вопросы приветствуются.

aptekarev@gmail.com

Ссылка на репозитория с демонстрацией и весам